
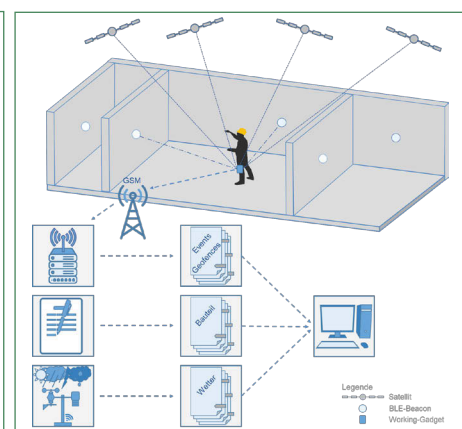
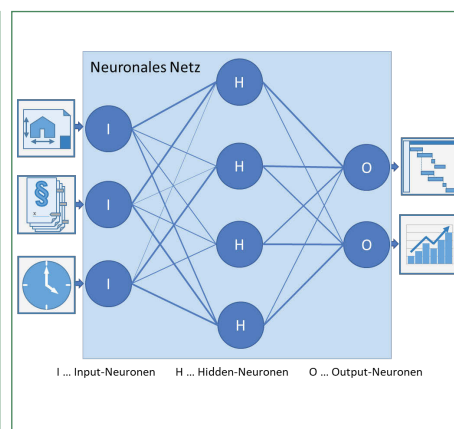
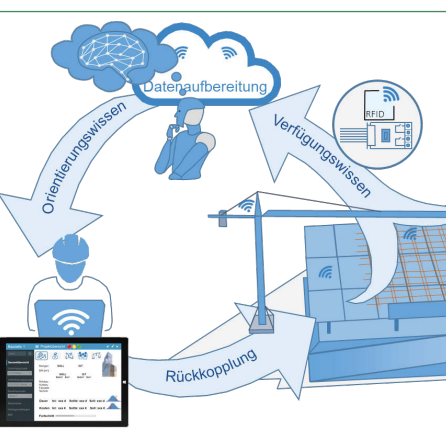


# schriftenreihe

## Heft 48



### Einsatzpotenzial neuronaler Netze im Baubetrieb und in der Bauwirtschaft

Von der automatischen Datenerfassung bis hin zur Tätigkeitsklassifikation anhand erhobener Bewegungsmuster

Ralph Stöckl, DDipl.-Ing. Dr.techn.

Ralph Stöckl

# **Einsatzpotenzial neuronaler Netze im Baubetrieb und in der Bauwirtschaft**

**Von der automatischen Datenerfassung bis hin zur  
Tätigkeitsklassifikation anhand erhobener Bewegungsmuster**

**Schriftenreihe des Instituts für Baubetrieb und Bauwirtschaft  
der Technischen Universität Graz**

**Heft 48**

# **Einsatzpotenzial neuronaler Netze im Baubetrieb und in der Bauwirtschaft**

**Von der automatischen Datenerfassung bis hin zur  
Tätigkeitsklassifikation anhand erhobener Bewegungsmuster**

von  
Ralph Stöckl

herausgegeben vom  
Institut für Baubetrieb und Bauwirtschaft der Technischen Universität Graz

Verlag der Technischen Universität Graz

Graz 2023

# EINSATZ NEURONALER NETZE IM BAUBETRIEB UND IN DER BAUWIRTSCHAFT

Von der automatischen Datenerfassung bis hin zur Tätigkeitsklassifikation anhand erhobener Bewegungsmuster

## AUTOR

DDipl.-Ing. Dr.techn. Ralph Stöckl

## BEGUTACHTER

Assoc.-Prof. Dipl.-Ing. Dr.techn. Christian Hofstadler

Univ.-Prof. Dr.-Ing. Christoph Motzko

Univ.-Prof. Dr.-Ing. Mike Gralla

## HERAUSGEBER

Assoc.Prof. Dipl.-Ing. Dr.techn. Christian Hofstadler

Univ.-Prof. Dr.-Ing. Detlef Heck

Institut für Baubetrieb und Bauwirtschaft

Technische Universität Graz

Lessingstraße 25/II

8010 Graz

Telefon +43 (0) 316 / 873 6251

E-Mail sekretariat.bbw@tugraz.at

Web www.bbw.tugraz.at

Druck: Buchschmiede (Dataform Media GmbH, Wien)

2023, Verlag der Technischen Universität Graz

www.tugraz-verlag.at

ISBN print 978-3-85125-941-4

ISBN e-book 978-3-85125-942-1

DOI 10.3217/978-3-85125-941-4



Dieses Werk ist lizenziert unter einer Creative Commons Namensnennung - Nicht kommerziell - Keine Bearbeitungen 4.0 International (CC BY-NC-ND 4.0) Lizenz. <http://creativecommons.org/licenses/by-nc-nd/4.0/>.

Diese CC-Lizenz gilt nicht für das Cover, Materialien von Dritten (anderen Quellen zugeschrieben) und anderweitig gekennzeichnete Inhalte.

## Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://www.dnb.de> abrufbar.

Die vorliegende Dissertation wurde im Dezember 2022 der Fakultät für Bauingenieurwesen der TU Graz zur Erlangung des akademischen Grades Doktor der technischen Wissenschaften (Dr.techn.) vorgelegt und angenommen.

# Vorwort

Die digitale Vernetzung der Prognose-, Planungs-, Steuerungs-, Kontroll-, Auswahl-, Organisations-, Kommunikations-, Dokumentations- und Wissensmanagementprozesse bietet enormes Potenzial für Weiterentwicklungen im Bereich des Bauwesens. Dadurch können Gebäude umweltfreundlicher geplant, gebaut und betrieben sowie Chancen und Risiken früher erkannt und verstärkt bzw. minimiert werden. Neben der Generierung von Orientierungswissen dienen Daten auch dem spezifischeren Bereich der Kennzahlengewinnung. Daten nehmen zudem eine wichtige Funktion für die Kontrolle, den Vergleich und die Steuerung ein, sie sollten dabei aber immer zielgerichtet eingesetzt und kontextbezogen interpretiert werden, um die richtigen Schlüsse aus den Ergebnissen zu ziehen. Es ist schon vor dem Einsatz der Sensorik zur Datengewinnung zu definieren, welche Kennzahlen zu ermitteln sind. Um einen ganzheitlichen Ansatz zu gewährleisten, bietet sich dabei der Einbezug von Analyse- und Visualisierungstools an, mit denen zunächst unerkannte Datenstrukturen sichtbar gemacht werden können. Dies ermöglicht die Berücksichtigung konkret definierter und anwendungsorientierter Grenzwerte, bei deren Überschreitung ein Frühwarnsystem aktiviert wird. Durch damit ausgestattete Rückkopplungsprozesse werden beispielsweise Gegensteuerungsmaßnahmen direkt an den Produktionsprozess weitergegeben, ehe anschließend anhand des Monitorings überprüft wird, ob mit den Maßnahmen die intendierten Wirkungen erreicht wurden oder nicht.

Neben der soeben aufgezeigten geführten Umwandlung von Verfügungswissen in Orientierungswissen wird auch beim Planen, Bauen und Betreiben vermehrt Data Mining implementiert. Unter diesem Begriff werden komplexe Analysen von Datenbeständen zur Entdeckung (verborgener) Strukturen und Muster durch Verfahren der Statistik und der künstlichen Intelligenz verstanden, die automatisch (geführt und/oder ungeführt) Orientierungswissen generieren. Eine ausreichende Datenmenge bildet die notwendige Basis dafür.

Im Zeitalter der digitalen Revolution ist ein Tag ohne künstliche Intelligenz kaum vorstellbar: selbstständig fahrende Autos, Bilderkennung, lernfähige Roboter und Spracherkennung erleichtern in dafür geeigneten Bereichen den menschlichen Alltag. Die künstliche Intelligenz stellt ein Teilgebiet der Informatik dar und wird von *Rich/Knight/Nair* auf folgende Art definiert: "Artificial Intelligence is the study of how to make computers do things at which, at the moment, people are better". Künstliche Intelligenz beschreibt somit Forschungsbestrebungen, die es sich zum Ziel gesetzt haben, einem Computer beizubringen, Aufgaben zu lösen, die der Mensch im Moment noch besser bewältigen kann. Das heißt, Maschinen müssen die Fähigkeit besitzen, zu lernen. Diese "Begabung", bestehendes Wissen auf neue Aufgaben anwenden zu können, wird durch maschinelle Lernverfahren, welche ein Teilgebiet der künstlichen Intelligenz darstellen, trainiert. Das Ziel beim maschinellen Lernen besteht darin, aus den gesammelten klassifizierten Daten eine Funktion zu generieren, mit deren Hilfe anschließend neue Inputparameter ausgewertet werden können. Hierbei zählen neuronale Netze zu den verbreitetsten Methoden.

Durch die stark angestiegene Rechenleistung von Computern sind neuronale Netze zu einem geeigneten Werkzeug für das Lösen technischer Aufgaben aus dem Bereich der Klassifizierung und der Prognose geworden. Um Problemstellungen bestmöglich zu bewältigen, ist es wichtig, den Aufbau und die Anwendungsbereiche der einzelnen Netztypen zu kennen. Hierbei empfiehlt es sich, in der Fachliteratur nach ähnlichen Problemstellungen zu suchen und das beschriebene Netz an die eigene Aufgabe anzupassen.

Die Bedeutung und die Aktualität der geschilderten Thematik wurden vom Dissertanten Herrn DDipl.-Ing. Ralph Stöckl zum Anlass genommen, sich im Kontext des Bauwesens mit dem Thema der künstlichen Intelligenz wissenschaftlich auseinanderzusetzen. Dabei werden ausgehend von einer umfassenden Situationsanalyse im Zuge einer Literaturrecherche sowie Softwareanalyse und von unstrukturierten Expert\*innengesprächen Potenziale und Anwendungsmöglichkeiten der künstlichen Intelligenz für baubetriebliche und bauwirtschaftliche Fragestellungen ermittelt. Durch Anwendung eines hermeneutischen Forschungsprozesses sowie des Systems Engineering werden die Wissens- und Erkenntniserweiterung vorangetrieben und daraus Forschungsfragen generiert.

Als wesentliches Ergebnis werden aus den Erkenntnissen Handlungsempfehlungen zur Implementierung künstlicher Intelligenz in den Baubetrieb und die Bauwirtschaft abgeleitet. Darüber hinaus werden Antworten auf grundsätzliche Fragen zum systematischen Umgang mit künstlicher Intelligenz geliefert. Dazu zeigt Herr Stöckl anhand sehr anschaulicher und nachvollziehbarer Praxisbeispiele, wie künstliche Intelligenz funktioniert und nutzbringend für baupraktische Fragestellungen eingesetzt werden kann.

Graz, im Jänner 2023

Christian Hofstadler  
Assoc.Prof. Dipl.-Ing. Dr.techn.

# Vorwort des Verfassers

Der Begriff der Künstlichen Intelligenz (KI) ist in aller Munde. Sie unterstützt uns bereits tatkräftig im Alltag – beispielsweise bei der Bild- und Spracherkennung oder mit intelligenten Musik- bzw. Videovorschlägen – und nimmt uns einfache Tätigkeiten ab. Den Menschen selbst wird sie aber aufgrund seiner kreativ-konzeptionellen Fähigkeiten niemals ersetzen.

Trotz der vielfältigen Anwendungsmöglichkeiten in anderen Branchen wird die KI im Bauwesen derzeit nur vereinzelt eingesetzt. Um dieser Situation entgegenzuwirken, möchte ich im Rahmen einer Dissertation dazu beitragen, der künstlichen Intelligenz den Weg auf die Baustelle zu ebnen und dabei helfen, die vollen Potenziale dieser Technologie auszuschöpfen.

Mit dem Abschluss des Doktoratsstudiums habe ich ein großes Ziel in meiner beruflichen Laufbahn erreicht. Die letzten Jahre auf der TU Graz waren zwar arbeitsintensiv, jedoch ist die Zeit schnell vergangen, da ich wunderbare Wegbegleiterinnen und Wegbegleiter hatte, die mich unterstützten. Dafür sage ich vielmals Danke!

Ganz herzlich möchte ich mich bei Prof. Christian Hofstadler für die ausgezeichnete Betreuung bedanken! Trotz seines vollen Terminkalenders nahm er sich immer sofort Zeit für meine Anliegen, wodurch ich stets rasch weiterarbeiten konnte. Auch die hilfreichen Anregungen und Diskussionen bei unseren gemeinsamen Mittagessen werden mir sehr gut in Erinnerung bleiben. Neben der Unterstützung bei meinem Dissertationsvorhaben möchte ich auch die spannenden Forschungsprojekte hervorheben, welche wir in bester Zusammenarbeit erfolgreich umsetzen konnten.

Ein besonders lieber Dank gebührt meinen Eltern, Anita und Gerd, die mich mein Leben lang mit vollster Kraft gefördert haben. Es ist bei weitem nicht selbstverständlich, eine solch fürsorgliche Unterstützung zu bekommen. Ebenso ist es mir ein großes Anliegen, mich bei meinem Bruder Christoph zu bedanken, der mein Interesse an künstlicher Intelligenz ursprünglich geweckt hat und mir immer mit Rat und Tat zur Seite steht.

Neben interessanten Forschungsprojekten zählt das Arbeitsumfeld zu den wichtigsten Erfolgsfaktoren beim Doktorat – hierbei hätte ich es nicht besser erwischen können, denn wenn die Arbeitskolleginnen und Arbeitskollegen zu Freunden werden, ist die beste Voraussetzung gegeben. Aufgrund dieser optimalen Bedingungen hatte ich immer jemanden, um alle Themen zu besprechen, die mich gerade beschäftigen. Jeder Tag mit euch an der Uni bereitete mir große Freude. Danke!

Abschließend möchte ich noch Prof. Motzko und Prof. Gralla für die hilfreichen Anmerkungen und die Begutachtung meiner Dissertation sowie Markus Kummer für die unterstützenden Ratschläge danken.

Graz, im Jänner 2023

Ralph Jakob Stöckl  
DDipl.-Ing. Dr.techn.





# Kurzfassung

Wir begegnen künstlicher Intelligenz nahezu täglich. Sei es bei selbstfahrenden Autos, Gesichts-, Bild- oder Spracherkennung, personalisierter Werbung, individuell abgestimmten Musikvorschlägen, Smart Homes, Wetter- und Sportberichten oder beim Einkaufen. Die hierbei eingesetzten neuronalen Netze ermöglichen auf Basis effizienter Datenanalysen das Erstellen von effektiven Vorhersagen, welche den menschlichen Alltag wesentlich erleichtern.

Aus diesem Grund setzen mittlerweile zahlreiche Branchen wie beispielsweise die Medizin, der Verkauf oder die Automobilindustrie auf künstliche Intelligenz, um Arbeitsprozesse zu verbessern. Der Baubetrieb und die Bauwirtschaft greifen bisher noch vergleichsweise wenig auf die Potenziale neuronaler Netze zurück.

Um den Weg der künstlichen Intelligenz auf die Baustelle zu ebnen, verfolgt die vorliegende Arbeit das Ziel, einen ganzheitlichen Ansatz für die Anwendung neuronaler Netze aufzuzeigen, welcher alle notwendigen Schritte von der Datenerhebung bis hin zur Modellbildung beinhaltet. Hierfür werden zunächst die theoretischen Grundlagen erläutert und anhand ausgewählter Prognosebeispiele, welche die Wichtigkeit der Verteilungsanalyse von Trainings- und Testdaten hervorheben, vertieft. Anschließend stehen sowohl baufertige als auch baubetriebliche und bauwirtschaftliche Einsatzmöglichkeiten im Fokus der Betrachtung, wobei die Inputparameterauswahl für Vorhersagen des Gesamt-Aufwandswertes und der Produktivitätsverluste eine tiefere Betrachtung erfährt.

Basierend auf einer umfassend durchgeführten Literaturrecherche wird gezeigt, dass ein wesentlicher Grund, weshalb künstliche Intelligenz bei Kosten-, Dauer- oder Produktivitätsprognosen bisher keine breite Anwendung findet, in der Datenverfügbarkeit liegt. Die vorhandenen Datensätze weisen häufig eine zu geringe Fallanzahl auf und eignen sich infolgedessen nicht für den Einsatz im Zusammenhang mit künstlicher Intelligenz. Aus diesem Grund werden fünf Konzepte zur automatischen Erhebung der Lohnstunden mit gleichzeitiger Bereichs- und Tätigkeitszuordnung erarbeitet. Anschließend wird aus diesen Konzepten eines ausgewählt und während der Stahlbetonarbeiten auf einer Baustelle evaluiert. Als Ergebnis ist festzuhalten, dass sich globale Navigationssatellitensysteme in Kombination mit Beacons basierend auf Bluetooth Low Energy sehr gut für diese Aufgabenstellung eignen, weil sie sowohl innerhalb als auch außerhalb des Bauwerks eine zuverlässige Datenerfassung ermöglichen.

Aufbauend auf die erhobenen Daten wird abschließend die Vorgehensweise beim Einsatz neuronaler Netze am Beispiel einer Klassifikation verdeutlicht. Diese verfolgt das Ziel, Schalen, Bewehren und Betonieren anhand der Bewegungsmuster der Arbeitskräfte zu erkennen. Hierbei stellt sich im Zuge des iterativen Modellierungsprozesses heraus, dass neuronale Netze ein großes Potenzial bei der Klassifizierung ausgewählter Tätigkeiten – basierend auf Dauer, Distanz, Anzahl der Wege und Lagerbesuche sowie durchschnittlicher und maximaler Geschwindigkeit – aufweisen.

# Abstract

We use artificial intelligence almost every day. Be it in self-driving cars, face, image, or voice recognition, personalised advertising, music suggestions, smart homes, weather, and sports reports, or shopping. These neural networks enable effective predictions based on efficient data analyses, which make human life much easier.

For this reason, numerous industries, such as medicine, sales, or the automotive industry, are now relying on artificial intelligence to improve their work processes. However, the construction industry has made comparatively little use of the potential of neural networks yet.

To pave the way for artificial intelligence on the construction site, this PhD thesis aims to present a holistic approach for the application of neural networks, which includes all necessary steps from data collection to model building. For this purpose, first, the theoretical background is explained and deepened through selected forecast examples, which emphasise the importance of the distribution analysis of training and test data. Subsequently, the focus is on use cases in construction management and economics, whereby the input parameter selection for predictions of the labour consumption rate and the productivity losses is examined in greater depth.

In the next step, the extensive literature review has shown that one major reason why artificial intelligence is not widely used in cost, duration, or productivity forecasting is data availability. The used data sets often have few cases. Thus they are not suitable for being analysed by artificial intelligence. For this reason, five concepts for the automatic collection of working hours with simultaneous area and activity allocation are developed. Subsequently, one of these concepts is selected and evaluated during reinforced concrete work on a construction site. The result is that global navigation satellite systems in combination with beacons based on Bluetooth Low Energy are very well suited for this task because they enable reliable data collection inside and outside the building.

Based on the collected data, the procedure for using neural networks is then illustrated. This example pursues the goal of recognising formwork, reinforcement, and concreting activities based on the workers' movement patterns. During the iterative modelling process, it turns out that neural networks have great potential in the classification of selected activities based on duration, distance, number of ways, and warehouse visits as well as average and maximum speed.

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung .....</b>	<b>1</b>
1.1	Einführung und Hintergründe der Arbeit .....	1
1.2	Zielsetzung und Forschungsfragen.....	4
1.3	Wissenschaftliche Einordnung der künstlichen Intelligenz.....	4
1.4	Forschungsmethodik.....	6
1.5	Inhaltliche Abgrenzung der Dissertation .....	10
1.6	Vorgehensweise und Gliederung der Arbeit .....	11
<b>2</b>	<b>Theoretische Grundlagen .....</b>	<b>15</b>
2.1	Einführung.....	15
2.2	Von der künstlichen Intelligenz zu neuronalen Netzen .....	19
2.2.1	Nachahmung der Funktionsweise des menschlichen Gehirns .....	22
2.2.2	Mathematischer Hintergrund.....	24
2.2.3	Funktionen .....	27
2.2.4	Die Fähigkeit zu lernen .....	32
2.3	Eingesetzte Software – NeuralTools.....	34
2.4	Einführungsbeispiele.....	37
2.4.1	Prognose des Gesamt-Aufwandswertes für Stahlbetonarbeiten auf Basis zufällig erstellter Datensätze....	37
2.4.2	Prognose des Aufwandswertes beim Bewehren von Stützen.....	48
<b>3</b>	<b>Anwendungsmöglichkeiten künstlicher Intelligenz .....</b>	<b>57</b>
3.1	Bauferne Anwendungsbereiche .....	57
3.2	Allgemeine Herangehensweise .....	64
3.3	Bauwirtschaftliche und baubetriebliche Anwendungsmöglichkeiten .....	68
3.3.1	Einsatzmöglichkeiten in Abhängigkeit der Projektphasen .....	68
3.3.2	Neuronale Netze für Produktivitätsprognosen .....	79
3.3.3	Neuronale Netze im Tunnelbau .....	85
3.3.4	Neuronale Netze bei Stahlbetonarbeiten .....	86
3.4	Literaturanalyse Einsatz neuronaler Netze .....	90
3.4.1	Kostenprognose.....	90
3.4.2	Prognose von Kosten und Dauer.....	95
3.4.3	Prognose der Dauer.....	96
3.4.4	Produktivitätsprognose .....	98
3.4.5	Weitere Anwendungsmöglichkeiten.....	101
3.4.6	Auswertung der Literaturanalyse .....	109

<b>4</b>	<b>Automatische Datenerhebung.....</b>	<b>115</b>
4.1	Sensoren – Funktionsweise und Einsatzmöglichkeit.....	115
4.2	Datenübertragung.....	120
4.3	RFID – Radio-Frequency Identification .....	124
4.4	Ortung.....	133
4.5	Prototypische Systementwicklung .....	139
4.5.1	Anforderungsanalyse .....	139
4.5.2	Systementwurf .....	140
4.6	Systemauswahl .....	143
<b>5</b>	<b>Fallstudienbezogene Systemimplementierung .....</b>	<b>145</b>
5.1	Vorstellung des Bauprojekts .....	145
5.2	Systembeschreibung und Funktionsweise .....	148
5.2.1	Working Gadget (GPStracer WG-1030) .....	149
5.2.2	BLE-Beacons (Blue Puck ID).....	150
5.2.3	Datenaufbereitung .....	151
5.2.4	Funktionsweise .....	153
5.3	Systemevaluation .....	157
<b>6</b>	<b>Exemplarische Vorgehensweise bei einer Klassifikation mittels neuronaler Netze.....</b>	<b>161</b>
6.1	Vorgehensweise und Parameterauswahl .....	161
6.2	Basisdatensatz .....	163
6.3	Modellbildung durch Begrenzung der Dauer .....	167
6.3.1	Zufällig ausgewählter Datensatz 1.....	168
6.3.2	Zufällig ausgewählter Datensatz 2.....	172
6.3.3	Zufällig ausgewählter Datensatz 3.....	177
6.3.4	Zufällig ausgewählter Datensatz 4.....	181
6.3.5	Zufällig ausgewählter Datensatz 5.....	186
6.3.6	Modellvalidierung mittels Testdaten.....	190
6.4	Modellbildung basierend auf Abbruchkriterien .....	196
6.4.1	Subdatensatz mit 10-minütigem Abbruchkriterium .....	197
6.4.2	Modellvalidierung des 10-minütigen Abbruchkriteriums mittels der Testdaten .....	202
6.4.3	Subdatensatz mit 20-minütigem Abbruchkriterium .....	208
6.4.4	Modellvalidierung des 20-minütigen Abbruchkriteriums mittels der Testdaten .....	213
6.4.5	Subdatensatz mit 30-minütigem Abbruchkriterium .....	219
6.4.6	Modellvalidierung des 30-minütigen Abbruchkriteriums mittels der Testdaten .....	224
6.4.7	Vergleich der Modellvalidierungen basierend auf dem 10-, 20- und 30-minütigen Abbruchkriterium.....	230
6.5	Tätigkeitsreduktion auf Schalen und Betonieren .....	232

6.5.1	Modellvalidierung von Schalen und Betonieren mittels der Testdaten .....	236
6.6	Zusammenfassung des Modellbildungsprozesses .....	238
<b>7</b>	<b>Zusammenfassung .....</b>	<b>241</b>
7.1	Beantwortung der Forschungsfragen.....	242
7.2	Nutzen der Arbeit .....	245
7.3	Ausblick und weiterer Forschungsbedarf.....	246
<b>8</b>	<b>Literaturverzeichnis .....</b>	<b>249</b>
8.1	Bücher und Buchkapitel .....	249
8.2	Zeitschriften- und Fachartikel.....	252
8.3	Internetquellen .....	260
8.4	Masterarbeiten und Dissertationen .....	262
8.5	Tagungs- und Kongressbeiträge.....	263
8.6	Vorträge, Präsentationen, Workshop- und Vorlesungsunterlagen .....	265
8.7	Dokumentationen und Interviews.....	265
8.8	Anwenderinformationen, Produktbeschreibung und Normen .....	266



## 1 Einleitung

Die vorliegende Dissertation beschäftigt sich mit dem Einsatz künstlicher Intelligenz, um Prognosen und Klassifizierungen im Bereich des Baubetriebs und der Bauwirtschaft zu erstellen. Weiters werden Sensoren sowie Ortungstechnologien näher beleuchtet, damit auf Baustellen die für das Lernen notwendigen Inputparameter automatisch erhoben werden können.

Die nachfolgende Einleitung stellt zunächst die Hintergründe der Arbeit, die wissenschaftliche Einordnung und die angewandte Forschungsmethodik dar. Abschließend erfolgt die inhaltliche Abgrenzung der Dissertation, welche sich aus der Zielformulierung ergibt, sowie die Erläuterung der Vorgehensweise und der Gliederung.

### 1.1 Einführung und Hintergründe der Arbeit

Aufwandswerte gehören neben Leistungswerten, Produktivitätsansätzen und Materialkosten zu den wichtigsten Vertretern in der Gruppe der Einflussfaktoren bei der Bildung des Angebotspreises von Bauprojekten, welcher in Österreich meist in Lohn und Sonstiges gegliedert wird. Der Lohnanteil einzelner Leistungspositionen ergibt sich aus der Multiplikation des Mittellohnpriees mit dem dazugehörigen Aufwandswert. Bei arbeitsintensiven Aufgaben kommt daher der Ermittlung dieser Beziehungszahl eine besondere Bedeutung zu, da bereits kleine Abweichungen große Auswirkungen auf den Angebotspreis mit sich bringen.

In der Praxis haben sich bei der Bestimmung der Arbeitsdauer verschiedene Herangehensweisen etabliert. Das Schätzen mit Hilfe des Bauchgefühls oder die Anwendung einer Standardkalkulation sind weit verbreitet. Eine neuartige, effektive und effiziente Methode stellt die Zuhilfenahme von künstlicher Intelligenz dar. Neuronale Netze können Aufwandswerte aus vergangenen Projekten erlernen und mit diesem Wissen Vorhersagen für neue Bauvorhaben tätigen. Diese Technologie kann jedoch nicht nur in der Angebotsphase, sondern über die gesamte Projektdauer hinweg erfolgreich bei Prognosen oder Klassifizierungen eingesetzt werden. Hierzu zählen beispielsweise auch erste Kostenschätzungen oder die Bestimmung der optimalen Projektdauer, welche vor der Ausschreibung vom AG zu erfolgen hat.

Durch die in den letzten Jahren stark angestiegene Rechenleistung der Computer sind neuronale Netze heutzutage in der Lage, technische Fragestellungen effizient und in einer angemessenen Dauer zu lösen. Aus diesem Grund wird künstliche Intelligenz in vielen Fachbereichen wie der Medizin, dem Banken- und Versicherungswesen, der Automobilindustrie sowie im menschlichen Alltag immer öfter eingesetzt. Beispielsweise erleichtern automatische Bilderkennung, Sprachassistenten oder Chatbots das Leben enorm und sind schon fast nicht mehr wegzudenken.

Mit diesen unumstrittenen Potenzialen gehen jedoch auch Gefahren einher. Damit künstliche Intelligenz effizient und effektiv eingesetzt werden kann, gilt es, diese zu kennen. Nur mittels ausreichenden Fachwissens, welches sich



sowohl über den Anwendungsbereich als auch über die grundlegende Funktionsweise des Algorithmus erstreckt, ist es möglich, die Auswirkungen abzuschätzen. Unter anderem hielt Googles Bilderkennungsalgorithmus<sup>1</sup> eine Katze für eine Guacamole und klassifizierte das Foto erst nach einer Rotation als Katze.<sup>2</sup> Sind bei der Anwendungen künstlicher Intelligenz solche Tricks bekannt, ziehen diese eine erhebliche Manipulationsgefahr nach sich. Ebenso kann es vorkommen, dass trotz verschiedener Perspektiven des Objektes beispielsweise eine Schildkröte bei der Bilderkennung als Gewehr detektiert wird.<sup>3</sup> Dies führt vor allem bei automatischen Abläufen zu Schwierigkeiten, weil die Ergebnisse nicht mehr überprüft werden. Wird beispielsweise im Straßenverkehr ein Stoppschild aufgrund kleiner Verschmutzungen fälschlicherweise als eine Geschwindigkeitsbegrenzung gedeutet, kann dies fatale Folgen haben.<sup>4</sup>

Weiters ist es wichtig hervorzuheben, dass bei der Anwendung künstlicher Intelligenz unbedingt theoretische Grundkenntnisse über die Technologie vorhanden sein müssen, damit es zu keinen fundamentalen Fehlinterpretationen der Berechnungsergebnisse kommt. Hierfür ist die weitverbreitete Abbildung 1-1 ein sehr gutes Beispiel. Diese zeigt die Entwicklung eines Fehlerverlaufes bei Bilderkennungen in Abhängigkeit der Jahre. Der erste Eindruck vermittelt, dass bei einer 5-prozentigen Fehlerquote 95 % der Bilder richtig erkannt werden. Erst durch den Vergleich mit Erfahrungswerten lässt sich erkennen, dass die angegebenen Fehlerwerte sehr niedrig sind. Bei genauerer Recherche<sup>5</sup> wird ersichtlich, dass diese Abbildung den Top-5-Fehler verdeutlicht. Somit befindet sich das Ergebnis der Klassifikation mit der angegebenen Prozentangabe (z.B.: 5 %) nicht unter den fünf wahrscheinlichsten Klassen. Ohne dieses Fachwissen könnten hierbei sehr rasch falsche Vorstellungen über die Fähigkeiten der maschinellen Bilderkennung entstehen.




Abb. 1-1 Fehlerquote Bilderkennung<sup>6</sup>

<sup>1</sup> Szegedy, C. et al.: Rethinking the Inception Architecture for Computer Vision. In: arXiv, 2015. <https://arxiv.org/abs/1512.00567>. Datum des Zugriffs: 22.06.2020

<sup>2</sup> Vgl.: <https://www.labsix.org/physical-objects-that-fool-neural-nets/>. Datum des Zugriffs: 22.06.2020

<sup>3</sup> Vgl.: Athalye, A. et al.: Synthesizing robust adversarial examples. In arXiv, 2018. <https://arxiv.org/abs/1707.07397>. Datum des Zugriffs: 22.06.2020

<sup>4</sup> Vgl.: Eykholt, K. et al.: Robust Physical-World Attacks on Deep Learning Visual Classification. In arXiv, 2018. <https://arxiv.org/abs/1707.08945>. Datum des Zugriffs: 22.06.2020

<sup>5</sup> <https://www.eff.org/ai/metrics>. Datum des Zugriffs: 22.06.2020

<sup>6</sup> Vgl.: Brynjolfsson, E.; McAfee, A.: Von Managern und Maschinen. In Harvard Business Manager Edition 3/2018. S. 35  
Aufbauend auf: <https://www.eff.org/de/ai/metrics>. Datum des Zugriffs: 22.06.2020

Nicht nur bei der Bilderkennung, sondern auch bei Prognosen oder Klassifizierungen gilt es, wichtige Aspekte (die in den nachfolgenden Kapiteln erläutert werden), zu beachten, damit mittels künstlicher Intelligenz Verfügungswissen in Orientierungswissen transformiert werden kann. Wie in Abbildung 1-2 ersichtlich, fungiert bei dieser Umwandlung das neuronale Netz als Filter, welcher Zusammenhänge zwischen den Input- und Outputparametern erkennt. Hierfür müssen lediglich ausreichend Daten vorliegen, anhand derer gelernt werden kann. Im besten Fall erfolgt die kontextbezogene Datenerhebung automatisch durch Sensoren und in Echtzeit.

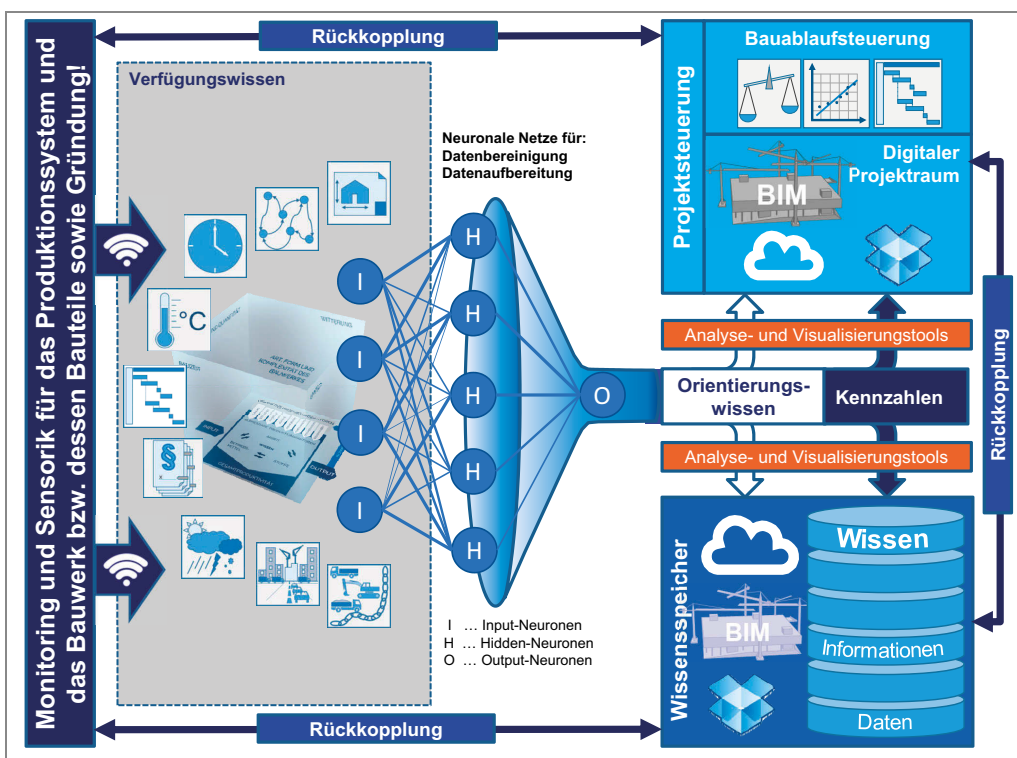


Abb. 1-2 Transformation von Verfügungswissen in Orientierungswissen<sup>7</sup>

Ein Tag ohne künstliche Intelligenz ist im Zeitalter der digitalen Revolution kaum vorstellbar. Selbstfahrende Autos, lernfähige Roboter, Bilderkennung sowie personalisierte Film- oder Musikvorschläge erhöhen den menschlichen Komfort. Diese bereits eingesetzte und nutzbringende Technik gilt es, nun auch im Bauwesen zu implementieren, weil dadurch Kosten gesenkt und Prozesse optimiert werden können. In weiterer Folge ermöglicht dies ein ressourcen- und umweltschonenderes Bauen. Darüber hinaus liefert die künstliche Intelligenz einen wesentlichen Beitrag zur Verbesserung des zukünftigen Bauens. Die Chance, eine Technologie, die Wissen implizit speichern und automatisiert anwenden kann, auf der Baustelle effektiv einsetzen zu können, darf nicht außer Acht gelassen werden, da sie für alle Beteiligten nutzbringend sein kann. Neben der Möglichkeit der Steigerung der Produktivität muss ebenfalls hervorgehoben werden, dass neuronale Netze im Wissensmanagement eine wichtige Rolle spielen. Erfahrungen aus laufenden und bereits abgeschlossenen Projekten werden in einer derartigen

<sup>7</sup> In Anlehnung an: Hofstadler, C.: Multisystemische Hybridpyramide für den agilen Baubetrieb – System- und Prozessinteraktionen mit der Digitalisierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 8

Form gespeichert, sodass sie dem Unternehmen langfristig erhalten bleiben. Dadurch wird die Fehlerquote reduziert und neue Mitarbeiter\*innen benötigen zudem weniger Einarbeitungszeit.

## 1.2 Zielsetzung und Forschungsfragen

Trotz der vielen Möglichkeiten, welche diese neue Technologie mit sich bringt, ist festzustellen, dass künstliche Intelligenz im Rahmen baubetrieblicher und bauwirtschaftlicher Prognosen bzw. Klassifizierungen noch nicht weit verbreitet ist. Um dies zu ändern, die Bedenken hinsichtlich maschinellen Lernens zu nehmen, die Potenziale sowie Einsatzmöglichkeiten aufzuzeigen und auf die Gefahren hinzuweisen, wird die vorliegende Arbeit verfasst. Sie verfolgt das Ziel, einen ganzheitlichen Ansatz für den effektiven und effizienten Einsatz neuronaler Netze zu entwickeln, welcher alle notwendigen Schritte von der Datenerhebung bis hin zur Modellbildung beinhaltet, um schließlich auch als Leitfaden herangezogen werden zu können. Hierfür gilt es, folgende Forschungsfragen zu behandeln:

1. Bei welchen Aufgabenstellungen aus dem Bauwesen kann künstliche Intelligenz auf Basis des überwachten Lernens zielführend eingesetzt werden?
2. Welchen Einfluss üben die Datensatzgröße sowie die Auswahl der Trainings- und Testfälle auf das Ergebnis aus?
3. Welche Voraussetzungen müssen für die Anwendung bei baubetrieblichen und bauwirtschaftlichen Fragestellungen erfüllt sein, damit effektive und effiziente Vorhersagen getroffen werden können?
4. Welches polysensorale System eignet sich bei Hochbaubaustellen, um automatisch die für die Vorhersage benötigten Einflussparameter zu erheben?
5. Welche Schrittfolge gilt es, bei der Implementierung einer Prognose oder Klassifizierung auf Basis neuronaler Netze einzuhalten und welche Herausforderungen können hierbei auftreten?

Nach den soeben definierten Zielen ist abschließend noch festzuhalten, dass die Programmierung der künstlichen Intelligenz zu den Nicht-Zielen zählt und daher keine Berücksichtigung in dieser Arbeit findet.

## 1.3 Wissenschaftliche Einordnung der künstlichen Intelligenz

Als grundlegendste Aufgliederung der Wissenschaft wird jene in Formal- und Realwissenschaften gewählt. Bei ersterem liegt der Fokus auf der Konstruktion von Sprachen, wobei dies immer basierend auf Zeichensystemen mit Regeln zur richtigen Verwendung geschieht. Weil hierbei kein Realitätsbezug aufzufinden ist, muss auf eine logische Wahrheit hin überprüft werden. Bekannte Vertreter dahingehend sind die Philosophie, die Logik, die Mathematik oder die Informatik. Die Realwissenschaften widmen sich hingegen der Beschreibung, Erklärung und Gestaltung empirisch wahrnehmbarer Wirklichkeitsausschnitte. Weiters lassen sich diese in Abhängigkeit des

verfolgten Ziels, welches theoretischer oder praktischer Natur sein kann, in Grundlagenwissenschaften und Handlungswissenschaften unterteilen.<sup>8</sup>

Die nachfolgende Abbildung 1-3 verdeutlicht die geschilderte Gliederung der Wissenschaften. Zusätzlich werden die Formalwissenschaften in axiomatische Wissenschaften und Seinswissenschaften sowie die Realwissenschaften in Naturwissenschaften, Ingenieurwissenschaften, Sozialwissenschaften und Geisteswissenschaften unterteilt. Die Baubetriebswissenschaft ist sowohl den Ingenieur- als auch den Sozialwissenschaften zuzuordnen und stellt dadurch ein interdisziplinäres sowie anwendungsorientiertes Forschungsfeld dar.<sup>9</sup>

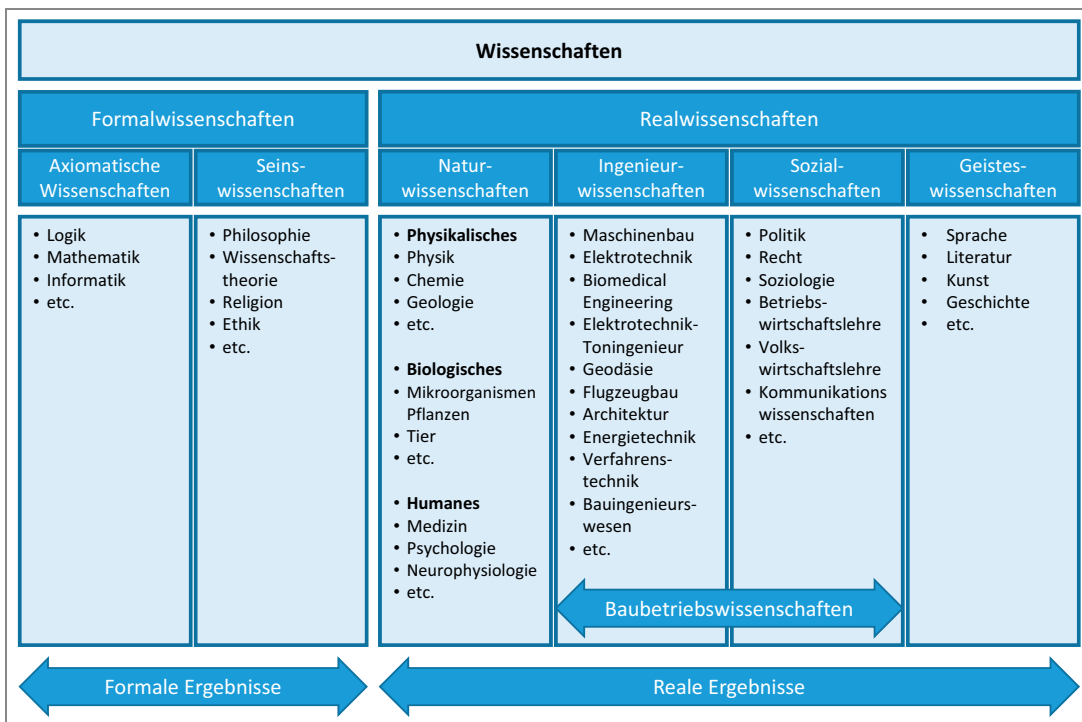


Abb. 1-3 Gliederung der Wissenschaft<sup>10</sup>

An dieser Stelle gilt, es anzumerken, dass bei der Lösung von Aufgabenstellungen aus dem Bauwesen auch Methoden und Instrumente anderer Wissenschaften wie beispielsweise der Logik, Mathematik oder Informatik – z.B. künstliche Intelligenz – eingesetzt werden.

Im Alltag wird der Begriff der künstlichen Intelligenz (KI) häufig mit Bild- und Spracherkennung, dem autonomen Fahren, Chatbots, Robotern oder Entscheidungssystemen in Verbindung gebracht. Daraus ist erkennbar, dass unter dem KI-Begriff im täglichen Sprachgebrauch ein spezifisches Werkzeug verstanden wird.

Die Informatik teilt diese Sichtweise und sieht die künstliche Intelligenz als losen Sammelbegriff für bestimmte Techniken der Softwareentwicklung.<sup>11</sup> Dass unter künstlicher Intelligenz auch ein interdisziplinärer Forschungs-

<sup>8</sup> Vgl.: Ulrich, P.; Hill, W.: Wissenschaftstheoretische Grundlagen der Betriebswirtschaftslehre (Teil I). S. 305

<sup>9</sup> Vgl.: Girmscheid, G.: Forschungsmethodik in den Baubetriebswissenschaften. S. 47

<sup>10</sup> Vgl.: Ulrich, P.; Hill, W.: Wissenschaftstheoretische Grundlagen der Betriebswirtschaftslehre (Teil II). S. 305  
Vgl.: Girmscheid, G.: Forschungsmethodik in den Baubetriebswissenschaften. S. 47

<sup>11</sup> Vgl.: Rosengrün, S.: Was ist KI und wenn ja, wie viele? – Vier Rätsel einer Philosophie der künstlichen Intelligenz. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. S. 37

zweig gemeint sein kann, in dem natürliche Intelligenz modelliert und simuliert wird, um beispielsweise die menschliche Fähigkeit des Lernens oder der Mustererkennung besser zu verstehen, sei hier nur der Vollständigkeit halber erwähnt.<sup>12,13</sup> In der vorliegenden Arbeit wird auf dieses Forschungsfeld nicht näher eingegangen, wodurch der KI-Begriff nachfolgend immer im Sinne einer Technik der Softwareentwicklung zu verstehen ist.

Damit die Verbundenheit zwischen der Informatik und der künstlichen Intelligenz besser verdeutlicht werden kann, muss erstere zunächst in ihre Teilbereiche aufgegliedert werden. Diese setzen sich aus der theoretischen Informatik (z.B.: Berechenbarkeit, formale Sprachen, Algorithmenanalyse), der praktischen Informatik (z.B.: Betriebssysteme, Compiler, Datenbanken), der technischen Informatik (z.B.: Schaltwerke, Prozessoren, Rechnernetze) und der angewandten Informatik (z.B.: Informationssysteme, Modellierung, Simulation) zusammen. Letztere kombiniert die Erkenntnisse der ersten drei Teilgebiete, um Aufgabenstellungen anderer Wissenschaften zu lösen. Der Einsatz künstlicher Intelligenz zählt genau zu diesem Teilbereich, weil dadurch Prognosen, Klassifizierungen oder Optimierungen von beliebigen Aufgabenstellungen durchgeführt werden können.<sup>14</sup>

Die künstliche Intelligenz selbst entwickelte sich so wie die Verhaltensökonomik aus der Kybernetik – der Wissenschaft der Steuerung und Regelung von Maschinen, lebenden Organismen und sozialen Organisationen. Sie wurde 1943 vom amerikanischen Mathematiker *Norbert Wiener* im Zuge einer Analyse von Kampfflugzeugpiloten aus dem Zweiten Weltkrieg begründet. Hierbei setzte er das Verhalten von Organismen mit dem von technischen Systemen gleich, sodass der Reiz-Reflex-Mechanismus für Prognosen herangezogen werden kann.<sup>15</sup>

## 1.4 Forschungsmethodik

Um gemeinsam Bauprojekte erfolgreich umsetzen zu können, müssen sich die beteiligten Personen sowohl auf sprachlicher als auch auf inhaltlicher Ebene verstehen. Die Vergangenheit hat jedoch gezeigt, dass es aufgrund verschiedener Verstehensumgebungen oftmals zu Missverständnissen kommt. Da das „Verstehen können“ kein sicheres und einfaches Unterfangen darstellt, zeigt sich in diesem Zusammenhang die Notwendigkeit der Hermeneutik als Lehre des Verstehens. Die Hermeneutik selbst, sprich die Technik des Verstehens, kann neben der Methodenlehre auch als Form des Weltzugangs oder als eine spezielle Philosophie gesehen werden.<sup>16</sup>

Für die folgende Dissertation wird die hermeneutische Spirale aus dem Bereich der Methodenlehre angewandt, wodurch sichergestellt ist, dass die Erkenntnis aufbauend auf einem bestimmten Vorverständnis fortlaufend durch immer mehr Wissen präzisiert wird. Die nachfolgende Abbildung 1-4 stellt die Wissenswachstumsspirale dar.

<sup>12</sup> Vgl.: Ertel, W.: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 265 ff.

<sup>13</sup> Vgl.: Mainzer, K.: Künstliche Intelligenz – Wann übernehmen die Maschinen?. S. 2

<sup>14</sup> Vgl.: Heyer, G.: Teilgebiete der Informatik. Universität Leipzig. <https://www.informatik.uni-leipzig.de/lehre/Heyer9900/kap1/sld013.htm>. Datum des Zugriffs: 02.07.2020

<sup>15</sup> Vgl.: Precht, R.: Jäger, Hirten, Kritiker. S. 70f

<sup>16</sup> Vgl.: Girmscheid, G.: Forschungsmethodik in den Baubetriebswissenschaften. S. 60f

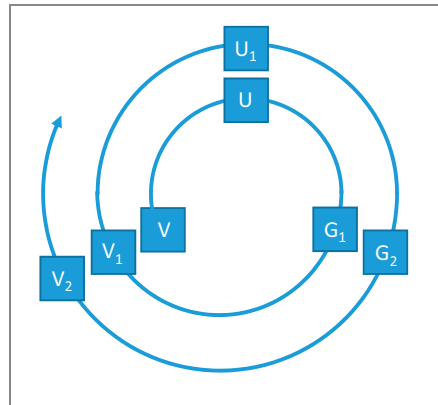


Abb. 1-4 Hermeneutische Methode – Wissenswachstumsspirale<sup>17</sup>

Die obige Abbildung zeigt, dass ausgehend von einer bestimmten Vorerkenntnis V mittels Untersuchung U ein Gegenstandsverständnis G erzielt wird. In weiterer Folge führt dies wiederum zu einem neuen Vorverständnis, welches die Ausgangsbasis einer weiteren Untersuchung darstellt. Diesen Prozess gilt es, solange zu durchlaufen, bis ein zufriedenstellendes Gegenstandsverständnis erreicht wird. An dieser Stelle ist jedoch anzumerken, dass der Erkenntnisgewinn mit jedem weiteren Zyklus abnimmt, bis er schließlich saturiert.<sup>18</sup>

Damit die Wissenserweiterung systematisch und effektiv erfolgt, wird auf die Methoden des Systems Engineering (SE) zurückgegriffen. Das hierbei eingesetzte zentrale Konzept, welches ein transparentes Vorgehen beim Lösen von komplexen Fragestellungen ermöglicht, wurde an der ETH Zürich entwickelt.<sup>19</sup> Bei diesem Ansatz verkörpert die SE-Philosophie den Überbau der SE-Methodik, welche eine transparente Gestaltung sowie effiziente Abwicklung des Problemlösungsprozesses ermöglicht. Sie setzt sich aus dem Systemdenken und dem SE-Vorgehensmodell zusammen.<sup>20</sup> Ersteres basiert auf dem Ansatz, dass mit Systemmodellen komplexe Zusammenhänge als Abstraktion der Wirklichkeit dargestellt werden können. Hierbei ist es von großer Wichtigkeit, dass dem System eine funktionserfüllende Struktur zugrunde gelegt wird, damit die vorgegebene Zwecksetzung bei vielfältigen Randbedingungen erreicht werden kann.<sup>21</sup> Die zweite Grundidee – das SE-Vorgehensmodell – beruht auf dem Vorgehensprinzip „Vom Groben ins Detail“, dem Prinzip der Variantenbildung, der Phasengliederung als Makro-Logik und dem Problemlösezyklus als Mikrologik.<sup>22</sup>

<sup>17</sup> Vgl.: Girmscheid, G.: Forschungsmethodik in den Baubetriebswissenschaften. S. 63

<sup>18</sup> Vgl.: Girmscheid, G.: Forschungsmethodik in den Baubetriebswissenschaften. S. 63

<sup>19</sup> Vgl.: Schütz, M.; Hofstadler, C.: Anwendung des Systems Engineering auf die Arbeitsvorbereitung von Bauprojekten. In: Bautechnik 89, Heft 11. S. 1

<sup>20</sup> Vgl.: Haberkellner, R.; Stelzmann, E.: Systems Engineering: neu überdacht. In: WINGbusiness 3/2008. S. 18

<sup>21</sup> Vgl.: Banse, G.: Idee-Entwurf-Gestaltung II. Der (schwierige) Weg zum (technischen) Neuen II. Folie 31

<sup>22</sup> Vgl.: Schütz, M.; Hofstadler, C.: Anwendung des Systems Engineering auf die Arbeitsvorbereitung von Bauprojekten. In: Bautechnik 89, Heft 11. S. 1

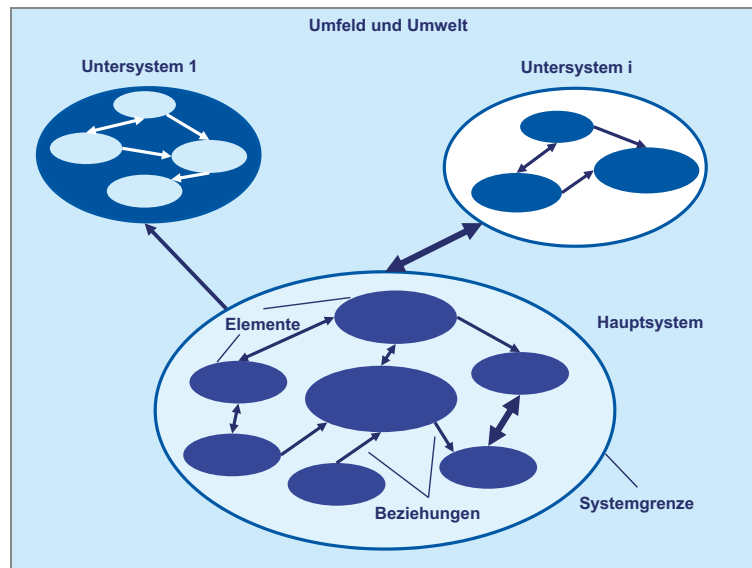


Abb. 1-5 Bestandteile eines Systems<sup>23</sup>

Ein System besteht aus Elementen, welche bestimmte Eigenschaften aufweisen und nicht weiter zerlegt werden können, sowie deren Beziehungen untereinander. Weiters wird das Haupt- oder Untersystem von der Umwelt und dem Umfeld durch die Systemgrenze getrennt. Abbildung 1-5 verdeutlicht die einzelnen Bestandteile eines Systems sowie deren Zusammengehörigkeit.<sup>24</sup>

Die vier Komponenten des Vorgehensmodells, welche nachfolgend näher erläutert werden, können beliebig miteinander kombiniert werden und stellen somit eine zusammenhängende Einheit dar.<sup>25</sup>

- Das Vorgehensprinzip „Vom Groben ins Detail“ besagt, dass das Betrachtungsfeld zuerst weit gefasst und erst danach sukzessive eingeeengt werden soll. Dadurch wird sichergestellt, dass kein wesentlicher Aspekt übersehen wird. Bezogen auf das Bauwesen bedeutet dies, dass die Einreichplanung erst nach der Entwurfsplanung beginnt.
- Dem Prinzip der Variantenbildung liegt zugrunde, dass grundsätzlich nicht jede erstbeste Lösung eines Problems umgesetzt werden soll. Es gilt, zunächst nach Alternativen zu suchen, aus denen abschließend eine Möglichkeit ausgewählt wird. Dadurch ist sichergestellt, dass eine Lösung gefunden wird, die den Anforderungen bestmöglich entspricht und die alle Denkrichtungen abdeckt.
- Die Phasengliederung als Makro-Logik verkörpert eine Erweiterung der beiden bereits vorgestellten Vorgehenskomponenten hinsichtlich der zeitlichen Betrachtung. Hierbei wird eine Gliederung der Realisierung und Lösung eines Problems in Projektphasen eingesetzt.
- Das vierte und somit letzte Element stellt der Problemlösungszyklus als Mikro-Logik dar, welcher auf jegliche Fragestellung angewendet werden kann. Er baut auf der Deweyschen Problemlösungslogik auf und kann in jeder Projektphase eingesetzt werden.

<sup>23</sup> Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 6

<sup>24</sup> Vgl.: Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 6

<sup>25</sup> Vgl.: Schütz, M.; Hofstadler, C.: Anwendung des Systems Engineering auf die Arbeitsvorbereitung von Bauprojekten. In: Bautechnik 89, Heft 11. S. 2f

Die Zusammenhänge der einzelnen Komponenten werden nochmals in Abbildung 1-6 gezeigt. Hierbei wird die allgemeine Vorgehensweise „Vom Groben ins Detail“ in einer zeitlich logischen Abfolge mit Hilfe der Projektphasen umgesetzt. Weiters werden die Variantenbildung und der Problemlösungszyklus in jedem Detaillierungsschritt miteingebunden.<sup>26</sup>

Die Entwicklung eines Ortungssystems in Kapitel 4 stützt sich besonders auf die einzelnen Schritte des Problemlösungszyklus. Nach der Zieldefinition werden verschiedene Lösungsmöglichkeiten aufgezeigt und abschließend die geeignetste ausgewählt. Die Prüfung des Erhebungskonzeptes erfolgt durch eine baustellenbezogene Umsetzung mit experimentellem Charakter, welche mittels Beobachtungsmethodik – bewusste Verfolgung eines Ziels oder Zwecks mittels menschlicher Sinnesorgane und des Gebrauchs technischer Mittel<sup>27</sup> – beurteilt wird. Die auf die Datenerhebung aufbauende Klassifizierung der Tätigkeiten stützt sich als Erkenntnismethode auf die Modellierung, wobei für die Gestaltungsmethode ein iterativer Lösungsfindungsprozess gewählt wird. Die abschließende Validierung des Modells erfolgt auf Basis der Testdaten.

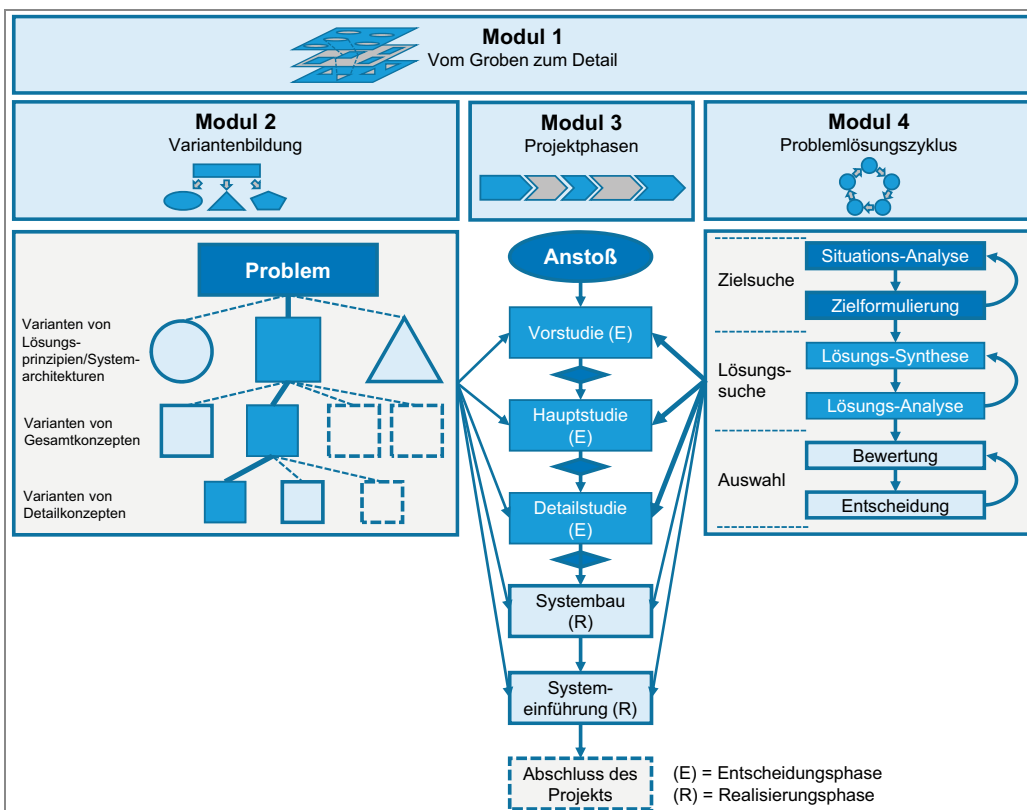


Abb. 1-6 Vorgehensmodell Systems Engineering<sup>28</sup>

Damit im Zuge dieser Arbeit die Voraussetzungen für das Erreichen der höchsten Ebene im Ideensuchraum nach Banse<sup>29</sup> (siehe Abbildung 1-7) gegeben sind, ist die Abstraktionshöhe über das strukturanaloge hinaus auf

<sup>26</sup> Vgl.: Schütz, M.; Hofstadler, C.: Anwendung des Systems Engineering auf die Arbeitsvorbereitung von Bauprojekten. In: Bautechnik 89, Heft 11, S. 3

<sup>27</sup> Vgl.: Banse, G.: Idee-Entwurf-Gestaltung III. Der (schwierige) Weg zum (technischen) Neuen III. Folie 13

<sup>28</sup> Hofstadler, C.: Baubetrieb FS. Systematisches Denken und Handeln, Wissenschaftliches Arbeiten. SS 2017, S. 15

<sup>29</sup> Vgl.: Banse, G.: Idee-Entwurf-Gestaltung I. Der (schwierige) Weg zum (technischen) Neuen I. Folie 38



das funktionsanaloge Denken zu heben. Weiters wird die Analogieweite auf fernliegende Fachbereiche sowie andere Wissenschaftsgebiete ausgedehnt und die Kommunikationsweite dementsprechend angepasst.

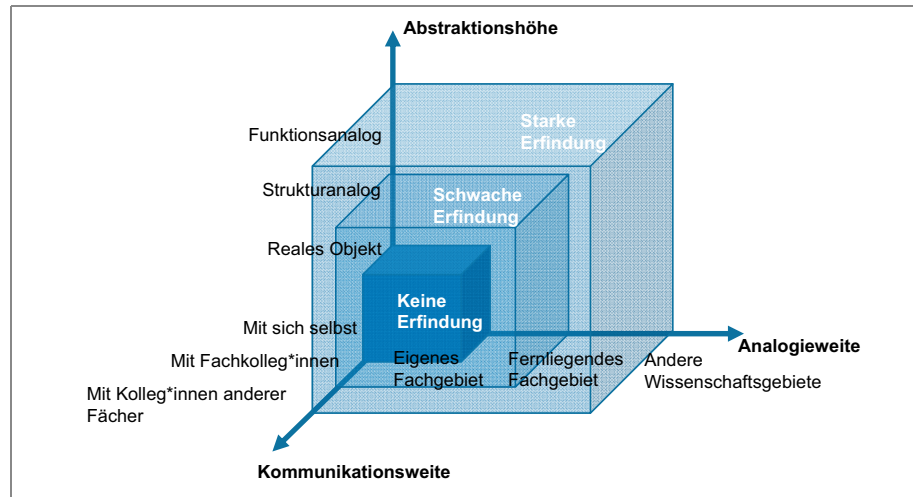


Abb. 1-7 Ideensuchraum<sup>30</sup>

**1.5 Inhaltliche Abgrenzung der Dissertation**

„Wer erfolgreich Mittel und Wege zeigt, ein bisher unerreichtes Ziel auf dem Gebiet materiellen Wirkens zu erreichen, oder auch wer neue Wege und Mittel zeigt, ein bereits bekanntes Ziel zu erreichen, hat eine Erfindung gemacht.“<sup>31</sup>

Eyth definiert anhand der Bekanntheit bzw. Unbekanntheit des Ziels und der Mittel vier Klassen von Erfindungen<sup>32,33</sup>, welche in Abbildung 1-8 veranschaulicht werden. Die vorliegende Dissertation ist dem Bereich des bereits realisierten Ziels mit neuen Mitteln und Wegen (Strukturerfindung) zuzuordnen. Als Beispiel für diese Gruppe führt Eyth den Buchdruck an, welcher eine neue und vor allem effizientere Methode darstellte, um Schriftstücke zu verbreiten.<sup>34</sup>

Erfindungs-einteilung nach Eyth		Ziel	
		Neu	Realisiert
Mittel	Neu	Funktionserfindung I (z.B. Fernsehen)	Strukturerfindung (z.B. Buchdruck)
	Realisiert	Funktionserfindung II (z.B. Telefax)	Übertragungserfindung (z.B. Daten-CD)

Abb. 1-8 Einteilung der Erfindungen nach Eyth<sup>35</sup>

<sup>30</sup> In Anlehnung an: Banse, G.: Idee-Entwurf-Gestaltung I. Der (schwierige) Weg zum (technischen) Neuen I. Folie 38  
<sup>31</sup> Eyth, M.: Zur Philosophie des Erfindens (1903). In: Eyth, M.: Lebendige Kräfte. Sieben Vorträge aus dem Gebiete der Technik. S. 231f  
<sup>32</sup> Erfindung: etwas neu Hervorgebrachtes, Neuheit, Entwicklung. Duden: <https://www.duden.de/rechtschreibung/Erfindung>. Datum des Zugriffs: 10.07.2020  
<sup>33</sup> Erfindung: (vergegenständlichtes) Ergebnis der Ingenieur-tätigkeit. Banse, G.: Erfindungen im Spannungsfeld von Methodik, Heuristik und Kreativität. In: Johann Beckmann und die Folgen. Erfindungen – Versuch der historischen, theoretischen und empirischen Annäherung an einen vielschichtigen Begriff. Hrsg.: Banse, G.; Müller H. S. 28  
<sup>34</sup> Vgl.: Eyth, M.: Zur Philosophie des Erfindens (1903). In: Eyth, M.: Lebendige Kräfte. Sieben Vorträge aus dem Gebiete der Technik. S. 231f

Künstliche Intelligenz, im Speziellen ein neuronales Netz, eignet sich für das zielsichere Erstellen von Prognosen und Klassifizierungen. Diese Art der Aufgabenstellung ist bereits bekannt und kann durch verschiedene, sich in ihrer Komplexität unterscheidende Algorithmen gelöst werden. Somit stellt der Einsatz von maschinellem Lernen ein neues Mittel bei derartigen Fragestellungen dar.

Die im Rahmen dieser Arbeit durchgeführte Literaturrecherche verdeutlicht, dass bereits unzählige effektive und effiziente Anwendungsmöglichkeiten von neuronalen Netzen im Baubetrieb sowie in der Bauwirtschaft diskutiert und deren Ergebnisse in diversen Veröffentlichungen festgehalten worden sind. Jedoch zeigt sich hinsichtlich einer systematischen Herangehensweise, welche eine Erklärung der wesentlichen Schritte eines digitalen Datenerhebungsprozesses sowie der Modellbildung und das Aufzeigen von Gefahrenpotenzial miteinschließt, eine unzureichende Darstellung. Die vorliegende Arbeit, welche auch als Handlungsanleitung für den Einsatz von künstlicher Intelligenz im Baubetrieb und in der Bauwirtschaft mit automatisierter Datenerfassung herangezogen werden kann, setzt sich zum Ziel, dieser Lücke entgegenzuwirken.

Somit stellt diese Dissertation keine Einzelfalllösung einer spezifischen Fragestellung dar, sondern beschreibt eine methodische Vorgehensweise, welche sich von der automatischen Datenerhebung bis hin zu mit neuronalen Netzen durchgeführten Vorhersagen erstreckt. Hierfür werden nachfolgend sowohl theoretische Grundlagen als auch eine Klassifikation basierend auf mit Ortungstechnologien auf einer Hochbaubaustelle erhobenen Bewegungsmustern behandelt, um das Spannungsfeld zwischen Theorie und Praxis, eingebettet in einem soziotechnischen System, bestmöglich zu bedienen.

## 1.6 Vorgehensweise und Gliederung der Arbeit

Die vorliegende Arbeit besteht aus sieben Kapiteln, wobei die Reihenfolge der Gliederung der Vorgehensweise beim Erstellen der Arbeit entspricht. Der inhaltliche Aufbau sowie die angewendete Forschungsmethodik basierend auf den Phasen von Systems Engineering werden in Abbildung 1-9 verdeutlicht.

Kapitel 1 stellt die Einleitung dar. Sie beinhaltet eine Einführung und die Hintergründe der Arbeit, die Zielsetzung, die wissenschaftliche Einordnung, die Forschungsmethodik, die inhaltliche Abgrenzung der Dissertation sowie die Vorgehensweise und Gliederung.

Im Zuge der Vorstudie werden darauffolgend in Kapitel 2 die theoretischen Grundlagen erörtert. Hierbei liegt der Schwerpunkt vor allem auf der Funktionsweise neuronaler Netze und der Software NeuralTools<sup>36</sup>. Weiters stehen zwei Anwendungsbeispiele basierend auf mittels Modellen erstellten Datensätzen im Zentrum der Betrachtung. Anhand dieser wird deutlich, welchen Einfluss die einzelnen Datenpunkte auf das Prognoseergebnis ausüben.

<sup>35</sup> In Anlehnung an: Ropohl, G.: Philosophie der Erfindung. In: Johann Beckmann und die Folgen. Erfindungen – Versuch der historischen, theoretischen und empirischen Annäherung an einen vielschichtigen Begriff. Hrsg.: Banse, G.; Müller H. S. 149  
Vgl.: Eyth, M.: Zur Philosophie des Erfindens (1903). In: Eyth, M.: Lebendige Kräfte. Sieben Vorträge aus dem Gebiete der Technik. S. 231f

<sup>36</sup> <https://www.palisade.com/neuraltools/default.asp>. Datum des Zugriffs: 05.12.2021

Nachdem ein grundlegendes Verständnis über neuronale Netze geschaffen worden ist, können die verschiedenen Anwendungsmöglichkeiten besser nachvollzogen werden. Die in Kapitel 3 geschilderte Hauptstudie befasst sich zunächst mit dem Einsatz neuronaler Netze in baufremden Branchen und zeigt eine systematische Vorgehensweise für die Modellerstellung auf. Anschließend werden Publikationen aus dem Fachbereich des Baubetriebs und der Bauwirtschaft analysiert. Hierbei liegt der Fokus auf Kosten-, Dauer- und Produktivitätsprognosen, welche auf Feedforward-Netzen basieren.

Die Ergebnisse der vorhin angesprochenen Literaturanalyse verdeutlichen die Notwendigkeit eines Systems, um Verfügungswissen automatisch in Orientierungswissen zu transformieren. Aus diesem Grund fokussiert sich das nachfolgende Kapitel 4 in der Detailstudie auf die polysensorale Datenerhebung. Hierbei werden zunächst die theoretischen Grundlagen von Sensoren und Ortungsmöglichkeiten beleuchtet, welche die Basis für die anschließenden prototypischen Systementwicklungen darstellen. Den Abschluss bildet die Systemauswahl basierend auf der Entscheidungsmatrix nach *Hofstadler*.

Kapitel 5 beinhaltet die fallstudienbezogene Systemimplementierung und stellt somit die Phase des Systembaus dar. Nach der Vorstellung der Baustelle wird der für das ausgewählte polysensorale Erhebungskonzept notwendige Prozess näher beleuchtet. Abschließend findet die Systemevaluation statt.

In Kapitel 6 steht die Klassifikation der Tätigkeiten Schalen, Bewehren und Betonieren mittels neuronaler Netze anhand der erhobenen Bewegungsmuster im Fokus der Betrachtung. Hierfür wird nach der Datenanalyse ein Basisdatensatz gebildet, welcher die Grundlage für die darauffolgenden Vorhersagen darstellt. Im Rahmen eines iterativen Prozesses werden einzelne Modelle erstellt und abschließend auf deren Übereinstimmung mit der Wirklichkeit überprüft (Modellvalidierung). Die erste Variante beinhaltet ausgewählte Zeitgrenzen und die zweite summierungsbedingte Abbruchkriterien. Das beste Ergebnis wird schlussendlich mittels einer Variablenelimination erzielt.

Die Zusammenfassung in Kapitel 7 schließt die Dissertation ab. Sie beinhaltet die Beantwortung der Forschungsfragen, den Nutzen der Arbeit sowie einen Ausblick und den weiteren Forschungsbedarf.

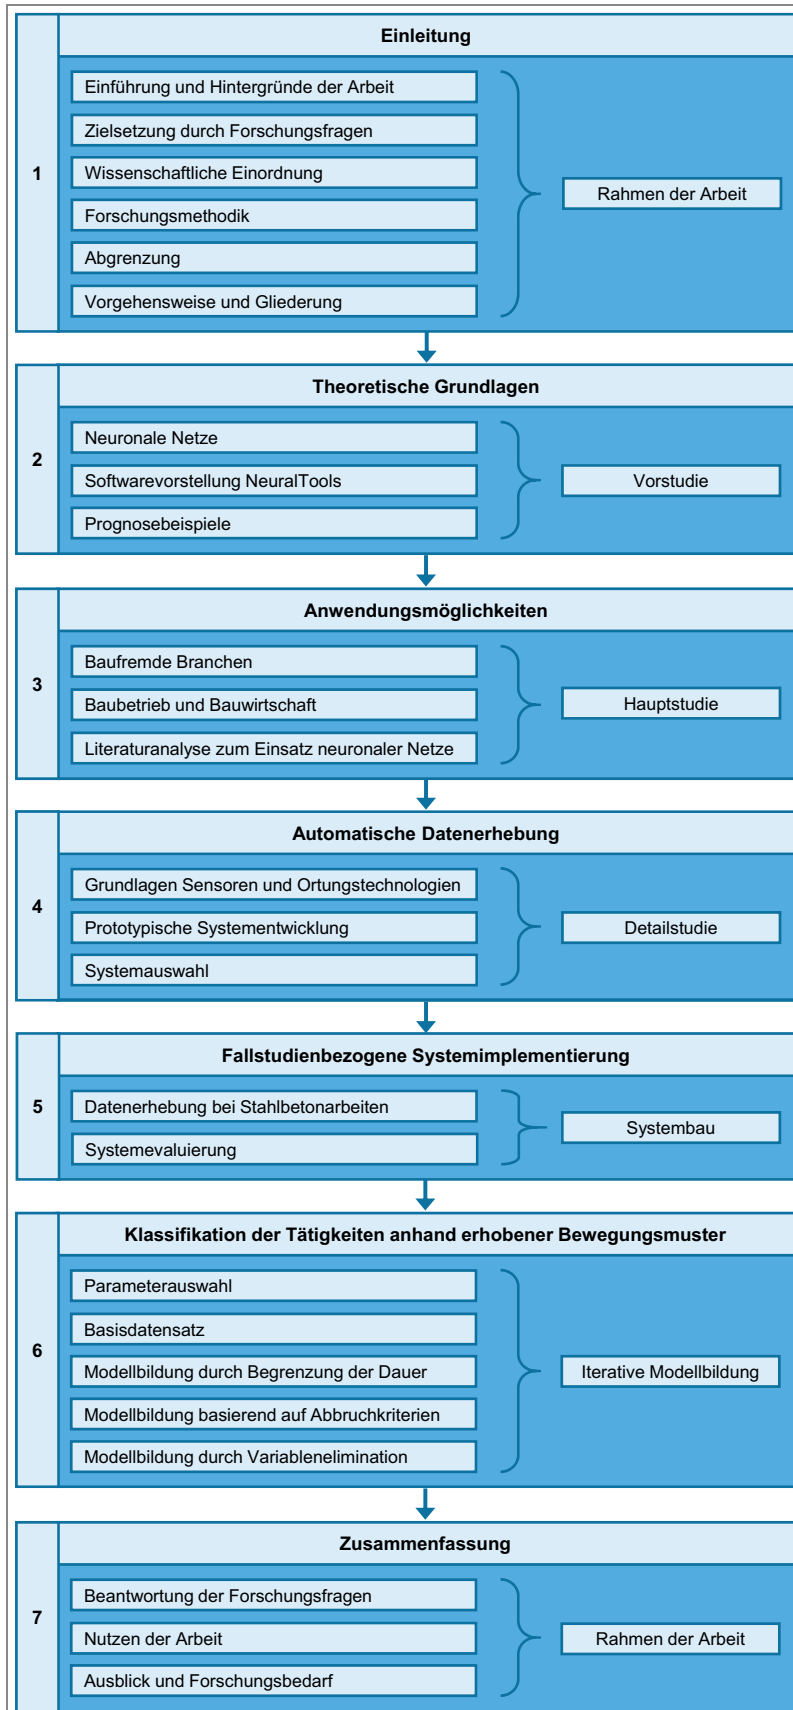


Abb. 1-9 Gliederung der Arbeit



## 2 Theoretische Grundlagen

Dieses Kapitel erläutert die Wissensbasis, welche für einen erfolgreichen Umgang mit neuronalen Netzen unumgänglich ist. Hierbei steht der Aufbau der mehrschichtigen Feedforward-Netze im Vordergrund. Abschließend wird auf das Programm NeuralTools, welches ein Excel-Add-In der Palisade Corporation darstellt, eingegangen und die Anwendung anhand grundlegender Beispiele erläutert.

### 2.1 Einführung

Damit Prognosen über zukünftige Entwicklungen nutzbringend durchgeführt werden können, muss zunächst ein Datensatz analysiert werden, um zielführende Zusammenhänge zu erkennen. Diese Datenansammlung beinhaltet somit das auf der Baustelle befindliche Verfügungswissen, zu dem unter anderem die Temperatur, die Anzahl der Arbeitskräfte oder die Kranverfügbarkeit zählen, und wird im Idealfall systematisch und automatisch aufgezeichnet. Die im Zuge der fortschreitenden Digitalisierung entstandenen Erhebungsmöglichkeiten (Sensoren, RFID-Technologie, Ortungsverfahren) gilt es, nutzbringend einzusetzen.

Im nächsten Schritt ist das gesammelte Verfügungswissen aufzubereiten, um eine Grundlage für effektive Entscheidungen zu schaffen. Bei der darauf aufbauenden Transformation in Orientierungswissen können verschiedene Analysealgorithmen oder auch künstliche Intelligenz, im Speziellen neuronale Netze, eingesetzt werden. Die aus der Umwandlung entstandenen Kennzahlen gilt es, anschließend in einer ansprechenden und übersichtlichen Form aufzubereiten. Hierbei können Apps oder Dashboards eingesetzt werden, bei denen beispielsweise mittels Ampelregelung sofort ersichtlich ist, in welchen Bereichen Handlungsbedarf besteht. Damit Erfolgswirksamkeit eintritt, ist es schlussendlich erforderlich, den Datenkreislauf mittels Rückkopplung wieder zu schließen. Durch diesen Zusammenschluss wird gewährleistet, dass die gewonnene Erkenntnis bei der Erhebung des neuen Verfügungswissens berücksichtigt und dadurch der gesamte Regelkreis verbessert wird.

In der nachfolgenden Abbildung 2-1 wird die soeben besprochene Transformation von Verfügungswissen in Orientierungswissen grafisch dargestellt. An dieser Stelle ist darauf hinzuweisen, dass gesammelte Daten und Informationen noch keinen Mehrwert für die Steuerung von Projekten erzeugen. Erst die Veredelung in Kennzahlen ermöglicht dem Menschen das Beurteilen des Baugeschehens.

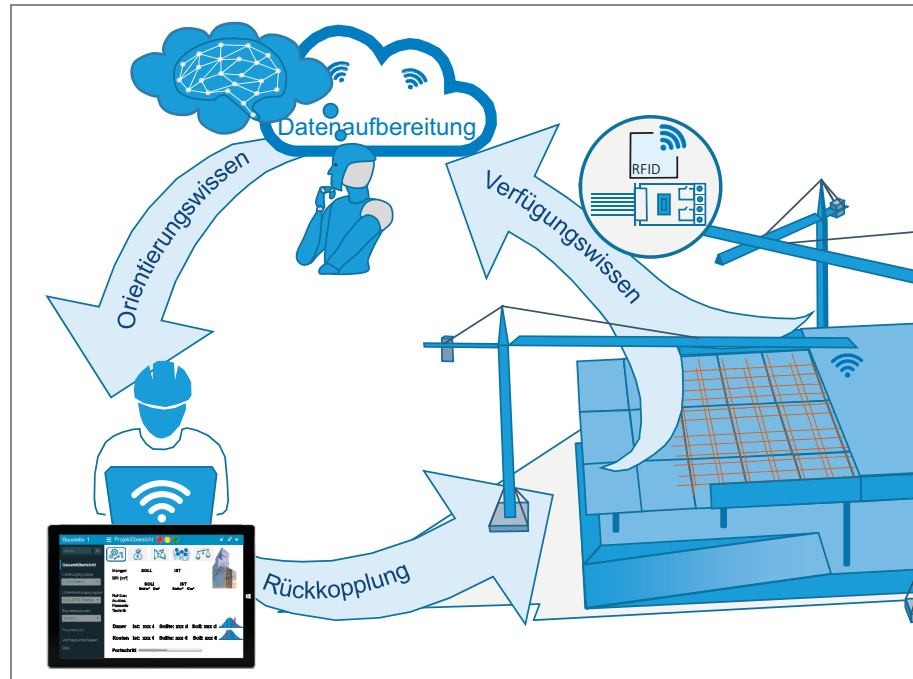


Abb. 2-1 Transformation von Verfügungswissen in Orientierungswissen

Eine Herausforderung für die Erhebung des Verfügungswissens stellen die sich ständig ändernden Umstände auf Baustellen dar (Abbildung 2-2). Aus diesem Grund müssen beim Sammeln von Daten und Informationen der Aufgabenstellung entsprechende Zeitintervalle gewählt werden. Weiters ist darauf zu achten, dass ein flexibles System zur Datenerhebung eingesetzt wird, damit bei fortschreitendem Baugeschehen auch in neu geschaffenen Bereichen kontextbezogene Daten aufgezeichnet werden können. Vor allem stellen hierbei Stahlbetondecken und -wände ein Hemmnis dar, weil sie Funk (elektromagnetische Wellen) stark abschwächen und dadurch die Reichweite von kabellosen Verbindungen begrenzen.

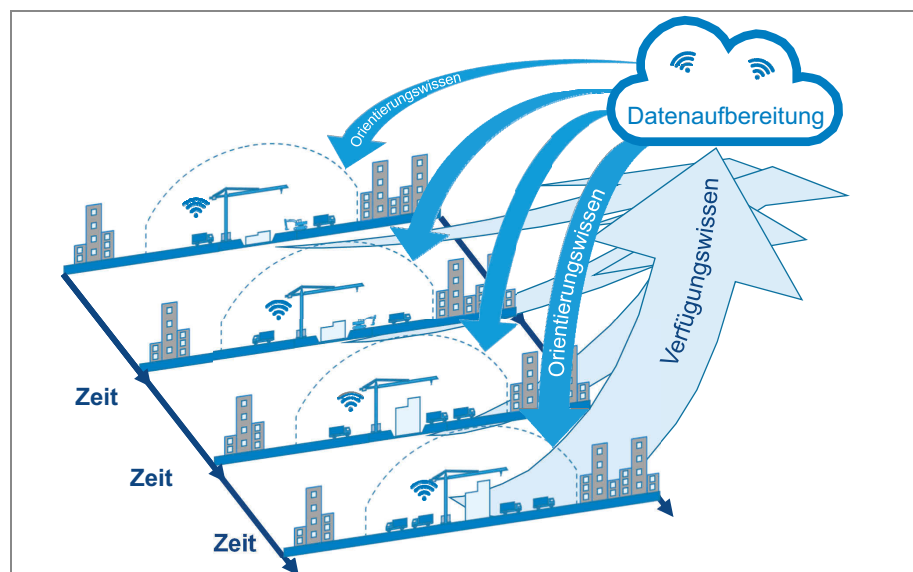


Abb. 2-2 Zeitliche Veränderung bei der Datenerhebung

Systematisch bedingt gliedert *Hofstadler* das Verfügungswissen in Prozessdaten, Daten zu Produktionsbedingungen und Bauwerksdaten. Zu ersterem zählen beispielsweise das gewählte Verfahren, die Partiedefinition, die tägliche Arbeitszeit oder die Bauzeit. Die Daten zu Produktionsbedingungen beschreiben die Umstände bei der Arbeit. Darunter fällt die Krananbindung, die Platzverhältnisse, die Einsatzortwechsel oder auch das Wetter. Die Bauwerksdaten fassen Informationen bezüglich des zu errichtenden Bauvorhabens zusammen. Dazu gehören unter anderem die geometrischen Abmessungen, Querschnittsformen, Bewehrungsgrade oder auch die geforderten Ausführungsqualitäten.

Das erhobene Verfügungswissen gilt es, darauffolgend zu bereinigen und aufzubereiten, damit daraus Orientierungswissen in Form von Kennzahlen entsteht. Wie in Abbildung 2-3 ersichtlich, unterstützt das extrahierte Wissen sofort die Projektsteuerung bei Entscheidungsfindungen. Gleichzeitig sollte es jedoch auch im Wissensspeicher abgelegt werden, damit bei zukünftigen Projekten darauf zurückgegriffen werden kann. Abschließend gilt es noch anzumerken, dass bei diesem gesamten Prozess nicht auf die Rückkopplung vergessen werden darf. Diese sorgt im Sinne der hermeneutischen Spirale für eine ständige Anpassung und legt dadurch die Basis für Verbesserung.

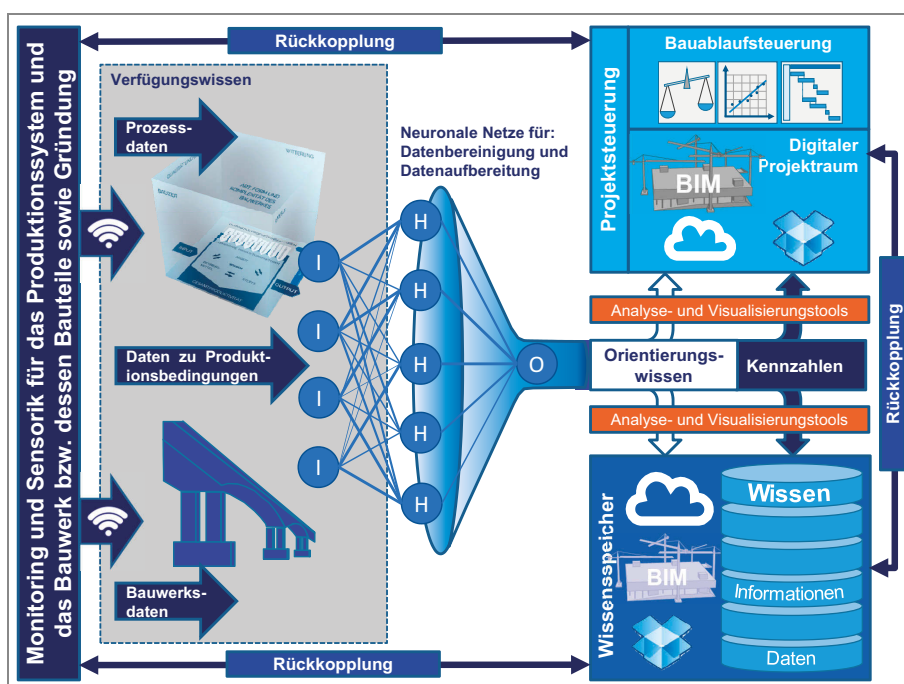


Abb. 2-3 Neuronale Netze für die Transformation von Verfügungswissen in Orientierungswissen<sup>1</sup>

Damit Kennzahlen wie beispielsweise Kosten, Dauern, Auslastungen, Aufwands- oder Leistungswerte für zukünftige Entwicklungen auf Basis des erhobenen Verfügungswissens vorhergesagt werden können, gilt es, Modelle für die Transformation einzusetzen. Neuronale Netze stellen hierbei eine geeignete und effektive Möglichkeit dar, die Wirklichkeit abzubilden.

<sup>1</sup> Hofstadler, C.; Stöckl, R.: Grundlagen zur Projekt- und Baustellenanalyse. In: Vorlesungsfolien, Baubetrieb und Exkursion, Sommersemester 2021, TU Graz. S. 8



Um bei jeglicher Art von Modellbildungen einen Mehrwert zu generieren, wird empfohlen, die multisystemische Hybridpyramide nach *Hofstadler* zu berücksichtigen. Hierbei stellen Digitalisierung sowie Daten- und Informationsgenerierung, Wissensmanagement, Simulation, Chancen-Risikomanagement, Ergebnisinterpretation, Diagnose/Prognose und (Berechnungs-)Modell (Abbild) die Basis dar. An der Spitze steht der Mensch mit seinen kreativ-konzeptionellen Fähigkeiten, der die Modellbeziehungen koordiniert. Dieser ganzheitliche Ansatz, welcher in Abbildung 2-4 dargestellt ist, verdeutlicht somit die in dreiecksform passierenden Interaktionen der einzelnen Elemente.<sup>2</sup>

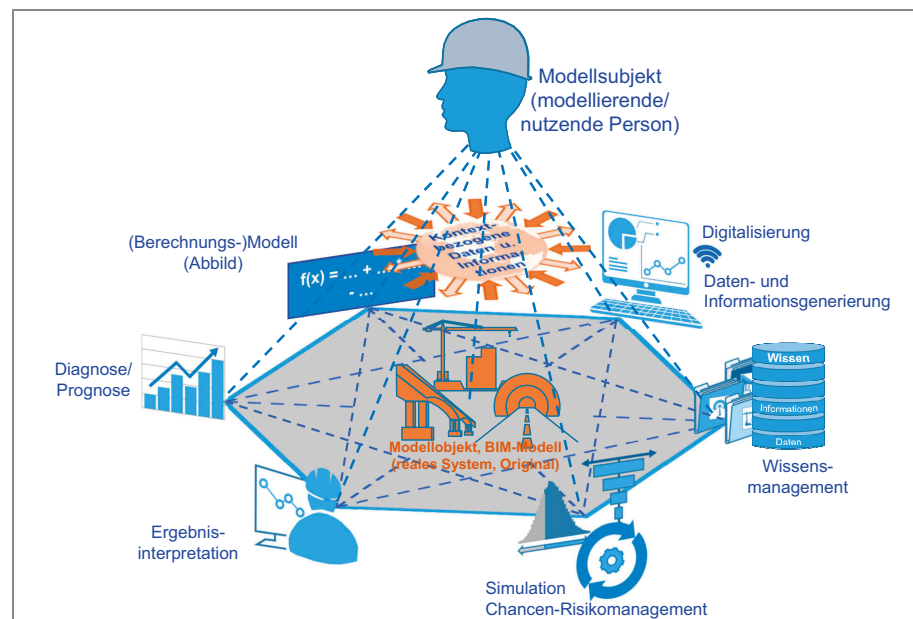
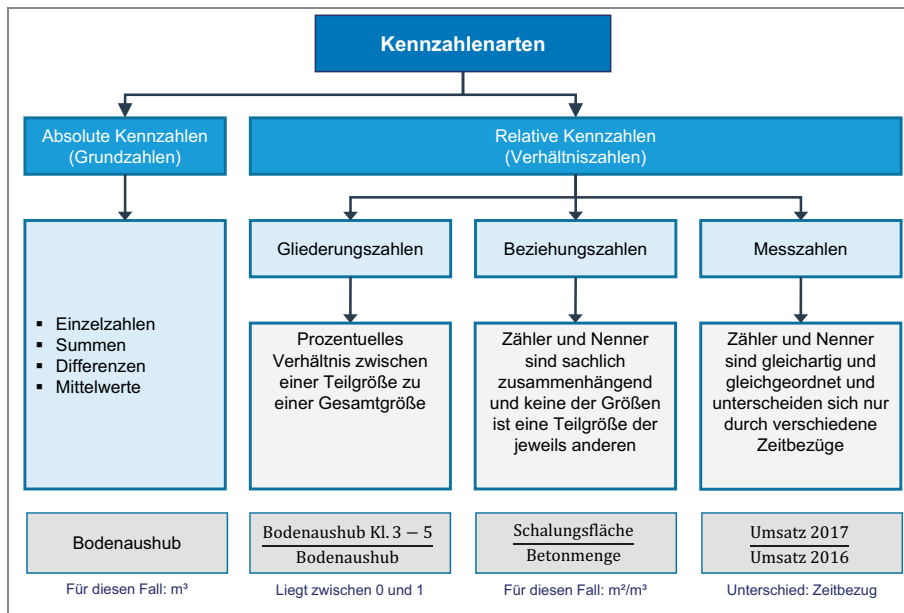


Abb. 2-4 Multisystemische Hybridpyramide<sup>3</sup>

Das bei der Transformation erzeugte Orientierungswissen in Form von Kennzahlen wird herangezogen, um vergangene/aktuelle Zustände zu beurteilen oder um zukünftiges Handeln abzuleiten. Hierbei gilt es, zu beachten, dass es absolute und relative Kennzahlen gibt, wobei letzteres nochmals in Gliederungs-, Beziehungs- und Messzahlen unterteilt werden kann (siehe Abbildung 2-5). Weiters ist darauf hinzuweisen, dass selbst bei Verwendung von künstlicher Intelligenz aus unvollständigem Verfügungswissen keine verlässlichen Kennzahlen erzeugt werden können. Aus diesem Grund ist es für ein nutzbringendes Output unerlässlich, dass die Inputparameter der neuronalen Netze – vor allem bei begrenzter Datengrundlage – eine hohe Genauigkeit (präzise und richtig) aufweisen. Abschließend ist noch anzumerken, dass künstliche Intelligenz auch bei Prognosen weicher Kennzahlen (Softfacts), welche sehr stark von subjektiven Empfindungen abhängen, eingesetzt werden können. Abhängig von der Anzahl der beurteilenden Personen lernen neuronale Netze entweder ein Bewertungsschema oder einen gewichteten Durchschnitt aus diesen.

<sup>2</sup> Vgl.: Hofstadler, C.: Multisystemische Hybridpyramide für den agilen Baubetrieb – System- und Prozessinteraktionen mit der Digitalisierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 13ff

<sup>3</sup> Hofstadler, C.: Multisystemic modeling to improve forecast accuracy in construction management. Konferenz: 10th International Structural Engineering and Construction Conference, 2019. S. 3

Abb. 2-5 Kennzahlenarten<sup>4</sup>

## 2.2 Von der künstlichen Intelligenz zu neuronalen Netzen

Wie bereits in der wissenschaftlichen Einordnung beschrieben, ist die künstliche Intelligenz (KI) der Informatik, die sich intensiv mit der systematischen Verarbeitung von Informationen mit Hilfe von Computern beschäftigt, zuzuordnen. In dieser Formalwissenschaft werden unterschiedliche Verfahrensweisen für die Aufbereitung von Daten sowie allgemeine Methoden der Anwendung solcher Techniken in den verschiedensten Bereichen entwickelt.<sup>5</sup>

Eine allgemein anerkannte Definition von künstlicher Intelligenz liegt derzeit nicht vor.<sup>6</sup> Werden die beiden Worte separat betrachtet, bezieht sich laut Duden künstlich auf „*natürliche Vorgänge nachahmend*“<sup>7</sup> und Intelligenz auf die „*Fähigkeit [des Menschen], abstrakt und vernünftig zu denken und daraus zweckvolles Handeln abzuleiten*“<sup>8</sup>.

Ein bis heute noch weit verbreitetes Verständnis von menschlicher Intelligenz stammt aus dem Jahr 1912 und ist auf *William Stern* zurückzuführen.<sup>9</sup> Er definiert diesen Begriff als „*allgemeine Fähigkeit eines Individuums, sein Denken bewußt auf neue Forderungen einzustellen; sie ist allgemeine geistige Anpassungsfähigkeit an neue Aufgaben und Bedingungen des Lebens*“<sup>10</sup>. Aufgrund der Tatsache, dass der Mensch heutzutage seine Umwelt an sich anpasst und teils irreversible Veränderungen (beispielsweise

<sup>4</sup> Hofstadler, C.: Baubetriebliche und bauwirtschaftliche Bedeutung. In: Vorlesungsfolien, Produktivität im Baubetrieb, Wintersemester 2020, TU Graz. S. 2  
In Anlehnung an: Gladen, W.: Performance Measurement Controlling mit Kennzahlen. S. 14ff

<sup>5</sup> Gabler Wirtschaftslexikon: Informatik. <https://wirtschaftslexikon.gabler.de/definition/informatik-38490>. Datum des Zugriffs: 03.08.2020

<sup>6</sup> Vgl.: Bünte, C.: Künstliche Intelligenz – die Zukunft des Marketing. S. 5

<sup>7</sup> Duden: künstlich. <https://www.duden.de/rechtschreibung/kuenstlich>. Datum des Zugriffs: 03.08.2020

<sup>8</sup> Duden: Intelligenz. <https://www.duden.de/rechtschreibung/Intelligenz>. Datum des Zugriffs: 03.08.2020

<sup>9</sup> Vgl.: Friedrich M.: Intelligenz aus philosophischpsychologischer Sicht. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. S. 140

<sup>10</sup> Stern W.: Die Intelligenz der Kinder und Jugendlichen und die Methoden ihrer Untersuchung. S. 3

der Verbrauch natürlicher Ressourcen) vollbringt, scheint diese Definition jedoch obsolet zu sein.<sup>11</sup>

Mainzer definiert ein intelligentes System, welches beispielsweise bei selbstfahrenden Autos, der Diktierfunktion, Robotern oder der personalisierten Werbung vorzufinden ist, folgendermaßen:

*„Ein System heißt intelligent, wenn es selbstständig und effizient Probleme lösen kann. Der Grad der Intelligenz hängt vom Grad der Selbstständigkeit, dem Grad der Komplexität des Problems und dem Grad der Effizienz des Problemlösungsverfahrens ab.“<sup>12</sup>*

Somit stellt die KI in Abgrenzung zur natürlichen (z.B.: menschlichen) Intelligenz ein durch technisches Eingreifen entstehendes System dar, das selbstständig und effizient Probleme lösen kann.<sup>13</sup> Ein weiteres wesentliches Unterscheidungsmerkmal liegt im Vorhandensein eines eigenen Bewusstseins, welches selbst die am höchsten entwickelten KI-Systeme derzeit nicht besitzen, wodurch diese trotz aller Fortschritte lediglich programmierte Datenmodelle bleiben.<sup>14</sup> Somit stellt aktuell die künstliche Intelligenz ein Werkzeug wie etwa Hammer und Säge dar, das auf das menschliche Bewusstsein angewiesen ist.<sup>15</sup> In diesem Fall wird auch von schwacher KI gesprochen, weil es lediglich zu einer Simulation des Denkens kommt.<sup>16</sup> Im Gegensatz dazu verfügt die starke KI über ein eigenes Bewusstsein, wodurch die gleichen kognitiven Fähigkeiten wie die eines Menschen erzielt werden.<sup>17</sup>

Ebenso existiert eine Differenzierung in spezialisierte und allgemeine KI. Hierbei ist festzuhalten, dass ersteres eine anwendungsbezogene KI darstellt, welche nur bestimmte Aufgabenstellungen wie beispielsweise Bilderkennung oder Sprachverarbeitung lösen kann. Die auf konkrete Anwendungstypen vorhandene Beschränktheit ist hingegen bei der allgemeinen KI nicht gegeben. Somit ermöglicht diese aufgrund der generalisierenden Form die gleichen Fähigkeiten, die mittels der menschlichen kognitiven Apparatur vollbracht werden können.<sup>18</sup>

Eine konzeptuelle Sonderform stellt die künstliche Superintelligenz dar. Diese folgt dem Gedanken, dass sich die KI nach dem Erreichen des menschlichen Niveaus selbstständig weiterentwickeln und die menschliche Intelligenz bei weitem übersteigen würde. Wie auch bei der allgemeinen und starken KI ist nicht geklärt, wann bzw. ob überhaupt jemals eine Superintelligenz existieren wird.<sup>19</sup>

Eine weitere, häufig zitierte Definition von künstlicher Intelligenz ist jene von Rich, Knight und Nair:

*„Artificial Intelligence is the study of how to make computers do things at which, at the moment, people are better.“<sup>20</sup>*

<sup>11</sup> Vgl.: Friedrich M.: Intelligenz aus philosophischpsychologischer Sicht. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. S. 157

<sup>12</sup> Mainzer, K.: Künstliche Intelligenz – Wann übernehmen die Maschinen?. S. 3

<sup>13</sup> Vgl.: Heichele, T.: Künstliche Intelligenz im Lichte der Technikphilosophie. Ein Überblick unter besonderer Berücksichtigung des Mensch-Natur-Technik-Verhältnisses. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. S. 91

<sup>14</sup> Vgl.: Krüger, S.: Die KI-Entscheidung – Künstliche Intelligenz und was wir daraus machen. S. 116

<sup>15</sup> Vgl.: Meixner, U.: Bewusstseinsintelligenz und Künstliche Intelligenz. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. S. 14

<sup>16</sup> Vgl.: Heichele, T.: Künstliche Intelligenz im Lichte der Technikphilosophie. Ein Überblick unter besonderer Berücksichtigung des Mensch-Natur-Technik-Verhältnisses. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. S. 83f

<sup>17</sup> Vgl.: Krüger, S.: Die KI-Entscheidung – Künstliche Intelligenz und was wir daraus machen. S. 89

<sup>18</sup> Vgl.: Heichele, T.: Künstliche Intelligenz im Lichte der Technikphilosophie. Ein Überblick unter besonderer Berücksichtigung des Mensch-Natur-Technik-Verhältnisses. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. S. 84

<sup>19</sup> Vgl.: Krüger, S.: Die KI-Entscheidung – Künstliche Intelligenz und was wir daraus machen. S. 89

Mit anderen Worten: Die künstliche Intelligenz beschreibt Vorhaben, bei denen einem Computer beigebracht wird, Aufgabenstellungen zu lösen, welche derzeit vom Menschen besser bewältigt werden. Das bedeutet, Maschinen erlernen eine intellektuelle Verarbeitungsfähigkeit, um Daten und Informationen nach humanem Vorbild auswerten und interpretieren zu können.

Amazon, einer der größten KI-Anbieter, versteht unter künstlicher Intelligenz die Beschäftigung mit dem Erwerb kognitiver Fähigkeiten, die in der Regel dem menschlichen Intellekt zugeordnet werden. Hierzu gehören beispielsweise das Lernen, die Problemlösung und die Mustererkennung.<sup>21</sup>

Ein weiterer Begriff, der oftmals in Verbindung mit künstlicher Intelligenz Anwendung findet, ist Machine Learning (ML). Dieser darf jedoch nicht mit KI gleichgesetzt werden, weil maschinelles Lernen eine Teildisziplin der künstlichen Intelligenz darstellt. Sie nimmt unterschiedliche Formen des Selbstlernens bei Systemen an und versucht, Regel- und Gesetzmäßigkeiten in Daten zu erkennen, um daraus Aktionen abzuleiten.<sup>22</sup> Das bedeutet, durch ML wird Wissen erzeugt, um weitere Aufgaben zielgerichtet lösen zu können.

Die Lernverfahren lassen sich in überwachtes Lernen (Supervised Learning), unüberwachtes Lernen (Unsupervised Learning) und Lernen durch Verstärkung (Reinforcement Learning) unterteilen. Bei letzterem eignet sich die Maschine nicht Wissen anhand eines Datensatzes, sondern auf Basis eines Belohnungssystems (beispielsweise wie bei der Erziehung eines Hundes) an.

Ein typisches Anwendungsfeld stellt hierbei die Robotik dar. Aufgrund der häufig auftretenden, komplexen Aufgabenstellungen für Roboter ist es nicht möglich, die Lösung in einem einfachen Programmcode zu implementieren. Aus diesem Grund ist es notwendig, dass die Maschine selbst – ähnlich wie ein Kleinkind – durch viele Versuche und Irrtümer herausfindet, wie sie sich beispielsweise am effizientesten und effektivsten fortbewegen kann.<sup>23</sup>

Beim unüberwachten Lernen wird versucht, innerhalb vorgegebener, nicht bewerteter Trainingsdaten ein Muster zu erkennen, welches nicht alleine durch ein gleichmäßig im Raum verteiltes, zufälliges Rauschen entstanden ist. Mathematisch gesehen spiegelt dies die Ermittlung struktureller Aussagen über die Verteilung der Trainingsdaten wider. Hierbei stellt der Algorithmus eine Modellannahme bezüglich des Datensatzes und dessen Eigenschaften auf. Diese gilt es, mittels Statistik zu prüfen, um herauszufinden, wie gut die im Modell vorkommenden Größen geschätzt werden.<sup>24</sup>

Beim überwachten Lernen wird anhand von bewerteten Trainingsdaten eine Abbildung der Inputvariablen auf die Outputs erlernt. An dieser Stelle ist es wichtig, hervorzuheben, dass für jeden Trainingsfall innerhalb eines Datensatzes sowohl die Eingabe X als auch die dazugehörige Ausgabe Y vorhanden sein muss. Diese Gegenüberstellung (X-Y) repräsentiert den Lehrer und legt die Basis, um Wissen herauszufiltern. Das bedeutet, die Aufgabe dieser Art von maschinellen Lernverfahren ist das Finden einer

<sup>20</sup> Rich, E.; Knight, K.; Nair S. B.: Artificial Intelligence. S. 3

<sup>21</sup> Amazon: Künstliche Intelligenz. <https://aws.amazon.com/de/machine-learning/what-is-ai/>. Datum des Zugriffs: 03.08.2020

<sup>22</sup> Gabler Wirtschaftslexikon: Machine Learning. <https://wirtschaftslexikon.gabler.de/definition/machine-learning-120982>. Datum des Zugriffs: 03.08.2020

<sup>23</sup> Vgl.: Ertel, W: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 313

<sup>24</sup> Vgl.: Richter, S.: Statistisches und maschinelles Lernen. S. 289

Funktion, die unter Beachtung des Rauschens innerhalb der Daten die Zusammenhänge bestmöglich abbildet. Die gefundenen Beziehungen werden in weiterer Folge für das Auswerten neuer Inputs herangezogen.<sup>25</sup>

Weiters stellt Supervised Learning inzwischen eine etablierte Ingenieurdisziplin mit vielen erfolgreichen Anwendungsfällen dar. Sind ausreichend Inputdaten mit dazugehörigem Output vorhanden, bietet die Mathematik und Informatik eine große Anzahl an Funktionsapproximationsalgorithmen, mit Hilfe derer zielführende Klassifizierungen oder Prognosen erstellt werden können. Beispielsweise werden hierbei neuronale Netze effektiv eingesetzt.<sup>26</sup>

Die nachfolgende Abbildung 2-6 verdeutlicht die soeben beschriebenen Zusammenhänge zwischen Informatik, künstlicher Intelligenz und maschinellem Lernen. Weiters werden von letzterem die drei Lernverfahren dargestellt.

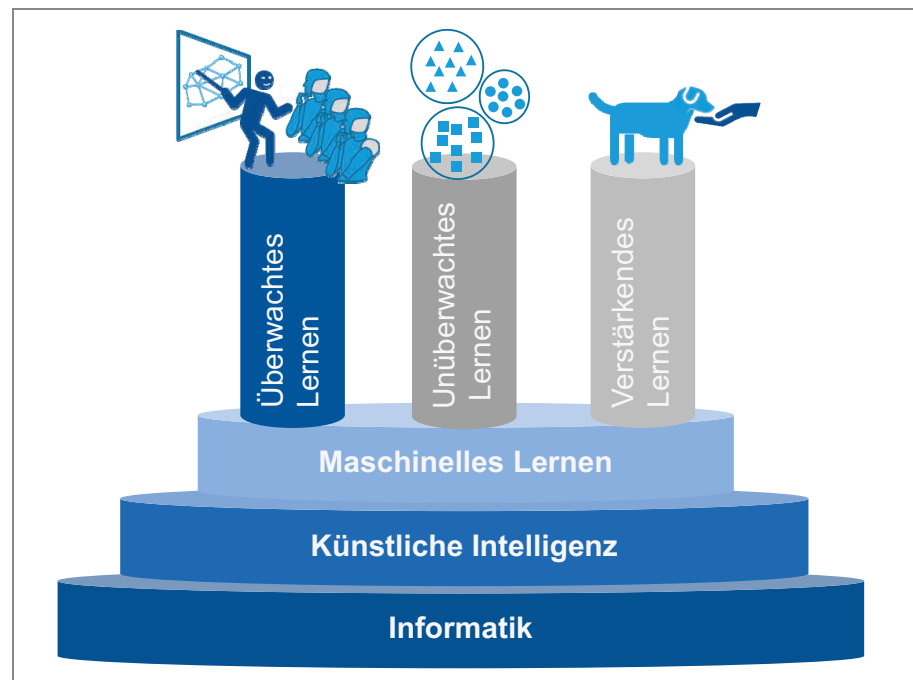


Abb. 2-6 Einteilung des maschinellen Lernens

### 2.2.1 Nachahmung der Funktionsweise des menschlichen Gehirns

Neuronale Netze stellen Verbindungen aus Nervenzellen im Gehirn von Menschen und Tieren dar. Den komplexen Verschaltungen zwischen diesen winzigen Bausteinen und deren Adaptivität verdankt der Homo sapiens seine Intelligenz und die Fähigkeit zu lernen. Weiters wird dadurch die Basis für das Lösen von motorischen und intellektuellen Problemstellungen unter variablen Umweltbedingungen geschaffen.<sup>27</sup>

Dass das Gehirn die Schaltstelle bei Informationsverarbeitungen darstellt, ist seit Beginn des 19. Jahrhunderts bekannt. Seither wurden die rund 80 Mrd. Nervenzellen im Hirnstamm, Kleinhirn, Zwischenhirn und Großhirn intensiv

<sup>25</sup> Vgl.: Ertel, W: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 313

<sup>26</sup> Vgl.: Ertel, W: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 257f

<sup>27</sup> Vgl.: Ertel, W: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 265

erforscht, damit unter anderem die menschliche Wahrnehmung, Assoziationen, Gedanken und die Lernfähigkeit besser nachvollzogen werden können. Der Hirnstamm selbst ist verantwortlich für die Verarbeitung der eingehenden Sinneseindrücke und der ausgehenden motorischen Reaktionen. Weiters werden in diesem Bereich die Reflexe und die automatischen Körperfunktionen (z.B.: die Atmung) gesteuert. Das Kleinhirn übernimmt hingegen das Gleichgewicht, die Bewegungskoordination sowie das unbewusste Lernen. Das Zwischenhirn überträgt sensorische und motorische Reize hin zum Großhirn und ist unter anderem auch für die Schlafsteuerung, das Schmerzempfinden und die Temperatursteuerung verantwortlich. Im Bereich des Großhirns werden visuelle und akustische Informationen wahrgenommen. Ebenso ist es für die Bewegungskontrolle, die Tastwahrnehmung und das Gedächtnis zuständig.<sup>28</sup>

Die Struktur des Gehirns, welche sich aus den einzelnen Nervenzellen ergibt, ändert sich entsprechend den Aktivitäten des Individuums ständig. Das bedeutet, die winzigen Bauteile schaffen von selbst neue Verbindungen oder lösen alte. Ein einzelnes Neuron ist hierbei mit 1.000 bis zu 10.000 weiteren verbunden. Weiters ist die Nervenzelle in einem weichen dreidimensionalen Gewebe eingelagert. Dadurch wird rasch ersichtlich, dass ein Zeichnen eines Schaltplanes für das bessere Verständnis des Gehirns ein Ding der Unmöglichkeit ist. Aus heutiger Sicht ist dies jedoch auch nicht mehr notwendig, weil nicht die Struktur, sondern die Synapsen, welche die Verbindungen zwischen den Neuronen herstellen, die zentrale Rolle spielen. Das besondere hierbei ist, dass diese Verbindungsstellen nicht perfekt leitend ausgeführt sind. Das freie Wandern der Elektronen wird durch einen kleinen Spalt erschwert, welcher mit einer chemischen Substanz, den Neurotransmittern, gefüllt ist. In Abhängigkeit diverser Parameter wie beispielsweise der Konzentration oder der chemischen Zusammensetzung von Neurotransmittern haben diese Spalte unterschiedliche Leitfähigkeiten beim Übertragen von Ladungen. Werden die synaptischen Verbindungen durch Substanzen wie zum Beispiel Alkohol oder Drogen manipuliert, reagiert das Gehirn sehr sensibel auf diese Veränderungen.<sup>29</sup>

Der Zellkörper des Neurons dient der Speicherung von kleinen elektrischen Spannungen und ist mit einem Kondensator oder einer Batterie zu vergleichen. Die Ladung erfolgt durch eingehende Spannungsimpulse anderer Nervenzellen so lange, bis ein gewisser Schwellenwert überschritten wird. Ist dies der Fall, feuert das Neuron. Hierbei wird die im Speicher angesammelte Spannung über alle Verbundstellen an andere Neuronen weitergegeben, in denen der gleiche Prozess abläuft. Welche Menge über den Berührungspunkt weitergereicht werden kann, ist von der dortigen Leitfähigkeit abhängig. Das Interessante dabei ist, dass durch eine gezielte Steuerung der Synapsen die Struktur verändert wird. Je größer die Notwendigkeit einer Verbindung, desto stärker wird diese ausgebildet. Das bedeutet, dass bei vermehrter Anzahl an Spannungsimpulsen der dortige Widerstand gesenkt wird. Bei Verbindungsstellen, welche sehr wenig genutzt werden, nimmt die Leitfähigkeit stark ab, bis sie schließlich vollkommen verloren geht und somit zum Absterben führt. Diese soeben beschriebene Adaptivität ist die Grundlage für die menschliche Fähigkeit, sich an ein Umfeld anzupassen und zu lernen.<sup>30</sup>

<sup>28</sup> Vgl.: Kaffka, T.: Neuronale Netze. Grundlagen. S. 24

<sup>29</sup> Vgl.: Ertel, W: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 266

<sup>30</sup> Vgl.: Ertel, W: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 266ff

Zum Abschluss des biologischen Exkurses gilt es noch anzumerken, dass bis heute noch nicht erforscht ist, wie diese bereits bekannten Prinzipien das intelligente Verhalten ermöglichen. Aus diesem Grund versuchen Wissenschaftler\*innen der Neuroinformatik zu neuen Erkenntnissen durch Simulationen von mathematischen Modellen neuronaler Netze zu gelangen, um beispielsweise zu erklären, wie die Mustererkennung möglich wird. Der erste Schritt erfolgte hierfür von *McCulloch* und *Pitts* im Jahre 1943, in dem sie ein mathematisches Modell des Neurons als grundlegendes Schaltelement von Gehirnen vorstellten.<sup>31</sup>

### 2.2.2 Mathematischer Hintergrund

Wie auch beim menschlichen Vorbild bestehen die künstlichen neuronalen Netze aus einzelnen Neuronen, die untereinander in Verbindung gesetzt werden. Jedoch setzen sich hierbei die Grundbausteine nicht aus biologischen Zellen zusammen, sondern werden durch eine Modellbildung in Form mathematischer Funktionen veranschaulicht. Somit ist ein Neuron mit einer Variablen, welche bestimmte Zahlenwerte aufgrund hinterlegter Zusammenhänge annehmen kann, gleichzusetzen. Meistens weist es einen positiven reellen Wert auf, wobei auch zu erwähnen ist, dass abhängig von speziellen Netztypen ebenso binäre (0 oder 1) oder bipolare (-1 oder +1) Werte hinterlegt werden können.<sup>32</sup>

Die ersten neuronalen Netze bauten auf binären Neuronen auf, weil die Nervenzelle zu Beginn als logisches Schwellenwertelement gesehen worden ist. Über Eingangsleitungen, von denen mehrere vorliegen können, gelangen somit nur Impulse in Form von Einsen und Nullen zum Grundbaustein. Zunächst addiert das Element alle eintreffenden Reize auf und sobald ein bestimmter Schwellenwert überschritten wird, gibt das Neuron selbst einen Impuls (Zustand 1) weiter. Hinzu kommt, dass die einzelnen Leitungen zwischen den künstlichen Nervenzellen eine hemmende (-1) oder eine erregende (+1) Wirkung haben. Dadurch wird versucht, die Synapsenstärke zu modellieren. Ein Nachteil dieses Aufbaues ist jedoch, dass nicht gezeigt werden kann, wie das Lernen zustande kommt. Um diesem Problem entgegenzuwirken, wird die Verbindung der Synapsen variabel gestaltet. Dies ermöglicht, dass beim Lernvorgang die Anpassung der Verbindungen mit vom Lernverfahren abhängigen Beträgen erfolgen kann.<sup>33</sup>

Die soeben vorgestellten Neuronen, die auch Units, Einheiten oder Knoten genannt werden, haben somit die Aufgabe, Informationen aus der Umwelt oder von anderen Neuronen aufzunehmen, zu modifizieren und an andere Units oder die Umwelt weiterzugeben. Abhängig vom Ausgangspunkt der Reize sowie dem Zielort lassen sich die künstlichen Neuronen in drei verschiedene Arten unterteilen:<sup>34</sup>

- Input-Neuronen: empfangen Signale/Reize von der Außenwelt
- Hidden-Neuronen: befinden sich zwischen Input- und Output-Neuronen und beinhalten eine interne Repräsentation der Außenwelt
- Output-Neuronen: geben Signale an die Außenwelt weiter

<sup>31</sup> Vgl.: Ertel, W.: Grundkurs Künstliche Intelligenz. 4. Auflage. S. 265

<sup>32</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 141

<sup>33</sup> Vgl.: Kaffka, T.: Neuronale Netze. Grundlagen. S. 29ff

<sup>34</sup> Vgl.: Rey, G. D.; Beck, F.: Neuronale Netze. <http://www.neuralesnetz.de/>. Datum des Zugriffs: 13.08.2020

Die zuvor erwähnten Verbindungen der Units, welche auch als Gewichtungen bezeichnet werden, bilden den zweiten wesentlichen Bestandteil. In Abhängigkeit ihrer Einflusstärke werden größere oder kleinere Werte in der Gewichtsmatrix  $W = (w_{ij})$  gespeichert. Diese wird in weiterer Folge mit dem Vektor der Eingangswerte multipliziert, um anschließend vom Neuron weiter verarbeitet zu werden.<sup>35</sup> Weiters kann in der Regel anhand dieser Matrix die topologische Struktur des Netzes abgelesen werden.<sup>36</sup> Das bedeutet, dass bei der Analyse der eingetragenen Abhängigkeiten ersichtlich wird, wie die Neuronen zueinander in Verbindung stehen. Beträgt das Gewicht Null, existiert kein Einfluss.

An dieser Stelle ist darauf hinzuweisen, dass erst die Gewichtungen zwischen den einzelnen Neuronen die Adaptionfähigkeit ermöglichen. Sie weisen Ähnlichkeiten mit der Leitfähigkeit einer Synapse im menschlichen Gehirn auf und bilden dadurch die Basis für das Erlernen von intellektuellen Fähigkeiten und deren Anwendung bei unterschiedlichen Umweltbedingungen.

Die nachfolgende Abbildung 2-7 zeigt den schematischen Aufbau eines im Bereich des Baubetriebs und der Bauwirtschaft eingebetteten neuronalen Netzes, um Prognosen zu erstellen.

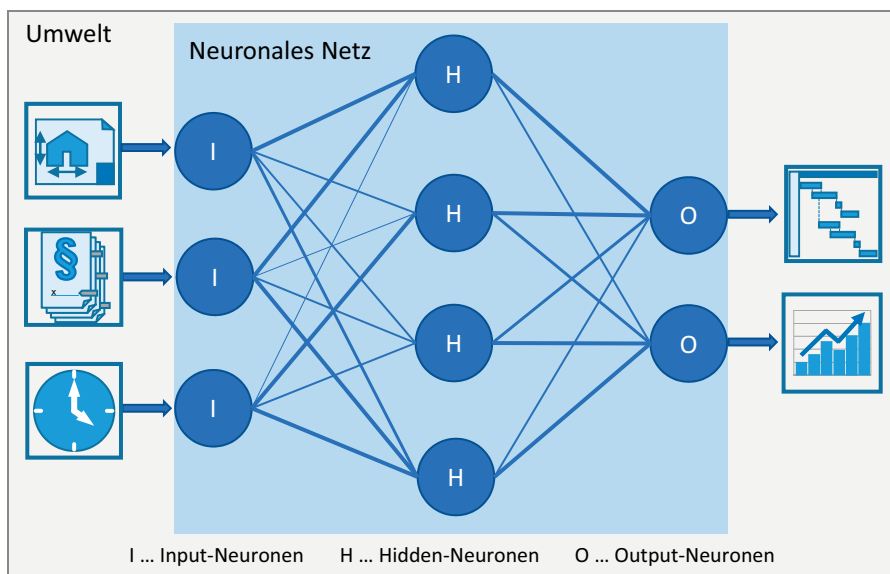


Abb. 2-7 Schematischer Aufbau eines neuronalen Netzes<sup>37</sup>

Die in der Grafik dargestellten runden Kreise repräsentieren die einzelnen Neuronen, wobei Neuronen mit der gleichen Aufgabe in einer Schicht, dem sogenannten Layer, zusammengefasst werden. Die Input-Neuronen (I) befinden sich immer am Anfang eines neuronalen Netzes und nehmen die vorgegebenen Reize aus der Umwelt auf. In diesem Fall sind dies Pläne, Bauverträge oder Zeitvorgaben. Die O-Einheiten verkörpern die Output-Neuronen, werden im Output-Layer angeordnet und geben die Ergebnisse – beispielsweise Tätigkeitsanordnungen, Dauern in Bauzeitplänen oder Kostenentwicklungen – an die Umwelt zurück. Zwischen den sieben

<sup>35</sup> Vgl.: Richter, S.: Statistisches und maschinelles Lernen. S. 225f

<sup>36</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 141

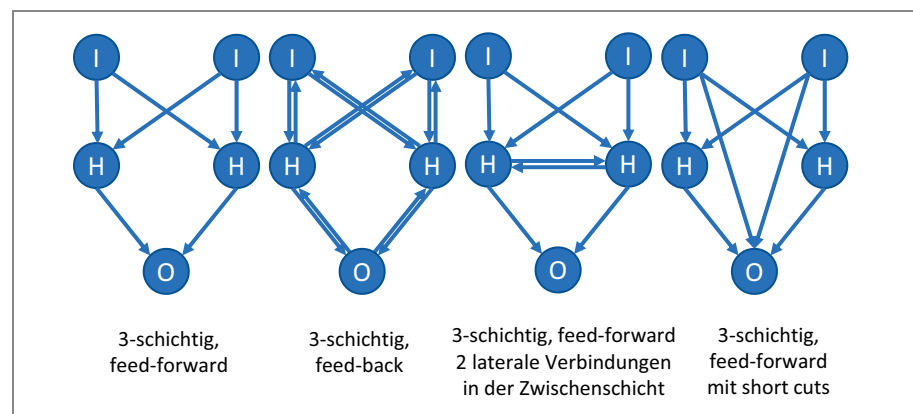
<sup>37</sup> Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2018. S. 8



genannten Schichten sind die Hidden-Neuronen (H) anzutreffen. Diese speichern die erlernten Zusammenhänge und können auch in einem oder mehreren Hidden-Layern zusammengefasst werden. Die Verknüpfungen zwischen den Units, sprich die Einflüsse untereinander, werden durch Linien dargestellt. Die unterschiedlichen Strichstärken repräsentieren die verschiedenen Beträge der Gewichtungen, welche in der Matrix eingetragen sind.

Die Struktur innerhalb der Gewichtsmatrix ist frei wählbar. Das bedeutet, es können neuronale Netze in homogenen Umgebungen konstruiert werden, bei denen jedes Neuron mit allen restlichen Units verbunden ist. Solche freien Strukturen rufen jedoch häufig aufgrund maximaler Rückkopplung komplexe Dynamiken hervor und konvergieren nur selten. Weil dadurch die Stabilität der Ergebnisse leidet, werden derartige Netze nur in wenigen Fällen eingesetzt.<sup>38</sup>

Damit die Ordnung innerhalb künstlicher neuronaler Netze erhöht wird, werden einzelne Neuronen in Schichten zusammengefasst, wobei sie untereinander keine Verbindung aufweisen. Nur Einheiten aus verschiedenen Klassen üben einen Einfluss aufeinander aus. In der Gewichtsmatrix ist diese strukturbildende Maßnahme in Form von Null-Blöcken zu erkennen. Weiters spielt auch die Richtung der Verbindungen eine wesentliche Rolle, weil dadurch die Anordnung der Layer untereinander festgelegt wird. Erfolgt die Reihenfolge wie in Abbildung 2-7 vom Input in Richtung Output, wird von Feedforward-Strukturen gesprochen. Existieren hingegen Verbindungen, die entgegen dieser Vorzugsrichtung verlaufen, tragen sie die Benennung rekurrent, während Abhängigkeiten innerhalb eines Layers als laterale Verbindungen bezeichnet werden. Die nachfolgende Abbildung 2-8 zeigt einige Beispiele.<sup>39</sup>



**Abb. 2-8** Schematische Darstellung von Netzstrukturen<sup>40</sup>

Beim Einsatz von vier Neuronen existieren bereits 218 verschiedene Graphen-Strukturen mit gerichteten Verbindungen. Liegen sechs Neuronen vor, steigt die Anzahl auf rund 1,5 Millionen Möglichkeiten. Aufgrund dieses explosionsartigen Anstiegs ist es sinnvoll, sich auf wenige spezielle Strukturen zu beschränken. Dadurch wird gewährleistet, dass die üblichen zu lösenden oder simulierenden Probleme bewältigt werden können. Ein weiterer Grund für die Verwendung strukturschaffender Maßnahmen ist, dass nur für wenige Neuronenkonstellationen Lernalgorithmen existieren, die

<sup>38</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 143

<sup>39</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 143f

<sup>40</sup> Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2018. S. 9

In Anlehnung an: Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 144f

theoretisch ausreichend erfassbar sind und dadurch fundierte Aussagen über das Konvergenzverhalten gemacht werden können. Der dritte Grund für eine Struktur im neuronalen Netz ist in der Performance der Programme zu finden. Natürlich ist es möglich, eine Software zu entwerfen, die jeden beliebigen Aufbau unterstützt. Jedoch wird dadurch in Kauf genommen, dass mit zunehmender Neuronenzahl die Algorithmen, welche die Gewichtsmatrizen verarbeiten müssen, uneffektiver und langsamer werden. Um Rechenschritte zu minimieren, werden daher in der Praxis die Programme auf bestimmte Netzstrukturen zugeschnitten.<sup>41</sup>

Typische und weitverbreitete Fälle stellen daher Schichtstrukturen in Verbindung mit reinen Feedforward-Architekturen dar. Durch das separate Abarbeiten aufeinanderfolgender Schichten können kleinere Teilmatrizen abgespalten und unter deutlich geringerem Rechenaufwand gelöst werden. Netze mit rekurrenten Verbindungen führen zu weitaus komplexeren Dynamiken, wodurch sich wiederum Probleme bei der Konvergenz bzw. Stabilität ergeben können. Bei der Wahl der Netzstruktur empfiehlt es sich daher, aus der Literatur ein im selben Fachbereich eingesetztes neuronales Netz zu suchen und dieses anschließend anzupassen. Somit ist sichergestellt, dass der Netzaufbau und die Lernalgorithmen zusammenspielen, was sich in weiterer Folge positiv auf die Eignung und Effizienz der künstlichen Intelligenz auswirkt. Ebenso gilt es zu beachten, dass mit keiner zu komplexen Neuronenkonstellation begonnen wird.<sup>42</sup>

### 2.2.3 Funktionen

Mathematisch gesehen basieren künstliche neuronale Netze auf einer Grundstruktur von Graphen<sup>43</sup>, deren wichtigste Repräsentation die Gewichtsmatrizen sind. Jede Ecke der Graphen wird hierbei als Neuron bezeichnet und bekommt einen Zustand (Aktivierung) sowie eine Transformationsfunktion zugesprochen. Letztere ist in der Regel in drei hintereinander auszuführende Funktionen (Propagierungs-, Aktivierungs- und Outputfunktion) unterteilt. In der Praxis ist es üblich, entweder für alle Neuronen oder zumindest für Units innerhalb einer Schicht dieselben mathematischen Zusammenhänge zu hinterlegen. Schlussfolgernd kann somit gesagt werden, dass ein Neuron nichts anderes als eine Variable darstellt, die verschiedene Zahlenwerte annehmen kann.<sup>44</sup>

Nachfolgend werden die gebräuchlichsten Propagierungs-, Aktivierungs- und Outputfunktionen kurz erklärt, weil diese große Auswirkungen auf die Netzeigenschaften haben.

#### Propagierungsfunktionen

Der lineare Zusammenhang stellt die einfachste Form von Propagierungsfunktionen dar. Der Nettoinput ( $net_j$ ) wird hierbei durch das Aufaddieren der Produkte (Ergebnis der Multiplikation) aus den einzelnen Outputs ( $o_i$ ) der sendenden Neuronen mit der dazugehörigen Gewichtung ( $w_{ij}$ ) berechnet. Diese Summenbildung wird in Gleichung (2-1) gezeigt. Wird zusätzlich ein Schwellenwert  $\Theta_j$  berücksichtigt, ist der Nettoinput nach Gleichung (2-2) zu

<sup>41</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 144f

<sup>42</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 145ff

<sup>43</sup> Graph: Ein Graph beschreibt die Beziehungen zwischen einer Menge von Objekten (Knoten)  
Vgl.: FU Berlin: <http://www.inf.fu-berlin.de/lehre/WS08/mafi1/skript5.pdf>. Datum des Zugriffs: 21.08.2020

<sup>44</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 139ff

berechnen. An dieser Stelle ist jedoch zu erwähnen, dass in den meisten Fällen ein Grenzwert innerhalb der Propagierungsfunktion durch eine geeignete Aktivierungsfunktion ersetzt wird.<sup>45</sup>

$$\text{net}_j = \sum_{i=1}^n w_{ij} o_i \quad (2-1)$$

$$\text{net}_j = \begin{cases} x & \text{für } \sum_{i=1}^n w_{ij} o_i > \Theta_j \\ 0 & \text{sonst} \end{cases} \quad (2-2)$$

### Aktivierungsfunktionen

Die Aktivierung eines Neurons wird häufig erst durch die Modifizierung des Nettoinputs dargestellt. Die hierbei erzielte Veränderung hängt von der Wahl der eingesetzten Aktivierungsfunktion  $F_j(\text{net}_j)$  ab und bestimmt in starkem Ausmaß die Eigenschaften des Netzes. Zu den wichtigsten Aufgaben, welche diese Funktion erfüllen muss, zählt es, die Aktivierungswerte  $a_j$  der einzelnen Neuronen in einem sinnvollen Intervall zu halten. Dadurch wird ein ständiges Anwachsen aufgrund der Summation der einzelnen Beiträge der Neuronen verhindert, wodurch das Netz stabiler wird und leichter konvergiert. Weiters werden unnötige Rechenoperationen aufgrund infinitesimal kleiner Veränderungen reduziert. Weil die Aktivierungsfunktion somit festlegt, ob Nicht-Linearitäten abgebildet werden können, mit welchen Aktivierungswerten ein Netz arbeitet (z.B.: binär) und wie schnell es konvergiert, zählt diese Funktion zum Herzstück der künstlichen neuronalen Netze. Aus diesem Grund hat die Auswahl immer unter Berücksichtigung der zugrundeliegenden Aufgabenstellung zu erfolgen. Folgende Aktivierungsfunktionen sind in der Praxis sehr gebräuchlich.<sup>46</sup>

#### Schwellenwertfunktion

$$a_j = \begin{cases} x & \text{für } \text{net}_j > \Theta_j \\ y & \text{für } \text{net}_j \leq \Theta_j \end{cases} \quad (2-3)$$

In Gleichung 2-3 repräsentieren  $x$  und  $y$  mögliche Aktivierungszustände des Neurons  $j$ , welche in Abhängigkeit des Nettoinputs und des angegebenen Schwellenwertes  $\Theta_j$  berechnet werden. Diese Beschränkungen können individuell für jedes Neuron selbst, für ganze Klassen oder für das gesamte Netz festgelegt werden. Weiters ist anzumerken, dass eine Schwellenwertfunktion auch häufig bei Outputfunktionen eingesetzt wird.<sup>47</sup>

#### Signumfunktion $\text{sgn}(\text{net}_j)$

Diese Funktion, auch Vorzeichenfunktion genannt, liefert die Aktivierungszustände  $a_j = +1$  oder  $-1$  und wird daher bei bipolar kodierten Netzen eingesetzt.<sup>48</sup> Die folgende Abbildung 2-9 und die kommende Gleichung (2-4)

<sup>45</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 149

<sup>46</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 150

<sup>47</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 150

<sup>48</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 150

stellen die Signumfunktion dar, welche jeder reellen Zahl ihr Vorzeichen zuordnet.<sup>49</sup>




Abb. 2-9 Signumfunktion<sup>50</sup>

$$a_j = \begin{cases} 1 & \text{für } x > 0 \\ 0 & \text{für } x = 0 \\ -1 & \text{für } x < 0 \end{cases} \quad (2-4)$$

### Lineare Aktivierungsfunktion

$$a_j = \sum_{i=1}^n w_{ij} o_i = \text{net}_j \quad (2-5)$$

In Gleichung (2-5) wird eine lineare Aktivierungsfunktion gezeigt. Weil diese aufgrund der dargestellten Summation beliebig anwachsen kann, werden häufig eine untere und eine obere Schranke,  $\Theta_u$  bzw.  $\Theta_o$ , hinzugefügt. Die modifizierte Funktion ist in Gleichung (2-6) ersichtlich und wird zusätzlich in Abbildung 2-10 verbildlicht.<sup>51</sup>

$$a_j = \begin{cases} \text{net}_j & \text{für } \Theta_u < \text{net}_j < \Theta_o \\ x & \text{für } \text{net}_j \leq \Theta_u \\ y & \text{für } \text{net}_j \geq \Theta_o \end{cases} \quad (2-6)$$

<sup>49</sup> Vgl.: Lexikon der Mathematik: Signumfunktion. online: <https://www.spektrum.de/lexikon/mathematik/signumfunktion/9749>. Datum des Zugriffs: 25.08.2020

<sup>50</sup> Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2018. S. 11

<sup>51</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 150f

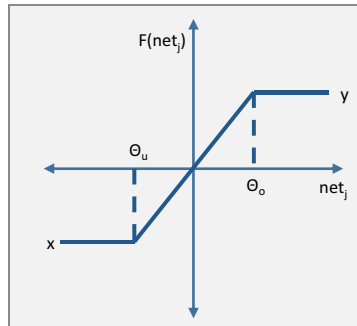


Abb. 2-10 Lineare Aktivierungsfunktion mit oberer und unterer Schranke<sup>52</sup>

Sigmoide Funktion

Sigmoide Funktionen, welche auch den Namen Schwanenhals- oder S-Funktionen tragen, werden oftmals als Aktivierungsfunktion eingesetzt. Die Namensgebung stützt sich hierbei auf den s-förmigen Verlauf. Ein häufig eingesetzter Zusammenhang stellt in diesem Bereich die logistische Funktion dar. Sie ist in Gleichung (2-7) ersichtlich und in Abbildung 2-11 schematisch aufbereitet.<sup>53</sup>

$$a_j = F_j(\text{net}_j) = \frac{1}{1 + e^{-\frac{\text{net}_j}{\delta}}} \tag{2-7}$$




Abb. 2-11 Schematische Darstellung einer sigmoiden Funktion<sup>54</sup>

Tangens-Hyperbolicus-Funktion

Ein weiterer funktionaler Zusammenhang mit der sigmoiden Form wird durch den Tangens-Hyperbolicus verkörpert. Die Aktivierungswerte werden nach Gleichung (2-8) berechnet. Der daraus resultierende Graph wird in Abbildung 2-12 wiedergegeben.<sup>55</sup>

$$a_j = F_j(\text{net}_j) = \tanh(\text{net}_j) \tag{2-8}$$

<sup>52</sup> Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2018. S. 12

<sup>53</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 151

<sup>54</sup> Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2018. S. 12

<sup>55</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 151

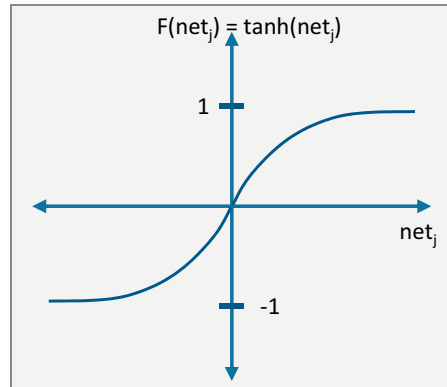


Abb. 2-12 Schematische Darstellung des Tangens-Hyperbolicus<sup>56</sup>

Bei praxisbezogenen Anwendungsfällen haben sich in Abhängigkeit der Aufgabenstellung verschiedene Funktionen und dazugehörige Parameter bewährt. Aus diesem Grund empfiehlt es sich, vor dem Entwurf eines Netzes die Literatur nach vergleichbaren Fällen zu durchsuchen, um mit den bereits erprobten Abhängigkeiten zu beginnen. Weiters gilt es, möglichst einfache und mit der Kodierung des Netzes abgestimmte Funktionen einzubauen. Die Schwellenwertfunktion ist häufig bei binär und die Signumfunktion bei bipolar kodierten Netzen zu finden. Ebenso ist hervorzuheben, dass Schwellenwert-, Signum- oder lineare Funktionen kurze Rechenzeiten hervorrufen.<sup>57</sup>

Der Vorteil der logistischen Funktion sowie des Tangens-Hyperbolicus ist, dass deren Ableitung, welche bei den Lernregeln einen wichtigen Platz einnimmt, durch die selbige Funktion ausgedrückt werden kann. Dies wird in Gleichung (2-9) gezeigt.<sup>58</sup>

$$\begin{array}{ll} \text{logistische Funktion:} & f'(x) = f(x)(1 - f(x)) \\ \text{Tangens-Hyperbolicus:} & f'(x) = 1 - (f(x))^2 \end{array} \quad (2-9)$$

### Outputfunktionen

Als Outputfunktion wird vorzugsweise die Identitätsfunktion oder die Schwellenwertfunktion implementiert. Ersteres ist in Gleichung (2-10) abgebildet und kann im Bedarfsfall noch skaliert werden. Letzteres wird in Gleichung (2-3) gezeigt und findet unter anderem bei ganzzahligen oder binären Outputs Verwendung wie beispielsweise bei der Mustererkennung oder der Simulation von Logikfunktionen. Ist eine bipolare Ausgabe gefordert, erfüllt die Signumfunktion diese Anforderung.<sup>59</sup>

$$o_j = a_j = F(\text{net}_j) \quad (2-10)$$

<sup>56</sup> Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2018. S. 13

<sup>57</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 152f

<sup>58</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 152

<sup>59</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 153

*Schmidt, Klüver und Klüver* fassen die drei Funktionen in jeweils einem Satz sehr treffend zusammen:

„Die Propagierungsfunktion fasst durch eine gewichtete Summe die Eingaben aus allen auf ein betreffendes Neuron  $j$  wirkenden anderen Neuronen zu der Netzeingabe  $net_j$  zusammen.

Die Aktivierungsfunktion erzeugt aus  $net_j$  und ggf. schon vorhandener Aktivierung einen neuen Aktivierungswert  $a_j$  des Neurons  $j$ .

Die Outputfunktion (Ausgabefunktion) erzeugt aus der Aktivierung  $a_j$  die Ausgabe  $o_j$ , die an andere Neuronen bzw. den Outputvektor weitergegeben wird.“<sup>60</sup>

Die soeben besprochenen Funktionen werden meistens global eingesetzt, das bedeutet, sie gelten für alle Neuronen im Netz oder zumindest in einer Schicht. Nur Schwellenwerte weisen gelegentlich lokale Anwendungen bei einzelnen Neuronen innerhalb eines Layers auf. Abschließend ist noch zu erwähnen, dass letztendlich die genaue Aufgabenverteilung von Propagierungs-, Aktivierungs- oder Outputfunktion innerhalb des Gesamtalgorithmus nur eine praktische und programmierertechnische Frage darstellt. Es kann problemlos die Propagierungs- oder Outputfunktion in die Aktivierungsfunktion integriert werden.<sup>61</sup>

#### 2.2.4 Die Fähigkeit zu lernen

Die Adaptionfähigkeit der künstlichen neuronalen Netze ermöglicht es, Zusammenhänge zu erkennen und somit zu lernen. Damit Wissen gespeichert werden kann, muss durch eine steuernde Instanz das Netz systematisch oder auch stochastisch verändert werden. Um die passenden Gewichtungen, sprich Abhängigkeiten der Neuronen untereinander, zu finden, muss diese Instanz zunächst den Status des Netzes evaluieren. Im Zuge dessen werden sowohl externe Größen wie beispielsweise ein Lernziel (Prognosewerte) oder ein zu erkennendes Muster (Bilder) als auch interne Größen, welche zum Beispiel Zustandsfunktionen darstellen, analysiert. Im ersten Fall handelt es sich um überwachtes Lernen oder auch Lernen mit Lehrer. Hierbei wird die Annäherung des Netzoutputs an das Lernziel zurückgegeben. Der zweite Fall ist dem nicht überwachten Lernen zuzuordnen.<sup>62</sup>

Die Anpassung eines künstlichen neuronalen Netzes an die Lösung einer Aufgabenstellung, kurz lernen, kann auf folgenden Ebenen Veränderungen bewirken:<sup>63</sup>

1. Hinzufügen neuer oder Löschen bestehender Neuronen
2. Hinzufügen neuer oder Löschen bestehender Verbindungen
3. Veränderung der Gewichtswerte  $w_{ij}$  (Verbindungsstärken der Neuronen, welche in der Gewichtsmatrix gespeichert sind)
4. Modifizierung der Transformationsfunktionen z.B.: durch den Einsatz eines anderen mathematischen Zusammenhangs oder Schwellenwerts
5. Abänderung der kontinuierlichen Inputs spezieller Neuronen

<sup>60</sup> Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 153

<sup>61</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 153f

<sup>62</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 140

<sup>63</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 140

Unter den ersten drei Möglichkeiten wird die Veränderung der Topologie eines Netzes verstanden, welche über die Anpassung der Gewichtsmatrix realisiert wird. Weist eine Verbindung den Wert Null auf, bedeutet dies, dass Neuron  $i$  auf  $j$  keinen Einfluss ausübt. Die letzten zwei Modifikationen können als Veränderung des Ablaufmodus interpretiert werden.<sup>64</sup>

Um den Stand eines Lernprozesses bewerten zu können, ist es notwendig, die Fehlerfunktion  $E$  einzuführen. Diese beschreibt bei überwacht lernenden neuronalen Netzen die Abweichung oder Distanz des Outputvektors  $Y$  zum Zielvektors  $T$ , der auch Target-Vektor genannt wird. Hierbei finden verschiedenste Distanzmaße Anwendung, wobei die euklidische Distanz, die in Gleichung (2-11) gezeigt wird, am häufigsten für  $n$ -dimensionale Vektoren mit binären, ganzzahligen oder reellen Komponenten eingesetzt wird.<sup>65</sup>

$$d = \sqrt{\sum_{i=1}^n (t_i - y_i)^2} \quad (2-11)$$

Oftmals findet jedoch auch nur das Quadrat derselben Funktion Anwendung, weil es beim Berechnen des Minimums der Distanz (Extremwertaufgabe) keine Auswirkung hat, ob die euklidische Distanz oder deren Quadrat, welche in Gleichung (2-12) abgebildet ist, eingesetzt wird.<sup>66</sup> Der Faktor  $1/2$  ermöglicht nach der Ableitung das Kürzen der herabgeschriebenen Hochzahl und führt somit zu einer Vereinfachung der Gleichung.

$$d = \frac{1}{2} \sum_{i=1}^n (t_i - y_i)^2 \quad (2-12)$$

Der Lernprozess läuft so lange, bis die Fehlerfunktion, welche den aktuellen Stand des Lernens bewertet, einen ausreichend kleinen Wert angenommen hat. Ist der gewünschte Fehlerwert erreicht oder unterschritten, ist das Suchen nach Zusammenhängen als abgeschlossen zu betrachten. Dieses Abbruchkriterium beinhaltet somit den Fehler des gesamten vom Netz ausgegebenen Outputvektors  $Y$  bezogen auf den ganzen Target-Vektor  $T$ , der aus dem Datensatz folgt. An dieser Stelle ist jedoch wichtig, hervorzuheben, dass dieser Wert nicht mit den Distanzen aus den einzelnen Komponenten  $y_i$  des Outputvektors und den dazugehörigen Komponenten  $t_i$  des Zielvektors gleichgesetzt werden darf. Diese Fehlerwerte der Form  $\delta_i = t_i - y_i$  beschreiben das Maß der einzelnen Abweichungen. Anwendung finden sie bei der Steuerung der mit den Komponenten verknüpften Gewichtswerten  $w_{ki}$  bzw. anderer Parameter, welche die Aktivierung  $y_j$  beeinflussen.<sup>67</sup>

Der durch die Fehlerfunktion bewertete Zustand eines Netzes hängt naturgemäß von allen Parametern ab, die während des Lernens angepasst werden können und dadurch die Adaption des Netzes ermöglichen. Die Darstellung der mehrdimensionalen Fehlerfunktion, welche die veränder-

<sup>64</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 140

<sup>65</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 160

<sup>66</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 160

<sup>67</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 160f



baren Gewichtswerte enthält, ist in Gleichung (2-13) beschrieben und stellt eine Fläche im  $n+1$ -dimensionalen Raum dar.<sup>68</sup>

$$E(W) = E(w_{ij}) \quad i = 1, 2, 3, \dots, n \quad (2-13)$$

Das Ziel des Lernprozesses, welcher beim überwachten Lernen in der Trainingsphase stattfindet, ist, auf Basis der bekannten Muster das globale Minimum der Fehlerfläche zu finden. Sobald der Gradient (Vektor, der die partiellen Ableitungen dieser Funktion enthält) den Wert Null aufweist, ist ein Minimum gefunden, weil es im untersuchten Punkt keinen weiteren steilsten Abstieg gibt. An dieser Stelle ist jedoch hervorzuheben, dass es sich bei dem detektierten Extremwert nicht zwingend um das globale Minimum handeln muss. Es kann auch lediglich ein lokales darstellen. Diese Vorgehensweise bei Abhängigkeiten mit mehreren Variablen ist mit der ersten Ableitung einer Funktion im zweidimensionalen Raum vergleichbar und liegt dem Gradientenabstiegsverfahren zu Grunde. Hierbei folgt man von einem Standpunkt aus, welcher den derzeitigen Systemzustand verkörpert, der Richtung des steilsten Abstiegs, sprich dem größten negativen Gradienten, um die Extremwertaufgabe zu lösen. Dieser soeben besprochene Algorithmus wird in seiner Grundfunktion oder in modifizierter Art und Weise (z.B.: konjugiertes Gradientenabstiegsverfahren) eingesetzt, um von einem beliebigen Punkt aus durch Modifikation der Variablen ein Minimum der Fehlerfläche zu erreichen.<sup>69</sup>

Beim Lernen in mehrschichtigen neuronalen Netzen ist es nicht möglich den Zwischenschichten konkrete Zielwerte zuzuordnen. Weil der Abgleich der Aktivierungen des Netzes mit dem Soll ausschließlich in dem Output-Layer erfolgt, müssen sich die Änderungen der Gewichte zwischen Input- und Hidden-Schicht sowie zwischen zwei Hidden-Layern aus den in der Ausgabe-Schicht berechneten Differenzen ergeben. Der bekannteste Lernalgorithmus, der hierbei eingesetzt wird, trägt den Namen Backpropagation und findet bei reinen Feedforward-Netzen mit mehreren Schichten sowie monotonen, differenzierbaren Aktivierungsfunktionen Anwendung. Die Namensgebung dieser Lernregel ist darauf zurückzuführen, dass die in der Output-Schicht errechneten Differenzen gegen die Rechenrichtung des Netzes, sprich rückwärts, in die Verbindungsgewichte eingearbeitet werden. Das fortlaufende Rückwärtsschreiten in die davor liegende Schicht ist wichtig, weil die Änderung eines Gewichtswertes  $w_{ij}$  vom Output aller empfangenden Neuronen der nächsten Schicht abhängt.<sup>70</sup>

### 2.3 Eingesetzte Software – NeuralTools

Prognosen und Klassifizierungen können mittels selbst programmierter oder kommerzieller Software erstellt werden. Hierbei gibt es jedoch große Unterschiede bei den Einsatzmöglichkeiten und in der Verwendungsfreiheit der Nutzer\*innen, weil mit zunehmender Distanz zur selbstständigen Programmierung die Fähigkeit der Neuentwicklung und Anpassung abnimmt. Gleichzeitig steigt jedoch die Anwenderfreundlichkeit. Weiters wird bei einem

<sup>68</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturalogier Verfahren. S. 161

<sup>69</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturalogier Verfahren. S. 161f

<sup>70</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturalogier Verfahren. S. 170ff

kommerziellen Produkt weniger Fachwissen benötigt als bei Eigenimplementierungen. Die Auswahl des Programmes oder der Programmierpakete ist somit immer auf den Anwendungsfall und die zur Verfügung stehenden Ressourcen zurückzuführen.

Die vorliegende Dissertation stützt sich auf NeuralTools<sup>71</sup>, ein Produkt der Palisade Corporation, da diese Software ein effizientes Erstellen und Verwalten von neuronalen Netzen ermöglicht. Weiters baut sie auf Microsoft Excel<sup>72</sup> auf, einem in der Bauwirtschaft und im Baubetrieb weit verbreiteten Programm, wodurch die Erreichbarkeit und die Nachvollziehbarkeit von Unternehmen gefördert wird. Zu Beginn dieser Arbeit wurden Überlegungen zum Einsatz von TensorFlow<sup>73</sup> und dessen benutzerfreundlicheren Erweiterung Keras<sup>74</sup> angestellt. Bald jedoch kristallisierte sich heraus, dass dieses datenstromorientierte Framework ein weitaus größeres Potenzial besitzt, als bei numerischen Prognosen benötigt wird, wodurch die Komplexität bei Demonstrationen unnötigerweise steigt. Um eine einfache Handhabung bei Vorzeigeprognosen sowie eine leichtere Nachvollziehbarkeit zu gewährleisten, wurde daher NeuralTools bewusst ausgewählt.

Ein weiterer Grund, der bei der Entscheidung mitgewirkt hat, ist, dass dieses Anwendungsprogramm mittels VBA-Makros<sup>75</sup> automatisiert werden kann, wodurch in weiterer Folge die Steuerung der Abläufe erleichtert wird. Abschließend ist noch anzuführen, dass bereits seit einigen Jahren am Institut für Baubetrieb und Bauwirtschaft der TU Graz erfolgreich Projekte mit einer Softwareunterstützung der Palisade Corporation durchgeführt werden.

Für eine genaue Anleitung zum Erstellen von Prognosen oder Klassifizierungen mit NeuralTools sei auf die Masterarbeit *Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft*<sup>76</sup> verwiesen. Im dortigen dritten Kapitel ist eine Anleitung zu finden, welche die Vorgehensweise Schritt für Schritt erklärt.

Ist die Entscheidung für ein bestimmtes Produkt gefallen, muss innerhalb der angebotenen Lösungsmöglichkeiten gearbeitet werden. Die Einschränkungen von NeuralTools werden nun im Folgenden näher erläutert.

Zu den wichtigsten Begrenzungen zählt, dass nur das Erstellen von mehrschichtigen Feedforward-Netzen, Wahrscheinlichkeits- und Regressionsnetzen möglich ist. Weiters ist bei ersterem die Anzahl an Hidden-Layer auf zwei Stück und die Neuronenanzahl je Layer auf 100 Einheiten beschränkt. Daraus wird sofort ersichtlich, dass mit Hilfe dieser Software kein Deep Learning<sup>77</sup> durchgeführt werden kann. Dies wäre aber auch aufgrund der geringen bauwirtschaftlichen und baubetrieblichen Datenlage nicht sinnvoll. Weiters besagt das Universal Approximation Theorem,<sup>78</sup> dass ein Feedforward-Netz mit einem Hidden-Layer eine stetige Funktion exakt nachbilden kann. Dies gilt jedoch nur, solange eine beliebige Anzahl an Hidden-Neuronen dem Layer hinzugefügt werden kann.<sup>79</sup> Aufgrund der

<sup>71</sup> <https://www.palisade.com/neuraltools/de/>. Datum des Zugriffs: 29.07.2019

<sup>72</sup> <https://products.office.com/de-at/excel>. Datum des Zugriffs: 29.07.2019

<sup>73</sup> <https://www.tensorflow.org/>. Datum des Zugriffs: 29.07.2019

<sup>74</sup> <https://keras.io/>. Datum des Zugriffs: 29.07.2019

<sup>75</sup> Visual Basics for Applications

<sup>76</sup> Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit am Institut für Baubetrieb und Bauwirtschaft. TU Graz. 2018

<sup>77</sup> Neuronales Netz mit mehreren Hidden-Layern

<sup>78</sup> Cybenko, G.: Approximation by superpositions of a sigmoidal function. In: Mathematics of Control, Signals, and Systems, 2 (4), 1989. S. 303-314

Hornik, K.; Stinchcombe, M.; White, H.: Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. In: Neural networks, 3 (5), 1990. S. 551-560

limitierten Datenmenge, die im Bauwesen für Prognosen und Klassifizierungen zur Verfügung steht, und dem Universal Approximation Theorem hat die soeben besprochene maximale Anzahl von zwei Hidden-Layern keinen wesentlichen Einfluss auf die Benutzbarkeit.

Ein ebenso wesentlicher Aspekt ist, dass NeuralTools keinen Backpropagation-Algorithmus beim Minimieren der Fehlerfunktion einsetzt. Die Anpassung der Gewichtungen erfolgt hierbei unter Verringerung der mittleren quadratischen Abweichungen mit Hilfe des konjugierten Gradientenverfahrens.<sup>80</sup>

Das besondere beim konjugierten Gradientenverfahren ist, dass dem Weg mit der steilsten Neigung unter Berücksichtigung der vorherigen Suchrichtungen gefolgt wird. Hierfür wird zunächst der Gradient am Startpunkt berechnet und dann als Richtungsvorgabe eingesetzt. Daraufhin gilt es, herauszufinden, wie weit diesem vorgeschlagenen Weg gefolgt werden soll. Dies geschieht, solange der Fehlerfunktionswert kleiner wird. Sobald er wieder zunimmt, ist ein neuer Tiefpunkt erreicht, der wiederum den Startpunkt für den nächsten Abstieg darstellt. Für die weitere Suche ist daraufhin die neue Richtung, welche durch den konjugierten Gradienten vorgegeben wird, zu bestimmen. Zu den Merkmalen dieses Gradienten zählt, dass die Richtungsanteile, welche parallel zu den vorherigen steilsten Abstiegen verlaufen, nicht berücksichtigt werden. Darauffolgend gilt es wiederum, die Distanz, welche auf dem neuen Weg zum nächsten Startpunkt zurückgelegt werden soll, zu ermitteln. Ist ein neuer Ausgangspunkt erreicht, beginnt der Lösungszyklus durch Bilden eines weiteren konjugierten Gradienten von vorne. Der soeben besprochene Vorgang wird so lange wiederholt, bis ein Minimum der Fehlerfunktion erreicht ist.<sup>81</sup>

Weiters wird die soeben besprochene deterministische Vorgehensweise mit Simulated Annealing verknüpft, damit ein lokales Extremum wieder verlassen werden kann.<sup>82</sup> Dieses Näherungsverfahren beruht auf dem Prinzip eines Abkühlvorgangs in der Metallverarbeitung und ist dem Gebiet der Stochastik<sup>83</sup> zuzuordnen. Hierbei wird das Tempern, ein metallurgischer Prozess, bei dem Atome durch Zuführen von Energie zunächst auf ein höheres Energieniveau ansteigen, um anschließend durch langsames Abkühlen den optimalen Gitterplatz, sprich deren Energieminimum, zu erreichen, nachgeahmt. Für das Lösen des Optimierungsproblems bedeutet dies, dass mit einer bestimmten Wahrscheinlichkeit auch schlechtere Lösungen während der algorithmischen Suche zugelassen werden. Dies ermöglicht das Verlassen von lokalen Extremstellen, um ein globales zu erreichen. Während des Fortschreitens des Verfahrens wird diese Wahrscheinlichkeit allerdings sukzessive verringert (Abkühlvorgang), bis schlussendlich nur noch Verbesserungen möglich sind. Dadurch kann bei unendlicher Abkühlzeit das globale Minimum erreicht werden.<sup>84</sup>

Bei endlicher Abkühlzeit, welche bei realen Aufgabenstellungen vorliegt, ist dies jedoch nicht garantiert. Aus diesem Grund startet der Trainings-Algorithmus von NeuralTools die Ermittlung des minimalen Fehlermesswertes oftmals von vorne, in der Hoffnung, das globale Minimum zu

<sup>79</sup> Vgl.: Goodfellow I. et al.: Deep Learning. S. 194f

<sup>80</sup> Vgl.: Palisade Corporation: Benutzerhandbuch, NeuralTools. S. 91f

<sup>81</sup> Vgl.: Bishop, C. M.: Neural Networks for Pattern Recognition. S. 275ff

<sup>82</sup> Vgl.: Palisade Corporation: Benutzerhandbuch, NeuralTools. S. 91

<sup>83</sup> Teilgebiet der Mathematik

<sup>84</sup> Vgl.: Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. S. 101f

finden. Hierbei gilt, dass mit länger andauernden Trainingsphasen eine größere Anzahl an Startfaktoren getestet werden kann.<sup>85</sup>

## 2.4 Einführungsbeispiele

Um eine bessere Verständlichkeit für die Anwendung neuronaler Netze zu erzielen, beinhaltet der folgende Abschnitt zwei eingängige Prognosen, die auf zufällig erstellten Datensätzen beruhen, um den Einfluss der Datensatzgröße auf den Testfehler zu beleuchten.

Erstere beinhaltet den Gesamt-Aufwandswert von Stahlbetonarbeiten sowie eine detaillierte Erläuterung wesentlicher Aspekte, die es bei der Auswertung zu berücksichtigen gilt. Hierbei werden neben dem standardmäßigen Testdatenbereich auch Vorhersagen außerhalb der Trainingsdaten sowie die Auswirkung fehlerbehafteter Inputparameter untersucht.<sup>86</sup>

Das zweite Beispiel beinhaltet die Ermittlung des Bewehrungs-Aufwandswertes bei Stützen unter Berücksichtigung diverser produktivitätsbeeinflussender Faktoren. Der hierbei eingesetzte Datensatz wird jedoch nicht wie beim ersten Beispiel mittels Monte-Carlo-Simulation erstellt, sondern beruht auf einem im Rahmen dieser Dissertation betreuten Masterprojekt.

### 2.4.1 Prognose des Gesamt-Aufwandswertes für Stahlbetonarbeiten auf Basis zufällig erstellter Datensätze

Nachfolgend werden die wichtigsten Grundlagen im Umgang mit künstlichen neuronalen Netzen anhand eines praxisnahen Beispiels verdeutlicht, wobei die versteckten Gefahrenpotenziale im Mittelpunkt stehen. Hierfür wird zunächst ein Datensatz mittels Monte-Carlo-Simulation erstellt und daraufhin verschiedene Netze mit dem Programm NeuralTools 7.6<sup>87</sup> der Palisade Corporation trainiert. Abschließend folgt die Analyse der Fehlerverläufe unter Berücksichtigung der verschiedenen Datensatzgrößen samt Interpretation der Ergebnisse. Hervorzuheben ist, dass nicht nur Prognosen im Bereich der Trainingsdaten, sondern auch außerhalb dieses untersucht werden und dass die Auswirkung eines fehlerbehafteten Datensatzes Eingang in die Analyse findet.

Damit auch ohne ein tiefgründiges Basiswissen die Nachvollziehbarkeit des Beispiels gewährleistet ist, wird auf die Tatsache, dass neuronale Netze ihre größte Stärke erst bei komplexen Zusammenhängen zeigen, nicht näher eingegangen. Der Gesamt-Aufwandswert der Stahlbetonarbeiten wurde somit bewusst gewählt, weil er einerseits aufgrund des sehr hohen Bekanntheitsgrades im Bauwesen geläufig ist und andererseits die Zusammenhänge der Variablen in einer Gleichung dargestellt werden können. Dadurch wird in weiterer Folge das Generieren und beliebige Erweitern des Datensatzes ermöglicht.

Der erste Schritt, um solch eine Prognose durchzuführen, beinhaltet die Definition der Einflussfaktoren. Diese ergeben sich aus den einzelnen

<sup>85</sup> Vgl.: Palisade Corporation: Benutzerhandbuch, NeuralTools. S. 91

<sup>86</sup> Als Kurzfassung dieses Beispiels siehe auch: Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C.

<sup>87</sup> <https://www.palisade.com/neuraltools/default.asp>. Datum des Zugriffs: 01.04.2020

Bestandteilen des Gesamt-Aufwandswertes<sup>88</sup>, der in Gleichung (2-14) ersichtlich ist. Er setzt sich aus der Summe der Multiplikationen vom Aufwandswert für die Schalarbeiten [ $AW_S$ ] mit dem Schalungsgrad [ $s_{g,bwk}$ ] und dem Aufwandswert der Bewehrungsarbeiten [ $AW_{BW}$ ] mit dem Bewehrungsgrad [ $bw_{g,bwk}$ ] sowie dem Aufwandswert der Betonierarbeiten [ $AW_{BT}$ ] zusammen.

$$AW_{STB} = AW_S \cdot s_{g,bwk} + AW_{BW} \cdot bw_{g,bwk} + AW_{BT} \quad (2-14)$$

Anschließend muss anhand der soeben definierten Variablen ein Datensatz erstellt werden. Weil diesem Beispiel keine Informationen von bereits abgeschlossenen Baustellen zu Verfügung stehen, wird der Datensatz mit Hilfe der Monte-Carlo-Simulation erstellt. Hierbei werden zufällige Werte innerhalb vorgegebener Verteilungsfunktionen für die einzelnen Inputparameter ausgewählt. Tabelle 2-1 verdeutlicht die eingesetzten Bandbreiten der symmetrischen Dreiecksverteilungen der Variablen mit dem dazugehörigen Erwartungswert.

Mit Hilfe dieser Methode werden unterschiedlich große Datensätze mit folgender Anzahl an Fällen – ein Fall besteht aus den Inputparametern mit dem dazugehörigen Output – erzeugt: 50, 100, 150, 200, 250, 300, 350, 400, 450, 500, 1.000, 2.500 und 5.000. Hierbei ist anzumerken, dass der jeweils nächstgrößere Datensatz alle Fälle des vorherigen beinhaltet und nur die Differenz neu generiert wird. Diese aufbauende Struktur gewährleistet in weiterer Folge eine bessere Vergleichbarkeit.

Lfd. Nr.	Berechnungsparameter		Einheit	Dreiecksverteilung		
				MIN	ERW	MAX
0	A	B	C	D	E	F
1	Aufwandswert Schalarbeiten	$AW_S$	Std/m <sup>2</sup>	1,08	1,35	1,62
2	Schalungsgrad	$s_{g,bwk}$	m <sup>2</sup> /m <sup>3</sup>	2,66	3,32	3,98
3	Aufwandswert Bewehrungsarbeiten	$AW_{BW}$	Std/t	9,12	11,40	13,68
4	Bewehrungsgrad	$bw_{g,bwk}$	kg/m <sup>3</sup>	103,20	129,00	154,80
5	Aufwandswert Betonarbeiten	$AW_{BT}$	Std/m <sup>3</sup>	0,84	1,05	1,26
6	<b>Gesamt-Aufwandswert der Stahlbetonarbeiten</b>	<b><math>AW_{STB}</math></b>	<b>Std/m<sup>3</sup></b>		<b>7,00</b>	

Tab. 2-1 Verteilung der Inputparameter<sup>89</sup>

Damit aus den erstellten neuronalen Netzen das beste ausgewählt werden kann, ist jeder einzelne Datensatz in Trainings- und Validierungsfälle aufzuteilen. Hierbei wird ein Verhältnis von 80:20 gewählt, wobei der nächstgrößere Datensatz alle Fallzuordnungen des vorherigen übernimmt, um ebenfalls eine bessere Vergleichbarkeit zu erzielen. Somit müssen nur die neuen Datensatzeinträge aufgeteilt werden. Tabelle 2-2 verdeutlicht beispielhaft die Struktur des Datensatzes mit zugewiesener Verwendung der ersten fünf Fälle.

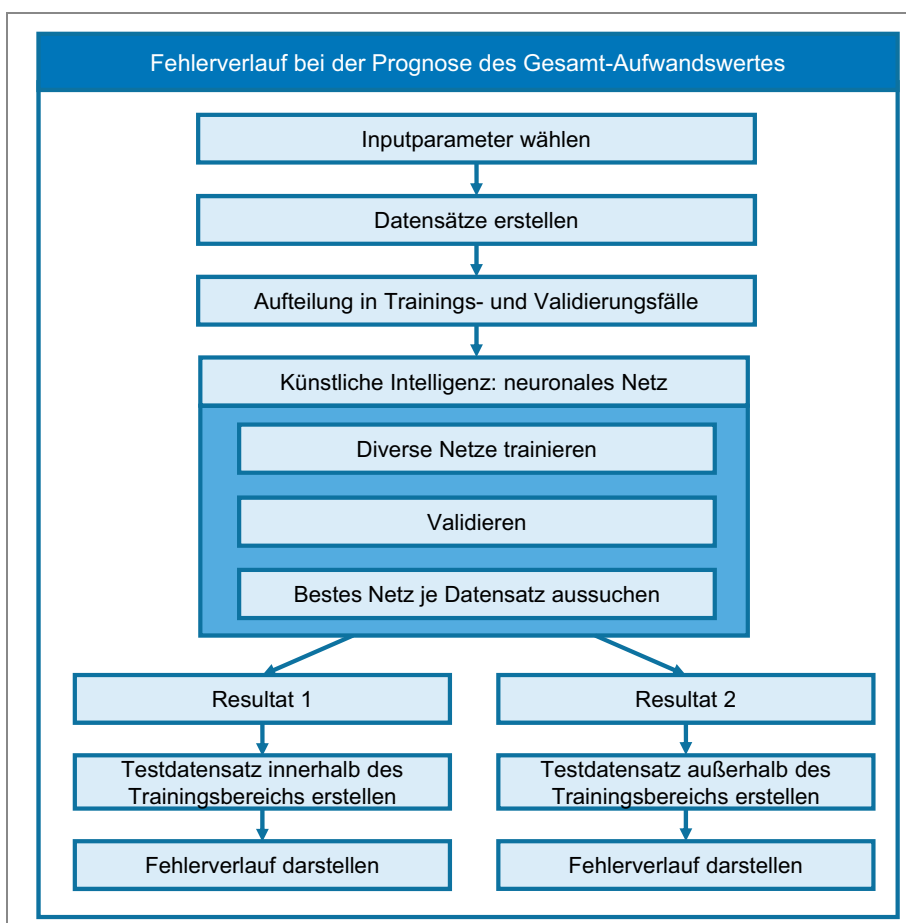
<sup>88</sup> Vgl.: Hofstadler, C.: Produktivität im Baubetrieb. S. 47

<sup>89</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 139

Lfd. Nr.	Inputparameter					Output	Verwendung
	$AW_S$	$s_g$	$AW_{BW}$	$bw_g$	$AW_{BT}$	$AW_{STB}$	
	[Std/m <sup>2</sup> ]	[m <sup>2</sup> /m <sup>3</sup> ]	[Std/t]	[kg/m <sup>3</sup> ]	[Std/m <sup>3</sup> ]	[Std/m <sup>3</sup> ]	
0	A	B	C	D	E	F	G
1	1,21	3,09	12,09	132,89	1,16	6,50	Trainieren
2	1,45	3,26	10,93	131,99	1,10	7,58	Trainieren
3	1,35	3,23	11,63	141,47	0,93	6,96	Trainieren
4	1,32	3,25	10,12	129,14	1,02	6,62	Trainieren
5	1,20	3,38	11,42	118,80	0,96	6,70	Validieren

Tab. 2-2 Beginn eines Datensatzes

Abschließend werden die anhand der Validierungsdaten ausgesuchten Netze mittels zweier Testdatensätze bewertet. Hierbei ist hervorzuheben, dass der erste Testdatensatz im Bereich der Trainingsdaten liegt und 4.000 Fälle beinhaltet. Der zweite wird hingegen außerhalb davon situiert, um die Prognosegenauigkeit bei Fällen zu beurteilen, welche nicht im Trainingsbereich liegen. Der soeben beschriebene Ablauf ist nochmals in der nachfolgenden Abbildung 2-13 zusammengefasst, wobei Resultat 1 die Testfälle innerhalb und Resultat 2 die außerhalb liegenden beinhaltet. Ebenso verdeutlicht die Grafik, dass die Testdaten bei allen Netzen die selben sind und nicht beim Trainingsprozess eingesetzt werden, wodurch eine objektive Beurteilung ermöglicht wird.

Abb. 2-13 Schematische Vorgehensweise<sup>90</sup>

Nachdem die einzelnen Datensätze mit den unterschiedlichen Größen erstellt und die Verwendungen den Fällen zugewiesen worden sind, kann mit dem Trainingsprozess begonnen werden. Hierfür wird das Programm NeuralTools<sup>91</sup> eingesetzt. Weiters wird unter Bezugnahme auf das Universal Approximation Theorem nur ein Hidden-Layer, welcher zwischen 2 und 50 Neuronen besitzen kann, bei der Modellbildung berücksichtigt. Somit sind je Datensatz 49 Netzvariationen durchzurechnen, bevor abschließend das Netz mit dem kleinsten quadratischen Fehler innerhalb der Validierungsfälle ausgewählt wird.

Beim Trainingsprozess der Feedforward-Netze berücksichtigt NeuralTools drei verschiedene Abbruchkriterien: die Zeit, die Schrittzahl und die Änderung des Fehlers. Da die vorliegende Aufgabenstellung eine geringe Komplexität aufweist, sinkt der Fehlerwert über die Zeit gesehen sehr rasch ab, weshalb als Abbruchkriterium das Erreichen von zwei Minuten gewählt wird.

Somit ist der Trainingsprozess 13 Mal für jeden Datensatz mit je 49 Netzen zu durchlaufen und jeweils auf Basis der Validierungsfälle die beste Netzkonfiguration zu bestimmen. Abschließend werden die ausgewählten Modelle mittels der Testdaten (4.000 Fälle) beurteilt, um ein objektives Bild des Prognosefehlers zu bekommen. Abbildung 2-14 verdeutlicht diesen, wobei in roter Farbe der mittlere absolute Fehler des Testdatensatzes und in Blau der Verlauf des RMS-Fehlers (Wurzel des mittleren Fehlerquadrates) ersichtlich ist. Weiters ist aus dem Trend beider Funktionen ablesbar, dass mit zunehmender Fallanzahl der Prognosefehler abnimmt. Das Minimum liegt bei 5.000 Fällen.




Abb. 2-14 Fehlerverlauf des Testdatensatzes<sup>92</sup>

<sup>90</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 140

<sup>91</sup> Siehe Abschnitt 2.3

<sup>92</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 142

Bei Betrachtung dieses Minimums gilt es jedoch, zu erwähnen, dass das anhand der 5.000 Fälle trainierte neuronale Netz nicht zwingend das beste sein muss. Die Grafik verdeutlicht nur, dass dieses Netz bei Anwendung der 4.000 Testfälle den kleinsten Fehlerwert besitzt. Natürlich deutet das Minimum in weiterer Folge darauf hin, dass das Modell die Zusammenhänge bei der Berechnung des Aufwandswertes am besten identifiziert hat. Welches Wissen die künstliche Intelligenz jedoch innerhalb der Hidden-Neuronen tatsächlich gespeichert hat, ist nicht bekannt. Dies gilt es, bei der Anwendung neuronaler Netze immer zu beachten.

Die nachfolgende Abbildung 2-15 verkörpert die Änderung des Fehlers der Validierungsfälle in Abhängigkeit der Datensatzgröße. Das Minimum ist bei 300 Fällen zu verzeichnen, wobei die Wurzel des mittleren quadratischen Fehlers  $0,009 \text{ Std/m}^3$  (rot) und der mittlere absolute Fehler  $0,007 \text{ Std/m}^3$  (blau) ausmachen. Bei dem Datensatz mit 500 Fällen weist der RMS-Fehler  $0,013 \text{ Std/m}^3$  und der mittlere absolute Fehler  $0,008 \text{ Std/m}^3$  auf.




Abb. 2-15 Fehlerverlauf der Validierungsfälle je Datensatz

Zusätzlich zur Modellbildung durch neuronale Netze wurde pro Datensatz eine lineare Regression durchgeführt. Der Fehlerwert dieser ist fast immer größer ausgefallen als jener der Netze. Lediglich beim ersten Datensatz mit 50 Einträgen erzielt der lineare Prädiktor eine bessere Lösung. Der Vergleich zwischen diesem und dem besten neuronalen Netz, welches 3 Hidden-Neuronen aufweist, wird in Tabelle 2-3 dargestellt. Es zeigt sich, dass die künstliche Intelligenz beim Training im Vergleich zum linearen Prädiktor besser abschneidet. Beim Validieren und beim Testen ist es genau umgekehrt. Das bedeutet, dass das neuronale Netz einen datensatzspezifischen Zusammenhang gefunden hat, mit welchem es die Trainingsdaten sehr gut abbildet, dieser jedoch nicht allgemeingültig ist. Daher schneidet es beim Testen und Validieren deutlich schlechter ab. Aufgrund dessen muss bei Prognosen mit Hilfe neuronaler Netze bei geringer Anzahl an Trainingsdaten eine besondere Vorsicht geboten sein, damit das soeben beschriebene Phänomen, welches Overfitting genannt wird, nicht zu falschen Prognosen führt. Die allgemeine Mindestgröße eines Datensatzes lässt sich jedoch



schwer festlegen, weil diese immer von der Komplexität der Aufgabe abhängt.

Lfd. Nr.	Art	Training		Validierung		Testen	
		RMS-Fehler	Mttl. abs. Fehler	RMS-Fehler	Mttl. abs. Fehler	RMS-Fehler	Mttl. abs. Fehler
		[Std/m³]	[Std/m³]	[Std/m³]	[Std/m³]	[Std/m³]	[Std/m³]
0	A	B	C	D	E	F	G
1	Linearer Prä.	0,027	0,018	0,041	0,031	0,037	0,026
2	3 Neuronen	0,010	0,008	0,204	0,132	0,157	0,082

Tab. 2-3 Gegenüberstellung linearer Prädiktor und neuronales Netz

Die nachfolgende Tabelle 2-4 listet die Anzahl der eingesetzten Neuronen des Hidden-Layers je ausgewähltem Netz auf. Die Bandbreite dieser erstreckt sich von 5 bis 34 Units, wobei im Durchschnitt 23 Neuronen eingesetzt werden.

Lfd. Nr.	Datensatzgröße	Anzahl der Hiddenneuronen	Lfd. Nr.	Datensatzgröße	Anzahl der Hiddenneuronen
0	A	B		A	B
1	50	Linearer Prä.	8	400	19
2	100	5	9	450	31
3	150	14	10	500	34
4	200	12	11	1.000	29
5	250	32	12	2.500	27
6	300	26	13	5.000	29
7	350	18			

Tab. 2-4 Anzahl der Neuronen des besten Netzes je Datensatz<sup>93</sup>

Damit die vorhin aufgezeigte Gefahr des Overfittings reduziert wird, gilt es, die Fehlerwerte des Trainings mit jenen der Validierung bzw. des Testens zu vergleichen. Sind diese zu groß, liegt dem Modell kein genereller Zusammenhang zu Grunde. Abbildung 2-16 beinhaltet aus diesem Grund die Verläufe der Wurzel des mittleren quadratischen Fehlers der Trainingsdaten (rot) und der Validierungsfälle (blau). Hierbei sind im Bereich der kleineren Datensätze größere Abweichungen vorzufinden. Diese reduzieren sich jedoch mit steigender Fallanzahl, wodurch das Risiko von Overfitting – Überanpassung aufgrund nicht generalisierbarer Zusammenhänge – abnimmt.

<sup>93</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 143

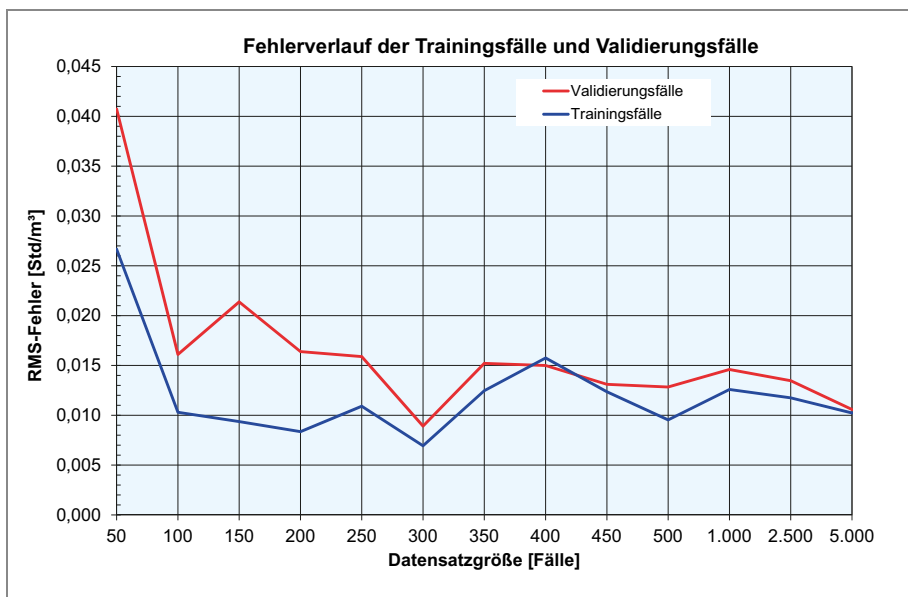


Abb. 2-16 Fehlerverlauf der Trainings- und Validierungsfälle<sup>94</sup>

Die nachfolgenden Abbildungen 2-17 und 2-18 vergleichen die Fehlerverläufe des Testdatensatzes und der Validierungsfälle je Datensatz. Das Minimum der Validierungsfälle liegt bei 300 und deckt sich nicht mit dem Minimum des Testdatensatzes, welches bei 5.000 vorzufinden ist. Daraus wird ersichtlich, dass das Minimum bei den Validierungsfällen nicht unbedingt die beste Generalisierungsoption mit sich bringen muss. Es sagt bloß aus, dass der Fehler bei den vorhandenen Validierungsfällen am geringsten ist. Ab 1.000 Fällen verlaufen die Kurven annähernd ident.




Abb. 2-17 RMS-Fehlerverlauf der Validierungsfälle und des Testdatensatzes

<sup>94</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 143

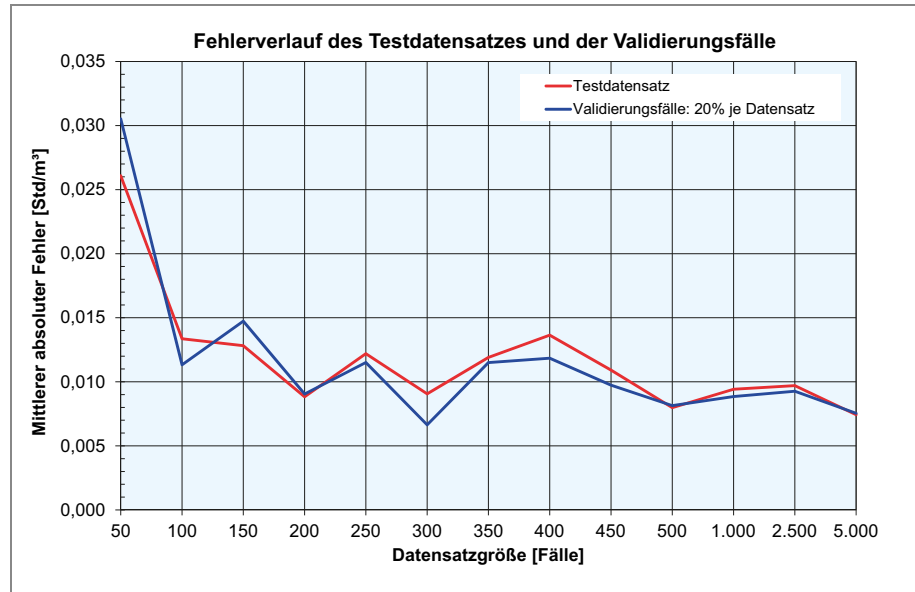


Abb. 2-18 Mittlerer absoluter Fehlerverlauf der Testdaten und Validierungsfälle

Nachdem Resultat 1, der Fehlerverlauf im Raum der Trainingsdaten, ausführlich aufbereitet und diskutiert wurde, werden nun die Prognosefähigkeiten des neuronalen Netzes außerhalb der Trainingsdaten beleuchtet. Hierfür wird zunächst ein neuer Testdatensatz generiert, welcher im Gegensatz zum vorherigen einer Rechteckverteilung unterliegt. Weiters ist er symmetrisch über bzw. unter den Maximal- und Minimalwerten der Trainingsdaten angeordnet. Die angenommenen Bandbreiten der Testparameter ergeben sich aus der Hälfte der Differenz von Maximum (MAX) und Minimum (MIN) der Trainingsdaten (TD). Um den Einfluss der Entfernung zu den Trainingsdaten besser beurteilen zu können, werden die neuen Testfälle zusätzlich in drei Bereiche gegliedert. Abbildung 2-19 stellt die soeben beschriebene Aufteilung grafisch dar.

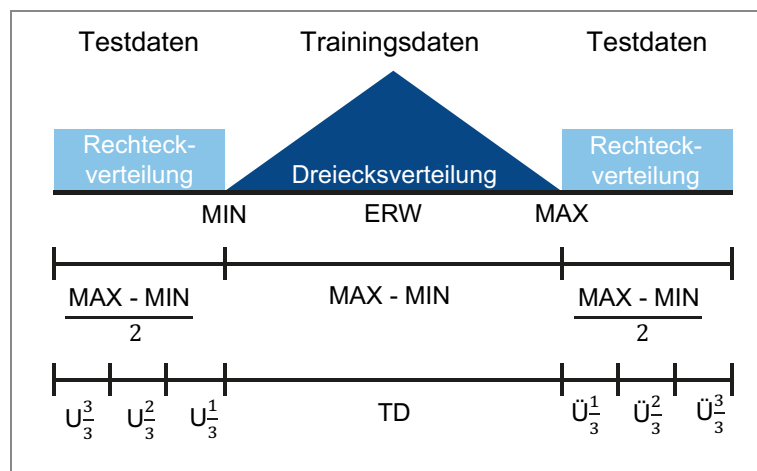


Abb. 2-19 Testdaten außerhalb des Trainingsdatenbereiches<sup>95</sup>

<sup>95</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 144

Im nächsten Schritt, gilt es, die neu erstellten Testdaten anzuwenden. Hierfür wird das neuronale Netz (34 Hidden-Neuronen) basierend auf dem 500er Datensatz ausgewählt, weil diese Fallanzahl eine praxisnahe Menge darstellt und das Netz bei der Evaluierung ein sehr gutes Resultat erzielt.

Abbildung 2-20 verdeutlicht die Auswertung des mittleren absoluten Fehlers für das getestete neuronale Netz. Sofort ist ersichtlich, dass Prognosen außerhalb der Trainingsdaten nicht zielführend sind, weil sie große Abweichungen aufweisen. Weiters ist abzulesen, dass mit zunehmender Entfernung zu den Trainingsdaten der Fehlerwert steigt. Im untersten und obersten Drittel sind die beiden Maxima mit  $1,5 \text{ Std/m}^3$  und  $3,1 \text{ Std/m}^3$  vorzufinden. Tabelle 2-5 beinhaltet die einzelnen Werte mit den dazugehörigen relativen Fehlern. Diese fallen im unteren Bereich deutlich größer aus, da der durchschnittliche Aufwandswert, welcher beim relativen Fehler im Nenner steht, kleiner wird. Abschließend ist somit festzuhalten, dass der Einsatz neuronaler Netze zu sehr unzuverlässigen Prognoseergebnissen außerhalb der Trainingsdaten führt.




Abb. 2-20 Mittlerer absoluter Fehlerverlauf der Testdatenbereiche

Lfd. Nr.	Parameter	u3/3	u2/3	u1/3	TD	ü1/3	ü2/3	ü3/3
0	A	B	C	D	E	F	G	H
1	$AW_{STB,MW}$ [Std/m³]	3,1	3,6	4,3	7,0	10,3	11,4	12,5
2	M. abs. F. 500 [Std/m³]	1,4	0,9	0,5	0,0	1,0	2,0	3,1
3	Rel. F. 500 [%]	45,3	25,8	10,7	0,0	9,6	17,3	24,4

Tab. 2-5 Relativer Fehler außerhalb liegender Testdaten

Nachfolgend stehen die Auswirkungen eines fehlerbehafteten Datensatzes auf die Fähigkeit, mittels neuronaler Netze Wissen zu erlangen, im Fokus der Betrachtung. Hierbei wird ein neues Prognosemodell basierend auf mit Abweichungen versehenen Trainingsdaten erstellt und der daraus folgende Testfehler mit jenem aus Resultat 1 verglichen.

Zu Beginn muss somit ein neuer Datensatz für das Trainieren und Validieren erstellt werden. Um eine Vergleichbarkeit zu gewährleisten, dienen die vorhin generierten Datensätze (welche zu Resultat 1 führen) als Basis der Analyse. Lediglich werden die einzelnen Werte der Inputparameter mit einer zufällig im Bereich  $-5$  bis  $+5$  % gewählten Abweichung versehen, wodurch beispielsweise ein Messfehler simuliert wird. Der Outputparameter sowie die Netzkonfigurationen bleiben unverändert. Nachdem der Trainingsprozess 13 Mal bei je 49 Netzen durchlaufen und auf Basis der Validierungsfälle jeweils das beste neuronale Netz ausgesucht wurde, beurteilt der unveränderte, 4.000 Fälle große Testdatensatz die ausgewählten Modelle.

Die nachfolgende Abbildung 2-21 stellt den Vergleich der Netze anhand der Testergebnisse dar. In Blau ist der RMS-Fehler und in Rot der mittlere absolute Fehler des mit Abweichungen versehenen Datensatzes ersichtlich. Im Vergleich dazu verkörpert die grüne Linie den RMS-Fehler des fehlerlosen Datensatzes und der violette Verlauf den dazugehörigen mittleren absoluten Fehler.

Grundsätzlich ist bei der Analyse festzuhalten, dass bei beiden Varianten die Fehlerwerte mit zunehmender Datensatzgröße abnehmen. Jedoch startet der mit Abweichungen behaftete Datensatz mit höheren Fehlerwerten und benötigt eine größere Datenbasis, um sich deutlich zu verbessern. Erst ab dem 2.500er Datensatz ist keine merkliche Verbesserung festzustellen. Somit geht aus dieser Untersuchung hervor, dass neuronale Netze auch bei fehlerhaften Daten zuverlässige Ergebnisse erzielen können. Hierfür wird jedoch eine größere Datenmenge benötigt, damit die künstliche Intelligenz zusätzlich zu den Zusammenhängen der einzelnen Inputparameter auch die möglichen Abweichungen erlernen kann.




Abb. 2-21 Fehlerverlauf des Testdatensatzes unter Berücksichtigung mit Abweichungen behafteter Trainingsdaten<sup>96</sup>

Die folgenden zwei Abbildungen 2-22 und 2-23 veranschaulichen die Fehlerverläufe des Testdatensatzes und der fehlerbehafteten Validierungsfälle. Im

<sup>96</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 145

Vergleich zu Resultat 1 liegen die beiden Verläufe getrennt voneinander und überschneiden sich kein einziges Mal. Die 4.000 fehlerfreien Testfälle schneiden hierbei jedoch deutlich besser ab. Die beiden Verläufe der Validierungsdaten (RMS-Fehler und mittlerer absoluter Fehler) pendeln sich rasch nach 100 Fällen ein und bei alleiniger Betrachtung dieser könnte man zu dem Entschluss kommen, dass die Netze bei steigender Datensatzgröße fast keinen weiteren Lernerfolg aufweisen. Der Verlauf des Testdatenfehlers zeigt jedoch sehr gut, dass weitere Zusammenhänge erkannt werden. Erst bei 2.500 Fällen ist keine wesentliche Verbesserung mehr zu vernehmen.




Abb. 2-22 RMS-Fehler aus dem Testdatensatz und der Validierungsfälle




Abb. 2-23 Mittlerer absoluter Fehler des Testdatensatzes und der Validierungsfälle

Schlussendlich wird noch der Fehler der Trainingsfälle jenem der Validierungsfälle gegenübergestellt, um zu überprüfen, ob Overfitting vorliegt.

Dieser Vergleich wird in Abbildung 2-24 visualisiert und zeigt, dass sich die Abweichung mit zunehmender Datensatzgröße verringert. Weiters sollte das erste Modell, welches anhand des 50er-Datensatzes erstellt wurde, keinesfalls für Vorhersagen verwendet werden, weil die beiden RMS-Fehler zu stark voneinander abweichen. Nach Bewertung der Fehlerverläufe aus Abbildung 2-21, 2-22, 2-23 und 2-24 wird geraten, ausschließlich Netze ab einschließlich 200 Fällen für Vorhersagen heranzuziehen.




Abb. 2-24 Fehlerverlauf Trainings- und Validierungsfälle<sup>97</sup>

#### 2.4.2 Prognose des Aufwandswertes beim Bewehren von Stützen

Nachfolgend wird der Aufwandswert von Bewehrungsarbeiten bei Stahlbetonstützen anhand eines Datensatzes mit Hilfe neuronaler Netze erlernt, um abschließend dieses Wissen für Prognosen einsetzen zu können. Die hierbei verwendete Datengrundlage stammt aus einem Masterprojekt<sup>98</sup>, welches im Rahmen dieser Dissertation ausgeschrieben wurde. Dieses hatte zum Ziel, anhand ausgewählter Parameter die für das Verlegen benötigten Lohnstunden pro Tonne Bewehrung unter Berücksichtigung produktivitätsbeeinflussender Faktoren zu berechnen.

Die Stahlbetonstütze selbst wird in diesem Modell mittels Länge, Breite und Höhe beschrieben. Um reale Baustellenbedingungen abzubilden, werden Produktivitätsverluste basierend auf der Gruppengröße, der Temperatur, der Arbeitszeit, der Lichtverhältnisse und der Krankkapazität berücksichtigt. Hierfür werden die von Hofstadler ermittelten funktionalen Aufwandswert erhöhungen<sup>99</sup> herangezogen. Der Basisaufwandswert errechnet sich aus den eingebauten Stabdurchmessern, wobei sich letztendlich bei jedem Durchmesser ein Bereich mit einer Bandbreite von 0,5 Std/t ergibt, in dem ein zufälliger Wert ausgewählt wird. Diese Basis wird abschließend mit den aufsummierten Produktivitätsverlusten beaufschlagt.<sup>100</sup>

<sup>97</sup> Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 146

<sup>98</sup> Vgl.: Fasching, M.: Ausarbeitung von Baustellendaten – Bewehrungsarbeiten. Masterprojekt. TU Graz.

<sup>99</sup> Hofstadler, C.: Produktivität im Baubetrieb. S. 305ff

<sup>100</sup> Vgl.: Fasching, M.: Ausarbeitung von Baustellendaten – Bewehrungsarbeiten. Masterprojekt. TU Graz. S. 31

Damit der Einfluss der Anzahl der zur Verfügung stehenden Fälle aufgezeigt wird, werden insgesamt 10 verschieden große Datensätze für das Erkennen von Zusammenhängen herangezogen. Der kleinste weist 100 Fälle auf und wird jeweils um weitere 100 ergänzt, bis eine Datensatzgröße von 1.000 erreicht ist. Die Aufteilung in Trainings- und Validierungsfälle erfolgt hierbei immer im Verhältnis 4:1. Somit bauen die größeren Datensätze immer auf die kleineren auf und verwenden aus diesem Grund auch dieselben Fallzuordnungen für das Trainieren und Validieren. Die nachfolgende Abbildung 2-25 zeigt den Beginn dieses Datensatzes. Als Inputparameter werden der Durchmesser der Längsbewehrung, das Gewicht der Längs- sowie Bügelbewehrung, die Temperatur, die Arbeitsgruppengröße, die Krankkapazitätsreduktion, die Lichtverhältnisse und die Arbeitszeit herangezogen. Als Outputparameter wird der Aufwandswert der Bewehrungsarbeiten definiert. Nachdem die Auswirkung der Datensatzgrößen unter Berücksichtigung der soeben vorgestellten Einflüsse untersucht wurde, werden weitere Modellparameter wie beispielsweise der Bewehrungsgrad und die geometrischen Abmessungen der Stütze analysiert.

Lfd. Nr.	Input								Output
	Gewählter Durchmesser	Gewicht Längsbewehrung	Gewicht Bügelbewehrung	Anzahl Personen	Krankkapazitätsverringeringung	Temperatur	Arbeitszeit	Lichtverhältnisse	Aufwandswert
	[mm]	[kg]	[kg]	[Anzahl]	[%]	[°C]	[h]	[-]	[Std/t]
0	A	B	C	D	E	F	G	H	I
1	16	63,1	13,0	3	13	-5	12	0	16,28
2	14	43,5	13,0	2	3	27	11	3	16,64
3	20	88,8	13,3	4	9	24	11	3	13,23
4	16	69,4	16,1	4	3	-2	8	2	18,78
5	26	83,4	12,1	2	5	28	10	3	9,59

Abb. 2-25 Beginn des Datensatzes für die Aufwandswertprognose von Bewehrungsarbeiten

Im vorherigen Beispiel wurde verstärkt auf die Gefahr außerhalb der Trainingsdaten angeordneter Validierungs- bzw. Testdaten aufmerksam gemacht. Um diesem Problem vorzubeugen, werden nachfolgend die Verteilungen der einzelnen Parameter, gegliedert in 800 Trainings- und 200 Validierungsfälle, unter die Lupe genommen. Begonnen wird in Abbildung 2-26 mit dem Durchmesser der Längsbewehrung, welcher 12, 14, 16, 20 oder 26 mm aufweist.




Abb. 2-26 Verteilung der Durchmesser der Längsbewehrung



Die nachfolgenden Abbildungen 2-27 und 2-28 verdeutlichen die Verteilung der Stützen unter dem Aspekt des Gewichtes der Längs- und der Bügelbewehrung. Im gesamten Datensatz weist die Längsbewehrung eine Bandbreite von 40 bis 200 kg/Stütze auf, während sich die Bügelbewehrung zwischen 6 und 20 kg/Stütze erstreckt. Anhand der an die Abszisse angefügten Datentabelle ist ersichtlich, dass die meisten Stützen bei der Längsbewehrung im Bereich zwischen 51 und 89 kg zu liegen kommen.




Abb. 2-27 Verteilung des Gewichtes der Längsbewehrung




Abb. 2-28 Verteilung des Gewichtes der Bügelbewehrung

Nachfolgend werden die produktivitätsbeeinflussenden Faktoren analysiert. Abbildung 2-29 zeigt die Verteilung der einzelnen Arbeitsgruppengrößen. Die optimale Gruppengröße weist zwei Arbeitskräfte<sup>101</sup> auf und innerhalb der Validierungsdaten kommt das Maximum mit 67 Stützen bei einer Arbeitskraft zu liegen. Die restlichen Gruppengrößen sind annähernd gleich verteilt.

<sup>101</sup> Vgl.: Hofstadler, C.: Produktivität im Baubetrieb. S. 209




Abb. 2-29 Verteilung der Arbeitsgruppengröße




Abb. 2-30 Verteilung der Verringerung der Krankkapazitäten

Eine Verringerung der Krankkapazität ist im Datensatz zwischen 0 und 20 % möglich – dessen Verteilung wird in Abbildung 2-30 ersichtlich. Die meisten Stützen (123 Stk.), welche den Trainingsfällen zugeordnet sind, fallen in jenen Bereich, der 0 bis 2 % abdeckt. Das Maximum der Validierungsfälle liegt mit 29 Stützen zwischen 8 und 10 %. Die dortige Anzahl an Trainingsstützen beträgt 76, was als ausreichend zu erachten ist.

Die Abbildungen 2-31, 2-32 und 2-33 geben die Verteilungen der Stützen in Bezug auf die Temperatur, die tägliche Arbeitszeit und die anzutreffenden Lichtverhältnisse wieder. Letzteres beinhaltet vier Lichtklassen, wobei 0 mit Tageslicht, 1 mit einer starken Bewölkung, 2 mit der Dämmerung und 3 mit einer mäßigen Sicht bei Nacht gleichzusetzen ist. Alle Histogramme weisen sowohl bei den Trainings- als auch bei den Validierungsdaten einen annähernd gleich verteilten Verlauf auf.




Abb. 2-31 Verteilung der Temperatur




Abb. 2-32 Verteilung der täglichen Arbeitszeit





Abb. 2-33 Verteilung der Lichtverhältnisse

Abschließend wird die Verteilung der Stützen unter Berücksichtigung des Aufwandswertes für die Bewehrungsarbeiten vorgenommen. In der nachfol-

genden Abbildung 2-34 wird sofort ersichtlich, dass die meisten Stützen (701 von 800) zwischen 9 Std/t und 21 Std/t zu liegen kommen, wobei davon 214 in den Bereich 12-15 Std/t fallen. Weiters wird deutlich, dass die Randbereiche sehr schwach besetzt sind. Aus diesem Grund gilt es, Prognoseergebnisse, welche über 24 Std/t liegen, kritisch zu hinterfragen und auf keinen Fall ungeprüft zu übernehmen. In der Praxis müssten für derartige Vorhersagen weitere Trainingsfälle im Datensatz aufgenommen werden, damit der schwach besetzte Bereich besser abgebildet werden kann.

Zusammenfassend ist festzustellen, dass die Trainingsdaten in allen Bereichen die vorhandenen Validierungsdaten in ausreichender Anzahl umgeben. Lediglich bei Aufwandswerten größer als 24 Std/t gilt es, den Validierungsfehler genau zu analysieren und derartige Prognoseergebnisse kritisch zu hinterfragen.



**Abb. 2-34** Verteilung der Aufwandswerte der Bewehrungsarbeiten

Nach der Analyse des Datensatzes wird im nächsten Schritt mit dem Trainieren der Netze mit Hilfe des Programmes NeuralTools<sup>102</sup> begonnen. Hierfür werden je Datensatz Feedforward-Netze mit einem Hidden-Layer, welcher zwischen 2 und 50 Neuronen aufweist, trainiert. Daraus wird mittels der Validierungsdaten die Netzkonfiguration mit dem geringsten quadratischen Fehler ausgewählt. Als Abbruchkriterium werden 100.000 Versuche festgesetzt. Das bedeutet, dass die Software 100.000 Versuche je Neuronenkonstellation unternimmt, um das globale Minimum der Fehlerfunktion zu finden.

Die nachfolgende Abbildung 2-35 zeigt die Entwicklung des RMS-Fehlers (Wurzel aus dem mittleren Fehlerquadrat) in Abhängigkeit der einzelnen Datensatzgrößen. Hierbei ist deutlich zu erkennen, dass die relative Verbesserung mit zunehmender Datenmenge abnimmt. Bei 100 Fällen (80 für das Training, 20 zum Validieren) beträgt der RMS-Validierungsfehler 1,6 Std/t und bei 1.000 Fällen nur noch 0,5 Std/t.

<sup>102</sup> <https://www.palisade.com/neuraltools/de/>. Datum des Zugriffs: 29.07.2019




Abb. 2-35 Fehlerverlauf der Trainings- und Validierungsfälle

Weiters ist anzumerken, dass sich die zufällige Positionierung der ersten Validierungsdaten sehr positiv ausgewirkt hat (Validierungsfehler liegt unter dem Trainingsfehler). Bei der Datensatzgröße von 900 Fällen weisen sowohl der Trainings- als auch der Validierungsfehler 0,6 Std/t auf.

Um die ausgewählten neuronalen Netze anhand desselben Datensatzes vergleichen zu können, werden nachfolgend 1.000 neue Aufwandswerte generiert und zum Testen herangezogen. Die Verteilung des Testdatensatzes wird in Abbildung 2-36 veranschaulicht. Bei der Betrachtung des Histogramms ist ersichtlich, dass die Validierungsdaten ebenfalls ab 24 Std/t sehr dünn besetzt sind.




Abb. 2-36 Verteilung der Aufwandswerte des Testdatensatzes

Der RMS-Fehlerverlauf der Validierungs- und Testfälle wird in Abhängigkeit der Datensatzgröße in Abbildung 2-37 gezeigt. Es ist deutlich zu erkennen, dass die zufällig gewählten Validierungsdaten im 100er- und 200er- Datensatz sehr günstig liegen. Beim Testen schneiden diese wesentlich schlechter ab.




Abb. 2-37 Fehlerverlauf der Validierungs- und Testfälle

Aus diesem Grund gilt es, besonders bei kleinen Datensätzen (für dieses Beispiel kleiner als 300 Fälle) darauf zu achten, welche Fälle als Validierungs- bzw. Testfälle gewählt werden. Je mehr Daten zur Verfügung stehen, desto geringer wird dieser Einfluss.

Abbildung 2-38 zeigt den RMS-Fehler in Abhängigkeit des dazugehörigen Aufwandswertebereichs. Es ist deutlich ersichtlich, dass in den Randbereichen, in denen weniger Anhaltspunkte zur Verfügung stehen, der Fehlerwert ansteigt. Besonders drastisch ist dies ab 24 Std/t zu erkennen. In der letzten Klasse, welche zwischen 30-33 Std/t liegt, ist wie in Abbildung 2-34 ersichtlich nur eine Stütze für das Training und keine zum Validieren vorzufinden. Aus diesem Grund fällt der RMS-Fehler beim Testen dieses Bereiches mit 1,98 Std/t sehr hoch aus.




Abb. 2-38 Verteilung der Aufwandswerte des Testdatensatzes

Abschließend ist festzuhalten, dass sich bei diesem Berechnungsbeispiel bereits 800 Stützen für Prognosen des Aufwandswertes eignen (RMS-Fehler:

0,6 Std/t). Hierbei gilt es jedoch, zu beachten, dass die Vorhersagen im dicht besetzten Trainingsbereich liegen, welcher in diesem Fall zwischen 9-24 Std/t angesiedelt ist. Für außerhalb situierte Prognosen sind die RMS-Fehler zu groß. Für die Baupraxis bedeutet dies, dass es problemlos möglich ist, bereits mit einer Datensatzgröße von rund 1.000 Fällen zielsichere Prognosen zu erstellen, welche vor allem bei der Plausibilisierung der getroffenen Annahmen sehr gut eingesetzt werden können. Für eine Automatisierung, bei der die Vorhersagen ohne menschliche Kontrolle eingesetzt werden, ist jedoch diese Fallanzahl zu niedrig und müsste soweit erhöht werden, bis der firmenspezifische, maximal verträgliche Fehlerwert unterschritten wird.

Schlussendlich muss noch festgehalten werden, dass neuronale Netze kein Wundermittel bei Prognosen darstellen. Für das Erkennen von Zusammenhängen in Datensätzen sind sie allerdings sehr gut geeignet. Kommt jedoch darin eine Zufallszahl vor, ist die Grenze des Machbaren verständlicherweise erreicht. Für das vorliegende Beispiel sei angemerkt, dass im Modell der Aufwandswert in Abhängigkeit des Bewehrungsdurchmessers innerhalb einer Bandbreite von 0,5 Std/t zufällig gewählt wird, bevor die aufsummierten Produktivitätsverluste hinzugezählt werden. Aus diesem Grund kann der RMS-Fehler Null nie erreichen.

### 3 Anwendungsmöglichkeiten künstlicher Intelligenz

Anhand der vorherigen Beispiele ist erkennbar, dass neuronale Netze zielsicher bei numerischen Prognosen eingesetzt werden können. Jedoch müssen für effektive Vorhersagen genügend Trainingsdaten zur Verfügung stehen. Ohne einen ausreichenden Datensatz ist es neuronalen Netzen nicht möglich, Zusammenhänge zu erkennen und diese als implizites Wissen zu speichern.

Andere Branchen wie beispielsweise die Medizin, die Automobilindustrie, der Handel oder der Finanzsektor haben die Potenziale bereits erkannt, sammeln riesige Mengen an Daten und transformieren erfolgreich das erhobene unstrukturierte Verfügungswissen in Orientierungswissen. Die daraus gewonnenen Kennzahlen führten zu einer Produktivitätssteigerung und zu höheren Wettbewerbschancen. Aufgrund dieser positiven Effekte wird laut einer von McKinsey durchgeführten Studie der globale Markt für künstliche Intelligenz (Service, Software, Hardware) jährlich um 15-25 % zunehmen und 2025 rund 130 Mrd. USD (115 Mrd. EUR) betragen.<sup>1</sup>

In diesem Kapitel wird zunächst auf Anwendungen in baufertigen Fachbereichen eingegangen und anhand verschiedener Beispiele der Nutzen herausgearbeitet. Daraufhin steht die allgemeine Vorgehensweise bei der Verwendung von neuronalen Netzen im Vordergrund. Abschließend werden konkrete Anwendungsmöglichkeiten aus dem Bauwesen mit zielführenden Input- und Outputparametern vorgestellt und eine Literaturlanalyse durchgeführt.

#### 3.1 Baufertige Anwendungsbereiche

Begonnen wird die exemplarische Auflistung, welche einen Überblick über die Diversität der Einsatzmöglichkeiten liefern soll, im Verkauf. Hierbei zählt es zu den Hauptaufgaben, interessierte Kunden zu erkennen und diese zum Kauf eines Produktes zu animieren. Aus diesem Grund sammeln Firmen bereits seit vielen Jahren Daten in der Hoffnung, einen besseren Überblick über das Kaufverhalten einzelner Kundensegmente zu erlangen. Solange hierfür nur einzelne Attribute wie beispielsweise Apps oder e-Mails analysiert werden, ist es möglich, unter angemessenem Aufwand einen Überblick zu erhalten. Sobald aber SMS-, Web-, Social-Media-, App- und In-Store-Interaktionen dem zu analysierenden Datensatz beigefügt werden, wird es schnell schwer, Muster im Kundenverhalten zu erkennen. Eine Möglichkeit, um aus solch riesigen Datenmengen erfolgreich Kundenprofile zu erstellen, ist es, Machine-Learning-Algorithmen anzuwenden. Diese können komplexe Zusammenhänge erkennen und Kunden in separaten Profilen abbilden. Eine verallgemeinernde Kundensegmentierung ist dabei nicht mehr notwendig. Dadurch können in weiterer Folge das optimale Produktangebot oder die bevorzugten Kommunikationskanäle, -inhalte, sowie -zeiten ausgewählt werden, um das Individuum bestmöglich anzusprechen. Diese intelligenten

<sup>1</sup> Vgl.: McKinsey: Smartening up with Artificial Intelligence (AI), S. 12



Werkzeuge analysieren auch die Wahrscheinlichkeit, mit der ein Kunde kauft oder den Vertrag kündigt und zu einem Konkurrenzprodukt wechselt. Sollte die Abwanderungswahrscheinlichkeit überwiegen, gilt es, im nächsten Schritt mittels effektiver Vorschläge dem entgegen zu wirken.<sup>2</sup>

Auch im Supermarkt wird es Änderungen beim gewohnten Einkaufen geben. Das Konzept von Amazon Go verspricht, dass zeitaufwendiges Anstellen und Produkte auf das Kassaband legen in Zukunft nicht mehr notwendig sein wird.<sup>3</sup> Die Ware muss nur noch aus dem Regal genommen und in die Tasche gesteckt werden. Das Zahlen funktioniert völlig automatisch mittels einer App, welche beim Eintreten in den Supermarkt einem Lesegerät vorgezeigt werden muss. Diese Vereinfachung ist durch die Datenauswertung komplizierter Sensortechnologie möglich. Mittels Bilderkennung kann dabei ermittelt werden, ob der Kunde ein Produkt herausnimmt oder dieses zurückstellt. Aber nicht nur die Interaktion mit dem Produkt wird analysiert, sondern auch das Verhalten der einkaufenden Person – beispielsweise das Stehen vor bestimmten Regalen – wird akribisch beobachtet und ausgewertet. In Kalifornien ist ein kassenloser Supermarkt bereits in Betrieb. Weil dieses Vohaben derartig positive Rückmeldungen liefert, plant Amazon weitere 50 Supermärkte, welche in Zukunft nur noch mit künstlicher Intelligenz und ohne Personal auskommen werden.<sup>4</sup>

Neben dem Vorhaben, Pakete automatisch per Drohne zu liefern, forscht Amazon auch daran, dass künstliche Intelligenz Obst und Gemüse automatisch anhand des Reifegrades sortiert. Hierfür werden die auf einem Förderband vorbeifahrenden Obst- oder Gemüsekisten mittels eines speziellen Sensors berührungsfrei untersucht und anschließend dessen Daten ausgewertet. Bei dieser Datenerhebung werden neben normalen Kamerainformation auch Parameter gemessen, die für das menschliche Auge unsichtbar sind. Durch diese automatische Beurteilung von verderblichen Lebensmitteln erhofft sich Amazon eine deutliche Reduktion der Ausschussrate.<sup>5</sup>

Um Kunden bestmöglich zu versorgen, müssen Händler bereits heute wissen, welche Produkte in ein bis zwei Wochen von ihnen verlangt werden könnten. Nur durch dieses Vorausdenken ist es möglich, unter Einhaltung geringster Lieferzeiten und ausreichender Vorhaltungsmengen den Kundenwunsch zu befriedigen. Liegen genügend Verkaufsdaten aus den letzten Jahren vor, können neuronale Netze auf diesen aufbauend Prognosen über einen zukünftigen Bedarf erstellen. Auch Amazon versucht, mittels speziellen Algorithmen die Nachfrage in vereinzelt Regionen vorherzusagen. Hierbei ist anzumerken, dass nicht das individuelle Kaufverhalten prognostiziert wird, sondern der gesamte Konsum einzelner geographischer Bereiche.<sup>6</sup>

Einen weiteren Aspekt, der durch die künstliche Intelligenz auf ein neues Level gehoben wurde, stellt die Spracherkennung dar. Alexa, Cortana, Siri und viele weitere Sprachassistenten haben bereits im Alltag eine große Bedeutung. Hierbei ist die sprachbasierte Adresseingabe bei den Navigationsgeräten oder die Diktierfunktion bei den Mobilgeräten erst der Anfang. Die wahre Stärke liegt

<sup>2</sup> Vgl.: Leukert, B.; Müller, J.; Noga, M.: Das intelligente Unternehmen: Maschinelles Lernen mit SAP zielgerichtet einsetzen. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. S. 50f

<sup>3</sup> Vgl.: Herbrich, R.: Künstliche Intelligenz bei Amazon Spitzentechnologie im Dienste des Kunden. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. S. 66f

<sup>4</sup> Vgl.: Wolff, T.; Yogeshwar, R.: Der große Umbruch. In: ORF2, Eco Spezial am 09.04.2020 um 22:30-23:05

<sup>5</sup> Vgl.: Herbrich, R.: Künstliche Intelligenz bei Amazon Spitzentechnologie im Dienste des Kunden. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. S. 68

<sup>6</sup> Vgl.: Herbrich, R.: Künstliche Intelligenz bei Amazon Spitzentechnologie im Dienste des Kunden. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. S. 70

in der Interpretation des Gesagten. Übersetzungsprogramme sind bereits derartig ausgereift, dass eine China-Reise ohne jeglicher Sprachkenntnisse mittels einer Sprach-App problemlos durchgeführt werden kann.

Durch die steigenden Errungenschaften in der Spracherkennung steht die Arbeit in Call Centern vor einem Wandel. Einfache Adressänderungen oder Terminvereinbarungen können mittlerweile problemlos im Gespräch mit einer künstlichen Intelligenz durchgeführt werden. Letzteres wurde bereits im Jahr 2018 mit Hilfe von Google Duplex anhand einer Tischreservierung und einem Frisörtermin demonstriert.<sup>7</sup> Ebenso wird bereits bei Telefonanfragen das vom Kunden beschriebene Problem analysiert und dem dafür zuständigen Facharbeiter bzw. der dafür zuständigen Facharbeiterin weitergeleitet. Weiters unterstützt diese Technologie im Hintergrund auch die Angestellten, indem Formulare durch Mithören automatisch ausgefüllt werden.

Aber nicht nur im Bereich des Gehörten sind großartige Möglichkeiten zu verzeichnen, sondern auch bei geschriebenen Texten können Chatbots den Alltag erleichtern. Bei vielen Konzernen wie beispielsweise bei A1 Telekom Austria beantwortet zunächst ein Bot die schriftlichen Chatanfragen, wodurch sehr schnell erste Lösungsmöglichkeiten aufgezeigt werden können. Wird keine zufriedenstellende Problembefehung gefunden, geht das Anliegen zu einem/einer Sachbearbeiter\*in weiter.

Einer der führenden Anbieter von Chatbot-Technologien ist IBM. Viele derer Kunden setzen auf intelligente digitale Serviceassistenten, um deren Mitarbeiter\*innen zu entlasten und gleichzeitig den Komfort für die Klient\*innen zu erhöhen. TOBi ist beispielsweise ein digitaler Serviceassistent, der bei der Bearbeitung von Anfragen auf Facebook, Apple Business Chat sowie per SMS unterstützt. Neben der Conciergetätigkeit, spricht er teilt das Anliegen dem/der richtigen Servicemitarbeiter\*in zu, versucht er auch, einfache Fragen selbst zu beantworten. Reisebuddy ist hingegen ein virtueller intelligenter Assistent, der von der Deutschen Bahn eingesetzt wird, um die rund 12 Millionen Anfragen pro Jahr effizienter zu bearbeiten. Hierfür stellt er mit Hilfe des antrainierten Wissens Antworten für die eingetroffene Kundenfragen zusammen, die vom/von der Servicemitarbeiter\*in nur noch überprüft werden müssen. Standardfragen werden automatisch beantwortet.<sup>8</sup>

IBM Watson bleibt jedoch nicht nur am Boden, sondern ist auch in höheren Sphären anzutreffen. CIMON, ein runder und 5 kg schwerer, intelligenter Astronautenassistent ist dank künstlicher Intelligenz in der Lage, zu sehen, zu hören, zu verstehen, zu sprechen und zu fliegen. Seit Sommer 2018 verbringt er die Tage im Weltall an Board der ISS. Seine Aufgabe ist es, die Astronaut\*innen bei Experimenten zu unterstützen.<sup>9</sup>

Watson ist auch als Wissensspeicher einsetzbar. Die Lufthansa hat als Unterstützung im Wissensmanagement ein internes Supportcenter auf Basis künstlicher Intelligenz eingeführt, welches dem raschen Beantworten der Fragen von Passagier\*innen und Angestellten dient. Sollte beispielsweise beim Einchecken ein Problem auftreten, können die Servicemitarbeiter\*innen dieses gleich mit Hilfe des neuen Supportcenters lösen.<sup>10</sup>

<sup>7</sup> Vgl.: <https://www.youtube.com/watch?v=D5VN56jQMWM>. Datum des Zugriffs: 03.04.2020

<sup>8</sup> Vgl.: IBM Deutschland: IBM Watson – Anwendungsbeispiele 2019. S. 3ff

<sup>9</sup> Vgl.: IBM Deutschland: IBM Watson – Anwendungsbeispiele 2019. S. 1

<sup>10</sup> Vgl.: IBM Deutschland: IBM Watson – Anwendungsbeispiele 2019. S. 6

Eine weitere Sparte, in der das Erkennen von Mustern mittels neuronaler Netze Einzug gefunden hat, stellt das Finanzwesen dar. Banken nutzen die Erfahrung aus dem Kundenverhalten der letzten Jahre, um die Kreditwürdigkeit zu beurteilen. Ebenso wird versucht, Markt- und Aktienentwicklungen mittels künstlicher Intelligenz vorherzusagen. Das Finden von Zusammenhängen ist aber auch bei der Bekämpfung von illegalen Finanztransaktionen und Geldwäsche äußerst wichtig.

Ebenso wird durch künstliche Intelligenz das Abschließen von Versicherungen vereinfacht. Seit November 2017 setzt die INTER Versicherung den kognitiven Chatbot EVA erfolgreich bei Online-Abschlüssen von Zahnzusatztarifen ein. Die Beraterin EVA chattet dabei monatlich mit rund 1.000 Interessent\*innen, klärt auf und verzeichnet dadurch mittlerweile eine deutlich steigende Anzahl an abgeschlossenen Verträgen. Weiters erkennt sie, ob vom Fachgebiet der Zahnzusatzversicherung abgewichen wird und führt daraufhin zum Thema zurück.<sup>11</sup>

Im Bereich der Medizin wurde bereits sehr früh erkannt, dass systematisches Erheben von Daten einen wesentlichen Mehrwert erzeugt. Beginnend mit den 1970er Jahren wurden bereits in der bibliografischen Referenzdatenbank PubMed Studien gesammelt.<sup>12</sup> Heutzutage weisen die in einem Datensatz aufbereiteten Informationen einen großen Wert auf, weil diese mit Hilfe künstlicher Intelligenz auf Zusammenhänge untersucht werden können, um in weiterer Folge effektive Prognosen und Klassifizierungen durchzuführen. Ein Beispiel stellt hierfür die Detektion von Hautkrebs mittels Bilderkennung dar. *Esteva et al.* trainierten ein neuronales Netz anhand 129.450 einzelner Bilder, um Hautläsionen zu erkennen. Abschließend wurde die Prognose der künstlichen Intelligenz mit jener von 21 Dermatologinnen und Dermatologen verglichen. Hierbei kommt die Studie zu der Erkenntnis, dass die computerbasierten Vorhersagen mit jenen der Fachärztinnen und -ärzte problemlos mithalten können.<sup>13</sup> Die selbe Vorgehensweise wird ebenso bei der Auswertung von Polypen, die bei Endoskopien entdeckt werden, erfolgversprechend eingesetzt. Aufgrund der Auswertung reichlicher Informationen der vergangenen Jahre können somit automatisch histopatologische Befunde anhand endoskopischer Bilder erstellt werden.<sup>14</sup>

Sind genügend Röntgenaufnahmen vorhanden, stellen auch hierbei neuronale Netze ein geeignetes Hilfsmittel dar, um Krankheiten zu erkennen. Im Mai 2017 veröffentlichten die National Institutes of Health (NIH) den Datensatz ChestX-ray8. Dieser beinhaltet 108.948 frontale Röntgenbilder, welche von 32.717 einzelnen Personen stammen. Daraus sind 84.312 Abbildungen von gesunden Menschen. Die restlichen 24.636 Aufnahmen zeigen acht verschiedene Lungenkrankheiten, wobei auf einem Bild auch mehrere erkennbar sein können. Das Ziel dieser Erhebung ist es, eine Datengrundlage für automatisierte Beurteilungen mittels künstlicher Intelligenz zur Verfügung zu stellen.<sup>15</sup> Im September 2017 wurde eine Erweiterung auf 14 Krankheiten mit einer Gesamtmenge von 120.120 Röntgenaufnahmen durchgeführt.<sup>16</sup> Auf diesen erweiterten Datensatz spezialisierte sich die

<sup>11</sup> Vgl.: IBM Deutschland: IBM Watson – Anwendungsbeispiele 2019. S. 6f

<sup>12</sup> Vgl.: Wittpahl, V.: Künstliche Intelligenz Technologie | Anwendung | Gesellschaft. S. 164

<sup>13</sup> Vgl.: Esteva, A. et al.: Dermatologist-level classification of skin cancer with deep neural networks. In: Nature, 542 (7939), 2017. S. 115-118.

<sup>14</sup> Vgl.: Schmitz, R.; Werner, R.; Rösch, T.: Künstliche Intelligenz in der Endoskopie: Neuronale Netze und maschinelles Sehen – Techniken und Perspektiven. In: Gastroenterol, 57 (06), 2019. S. 767-780

<sup>15</sup> Vgl.: Wang, X. et al.: ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases. In: IEEE CVPR, 2017. S. 2097-2106

Stanford Machine Learning Group und entwickelte den Deep-Learning-Algorithmus CheXNet, welcher herausragende Ergebnisse lieferte. Nach über einem Monat des Trainings gelang es CheXNet, Lungenentzündungen besser auf Röntgenbildern zu erkennen als vier Stanford-Radiolog\*innen.<sup>17</sup>

Neben der Bewertung medizinischer Bilder, erleichtert künstliche Intelligenz auch den Alltag von Parkinsonpatient\*innen. Microsoft nahm sich der Krankheitsgeschichte einer Grafikerin an und fand nach mehrmonatiger Forschungsarbeit eine Lösung, die vom Aussehen her einer Armbanduhr gleicht. Die Kompensation der Armmuskelkontraktionen mittels einer um das Handgelenk geschallten Scheibe ermöglicht hierbei, dass die Patientin wieder Zeichnen und Schreiben kann. Diese vibrierende Masse ist genau auf die Bewegungsmuster der jungen Dame abgestimmt, welche zuvor mittels Sensoren erhoben wurden. Mit Hilfe künstlicher Intelligenz konnte aus diesen Informationen eine gezielte Gegenbewegung generiert werden, wodurch die Hand in Ruhelage bleibt.<sup>18</sup>

Heutzutage gibt es eine Unzahl an Arzneimitteln, um diverse Krankheiten sowohl traditionell als auch mittels Schulmedizin zu behandeln. Durch diese enorme Menge an Produkten ist es für das ärztliche Personal sehr schwer geworden, alle Wechselwirkungen untereinander und die Nebenwirkungen zu kennen. Eine Möglichkeit, diese Herausforderung zu bewältigen, ist der Einsatz künstlicher Intelligenz. Durch das umfangreiche Erkennen von Zusammenhängen zwischen den einzelnen Medikamenten können Fehlmedikationen sofort detektiert und dadurch Leben gerettet werden.

Big data und die derzeitige Methoden zur Auswertung tragen ein enormes Potenzial in sich, um die Gesundheitsversorgung sowie Patient\*innenergebnisse zu verbessern. Durch effizientere und auf das Individuum abgestimmte Behandlungen ist es möglich, die Verschwendung von Ressourcen zu verringern. Weitere durch die Auswertung großer Datenmengen profitierende Anwendungsbereiche sind die Überwachung der molekularen Charakteristika im Verlauf der Behandlung, DNA-Sequenzierungen, die Entlarvung von Betrugsfällen, Behandlungsentscheidungen oder Modellbildungen, welche die Ausbreitung einzelner Krankheiten beschreiben.<sup>19</sup>

Damit einerseits mögliche Patient\*innen bereits im Vorhinein präventiv behandelt werden können und es andererseits zu keinen unnötigen medizinischen Interventionen kommt, ist eine präzise Prognose für zukünftige Erkrankungen notwendig. Dieser herausfordernden Aufgabe stellte sich ein Forscherteam der Universität Nottingham. Anhand medizinischer Daten von 378.256 Patient\*innen versuchten die Wissenschaftler\*innen kardiovaskuläre (Herz und Kreislauf betreffende) Krankheiten im Zeitraum von 10 Jahren vorherzusagen. Hierfür testeten sie vier verschiedene Machine-Learning-Algorithmen, von denen die neuronalen Netze am besten abschnitten. Der Gesamtdatensatz wurde zufällig in zwei kleinere, 295.267 und 82.989, aufgeteilt, wobei der erste zum Trainieren und der zweite zum Validieren herangezogen wurde. Beim Überprüfen des neuro-

<sup>16</sup> Vgl.: Summers, R. M.: NIH Clinical Center provides one of the largest publicly available chest x-ray datasets to scientific community. <https://www.nih.gov/news-events/news-releases/nih-clinical-center-provides-one-largest-publicly-available-chest-x-ray-datasets-scientific-community>. Datum des Zugriffs: 06.04.2020

<sup>17</sup> Vgl.: Kubota, T.: Stanford algorithm can diagnose pneumonia better than radiologists. <https://news.stanford.edu/2017/11/15/algorithm-outperforms-radiologists-diagnosing-pneumonia/>. Datum des Zugriffs: 06.04.2020

<sup>18</sup> Vgl.: Gürtler, O.: Künstliche Intelligenz als Weg zur wahren digitalen Transformation In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. S. 102

<sup>19</sup> Vgl.: Lee, C. H.; Yoon H.: Medical big data: promise and challenges. In: *Kidney Research and Clinical Practice*, 36 (1), 2017. S. 3-11

nen Netzes konnten 4.998 aus 7.404 Krankheitsfällen (68 %) und 53.458 von 75.585 gesunde Lebensverläufe (71 %) richtig prognostiziert werden.<sup>20</sup>

Neben den Anwendungsmöglichkeiten, die den menschlichen Gesundheitszustand verbessern, wird künstliche Intelligenz auch auf den Feldern eingesetzt, um Pflanzen bestmöglich mit Wasser und Nährstoffen zu versorgen. Über Sensoren im Boden werden die wesentlichen Parameter erhoben und mit weiteren Daten – beispielsweise dem Wetter – zu einem Datensatz vereint. Dieser kann anschließend von neuronalen Netzen analysiert werden. Somit können unter anderem zielgerichtete Prognosen über den Erntezeitpunkt, den Einsatz von Schädlingsbekämpfungsmitteln, das Wasserbedürfnis oder die Lüftung von Glashäusern erstellt werden.

In der Landwirtschaft wird die künstliche Intelligenz jedoch nicht nur für Vorhersagen verwendet, sondern auch bei Robotern eingesetzt, damit diese einzelne Tätigkeiten selbstständig durchführen können. Zu den Hauptaufgaben gehören hierbei die Navigation über das Feld (Flug- oder Landrobooter), Objekterkennung bei Aufnahmen, Precision Farming (z.B.: Säen oder Bewuchs ausdünnen), präzise Manipulationen (z.B.: Ernten), die Kommunikation der Geräte untereinander und das Anlegen von Bepflanzungskarten.<sup>21</sup>

Jahrzehntlang galt es in der Landwirtschaft, massivere und vor allem leistungsstärkere Geräte einzusetzen, damit immer größere Flächen bearbeitet werden können. Das starke Verdichten des Bodens durch schwere Maschinen oder Sondergenehmigungen, um auf der Straße zu fahren, wurden dafür in Kauf genommen. Durch kleine Feldroboter, die in Schwärmen über die Ackerfläche fahren, wird diese Denkweise nun in Frage gestellt. Der Bauer bzw. die Bäuerin muss nur noch einen Anhänger mit Saatgut auf dem Feld platzieren, damit die kleinen Helfer selbstständig nachladen können. Mit einem Gewicht von 50 kg wird somit beim Säen der Boden nicht verdichtet und zusätzlich die Position eines jeden Kornes mit einer Genauigkeit von 4 cm dokumentiert. Dies hilft in weiterer Folge, die Düngemittel effizienter einzusetzen.<sup>22</sup>

Bildererkennung kann nicht nur einem Roboter dabei helfen, Unkraut und Nutzpflanzen auseinander zu halten, sondern auch Versicherungen unterstützen, indem Autounfälle automatisch in Schadensklassen eingeteilt werden. Hierfür ist es lediglich notwendig, ein Foto des Blechschadens zu machen und an die Versicherung zu schicken. Die künstliche Intelligenz erkennt sofort die Problemstelle und ordnet sie sachgemäß in die passende Kategorie. Diese Art der Bearbeitung geht sehr schnell, erspart der Versicherung Kosten und führt in weiterer Folge zu einer höheren Kundenzufriedenheit, da die Antwort postwendend zurückkommt.<sup>23</sup>

Es benötigt aber nicht immer einen Unfall, damit ein PKW zum Stehen kommt. Oftmals reicht hierfür schon ein Problem in der Elektronik, wodurch das Auto nicht gestartet werden kann. Lediglich eine Warnlampe leuchtet auf, deren genaue Bedeutung nur mittels Betriebsanleitung entziffert werden kann. Damit Autofahrern das Suchen in dieser erspart bleibt, entwickelte

<sup>20</sup> Vgl.: Weng, S. F. et al.: Can machine-learning improve cardiovascular risk prediction using routine clinical data?. In: PLoS ONE, 12 (4), 2017. S. 1-14

<sup>21</sup> Vgl.: Wittpahl, V.: Künstliche Intelligenz Technologie | Anwendung | Gesellschaft. S.109

<sup>22</sup> Vgl.: Wölbert, C.: Das sind die Stars auf der Agritechnica. In: Hannoversche Allgemeine, am 17.11.2017. <https://www.haz.de/Nachrichten/Wirtschaft/Niedersachsen/Das-sind-die-Stars-auf-der-Agritechnica-2017-in-Hannover>. Datum des Zugriffs:01.04.2020

<sup>23</sup> Vgl.: Hildesheim, W.; Michelsen, D.: Künstliche Intelligenz im Jahr 2018 – Aktueller Stand von branchenübergreifenden KI-Lösungen: Was ist möglich? Was nicht? Beispiele und Empfehlungen. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. S. 136

Mercedes einen eigens darauf trainierten Chatbot. Dieser trägt den Namen „Ask Mercedes“, wurde gemeinsam mit IBM ins Leben gerufen und ist für die E- und S-Klasse verfügbar. Neben den Antworten auf die klassischen Fragen liefert diese leistungsfähige Software jegliches Wissen zum vollständigen Betrieb der beiden Modelle. Dies ist nicht nur bei der ständig wachsenden Anzahl an Funktionen im Auto, sondern auch beim Nutzen eines Mietwagens hilfreich, weil man sich dadurch sehr rasch zurecht findet.<sup>24</sup>

In der Vergangenheit haben es hart umkämpfte Entwicklungen im Rennsport bereits in die Großserie geschafft. Hierzu zählen zum Beispiel Leichtbaumaterialien, durch die der Kraftstoffverbrauch gesunken ist, Scheibenbremsen oder elektronische Einspritzanlagen, welche die Leistung zudem deutlich erhöhen. Ein aktuelles vielversprechendes Forschungsergebnis, das ebenfalls großes Potenzial zeigt, um in Serie zu gehen, stammt aus einer Kooperation von Volkswagen Data:Lab und Audi Motorsport in der Formel E. Das Hauptziel dieser Partnerschaft ist die optimale Ausnutzung der Batterie der elektrischen Rennwagen. Das Optimum ist dann erreicht, wenn die Energiequelle genau beim Zieleinlauf leer ist. Dies ist das entscheidende Kriterium für einen Sieg, weil die verfügbare Batterieleistung für alle Teams gleich ist. Einen wesentlichen Einflussfaktor auf die Entladung stellt die Temperatur der Energiequelle dar. Aus diesem Grund versuchte Data:Lab mittels künstlicher Intelligenz die Wärmeentwicklung des Batteriesystems vorherzusagen. Nach einer dreimonatigen Entwicklungszeit lieferten bereits die ersten Tests im Simulator und auf der Rennstrecke vielversprechende Ergebnisse.<sup>25</sup>

Neben intensiver Forschungsarbeit am Elektroantrieb sind selbstfahrende Autos ein weiterer Bereich, in den aktuell viele Entwicklungsbemühungen gesteckt werden. Damit ein Transportmittel ohne Fahrer unterwegs sein kann, muss es die Umgebung mittels Sensoren wahrnehmen können und das Gesehene verstehen. Ein wesentlicher Bestandteil ist hierbei die Auswertung von Bildern mittels künstlicher Intelligenz. In diesem Forschungsbereich ist ImageNet 2012 ein weit verbreiteter Datensatz, der als Vergleichsbasis verschiedener Bilderkennungsalgorithmen herangezogen wird. Dieser besteht aus 1.000 Begriffsgruppen, bei denen jede einzelne rund 1.200 Bilder beinhaltet.<sup>26</sup> Der Top-5-Fehler eines Menschen liegt bei diesem Datensatz laut *Russakovsky et al.* bei 5,1 %.<sup>27</sup> Top-5 bedeutet, dass eine der fünf wahrscheinlichsten Bildgruppen laut künstlicher Intelligenz mit dem richtigen Ergebnis übereinstimmt. Top-1 heißt somit, dass die eine vom Algorithmus ausgewählte Bildgruppe mit dem Ergebnis identisch ist. *Xie et al.* (2020) erzielen mittels deren Algorithmus bei der Klassifikation dieser Bilder einen Top-5-Fehler von 1,3 % und einen Top-1-Fehler von 11,6 %.<sup>28</sup> Mit Hilfe eines erweiterten Trainingsdatensatzes senken *Zihang et al.* (2021) den Top-1-Fehler auf 9,12 %.<sup>29</sup> An dieser Stelle gilt es jedoch, darauf hinzuweisen, dass dieses herausragenden Ergebnisse hauptsächlich auf die enorme Rechenleistung, die Google mittels spezieller Hardware erreicht, zurückzuführen ist.

<sup>24</sup> Vgl.: Hildesheim, W.; Scheunert, S.: Ask Mercedes: Chatbot statt Betriebsanleitung. <https://www.ibm.com/de-de/blogs/think/2017/11/30/ask-mercedes-chatbot-statt-betriebsanleitung/>. Datum des Zugriffs: 03.04.2020

<sup>25</sup> Vgl.: Hilbert, M. et al.: KI-Innovation über das autonome Fahren hinaus In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. S. 177f

<sup>26</sup> Vgl.: <http://www.image-net.org/challenges/LSVRC/2012/>. Datum des Zugriffs: 07.04.2020

<sup>27</sup> Vgl.: Russakovsky, O. et al.: ImageNet Large Scale Visual Recognition Challenge. In: arXiv, 2015. <https://arxiv.org/abs/1409.0575>. Datum des Zugriffs: 07.04.2020. S. 31

<sup>28</sup> Vgl.: Xie, O. et al.: Self-training with Noisy Student improves ImageNet classification. In arXiv, 2020. <https://arxiv.org/abs/1911.04252>. Datum des Zugriffs: 07.04.2020. S. 1-16

<sup>29</sup> Vgl.: Zihang, D. et al.: CoAtNet: Marrying Convolution and Attention for All Data Sizes. In: arXiv, 2021. <https://arxiv.org/abs/2106.04803>. Datum des Zugriffs: 19.12.2021

Sensoren spielen nicht nur im Auto eine wesentliche Rolle, sondern auch bei technischen Anlagen. Der Samson-Prozessknoten besteht aus dem Ventil sowie einer Sensor-Aktor-Einheit und sendet die gesammelten Daten an den Sam Digital Hub. Dort werden sie mit Hilfe künstlicher Intelligenz ausgewertet und grafisch aufbereitet. Dadurch können beispielsweise Unregelmäßigkeiten anhand einer Geräuschanalyse in Echtzeit detektiert werden. Mit zunehmender Anzahl an Prozessknoten und Laufzeit steigt die Schwarmintelligenz und somit das Wissen über die Anlage. Diese aus den Feldgeräten gesammelten Informationen helfen, Kosten zu senken und die Effizienz zu steigern. Weiters können Ausfälle durch prädiktive Wartungen reduziert werden.<sup>30</sup>

Neben der Vorhersage von Wartungen ist auch eine Prognose über Ausfälle von bestimmten (Bau-)Teilen möglich. In Australien wird beispielsweise das Ausfallrisiko von Wasserleitungen beurteilt. Dadurch können Problemstellen detektiert und vorzeitig behoben werden, wodurch sich Folgeschäden minimieren. Diesem Hilfsmittel bedienen sich auch amerikanische Behörden um herauszufinden, wo sich bauaufsichtliche Inspektionen am ehesten lohnen.<sup>31</sup>

### 3.2 Allgemeine Herangehensweise

In folgendem Abschnitt wird die allgemeine Herangehensweise für die Implementierung von künstlicher Intelligenz aus dem Bereich Supervised Learning vorgestellt. Unabhängig von der Art der Prognose gilt es, diese Schritte einzuhalten, um zu effektiven Lösungen wie beispielsweise den vorgestellten Anwendungsmöglichkeiten zu kommen.

Die nachfolgende Abbildung 3-1 verdeutlicht die einzuhaltende Reihenfolge. An dieser Stelle muss jedoch erwähnt werden, dass die gezeigte Grafik bereits ein Vorwissen über künstliche Intelligenz sowie deren Einsatzmöglichkeiten voraussetzt. Wurde ein Prozess beispielsweise vom Management aus detektiert, welcher mit Hilfe von Supervised Learning effektiver gestaltet werden kann, ist zunächst ein Team für die Umsetzung zu bestimmen, in welchem die Zuständigkeiten und die Verantwortlichkeiten klar geregelt sind.

Ist diese Vorarbeit getan, wird im ersten Schritt die Zieldefinition formuliert. Diese beinhaltet neben der gewünschten Vorhersage auch den für ein Unternehmen maximal vertretbaren Fehler. So wie Menschen irren sich auch neuronale Netze. Der maximale Fehler muss somit in Abhängigkeit der Folgen einer Fehlinterpretation festgelegt werden. Wird dies vorab nicht besprochen, kann es nach dem Implementierungsprozesses zu einer bitteren Enttäuschung kommen. Wenn der Fehler in den Vorhersagen zu groß ist, führt dies im schlimmsten Fall sogar zu einem Produktivitätsverlust. Ob eine 80-prozentige Eintrittswahrscheinlichkeit für grobe Abschätzungen oder eine 99-prozentige Trefferquote für folgenschwerere Prognosen ausreicht, ist somit immer individuell zu prüfen.

<sup>30</sup> Vgl.: Interview mit Widl, A., et al.: Best of both Worlds. In: Industriearmaturen & Dichtungstechnik 4/2017. S. 1-6

<sup>31</sup> Vgl.: Roth, F.; Kohler, K.: KI verändert auch das Risikomanagement. In: IT-Security 5/19. S. 23

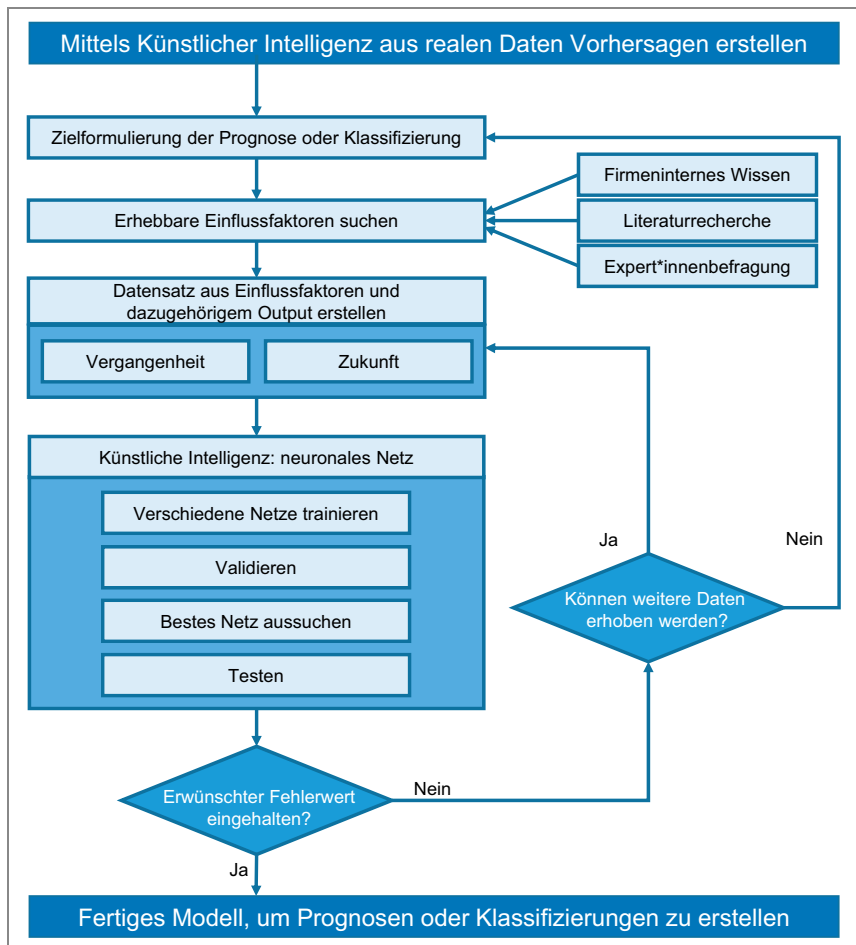


Abb. 3-1 Allgemeine Herangehensweise für Prognosen oder Klassifizierungen im Bereich Supervised Learning

Da im Bauwesen deutlich kleinere Datensätze als beispielsweise in der Medizin vorliegen, müssen im nächsten Schritt erhebbare Faktoren bestimmt werden, die einen möglichst großen Einfluss auf den Prognosewert ausüben. Theoretisch lernen neuronale Netze aus jedem Datensatz, welche Inputparameter eine große und welche eine geringe Bedeutung für das Output haben, jedoch gilt dies nur, wenn eine ausreichende Datenmenge vorhanden ist. Deshalb muss bei kleineren Datengrundlagen eine menschliche Vorauswahl getroffen werden, um bessere Prognoseergebnisse zu erzielen. Bei dieser notwendigen Auswahl kann beispielsweise auf firmeninternes Wissen (kontextbezogene Informationen), eine Literaturrecherche oder eine Expert\*innenbefragung zurückgegriffen werden. Wichtige Aspekte, die es bei der Einflussfaktorensuche zu beachten gilt, sind die Verfügbarkeit von bereits erhobenem und systematisch aufbereitetem Wissen sowie die Möglichkeit, automatisch Informationen im laufenden Betrieb zu sammeln.

Wurden die Parameter mit dem größtmöglichen Einfluss bestimmt, ist daraufhin zu überprüfen, ob diese Informationen bereits in Verbindung mit dem zu prognostizierenden Ergebnis im Wissensspeicher des Unternehmens vorhanden sind. Sollen beispielsweise die Kosten einer Hochhausbaustelle prognostiziert und als Einflussfaktoren die Grundfläche, die Stockwerk-sanzahl und die Ausstattungsqualität ausgewählt werden, müssen nun alle



vergangenen Baustellen dieser Art auf diese drei Parameter und die Kosten hin untersucht werden.

In weiterer Folge gilt es, die Informationen (Grundfläche, Stockanzahl, Ausstattungsqualität und Kosten) in einem Datensatz zusammenzufassen. Ein hierfür beispielhafter Aufbau wird in Abbildung 3-2 gezeigt. Jede Zeile repräsentiert einen Fall, welcher aus den Einflussfaktoren, den sogenannten Inputparametern, und dem vorherzusagenden Wert (Output) besteht. Wichtig ist es hierbei, auf die Vollständigkeit innerhalb der einzelnen Fälle zu achten.

Nr.:	Datensatz	
Fall 1	Inputparameter	Output
Fall 2	Inputparameter	Output
Fall 3	Inputparameter	Output
Fall 4	Inputparameter	Output

Abb. 3-2 Demonstrativer Aufbau eines Datensatzes

Neben der Analyse der Vergangenheit muss ebenso überlegt werden, auf welche Art und Weise zukünftige Fälle (Baustellen), am besten automatisch, in den Datensatz eingebunden werden. Nur durch eine Vergrößerung der Datengrundlage ist es möglich, dass sich die künstliche Intelligenz weiterentwickelt und dadurch zu genaueren Ergebnissen kommt.

Sollten zu wenig Informationen aus bereits abgeschlossenen Arbeiten vorliegen, kann kein neuronales Netz trainiert werden. In diesem Fall gilt es, sich zunächst auf die systematische Erhebung von Informationen zu fokussieren, damit ein Datensatz aus kommenden Projekten erstellt werden kann. Hierbei ist die Anwendung von Sensoren und Ortungstechnologien sehr zu empfehlen, weil dadurch eine lückenlose und automatische Dokumentation gewährleistet wird.

Nach ausreichendem Sammeln von Daten kann mit dem Trainieren der neuronalen Netze begonnen werden. In Abhängigkeit von der Komplexität der Aufgabenstellung und den programmiertechnischen Fähigkeiten der Arbeitsgruppe muss zunächst entschieden werden, ob der Programmierauftrag extern oder intern abgearbeitet wird. Weiters ist anhand des vorhandenen Wissens, der gewünschten Anwenderfreundlichkeit, der Möglichkeit einer zukünftigen Anpassung sowie weiterer firmenspezifischer Überlegungen festzulegen, auf welche Art und Weise die künstliche Intelligenz implementiert wird. Hierbei liegt die Auswahlmöglichkeit zwischen dem kompletten Code selbst verfassen bis hin zur Anwendung eines fertigen Programms.

Abbildung 3-3 zeigt den Einfluss der einzelnen Faktoren auf die Implementierungsart. Unter Selbstbedienungs-KI wird eine intuitive, einfache Software verstanden, welche ohne explizites Fachwissen eingesetzt werden kann. Mit der hohen Anwenderfreundlichkeit geht jedoch eine sehr geringe Anpassungsmöglichkeit einher. Genau das Gegenteil stellt KI Backbone dar. Das sogenannte Rückgrat der künstlichen Intelligenz spiegelt detailliert die programmiertechnischen Einzelheiten wider. Mit hohem Fachwissen ist es möglich, die Problemstellung bestmöglich zu lösen und zukünftig Änderungen rasch zu implementieren. Zwischen den soeben beschriebenen

Randpunkten liegen noch drei weitere Ebenen mit unterschiedlicher Programmtiefe. Diese werden wiederverwendbare Module, Machine-Learning-Algorithmen und Deep Learning Framework genannt.<sup>32</sup>

Ein weitverbreitetes Framework ist TensorFlow, welches von Google entwickelt wurde. Diese Machine Learning Bibliothek bietet mit all ihren Werkzeugen und einer weltweiten Community eine solide Grundlage für das Umsetzen und Implementieren neuronaler Netze.<sup>33</sup> Aus diesem Grund wird sie nicht nur in der Forschung, sondern auch in der Wirtschaft erfolgreich eingesetzt. Die nutzerfreundliche Erweiterung Keras<sup>34</sup> zeigt bereits, dass der Trend immer mehr in Richtung der wiederverwendbaren Module geht, damit diese großflächig in der Wirtschaft eingesetzt werden können.

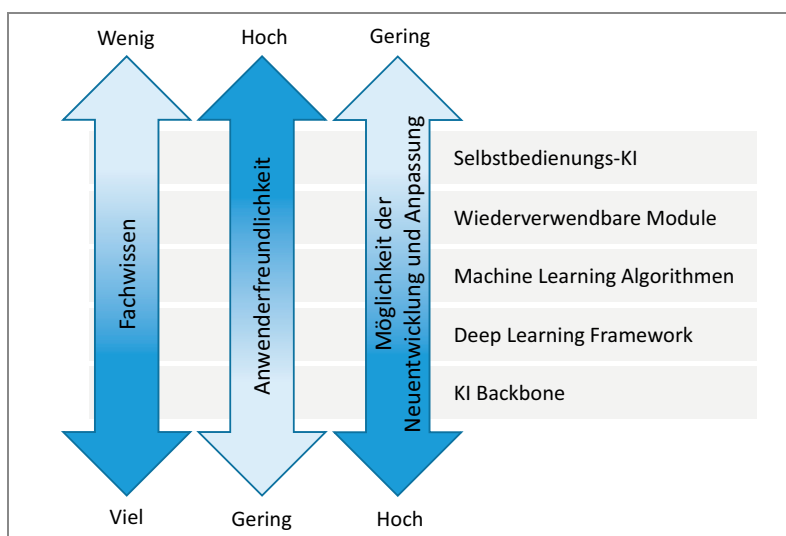


Abb. 3-3 Einfluss der Programmtiefe<sup>35</sup>

Beim Einsatz neuronaler Netze für Prognose- oder Klassifizierungszwecke sind, wie in Abbildung 3-1 gezeigt, zunächst verschiedene Netze zu trainieren, welche unterschiedliche Netzkonfigurationen aufweisen. Weil zu Beginn der beste Netzaufbau nicht bekannt ist, sollte zunächst mit Hilfe von einer Literaturrecherche oder Expert\*innenmeinung abgeschätzt werden, welche Neuronenkonstellationen am geeignetsten erscheinen. Diese gilt es anschließend umzusetzen, mittels Validierungsdaten zu beurteilen und das Modell, welches den geringsten Fehlerwert (beispielsweise der kleinste mittlere quadratische Fehler) aufweist, auszuwählen.

An dieser Stelle ist es besonders wichtig, darauf zu achten, dass kein Overfitting stattfindet. Dieses Phänomen bezeichnet das Erkennen eines Zusammenhangs, der nur innerhalb des Datensatzes zu finden und daher nicht allgemeingültig ist. Durch das Vergleichen der Fehlerwerte der Trainingsfälle mit jenen der Validierungsfälle ist es möglich, Overfitting zu detektieren. Weichen diese beiden voneinander stark ab, bedeutet es, dass zwar innerhalb der Trainingsdaten Zusammenhänge gefunden wurden, diese jedoch keine allgemeine Gültigkeit aufweisen. Somit sind diese Erkenntnisse nicht auf die Aufgabenstellung anwendbar und müssen verworfen werden.

<sup>32</sup> Vgl.: Berinato, S.: In Facebooks KI-Fabrik. In: Harvard Business manager 11/2017. S. 41

<sup>33</sup> TensorFlow: <https://www.tensorflow.org/>. Datum des Zugriffs: 15.04.2020

<sup>34</sup> Keras: <https://keras.io/>. Datum des Zugriffs: 15.04.2020

<sup>35</sup> Schichtenmodell angelehnt an Berinato, S.: In Facebooks KI-Fabrik. In: Harvard Business manager 11/2017. S. 41

Abschließend kann das ausgewählte Modell nochmals auf Basis der Testfälle beurteilt werden, um eine hohe Qualität zu gewährleisten. Der Unterschied zu den Validierungsdaten besteht hierbei darin, dass das neuronale Netz die Testfälle nicht kennt und dadurch eine allgemeinere Aussage ermöglicht wird. Die Validierungsdaten bilden hingegen die Basis für die Modellauswahl, wodurch das neuronale Netz auf diese hin optimiert ist.

Nach der Bestimmung des besten Netzes ist zu überprüfen, ob die Vorgaben aus der Zielformulierung eingehalten werden. Ist dies der Fall, können zukünftige Prognosen oder Klassifizierungen mit Hilfe dieser künstlichen Intelligenz durchgeführt werden. Sollte sich hingegen herausstellen, dass die im Vorhinein bestimmten Fehlerwerte nicht eingehalten werden, muss das neuronale Netz verbessert werden. Hierbei stellt sich zunächst die Frage, ob noch weitere Daten erhoben werden können, damit bei einem erneuten Training der Machine-Learning-Algorithmus die Zusammenhänge besser erkennt. Kristallisiert sich heraus, dass der Datensatz aktuell und in naher Zukunft nicht vergrößert werden kann, muss zum Anfang zurückgekehrt werden. Im Falle, dass die Zieldefinition nicht verändert werden darf, sind weitere Parameter zu finden, die dem Datensatz beigefügt werden können. Daraufhin wird wieder mit dem Trainieren der verschiedenen Netze begonnen.

An dieser Stelle ist es wichtig, hervorzuheben, dass nicht jeder maximale Fehler der Zielformulierung sofort unterschritten wird. Somit kann es vorkommen, dass dieser Implementierungsprozess länger dauert, da das Vergrößern eines Datensatzes Zeit bedarf. Sollte diese nicht vorhanden sein, ist ein Abbruch des Vorhabens zu empfehlen.

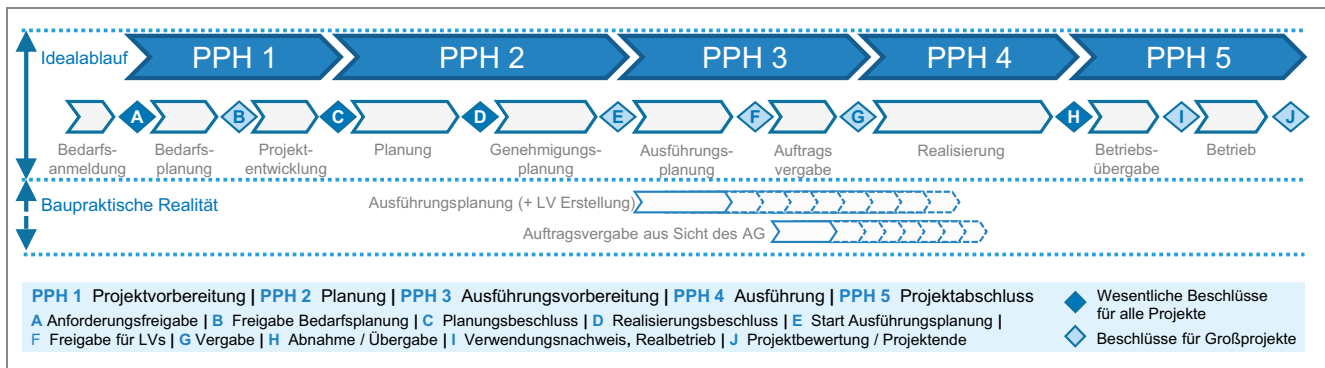
### **3.3 Bauwirtschaftliche und baubetriebliche Anwendungsmöglichkeiten**

In diesem Abschnitt werden zu Beginn baubetriebliche und bauwirtschaftliche Anwendungsmöglichkeiten von neuronalen Netzen in den einzelnen Projektphasen für Auftraggeber (AG) und Auftragnehmer (AN) vorgestellt. Anschließend stehen in Abhängigkeit ausgewählter Outputs mögliche Einflussfaktoren, die als Input bei neuronalen Netzen eingesetzt werden können, im Fokus der Betrachtung.

#### **3.3.1 Einsatzmöglichkeiten in Abhängigkeit der Projektphasen**

Der Ablauf eines Bauprojekts wird in fünf Projektphasen (PPH) gegliedert, welche in Abbildung 3-4 dargestellt sind. Diese werden als Projektvorbereitung, Planung, Ausführungsvorbereitung, Ausführung sowie Projektabschluss bezeichnet und erstrecken sich von der Anforderungsfreigabe bis hin zur Projektbewertung. Darüber hinaus lassen sich diese Phasen in Unterbereiche gliedern, die wiederum durch Quality Gates (QG) voneinander getrennt sind. Diese detailliertere Einteilung mit abschließender Kontrolle soll gewährleisten, dass erst nach dem Festlegen wesentlicher Aspekte und dem Fassen maßgebender Beschlüsse zur nächsten Phase vorangeschritten wird.<sup>36</sup>

<sup>36</sup> Vgl.: Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 158

Abb. 3-4 Projektphasen<sup>37</sup>

Damit ein neues Vorhaben gestartet werden kann, muss zunächst eine Projektidee vorliegen, für welche ein allgemeiner oder spezieller Bedarf besteht. Ist dieses Kriterium erfüllt, erfolgt durch das Überschreiten von QG A (Anforderungsfreigabe) der Eintritt in Projektphase 1. Diese ist in Bedarfsplanung sowie Projektentwicklung unterteilt, wobei das dazwischenliegende QG B ersteres freigibt. Mit QG C wird der Planungsbeschluss finalisiert und nach Bestehen der Anforderungen PPH 2 eingeleitet. In Projektphase 2 wird zunächst entworfen und nach dem Realisierungsbeschluss (QG D) mit der Genehmigungsplanung (Einreichplanung) fortgeföhren. Das Einleiten des Einreichverfahrens mit abschließendem Erhalt der Baubewilligung führt zum Beginn der PPH 3. In dieser werden zunächst im Rahmen der Ausführungsplanung die entsprechenden Leistungsverzeichnisse erstellt und nach deren Freigabe (QG F) mit der Ausschreibung begonnen. Mit der Vergabe der Aufträge wird die Ausführungsvorbereitung abgeschlossen.<sup>38</sup>

In einem idealen Projektablauf erfolgt die Anordnung der einzelnen Projektphasen in chronologischer Reihenfolge, wobei erst zur nächsten Phase fortgeschritten werden kann, wenn das zugehörige QG erfüllt ist. Das heißt, bevor mit der Umsetzung begonnen wird, ist bereits die Ausführungsplanung sowie die Vergabe aller Leistungen abgeschlossen. In der Realität ist dieser ideale Ablauf jedoch nur sehr selten anzutreffen. Meistens werden die Arbeiten aus PPH 3 baubegleitend fortgeföhrt. Durch das Planen und Vergaben von Leistungen parallel zum Bauprozess verkürzt der AG die Projektdauer des gesamten Vorhabens und kann flexibler auf geänderte Anforderungen reagieren. Gleichzeitig nimmt er jedoch zusätzliche Schwierigkeiten, die auf den hohen Zeitdruck zurückzuführen sind, in Kauf. Durch verspätete Planungsänderungen können beispielsweise Mehrkosten oder Bauzeitüberschreitungen auftreten, die bei bereits abgeschlossener Planung nicht entstanden wären. Weiters besteht immer ein Risiko, dass Pläne nicht pünktlich geliefert werden oder deren Qualität aufgrund des Zeitdrucks geringer ausfällt.<sup>39</sup>

Der technische Projektabschluss wird nach Vollendung der Baumaßnahmen mit dem Erreichen des QG H erzielt. Bei diesem übernimmt im Zuge der Abnahme der AG vom AN das Bauwerk. Daraufhin beginnt Projektphase 5, welche in Betriebsübergabe und Betrieb gegliedert ist. In ersterem werden

<sup>37</sup> Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 158

<sup>38</sup> Vgl.: Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 158f

<sup>39</sup> Vgl.: Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 159

die letzten Abrechnungen und Mängelbehebungen durchgeführt, um den kaufmännischen Projektabschluss zu erzielen. Weiters erfolgt in Abhängigkeit des Bauwerkstyps der Verwendungsnachweis und der Probe- oder Realbetrieb (QG I). Abgeschlossen wird das gesamte Vorhaben durch die Projektbewertung (QG J). Im Zuge dieser gilt es, zentrale Daten und Kennwerte systematisch zu erheben, nutzerfreundlich zu dokumentieren und anwenderorientiert zu speichern. Nur dadurch kann aus den gesammelten Informationen Wissen oder beispielsweise ein Datensatz für neuronale Netze erzeugt werden.<sup>40</sup>

Über die gesamte Projektdauer hinweg müssen Entscheidungen gefällt und Analysen durchgeführt werden, um das Projektziel zu erreichen. Sind genügend Daten aus der Vergangenheit vorhanden, kann hierbei mittels künstlicher Intelligenz Abhilfe geschaffen werden. Im Speziellen lassen sich neuronale Netze bei Prognosen und Klassifizierungen einsetzen.

Die nachfolgende Abbildung zeigt ausgewählte Anwendungsmöglichkeiten für AG in Projektphase 1 und 3. In der Projektvorbereitung können beispielsweise neuronale Netze eingesetzt werden, um verschiedene Bedürfnisse vorherzusagen und automatisch den zukünftigen Bedarf zu ermitteln. Dies gilt auch für die Entwicklung von verschiedenen Stadtteilen. Ein weiterer wichtiger Aspekt in PPH 1 ist eine erste Kosten- und Bauzeitschätzung. Wird diese mittels künstlicher Intelligenz durchgeführt, werden zunächst aus bereits abgeschlossenen Projekten die Kosten und die Dauer analysiert, um anschließend jene des aktuellen Vorhabens abschätzen zu können. Weil sich diese Prognosen auf eigene bereits abgewickelte Bauvorhaben stützen, weisen sie geringere Abweichungen auf als Abschätzungen, die anhand allgemeiner Kennwerte getätigt werden. Ebenso ist es möglich, ein neuronales Netz auf die Zahlungsbereitschaft der verschiedenen Kundinnen und Kunden zu trainieren. Dadurch können zukünftige Mieteinnahmen oder Verkaufserlöse effektiv beurteilt werden.

Die Einteilung potenzieller AN anhand deren Konkursrisiko nach Auftragserteilung bietet in PPH3 eine vielversprechende Möglichkeit, bereits im Vorhinein Firmen ausfindig zu machen, deren Fortbestand über die gesamte Projektdauer womöglich nicht gewährleistet ist. Durch das präventive Erkennen, ob sich ein AN mit der Annahme des Projektes übernehmen würde, wird das Risiko von konkursbedingten Ausfällen während der Bauphase stark reduziert. Diese Störungsreduktion führt in weiterer Folge zu einem harmonischeren Bauablauf.

<sup>40</sup> Vgl.: Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 159

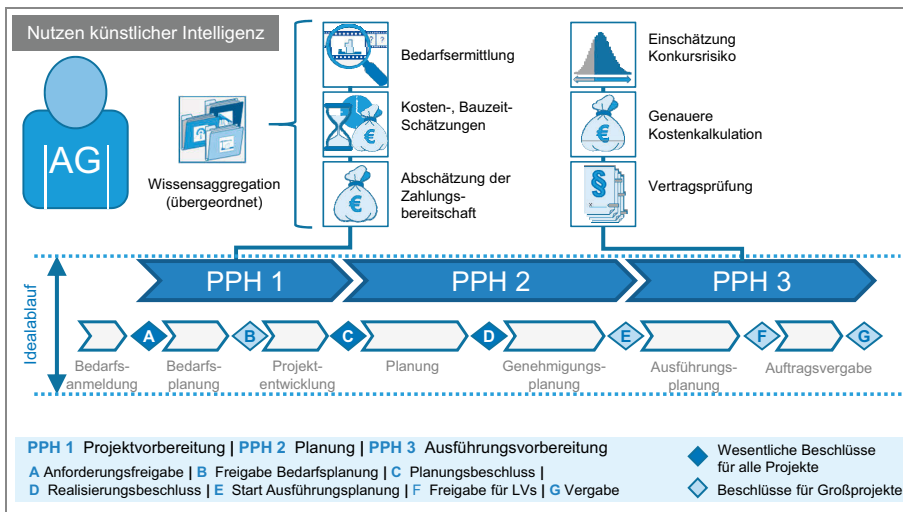


Abb. 3-5 Auftraggeberseitige Anwendungsmöglichkeiten in PPH 1 und PPH 3

Mit fortschreitender Projektdauer wird gleichzeitig der Konkretisierungsgrad des Bauwerks erhöht. Durch immer präzisere Wunschvorstellungen des AG werden somit auch die Kosten besser abschätzbar. Damit zu jedem Zeitpunkt in Abhängigkeit des aktuell vorhandenen Wissens effektive Kostenprognosen durchgeführt werden können, empfiehlt es sich, ein mehrstufiges System aus neuronalen Netzen einzusetzen. Dies bietet den Vorteil, dass – sobald ein neuer Parameter bekannt ist – die Prognose automatisch mit dem nächsten Netz konkretisiert wird.

Die Vertragsprüfung gehört bei der erfolgreichen Abwicklung von Bauprojekten zu einer der wichtigsten Aufgaben. Wird beispielsweise eine Risikoübertragung übersehen, kann diese nach dem Setzen der Unterschrift nicht mehr rückgängig gemacht werden. Daher muss jeder Vertrag bestmöglich kontrolliert und auf das Chancen- und Risikoverhältnis hin überprüft werden. Eine rasche Klassifizierung in risikoreich oder -arm ist von künstlicher Intelligenz durchführbar. Hierbei stellt sich lediglich die Frage, welche Inputparameter ausgewählt werden. Das bedeutet: Machine-Learning-Algorithmen werden in Zukunft komplette Verträge samt Beilagen einlesen und verstehen können. Bis dahin gilt es, sich beispielsweise mit bestimmten Wortfolgen oder der Anzahl einzelner ausgewählter Begriffe als Inputparameter zu begnügen.

In der nachfolgenden Abbildung 3-6 wird auf Einsatzmöglichkeiten in der Ausführung und in der Phase des Projektabschlusses aus Sicht des AG eingegangen. Auch in PPH 4 werden durch effektive Machine-Learning-Prognosen Kosten und Dauern mit geringeren Abweichungen vorhergesagt.

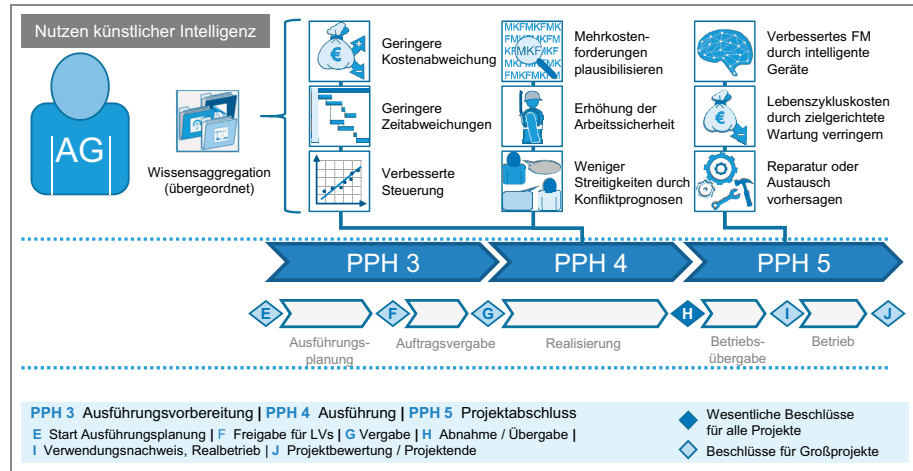


Abb. 3-6 Auftraggeberseitige Anwendungsmöglichkeiten in PPH 4 und PPH 5

Weiters verbessert sich die Steuerungsmöglichkeit von Projekten, da bereits frühzeitig Abweichungen detektiert werden. Bei der kontinuierlichen Überwachung des Baugeschehens mittels neuronaler Netze werden Auffälligkeiten sofort erkannt und davor gewarnt. Die Meldung beinhaltet neben den Auswirkungen auf den geplanten Ablauf auch verschiedene Handlungsempfehlungen, durch die der Schaden möglichst gering gehalten werden würde. Die letztendliche Entscheidung liegt bei der verantwortlichen Person. Die künstliche Intelligenz unterstützt nur bei der Entscheidungsfindung und wird daher den Menschen mit seinen kreativ-konzeptionellen Fähigkeiten nicht ersetzen.

Mehrkostenforderungen (MKF) müssen vom AG akribisch, aber trotzdem mit minimalem Zeiteinsatz kontrolliert werden. Eine rasche und effiziente Hilfe bieten hierbei neuronale Netze. Sind ausreichend bereits beurteilte MKF aus vergangenen Projekten vorhanden, denen die selbe Thematik zu Grunde liegt, können Machine-Learning-Algorithmen trainiert werden. Diese beurteilen in weiterer Folge neue MKF anhand der erlernten Zusammenhänge. Dabei werden Aufwandswerte in kürzester Zeit plausibilisiert und die Kosten verifiziert.

Bereits seit einigen Jahren wird in Amerika künstliche Intelligenz vielversprechend zur Verbrechensbekämpfung eingesetzt.<sup>41</sup> Seither werden diese Algorithmen immer weiter verbessert und führen in deren Einsatzgebieten zu einer Senkung der Kriminalitätsrate. Diese Art der Vorhersage ist auch auf Baustellen anwendbar. Einerseits werden dadurch Materialdiebstähle verringert und andererseits könnten durch Anpassung dieser Technologie potenzielle Arbeitsunfälle vorhergesagt werden. Mögliche Einflussfaktoren, die zur Beurteilung der Unfallgefahr beitragen, sind beispielsweise die tägliche Arbeitszeit, der Kalendertag, die aktuelle Uhrzeit, die Anzahl der Arbeitskräfte, der Baufortschritt oder das Wetter. Künstliche Intelligenz spielt jedoch nicht nur bei der prädiktiven Unfallvermeidung eine wichtige Rolle, sondern unterstützt auch durch Bilderkennung die Bewertung der aktuellen Baustellensicherungsmaßnahmen. Wird eine Holzabspernung vor einem Liftschacht zweckentfremdet, weil ein Arbeiter gerade ein Brett in der vorhan-

<sup>41</sup> Vgl.: <https://www.br.de/kultur/pre-crime-predictive-policing-bayerische-polizei-verbrechen-verhindern-100.html>. Datum des Zugriffs: 18.12.2021

denen Länge braucht, meldet dies der Bilderkennungsalgorithmus sofort. Daraufhin können rasch Maßnahmen zur Wiederherstellung ergriffen werden. Neben der Überprüfung der Baustellensicherungsmaßnahmen ist es ebenso erdenklich, das ordnungsgemäße Tragen der Schutzausrüstung zu überwachen.

Auf dem gleichen Prinzip beruhend unterstützen neuronale Netze bei der Detektion von Unklarheiten und in weiterer Folge bei der Früherkennung von Konfliktpotenzial. Die Minimierung von Streitigkeiten durch zielgerichtete Aufklärung führt somit zu einem besseren Arbeitsverhältnis und einem harmonischeren Bauablauf mit weniger Auseinandersetzungen.

Im Betrieb des Bauwerks wird das Potenzial der künstlichen Intelligenz unter anderem im Facilitymanagement beim Einsatz intelligenter Geräte sichtbar. Die gespeicherten Tätigkeiten der Maschinen können dazu beitragen, die zukünftigen Arbeiten vorherzusagen. Aber auch innerhalb von Bauwerken angebrachte Sensoren ermöglichen in Kombination mit einem BIM-Modell eine zentrale und transparente Datenverfügbarkeit, welche die Voraussetzung für weitere Auswertungen darstellt.<sup>42</sup> Reinigungsfahrten sind somit nicht mehr in einem regelmäßigen Rhythmus erforderlich, sondern werden nur noch durchgeführt, wenn eine Notwendigkeit besteht. Ebenso unterstützt Bilderkennung bei der Dokumentation und Bewertung des Gebäudezustandes. Risse oder andere Problemstellen werden rasch erkannt und in Schadensklassen eingeteilt.

Eine weitere Einsatzmöglichkeit ist die Verringerung von Lebenszykluskosten durch zielgerichtete Wartungen. Die Auswertung von Durchflussmessungen, Verschiebungen oder Stromverbräuchen lässt unter anderem Rückschlüsse auf den Zustand der Geräte, Leitungen, aber auch Bauteile zu. Das frühzeitige Austauschen von Dichtungen oder verlegten Rohren ist somit nicht mehr notwendig. Ebenso sind längerfristige Ausfälle von beispielsweise Heizung oder Warmwasser zu verhindern, da Prognosen diese bereits im Vorhinein erkennen. Kristallisiert sich aus den Sensordaten eine Problemstelle heraus, detektiert die künstliche Intelligenz diese automatisch und schlägt entweder die komplette Erneuerung oder eine Reparatur vor. Diese Beispiele zeigen sehr deutlich, dass somit nicht nur Kosten gespart werden können, sondern auch die Nutzungsqualität gesteigert wird.

Die nachfolgende Grafik 3-7 verdeutlicht im Bereich des Supervised Learning auftragnehmerseitige Anwendungsmöglichkeiten neuronaler Netze in der Ausführungsvorbereitung. Sofort wird daraus ersichtlich, dass solche Prognosen sowie Klassifizierungen für den AN einen deutlichen Mehrwert für die übergeordnete Wissensaggregation darstellen. Es gilt jedoch anzumerken, dass dieser nur erzielt werden kann, wenn eine ausreichende Datengrundlage vorhanden ist. Das heißt, bevor diese Technologie eingesetzt werden kann, muss ein funktionierendes (bestenfalls automatisches) Wissensmanagement im Unternehmen implementiert sein. Ansonsten steht den Machine-Learning-Algorithmen keine ausreichende Datengrundlage für das Erkennen von Zusammenhängen zur Verfügung.

<sup>42</sup> Vgl.: Gralla, M.; Weist, K. C.: Komplexitätsbeherrschung durch Anwendung dynamisch-interdisziplinärer BIM-Modelle – Ein Lösungsansatz für die Fabrikplanung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 641f



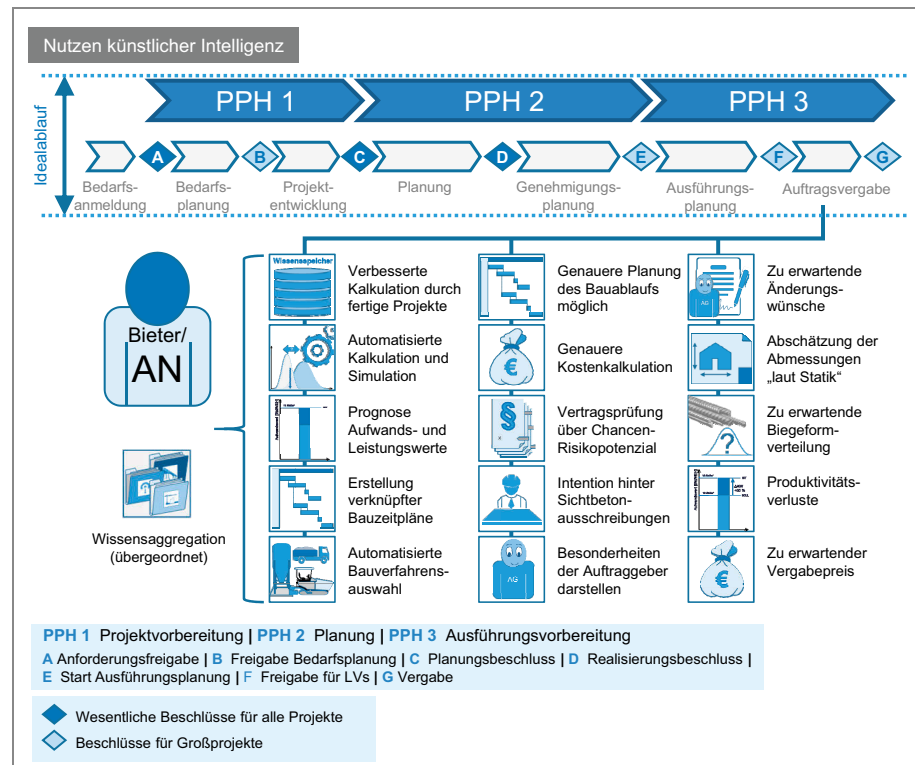


Abb. 3-7 Auftragnehmerseitige Anwendungsmöglichkeiten in PPH 3

Oftmals müssen rund zehn Angebote abgegeben werden, um einen Auftrag zu erhalten. Somit gilt, es die Kosten der neun anderen Bepreisungen auf die erhaltene Baustelle umzulegen. Damit in die Kalkulation nicht zu viel Zeit investiert werden muss, empfiehlt es sich, neuronale Netze zu verwenden. Einerseits erhöht sich die Eintrittswahrscheinlichkeit der Annahmen, andererseits werden Teilleistungen automatisch beurteilt. Im Gegensatz zur Standardkalkulation werden hierbei jedoch die Umstände der Leistungserbringung sowie weitere Einflussfaktoren (z.B.: Baudauer, Jahreszeit oder zur Verfügung stehende Arbeitsgruppen) berücksichtigt. Durch diese multidimensionale Beurteilung des zukünftigen Arbeitsaufwandes werden die Kosten von Leistungen genauer eingeschätzt. In Zukunft wird es möglich sein, Angebote mit Hilfe von Machine-Learning-Algorithmen, die zuvor vergangene Bauprojekte ausgewertet haben, völlig automatisch auszufüllen und daraufhin mit diesen Annahmen den Bauablauf zu simulieren.

Die Erstellung richtiger und präziser Bauzeitpläne benötigt zu erwartende Aufwands- und Leistungswerte. Auch für diese Aufgabenstellung eignen sich neuronale Netze, da sie unter Berücksichtigung bereits abgeschlossener Projekte diese Kennzahlen erlernen und für Prognosen zukünftiger Bauwerke einsetzen können. Selbst die richtige Anordnung der Tätigkeiten ist für die künstliche Intelligenz kein Problem. Abschließend wird in Kombination mit der Menge die Dauer der einzelnen Arbeiten ermittelt. Ändern sich die Art, die Form, die Komplexität, die Qualität oder die Umstände der Leistungserbringung, passt die künstliche Intelligenz den Bauzeitplan automatisch an.

Die Bauverfahrensauswahl gehört zu den wichtigsten Punkten in der Arbeitsvorbereitung und hat einen wesentlichen Einfluss auf den Angebotspreis, weil nur eine effektive und effiziente Kombination der Produktionsfaktoren zum

Zuschlag führt. Aus diesem Grund muss das Produktionssystem genauestens analysiert und bewertet werden. Selbst bei dieser komplexen und vielseitigen Aufgabe stellt die künstliche Intelligenz ein gutes Hilfsmittel dar. Beispielsweise werden Vorschläge über die Auswahl des Bauverfahrens anhand aus der Vergangenheit bereits bewerteter Entscheidungen geliefert. Wie bei jeder den Entscheidungsprozess betreffenden Anwendungsmöglichkeit bildet auch bei diesem Exempel eine einheitliche und nachvollziehbare Dokumentation die Basis, um große Datenmengen zielführend auswerten zu können.<sup>43</sup> Ebenso ist es möglich, durch eine Modellierung des Vorhabens mit anschließender Simulation das beste Verfahren in Hinblick auf die gewünschte Anforderung zu finden. Hierbei werden neben den baustellenrelevanten Faktoren auch innerbetriebliche Überlegungen wie beispielsweise die Verfügbarkeit von bestimmten Geräten berücksichtigt.

Die im Anwendungsbereich des AG bereits besprochene Einsatzmöglichkeit von künstlicher Intelligenz bei der Beurteilung von Bauverträgen gilt natürlich auch für AN. Zusätzlich zur Beurteilung der Chancen und Risiken ist es erdenklich, ein neuronales Netz auf das Erkennen der Intention des AG hin zu trainieren. Anhand der Art und Formulierung der Leistungsbeschreibung ist es beispielsweise möglich, herauszufinden, ob der AG Sichtbeton ausgeschrieben hat, weil ihm dieser wirklich gefällt oder weil er Chancen sieht, bei Nichteinhaltung der Vorgaben Abzüge geltend zu machen.

Verfügt ein Unternehmen über einen Datensatz, welcher Verhalten und Besonderheiten bestimmter AG beinhaltet, kann künstliche Intelligenz zum Finden von Zusammenhängen eingesetzt werden, um in weiterer Folge Handlungsweisen abzuleiten. Die Überlegungen zu dieser Einsatzmöglichkeit werden von der individuellen Analyse der Kund\*innen im Handel abgeleitet. Das dortige Ziel ist es, völlig automatisiert herauszufinden, welche Vorlieben und welchen Geschmack die potenziellen Käufer\*innen haben. Dadurch kann individuell auf deren Bedürfnisse eingegangen werden, was in weiterer Folge zu vermehrten Einkäufen und somit zu einer Umsatzsteigerung führt. Für derartige Prognosen werden jedoch ausreichend Informationen über jede\*n Einzelne\*n benötigt. Aus diesem Grund wird diese Anwendungsmöglichkeit im Bauwesen nur jenen Firmen vorbehalten sein, die bereits zahlreiche Projekte für ein und denselben AG durchgeführt haben. Bei unzureichender Datengrundlage wird der Machine-Learning-Algorithmus keine allgemein zutreffenden Zusammenhänge herausfinden. Für kleinere Unternehmen besteht jedoch Hoffnung, diese Verhaltensvorhersage ebenfalls zu nutzen, wenn sie sich untereinander vernetzen und einen gemeinsamen Datensatz aufbauen. Hierbei ist wichtig, zu erwähnen, dass keine firmenspezifischen Informationen an Kontrahenten weitergegeben werden. Lediglich eine Beschreibung des AG wird gespeichert. Schaffen es kleine Betriebe nicht, sich untereinander zu verknüpfen, werden sie den großen Firmen hinterherhinken und einen Nachteil erleiden. Andere Branchen wie zum Beispiel die Medizin, der Handel oder auch die Automobilindustrie haben bereits gezeigt, dass kontextbezogene Daten das neue Gold darstellen. Dies wird sich speziell in den nächsten Jahren auch im Bauwesen deutlich herauskristallisieren, da jegliche Technologien erhältlich sind, um Daten automatisch zu erheben und auszuwerten.

<sup>43</sup> Vgl.: Lenz, L. T. et al.: Multi-criteria decision support in construction management: life cycleoriented investigation of the economic efficiency. Konferenz: 2021 European Conference on Computing in Construction, 2021. S. 138

Ist ein dementsprechender Datensatz vorhanden, können ebenfalls zu erwartende vom AG veranlasste Änderungswünsche prognostiziert werden. Dadurch wird es möglich, bereits im Vorhinein Überlegungen dazu anzustellen und eventuell im Angebot zu berücksichtigen. Diese Art der Vorhersage mag zwar noch nach Fiktion klingen, wird aber wohl rasch der Realität entsprechen. Im Endeffekt ist sie mit dem Wissen einer erfahrenen Kalkulantin bzw. eines erfahrenen Kalkulanten gleichzusetzen, der/die seine/ihre Auftraggeber hervorragend kennt. Auch diese haben die Fähigkeit, mit Hilfe ihres impliziten Wissens Änderungswünsche oder Konkretisierungen abzuschätzen. Der Vorteil der künstlichen Intelligenz liegt jedoch darin, dass jeder im Unternehmen darauf zugreifen und diese gewinnbringend einsetzen kann. Weiters können in Form von neuronalen Netzen gespeicherte Informationen die Firma beispielsweise durch eine Abwerbung oder einen Pensionsantritt nicht verlassen. Somit wird ermöglicht, neben objektivem auch subjektives Wissen über einen längeren Zeitraum zu behalten.

Das Bewerten von Abmessungen „laut Statik“ stellt ein weiteres Beispiel für den Einsatz von künstlicher Intelligenz dar. Neuronale Netze lernen unter anderem aus der Art des Gebäudes, der Anzahl der Stockwerke, der Spannweite, der Bauweise und der Verwendung, welche Abmessungen typisch für tragende Bauteile (Stützen, Wände, Unterzüge oder Decken) sind. Den Nachweis der Tragfähigkeit durch eine statische Berechnung nach Norm wird die künstliche Intelligenz nicht ersetzen. Sie hilft lediglich dabei, präzise Annahmen zu treffen. Eine weitere Anwendungsmöglichkeit in diesem Kontext stellt die Vorhersage der zu erwartenden Biegeformverteilung der einzelnen Bauteile dar. Der Prozentsatz an geraden sowie einfach oder kompliziert gebogenen Bewehrungsstäben, oder auch der Mattenanteil wird durch Machine-Learning-Algorithmen in Abhängigkeit der Art, Form und Komplexität des Bauwerks sowie der zuständigen Statikerin bzw. des zuständigen Statikers prognostiziert.

Eine weitere Einsatzmöglichkeit, welche ein großes Potenzial für die Zukunft aufweist, ist die Prognose von Aufwands- und Leistungswerten unter Berücksichtigung der Produktionsbedingungen. Hierbei gilt, je mehr produktivitätsbeeinflussende Faktoren wie beispielsweise der vorhandene Arbeitsraum, die Temperatur, oder die Gruppengröße erhoben werden, desto präziser ist das Ergebnis. Die Schwierigkeit liegt jedoch in der Auswahl der passenden Einflussfaktoren und der zugehörigen Datensatzgröße, da mit steigender Inputparameteranzahl auch die benötigten Trainingsfälle positiv korrelieren. Grundsätzlich gilt, dass neuronale Netze ihre Stärke durch die Vielzahl an zu verarbeitenden Inputs zeigen. Jedoch setzt dies eine ausreichende Datenmenge voraus. Bei baubetrieblichen und bauwirtschaftlichen Anwendungsmöglichkeiten steht meistens kein beliebig großer Datensatz zur Verfügung. Aus diesem Grund gilt es, durch das Trainieren verschiedener Netze mit unterschiedlichen Inputparametern das beste neuronale Netz zu finden.

Den Abschluss der exemplarischen Aufzählung von Einsatzmöglichkeiten in der Ausführungsvorbereitung aus Sicht des AN stellt die Prognose des zu erwartenden Vergabepreises dar. Liegen beispielsweise gesammelte Informationen von bereits vergebenen Projekten über das Bauwerk, die vorgegebene Bauzeit, Produktionsbedingungen und den dazugehörigen Vergabepreis vor, kann künstliche Intelligenz diesen Datensatz auswerten und in weiterer Folge Vorhersagen erstellen. Dies führt zu einer besseren

Einschätzung, ob ein Zuschlag für das abgegebene Angebot erfolgen wird oder eher nicht. Weiters kann diese Prognose als Orientierungshilfe dienen, damit bewusst wird, in welchem Preisrahmen das Projekt liegen muss, um unter den verschiedenen Bietern in die engere Auswahl zu gelangen.

Die nachfolgende Abbildung 3-8 verdeutlicht mögliche Beispiele für den Einsatz von künstlicher Intelligenz in der Phase der Bauausführung (PPH4) seitens des AN. Das übergeordnete Ziel der Verwendung von Machine-Learning-Algorithmen ist wiederum das Analysieren vergangener Daten, um firmeninternes Wissen zu aggregieren und daraus zukünftiges Handeln ableiten zu können.

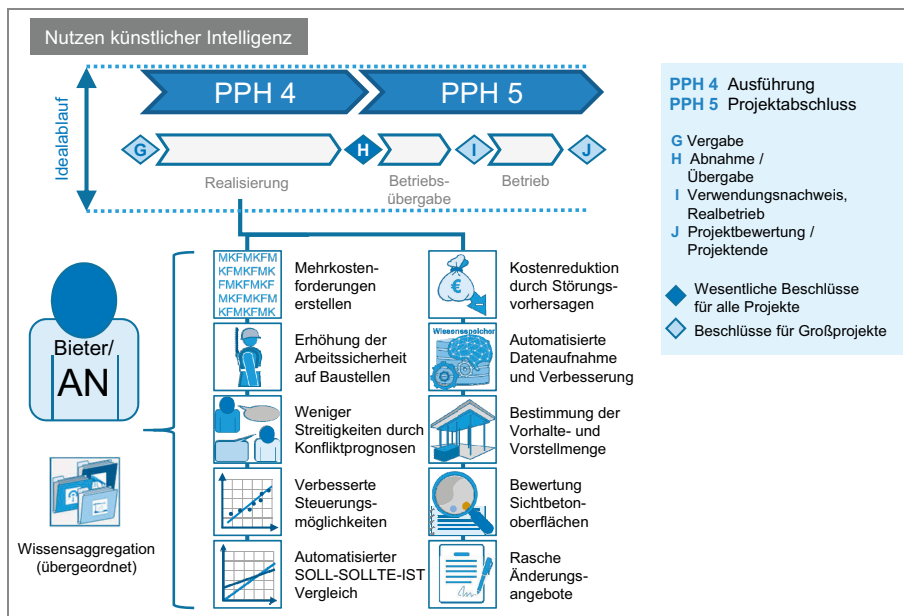


Abb. 3-8 Auftragnehmerseitige Anwendungsmöglichkeiten in PPH 4

In PPH4 eignet sich künstliche Intelligenz unter anderem zum Erkennen von möglichen Mehrkostenforderungen und für das automatisierte Anmelden dem Grunde nach. Aus dem Abgleich des Leistungsverzeichnisses und der aus den Vertragsunterlagen abgeleiteten Produktionsbedingungen mit den aktuellen Leistungen und Mengen auf der Baustelle werden Abweichungen detektiert und aufgezeigt. Zusätzlich werden für die Anmeldung der Höhe nach Lohn und sonstige Kosten bereitgestellt.

Wie auch auf Seiten der Auftraggeber beschrieben, zählt die Erhöhung der Arbeitssicherheit sowie die Reduktion von Konflikten zu wichtigen Aspekten, die mittels Machine-Learning-Algorithmen effektiv und effizient unterstützt werden. Das Vorhersagen von Unfällen, das Aufzeigen von Gefahren- oder Absturzpotenzial sowie das Überprüfen der notwendigen Schutzausrüstung hilft dabei, Baustellen sicherer zu machen und unfallbedingte Krankenstände bis hin zu Todesfällen zu reduzieren. Neben dem Kalendertag, dem Baufortschritt, der Anzahl der Arbeitskräfte und dem Wetter gilt es jedenfalls, auch das Stresslevel durch einen geeigneten Inputparameter abzubilden. Dies kann beispielsweise über Stressklassen oder Vitalwerte der Arbeiter\*innen erfolgen.

Die Steuerungsmöglichkeiten des Baugeschehens profitieren ebenfalls stark von Machine-Learning-Algorithmen. Programme lernen praxisrelevante

Ablaufzusammenhänge und können mit Hilfe dieses Wissens den aktuellen Bauablauf hinsichtlich der Erreichung der normalen Produktivität steuern. Dadurch wird gewährleistet, dass der lineare Bereich der Leistungsbe-  
rechnung nicht verlassen wird und sich die Produktivitätsverluste nicht überdimensional aufschaukeln. Nach Implementierung eines derartigen Systems ist es rasch möglich, auf geänderte Produktionsbedingungen zu reagieren. Die neuen Randbedingungen müssen lediglich dem Algorithmus zur Verfügung gestellt werden und dieser ermittelt durch verschiedene Simulationen, in denen die Erfahrungen der vergangenen Bauprojekte berücksichtigt werden, die optimale Kombination der Produktionsfaktoren.

Bildererkennung bringt ein wesentliches Verbesserungspotenzial für automatische SOLL-SOLLTE-IST-Vergleiche. Diese Algorithmen helfen, Baustellenbilder, die beispielsweise vom Kran aus oder per Drohne gemacht werden, zu analysieren und den aktuellen Stand zu bewerten. Dieser wird in weiterer Folge mit dem im BIM-Modell hinterlegten Bauteilen abgeglichen. Weiters ist zu empfehlen, zusätzlich zur Bildererkennung den Baufortschritt durch eine geeignete Sensorenauswahl zu beurteilen. Hierfür können unter anderem Drucksensoren eingesetzt werden, die automatisch melden, wenn in ihrem Bereich eine Laständerung erfolgt. *Motzko et al.* bringen diese in Kombination mit Ortungstechnologien an einer Palette an, um anhand der übermittelten Positions- und Gewichtsdaten Rückschlüsse auf den Materialfluss sowie den Baufortschritt ziehen zu können.<sup>44</sup> Ebenso ermöglicht das Montieren eines solchen Sensors auf einer Schalungsstütze das Beurteilen des Betonierfortschrittes.

Das Vorhersagen von Störungen bei Geräten auf Basis von Bewegungen und Verbräuchen ist auch auf die Baustelle übertragbar. Werden Parameter, die Bauablaufstörungen auslösen, kontinuierlich erhoben und in einem Datensatz gespeichert sowie bewertet, können Machine-Learning-Algorithmen in Echtzeit beurteilen, welches Problem in naher Zukunft auftreten wird. Dadurch ist es möglich, vorzeitig Maßnahmen zu ergreifen, damit die Eintrittswahrscheinlichkeiten von Erschwernissen wie beispielsweise Krankkapazitätsengpässe, Arbeitsgruppenüberschneidungen oder Lagerplatzschwierigkeiten reduziert werden.

Die optimalen Mengen sind ein wesentlicher Aspekt, um die Baustelle wirtschaftlich abwickeln zu können, da sowohl zu wenig Betriebsmittel oder Materialien als auch zu viele zu höheren Kosten führen. Ein möglicher Weg, die Vorhaltemenge zu bestimmen, führt über die künstliche Intelligenz. Anhand von Erfahrungen aus abgeschlossenen Baustellen, dem aktuell eingesetzten Bauverfahren und der Simulation des geplanten Bauablaufes berechnen Machine-Learning-Algorithmen die benötigte Menge sowie die passende Stückliste. Bei Schalungsarbeiten ist es zusätzlich noch möglich, die Vorstellmenge vorherzusagen. Diese zusätzliche Unterstützung bei Ressourcenplanungen wirkt sich positiv auf die zu erzielende Produktivität aus, weil die Art, Form und Kombination der Produktionsfaktoren bestmöglich aufeinander abgestimmt werden.

Eine weitere Stärke von neuronalen Netzen liegt in den herausragenden Klassifizierungsfähigkeiten. Im Bauwesen ist die Zuteilung in bestimmte Klassen besonders bei Bewertungen von Bauteilen hilfreich. So kann beispielsweise ein Machine-Learning-Algorithmus darauf trainiert werden,

<sup>44</sup> Motzko, C. et al.: Zur Relevanz der Baugestaltung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 90

fertigen Sichtbeton anhand von Bildern und weiteren beeinflussenden Parametern wie dem Porenanteil oder -durchmesser zu beurteilen. An dieser Stelle gilt es jedoch, anzumerken, dass die Herausforderung bei dieser Anwendung in der Erstellung eines ausführlichen Datensatzes liegt. 1000 Trainingsfälle, die aus einem oder mehreren bewerteten Bildern bestehen, reichen hierbei bei weitem nicht aus, um verlässliche Prognosen zu erhalten. Weiters erschweren unterschiedliche Lichtverhältnisse die Modellbildung.

Abgeschlossen wird diese exemplarische Aufzählung der Einsatzmöglichkeiten von künstlicher Intelligenz seitens der AN mit dem raschen Erstellen von Änderungsangeboten. Oftmals tritt die Situation ein, dass im Zuge der Konkretisierung der Projektziele der AG etwas ändern möchte, weil ihm das Vereinbarte nicht mehr zusagt. In diesem Fall bedeutet dies für den AN, während das gesamte Baugeschehen weiterläuft, möglichst rasch ein Änderungsangebot vorzulegen, damit die neu entstehenden Kosten beurteilt und anschließend vom Bauherrn freigegeben werden können. Besonders in dieser arbeitsintensiven Phase ist zu empfehlen, dass sich AN künstlicher Intelligenz bedienen, um effektiv und effizient Änderungswünsche zu bepreisen. Die Algorithmen unterstützen hierbei einerseits bei der Beurteilung des Aufwandes in Abhängigkeit der Produktionsrandbedingungen und andererseits werden automatisch im Sinne von Chatbots Anfragen an Subunternehmer bezüglich der Kosten der durchzuführenden Leistung verschickt. Die bepreisten Antworten werden selbstverständlich automatisch ausgewertet und der Kostenermittlung beigelegt.

Zusammenfassend ist festzuhalten, dass sich künstliche Intelligenz für Prognosen und Klassifizierungen jeglicher Art einsetzen lässt. Hierbei ist jedoch zu beachten, dass genügend Trainingsfälle aus kontextbezogenen Daten und Informationen mit dem dazugehörigen Output erforderlich sind. Ist der Datensatz zu klein, wird der gewünschte Fehlerwert nicht eingehalten und die Vorhersagen sind somit als Entscheidungshilfe wertlos.

### 3.3.2 Neuronale Netze für Produktivitätsprognosen

Die aus den Baustellenbedingungen abgeleitete Produktivität stellt eine wesentliche Kenngröße in der Arbeitsvorbereitung und in der Ausführungsphase dar, weil sie bei arbeitsintensiven Tätigkeiten einen großen Einfluss auf den Aufwandswert und bei geräteintensiven Vorhaben auf den Leistungswert ausübt. Damit die Produktivität vor Baubeginn beurteilt werden kann, müssen das Produktionssystem genauestens analysiert sowie die Einflussparameter identifiziert und ausgewertet werden. Um hierbei den größten Nutzen zu erzielen, gilt es, systematisch und strukturiert vorzugehen. Aus diesem Grund wird die Anwendung des Produktionswürfels nach *Hofstadler*<sup>45</sup> empfohlen. Die nachfolgende Abbildung 3-9 zeigt diesen und verdeutlicht, dass das System der Gesamtproduktivität nicht als zweidimensionales, sondern als dreidimensionales Konstrukt zu sehen ist.<sup>46</sup> Die elementaren und dispositiven Produktionsfaktoren werden hierbei um die Bauzeit, die Qualität und Quantität, die Witterung, das Umfeld, sowie die Art, Form und Komplexität des Bauwerks erweitert.

<sup>45</sup> Hofstadler, C.; Kummer, M.: Risiken und Chancen der Mischpreiskalkulation. In: Tagungsband – 13. Grazer Baubetriebs- und Bauwirtschaftssymposium – Preisermittlung und Vergabe in der Bauwirtschaft – Baubetriebliche, bauwirtschaftliche und rechtliche Aspekte. 2015. Hrsg.: Heck, D.; Mauerhofer, G.; Hofstadler, C. S. 52

<sup>46</sup> Vgl.: Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 2



Abb. 3-9 Produktionswürfel nach Hofstadler<sup>47</sup>

Weiters setzt sich die zu analysierende Gesamtproduktivität aus der Arbeits-, Betriebsmittel- und Materialproduktivität zusammen.<sup>48</sup> Im Zuge der Beurteilung dieser besteht die Möglichkeit, alle drei in einem neuronalen Netz abzubilden oder je ein separates dafür zu trainieren.

Im Folgenden wird auf ausgewählte Einflussfaktoren in Hinblick auf Arbeits-, Betriebsmittel- und Stoffproduktivität eingegangen. Bei der Erstellung eines Datensatzes aus bereits abgeschlossenen Projekten müssen die einzelnen Einflüsse, die durch eine Zahl oder eine Klassenzugehörigkeit charakterisiert sind, mit dem dazugehörigen Output in Verbindung gebracht werden. Hierbei gilt es, zu beachten, dass sowohl harte als auch weiche Faktoren für die Prognose der Gesamtproduktivität herangezogen werden können.

Laut dem Wirtschaftslexikon Gabler lassen sich erstere (hard facts) in betriebswirtschaftliche Kennzahlen (z.B.: Kosten oder Durchlaufzeiten) fassen, wohingegen letztere (soft facts) Stimmungen, Wissen und daraus resultierende Verhaltensweisen beschreiben.<sup>49</sup> Aus dieser Definition wird ersichtlich, dass

<sup>47</sup> Hofstadler, C.; Grundlagen zur Produktivität im Baubetrieb. Vorlesungsfolien von Produktivität im Baubetrieb Wintersemester 2021, Technische Universität Graz, Folie 28

<sup>48</sup> Hofstadler, C.: Produktivität im Baubetrieb. S. 17ff

<sup>49</sup> Gabler Wirtschaftslexikon: <https://wirtschaftslexikon.gabler.de/definition/harte-und-weiche-faktoren-52688>. Datum des Zugriffs: 27.04.2020

sich harte Faktoren als numerische Zahl einer Berechnung oder Messung abbilden lassen. Weiche Einflüsse müssen hingegen zuvor beurteilt werden, bevor künstliche Intelligenz diese auswerten kann. Hierbei ist darauf zu achten, dass die Bewertungen der Umstände möglichst objektiv und immer nach den selben Entscheidungsgrundlagen erfolgen.

Eine Option, um verschiedene subjektive Empfindungen zu verhindern, ist, dass sowohl die Datensatzerstellung als auch die Prognose von ein und derselben Person durchgeführt wird. Somit werden verschiedene Situationen mit der gleichen Beurteilungsbasis bewertet. Für größere Unternehmen stellt dies jedoch keine Lösung dar, weil beispielsweise verschiedene Bauleiter auf das selbe neuronale Netz zugreifen, um Vorhersagen zu erstellen. In dieser Situation muss die Bewertung der qualitativen Inputparameter genauestens dokumentiert und die Beurteilung des Datensatzes von möglichst vielen Mitarbeiter\*innen erfolgen, wodurch die einzelnen subjektiven Einflüsse gering gehalten werden. Hierbei kann beispielsweise auf ein Schulnotensystem zurückgegriffen werden. Weiters empfiehlt es sich, beim Training aus dem kompletten Datensatz ein Netz zu erstellen, welches nur harte Einflussparameter beinhaltet. Dieses bildet eine sehr gute Vergleichsbasis und zeigt die Auswirkungen der soft facts auf das Prognoseergebnis. Dadurch wird auch in weiterer Folge das Verständnis über die einzelnen Inputparameter gefördert, welches die Grundvoraussetzung für eine sachgemäße Anwendung darstellt.

Um einen Überblick über mögliche harte und weiche Einflussfaktoren zu bekommen, werden nachfolgend wesentliche Inputparameter – gegliedert in die drei Produktivitätsbereiche – erläutert. Begonnen wird mit arbeitsproduktivitätsbeeinflussenden Aspekten.<sup>50</sup>

- **Arbeitsraum:**  
Damit sich Arbeitskräfte uneingeschränkt bewegen und die gewohnten Bewegungsabläufe ungehindert durchführen können, wird ein gewisser Arbeitsraum, der in Abhängigkeit der zu verrichtenden Tätigkeit unterschiedliche Größen aufweist, benötigt. Wird der Arbeitsfluss gestört, weil bei horizontalen Bauteilen die Mindestarbeitsfläche und bei vertikalen Elementen die Mindestarbeitslänge je Arbeitskraft nicht eingehalten werden, entstehen Produktivitätsverluste. Die Größe des benötigten Mindestarbeitsraumes hängt von der Tätigkeit, den verwendeten Betriebsmitteln und Materialien ab.
- **Arbeitsgruppengröße:**  
In Abhängigkeit der Bauteilart (Stützen, Wände, Decken, Bodenplatten etc.) lassen sich eine unterschiedliche Anzahl an Arbeitskräften je Arbeitsgruppe unter normalen Produktivitätsbedingungen einsetzen. Wird diese ideale Gruppengröße unter- oder überschritten, entstehen Produktivitätsverluste, weil einzelne Arbeiter über- oder unterfordert werden. Dadurch können die gewohnten Handgriffe nicht mehr durchgeführt und müssen beispielsweise aufgrund fehlender Haltekapazitäten abgeändert werden.
- **Tägliche Arbeitszeit:**  
Übersteigt die tägliche Arbeitszeit eine gewisse Grenze, sinkt die Arbeitsproduktivität aufgrund von Ermüdung, Erschöpfung und einer damit einhergehenden abnehmenden Motivation.

<sup>50</sup> Vgl.: Hofstadler, C.: Produktivität im Baubetrieb. S. 19f



- **Einsatzortwechsel:**  
Ein häufiger Wechsel des Einsatzortes wirkt sich negativ auf die Produktivität aus, weil durch An- und Auslaufverluste sowie zusätzliche Wegzeiten der Aufwand steigt. Durch ein gleichzeitiges Wechseln der Tätigkeit wird dieser Effekt verstärkt.
- **Arbeitsanweisungen:**  
Die Arbeitsanweisungen bauen auf den Bauvertrag samt dessen Bestandteilen (z.B.Pläne, Leistungsbeschreibung oder Produktinformationsblätter) und internen Vorgaben der AN auf. Werden diese Anweisungen zu spät oder auf falschen Informationen basierend bekanntgegeben, entstehen Produktivitätsverluste.
- **Bauweise:**  
Einen wesentlichen Einfluss auf die Arbeitsproduktivität stellt die Bauweise dar, weil sie eine bedeutende Randbedingung für die Art der Materialien und deren Kombination mit Betriebsmitteln ist. Wird beispielsweise auf die Fertigteilbauweise zurückgegriffen, werden auf der Baustelle höhere Produktivitäten erzielt als beim Einsatz von Ortbeton.
- **Qualitative Verfügbarkeit:**  
In Abhängigkeit der Qualifikation und der Motivation sind Arbeitskräfte für mehr oder weniger anspruchsvolle Tätigkeiten einzusetzen. Übersteigt die Komplexität der Aufgabe ständig das Können der Arbeitskraft, führt dies zu Demotivation und in weiterer Folge zu einer abnehmenden Produktivität. Ist die Arbeitskraft oftmals unterfordert, wirkt sich dies ebenfalls negativ aus.
- **Arbeitsgruppenzusammensetzungen:**  
Die soeben angesprochenen Effekte gilt es, auch bei der Arbeitsgruppenzusammenstellung zu beachten. Abhängig von der Komplexität und der Art der Tätigkeit müssen Facharbeiter\*innen, Hilfskräfte und Lehrlinge in einem passenden Team zusammengestellt werden.
- **Fertigungsablauf:**  
Ein systematisch durchdachter und gut strukturierter Fertigungsablauf wirkt sich positiv auf die Arbeitsproduktivität aus, weil dadurch gleiche Tätigkeiten hintereinander auf demselben Arbeitsniveau (im Sinne von gleicher Geschossebene) durchgeführt werden können.
- **Spezifische Bauwerks- und Baustellenbedingungen:**  
Die Tragstruktur, die Form der Bauteile und die Verteilung dieser im Bauwerk üben einen wesentlichen Einfluss auf die zu erzielende Produktivität aus (z.B.: Passflächenanteil). Die Bedingungen auf der Baustelle wie beispielsweise die Topografie des Baufelds, Entfernung des Fertigungsschwerpunktes vom Lagerplatz oder die Platzverhältnisse spielen bei der Beurteilung der Arbeitsproduktivität ebenfalls eine wichtige Rolle.

Spezifische Baustellen- und Bauwerksbedingungen beeinflussen wie bei der Arbeitsproduktivität auch die Betriebsmittelproduktivität. Da diese bereits zuvor beschrieben wurden, wird an dieser Stelle nicht nochmals darauf eingegangen. Zu den wichtigen Einflüssen auf die Betriebsmittelproduktivität zählen:<sup>51</sup>

- **Quantitative Verfügbarkeit:**  
Ist ein benötigtes Betriebsmittel zur Zeit nicht verfügbar, weil es auf einer

<sup>51</sup> Vgl.: Hofstadler, C.: Produktivität im Baubetrieb. S. 20

anderen Baustelle eingesetzt wird oder sich gerade in Reparatur befindet, muss dieses beispielsweise durch einen anderen Bauablauf und/oder den Einsatz eines anderen Verfahrens kompensiert werden. Dadurch entstehen Produktivitätsverluste. Dies gilt besonders für Engpassgeräte. Fehlt im Hochbau dringend benötigte Krankkapazität, müssen Arbeiten eingestellt und verschoben werden, da kein Material zum Einsatzort gebracht werden kann.

- **Arbeitsraum:**  
Wie bei der Arbeitsproduktivität spielt auch im Umgang mit Betriebsmitteln der zur Verfügung stehende Platz eine wesentliche Rolle. Können Geräte nicht problemlos bedient werden, weil der notwendige Arbeitsraum fehlt, steigt der Aufwand.
- **Leistungspotenzial:**  
Die vom Betriebsmittel abhängige Spitzenleistung und erreichbare Normalleistung stehen in enger Verbindung mit der Produktivität. Wird beispielsweise ein zu großer oder zu kleiner Bagger auf der Baustelle eingesetzt, sinkt der Leistungswert.
- **Bedienbarkeit:**  
Die Anwenderfreundlichkeit der Betriebsmittel wirkt sich stark auf die damit erzielbare Leistung aus. Je leichter und intuitiver der Umgang mit diesen erfolgt, desto besser ist die Bedienbarkeit und das erzielte Ergebnis. Beispielsweise ist der Aufwandswert für die Schalarbeiten in den letzten Jahren deutlich gesunken, weil neue Schalsysteme auf den Markt gekommen sind.
- **Qualitative Verfügbarkeit:**  
Die Qualität der Betriebsmittel ist mit der geforderten Ausführungsqualität abzustimmen. Dies kann bedeuten, dass beispielsweise GPS-gesteuerte Erbaugeräte eingesetzt oder bestimmte Schalhautmaterialien ausgesucht werden, um die gewünschte Qualität zu gewährleisten.

Abschließend werden ausgewählte Einflüsse auf die Materialproduktivität beleuchtet.<sup>52</sup>

- **Spezifische Baustellenbedingungen:**  
In Abhängigkeit der Lage und der Klimabedingungen der Baustelle ergeben sich unterschiedliche Witterungseinflüsse. Diese wirken sich in weiterer Folge auf die Lager- und Transportfähigkeit der Materialien aus.
- **Bearbeitbarkeit:**  
Materialien (z.B.: Frischbeton oder Asphalt) besitzen, beeinflusst vom Verwendungszweck und den Umgebungsbedingungen, ein determiniertes Verarbeitungszeitfenster. Außerhalb dieses Zeitraumes sind sie nicht mehr einsetzbar.
- **Nachbearbeitung:**  
Nach dem Einbauprozess benötigen bestimmte Materialien eine Nachbearbeitung. Dies reicht vom Aufbringen eines Verdunstungsschutzes bis hin zur Sicherstellung einer geführten Temperierung. Auch das nachträgliche Schützen vor Verschmutzungen zählt zu diesen Aufgaben.

<sup>52</sup> Vgl.: Hofstadler, C.: Produktivität im Baubetrieb, S. 21f

- **Festigkeitsentwicklung:**  
Die Festigkeitsentwicklung ist ein wichtiger Aspekt bei der Beurteilung der Vorhaltdauer und -menge bei Geräten sowie Materialien für Schalarbeiten. Dadurch wird nicht nur der Bauablauf beeinflusst, sondern auch die Qualität der geleisteten Arbeit.
- **Lagerfähigkeit:**  
Der Platzbedarf sowie die Art der Lagerung resultiert unter anderem aus den verwendeten Materialien und deren Aggregatzustand. Im Freien gelagerte Baustoffe sind leichter zu manipulieren, als jene, die in überdachten oder sogar beheizten Räumlichkeiten situiert sind.
- **Transportfähigkeit:**  
Müssen beim Antransport zum Einbauort Umwege oder spezielle Erschwernisse in Kauf genommen werden, führt dies zu höheren Aufwandswerten und somit zu einer geringeren Produktivität. Bei Hochhausprojekten müssen beispielsweise besondere Maßnahmen ergriffen werden, damit der Beton in die oberen Stockwerke gepumpt werden kann.
- **Verwendete Materialien:**  
In Abhängigkeit der einzelnen Materialien sind verschiedene Produktivitäten zu erzielen. Werden beispielsweise Fertigbauteile auf die Baustelle geliefert und dort nur noch zusammengefügt, können in kürzerer Zeit wesentlich größere Mengen umgesetzt und montiert werden, als bei der Verwendung von Ortbeton.

Abbildung 3-10 fasst die soeben aufgezeigten Aspekte zusammen und liefert somit wesentliche Anhaltspunkte zur Beurteilung der Produktivität. Wird ein neuronales Netz für die Bestimmung des Aufwandswertes oder des Leistungswertes eingesetzt, gilt es, möglichst viele Einflüsse systematisch zu erheben, damit die künstliche Intelligenz deren Zusammenhänge erlernen kann.

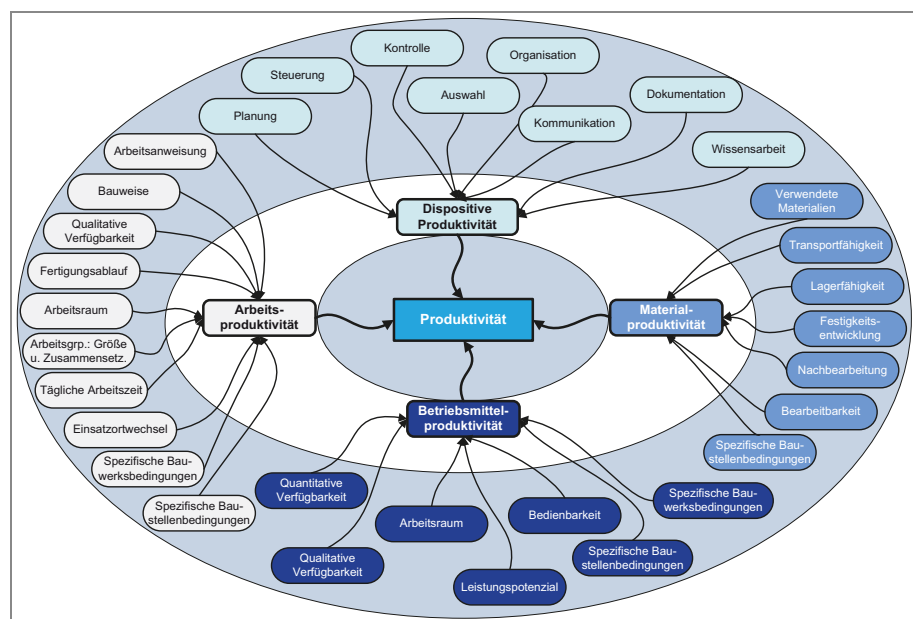


Abb. 3-10 Einflüsse auf die Produktivität – demonstrative Darstellung<sup>53</sup>

<sup>53</sup> Hofstadler, C.: Produktivität im Baubetrieb. S. 18

### 3.3.3 Neuronale Netze im Tunnelbau

Der Tunnelbau ist durch geräteintensive Tätigkeiten geprägt. Dadurch stehen sowohl beim kontinuierlichen als auch zyklischen Vortrieb große Mengen an Maschinendaten zur Verfügung. Diese gilt es, automatisch zu erheben, zu analysieren und zu speichern, damit aus den kontextbezogenen Daten und Informationen zielgerichtete Entscheidungen abgeleitet werden können.

Um das bestmögliche Ergebnis nach der Auswertung des Verfügungswissens zu erhalten, müssen im Vorhinein Überlegungen zu den einzelnen Parametern, die in der Analyse einfließen sollen, angestellt werden. Ansonsten besteht die Gefahr, dass die gesammelten Informationen keinen bedeutenden Einfluss auf die zu vorhersagende Größe ausüben. Das heißt: Wird als Output eine Kostenvorhersage geplant, ist es ratsam, beispielsweise Daten über das Gebirge oder die Art des Vortriebes zu wählen, anstatt jene zu Förderbandgeschwindigkeit.

Eine Möglichkeit, die Datenmengen zu strukturieren, stellt die Einteilung des Verfügungswissens in Prozessdaten, Daten zu Produktionsbedingungen und Bauwerksdaten dar.<sup>54</sup> Ein Prozess ist ein dynamisches System. Aus diesem Grund beschreiben die dazugehörigen Daten die einzelnen Elemente, die Beziehungen dieser und die Randbedingungen des Systems (z.B.: Vortriebswahl oder Gesteinsfestigkeit). Die Produktionsbedingungen verdeutlichen die Umstände bei der Kombination der Produktionsfaktoren und bilden die Produktivität ab (z.B.: Wassereintritt oder Temperatur). Bauwerksdaten (z.B.: Tunnellänge oder -durchmesser) fassen das geplante Vorhaben und dadurch die Vorgaben des Bauherrn zusammen. Diese Vorgehensweise bildet somit einen Rahmen für Parametererhebungen und hilft dabei, dass einzelne Einflussbereiche nicht übersehen werden.

Damit bereits bei geringer Datengrundlage gute Prognosen gemacht werden können, ist es wichtig, die Einflussfaktoren der gewünschten Vorhersage weise auszuwählen und im Vorhinein eine Datenbereinigung durchzuführen. Hierbei gilt es, vor allem die Verteilung der Trainingsdaten genauestens zu analysieren und Ausreißer zu eliminieren, weil nur innerhalb der Trainingsbandbreiten verlässliche Ergebnisse erzielt werden. Sind ausreichend Trainingsfälle vorhanden, ist diese Vorgehensweise nicht unbedingt erforderlich, weil neuronale Netze selbst den Einfluss der einzelnen Parameter auf das Prognoseergebnis erlernen. In der nachfolgenden Abbildung 3-11 sind ausgewählte Einflussfaktoren im Tunnelbau – gegliedert in Prozessdaten, Daten zu Produktionsbedingungen und Bauwerksdaten – sowie konkrete Prognosemöglichkeiten abgebildet.

<sup>54</sup> Vgl.: Hofstadler, C.: Multisystemische Hybridpyramide für den agilen Baubetrieb – System- und Prozessinteraktionen mit der Digitalisierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Molzko, C. S. 8

Verfügungswissen			Orientierungswissen
Prozessdaten	Daten zu Produktionsbedingungen	Bauwerksdaten	Output
<ul style="list-style-type: none"> <li>• Zerlegungsgrad</li> <li>• Trennflächencharakteristika</li> <li>• Störzonen</li> <li>• Abrasivität</li> <li>• Gesteinsart</li> <li>• Gesteinsfestigkeit</li> <li>• E-Modul</li> <li>• Bergwasser- verhältnisse</li> <li>• Umfeld</li> <li>• Stützmitteleinsatz</li> <li>• Zyklischer Vortrieb</li> <li>• Kontinuierlicher Vortrieb</li> <li>• Sicherheitskonzept</li> <li>• TBM-Typ</li> <li>• Vorauserkundungs- bohrungen</li> <li>• Maximale Verschiebung</li> <li>• Materialförderung</li> </ul>	<ul style="list-style-type: none"> <li>• Versorgung TBM</li> <li>• Abtransport des Materials</li> <li>• Wartungsintervalle</li> <li>• Maschinenschäden</li> <li>• Arbeitssicherheit</li> <li>• Arbeitszeit</li> <li>• Schall/Lärm</li> <li>• Feuchtigkeit</li> <li>• Wassereintritt</li> <li>• Lichtverhältnisse</li> <li>• Temperatur</li> <li>• Gruppengröße</li> <li>• Gruppen- zusammensetzung</li> <li>• Gruppenstimmung</li> <li>• Arbeitsanweisung</li> <li>• Einsatzortwechsel</li> <li>• Über- Unterforderung</li> <li>• Über- oder Unterversorgung mit Gerät</li> <li>• Über- oder Unterversorgung mit Material</li> <li>• Druckverhältnisse</li> </ul>	<ul style="list-style-type: none"> <li>• Ausbruchs- durchmesser</li> <li>• Durchmesser Tunnel</li> <li>• Tunnellänge</li> <li>• Überlagerungshöhe</li> <li>• Vortriebsart</li> <li>• Steigender/ fallender Tunnel</li> <li>• Deponierung des Materials</li> <li>• Lichtraumprofil</li> <li>• Anzahl der Zwischenangriffe</li> <li>• Anzahl der Schächte</li> <li>• Anzahl der Röhren</li> <li>• Anzahl/Art der Hohlräume (z.B.: Maschinenkaverne)</li> </ul>	<ul style="list-style-type: none"> <li>• Kostenschätzung</li> <li>• Vortriebsleistung</li> <li>• Ungeplante Stillstände</li> <li>• Baudauer</li> <li>• Aufwandswerte</li> <li>• Leistungswerte</li> <li>• Produktivität</li> <li>• Vorhaltungsmengen</li> <li>• Anzahl der Transport</li> <li>• Technische Gebrechen im Betrieb vorhersagen</li> <li>• Technische Gebrechen Ver- und Entsorgung</li> <li>• Tätigkeitsverteilungen</li> <li>• Bohrzeit</li> <li>• Vortriebs- geschwindigkeit</li> <li>• Wahl der Stützmittel</li> <li>• Gesteinsentwicklung hinter der Ortsbrust</li> </ul>

Abb. 3-11 Mögliche Input- und Outputparameter im Tunnelbau

### 3.3.4 Neuronale Netze bei Stahlbetonarbeiten

In diesem Abschnitt werden mögliche Einflussfaktoren des Gesamtaufwandswerts von Stahlbetonarbeiten – gegliedert in Schalen, Bewehren und Betonieren – beschrieben. Dies soll zeigen, welche Aspekte bei Prognosen zu analysieren sind und wie schnell bei ganzheitlicher Berücksichtigung große Datenmengen zusammenkommen. Bei der Auswertung solcher kontextbezogenen Daten und Informationen wird empfohlen, dass neben einem allumfassenden neuronalen Netz auch für jeden Teilaspekt einzelne Netze trainiert und getestet werden.

In den folgenden Ausführungen werden sowohl hard facts als auch soft facts vorgestellt. Diese müssen individuell für jedes Unternehmen auf die vorhandenen Erhebungsmöglichkeiten abgestimmt werden. Hierbei ist es nicht erforderlich, dass jeder aufgezeigte Aspekt in der Prognose Eingang findet. Werden die Randbedingungen sauber formuliert und klar dargestellt, liefert die künstliche Intelligenz bei ausreichender Datengrundlage bereits mit wenigen, aber dafür markanten Inputparametern ein sehr gutes Ergebnis.

Abbildung 3-12 zeigt ausgewählte Einflüsse auf den Aufwandswert von Schalarbeiten. Im Unterschied zur Gliederung der Einflussfaktoren im Tunnelbau wird in dieser Grafik in generelle Baustellenbedingungen, Einflüsse des Bauverfahrens, spezifische Bauwerksbedingungen und generelle Betriebsbedingungen unterteilt. Dies soll verdeutlichen, dass verschiedene Strukturierungen zum Ziel führen, solange diese systematisch erfolgen. Um von einer Gliederung in die andere umzusortieren, ist zu beachten, dass die Einflüsse des Bauverfahrens sowie Teile der generellen Baustellenbedingungen zu den Prozessdaten zählen, spezifische Bauwerksbedingungen mit Bauwerksdaten gleichzusetzen sind und generelle Betriebsbedingungen sowie Teile der generellen Baustellenbedingungen zu den Daten der Produktionsbedingungen gehören.

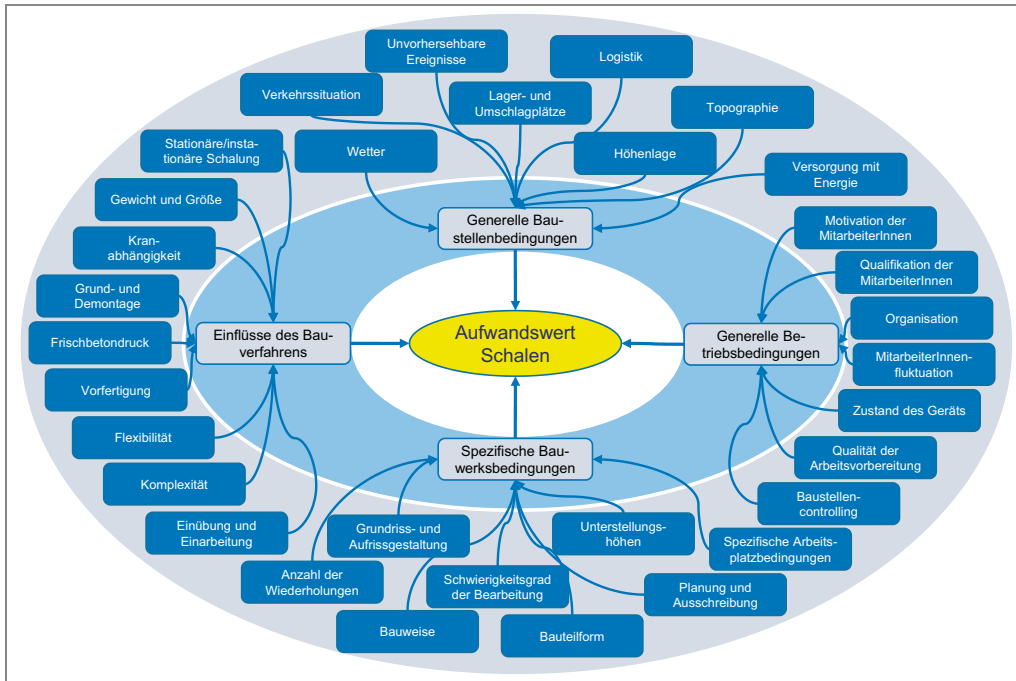


Abb. 3-12 Einflussfaktoren für den Aufwandswert von Schalarbeiten<sup>55</sup>

Weiters wird bei der Analyse der einzelnen Faktoren empfohlen, möglichst viele hard facts in den Datensatz aufzunehmen, weil bei diesen keine subjektive Beurteilung notwendig ist. Das bedeutet, beispielsweise dem Frischbetondruck, dem Vorfertigungsgrad oder der Schalflächenform gegenüber der Qualität der Arbeitsvorbereitung, der Motivation der Mitarbeiter\*innen oder der Qualität der Pläne Vorrang zu geben. Um die überbleibenden qualitativen Einflüsse dennoch mit geringer und bestenfalls konstanter Subjektivität zu beurteilen, ist es ratsam, ein weiteres neuronales Netz für diesen Aspekt zu trainieren. Durch das Ineinandergreifen verschiedener Machine-Learning-Algorithmen wird einerseits die Beurteilung objektiviert und andererseits ein Schritt in die Teilautomatisierung unternommen.

Die nachfolgende Abbildung 3-13 stellt einflussreiche Aspekte bezüglich des Aufwandswerts für Bewehrungsarbeiten dar. Eine Möglichkeit, um die Qualifikation der Mitarbeiter\*innen zu beurteilen, wäre, diese in Eigen- und Fremdpersonal einzuteilen. Dieser Unterschied ist klar und deutlich definiert und kann somit durch keine subjektiven Empfindungen verändert werden.

<sup>55</sup> Hofstadler, C.: Grundlagen zur Projekt- und Baustellenanalyse. In: Vorlesungsfolien, Baubetrieb und Exkursion, Sommersemester 2020, TU Graz. S. 146

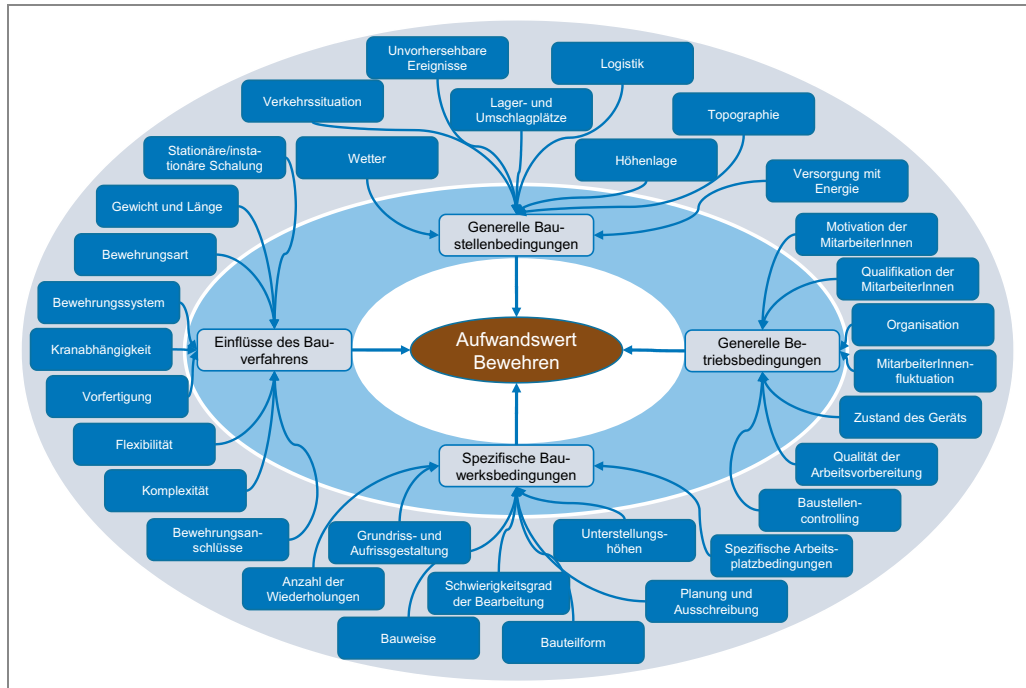


Abb. 3-13 Einflussfaktoren für den Aufwandswert von Bewehrungsarbeiten<sup>56</sup>

Die Analyse, die Synthese und die Beurteilung des Produktionsprozesses Bewehren ist hinsichtlich der geplanten Prognoseziele von enormer Bedeutung. Damit der Prozessablauf bestmöglich mittels neuronaler Netze modelliert werden und somit als fundierte Entscheidungsgrundlage dienen kann, muss die zeitliche, räumliche und quantitative Kombination der Produktionsfaktoren erfasst werden. Das bedeutet, dass bei der Erhebung der Tätigkeitsdauern und in weiterer Folge bei der Berechnung des Aufwandswertes nur Bauteile unterschiedlicher Art, Form und Komplexität in den Datensatz aufgenommen werden dürfen, insofern diese Aspekte auch in den Inputparametern berücksichtigt werden. Ebenso gilt dies für Bewehrungskörbe, die entweder auf der Baustelle oder im Werk gestrickt werden. Wird dieser prozessrelevante Hinweis der künstlichen Intelligenz verschwiegen, ist es für den Algorithmus nicht möglich, herauszufinden, warum augenscheinlich gleiche Stützen (Abmessungen, Biegeformverteilung, Bewehrungsgrad) doch zu unterschiedlichen Aufwandswerten führen.

Neuronale Netze sind kein Zauberwerkzeug. Machine-Learning-Algorithmen ermöglichen zwar das Auswerten vorhandener Daten, können jedoch keine fehlenden Informationen wie beispielsweise den Ort des Bindens erraten. Im Prinzip verlaufen die Grenzen der Machbarkeit ähnlich wie bei einem Menschen, wenn dieser anhand einzelner Aspekte einen Sachverhalt nachstellen soll. Wird hierbei etwas abgefragt, worüber kontextbezogene Daten fehlen, kann keine effektive Prognose erwartet werden. Aus diesem Grund ist es bei der Auswahl der Inputparameter zu empfehlen, sich zu fragen, welche Einflussfaktoren ein Experte benötigen würde. Dadurch wird gewährleistet, dass die ausschlaggebendsten Punkte Berücksichtigung finden.

<sup>56</sup> Hofstadler, C.: Grundlagen zur Projekt- und Baustellenanalyse. In: Vorlesungsfolien, Baubetrieb und Exkursion, Sommersemester 2020, TU Graz. S. 147

Ebenso spielt bei der Extraktion heterogener, produktrelevanter Daten die genaue Abgrenzung der Outputparameter eine bedeutende Rolle. Aus diesem Grund muss bereits beim Erstellen des Datensatzes klar definiert sein, welche Tätigkeiten in den Aufwandswert einfließen und welche unberücksichtigt bleiben. Nach einer Erhebung ist es ohne dafür vorhergesehenen Inputparameter nicht mehr möglich, herauszufinden, welche Aufwandswerte beispielsweise das Reinigen der Schalung berücksichtigen und welche nicht. Werden diese Randbedingungen beim Erfassen der Parameter nicht festgehalten, führt dies zu keiner effektiven Transformation von Verfügungswissen in Orientierungswissen. Dies ist damit zu begründen, dass Machine-Learning-Algorithmen nicht in der Lage sind, auf unterschiedliche Weise erhobene Trainingsfälle zu vereinheitlichen.

Abschließend werden in Abbildung 3-14 mögliche Einflüsse auf die Betonierarbeiten gezeigt. Diese sind wiederum in generelle Baustellenbedingungen, Einflüsse des Bauverfahrens, spezifische Bauwerksbedingungen und generelle Betriebsbedingungen unterteilt, um dieselbe Systematik der vorherigen MindMaps beizubehalten. Die spezifischen Prozessabläufe und damit einhergehenden Einschränkungen gilt es natürlicherweise, auch beim Aufwandswert für das Betonieren zu beachten.

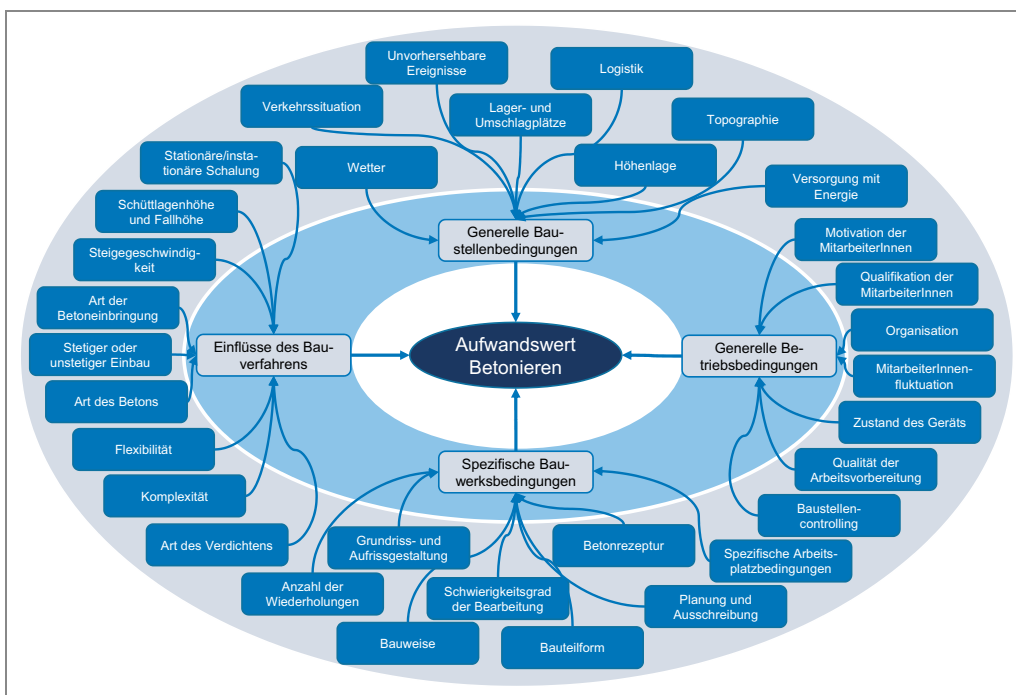


Abb. 3-14 Einflussfaktoren für den Aufwandswert von Betonierarbeiten<sup>57</sup>

<sup>57</sup> Hofstadler, C.: Grundlagen zur Projekt- und Baustellenanalyse. In: Vorlesungsfolien, Baubetrieb und Exkursion, Sommersemester 2020, TU Graz. S. 148



### 3.4 Literaturanalyse Einsatz neuronaler Netze

In folgendem Abschnitt wird ein Überblick über den Einsatz von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft gegeben. Hierbei ist jedoch zu beachten, dass nur Netze aus dem Bereich des überwachten Lernens mit einer Feedforward-Struktur Berücksichtigung finden. Publikationen, welche Klassifizierungen auf Basis von Bildern oder Videomaterial durchführen, zählen nicht zum Untersuchungsgegenstand.

Weiters liegen die Schwerpunkte der Anwendungsmöglichkeiten in den Bereichen Kosten, Dauer und Produktivität. Abschließend werden die einzelnen Veröffentlichungen in einer Tabelle zusammengefasst, wobei die Datensatzgröße, die Anzahl der Trainingsfälle und der Inputparameter, der Datenursprung, die Anzahl des Datenursprungs, die Hidden-Layer sowie die Hidden-Neuronen analysiert werden.

#### 3.4.1 Kostenprognose

*Hong et al.* (2020) analysieren mittels künstlicher Intelligenz Kosten und Nutzen von BIM-Implementierungen in Unternehmen. Die Datengrundlage bietet hierbei eine Umfrage, bei der 401 Personen teilgenommen haben, wobei als Resultat festzuhalten ist, dass die 3D-Visualisierung zu den wesentlichsten Nutzenaspekten zählt. Dies gilt besonders für Neueinsteiger.<sup>58</sup>

*Liu et al.* (2020) setzen Methoden der künstlichen Intelligenz ein, um Kostenprognosen von Schildkonstruktionen im U-Bahn-Bau zu erstellen. Hierbei werden verschiedene Backpropagation-Netze auf einen Datensatz, welcher 50 Baustellen beinhaltet, angewendet.<sup>59</sup>

*Omotayo et al.* (2020) implementieren neuronale Netze, um Methoden der Kostenkontrolle in unterschiedlichen Projektphasen zu bewerten. Hierbei wird auf einen aus einer Umfrage stammenden Datensatz mit 135 Einträgen aufgebaut. Abschließend zeigt das Modell, dass nach Beginn der Ausführungsphase zunächst das Monitoring von Material, Geräten und den Gemeinkosten im Vordergrund steht. Mit zunehmendem Projektfortschritt gewinnen jedoch Gewinn- und Verlustrechnungen oder Cashflowbetrachtungen mehr an Bedeutung.<sup>60</sup>

*Tijanac, Car-Pusic und Sperac* (2020) untersuchen abgeschlossene Projekte im Verkehrswegebau in Hinblick auf die tatsächlich angefallenen Kosten. Hierbei werden verschiedene Netze trainiert, um Kostenprognosen auf Basis der Straßenlänge, -breite, geplanten Baukosten, und -dauer zu erstellen. Das neuronale Regressionsnetz (GRNN) erzieht hierbei mit 13 % den geringsten mittleren absoluten prozentualen Fehler.<sup>61</sup>

<sup>58</sup> Vgl.: Hong, Y.; Hamman, A. W. A.; Akbarnezhad, A.; Arashpour, M.: A neural network approach to predicting the net costs associated with BIM adoption, In: Automation in Construction, 119, 2020, S. 1-16

<sup>59</sup> Vgl.: Liu, L.; Liu, D.; Wu, H.; Wang, X.: The Prediction of Metro Shield Construction Cost Based on a Backpropagation Neural Network Improved by Quantum Particle Swarm Optimization, In: Advances in Civil Engineering, Volume 2020, Article ID 6692130, 2020, S. 1-15

<sup>60</sup> Vgl.: Omotayo, T.; Bankole, A.; Olubunmi Olanipekun, A.: An Artificial Neural Network Approach to Predicting Most Applicable Post-Contract Cost Controlling Techniques in Construction Projects, In: Applied Sciences, 10 (15), 2020, S. 1-24

<sup>61</sup> Vgl.: Tijanic, K.; Car-Pušić, D.; Šperac, M.: Cost estimation in road construction using artificial neural network. In: Neural Computing and Applications, 32, 2020, S. 9343-9355

*Hakami und Hassan (2019)* setzen ebenfalls erfolgreich neuronale Netze ein, um die Kosten von Bauwerken im Yemen zu prognostizieren, wobei ein Datensatz zu 136 Fällen die Basis für die Modellbildung darstellt. Auch diese Autoren heben das schnellere Bepreisen sowie höhere Genauigkeiten als Vorteil hervor, warnen jedoch vor einer zu alten Datengrundlage.<sup>62</sup>

*Juszczuk, Zima und Lelek (2019)* trainieren neuronale Netze für die Kostenprognose von Sportstätten anhand von 115 abgeschlossenen Projekten, wobei das Modell 7 Inputparameter (Spielfeldfläche, Spielflächentyp, Qualitätsanforderungen, Ballnetzfläche, Aufenthaltsflächen, Zaunlänge, Grünfläche) berücksichtigt. Hierbei ist hervorzuheben, dass nicht einzelne neuronale Netze untersucht werden, sondern deren gemeinsames Wirken in Gruppen. In dieser Veröffentlichung zeigen die Autoren, dass die Gruppenbildung bessere Ergebnisse liefert als alleinstehende neuronale Netze. Dies ist auf das Ausgleichen der Einzelfehler im Gruppenverband zurückzuführen.<sup>63</sup>

*Matel et al. (2019)* erstellen ein auf neuronalen Netzen basierendes Modell, welches die zu erwartenden Kosten der Ingenieurleistungen für Auftraggeber prognostiziert. Die Datengrundlage bilden hierbei 132 Projekte. Nach einem mehrstufigen Modellierungsprozess wird deutlich, dass das Netz, bestehend aus 7 Inputparametern, 4 Hidden-Neuronen und einem Output-Neuron, das beste Ergebnis erzielt. Abschließend heben die Autoren noch hervor, dass 12 Testdaten nicht ausreichend sind, um das Modell allumfassend zu validieren. Hierfür müssten noch weitere Daten erhoben und das Prognosemodell in der Praxis eingesetzt werden.<sup>64</sup>

*Chandanshive und Kambekar (2019)* zeigen anhand eines auf 78 Bauprojekten basierenden Modells, dass neuronale Netze bereits in den frühen Projektphasen für Kostenprognosen sehr gut einzusetzen sind. Insgesamt werden hierbei 11 Inputparameter (Fläche Erdgeschoss, Stockwerksfläche, Stockwerke, Parkfläche, Volumen der Aufzugswände, der Außenwände sowie des Außenputzes, Bodenfläche, Anzahl der Stützen, Gründungstyp, Anzahl der Hausbesitzer) berücksichtigt. Das beste Netz weist neben dem Input- und Output-Layer einen Hidden-Layer mit 3 Neuronen auf. Abschließend heben die Autoren hervor, dass neuronale Netze bereits in der Anfangsphase eingesetzt werden können, jedoch das Ergebnis stark von der zur Verfügung stehenden Datengrundlage abhängt. Aus diesem Grund sollten in Zukunft Data-Mining-Ansätze verstärkt gefördert werden.<sup>65</sup>

*Juszczuk und Lesniak (2019)* prognostizieren mittels neuronaler Netze die Baustellengemeinkostenanteile. Hierbei werden nicht nur einzelne Netze, sondern auch Gruppierungen aus fünf der besten untersucht. Die einzelnen Netze werden auf Basis eines 143 Fall großen Datensatzes erstellt und weisen jeweils 11 Input-Neuronen, einen Hidden-Layer sowie ein Output-Neuron auf. Lediglich die Anzahl an Hidden-Neuronen schwankt zwischen 6 und 10. Abschließenden ist deutlich zu erkennen, dass die Gruppierungen weitaus präzisere Ergebnisse liefern als die einzelnen Netze.<sup>66</sup>

<sup>62</sup> Vgl.: Hakami, W.; Hassan, A. : Preliminary Construction Cost Estimate in Yemen by Artificial Neural Network, In: Baltic Journal of Real Estate Economics and Construction Management, 7 (1), 2019, S. 110-122

<sup>63</sup> Vgl.: Juszczuk, M.; Zima, K.; Lelek, W.: Forecasting of sports fields construction costs aided by ensembles of neural networks. In: Journal of Civil Engineering and Management, 25 (7), 2019, S. 715-729

<sup>64</sup> Vgl.: Matel, E.; Vahdatikhaki, F.; Hosseinyalamdary, S.; Evers, S.; Voordijk, H.: An artificial neural network approach for cost estimation of engineering services. In: International Journal of Construction Management, 2019, S. 1-14

<sup>65</sup> Vgl.: Chandanshive, V. B.; Kambekar, A. R.: Estimation of Building Construction Cost Using Artificial Neural Networks. In: Journal of Soft Computing in Civil Engineering, 3, (1), 2019, S. 91-107

*Lesniak und Juszczak* (2018) prognostizieren auf Basis von 143 abgeschlossenen Bauprojekten die Baustellengemeinkosten in Form eines relativen Anteils bezogen auf die direkten Kosten. Im Zuge deren Untersuchung wird in einem zweistufigen Auswahlverfahren die beste Netzkonfiguration gesucht. Abschließend werden fünf neue Projekte dem neuronalen Netz zur Vorhersage übergeben. Bei dieser Überprüfung weisen die Projektprognosen eine Abweichung zwischen 3 und 20 % von den tatsächlich angefallenen Baustellengemeinkosten auf.<sup>67</sup>

*Juszczak, Zima und Lelek* (2018) zeigen anhand des Kostendatensatzes von 115 Sportstätten zunächst, dass sich neuronale Netze für Kostenprognosen sehr gut eignen. Beim Training greift das Modell auf 60 % der Daten, beim Validieren auf 20 % und beim Testen ebenfalls auf 20 % zurück. Anschließend werden daraus die 5 besten Netze ausgewählt und anhand des Kreuzvalidierungsverfahrens ( $k = 10$ )<sup>68</sup> weiter untersucht. Das neuronale Netz, welches 5 Hidden-Neuronen besitzt, erzielt hierbei die stabilsten Ergebnisse. Abschließend weisen sie darauf hin, dass diese Art der Modellbildung in kürzester Zeit Kostenprognosen von unterschiedlichen Varianten ermöglicht und dadurch die Entscheidungsfindung unterstützen kann.<sup>69</sup>

*Gardner, Gransberg und Rueda* (2017) kombinieren das Bootstrapping-Verfahren<sup>70</sup> mit neuronalen Netzen, um Kostenschätzungen bei Autobahnprojekten erstellen zu können. Durch die Analyse und Auswertung der 100 erstellten Teildatensätze wird es möglich, eine Verteilungsfunktion für das Output zu erzeugen. Weiters weisen sie darauf hin, dass dies speziell bei auf kleinen Datensätzen basierenden Prognosen und in frühen Projektphasen einen erheblichen Mehrwert erzielt.<sup>71</sup>

*Hyari, Al-Daraiseh und El-Mashaleh* (2016) setzen ebenfalls neuronale Netze bei Kostenprognosen in der Projektvorbereitung ein. Hierbei prognostizieren sie die Ingenieurdienstleistungen als Prozentsatz der Bauwerkskosten unter Berücksichtigung von Projekt-Typ, Art der Ingenieurdienstleistung, Ort des Bauwerks, Bauwerkskosten und Art des Bauvorhabens. Beim Training wird auf 170 Fälle zurückgegriffen. Bei den 54 Testfällen schneidet das neuronale Netz mit 15 Hidden-Neuronen in einem Layer am besten ab.<sup>72</sup>

*Yadav et al.* (2016) greifen bei der Kostenprognose von Wohnbauten auf neuronale Netze zurück. Die Datenbasis für diese Kostenprognose unter Berücksichtigung der Kostenentwicklung seit 1993 bilden 23 Fälle, die auf Kostenkennwerten aus der Literatur aufbauen. Zu den eingesetzten Inputparametern zählen die Kosten des Zements, des Sandes, des Stahls, der Zuschlagstoffe, der Maurer\*innen und der Facharbeiter\*innen. Abschließend meinen die Autoren, dass solch eine Art der Modellbildung in den frühen Projektphasen sehr gut eingesetzt werden könnte, weil dadurch ein rasches Vergleichen von Varianten ermöglicht wird.<sup>73</sup>

<sup>66</sup> Vgl.: Juszczak, M.; Lesniak, A.: Modelling Construction Site Cost Index Based on Neural Network Ensembles. In: Symmetry, 11(3), 2019. S. 1-18

<sup>67</sup> Vgl.: Lesniak, A.; Juszczak, M.: Prediction of site overhead costs with the use of artificial neural network based model. In: Archives of Civil and Mechanical Engineering, 18 (3), 2018. S. 973-982

<sup>68</sup> Gliederung des Datensatzes in  $k$  Teilmengen, wobei jede einmal zum Validieren eingesetzt wird

<sup>69</sup> Vgl.: Juszczak, M.; Lesniak, A.; Zima, K.: ANN Based Approach for Estimation of Construction Costs of Sports Fields. In: Complexity, 2018, Article ID 7952434. S. 1-11

<sup>70</sup> Sich wiederholende, zufällige Fallzuteilung

<sup>71</sup> Vgl.: Gardner, B. J.; Gransberg, D. D.; Rueda J. A.: Stochastic Conceptual Cost Estimation of Highway Projects to Communicate Uncertainty Using Bootstrap Sampling. In: ASCE - ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering, 3 (3), 2017. S. 1-9

<sup>72</sup> Vgl.: Hyari, A. H.; Al-Daraiseh, A.; El-Mashaleh, M.: Conceptual Cost Estimation Modul for Engineering Services in Public Construction Projects. In: Journal of Management in Engineering, 32 (1), 2016. S. 1-9

*Gunduz und Sahin* (2015) verdeutlichen, dass neuronale Netze bei der Kostenprognose von Wasserkraftwerken nutzbringend eingesetzt werden können. Hierbei stützen sie sich auf 54 Projekte und berücksichtigen 12 Inputparameter. Das beste Ergebnis wird mit einem Netz erzielt, welches in dem Hidden-Layer 9 Neuronen beinhaltet. Auch diese Autoren sehen einen großen Vorteil für die anfänglichen Projektphasen.<sup>74</sup>

*Bala, Bustani und Waziri* (2014) zeigen in deren Publikation einen effizienten Weg, um mittels neuronaler Netze die Bauwerkskosten von institutionellen Projekten in Nigeria zu prognostizieren. Bei der Suche nach Zusammenhängen zwischen Bauwerkshöhe, Kompaktheit, Baudauer, Außenwandfläche, Bruttoraumfläche, Stockwerkanzahl, Mauerwerksöffnungen, Zeitindex und Kosten werden Netze mit einem oder zwei Hidden-Layern herangezogen. Das beste Ergebnis wird mit 7 Neuronen im ersten Hidden-Layer und 5 Neuronen im zweiten erzielt. Abschließend weisen die Autoren darauf hin, dass neuronale Netze eine sehr gute Möglichkeit darstellen, um Nichtlinearitäten abzubilden.<sup>75</sup>

*Elbeltagi et al.* setzen ebenfalls neuronale Netze für die Kostenprognose im Verkehrswegebau ein, wobei 67 Projekte als Datengrundlage dienen. Hierbei werden insgesamt 11 Inputparameter berücksichtigt und die Kosten pro Quadratmeter vorhergesagt.<sup>76</sup>

*Ahiaga-Dagbui und Smith* (2012) verdeutlichen, dass neuronale Netze auch im Wasserbau bei der Kostenprognose eingesetzt werden können. Anhand von 98 verschiedenen Projekten trainieren sie unterschiedliche Netze, wobei schlussendlich das beste 25 Input-Neuronen und einen Hidden-Layer mit 19 Neuronen aufweist. Abschließend weisen sie darauf hin, dass diese Art der Modellbildung ein großes Potenzial besitzt, da durch richtige Auswahl der Inputparameter bereits zu Projektbeginn die Kosten sehr gut prognostiziert werden können.<sup>77</sup>

*Petroutsatou et al.* (2012) ermittelte die Kosten im Tunnelbau mit Hilfe von künstlicher Intelligenz. Der Modellbildung liegen insgesamt 33 Bauwerke mit einer Gesamtlänge von 46 km und 149 Abschnitten zu Grunde, wobei fünf die Geologie beschreibende Parameter als Input herangezogen werden. Anhand dieser wird im ersten Netz auf die Stahl- und Betonmengen geschlossen, welche mittels eines weiteren neuronalen Netzes zu Kosten transformiert werden. Somit werden 10 Inputparameter für die Vorhersage, welche in zwei Phasen gegliedert ist, benötigt.<sup>78</sup>

*Arafa und Alqedra* (2011) prognostizieren die Baukosten in der Anfangsphase eines Projektes mit Hilfe von neuronalen Netzen. Hierbei werden die Fläche des Erdgeschosses, die Stockwerksfläche, die Anzahl der Stockwerke, die Stützenanzahl, die Gründungsart, die Anzahl der Lifte und der Räumlichkeiten als Inputparameter berücksichtigt. Im Zuge der durchgeführten Sensitivitätsanalyse wird festgestellt, dass die Fläche des Erdgeschosses, die Anzahl der

<sup>73</sup> Vgl.: Yadav, R. et al.: Cost Estimation Model (Cem) for Residential Building using Artificial Neural Network. In: International Journal of Engineering Research & Technology (IJERT), 5 (1), 2016. S. 430-432

<sup>74</sup> Vgl.: Gunduz, M.; Sahin, H. B.: An early cost estimation model for hydroelectric power plant projects using neural networks and multiple regression analysis. In: Journal of Civil Engineering and Management, 21 (4), 2015. S. 470-477

<sup>75</sup> Vgl.: Bala, K.; Bustani, S.; Waziri, B.: A computer-based cost prediction model for institutional building projects in Nigeria: An artificial neural networks approach. In: J. of Engineering, Design and Technology, 12 (4), 2014. S. 518-529

<sup>76</sup> Vgl.: Elbeltagi, E.; Hosny, O.; Abdel-Razek, R.; El-Fitury, A.: Conceptual Cost Estimate of Libyan Highway Projects Using Artificial Neural Network. In: International Journal of Engineering Research and Applications, 4 (8), 2014. S. 55-66

<sup>77</sup> Vgl.: Ahiaga-Dagbui, D. D.; Smith, S. D.: Neural networks for modelling the final target cost of water projects. Konferenz: Procs 28th Annual ARCOM Conference, 2012. S. 307-316

<sup>78</sup> Vgl.: Petroutsatou, K. et al.: Early Cost Estimation of Road Tunnel Construction Using Neural Networks. In: Journal of Construction Engineering and Management, 138(6), 2012. S. 679-687

Stockwerke und der Lifte, sowie die Art der Gründung den größten Einfluss auf das Prognoseergebnis ausüben. Abschließend empfehlen die Autoren, weitere Parameter zu erheben und dem Datensatz beizufügen, damit genauere Vorhersagen erstellt werden können.<sup>79</sup>

*El-Sawy, Hosny und Razek (2011)* verdeutlichen anhand eines Prognosebeispiels, dass sich neuronale Netze für Vorhersagen von Baustellengemeinkosten gut einsetzen lassen. Hierfür führen sie zunächst eine Umfrage durch, um die Haupteinflussfaktoren zu identifizieren. Diese werden in weiterer Folge auf Baustellen in Ägypten erhoben. Bei der Auswertung erzielt das neuronale Netz mit 10 Input-Neuronen und einem Hidden-Layer mit 13 Neuronen das beste Ergebnis.<sup>80</sup>

Nicht nur bei der Prognose von Baukosten, sondern auch bei der Vorhersage von Kostenprämien bei LEED-Zertifizierungen werden neuronale Netze eingesetzt. Unter Berücksichtigung der hierbei bewerteten Kategorien trainieren *Tatari und Kucukvar (2010)* verschiedene Netze. Schlussendlich wird mit nur einem Hidden-Layer und 5 Neuronen das beste Ergebnis bei einem Datensatz im Umfang von 74 Fällen erzielt.<sup>81</sup>

*Shehab et al. (2010)* prognostizieren auf Basis von 54 abgeschlossenen Projekten die Sanierungskosten von Frisch- und Abwasserleitungen. Hierbei werden zunächst die Haupteinflussfaktoren mittels Paretoprinzip<sup>82</sup> bestimmt und darauffolgend diverse Netzkonfigurationen trainiert. Insgesamt werden 63 Input-Neuronen berücksichtigt. Abschließend zeigen die Autoren, dass das neuronale Netz deutlich besser abschneidet als das Regressionsmodell.<sup>83</sup>

*Luu und Kim (2009)* heben in ihrer Arbeit hervor, dass künstliche neuronale Netze ein riesiges Potenzial für Kostenschätzungen im Wohnbau besitzen. Dies wird anhand eines Prognosebeispiels gezeigt, wobei 14 abgeschlossene Wohnbauprojekte für das Training und 5 für das Testen herangezogen werden. Die hierbei eingesetzten Inputparameter (Projektrang, Bruttogeschossfläche, Stockwerksanzahl, Baujahr, Benzin-, Stahl- und Zementpreis) stammen aus einer Umfrage, bei der 91 Expert\*innen teilgenommen haben.<sup>84</sup>

*Wilmot und Mei (2005)* stellen ein Modell auf, welches die Baukostenentwicklung im Autobahnbau abbildet. Hierbei werden 5 Submodelle erstellt, innerhalb derer mittels neuronaler Netze die repräsentativen Einheitspreise berechnet werden. Die Datensatzgröße innerhalb dieser variiert zwischen 180 und 1.723, wobei jeweils 85 % für das Trainieren herangezogen werden. Abschließend stellen die Autoren fest, dass neuronale Netze für die Prognose der Kostenentwicklung von Autobahnprojekten ein geeignetes Mittel darstellen und heben hervor, dass das beschriebene Modell nicht zum Vorhersagen individueller Projektkosten geeignet ist, sondern nur die allgemeine Entwicklung der Kosten beschreibt.<sup>85</sup>

<sup>79</sup> Vgl.: Arafa, M.; Alqedra, M.: Early Stage Cost Estimation of Buildings Construction Projects using Artificial Neural Network. In: Journal of Artificial Intelligence, 4 (1), 2011. S. 63-75

<sup>80</sup> Vgl.: El-Sawy, I.; Hosny, H.; Razek, M. A.: A Neural Network Model for Construction Projects Site Overhead Cost Estimating in Egypt. In: International Journal of Computer Science Issues, 8(3), 2011. S. 273-283

<sup>81</sup> Vgl.: Tatari, O.; Kucukvar, M.: Cost premium prediction of certified green buildings: A neural network approach, In: Building and Environment, 46 (5), 2010. S. 1081-1086

<sup>82</sup> 80-20-Regel

<sup>83</sup> Vgl.: Shehab, T. et al.: Cost Estimating Models for Utility Rehabilitation Projects: Neural Networks versus Regression. In: Journal of Pipeline Systems Engineering and Practice, 1 (3), 2010. S. 104-110

<sup>84</sup> Vgl.: Luu, V. T.; Kim, S. Y.: Neural Network Model for Construction Cost Prediction of Apartment Projects in Vietnam. In: Korean Journal of Construction Engineering and Management, 10 (3), 2010. S. 139-147

<sup>85</sup> Vgl.: Wilmot, C. G.; Mei, B.: Neural Network Modeling of Highway Construction Costs. In: Journal of Construction Engineering and Management, 131 (7), 2005. S. 765-771

*Günaydin* und *Dogan* (2004) setzen neuronale Netze ein, um die Kosten von Stahlbeton-Tragwerken im Wohnbau bereits in der Entwurfsphase zu bestimmen. Ihr Modell baut auf 30 abgeschlossenen Projekten auf, wobei 24 zum Trainieren und 6 für das Testen herangezogen werden. Das eingesetzte Netz weist 8 Inputparameter (Gesamtfläche des Bauwerks, Geschossflächenanteil, Erdgeschossflächenanteil, Stockwerksanzahl, Ausrichtung, Gründungsart, Deckentyp, Platzierung des Gebäudekerns), einen Hidden-Layer mit 4 Neuronen und ein Output-Neuron, welches die Kosten pro Quadratmeter wiedergibt, auf. Abschließend halten die Autoren fest, dass neuronale Netze eine Möglichkeit darstellen, um die komplexen Nichtlinearitäten bei der Kostenprognose abzubilden. Weiters merken sie an, dass mit steigender Datenmenge geringere Prognosefehler erzielt werden, weshalb es den vorliegenden Datensatz zu vergrößern gilt.<sup>86</sup>

*Issa* (2000) zeigt auf, dass neuronale Netze bei der Vorhersage von Materialpreisen zielführend eingesetzt werden können und stellt Verbesserungsmöglichkeiten dar. Hierbei hebt er hervor, dass die Anzahl an Trainingsdaten sowie die Auswahl der Inputparameter einen wesentlichen Einfluss auf die Prognosequalität ausüben.<sup>87</sup>

### 3.4.2 Prognose von Kosten und Dauer

*Karatas* und *Al-Sharif* (2020) prognostizieren die anfallenden Kosten und Dauern im Kernkraftwerksbau mittels neuronaler Netze. Hierbei stützen sie sich auch auf Tätigkeiten, die im Zuge der Instandhaltung sowie Instandsetzung anfallen und greifen auf einen Datensatz bestehend aus 2.370 Fällen zurück.<sup>88</sup>

*Alaloul et al.* (2018) nutzen drei neuronale Netze, um auf Basis von 16 Koordinationsfaktoren die Kosten, die Zeit und die Qualität von Bauprojekten beurteilen zu können. Hierfür wird ein Datensatz, welcher eine Größe von 325 Einträgen aufweist, herangezogen und in Trainings-, Validierungs- und Testfälle (70 %, 15 %, 15 %) unterteilt. Das beste Ergebnis wird mit 2 Hidden-Layern zu je 10 Neuronen erzielt.<sup>89</sup>

*Naik* und *Radhika* (2015) analysieren bei zwei Autobahnprojekten die Kosten und die Dauer mit Hilfe neuronaler Netze, wobei mit 10 Neuronen im Hidden-Layer das beste Ergebnis erreicht wird.<sup>90</sup>

*Hola* und *Schabowicz* (2010) zeigen, dass neuronale Netze erfolgreich unter Berücksichtigung der minimalen Dauer oder minimalen Kosten bei der Zusammenstellung der Geräteketten im Erdbau eingesetzt werden können. Hierfür wird zunächst ein Leistungswert prognostiziert, welcher auf Basis einer Erdbau-Datenerhebung erfolgt. Diese umfasst fünf Teildatensätze, welche in die Transportdistanzen 1, 2, 3, 5 und 7 km unterteilt sind und jeweils 200 Fälle aufweisen. Innerhalb eines Teildatensatzes werden 170 Trainingsfälle und 30 Testfälle ausgewählt. Das neuronale Netz selbst berüc-

<sup>86</sup> Vgl.: Günaydin, H. M.; Dogan, S. Z.: A neural network approach for early cost estimation of structural systems of buildings. In: International Journal of Project management, 22 (7), 2004. S. 595-602

<sup>87</sup> Vgl.: Issa, R. R. A.: Application of Artificial Neural Networks to predicting construction material prices. Konferenz: Proceedings of the 8th International Conference on Computing in Civil and Building Engineering, 2000. S.1129-1132

<sup>88</sup> Vgl.: Karatas, A.; Al-Sharif, S.: Schedule and Cost Forecasting Model for Nuclear Power Plant Projects. In: Construction Research Congress 2020, 2020. S. 721-729

<sup>89</sup> Vgl.: Alaloul, W. S. et al.: An Artificial neural networks (ANN) model for evaluating construction project performance based on coordination factors. In: Cogent Engineering, 5 (1), 2018. S. 1-18

<sup>90</sup> Vgl.: Naik, G. M.; Radhika, V. S. B.: Time and Cost Analysis for Highway Road Construction Project Using Artificial Neural Networks. In: KICEM Journal of Construction Engineering and Project Management, 4 (3), 2015. S. 26-31

ksichtigt die Anzahl der Bagger, die Anzahl der LKWs, die Schaufelgröße, die Ladekapazität und die Straßenverhältnisse. Weiters weist es im Hidden-Layer 8 Neuronen auf. Anhand der prognostizierten Leistung werden in weiterer Folge die Kosten und Dauern berechnet. Durch das Auswerten verschiedener Gerätezusammenstellungen kann abschließend die beste Kombination ausgewählt werden.<sup>91</sup>

*Pewdum, Rujiranyong und Sooksatra (2009)* greifen bei der Prognose von Kosten und Baudauer bei Autobahnprojekten ebenfalls auf neuronale Netze zurück. Die zwei Modelle basieren auf 1.022 Fällen, von denen 998 fürs Trainieren und 24 zum Testen herangezogen werden. Die zu erwartenden Kosten (8 Inputparameter, ein Hidden-Layer und 300 Neuronen) weisen einen geringeren Testfehler auf als die Vorhersage der Baudauer (5 Inputparameter, 2 Hidden-Layer und 300 Neuronen). Abschließend vertreten die Autoren die Meinung, dass diese Art der Vorhersage nicht nur bessere Entscheidungsgrundlagen bietet, sondern auch Überbudgetierungen oder Bauzeitverzögerungen reduziert.<sup>92</sup>

### 3.4.3 Prognose der Dauer

*Fan, Yeh und Chi (2021)* setzen ebenso neuronale Netze für die Prognose der Projektdauer ein. Ausgehend von einem Datensatz basierend auf 40 Projekten in Taiwan, welcher sieben Inputparameter beinhaltet, wird zunächst ein allgemeines Netz trainiert. Daraufhin wird dieses einerseits auf Basis einer Sensitivitätsanalyse verfeinert und andererseits in ein zweistufiges Modell (Gründungsdauer und Dauer des Hochbaus) transformiert. Abschließend halten die Autoren fest, dass diese weiterführende Modellbildung nicht nur zu einer Verbesserung der Genauigkeit führt, sondern auch die Black-Box Eigenschaften reduziert.<sup>93</sup>

*Golizadeh et al. (2015)* setzen neuronale Netze für die Vorhersage von Tätigkeitsdauern beim Bewehren und Betonieren von Trägern und Stützen ein. Hierbei werden Länge, Breite, Höhe des Bauteils, sowie Arbeitskräfteanzahl, Arbeitshöhe, Arbeitserfahrung, tägliche Arbeitszeit und Länge der Projektinvolvierung bei beiden Tätigkeiten berücksichtigt. Beim Bewehren greift das Modell zusätzlich noch auf die Anzahl der durchgängigen Bewehrung und der täglichen Niederschlagsmenge zurück. Beim Betonieren kommt bei den Inputparametern lediglich die Beschaffung hinzu. Die Datengrundlage stützt sich auf 4 durchgeführte Projekte, von denen 156 Träger und 100 Stützen für das Bewehren und 146 Träger und 87 Stützen für das Betonieren herangezogen werden. Dabei erzielen die Autoren mit 10 Hidden-Neuronen das beste Ergebnis und weisen abschließend darauf hin, dass künstliche Intelligenz den Entscheidungsprozess positiv beeinflusst.<sup>94</sup>

*Najafi und Kong (2016)* prognostizieren mittels neuronaler Netze die Installationszeit von Fertigteilen bei Wänden, Trägern, Stützen und Decken. Die Untersuchung basiert auf 220 Fällen, welche auf 4 verschiedenen mehrstöckigen Wohnbau- und Schulprojekten erhoben wurden. In Anbetracht der

<sup>91</sup> Vgl.: Holo, B.; Schabowicz, K.: Estimation of earthworks execution time cost by means of artificial neural networks. In: Automation in Construction, 19 (5), 2010. S. 570-579

<sup>92</sup> Vgl.: Pewdum, W.; Rujiranyong, T.; Sooksatra, V.: Forecasting final budget and duration of highway construction projects. In: Engineering, Construction and Architectural Management, 16(6), 2009. S. 544-557

<sup>93</sup> Vgl.: Fan, S.-L.; Yeh, I.-C.; Chi, W.-S.: Improvement in Estimating Durations for Building Projects Using Artificial Neural Network and Sensitivity Analysis. In: Journal of Construction Engineering and Management, 147 (7), 2021. S. 1-9

<sup>94</sup> Vgl.: Golizadeh, H. et al.: Automated tool for predicting duration of construction activities in tropical countries. In: KSCE Journal of Civil Engineering, 20 (1), 2016. S. 12-22

Tatsache, dass mehrere kleine Netze effizienter arbeiten als ein großes, wird das Aufstellen von Fertigteilen in drei Teilprozesse (Vorbereitung, Heben, Aufstellen) gegliedert. Diese werden einzeln prognostiziert und abschließend aufsummiert. Die drei Netze weisen folgende Strukturen auf: 4-6-1, 8-12-4-1, 5-9-1 (die erste Zahl stellt die Input-Neuronen dar, dazwischen liegen die Hidden-Neuronen, die letzte das Output-Neuron). Die Autoren erreichen anhand des zugrunde liegenden Datensatzes einen mittleren absoluten prozentualen Fehler von 13 % und heben hervor, dass in Zukunft noch weitere Daten gesammelt werden sollten, damit auch Dauern für Stiegen oder Balkone prognostiziert werden können.<sup>95</sup>

*Mensah, Adjei-Kumi und Nani (2016)* nutzen neuronale Netze für die Prognose der Baudauer von Landstraßen. Hierbei untersuchen sie 22 abgeschlossene Projekte und wählen anhand der vorliegenden Leistungsverzeichnisse drei Haupteinflussfaktoren aus. Zu diesen zählen: Die Grundstücksräumung, die benötigte Bewehrungsmenge und die Straßenmarkierungen. Von den zur Verfügung stehenden Baustellen werden 60% für das Trainieren, 20 % zum Validieren und 20 % zum Testen herangezogen. Abschließend heben die Autoren hervor, dass deren Methode, die Dauern zu berechnen, als passend anzusehen ist, jedoch ein größerer Datensatz zielführender wäre. Das beste Netz weist folgende Strukturierung auf: 3-38-1. Vor allem zu Beginn eines neuen Projektes kann durch diese Modellbildung unter Berücksichtigung der drei Parameter sehr rasch die Dauer abgeschätzt werden.<sup>96</sup>

*Petruseva, Zujo und Zileska-Pancovska (2013)* versuchen, anhand der anfallenden Kosten auf die Baudauer zu schließen. Die Modellbildung basiert auf 75 abgeschlossenen Projekten, welche durch Umfragen erhoben wurden. Hierbei ist zu erkennen, dass das neuronale Netz mit 7 Neuronen im Hidden-Layer deutlich bessere Prognosen abgibt, als die lineare Regression.<sup>97</sup>

*Dikmen und Sonmez (2011)* setzen neuronale Netze ein, um ein Modell zu erstellen, welches die Gesamt-Lohnstunden der Schalarbeiten eines Stockwerks prognostiziert. Hierbei stehen 613 Fälle zur Verfügung, wobei 551 für das Trainieren herangezogen werden. Das Netz selbst besteht aus 7 Inputparametern (Deckenfläche, Länge der Träger, Länge der Stützen, Wandfläche, Geschosshöhe, Höhenlage und gesamte Stockwerksanzahl), einem Hidden-Layer mit 5 Neuronen sowie einem Output-Neuron. Neben den Testdaten überprüfen die Autoren die trainierte künstliche Intelligenz anhand von zwei weiteren Anwendungsfällen und zeigen hierbei auf, dass sehr gute Ergebnisse erzielt werden. Abschließend weisen sie darauf hin, dass dieses Modell eine einfache und gute Möglichkeit darstellt, um die Annahmen eines Kalkulanten bzw. einer Kalkulantin zu validieren.<sup>98</sup>

*Leung, Tam und Liu (2001)* untersuchen die Hebezeiten von Kranen auf Basis von 7 verschiedenen Bauprojekten. Insgesamt beinhaltet der Datensatz 1.243 Fälle fürs Trainieren. Das Modell berücksichtigt 17 Inputparameter und besitzt in einem Hidden-Layer 42 Neuronen. Abschließend halten die Autoren fest, dass die Hebehöhe den größten Einfluss ausübt. Gefolgt wird diese von dem zu hebenden Gewicht und der Anzahl der gleichzeitigen Bewegungen.<sup>99</sup>

<sup>95</sup> Vgl.: Najafi, A.; Kong, R. T. L.: Productivity analysis of precast concrete operations by artificial neural networks. In: ARPN Journal of Engineering and Applied Sciences, 11 (17), 2016. S. 10512-10521

<sup>96</sup> Vgl.: Mensah, I.; Adjei-Kumi, T.; Nani, G.: Duration determination for rural roads using the principal component analysis and artificial neural network. In: Engineering, Construction and Architectural Management, 23, (5), 2016. S. 638-656

<sup>97</sup> Vgl.: Petruseva, S.; Zujo, V.; Zileska-Pancovska, V.: Neural Network Prediction Model for Construction Project Duration. In: International Journal of Engineering Research and Technology, 2 (11), 2013. S. 1646-1654

<sup>98</sup> Vgl.: Dikmen, S. U.; Sonmez, M.: An artificial neural networks model for the estimation of formwork labour. In: Journal of engineering and management, 17 (3), 2011. S. 340-347



*Bhokha* und *Ogunlana* (1999) prognostizieren die benötigte Baudauer mit Hilfe neuronaler Netze. Für die Modellbildung stehen 136 Fälle zur Verfügung, wobei die Hälfte fürs Trainieren und die andere Hälfte fürs Testen eingesetzt wird. Weiters werden 8 Inputparameter mittels 11 Input-Neuronen berücksichtigt. Abschließend weisen die Autoren darauf hin, dass sich neuronale Netze gut für derartige Prognosen eignen, weil diese bereits mit Basisinformationen, welche in der Entwurfsphase vorhanden sind, auskommen.<sup>100</sup>

#### 3.4.4 Produktivitätsprognose

*Kassem et al.* (2021) prognostizieren mittels neuronaler Netze die Leistung von Baggern. Hierbei bilden vor allem automatisch ausgelesene Maschinendaten wie beispielsweise der Kraftstoffverbrauch oder die Motorlaufzeit die Basis des Prognosemodells, welches anhand von 700 Fällen mit 12 Inputparametern erstellt wird. Das beste Ergebnis erzielt jenes neuronale Netz, welches im ersten Hidden-Layer 50 Neuronen und im zweiten 25 aufweist. Ein zukünftiges Verbesserungspotenzial sehen die Autoren bei der Integration der einzelnen Datenströme, um Inkonsistenzen zu vermeiden.<sup>101</sup>

*Ebrahimi, Raoufi* und *Fayek* (2020) setzen ebenfalls ein neuronales Netz ein, um Prognosen bezüglich der Produktivität zu erstellen. Das Besondere ist hierbei jedoch, dass die Auswahl der Inputparameter auf Basis eines genetischen Algorithmus geschieht. Für die Modellerstellung selbst stehen 92 Fälle zur Verfügung, bei denen 20 verschiedene Inputparameter berücksichtigt werden können. Das beste Ergebnis wird unter Verwendung der Arbeitsgruppengröße, der Ausbildung, der Kooperation der Arbeitskräfte untereinander, der Motivation, der Ermüdung, der Art der Arbeitsaufträge und des Teilens von Werkzeug erzielt. Diese aus den 20 möglichen Einflüssen ausgewählten Inputparameter werden in nur einem Hidden-Layer mit 6 Neuronen verarbeitet, wobei beim Training 70 %, beim Validieren 15 % und beim Testen ebenfalls 15 % eingesetzt werden.<sup>102</sup>

*Golnaraghi et al.* (2019) untersuchen diverse neuronale Netze, um die Produktivität bei Schalarbeiten vorherzusagen, und kommen dabei zu dem Schluss, dass beim Einsatz von Backpropagation die besten Ergebnisse geliefert werden. Die der Untersuchung zugrundeliegenden Daten (221) stammen aus zwei Hochhausprojekten und beinhalten neben dem gewünschten Output zusätzlich noch Parameter wie Temperatur, Luftfeuchtigkeit, Niederschlag, Windgeschwindigkeit, Gruppengröße, Gruppenzusammensetzung, Bauteiltyp, Schalungsart sowie das Stockwerk. Weiters wird bei der Auswertung ersichtlich, dass die Temperatur den größten Einfluss auf die Produktivität ausübt. Abschließend halten die Autoren fest, dass die mittels Backpropagation trainierten Netze im Vergleich zu den bekannten statistischen Methoden wie beispielsweise der Regression erfolgreicher abschneiden.<sup>103</sup>

<sup>99</sup> Vgl.: Leung, A. W. T.; Tam, C. M.; Liu, D. K.: Comparative study of artificial neural networks and multiple regression analysis for predicting hoisting times of tower cranes. In: Building and Environment, 36 (4), 2001. S. 457-467

<sup>100</sup> Vgl.: Bhokha, S.; Ogunlana, S. O.: Application of artificial neural network to forecast construction duration of buildings at the pre-design stage. In: Engineering, Construction and Architectural Management, 6 (2), 1999. S. 133-144

<sup>101</sup> Vgl.: Kassem, M.; Mahamedi, E.; Rogage, K.; Duffy, K.; Huntingdon, J.: Measuring and benchmarking the productivity of excavators in infrastructure projects: A deep neural network approach. In: Automation in Construction 124, 2021. S. 1-15.

<sup>102</sup> Vgl.: Ebrahimi, S.; Raoufi, M.; Fayek, A. R.: Framework for Integrating an Artificial Neural Network and a Genetic Algorithm to Develop a Predictive Model for Construction Labor Productivity. In: Construction Research Congress 2020, 2020. S. 58-66

<sup>103</sup> Vgl.: Golnaraghi, S. et al.: Application of Artificial Neural Network(s) in Predicting Formwork Labor Productivity, In: Advanced in Civil Engineering, Article ID 5972620, 2019. S. 1-11

*Haddad* (2017) prognostiziert mittels neuronaler Netze die Leistung [ $m^3/d$ ] bei der Fundamentherstellung unter Berücksichtigung produktivitätsbeeinflussender Faktoren. Insgesamt fließen 16 Inputparameter in die Modellbildung ein. Für das Training werden 83 Fälle herangezogen, welche anhand von 15 weiteren validiert werden. Die Bewertung findet mit 13 für das neuronale Netz unbekanntem Testfällen statt. Unter Einsatz dieser 111 Fälle wird das beste Ergebnis mit der Netzstruktur 16-22-1 erzielt. Die abschließende Sensitivitätsanalyse ergibt, dass das Fundamentvolumen den größten Einfluss ausübt.<sup>104</sup>

*El-Kohly* (2016) zeigt, dass neuronale Netze für die Bestimmung des Produktivitätsindex besser abschneiden als die Regressionsanalyse. Hierbei ist anzumerken, dass der aus einer Umfrage stammende Datensatz nur 25 Fälle beinhaltet, wobei 10 zum Trainieren, 5 zum Validieren und 10 zum Testen herangezogen werden. Insgesamt werden 12 Inputparameter berücksichtigt, wobei unter Verwendung von 16 Hidden-Neuronen in einem Layer die besten Resultate erzielt werden.<sup>105</sup>

*Kareem* (2016) prognostiziert mittels künstlicher Intelligenz die zu erwartende Produktivität bei Mauerwerksarbeiten. Das Modell berücksichtigt 13 Inputparameter und stützt sich auf 32 Bauprojekte, bei denen 118 verschiedene Fälle erhoben wurden. Das beste Ergebnis wird bei einem Hidden-Layer und 3 Hidden-Neuronen erzielt. Seine Ergebnisse zeigen, dass neuronale Netze erfolgreich für derartige Produktivitätsprognosen eingesetzt werden können. Weiters kommt der Autor zum Entschluss, dass die Mauerdicke die größten Auswirkungen nach sich zieht. Ebenso weisen die Zahlungsart und der Mörteltyp einen hohen Einfluss auf.<sup>106</sup>

*Heravi und Eslamdoost* (2015) prognostizieren mit Hilfe von neuronalen Netzen die Produktivität bei Betonfundamenten von Kraftwerken. Deren Modell baut auf 39 abgeschlossenen Projekten auf, welche im Zuge von Umfragen erhoben wurden, und berücksichtigt 15 Inputparameter. Das beste Ergebnis wird bei einem Netz mit 2 Hidden-Layern zu je 12 Neuronen erzielt. Bei der abschließenden Sensitivitätsanalyse wird festgestellt, dass Fachkenntnisse, falsche Entscheidungen, die Motivation der Arbeitskräfte, Baustellenbedingungen und eine baubare Terminplanung zu den wichtigsten Einflussfaktoren zählen.<sup>107</sup>

*AL-Zwainy et al.* setzen neuronale Netze zur Produktivitätsprognose bei Marmor-Verlegearbeiten ein. Die verwendete Datengrundlage stützt sich auf 10 Bauprojekte, bei denen jeweils mittels Stoppuhr 15 Beobachtungen erhoben wurden. Folglich weist der Datensatz eine Größe 150 Fällen auf, wobei 60 % für das Trainieren 25 % für das Validieren und 15 % für das Testen eingesetzt werden. Zu den Inputparametern zählen Alter, Erfahrung, Anzahl an Hilfskräften, Stockwerkhöhe, Fläche der Marmorsteine, Sicherheitsbedingungen, gesundheitlicher Zustand, Wetter, Baustellenbedingungen und Verfügbarkeit von Material. Abschließend heben die Autoren hervor, dass deren Modell eine Prognosegenauigkeit von fast 91 % aufweist, wobei das Alter, die Erfahrung sowie die Anzahl an Hilfskräften den größten Einfluss auf

<sup>104</sup> Vgl.: Haddad, E.: Construction Productivity Estimation Model Using Artificial Neural Network for Foundations Work in Gaya Strip Construction Sites. In: International Journal of Advanced Engineering Research and Science, 4 (7), 2017. S. 50-62

<sup>105</sup> Vgl.: El-Kholy, A. M.: Towards The Development of an Index to Measure the Performance of Multi-Productivity Areas. In: International Journal of Engineering Research And Application, 6 (7), 2016. S. 1-14

<sup>106</sup> Vgl.: Kareem, G.: Productivity estimation model for bricklayer in construction projects using Neural Network. In: Al-Qadisiyah Journal for Engineering Sciences, 9 (2), 2016. S. 183-199

<sup>107</sup> Vgl.: Heravi, G.; Eslamdoost, E.: Applying Artificial Neural Networks for Measuring and Predicting Construction-Labor Productivity. In: Journal of Construction Engineering and Management, 141 (10), 2015. S. 1-11

die Produktivität ausüben. Weiters unterstreichen sie, dass neuronale Netze sehr gut für das Abbilden von Nichtlinearitäten geeignet sind.<sup>108</sup>

*Muqueem et al.* (2011) nutzen neuronale Netze, um Produktivitätsprognosen bei Betonierarbeiten von Trägern durchzuführen. Hierfür werden auf 7 Baustellen insgesamt 84 Fälle aufgezeichnet und in einem Datensatz aufbereitet. Das trainierte Netz berücksichtigt die Wetterbedingungen, die Verfügbarkeit von Material und Geräten, den Projektort, Baustellenbedingungen und die Anzahl der Arbeitskräfte. Weiters besteht es aus einem Hidden-Layer mit 25 Neuronen. Abschließend wird aufgezeigt, dass neuronale Netze ein verlässliches Werkzeug für Produktivitätsprognosen darstellen und bei der vorliegenden Aufgabenstellung die Material- und Geräteverfügbarkeit sowie die Anzahl der Arbeitskräfte den größten Einfluss aufweisen.<sup>109</sup>

Weiters veröffentlichten *Muqueem et al.* (2011) ein neuronales Netz, welches die zu erwartende Produktivität beim Betonieren von Stützen vorhersagt. Bei dieser Aufgabenstellung stammen die Trainingsfälle aus 5 Projekten mit je 12 Erhebungen und die Testfälle aus 2 Projekten mit je 12 Messungen. Bei der Auswertung des Datensatzes wird ein Hidden-Layer mit 3 Neuronen eingesetzt. Wie in der vorherigen Veröffentlichung werden Wetterbedingungen, Verfügbarkeit von Material und Geräten, Projektort, Baustellenbedingungen und Anzahl der Arbeitskräfte als Inputparameter gewählt. Das Ergebnis der Arbeit zeigt, dass neuronale Netze sehr gut für solche Prognosen eingesetzt werden können. Das vorgestellte Netz weist eine mittlere prozentuelle Abweichung von 7,8 % beim Trainieren und 12,3 % beim Testen auf.<sup>110</sup>

*Muqueem et al.* (2011) zeigen ebenso, dass auch Produktivitätsprognosen bei Schalarbeiten mittels neuronaler Netze durchgeführt werden können. Die Datenbasis bildet wieder Datensatz, der 84 Fälle beinhaltet. Jedoch handelt diese Veröffentlichung von sieben Hochhausprojekten, bei denen die Inputparameter anhand einer Umfrage ausgewählt wurden. Weiters wird bei dem Modellerstellungsvorgang das Kreuzvalidierungsverfahren mit  $k = 10$  eingesetzt. Abschließend halten die Autoren fest, dass mit den gewählten Inputparametern (Wetterbedingungen, Verfügbarkeit von Material und Geräten, Projektort, Baustellenbedingungen und Anzahl der Arbeitskräfte) verlässliche Ergebnisse erzielt werden.<sup>111</sup>

*Mohammed und Tofan* (2011) greifen bei der Produktivitätsprognose von Keramikarbeiten auf neuronale Netze zurück. Der zugrunde liegende Datensatz weist 100 Fälle auf, wobei 60 zum Trainieren, 30 zum Validieren und 10 zum Testen herangezogen werden. Zu den Inputparametern zählen Erfahrung, Gruppengröße, Anzahl der Hilfsarbeiter, Fläche der Keramikfliesen, Baustellenbedingungen, Stockwerk und das Wetter. Abschließend halten die Autoren fest, dass neuronale Netze sehr gut geeignet sind, um komplexe Zusammenhänge zwischen den vorzufindenden Umständen und der Produktivität zu beschreiben. Weiters merken sie an, dass das Stockwerk, in dem die Arbeiten durchzuführen sind, mit 28 % den größten Einfluss auf die Produktivität ausübt.<sup>112</sup>

<sup>108</sup> Vgl.: AL-Zwainy, F. M. S.; Rasheed, H. A.; Ibraheem, H. F.: Development of the construction productivity estimation model using artificial neural network for finishing works for floors with marble. In: ARPN Journal of Engineering and Applied Sciences, 7 (6), 2012. S. 714-722

<sup>109</sup> Vgl.: Muqueem, S. et al.: Development of Construction Labor Productivity Estimation Model using Artificial Neural Network. Konferenz: 2011 National Postgraduate Conference, 2011. S. 1-6

<sup>110</sup> Vgl.: Muqueem, S. et al.: Prediction Modeling of Construction Labor Production Rates using Artificial Neural Network. Konferenz: 2011 2nd International Conference on Environmental Science and Technology, 2011. S. 32-26

<sup>111</sup> Vgl.: Muqueem, S. et al.: Construction Labor Production Rates Modeling using Artificial Neural Network. In: Journal of Information Technology in Construction, 16, 2011. S. 713-726

*Elshakour et al.* (2007) verdeutlichen anhand von 114 erhobenen Betoniervorgängen, dass neuronale Netze sehr gut bei Produktivitätsprognosen eingesetzt werden können. Insgesamt berücksichtigt das Modell 27 Inputparameter, wobei die besten Ergebnisse mittels eines Hidden-Layers erzielt werden, in der 14 Neuronen platziert sind. Auch diese Autoren heben abschließend hervor, dass neuronale Netze ein hilfreiches Werkzeug darstellen, um Produktivitätsprognosen durchzuführen.<sup>113</sup>

*Ezeldin und Sharara* (2006) prognostizieren auf Basis von künstlicher Intelligenz die Produktivität beim Schalen, Bewehren und Betonieren. Das Modell der Schalungsarbeiten stützt sich hierbei auf 90 Fälle, die Bewehrungsarbeiten auf 80 und das Betonieren auf 92, wobei jeweils 90 % für das Training herangezogen werden. Bei der Modellbildung setzen die Autoren neuronale Netze mit 2 Hidden-Layer ein, bei denen in Abhängigkeit der vorherzusagenden Tätigkeitsproduktivität je 35, 15 oder 10 Hidden-Neuronen zur Anwendung kommen. Abschließend wird mittels Sensitivitätsanalyse festgestellt, dass die Temperatur, die Arbeitskontrolle, das Geschick sowie die Anzahl an Wiederholungen einen sehr großen Einfluss auf die Produktivität ausüben.<sup>114</sup>

*Sonmez und Rowings* (1998) analysieren Produktivitätsverluste mittels neuronaler Netze. Hierbei werden in Abhängigkeit der Tätigkeit (Schalen oder Betonieren) die Aspekte Menge, Bauteilart, Gruppengröße, Prozentwert für Überstunden, Prozentwert für Arbeit, Temperatur, relative Luftfeuchtigkeit, Niederschlag oder Betoneinbringung untersucht. Beim Betonieren steht ein Datensatz mit 112 Fällen zur Verfügung. Die Schalarbeiten stützen sich auf 76 Fälle und das Glätten auf 46 Fälle. Anhand der Untersuchung wird ersichtlich, dass die Menge, die Temperatur und die Gruppengröße einen deutlich stärkeren Einfluss auf die Produktivität ausüben, als die relative Luftfeuchtigkeit, der Regen oder die Überstunden. Weiters halten die Autoren fest, dass wenige signifikante Inputparameter bessere Ergebnisse liefern, als Datensätze mit vielen, aber unwesentlicheren Faktoren.<sup>115</sup>

### 3.4.5 Weitere Anwendungsmöglichkeiten

*Maya, Hassan B. und Hassan A.* (2021) analysieren und prognostizieren die Performance bei Bauprojekten. Die Performance-Kennzahl selbst setzt sich hierbei aus den Kosten, der Qualität, dem Profit und der Bauzeit zusammen. Insgesamt finden 42 Projekte bei der Modellbildung Berücksichtigung. Abschließend ist festzuhalten, dass die Koordination sowie das Engagement der Projektbeteiligten, die einzuhaltenden Termine, die Erfahrung der Projektbeteiligten und die Unterstützung der Geschäftsleitung zu den wesentlichsten Einflüssen zählt.<sup>116</sup>

*Aidan, Al-Jeznawi und Al-Zwanji* (2020) prognostizieren die Entwicklung von Indizes betreffend Kosten und Dauer mit Hilfe von neuronalen Netzen.

<sup>112</sup> Vgl.: Mohammed, S. R.; Tofan, A. S.: Neural networks for estimating the ceramic productivity of walls. In: Journal of Engineering, 17 (2), 2011. S. 200-217

<sup>113</sup> Vgl.: Elshakour, H. A.; Abdel-Razek, R. H.; Abdel-Samad, D.: Predicting Production Rate of Pouring Ready-Mixed Concrete Using Neural Networks. Konferenz: Sixth Alexandria International Conference on Structural and Geotechnical Engineering, 2007. S. 15-30

<sup>114</sup> Vgl.: Ezeldin, A.; Sharara, L.: Neural Networks for Estimating the Productivity of Concreting Activities. In: Journal of Construction Engineering and Management, 132 (6), 2006. S. 650-656

<sup>115</sup> Vgl.: Sonmez, R.; Rowings, J. E.: Construction Labor Productivity Modeling with Neural Networks. In: Journal of Construction Engineering and Management, 124 (6), 1998. S. 498-504

<sup>116</sup> Vgl.: Maya, R.; Hassan, B.; Hassan, A.: Develop an artificial neural network (ANN) model to predict construction projects performance in Syria, In: Journal of King Sauda University-Engineering Sciences, 2021. S. 1-6

Hierbei werden 6 Inputparameter berücksichtigt. Der Datensatz wird in 80 % Trainingsfälle, 10 % Validierungsfälle und 10 % Testfälle unterteilt. Weil die Veröffentlichung 4 Validierungsprojekte beinhaltet, lässt sich anhand dieser errechnen, dass für das gesamte Modell 40 Daten aus Wohnbauprojekten zur Verfügung gestanden sind. Abschließend heben die Autoren hervor, dass sehr gute Ergebnisse mit neuronalen Netze erzielt werden, jedoch für eine bessere Beurteilung auch weitere Prognosemethoden überprüft werden sollten.<sup>117</sup>

*Shiha, Dorra und Nassar (2020)* modellieren die zukünftige, innerhalb von sechs Monaten basierende Entwicklung des Stahl- und Zementpreises. Hierbei werden verschiedene Netze anhand von 116 Daten trainiert sowie getestet und ein weiteres halbes Jahr (6 Fälle) zum Validieren herangezogen, wobei auch die Software NeuralTools eingesetzt wird. Zusammenfassend halten die Autoren fest, dass diese Art der Modellbildung vielversprechend ist und auf andere für die Bauindustrie wichtige Indizes erweitert werden sollte.<sup>118</sup>

*Ayhan und Tokdemir (2019)* analysieren den Schweregrad von Arbeitsunfällen auf Baustellen, um daraus vorbeugende Maßnahmen ableiten zu können. Hierbei wenden die Autoren für die Gliederung in leichte und schwere Unfälle neuronale Netze auf einen 4.109 Fälle umfassenden Datensatz an, welcher 142 Inputvariablen beinhaltet. In der Untersuchung hat sich gezeigt, dass bessere Ergebnisse erzielt werden, wenn der Datensatz zuvor geklustert wird, wodurch sich die wesentlichen Einflussparameter herauskristallisieren. Abschließend werden 60 Inputneuronen für das Trainieren herangezogen.<sup>119</sup>

*Changwei et al. (2019)* setzen neuronale Netze zur Bewertung des Risikos bei Eisenbahnprojekten ein, um den Einfluss unterschiedlicher Länder zu prognostizieren. Hierbei werden zwei verschiedene Netze, für Europa und Asien, mit jeweils einem Hidden-Layer zu je 6 Neuronen trainiert. Insgesamt werden 17 Inputparameter berücksichtigt, welche im Vorhinein in Abhängigkeit der einzelnen Länder von Experten beurteilt wurden.<sup>120</sup>

*Fernandes, Rocha und Costa (2019)* nutzen neuronale Netze, um die umweltspezifischen Indikatoren (Wasser-, Energieverbrauch, Müllherzeugung) in Bezug auf den Baustellenfortschritt zu analysieren.<sup>121</sup>

*Ferreira et al. (2018)* versuchen, mit Hilfe neuronaler Netze unter Berücksichtigung von 17 verschiedenen Inputparametern Fehlzeiten von Arbeitskräften vorherzusagen. Insgesamt beruht die Modellbildung auf einem 2.243 Fälle umfassenden Datensatz, von dem 60 % für das Training verwendet werden.<sup>122</sup>

Weil in China das Müllmanagement auf Baustellen immer mehr an Bedeutung gewinnt, setzten *Liu, Chen und Tang (2018)* neuronale Netze ein, um die Nichtlinearitäten bei der Modellbildung für den anfallenden Müll auf

<sup>117</sup> Vgl.: Aidan, I. A.; Al-Jeznawi, D.; Al-Zwaniy, F. M. S.: Predicting Earned Value Indexes in Residential Complexes' Construction Projects Using Artificial Neural Network Model. In: International Journal of Intelligent Engineering and Systems, 13 (4), 2020. S. 248-259

<sup>118</sup> Vgl.: Shiha, A.; Dorra, E. M.; Nassar, K.: Neural Networks Model for Prediction of Construction Material Prices in Egypt Using Macroeconomic Indicators. In: Journal of Construction Engineering and Management, 146 (3), 2020. S. 1-16

<sup>119</sup> Vgl.: Ayhan, B. U.; Tokdemir, O. B.: Accident Analysis for Construction Safety Using Latent Class Clustering and Artificial Neural Networks, In: Journal of Construction Engineering and Management, 146 (3), 2020. S. 1-14

<sup>120</sup> Vgl.: Changwei, Y.; Zanghao, L.; Xueyan, G.; Wnying, Y.; Jing, J.; Liang, Z.: Application of BP Neural Network Model in Risk Evaluation of Railway Construction, In: Complexity, 2019, Article ID 2946158, 2019. S. 1-12

<sup>121</sup> Vgl.: Fernandes, L. L. A.; Rocha, M. J.; Costa, D. B.: Prediction of environmental performance indicators for construction sites based on artificial Neural Networks, Konferenz: Proc. 27th Annual Conference of IGLC, 2019. S. 1413-1424

<sup>122</sup> Vgl.: Ferreira, R. P. et al.: Artificial Neural Network and their Application in the Prediction of Absenteeism at Work. In: International Journal of Recent Scientific Research, 9 (1), 2018. S. 23332-23334

einer Baustelle abzubilden. Hierbei stützen sie sich auf 20 Wohnbauprojekte, von denen 80 % zum Trainieren und 20 % für das Testen herangezogen werden. Das eingesetzte neuronale Netz berücksichtigt 8 Inputparameter und weist 2 Hidden-Layer mit 20 und 40 Neuronen auf. Abschließend heben die Autoren hervor, dass ein maximaler Fehler von 12 % für den Projektanfang als akzeptabel erachtet werden kann.<sup>123</sup>

*Dimitriou, Marinelli und Fragkakis (2017)* nutzen neuronale Netze für die Mengenvorhersage von Beton und Stahl bei Brückenbauwerken. Hierfür werden zunächst die Inputparameter mit Hilfe einer Umfrage und anschließender Kontrolle erhoben. Die gesammelten Daten stellen die Basis für zwei verschiedene Netze dar. Das erste berechnet anhand von 70 % der 68 Brücken die dafür notwendige Beton-, Bewehrungs- und Spannstahlmenge des Tragwerks und das zweite anhand von 70 % der 321 Pfeiler die nötige Beton- und Bewehrungsmenge der Pfeiler. Beim Tragwerk werden die Spannweite, die Breite und der Brückentyp berücksichtigt, bei den Pfeilern die Spannweite und die Höhe. Darauf aufbauend haben die beiden Netze folgende Struktur: 3-10-3; 2-20-2. Abschließend merken die Autoren an, dass diese Mengenvorhersage vor allem in der Planungsphase ein hilfreiches und verlässliches Tool darstellt. Weiters ist anzudenken, das vorliegende Modell beispielsweise durch zusätzliche Materialien oder andere Bauwerkstypen zu erweitern, damit Planende frühzeitig verlässliche Mengen ermitteln können.<sup>124</sup>

*Oshodi et al. (2017)* prognostizieren mittels eines neuronalen Netzes den Angebotspreisindex. Hierfür nehmen sie jeweils Quartal 1 bis 4 aus dem Zeitraum von 1983 bis 2012 zum Trainieren und die Zeitspanne 2013-2015 für das Testen, wobei in dem Hidden-Layer 9 Neuronen platziert werden. Abschließend heben sie hervor, dass das neuronale Netz sehr gute Ergebnisse liefert, jedoch ein Nachteil darin bestünde, das Modell jedes Quartal neu erstellen zu müssen, um den aktuellen Wert einzuarbeiten.<sup>125</sup>

*El-Sawalhi und Hajar (2016)* wählen den besten Bieter mit Hilfe von künstlicher Intelligenz aus. Hierbei werden 91 Angebote bei 13 Projekten analysiert. Das eingesetzte Netz weist 21 Input-Neuronen, 30 Hidden-Neuronen in einem Layer und ein Output-Neuron auf.<sup>126</sup>

*Mohammadfam et al. (2015)* verdeutlichen, dass neuronale Netze auch bei der Analyse von Arbeitsunfällen hilfreich zur Seite stehen. Hierfür entwerfen die Autoren ein Modell, welches unter Berücksichtigung von 13 Inputparametern auf 960 Arbeitsunfällen aufbaut und die Schwere des Betriebsunfalles vorhersagt. Abschließend unterstreichen die Autoren den Nutzen dieses Modells.<sup>127</sup>

Weil die Zusammenhänge zwischen dem Verhalten bezüglich der Arbeitssicherheit und einzelner Sicherheitsaspekte auf der Baustelle Nichtlinearitäten aufweisen, setzen *Patel und Jha (2015)* künstliche Intelligenz ein, um diese abzubilden. Hierbei werden zehn verschiedene Inputparameter berück-

<sup>123</sup> Vgl.: Liu, J.; Chen, J.; Tang, K.: A Method for Estimation of the On-Site Construction Waste Quantity of Residential Projects. Konferenz: International Conference on Construction and Real Estate Management, 2018. S. 225-231

<sup>124</sup> Vgl.: Dimitriou, L.; Marinelli, M.; Fragkakis, N.: Early Bill-of-Quantities Estimation of Concrete Road Bridges: An Artificial Intelligence-Based Application. In: Public Works Management & Policy, 23 (2), 2018. S. 127-149

<sup>125</sup> Vgl.: Oshodi, O. S. et al.: Comparing univariate techniques for tender price index forecasting: Box-Jenkins and neural network model. In: Construction Economics and Building, 17 (3), 2017. S. 109-123

<sup>126</sup> Vgl.: El-Sawalhi, N.; Hajar, J. A.: Development of Awarding System for Construction Contractors in Gaza Strip Using Artificial Neural Network (ANN). In: Journal of Construction Engineering and Project Management, 6 (3), 2016. S. 1-7

<sup>127</sup> Vgl.: Mohammadfam, I. et al.: Use of Artificial Neural Networks (ANNs) for the Analysis and Modeling of Factors That Affect Occupational Injuries in Large Construction Industries. In: Electronic Physician, 7 (7), 2015. S. 1515-1522

sichtigt, die mittels einer Umfrage erhoben worden sind. Das beste neuronale Netz weist 11 Hidden-Neuronen auf, welche in einem Layer zusammengefasst werden. Eine Analyse der Modelleinflüsse ergibt, dass das Aufsichtsumfeld die größten Auswirkungen auf das sichere Arbeitsverhalten hat. Sicherheitsregeln und -abläufe sind hierbei letztgereiht.<sup>128</sup>

Yeh (1998) setzt neuronale Netze für das Prognostizieren der benötigten Stahlmenge ein, wobei das Hauptaugenmerk auf logarithmische Neuronen gelegt wird. Weiters unterscheidet er zwischen Stahlelementen und Bewehrungsstahl. Für ersteres steht ein Datensatz mit 450 (300 Training, 150 Testen) aus der Praxis gesammelten Fällen zur Verfügung, welcher 8 Inputparameter besitzt. Die Mengenprognose von Bewehrungsstahl beruht auf 400 Fällen (300 Trainieren und 100 Testen), wobei 10 Inputparameter berücksichtigt werden. Als Resultat ist hervorzuheben, dass künstliche neuronale Netze sehr gut dafür geeignet sind, nichtlineare Zusammenhänge zu erkennen und dass bei dem untersuchten Datensatz der Einsatz logarithmischer Neuronen zu einer signifikanten Performancesteigerung führt.<sup>129</sup>

Chua *et al.* (1997) untersuchen mit Hilfe neuronaler Netze, welche Managementfaktoren die Baubudgetentwicklung am stärksten beeinflussen. Hierbei werden aus 27 Aspekten 8 Haupteinflüsse berechnet. Zu diesen zählen: Anzahl der organisatorischen Ebenen zwischen Projektleiter und Handwerkern, Erfahrung des Projektleiters mit einem ähnlichen technischen Umfang, abgeschlossene Planung bei Baubeginn, Bauablaufstudie, Projektteam-Fluktuationsrate, Häufigkeit der Kontrollmeetings während der Bauarbeiten, Häufigkeit der Budgetaktualisierungen und das zur Verfügung stehende Budget für Kontrollsysteme.<sup>130</sup>

In den folgenden Tabellen 3-1, 3-2, 3-3, 3-4 und 3-5 werden die einzelnen Publikationen zusammengefasst und nach deren Veröffentlichungsjahr sortiert. Hierbei gliedern sich die Kategorien in Kosten (K), Dauer (D), Produktivität (P) und weitere Anwendungsmöglichkeiten (W). Der Datenursprung beinhaltet Projekte (P), Indizes (I), Befragungen (B), die Baubehörde (BB), Kostenkennwerte (KKW), Experten (E) und Aufzeichnungen (A). Ist einer der Parameter in der untersuchten Veröffentlichung nicht beschrieben, wird dies durch NA (nicht angegeben) gekennzeichnet.

<sup>128</sup> Vgl.: Patel, D. A.; Jha, K. N.: Neural Network Model for the Prediction of Safe Work Behavior in Construction Projects. In: Journal of Construction Engineering and Management, 141 (1), 2015. S. 1-13

<sup>129</sup> Vgl.: Yeh, I.-C.: Quantity Estimating of Building with Logarithm-Neuron Networks, In: Journal of Construction Engineering and Management, 124 (5), 1998. S. 374-380

<sup>130</sup> Vgl.: Chua, D. K. H. et al.: Model for Construction Budget performance - Neural Network Approach. In: Journal of Construction Engineering and Management, 123 (3), 1997. S. 214-222

Lfd. Nr.	Paper			Daten							Netz	
	Titel	Autoren	Jahr	Kategorie	Datensatzgröße	Trainingsfälle	Inputparameter	Datenursprung	Anzahl Ursprung	Hidden-Layer	Hidden-Neuronen	
0	A	B	C	D	E	F	G	H	I	J	K	
1	Develop an artificial neural network (ANN) model to predict construction projects performance in Syria	Maya, R.; Hassan, B.; Hassan, A.	2021	W	42	80%	6	P	42	1	2	
2	Improvement in Estimating Durations for Building Projects Using Artificial Neural Network and Sensitivity Analysis	Fan, S.-L.; Yeh, I-C.; Chi, W.-S.	2021	D	40	NA	7	P	40	1	7	
3	Measuring and benchmarking the productivity of excavators in infrastructure projects: A deep neural network approach	Kassem, M.; et al.	2021	P	700	72%	12	P	NA	2	50 und 25	
4	Cost estimation in road construction using artificial neural network	Tijanić, K.; Car-Pušić, D; Šperac, M.	2020	K	57	NA	4	P	57	1	21	
5	Neural Networks Model for Prediction of Construction Material Prices in Egypt Using Macroeconomic Indicators	Shiha, A.; Dorra, E.M.; Nassar, K.	2020	W	116	80%	7	I	2008 - 2017	NA	NA	
6	Predicting Earned Value Indexes in Residential Complexes' Construction Projects Using Artificial Neural Network Model	Aidan, I.A.; Al-Jeznawi, D.; Al-Zwaniy, F.M.S.	2020	W	40	80%	6	P	NA	1	1	
7	Framework for Integrating an Artificial Neural Network and a Genetic Algorithm to Develop a Predictive Model for Construction Labor Productivity	Ebrahimi, S.; Raoufi, M.; Fayek, A. R.	2020	P	92	70%	7	E	92	1	6	
8	Schedule and Cost Forecasting Model for Nuclear Power Plant Projects	Karatas, A.; Al-Sharif, S.	2020	D, K	2.370	70%	3	P	5	NA	NA	
9	The Prediction of Metro Shield Construction Cost Based on a Backpropagation Neural Network Improved by Quantum Particle Swarm Optimization	Liu, L.; et al.	2020	K	50	90%	10	P	50	2	12 und 8	
10	A neural network approach to predicting the net costs associated with BIM adoption	Hong, Y.; et al.	2020	K	401	60%	8	B	401	NA	NA	
11	An Artificial Neural Network Approach to Predicting Most Applicable Post-Contract Cost Controlling Techniques in Construction Projects	Omotayo, T.; Bankole, A.; Olubunmi Olanipekun, A.	2020	K	135	50%	17	B	135	1	6	
12	Prediction of environmental performance indicators for construction sites based on artificial Neural Networks	Fernandes, L. L. A.; Rocha, M. J.; Costa, D. B.	2019	W	NA	NA	1	P	15	1	5	
13	Application of Artificial Neural Network(s) in Predicting Formwork Labour Productivity	Golnaraghi, S.; et al.	2019	P	221	80%	9	P	2	2	20 und 20	
14	Forecasting of sports fields construction costs aided by ensembles of neural networks	Juszczuk, M.; Zima, K.; Lelek, W.	2019	K	115	81%	7	P	129	1	5	
15	An artificial neural network approach for cost estimation of engineering services	Matel, E.; et al.	2019	K	132	45%	7	P	132	1	4	

Tab. 3-1 Tabellarische Übersicht der Publikationen – Teil 1



Lfd. Nr.	Paper				Daten						Netz	
	Titel	Autoren	Jahr	Kategorie	Datensatzgröße	Trainingsfälle	Inputparameter	Datenerzeugung	Anzahl Ursprung	Hidden-Layer	Hidden-Neuronen	
0	A	B	C	D	E	F	G	H	I	J	K	
16	Estimation of Building Construction Cost Using Artificial Neural Networks	Chandanshive, V.B.; Kambekar, A.R.	2019	K	78	70%	11	P	78	1	3	
17	Modelling Construction Site Cost Index Based on Neural Network Ensembles	Juszczyk, M.; Lesniak, A.	2019	K	143	80%	11	B	NA	1	8	
18	Accident Analysis for Construction Safety Using Latent Class Clustering and Artificial Neural Networks	Ayhan, B. U.; Tokdemir, O. B.	2019	W	4.109	84%	60	P	NA	NA	NA	
19	Application of BP Neural Network Model in Risk Evaluation of Railway Construction	Changewei, Y.; et al.	2019	W	56	66%	17	E	56	1	6	
20	Preliminary Construction Cost Estimate in Yemen by Artificial Neural Network	Hakami, W.; Hassan, A.	2019	K	136	70%	11	P	136	1	38	
21	Prediction of site overhead costs with the use of artificial neural network based model	Leśniak, A.; Juszczyk, M.	2018	K	143	NA	10	P	143	1	4	
22	ANN Based Approach for Estimation of Construction Costs of Sports Fields	Juszczyk, M.; Lesniak, A.; Zima, K.	2018	K	115	60%	7	P	129	1	5	
23	A Method for Estimation of the On-Site Construction Waste Quantity of Residential Projects	Liu, J.; Chen, J.; Tang, K.	2018	W	20	80%	8	P	20	2	20 und 40	
24	An Artificial neural networks (ANN) model for evaluating construction project performance based on coordination factors	Alaloul, W. S.; et al.	2018	D, K	325	70%	16	B	325	2	10 und 10	
25	Artificial Neural Network and their Application in the Prediction of Absenteeism at Work	Ferreira, R. P.; et al.	2018	W	2.243	60%	17	A	2.243	2	10	
26	Stochastic Conceptual Cost Estimation of Highway Projects to Communicate Uncertainty Using Bootstrap Sampling	Gardner, B. J.; Gransberg, D. D.; Rueda J. A.	2017	K	189	80%	14	P	189	NA	NA	
27	Comparing univariate techniques for tender price index forecasting Box-Jenkins and neural network model	Oshodi, O.S.; et al.	2017	W	132	91%	1	I	1983 - 2015	1	9	
28	Early Bill-of-Quantities Estimation of Concrete Road Bridges: An Artificial Intelligence-Based Application	Dimitriou, L.; Marinelli, M.; Fragkakis, N.	2017	W	321	70%	2	P, B	68	1	20	
29	Construction Productivity Estimation Model Using Artificial Neural Network for Foundations Work in Gaza Strip Construction Sites	Haddad, E.	2017	P	111	75%	16	B	111	1	22	
30	Automated Tool for Predicting Duration of Construction Activities in Tropical Countries	Golizadeh, H.; et al.	2016	D	256	NA	10	P	4	1	10	
31	Productivity estimation model for bricklayer in construction projects using neural network	Kareem, G.	2016	P	118	NA	13	P, B	32	1	3	

Tab. 3-2 Tabellarische Übersicht der Publikationen – Teil 2

Lfd. Nr.	Paper				Daten						Netz	
	Titel	Autoren	Jahr	Kategorie	Datensatzgröße	Trainingsfälle	Inputparameter	Datenursprung	Anzahl Ursprung	Hidden-Layer	Hidden-Neuronen	
0	A	B	C	D	E	F	G	H	I	J	K	
32	Productivity analysis of precast concrete operations by artificial neural networks	Najafi, A.; Kong, R.T.L.	2016	D	220	73%	5	P	4	1	9	
33	Preliminary Resource-based Estimates Combining Artificial Intelligence Approaches and Traditional Techniques	Garcia de Soto, B.; Adey, B.T.	2016	W	148	80%	5	P	148	1	3	
34	Cost Estimation Model (Cem) for Residential Building using Artificial Neural Network	Yadav, R.; et al.	2016	K	23	83%	6	KKW	23	1	NA	
35	Duration determination for rural roads using the principal component analysis and artificial neural network	Mensah, I.; Adjei-Kumi, T.; Nani, G.	2016	D	22	60%	3	P	22	1	38	
36	Development of Awarding System for Construction Contractors in Gaza Strip Using Artificial Neural Network (ANN)	El-Sawalhi, N.; Hajar, J.A.	2016	W	91	61%	21	P	13	1	30	
37	Conceptual Cost Estimation Modul for Engineering Services in Public Construction Projects	Hyari, A. H.; Al-Daraiseh, A.; El-Mashaleh, M.	2016	K	224	76%	5	BB	224	1	15	
38	Towards The Development of an Index to Measure the Performance of Multi-Productivity Areas	El-Kholy, A.M.	2016	P	25	60%	12	B	25	1	16	
39	Time and Cost Analysis for Highway Road Construction Project Using Artificial Neural Networks	Naik, M.G.; Radhika, V.S.B.	2015	D, K	NA	NA	NA	P	2	1	10	
40	Neural Network Model for the Prediction of Safe Work Behavior in Construction Projects	Patel, D.A.; Jha, K.N.	2015	W	200	75%	10	B	222	1	11	
41	An early cost estimation model for hydroelectric power plant projects using neural networks and multiple regression analysis	Gunduz, M.; Sahin, H. B.	2015	K	54	90%	12	P	54	1	9	
42	Applying Artificial Neural Networks for Measuring and Predicting Construction-Labor Productivity	Heravi, G.; Eslamdoost, E.	2015	P	39	100%	15	B	39	2	12 und 12	
43	Use of Artificial Neural Networks (ANNs) for the Analysis and Modeling of Factors That Affect Occupational Injuries in Large Construction Industries	Mohammadfam, I.; et al.	2015	W	960	80%	13	B	980	1	20	
44	A computer-based cost prediction model for institutional building projects in Nigeria	Bala, K.; Bustani, S.; Waziri, B.	2014	K	260	70%	9	P	260	2	7 und 5	
45	Conceptual Cost Estimate of Libyan Highway Projects Using Artificial Neural Network	Elbeltagi, E.; Hosny, O.; Abdel-Razek, R.H.	2014	K	67	75%	11	P	67	2	5 und 30	
46	Neural Network Prediction Model for Construction Project Duration	Petruseva, S.; Zujo, V.; Zileska-Pancovska, V.	2013	D	75	NA	3	B	75	1	7	

Tab. 3-3 Tabellarische Übersicht der Publikationen – Teil 3

Lfd. Nr.	Paper				Daten						Netz	
	Titel	Autoren	Jahr	Kategorie	Datensatzgröße	Trainingsfälle	Inputparameter	Datenursprung	Anzahl Ursprung	Hidden-Layer	Hidden-Neuronen	
0	A	B	C	D	E	F	G	H	I	J	K	
47	Development of the construction productivity estimation model using artificial neural network for finishing works for floors with marble	AL-Zwainy, F.M.S.; et al.	2012	P	150	60%	10	P	10	1	1	
48	Neural networks for modelling the final target cost of water projects	Ahiaga-Dagbui, D.D.; Smith, S.D.	2012	K	98	75%	25	P	98	1	19	
49	Early Cost Estimation of Road Tunnel Construction Using Neural Networks	Petroutsatou, K.; et al.	2012	K	149	58%	10	B	33	NA	NA	
50	Development of Construction Labor Productivity Estimation Model using Artificial Neural Network	Muqueem, S.; et al.	2011	P	84	72%	5	P	7	1	25	
51	Prediction Modeling of Construction Labor Production Rates using Artificial Neural Network	Muqueem, S.; et al.	2011	P	84	72%	5	P	7	1	3	
52	Construction Labor Production Rates Modeling using Artificial Neural Network	Muqueem, S.; et al.	2011	P	84	90%	5	P	7	1	10	
53	Neural networks for estimating the ceramic productivity of walls	Mohammed, S.R.; Tofan, A.S.	2011	P	100	60%	7	P, B	NA	1	1	
54	An artificial neural networks model for the estimation of formwork labour	Dikmen, S.U.; Sonmez, M.	2011	D	613	90%	7	P	22	1	5	
55	A Neural Network Model for Construction Projects Site Overhead Cost Estimating in Egypt	EISawy, I.; Hosny, H.; Razek, M.A.	2011	K	52	90%	10	P	52	1	13	
56	Early Stage Cost Estimation of Buildings Construction Projects using Artificial Neural Networks	Arafa, M.; Alqedra, M.	2011	K	71	49%	7	P	71	1	7	
57	Cost premium prediction of certified green buildings: A neural network approach	Tatari, O.; Kucukvar, M.	2011	K	74	80%	7	P	74	1	5	
58	Estimation of earthworks execution time cost by means of artificial neural networks	Hola, B.; Schabowicz, K.	2010	D, K	200	85%	5	P	1	1	8	
59	Cost Estimating Models for Utility Rehabilitation Projects: Neural Networks versus Regression	Shehab, T.; et al.	2010	K	54	63%	63	P	54	NA	NA	
60	Neural Network Model for Construction Cost Prediction of Apartment Projects in Vietnam	Luu, V. T.; Kim, S. Y.	2009	K	19	74%	7	P	19	1	5	
61	Forecasting final budget and duration of highway construction projects	Pewdum, W.; Rujirayanyong, T.; Sooksatra, V.	2009	D, K	1.022	98%	8	P	51	1	300	
62	Predicting Production Rate of Pouring Ready-Mixed Concrete Using Neural Networks	Elshakour, H.A.; Abdel-Razek, R.H.; Abdel-Samad, D.	2007	P	114	90%	27	P, B	10	1	14	
63	Neural Networks for Estimating the Productivity of Concreting Activities	Ezeldin, A.; Sharara, L.	2006	P	90	90%	12	P	6	2	35 und 35	

Tab. 3-4 Tabellarische Übersicht der Publikationen – Teil 4

Lfd. Nr.	Paper			Daten							Netz	
	Titel	Autoren	Jahr	Kategorie	Datensatzgröße	Trainingsfälle	Inputparameter	Datenursprung	Anzahl Ursprung	Hidden-Layer	Hidden-Neuronen	
0	A	B	C	D	E	F	G	H	I	J	K	
64	Neural Network Modeling of Highway Construction Costs	Wilmot, C. G.; Mei, B.	2005	K	1.723	85%	11	V	2.827	1	5	
65	A neural network approach for early cost estimation of structural systems of buildings	Günaydin, H.M.; Dogan, S.Z.	2004	K	30	80%	8	P	30	1	4	
66	Comparative study of artificial neural networks and multiple regression analysis for predicting hoisting times of tower cranes	Leung, A.W.T.; Tam, C.M.; Liu, D.k.	2001	D	1.293	96%	17	P	7	1	42	
67	Application of artificial neural network to forecast construction duration of buildings at the predesign stage	Bhokha, S.; Ogunlana, S.O.	1999	D	136	50%	11	P	136	1	6	
68	Quantity Estimating of Building with Logarithm - Neural Networks	Yeh, I-C.	1998	W	400	25%	10	P	NA	NA	NA	
69	Construction Labor Productivity Modeling with Neural Networks	Sonmez, R.; Rowings, J. E.	1998	P	112	NA	6	P	8	1	13	
70	Model for Construction Budget Performance - Neural Network Approach	Chua, D. K. H.; et al.	1997	W	20	NA	8	B	75	2	5 und 3	
<b>Legende</b>												
Kategorie	K	Kosten										
	D	Dauer										
	P	Produktivität										
	W	Weitere Anwendungen										
Datenursprung	A	Aufzeichnung										
	B	Befragung										
	BB	Baubehörde										
	E	Experten										
	I	Index										
	KKW	Kostenkennwerte										
	P	Projekte										
	V	Verträge										
NA	Nicht angegeben											

Tab. 3-5 Tabellarische Übersicht der Publikationen – Teil 5

### 3.4.6 Auswertung der Literaturanalyse

Die exemplarische Auflistung der 70 Anwendungen (Tabelle 3-1, 3-2, 3-3, 3-4 und 3-5) zeigt sehr deutlich, dass neuronale Netze bereits seit vielen Jahren erfolgreich bei baubetrieblichen bzw. bauwirtschaftlichen Fragestellungen eingesetzt werden. Für den Modellierungsprozess ist lediglich ein Datensatz notwendig, welcher neben den Inputparametern auch das gewünschte Output beinhaltet. Hierbei schwankt die prozentuelle Anzahl der Trainingsfälle der analysierten Publikationen zwischen 25 und 100 % des gesamten Datensatzes, wobei der Mittelwert 74 % und der Median 75 % betragen (Abbildung 3-15). Die meisten Trainingsfallanteile liegen zwischen 70 und 80 %. An dieser Stelle ist anzumerken, dass eine Modellbildung, welche nur auf

Trainingsdaten basiert (100 %), nicht eingesetzt werden sollte, weil keine Aussage über die Qualität des Netzes getroffen werden kann.




Abb. 3-15 Histogramm des Trainingsanteils

Die Anzahl der Inputparameter weist eine Bandbreite von einer bis zu 63 Variablen auf. Der dazugehörige Mittelwert beträgt 11 und der Median 9 Inputs. Abbildung 3-16 zeigt das dazugehörige Histogramm, wobei ersichtlich ist, dass am häufigsten zwischen 6 und 8 Variablen in der Modellbildung berücksichtigt werden.




Abb. 3-16 Histogramm der Inputparameteranzahl

Weiters werden bei 50 der 70 Publikationen Projekte als Datenursprung herangezogen. Die Anzahl dieser schwankt zwischen einem und 260 verschiedenen Bauvorhaben, wobei im Mittel 56 Bauprojekte Berücksichtigung finden. Der dazugehörige Median, welcher 40 Projekte ausmacht, weicht vom Mittelwert

deutlich ab. Diese Schiefe Lage wird auch im in Abbildung 3-17 dargestellten Histogramm ersichtlich. Am häufigsten beziehen sich die Daten auf eine Bauprojektanzahl, die zwischen 1 und 10 Bauvorhaben liegt.




Abb. 3-17 Histogramm der Datenursprungsanzahl bei Projekten

Ebenso weisen 51 der 70 Veröffentlichungen lediglich einen Hidden-Layer auf, in dem bis zu 300 Neuronen eingesetzt werden (Abbildung 3-18). Der dazugehörige Mittelwert beziffert 17 und der Median 7,5 Neuronen. In nur 11 Publikationen wird auf zwei Hidden-Layer mit einer Bandbreite zwischen 3 und 50 Neuronen zurückgegriffen.





Abb. 3-18 Histogramm der Neuronen bei einem Hidden-Layer

Um einen besseren Überblick über den typischen Aufbau der vorgestellten neuronalen Netze zu erlangen, wird nachfolgend ein fiktives Prognosemodell basierend auf den einzelnen Medianen der soeben vorgestellten Parameter erstellt. Dieses beinhaltet einen Hidden-Layer mit 8 Neuronen und berücksichtigt

sichtigt 7 Inputparameter. Hierbei stammt die Datengrundlage von 40 verschiedenen Projekten, wobei 75 % des gesamten Datensatzes (86 Fälle) für das Trainieren des Modells eingesetzt werden. Daraus ist abzuleiten, dass hauptsächlich sehr kleine Netze angewendet werden. Deep Learning, sprich mehrere in einem Netz hintereinanderliegende Hidden-Layer, hat somit bei Prognosen mit dem Schwerpunkt auf Kosten, Dauern und Produktivitäten noch keinen weitreichenden Einfluss gefunden.

Viele Autoren berichten in deren Veröffentlichungen vom großen Potenzial der neuronalen Netze, weil Vorhersagen damit genauer und effizienter sowie in Echtzeit erstellt werden können. Beispielsweise ist es dadurch per Knopfdruck möglich, die Kosten bzw. die Dauer eines neuen Projektes oder eines Änderungswunsches zu ermitteln. Trotz dieser zuversichtlichen Einschätzungen haben sich jedoch neuronale Netze im täglichen Baugeschehen noch nicht etabliert. Basierend auf den Ergebnissen der durchgeführten Literaturanalyse liegt der Hauptgrund hierfür in der Notwendigkeit eines umfangreichen Datensatzes, welchen die künstliche Intelligenz für das Erlernen von Wissen benötigt. Bei näherer Betrachtung der vorgestellten Publikationen fällt auf, dass die unterschiedlichen Modelle lediglich auf 19 bis 4.109 Fälle aufbauen (Abbildung 3-19). Hierbei beträgt der Mittelwert 326 und der Median 115 Fälle.



**Abb. 3-19** Histogramm über die Datensatzgröße

Bei einer Gegenüberstellung der vorhandenen Datensatzgrößen mit jenen aus dem Handel wird rasch ersichtlich, dass der auf den Baustellen gesammelte Datensatz deutlich geringer ausfallen. *Chaudhuri et al.* greifen beispielsweise auf eine Datenbasis von 50.000 Einträgen zurück, um das Kaufverhalten von Kunden zu prognostizieren.<sup>131</sup> Ein Grund für diese Unterschiede in der Datenverfügbarkeit ist auf den Digitalisierungsgrad zurückzuführen. Hierbei liegt der Handel, bei dem bereits nahezu jede verkaufte Ware digital erfasst ist, vor der Bauindustrie.<sup>132</sup>

<sup>131</sup> Vgl.: Chaudhuri, N.; Gupta, G.; Wamsi, V.; Bose, I.: On the platform but will they buy? Predicting customers' purchase behavior using deep learning. In: Decision Support Systems 149, 2021. S. 1-10.

<sup>132</sup> Vgl.: <https://www.de.digital/DIGITAL/Navigation/DE/Lagebild/Indikatorentool/indikatorentool.html>. Datum des Zugriffs: 14.11.2021

Als Zwischenfazit ist festzuhalten, dass sich neuronale Netze erfolgreich bei Prognosen im Baubetrieb oder in der Bauwirtschaft einsetzen lassen, wenn genügend Daten vorhanden sind. Dies stellt jedoch aktuell noch eine Herausforderung dar, weil das automatisierte Erheben der Inputparameter auf den Baustellen nicht ausreichend umgesetzt wird. Erst wenn die notwendigen Einflussfaktoren mittels polysensoraler Systeme erfasst und in Kennzahlen transformiert werden, ist das Potenzial der neuronalen Netze zur Gänze ausnutzbar. Um diesen Prozess zu fördern, beinhalten die nachfolgenden Kapitel eine Vorstellung verschiedener digitaler Technologien sowie ein konkretes Anwendungsbeispiel.





## 4 Automatische Datenerhebung

Im vorliegenden Kapitel werden Werkzeuge und Herangehensweisen für die systematische und kontinuierliche Datenerhebung vorgestellt. Dies ist besonders wichtig, damit das Potenzial der künstlichen Intelligenz zur Gänze ausgeschöpft werden kann. Auch *Wahlster* sieht das Ablösen analoger Methoden und das nahezu vollständig digitale Erfassen, Übertragen und Speichern von Daten als erste Welle der Digitalisierung, welche als Vorläufer der maschinenverständlichen Daten dient. Ohne maschinenlesbare Daten kann das Verstehen, Veredeln und aktive Nutzen im Zuge der zweiten Digitalisierungswelle nicht vollständig ausgeschöpft werden.<sup>1</sup>

Aktuell stellt das automatische Erheben von Daten und Informationen auf der Baustelle eine Herausforderung dar, weil das zu errichtende Bauwerk einem ständigen Wandel unterliegt. Dieser erschwert im Gegensatz zur stationären Industrie den Einsatz von Sensoren bzw. Ortungstechnologie und erhöht die Anforderungen an die Datenübertragung.

Die folgenden Abschnitte haben das Ziel, den soeben aufgezeigten Schwierigkeiten entgegenzuwirken und Lösungsmöglichkeiten aufzuzeigen. Hierfür werden zunächst die theoretischen Grundlagen von Sensoren behandelt, damit eine einheitliche Verstehensumgebung geschaffen wird. Darauf aufbauend steht die Auswahl geeigneter Messfühler, die Datenübertragung sowie Ortungsmöglichkeiten im Fokus der Betrachtung. Abschließend werden fünf verschiedene Konzepte zur automatischen Erhebung anfallender Lohnstunden mit verursachungsgerechter Bereichszuordnung vorgestellt, aus denen schlussendlich eines ausgewählt wird.

### 4.1 Sensoren – Funktionsweise und Einsatzmöglichkeit

Der Begriff Sensor ist auf das lateinische Wort *sensus* zurückzuführen, welches mit *Sinn*<sup>2</sup> übersetzt werden kann. Im Kontext der deutschen Sprache bedeutet er Messfühler.<sup>3</sup>

Durch dieses Element wird es möglich, physikalische, chemische, klimatische, biologische und medizinische Größen quantitativ und qualitativ zu bestimmen. Erst durch das Erfassen von Messgrößen wird es dem Menschen ermöglicht, Prozesse zu beeinflussen und zu steuern.<sup>4</sup>

Die nachfolgende Abbildung 4-1 verdeutlicht das Wirkungsprinzip eines Sensors. Dieser besteht aus zwei wesentlichen Komponenten, dem Sensorelement und der Auswertelektronik.

<sup>1</sup> Vgl.: Wahlster, W.: Künstliche Intelligenz: Digitales Verstehen. In: Naturwissenschaftliche Rundschau. 72. Jahrgang, Heft 9/10. 2019. S. 4

<sup>2</sup> Langenscheidt: <https://de.langenscheidt.com/latein-deutsch/sensus>. Datum des Zugriffs: 08.05.2020

<sup>3</sup> Duden: <https://www.duden.de/rechtschreibung/Sensor>. Datum des Zugriffs: 08.05.2020

<sup>4</sup> Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik. S. 1

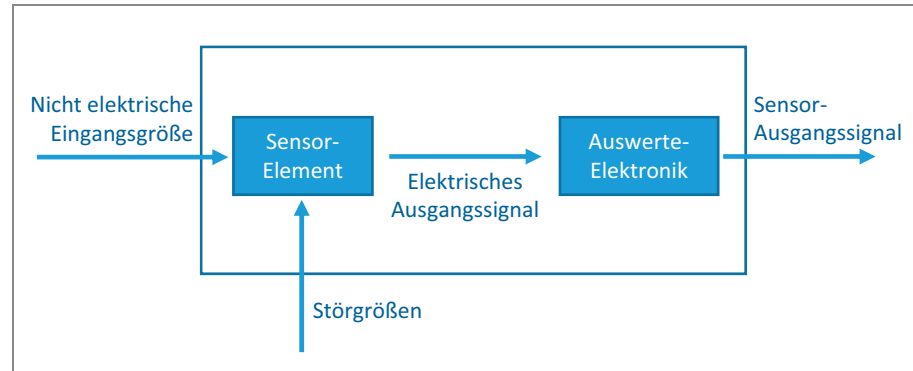


Abb. 4-1 Wirkungsweise eines Sensors<sup>5</sup>

Das Sensor-Element wandelt mit Hilfe von naturwissenschaftlichen Gesetzen die nicht elektrische Eingangsgröße in ein elektrisches Ausgangssignal um. Dieses wird nachfolgend durch die Auswerte-Elektronik, welche aus Schaltungselektronik und Softwareprogrammen besteht, aufbereitet und als Sensor-Ausgangssignal weitergegeben. Die auf das Sensor-Element einwirkenden Störgrößen wie beispielsweise Temperatureinflüsse werden bei der Auswertung ebenfalls berücksichtigt. Das abschließende Output wird in weiterer Folge für Steuerungen oder Analysen herangezogen.<sup>6</sup>

Damit störende Einflüsse auf die Messgröße berücksichtigt und nutzerorientierte Auswertungen durchgeführt werden können, sind in der Regel Mikroprozessoren erforderlich. Diese werden dank fortschreitender Miniaturisierung immer kleiner, wodurch es möglich wird, sowohl das Sensor-Element, als auch die Auswerte-Elektronik in einem einzigen Bauteil unterzubringen. Diese intelligenten Sensoren sind in der Literatur auch unter dem Begriff smart sensors zu finden und legen den Grundstein für eine automatisierte Datenerhebung.<sup>7</sup>

Für die Einteilung der Sensoren gibt es einige Möglichkeiten. Eine weitverbreitete stellt die Gliederung anhand einer zusätzlichen Hilfsenergie dar. Erfolgt hierbei die Umwandlung des gewünschten Parameters in ein elektrisches Signal ohne äußere Hilfsspannung, werden diese als aktive Sensoren bezeichnet. Muss hingegen eine zusätzliche Spannung angebracht werden, um die Messgröße zu transformieren, wird von einem passiven Sensor gesprochen. Ebenso ist es erdenklich, die einzelnen Messfühler anhand deren zu Grunde liegender Naturgesetze zu unterscheiden.<sup>8</sup>

Eine weitere Einteilungsmöglichkeit stellt das Aufzeigen verschiedener Messgrößen in zusammenhängenden Gruppen dar. Dies hat besonders für die Bauwirtschaft und den Baubetrieb eine wesentliche Bedeutung, weil dadurch sofort ersichtlich wird, welche Parameter erhoben werden können. Tabelle 4-1 zeigt exemplarisch für das Bauwesen relevante Faktoren, gegliedert in geometrische, mechanische, zeitbasierte, elektrische/magnetische und klimatische Messgrößen, sowie auf Schall und Licht bezogene Einflüsse.

<sup>5</sup> Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik. S. 1

<sup>6</sup> Vgl.: Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik. S. 1

<sup>7</sup> Vgl.: Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik. S. 1

<sup>8</sup> Vgl.: Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik. S. 2

Lfd. Nr.:	Geometrische Messgrößen	Mechanische Messgrößen	Zeitbasierte Messgrößen	Elektrische/magnetische Messgrößen	Klimatische Messgrößen	Schall/Licht
0	A	B	C	D	E	F
1	Weg	Masse	Zeit	Spannung	Luftfeuchtigkeit	Radiometrische Größen
2	Abstand	Kraft	Frequenz	Stromstärke	Niederschlag	Fotometrische Größen
3	Position	Dehnung	Pulsbreite	Widerstand	Luftdruck	Helligkeit
4	Winkel	Druck	Phase	Kapazität	Wind	Farbe
5	Drehung	Drehmoment	Laufzeit	Feldstärke	Lüftströmungen	Strahlungsleistung
6	Neigung	Härte	Drehzahl und Drehwinkel	Leistung	Flüssigkeitsströmungen	Schallpegel
7	Objekt- erfassung		Geschwindigkeit	Induktivität	Temperatur	Lautheit
8	Anzahl		Beschleunigung	Leitfähigkeit	Baustoff- feuchtigkeit	Lautstärke
9	Füllstand		Durchfluss	Ladung		Direkt- und Diffusstrahlung
10	Abmessungen		Vibrationen			

Tab. 4-1 Exemplarische Auflistung messbarer Einflüsse<sup>9</sup>

Werden die gewünschten Messgrößen nicht durch reale Sensoren ermittelt, sondern unter Zuhilfenahme einer Software berechnet, nennt man diese Messfühler virtuelle Sensoren. Dem hierbei verwendeten Programm liegt ein ausgereiftes mathematisches Rechenmodell oder auch empirisch erfasste Zusammenhänge wie beispielsweise das subjektive Hörempfinden zugrunde. Diese Art von Sensoren werden häufig in Hinblick auf deren Kosteneffizienz eingesetzt. Ebenso eignen sie sich sehr gut für Anwendungsfälle, bei denen reale Sensoren zerstört oder zu schnell abgenutzt werden würden (z.B.: in Kernkraftwerken).<sup>10</sup>

Die nachfolgende Tabelle 4-2 verdeutlicht eine Übersicht, bei der ausgewählte Input- und Outputgrößen in einer Matrix in Abhängigkeit des Sensors dargestellt werden. Sofort ist ersichtlich, dass beispielsweise eine Länge auf fünf verschiedenen Prinzipien beruhend gemessen werden kann. Welche Möglichkeit in Bezug auf wirtschaftliches und effektives Erheben von kontextbezogenen Daten auf der Baustelle am besten geeignet ist, muss mit den Herstellern abgeklärt werden. Hierbei gilt es, unter anderem ein besonderes Augenmerk auf die benötigte Genauigkeit, Robustheit, Feuchteempfindlichkeit, Energiezufuhr und die Art der Datenübertragung zu legen.

Die soeben genannte Genauigkeit lässt sich durch richtig und präzise konkretisieren. In Abbildung 4-2 wird ersichtlich, dass eine hohe Präzision kombiniert mit Richtigkeit zu einem sehr genauen Ergebnis führt. Unpräzise und richtig ergibt genau, wobei präzise und unrichtig ein ungenaues Resultat verkörpert. Weder präzise noch richtig führt ebenfalls zu ungenau. Weiters geht aus der Darstellung hervor, dass die Präzision die Streuung und die Richtigkeit die Verzerrung (Abstand zum anerkannten Bezugswert) beschreiben.<sup>11</sup> Eine normative Verschriftlichung hiervon ist in der DIN ISO 5725-1:1997 zu finden.<sup>12</sup>

<sup>9</sup> In Anlehnung an: Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik. S. Xlff

<sup>10</sup> Vgl.: Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik. S. 2

<sup>11</sup> Hofstadler, C.: Einleitung und Grundlagen. In: Vorlesungsfolien von Chancen- und Risikomanagement in der Bauwirtschaft, Sommersemester 2018, TU Graz. Folie 117

Lfd. Nr.:	Eingangsgröße	Ausgangsgröße					
		Elektrischer Widerstand			Spannung	Strom	Ladung
		resistiv R	induktiv L	kapazitiv C	U	I	Q
0	A	B	C	D	E	F	G
1	Positionen: Länge Weg Winkel	Potentiometer, Magnetoresistiver Sensor, Gauß- Feldplatte	Differenzial Transformator, Tauchanker- Wegsensor	Kapazitiver Wegsensor	Hall-Sensor, Optoelektron. Lichtschranken- Sensor	Wirbelstrom- Sensor	
2	Dehnung	Dehnungsmess- streifen				Faseroptische Sensoren	
3	Geschwindigkeit	Magnetoresistiver Drehwinkel-Sensor	Induktiver Drehwinkel- Sensor		Magnetpol- Drehzahl-Sensor	Optoelektron. Drehzahl- Sensoren	Gyrometer/Piezo- Sensor
4	Beschleunigung	Seismische Masse-Dämpfer-Feder Systeme, Rückführung auf Wegmessung: resistiv, induktiv, kapazitiv, optoelektronisch, piezoresistiv; Hall/Gauß-Sensorik oder Dehnungsmessung (DMS)					
5	Kraft und Moment	Piezoresistiver Sensor, Dehnstoffe	Magneto- elastischer Sensor	Kraft- kompensations- Sensor	Federelemente oder DMS	Federelemente oder DMS	Piezoelektrischer Sensor
6	Druck	Piezoresistiver Dehnstoff-Sensor	Magneto- elastischer Sensor	Kapazitiver Drucksensor	Federelemente oder DMS	Federelemente oder DMS	Piezoelektrischer Sensor
7	Temperatur	NTC/ PTC Widerstände			Thermoelemente	Optoelektron. Pyrometer	
8	Feuchtigkeit	Resistive Hygrometer		Kondensator Hygrometer			

Tab. 4-2 Exemplarische Auflistung der Sensorarten<sup>13</sup>

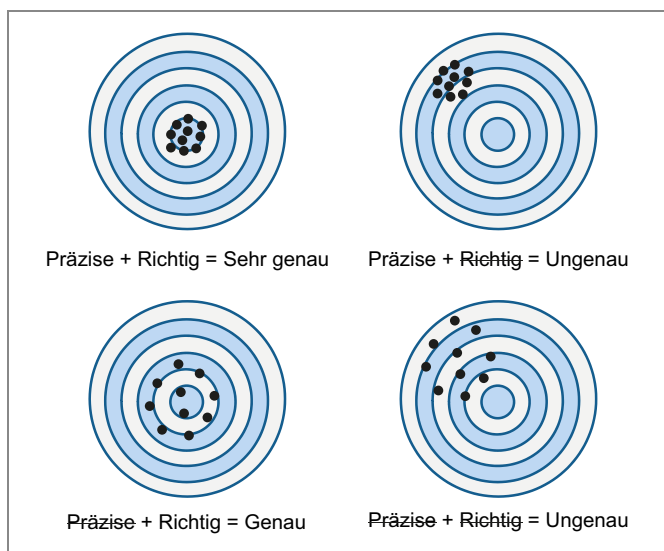


Abb. 4-2 Verdeutlichung von genau durch präzise und richtig<sup>14</sup>

Abschließend werden noch Vorschläge zur Ermittlung von Stahlbetonar-  
beiten beeinflussender Faktoren mit Hilfe digitaler Technologien aufgezeigt.  
Im Zuge der Datenerhebung auf der Baustelle ist darauf zu achten, dass die  
eingesetzten Sensoren robust sind, um den Einwirkungen durch Feuch-

<sup>12</sup> DIN ISO 5725-1:1997, S. 15f

<sup>13</sup> Czichos, H.: Mechatronik Grundlagen und Anwendungen technischer Systeme S. 78

<sup>14</sup> Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. S. 5

tigkeit, Temperatur, Staub und mechanische Belastungen standzuhalten.<sup>15</sup> Tabelle 4-3 stellt ausgewählten Einflussparametern eine Erfassungsmöglichkeit gegenüber, wobei auch die dazugehörige Eingangsgröße angeführt wird. Hierbei kristallisiert sich heraus, dass der durch Ortung ermittelten Position und der beispielsweise durch RFID (Radio Frequency Identification) bestimmten Anzahl eine hohe Bedeutung zukommt. Ebenso zählt der Abstand oder die Zeit zu den oftmals vorkommenden Eingangsgrößen.

Lfd. Nr.	Parameter	Eingangsgröße	Erhebungsmöglichkeit
0	A	B	C
1	Anzahl Handgeräte	Anzahl	RFID
2	Arbeitsfortschritt Betondecke	Kraft	Kraftsensor
3	Arbeitskräfte	Position/Anzahl	Ortung/RFID
4	Arbeitslänge/-fläche	Position	Ortung
5	Ausschalungszeitpunkt	Temperatur	Temperatursensor
6	Baustellentransporte	Anzahl	Ortung/RFID
7	Baustoffgewicht heben Kran	Gewicht	Kraftsensor
8	Betondruck	Druck	Drucksensor
9	Biegeverteilung	Winkel	Winkelsensor
10	Dauer der Tätigkeiten	Zeit	Uhr/Ortung/RFID
11	Diebstahl	Position/Anzahl	Ortung/RFID
12	Ebenheit Betonbauteile	Abstand	Abstandssensor
13	Einsatzortwechsel	Position	Ortung
14	Füllstand des Betons	Abstand	Abstandssensor
15	Gruppengröße	Position/Anzahl	Ortung/RFID
16	Kranbelegezeiten	Zeit	Ortung/RFID
17	Krankübefahrten	Anzahl	RFID
18	Lagerbestand	Anzahl	RFID
19	Neigung	Winkel	Neigungssensor
20	Regen	Regenmenge	Regensensor
21	Rel. Luftfeuchtigkeit	Rel. Luftfeuchtigkeit	Feuchtesensor
22	Schalungsposition	Position	Ortung/Lagesensor
23	Tägliche Arbeitszeit	Zeit	RFID
24	Temperatur	Temperatur	Temperatursensor
25	Überprüfung Vollständigkeit	Position/Anzahl	Ortung/RFID
26	Verdichtungsgrad	Schwingungen	Schwingungssensor
27	Verlegte Schalfläche	Position	Ortung
28	Wandversatz	Abstand	Abstandssensor
29	Windgeschwindigkeit	Geschwindigkeit	Windsensor
30	Zug in Abspannungen	Kraft	Kraftsensor

Tab. 4-3 Digitale Erhebungsmöglichkeiten ausgewählter Parameter

<sup>15</sup> Vgl.: Motzko, C. et al.: Grundlagen des Bauprozessmanagements. In: Praxis des Bauprozessmanagements – Termine, Kosten und Qualität zuverlässig steuern. Hrsg.: Motzko, C. S. 29

Um die gewünschten Prozesse auf der Baustelle digital erfassen und auswerten zu können, gilt es, Sensoren einzusetzen, deren Messgrößen in Zusammenhang mit dem zu untersuchenden Arbeitsablauf stehen und charakteristische Muster aufweisen. *Mehr* zeigt beispielsweise auf, dass während des Betonierens auf Basis der erhobenen Beschleunigungsdaten des Krankübels auf das Füllen, dessen Transport und das Leeren zu schließen ist. Ebenso hebt er hervor, dass das Anbringen eines Beschleunigungssensors auf der Schalung die Nachvollziehbarkeit des Ein- und Ausschaltvorgangs sowie die Kontrolle der Elementausrichtung fördert. Für die Auswertung der erhobenen Rohdaten, sprich die Mustererkennung, sieht *Mehr* den Einsatz neuronaler Netze als zielführend an.<sup>16</sup>

## 4.2 Datenübertragung

Nachdem die Sensoren die gewünschten Messwerte ermittelt haben, müssen diese ausgewertet, gespeichert bzw. visualisiert werden. Hierbei erfolgt die Weiterleitung der Daten über den Draht-, Funk- oder Lichtweg. In der Regel besteht der gesamte Übertragungsweg nicht nur aus einem der drei Medien, sondern aus einer aufeinanderfolgenden Kombination dieser.<sup>17</sup>

Die herkömmliche Methode für das Bindeglied zwischen den Sensoren und dem Datenerfassungssystem stellen Kupferleitungen dar.<sup>18</sup> Weil diese jedoch für Hochbaustellen aufgrund sich ständig ändernder Umstände nicht geeignet sind, wird im Folgenden das Übertragungsmedium Drahtweg nicht näher erläutert. Es sei lediglich darauf hingewiesen, dass es in Hinblick auf die Störanfälligkeit verschiedene Ausführungsarten an Kabelverbindungen gibt. Weiters wird die dem Sensornetzwerk zugrunde gelegte Topologie entweder als Stern oder als Linie implementiert.<sup>19</sup>

Bei der Übertragung mittels Funk wird hingegen keine direkte Verbindung durch ein Kabel oder eine optische Faserstrecke benötigt, sondern es werden die Daten mit Hilfe von elektromagnetischen Wellen durch den Raum geschickt. Damit Funkübertragung möglich ist, müssen zuerst die Informationen auf sinusförmige Trägersignale gesetzt werden. Dies geschieht, indem die zu versendende Nachricht auf den Amplituden, den Phasen und/oder der Frequenzen des Trägers aufgeprägt werden.<sup>20</sup>

Ähnlich wie bei der Sprache ist es wichtig, dass Sender und Empfänger einander verstehen. Aus diesem Grund wurden in den vergangenen Jahren verschiedene Standards entwickelt. Nachfolgend werden drei weitverbreitete Kommunikationsmöglichkeiten auf Funkbasis vorgestellt.

ZigBee stellt einen äußerst energieverbrauchersparmen, drahtlosen Kommunikationsstandard dar und wurde erstmals im Jahr 2004 vorgestellt. Weitere Ziele, welche mit Hilfe dieses Produktes von der ZigBee Alliance, einem weltweiten Zusammenschluss von Unternehmen, verfolgt werden, sind

<sup>16</sup> Vgl.: Mehr, O.: Polysensorale Bauprozessidentifikation durch kognitive Systeme. Dissertation. Technischen Universität Darmstadt. 2012. S.117ff

<sup>17</sup> Vgl.: Elektronik Kompendium: Übertragungsmedium. <https://www.elektronik-kompendium.de/sites/kom/0211192.htm>. Datum des Zugriffs: 24.06.2020

<sup>18</sup> Vgl.: Schnellenbach-Held, M.; Karczewski, B.; Kühn, O.: Intelligente Brücke - Machbarkeitsstudie für ein System zur Informationsbereitstellung und ganzheitlichen Bewertung in Echtzeit für Brückenbauwerke. In: Brücke- und Ingenieurbau Heft B 105. Hrsg.: Bundesanstalt für Straßenwesen. 2014. S. 15

<sup>19</sup> Vgl.: Hesse, S.; Schnell, G.: Sensoren für die Prozess- und Fabrikautomation. S. 446

<sup>20</sup> Vgl.: Werner, M.: Nachrichtentechnik. S. 112

geringe Kosten sowie größtmögliche Flexibilität. Die Stärke liegt in einer gemeinsam verwendeten Sprache, welche einen einfachen Zusammenschluss verschiedener Produkte ermöglicht. Zum Hauptanwendungsbereich zählen die Automatisierung und das Monitoring in smart homes. Die Datenübertragungsrate beträgt hierbei bis zu 250 kbits pro Sekunde.<sup>21,22</sup>

Eine weitere Möglichkeit stellt die Verbindung über Bluetooth dar, welche beispielsweise bei kabellosen Mäusen oder Tastaturen eingesetzt wird. Anfangs war Bluetooth als Punkt-zu-Punkt-Verbindung konzipiert und fand unter anderem beim Datenaustausch zweier Mobiltelefone Anwendung. In den vergangenen Jahren hat sich neben Bluetooth Classic die energiesparendere Variante Bluetooth Low Energy entwickelt. Diese Technologie unterstützt auch die Mesh-Topologie, bei der die einzelnen Knoten ohne dazwischenliegendem Hub kommunizieren können, und ermöglicht eine energieeffiziente Datenübertragung zwischen 125 kbits bis hin zu 2 Mbits pro Sekunde. In den Bereichen Gesundheit und Fitness sowie bei der Echtzeitortung und innerräumlichen Navigation ist Bluetooth LE weit verbreitet.<sup>23</sup>

Bereits seit der ersten Version, welche 1999 erschienen ist, setzt Bluetooth einen Kanal im 2,4 GHz ISM<sup>24</sup>-Band mit einer Bandbreite von 1 MHz ein. WLAN (Wireless Local Area Network) benötigt hingegen bei dem gleichen Kanal eine Bandbreite von 22 MHz. Damit sich Bluetooth mit WLAN oder anderen Funktechnologien im selben Frequenzbereich nicht in die Quere kommt, wird Frequency Hopping Spread Spectrum (FHSS) angewendet. Bei diesem Verfahren wird nach jedem gesendeten Paket die Frequenz gewechselt, wodurch Störungen vermieden werden.<sup>25</sup>

Zum Ursprungsgedanken bei der Konzeptionierung von Bluetooth zählte das Ersetzen der Kabelverbindungen zwischen diversen Geräten.<sup>26</sup> Im Laufe der Zeit entwickelte sich aber dieser Standard immer weiter und ist heutzutage aus dem Alltag nicht mehr wegzudenken. Einsatzmöglichkeiten sind beispielsweise das Austauschen von Dateien, das Verbinden von Handys mit anderen Devices wie Kopfhörern, aber auch mit einem Hochdruckreiniger, oder im Bereich der Automatisierung. Ebenso findet diese Technologie bei der Ortung Anwendung, welche vor allem von der Version 5.1 profitiert, weil diese Funktionen zur Richtungserkennung beinhaltet und somit Positionsbestimmungen im dreidimensionalen Raum mit einer Genauigkeit von bis zu 10 cm ermöglicht.<sup>27</sup> Die hierbei eingesetzte Methode, welche in Abschnitt 4.4 näher erläutert wird, beruht auf dem Erfassen der Winkel der empfangenen Signale.

Durch die Einführung von Bluetooth LE (Bluetooth v4.0) im Jahr 2010 wurde ein Meilenstein in der Entwicklungsgeschichte dieser Technologie erreicht, da die Energiemenge drastisch reduziert und die Verbindungsgeschwindigkeit (auf 3 Millisekunden) erhöht wurde. Aus diesem Grund bietet Bluetooth eine gute Basis für Internet-of-Things-Anwendungen, da hierbei die Batterielaufzeit einen wesentlichen Faktor darstellt und keine großen Datenmengen verschickt werden müssen.<sup>28</sup>

<sup>21</sup> Vgl.: ZigBee Alliance: ZigBee Specification. ZigBee Document 05-3474-21. S. 5ff

<sup>22</sup> Vgl.: ZigBee Alliance: <https://zigbeealliance.org/solution/zigbee/>. Datum des Zugriffs: 26.06.2020

<sup>23</sup> Vgl.: Afaneh, M.: Wireless Connectivity Options for IoT Applications. <https://www.bluetooth.com/blog/wireless-connectivity-options-for-iot-applications-technology-comparison/>. Datum des Zugriffs: 26.06.2020

<sup>24</sup> Industrial Scientific and Medical

<sup>25</sup> Vgl.: Sauter, M.: Grundkurs Mobile Kommunikationssysteme. S. 299ff.

<sup>26</sup> Vgl.: Gupta, N.: Inside Bluetooth Low Energy. S. 6

<sup>27</sup> Vgl.: Elektronik Kompendium: <https://www.elektronik-kompendium.de/sites/kom/2107121.htm>. Datum des Zugriffs: 27.07.2021

<sup>28</sup> Vgl.: Gupta, N.: Inside Bluetooth Low Energy. S. 6ff



Das WLAN zählt zu den bekanntesten Funknetzwerken und verzeichnet seit Anfang 2000 schnell wachsende Verbreitung. Vor allem im Heim- und Bürobereich oder auch auf öffentlichen Plätzen und in Gebäuden findet die Möglichkeit eines spontanen Internetzugangs große Beliebtheit. Die Stärken liegen hierbei bei der hohen Datenübertragungsrate, welche beispielsweise für das Arbeiten, Streamen von Videos oder dem Musikhören verwendet werden kann. Mit der Fähigkeit, große Mengen an Daten zu verschicken, muss jedoch ein erhöhter Energieverbrauch in Kauf genommen werden.<sup>29</sup>

Zur Übertragung der Daten existieren hierfür verschiedene Standards. Abhängig von diesen werden unterschiedliche Datenübertragungsraten erzielt. Bei einer Frequenz von 40 MHz erreicht beispielsweise IEEE 802.11h eine Übertragungsgeschwindigkeit von 108 Mbit pro Sekunde.<sup>30</sup>

Die nachfolgende Tabelle 4-4 zeigt ausgewählte Merkmale für ZigBee, Bluetooth und WLAN und soll dadurch eine bessere Vergleichbarkeit gewährleisten.

Lfd. Nr.:	Merkmale	ZigBee	Bluetooth	WLAN
0	A	B	C	D
1	Energieverbrauch	Niedrig	Mittel	Hoch
2	Datenübertragungsrate	20 - 250 kbps	125 kbps - 2Mbps	54 Mbps - 7 Gbps
3	Distanz	30 - 100+ m	1 - 100+ m	100+ m
4	Frequenz	868 MHz, 915 MHz und 2,4 GHz	2,4 GHz	2,4 GHz und 5,8 GHz
5	Knotenpunkte	65.000	7	>1.000
6	Verwendung	Automatisierung	Kabelersatz	Internet
7	Vorteile	Verlässlichkeit, Performance, Kosten	Übertragungsrate, Flexibilität	Kosten, Komfort

Tab. 4-4 Vergleich ZigBee, Bluetooth, WLAN<sup>31, 32, 33, 34</sup>

Anhand der zuvor gezeigten Tabelle 4-4 wird rasch ersichtlich, dass die Distanz und die zu übermittelnde Datenmenge zwei wesentliche Faktoren bei der Entscheidung, welche Funktechnologie einzusetzen ist, darstellen. Abbildung 4-3 fasst die bekanntesten Übertragungsstandards unter Berücksichtigung dieser zwei Aspekte nochmals zusammen.

Anhand von Abbildung 4-3 wird auch ersichtlich, dass mittels Ultra Breitband (UWB) über kurze bis mittelkurze Distanzen eine große Datenmenge verschickt werden kann. Das nicht lizenzierte UWB-System liegt im Frequenzbereich zwischen 3,1-10,6 GHz und lässt sich prinzipiell in drei Anwendungsbereiche, zu denen Kommunikation, Lokalisierung und Bildgebung sowie Sensorik zählen, einteilen.<sup>35</sup>

<sup>29</sup> Vgl.: Werner, M.: Nachrichtentechnik. S. 331

<sup>30</sup> Vgl.: Colhoun O.: WLAN. In: Lexikon der Medizinischen Laboratoriumsdiagnostik. S. 2514

<sup>31</sup> Vgl.: Varga, A. K.: ZigBee based wireless sensor networks. Konferenz: International scientific conference on advances in mechanical engineering, proceedings, 2014. S. 175

<sup>32</sup> Vgl.: Zahurul, S. et al.: Future strategic plan analysis for integrating distributed renewable generation to smart grid through wireless sensor network: Malaysia prospect. In Renewable and Sustainable Energy Reviews, 53. 2016. S. 984

<sup>33</sup> Vgl.: Afaneh, M.: Wireless Connectivity Options for IoT Applications. <https://www.bluetooth.com/blog/wireless-connectivity-options-for-iiot-applications-technology-comparison/>. Datum des Zugriffs: 26.06.2020

<sup>34</sup> Vgl.: Colhoun O.: WLAN. In: Lexikon der Medizinischen Laboratoriumsdiagnostik. S. 2514

<sup>35</sup> Vgl.: Dehner, H.-U.: Interferenzuntersuchungen für inkohärente Multiband Ultra-Breitband (UWB) Übertragung. Dissertation. Institut für Nachrichtentechnik am Karlsruher Institut für Technologie. 2012. S. 8ff

Der GSM-Standard (Global System for Mobile Communications) stellt die zweite Generation (2G) des Mobilfunkstandards dar und ermöglicht erstmals neben dem Telefonieren und SMS-Schreiben, die mobile Datenübertragung. Heutzutage existiert bereits 5G mit seither deutlich gesteigerten Übertragungsraten, jedoch findet 2G aufgrund der nahezu flächendeckenden Infrastruktur noch immer Anwendung.<sup>36</sup>




Abb. 4-3 Datenrate und Reichweite ausgewählter Funktechnologien<sup>37</sup>

Abschließend wird noch auf LoRaWAN, ein Niedrigenergienetzwerk für drahtlose, batteriebetriebene Systeme, eingegangen. Die hierbei typischerweise eingesetzte Netzwerkarchitektur ist die Sterntopologie, bei der zwischen den Endgeräten und dem zentralen Netzwerkserver Gateways Anwendung finden. Die übermittelbare Datenrate liegt zwischen 0,3 kbps und 50 kbps.<sup>38</sup>

Im Spannungsdreieck für Funktechnologien (Reichweitenmaximierung, Optimierung des Energieverbrauchs und Datenübertragung) zeichnet sich LoRaWAN vor allem durch die ersten zwei Ziele aus. Daher können zwar nur sehr geringe Datenmengen, diese aber energieeffizient und über eine große Distanz übertragen werden. In unbebautem Gebiet erzielen LoRaWAN Gateways in der Praxis eine Reichweite von rund 15 km. Reflexionen, Brechungen oder Dämpfungen von Gebäuden wirken sich jedoch negativ aus, wodurch im städtischen Bereich die Übertragungsdistanz auf 2 bis 4 km sinkt. Werden Daten beispielsweise aus einem Keller heraus geschickt, wird durch die zusätzliche Dämpfung nochmals die Reichweite reduziert. Bei der Umsetzung solcher Aufgabenstellungen kann nach bisherigen Erfahrungen eine Übertragungsdistanz von rund einem Kilometer als Faustformel angenommen werden.<sup>39</sup>

<sup>36</sup> Vgl.: <https://www.sparhandy.de/mobiles-internet/info/mobilfunkstandards/>. Datum des Zugriffs: 27.12.2021

<sup>37</sup> In Anlehnung an: Gupta, N.: Inside Bluetooth Low Energy. S. 3

<sup>38</sup> Vgl.: <https://www.lora-wan.de/>. Datum des Zugriffs: 29.07.2021

<sup>39</sup> Vgl.: Linnemann, M.; Sommer, A.; Leufkes, R.: Einsatzpotentiale von LoRaWAN in der Energiewirtschaft. S. 28

### 4.3 RFID – Radio-Frequency Identification

Folgender Unterpunkt behandelt die theoretischen Grundlagen der RFID-Technologie (radio frequency identification). Nach einer kurzen Darstellung der Anwendungsgebiete werden die einzelnen Komponenten sowie verschiedene Einteilungen dieser Technologie beleuchtet.

Die Radiofrequenzidentifikation gehört neben dem Barcode zu den automatischen Identifikationssystemen und ermöglicht ein kontaktloses Erkennen von Einzelteilen. Wesentliche Einsatzmöglichkeiten stellen Produktidentifikationen, Zugangskontrollen, elektrische Wegfahrsperrern, Zeitmessungen bei Sportveranstaltungen, Tier- oder Behälteridentifikationen sowie Industrieautomationen dar. Bei dieser Vielzahl an Anwendungen sind RFID-Chips unter anderem in Chipkarten, Paletten/Kartons, Bekleidungen, Bücher, Pässe, Eintrittskarten, Autoschlüsseln und im Flugzeuggepäck anzutreffen.<sup>40</sup>

Damit eine automatische Identifizierung berührungslos und sichtkontaktfrei durchgeführt werden kann, muss am gewünschten Objekt ein Datenträger angebracht werden. Dieser wird RFID-Transponder (Tag) genannt und besteht aus Mikrochip, Antenne und einem Trägerelement. Gelangt ein solcher Tag in die Reichweite eines RFID-Lesegeräts (RFID-Reader) wird er erkannt und Daten können unter Zuhilfenahme eines vorgegebenen Taktes ausgetauscht werden. Die Energieübertragung erfolgt hierbei über elektromagnetische Wellen oder einer magnetischen Kopplung.<sup>41</sup>

Die ausgelesenen Transponderinhalte werden anschließend durch geeignete Informationssysteme (Middleware) aufbereitet. In diesem Schritt erfolgt die Transformation von Verfügungswissen in Orientierungswissen, welches in weiterer Folge im Wissensspeicher abgelegt wird. Durch die gezielte Filterung der erhobenen Daten wird sichergestellt, dass bei einem Zugriff auf den Datenspeicher nur die essentiellen kontextbezogenen Informationen abgerufen werden können. Die nachfolgende Abbildung 4-4 verdeutlicht den soeben beschriebenen Systemaufbau.

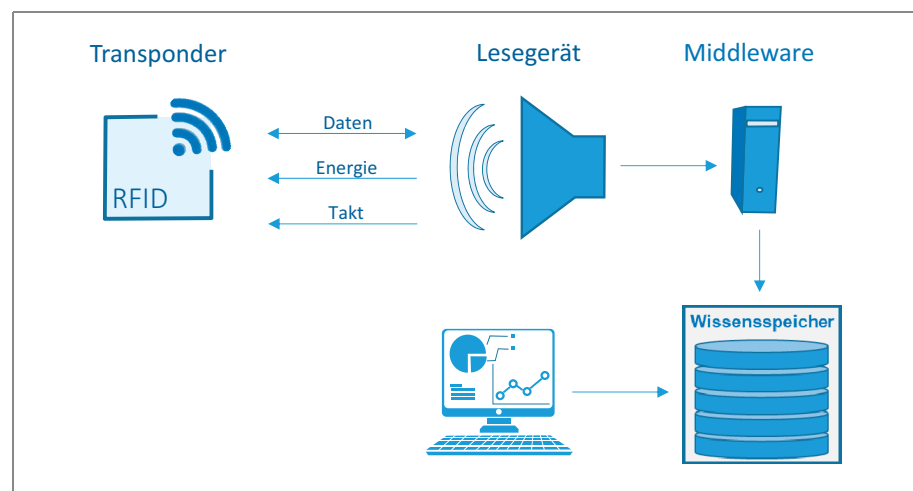


Abb. 4-4 RFID-Komponenten

<sup>40</sup> Vgl.: Tamm, G.; Tribowski, C.: RFID. Informatik im Fokus. S. 2f

<sup>41</sup> Vgl.: Helmus, M. et al.: RFID-Baugistikleitstand. S. 5f

RFID-Transponder weisen unterschiedliche Bauformen, welche wesentlich vom Verwendungszweck abhängen, auf. Sie reichen beispielsweise von Etiketten bis hin zu Schlüsselanhängern oder Uhren. Bei Tieridentifikationen ist es üblich, die Transponder in kleine Glasröhrchen zu verpacken und unter die Haut zu schieben. Bei härteren Umfeldbedingungen wie zum Beispiel auf Baustellen ist ein Kunststoffgehäuse, das vor Staub und mechanischer Beanspruchung schützt, zu empfehlen. Weiters werden die Transponder nach EPCglobal (Industriekonsortium) anhand deren Energieversorgung und Beschreibbarkeit in sechs Kategorien (0-5) gegliedert. Die ersten drei Klassen stehen passiven Tags zur Verfügung, welche ihre Energie aus dem Feld des Lesegerätes übernehmen. Zur Klasse 3 gehören semi-aktive und zur Klasse 4 und 5 aktive Transponder.<sup>42</sup>

Klasse 0 beinhaltet nicht beschreibbare Tags, welche nur ausgelesen werden können (Read Only). Klasse 1 ermöglicht nach einmaligem Beschreiben eines Transponders nur noch das Erkennen (Write Once, Read Multiple), während Klasse 2 wiederbeschreibbare Tags (Read & Write) beinhaltet.<sup>43</sup>

Kategorie 3 ist durch eine eigene Energiequelle charakterisiert, welche für das Versorgen des Mikrochips eingesetzt wird. Weil für das Senden und Empfangen der Daten nach wie vor die Energie des Lesegeräts genutzt wird, tragen diese Tags die Bezeichnung semi-aktiv. Klasse 4 und 5 zählen zu den aktiven Transpondern. Das heißt, sie verwenden die eigene Energiequelle sowohl für den Chip, als auch für die Übertragung der Daten. Der Unterschied zwischen den beiden Klassen liegt in der Fähigkeit, mit passiven Tags zu kommunizieren.<sup>44</sup>

Um die Energiequelle zusammenzufassen, wird Abbildung 4-5 gezeigt. Hierbei ist es wichtig, hervorzuheben, dass mit einer zusätzlichen Stromversorgung die Reichweite stark ansteigt. Dafür sinkt die Lebensdauer des Tags, weil nach Entladung der Batterie keine Daten mehr versendet werden können.

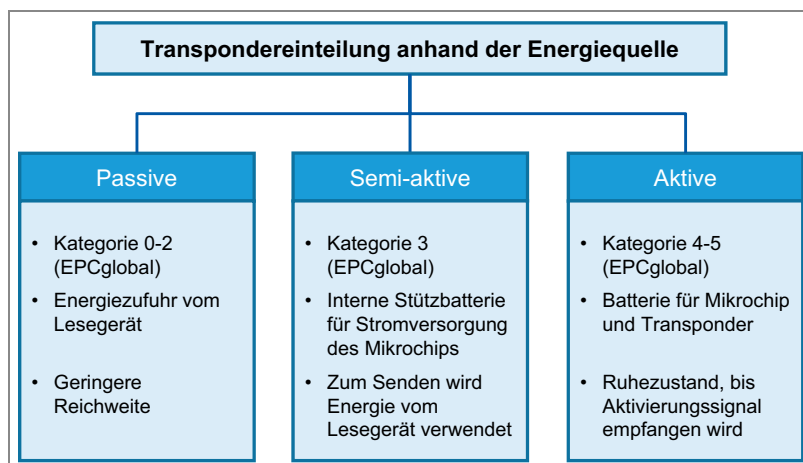


Abb. 4-5 Transpondereinteilung anhand der Energiequelle<sup>45</sup>

Die nachfolgende Tabelle 4-5 verdeutlicht die Unterschiede bei der Transpondereinteilung anhand der Energiequelle in Bezug auf ausgesuchte Merkmale. Die Lesedistanz, die Lesezuverlässigkeit sowie die Speicherkapazität nimmt

<sup>42</sup> Vgl.: Tamm, G.; Tribowski, C.: RFID. S. 15f

<sup>43</sup> Vgl.: Hompel, M.; Heidenblut V.: Taschenlexikon Logistik. S. 81

<sup>44</sup> Vgl.: Tamm, G.; Tribowski, C.: RFID. S. 15f

<sup>45</sup> Vgl.: Bundesnetzagentur: RFID, das kontaktlose Informationssystem. <https://emf3.bundesnetzagentur.de/pdf/RFID-BNetzA.pdf>. Datum des Zugriffs 19.05.2020

durch die Zuhilfenahme einer eigenen Energiequelle zu. Damit geht jedoch eine größere Bauform, eine kürzere Lebenserwartung und ein Anstieg der Kosten einher. Vor der Implementierung eines RFID-Systems ist es wichtig, diese Punkte zu analysieren, damit in Abhängigkeit der gewünschten Funktion und der Einsatzdauer der passende Transponder ausgewählt werden kann.

Lfd. Nr.:	Merkmale/System	Passiv	Semi-aktiv	Aktiv
0	A	B	C	D
1	Lesedistanz	gering	gering	groß
2	Lesezuverlässigkeit	hoch	sehr hoch	sehr hoch
3	Lebensdauer	lang	mittel	kurz
4	Speicherkapazität	gering	hoch	hoch
5	Bauform	klein	mittel	groß
6	Sensorik	möglich	möglich	möglich
7	Kosten	gering	mittel	hoch

Tab. 4-5 Merkmale der Transpondereinteilung anhand der Energiequelle<sup>46</sup>

Das Lesegerät stellt die Verbindung zwischen der Middleware und den Transpondern dar. Zu dessen Aufgaben zählen, die empfangenen Steuerbefehle auszuführen, die Verbindung zu den Transpondern herzustellen, die Antikollision und Authentifizierung zu gewährleisten, Daten des Tags auszulesen sowie diese zu beschreiben und Sleep- oder Wakeup-Signale zu verschicken. Die Form des Lesegerätes ist wie auch der Tag von der Art der Anwendung abhängig. Hierbei gibt es zwei wesentliche Varianten: Sind die Antenne und das Lesegerät in einem handlichen Gehäuse integriert, wird von einem mobilen Lesegerät gesprochen. Sind die beiden Bauteile hingegen räumlich voneinander getrennt, werden diese als stationär bezeichnet. Typische Einsatzbereiche stellen hierfür Tore dar. Verlässt die Ware die Lagerhalle, wird sie bei der Durchfahrt automatisch detektiert.<sup>47</sup>

Aus der obigen Erklärung ist ersichtlich, dass die Distanz zu den wichtigsten Aspekten bei der Entscheidung über die zu verwendenden Transponder gehört. Aus diesem Grund zeigt die nachfolgende Abbildung 4-6, wie die RFID-Technologie anhand deren Reichweite eingeteilt werden kann.

Grundsätzlich gilt: je größer die Entfernung, desto größer die Kosten, da die Magnetfelder entsprechend verstärkt werden müssen. Weiters steigt mit zunehmender Distanz die Wahrscheinlichkeit, auf Störeinflüsse wie beispielsweise Metalle oder Wasser zu treffen, welche die elektromagnetischen Wellen reflektieren oder absorbieren. Anhand der Reichweite werden drei Coupling-Klassen charakterisiert. Die erste wird Close Coupling genannt und beinhaltet eine Distanz von 0 bis 1 cm. Die Entfernung ist dermaßen gering, dass der Transponder entweder in das Lesegerät hineingesteckt oder auf eine genaue Position gelegt werden muss. Als Vorteil ist hierbei anzumerken, dass durch die enge Kopplung größere Energiemengen transportiert und höchste Sicherheitsvorkehrungen eingehalten werden können. Der zugrundeliegende Frequenzbereich erstreckt sich von 1 Hz bis 30 MHz, wobei die Datenübertragung durch induktive oder kapazitive Kopplung erfolgt.<sup>48</sup>

<sup>46</sup> Adam Melski: Grundlagen und betriebswirtschaftliche Anwendung von RFID. Arbeitsbericht Nr. 11/2006 Hrsg.: Matthias Schumann. S. 10

<sup>47</sup> Vgl.: Tamm, G.; Tribowski, C.: RFID. S. 17f

Der zweite Bereich reicht bis zu einem Meter und wird als Remote Coupling bezeichnet. Die Datenübertragung wird hierbei über eine induktive Kopplung erreicht, wobei die Transponder meistens passiver Natur sind. Eingesetzte Übertragungsfrequenzen sind 100 kHz, 135 kHz, 6,75 MHz, 13,56 MHz, und 27,125 MHz. Die dritte Klasse wird Long Range Coupling genannt und deckt den Bereich größer als einen Meter ab. Die hierbei eingesetzten Frequenzen liegen im Mikrowellenbereich, wobei die Datenübertragung mittels Backscatterverfahren durchgeführt wird. Aufgrund der hohen Reichweite reicht die gesendete Energie nur noch für einen Wakeup oder Sleep Call aus, weshalb der Transponder mit zusätzlicher Energie versorgt werden muss. Die nachfolgende Abbildung 4-6 fasst die soeben beschriebenen Kategorien übersichtlich zusammen.<sup>49</sup>

Die unterschiedlichen Frequenzen spielen bei der Reichweite eine bedeutende Rolle. Die am häufigsten verwendeten Frequenzen liegen in den lizenzfreien ISM-Bändern (Industrial-Scientific-Medical) und werden in vier für RFID typische Bereiche gegliedert. Der niederfrequente Bereich (LF) erstreckt sich von 100-135 kHz. Zur Hochfrequenz (HF) zählen 6,78 MHz, 13,56 MHz und 27,125 MHz. Eine Stufe darüber ist der ultrahochfrequente Bereich (UHF) angesiedelt. Dieser beinhaltet 433,92MHz, 868 MHz (Europa) und 915 MHz (USA). Den Abschluss bildet die vierte Klasse, welche die Mikrowellenstrahlung beinhaltet. Hierzu gehören 2,45 GHz und 5,8 GHz.<sup>50</sup>

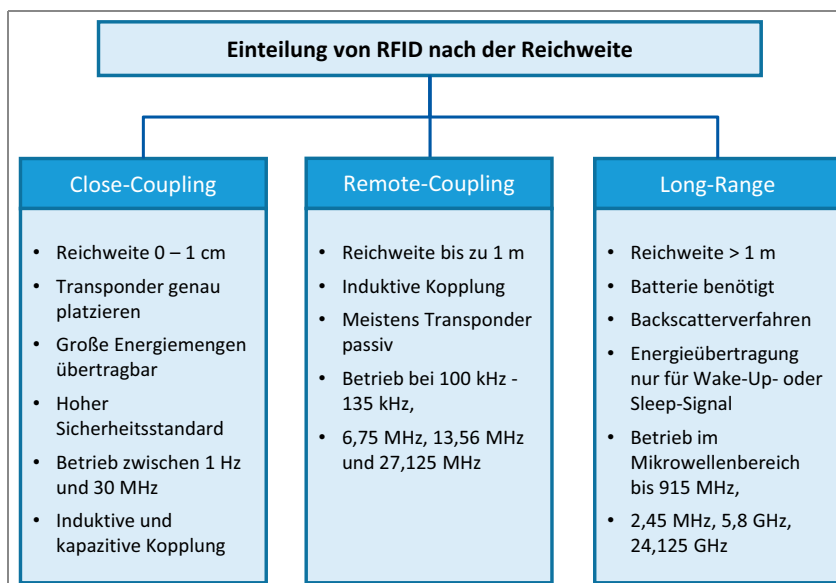


Abb. 4-6 Einteilung anhand der Reichweite<sup>51</sup>

Im Niederfrequenz- und Hochfrequenzbereich erfolgt der Datentransfer über induktive Kopplungen. Hierbei ist der Transponder im Nahfeld der Antenne des Lesegerätes und wird über das Wechselfeld mit Energie versorgt. Dieser Bereich ist dadurch charakterisiert, dass der Abstand zwischen Sender und Empfänger

<sup>48</sup> Vgl.: RFID Grundlagen Das RFID Informationsportal: RFID Reichweite. <https://www.rfid-grundlagen.de/reichweite.html>. Datum des Zugriffs: 19.05.2020

<sup>49</sup> Vgl.: RFID Grundlagen Das RFID Informationsportal: RFID Reichweite. <https://www.rfid-grundlagen.de/reichweite.html>. Datum des Zugriffs: 19.05.2020

<sup>50</sup> Vgl.: Bundesnetzagentur: RFID, das kontaktlose Informationssystem. <https://emf3.bundesnetzagentur.de/pdf/RFID-BNetzA.pdf>. Datum des Zugriffs 19.05.2020

<sup>51</sup> Vgl.: RFID Grundlagen Das RFID Informationsportal: RFID Reichweite. <https://www.rfid-grundlagen.de/reichweite.html>. Datum des Zugriffs: 19.05.2020

im Vergleich zur Wellenlänge des elektromagnetischen Feldes klein ist. Mit Hilfe eines an der Antenne anliegenden Lastwiderstandes, welcher im Rhythmus der zu übertragenden Daten ein- und ausgeschaltet wird, ruft der Transponder eine Spannungsänderung an der Antenne des Lesegerätes hervor. Diese wird in weiterer Folge von der Auswerteeinheit detektiert und aufbereitet.<sup>52</sup>

Ultrahochfrequenz wird eingesetzt, um große Distanzen zu überbrücken. Hierbei erfolgt die Übertragung mittels Backscatter-Verfahren (Rückstreuung). Zur Generierung eines Signals wird wie zuvor vom Chip eine aus der Antenne generierte Hochfrequenzspannung verwendet. In diesem Fall werden jedoch keine Spulen und Ferritkerne, sondern Dipolantennen eingesetzt. Weiters beruht das Backscatter-Prinzip nicht auf dem Zurücksenden, sondern auf dem Reflektieren der vom Lesegerät ausgesandten elektromagnetischen Wellen. Diesem Verfahren aus der Radar-Technik liegt zugrunde, dass jedes Material, dessen Abmessungen größer sind als die halbe Wellenlänge des ausgesandten Radarstrahls, diesen zurückwirft, sprich reflektiert. Besonders gut geschieht dies, wenn das angefunkte Objekt mit der elektromagnetischen Welle in Resonanz steht. Die Informationsübertragung basiert nun darauf, dass die Rückstrahleigenschaften an der Transponderantenne geändert werden. Das bedeutet, dass die Antenne des Transponders abwechselnd in guter und weniger guter Resonanz steht. Dieser Effekt wird durch wechselweises Zu- und Abschalten eines Lastwiderstandes erzielt.<sup>53</sup>

Tabelle 4-6 verdeutlicht die Unterschiede der soeben beschriebenen Frequenzbereiche anhand ausgewählter Kriterien. Aus dieser Tabelle geht hervor, dass die Wahl der eingesetzten Frequenz eine wesentliche Bedeutung für die Gewährleistung der Funktion und somit in weiterer Folge für das Erreichen des Projektziels hat.

Lfd. Nr.:	Eigenschaft	LF – Low Frequency	HF – High Frequency	UHF – Ultra High Frequency
0	A	B	C	D
1	Energieversorgung	passiv	passiv	passiv/aktiv
2	Reichweite	weniger als 1 m	max. 1,7 m	max. ca. 6 m (passiv) max. ca. 100 m (aktiv)
3	Übertragungsrage	niedrig	mittel	hoch
4	Störung durch Flüssigkeiten	kein Einfluss	geringer Einfluss	starker Einfluss
5	Störung durch Metall	starker Einfluss	starker Einfluss	sehr starker Einfluss
6	Ausrichtung des Transponders	nicht nötig	nicht nötig	teilweise nötig

Tab. 4-6 Einteilung anhand der Frequenzen<sup>54</sup>

An dieser Stelle ist anzumerken, dass es keine ideale Frequenz für ein allgemeines RFID-System gibt. Aus diesem Grund haben sich in Abhängigkeit der Anwendung verschiedene Frequenzbereiche als vorteilhaft herauskristalli-

<sup>52</sup> Vgl.: Bundesnetzagentur: RFID, das kontaktlose Informationssystem. <https://emf3.bundesnetzagentur.de/pdf/RFID-BNetzA.pdf>. Datum des Zugriffs: 19.05.2020

<sup>53</sup> Vgl.: Kern, C.: Anwendung von RFID-Systemen. S. 55ff

<sup>54</sup> RFID Grundlagen Das RFID Informationsportal: RFID Frequenzen. <https://www.rfid-grundlagen.de/frequenzen.html>. Datum des Zugriffs: 19.05.2020

siert. Grundsätzlich werden elektromagnetische Wellen immer besser mit sichtbarem Licht vergleichbar, je höher die Frequenz ist. Damit geht einher, dass die Reflexionen zunehmen und die Verluste bei der Durchdringung gewisser Medien steigen. Dies ist beispielsweise bei Wasser sehr deutlich zu erkennen. Hierbei wird die Energie der elektromagnetischen Welle in Wärme umgewandelt (Mikrowelle). Aus diesem Grund sind ultrahohe Frequenzen bei der Detektion von Gegenständen, die Wasser enthalten, ungeeignet. Die Dämpfung ist einfach zu groß. Auch organische Körper reduzieren die Signalstärke, weshalb bei der Tieridentifikation der LF-Bereich eingesetzt wird.<sup>55</sup>

Somit sind die Materialeigenschaften der im Strahlungsfeld situierten Objekte neben der Lesedistanz ein weiterer wichtiger Aspekt, den es bei der Auswahl der Frequenz zu beachten gilt. Bei nicht leitfähigen Stoffen ist die Dämpfung der elektromagnetischen Welle von der Dichte des Materials abhängig. Das Reflexionsvermögen wird durch die Dielektrizitätskonstante beschrieben. Das heißt, Materialien, die bei diesen zwei Parametern niedrige Werte aufweisen wie beispielsweise PVC, beeinflussen die Ausbreitung der Welle nur minimal. Bei leitfähigen Stoffen (Metall) kommt es hingegen zur Totalreflexion. Durch das ungewollte Umlenken der Strahlung kann es sein, dass die reflektierte elektromagnetische Welle auf eine von der Antenne abgestrahlte trifft. In diesem Fall wird von Interferenzen gesprochen und führt in weiterer Folge zu einer Feldverstärkung oder -abschwächung. Wird aufgrund einer Feldschwächung ein Transponder mit zu wenig Energie versorgt, kann dessen Antenne kein Signal zurückstrahlen, wodurch der RFID-Tag nicht erkannt wird. An dieser Stelle muss jedoch festgehalten werden, dass Reflexionen von vornherein nicht als schlecht angesehen werden müssen. Als positive Auswirkung ist hervorzuheben, dass sie es ermöglichen, Transponder im Schatten von anderen Objekten zu detektieren, weil die Wellen herumgeleitet werden.<sup>56</sup>

Aus den soeben beschriebenen Einflüssen der Materialien der Objekte im elektromagnetischen Feld wird ersichtlich, dass die Baustelle kein einfaches Anwendungsgebiet darstellt. Metallschalungen, Stahlträger, Stützen, Baugeräte oder Stahlbetonwände erschweren die Ausbreitung der Wellen. Solange keine Geschossdecke auf dem aktuell obersten Stockwerk betoniert wurde, ist die horizontale Ausbreitung stärker beeinträchtigt als die vertikale. Aus diesem Grund wird empfohlen, die Sende- und Empfangsantennen auf einer höher gelegenen Ebene zu installieren. Am besten wäre Sichtkontakt. Dadurch wird zumindest auf der obersten Ebene eine geringere Fehleranfälligkeit erzielt.

Neben dem Transponder und dem Lesegerät stellt die Middleware den letzten wesentlichen Bestandteil eines RFID-Systems dar. Diese Softwarekomponente ermöglicht das Aufbereiten und Bereitstellen von RFID-Daten. Daher beziehen sich die Hauptaufgaben auf die Bereinigung, Aggregation und Transformation der erhobenen Werte. Hierbei ist das Filtern besonders wichtig, weil die empfangenen Daten redundant (ein Transponder wird in einem Zeitfenster oder von mehreren Antennen öfters erfasst) beziehungsweise fehlerhaft sein können. Ein Fehler tritt auf, wenn Tags im vorgesehenen Lesefeld nicht oder beispielsweise durch Reflexionen außerhalb von

<sup>55</sup> Vgl.: Kern, C.: Anwendung von RFID-Systemen. S. 41ff

<sup>56</sup> Vgl.: Helmus, M. et al.: RFID-Baustandards. S. 9f



diesem detektiert werden. Eine weitere Aufgabe der Middleware stellt das Verwalten der Lesegeräte dar. Die Offenheit bezüglich des Hinzufügens neuer Komponenten sowie nichtbenötigte Komplexitäten zu reduzieren, steht hierbei im Mittelpunkt.<sup>57</sup>

Bewegen sich mehrere Transponder in einem Feld, ist es erforderlich, diese beim Auslesen auseinanderzuhalten, um mit ihnen einzeln kommunizieren zu können. Dieser Vorgang wird Antikollision genannt. Das Broadcast-Verfahren stellt die einfachste Möglichkeit der Kommunikation mit Transpondern dar. Hierbei wird wie bei einem Radiosender ein Signal an alle Tags (Zuhörer) ausgeschickt. Der umgekehrte Ablauf, sprich das Zugreifen der verschiedenen Transponder auf das Lesegerät, wird Mehrfachzugriff genannt und gestaltet sich deutlich komplizierter. Damit trotz gleichzeitigem Antworten erkannt wird, ob es ein oder mehrere Signale sind, gilt es, diese zu differenzieren. Hierbei haben sich vier Multiplexverfahren herauskristallisiert. Diese unterscheiden sich zeitlich, in der Frequenz, räumlich oder in der Kodierung und können entweder einzeln oder in Kombination gewählt werden.<sup>58</sup>

Das Frequenzmultiplexverfahren (FDMA) zählt zu den wirkungsvollsten, da ein gleichzeitiges Senden der Tags ermöglicht wird. Es ist jedoch durch die Anzahl der Kanäle – wie bei einem Sprechfunkgerät – beschränkt. Dem Zeitmultiplexverfahren (TDMA) liegt zugrunde, dass Zeitfenster genutzt werden, in denen jeweils nur ein Transponder mit dem Lesegerät kommuniziert. Weiters wird es durch den Tag gesteuert, welcher kleine Datenpakete wiederholend in bestimmten Zeitabständen versendet. Bei dem Raummultiplexverfahren (SDMA) wird versucht, nur einzelne Transponder in den Lesebereich zu bekommen. Dies kann durch gezielte Ausrichtungsveränderung des Lesefeldes oder durch sich bewegende Tags erreicht werden. Ebenso ist es erdenklich, einen Raum mit mehreren Antennen und Lesegeräten auszustatten, damit jeder Transponder genau lokalisiert werden kann. Das Codemultiplexverfahren (CDMA) ist das am besten entwickelte Antikollisionsverfahren. Hierbei werden die Signale der Transponder analysiert, um sie selektiv auszuschalten, bis nur noch mit einem kommuniziert werden kann. Nach dem Datentransfer wird der Tag deaktiviert und die Suche beginnt von vorne, bis alle Transponder eingelesen wurden. Dies ermöglicht es, beliebig viele Tags in einem Feld zu erkennen.<sup>59</sup>

Nachfolgend wird kurz auf den zu Beginn erwähnten Barcode eingegangen, indem die Unterschiede zwischen diesem und RFID-basierten automatischen Informationssystemen beleuchtet werden. Tabelle 4-7 zeigt hierfür einen Vergleich anhand ausgewählter Aspekte.

Unumstritten ist, dass das sichtkontaktfreie Auslesen, das gleichzeitige Erkennen verschiedener Transponder, das Speichern von Daten auf dem Chip und die Kombinationsmöglichkeit mit Sensoren zu den wesentlichen Vorteilen dieser Technologie im Vergleich zu anderen Identifikationstechniken zählen. Jedoch muss für jeden Prozess separat beurteilt werden, ob diese positiven Eigenschaften auch wirklich den erhofften Mehrwert schaffen.<sup>60</sup>

<sup>57</sup> Vgl.: Tamm, G.; Tribowski, C.: RFID. S. 20f

<sup>58</sup> Vgl.: Kern, C.: Anwendung von RFID-Systemen. S. 63f

<sup>59</sup> Vgl.: Kern, C.: Anwendung von RFID-Systemen. S. 65f

<sup>60</sup> Vgl.: Helmus, M. et al.: RFID-Baustandards. S. 11f

Lfd. Nr.:	Merkmale	Barcode	RFID
0	A	B	C
1	Datendichte	gering	sehr hoch
2	Manuelle Lesbarkeit	bedingt	unmöglich
3	Witterungseinflüsse	sehr stark	gering
4	Einfluss von optischer Abdeckung	nicht lesbar	lesbar
5	Einfluss der Medienausrichtung	hoch	mäßig
6	Abnutzung/Verschleiß	bedingt	Kein Einfluss
7	Anschaffungskosten Elektronik	sehr gering	mittel
8	Lesegeschwindigkeit	langsam	schnell
9	Veränderbarkeit der Daten auf dem Datenträger	nicht möglich	möglich
10	Pulkfähigkeit	bedingt möglich	möglich
11	Anbindung von Sensorik	nicht möglich	möglich

Tab. 4-7 Vergleich Barcode und RFID<sup>61</sup>

Dem Barcode setzen im Gegensatz zu RFID Schmutz, Feuchtigkeit und Hitze viel stärker zu als Metall und Flüssigkeiten.<sup>62</sup> Dies ist auf die zwei Funktionsprinzipien des Barcodelesegerätes zurückzuführen, welchen die Abtastung durch einen Laserstrahl oder die Bilderfassung mittels einer Kamera zugrunde liegt.<sup>63</sup> Dies wirkt sich jedoch in weiterer Folge wiederum positiv auf die Gefahr der Manipulation, des unberechtigten Löschens oder Kopierens von Daten sowie des unbemerkten Auslesens aus.<sup>64</sup>

Die Hauptanwendung der soeben vorgestellten RFID-Technologie ist in der Objektidentifikation von Waren und Gütern zu finden. Bei Einsätzen in der modernen Industrie kommt jedoch immer häufiger der Wunsch auf, zusätzlich physikalische Parameter wie beispielsweise Temperatur, relative Luftfeuchtigkeit oder Druck mittels Sensoren zu erheben. Bei der Übertragung wird meistens erwartet, dass diese kontaktlos erfolgt, da oftmals die Anbringung von Kabeln aufgrund unzugänglicher Bereiche oder sich bewegender Elemente nicht möglich ist. Bei solchen Aufgabenstellungen stellt die Kombination aus energieeffizienten Sensoren mit standardkonformen RFID-Protokollen eine ideale Lösungsmöglichkeit dar. Die hierfür benötigte Energie beim Erfassen der Sensorwerte wird zur Gänze von RFID-Readern geliefert. Aufgrund dieser Versorgung werden keine Energiespeicher benötigt, wodurch die passiven Sensortransponder vollständig wartungsfrei sind.<sup>65</sup>

<sup>61</sup> Vgl.: Helmus, M. et al.: RFID-Bauleistungsstand. S. 12

<sup>62</sup> Vgl.: Adam Melski: Grundlagen und betriebswirtschaftliche Anwendung von RFID. Arbeitsbericht Nr. 11/2006 Hrsg.: Matthias Schumann. S. 21

<sup>63</sup> Vgl.: Kern, C.: Anwendung von RFID-Systemen. S. 36

<sup>64</sup> Vgl.: Helmus, M. et al.: RFID-Bauleistungsstand. S. 12

<sup>65</sup> Vgl.: Fraunhofer IPMS: Mit RFID-Sensorik in die Cloud. [https://www.silicon-saxony.de/fileadmin/user\\_upload/RFID-Seite/RFID-Sensorik\\_d\\_Web.pdf](https://www.silicon-saxony.de/fileadmin/user_upload/RFID-Seite/RFID-Sensorik_d_Web.pdf). Datum des Zugriffs: 29.05.2020

In den batterielosen Sensorsystemen, welche die Frequenzbereiche LF, HF und UHF abdecken, lassen sich beispielsweise ein Temperatur-, Luftdruck-, Luftfeuchtigkeits-, Feuchtigkeits-, Licht-, Beschleunigungs- und Kraftsensor integrieren.<sup>66</sup> Die Anbindung diverser Sensoren kann hierbei sowohl mittels analoger Schnittstellen für resistive, induktive und kapazitive Messfühler als auch über digitale Schnittstellen, welche dem Nutzer einen einfacheren Umgang mit den Sensormodulen ermöglichen, erfolgen.<sup>67</sup>

Zu den Einsatzgebieten von solchen Sensortranspondern zählen beispielsweise das Überwachen von Gebäuden oder der Umwelt, die Ortung von Objekten mit gleichzeitiger Parametererhebung sowie das Aufnehmen des Gesundheitszustandes und durchgeführter Bewegungen von Mensch und Tier. Im Gebäudemonitoring werden durch diese Sensoren unter anderem Deformationen, Setzungen, Risse, Korrosion oder Belastungen ermittelt und bewertet. Beliebte umweltspezifische Messgrößen stellen die Temperatur, die relative Luftfeuchtigkeit, der Wasserstand oder die Konzentration bestimmter Gase dar. Ebenso werden Sensortransponder gezielt für das Erkennen von Kühlkettenunterbrechungen bei Lebensmitteltransporten eingesetzt.<sup>68</sup>

Wie bei allen RFID-Anwendungen hat die Lesedistanz, welche in engem Zusammenhang mit der verwendeten Frequenz und der damit übertragbaren Energie steht, eine wesentliche Bedeutung. Werden Sensoren über passive Transponder angesteuert, muss ein besonderes Augenmerk auf den Energiebedarf der Messfühler gelegt werden.<sup>69</sup> Die nachfolgende Tabelle 4-8 fasst die wichtigsten Merkmale in Abhängigkeit verschiedener Frequenzen zusammen. Im LF-Bereich ist zwar die geringste Lesedistanz vorhanden, jedoch wird damit die höchste Energieübertragung ermöglicht. Die Datenübertragungsrate ist hierbei sehr gering, dafür wird von Wasser keine Störung hervorgerufen und nur ein mittlerer Einfluss von Metallen ist zu vernehmen.

Lfd. Nr.:	Merkmale	125 kHz (LF)	13,56 MHz (HF)	860-960 MHz (UHF)
0	A	B	C	D
1	Typische Lesereichweite	bis 0,5 m	bis 0,8 m	bis 3 m
2	Einfluss Metall	mittel	hoch	hoch
3	Einfluss Wasser	Keine	mittel	hoch
4	Typische Datenübertragungsraten	bis 4 kB/s	bis 848 kB/s	bis 640 kB/s
5	Powerbudget für Sensor	bis 10 mW	bis 2 mW	bis 300 µW

Tab. 4-8 Sensormerkmale in Abhängigkeit von der Frequenz<sup>70</sup>

<sup>66</sup> Vgl.: Fraunhofer IPMS: <https://www.ipms.fraunhofer.de/de/research-development/wireless-microsystems/rfid-sensor-systems/rfid-sensors.html>. Datum des Zugriffs: 27.05.2020

<sup>67</sup> Vgl.: Deicke, F.: RFID-Sensoren für das Internet der Dinge. <https://www.all-electronics.de/rfid-sensoren-fuer-das-internet-der-dinge/>. Datum des Zugriffs: 29.05.2020

<sup>68</sup> Vgl.: Meng, Z.; Li, Z.: RFID Tag as a Sensor - A Review on the Innovative Designs and Applications. In: Measurement Science Review, 16 (6), 2016. S. 309

<sup>69</sup> Vgl.: Vgl.: Deicke, F.: RFID-Sensoren für das Internet der Dinge. <https://www.all-electronics.de/rfid-sensoren-fuer-das-internet-der-dinge/>. Datum des Zugriffs: 29.05.2020

<sup>70</sup> Vgl.: Deicke, F.: RFID-Sensoren für das Internet der Dinge. <https://www.all-electronics.de/rfid-sensoren-fuer-das-internet-der-dinge/>. Datum des Zugriffs: 29.05.2020

## 4.4 Ortung

Neben den physikalischen Eigenschaften sind vor allem die Positionen von Materialien, Geräten oder Arbeitskräften für einen effektiven und effizienten Baubetrieb von großer Bedeutung. Aktuell findet die Positionsbestimmung vor allem bei Vermessungen stationärer Objekte Anwendung, wobei die Erfassung bewegter Gegenstände auf der Baustelle aufgrund technologischer Entwicklungen zunehmend an Bedeutung gewinnt.<sup>71</sup> Die Ermittlung des momentanen Ortes eines solchen beweglichen Körpers zählt zum Ziel der Ortung.<sup>72</sup> Das Ergebnis dieser ist grundsätzlich die geographische Länge, die geographische Breite und die Höhe, wobei letzteres bei Positionsbestimmungen innerhalb einer Horizontalebene (Lokalisierung) nicht notwendig ist.<sup>73</sup> Basiert hierbei die Ermittlung des Aufenthaltsortes auf elektromagnetischen Wellen, wird von Funkortung gesprochen.<sup>74</sup> Erfolgt die Ortung beispielsweise mittels RFID-Technologie, WLAN, UWB oder Bluetooth, ist dies der Fall.

Es gilt jedoch, zu erwähnen, dass die auf elektromagnetischen Wellen basierende Positionsbestimmung nicht die einzige Möglichkeit für das Verfolgen von Objekten darstellt. Ebenso können beispielsweise Arbeitskräfte mittels auf Baustellen verteilter Kameras anhand von Bilderkennungsalgorithmen lokalisiert werden.<sup>75</sup> Somit kann anhand einer Aufnahme festgestellt werden, ob sich eine Person im Gefahrenbereich eines Kranes befinden oder im sicheren Bereich steht.<sup>76</sup> In der vorliegenden Arbeit wird jedoch nicht näher auf diese Art der Ortung eingegangen.

Die Ermittlung der Position eines mobilen Objektes basiert meistens unter Verwendung mehrerer ortsfester Referenzstationen (Koordinaten sind bekannt), wobei die häufigsten Verfahren auf einer Messung der Signallaufzeit, der Signallaufzeitdifferenz, des Einfallswinkels der elektromagnetischen Wellen, der Signalstärke oder des Verzögerungs-Leistungsdichtespektrums beruhen.<sup>77</sup>

Zu den populärsten zählt die Messung der Signallaufzeit (Time of Arrival, TOA). Hierbei gilt es, sowohl den Sender als auch den Empfänger mit präzisen Uhren auszurüsten, damit die Laufzeit zwischen Sende- und Empfangszeitpunkt ermittelt werden kann. Diese steht in einem direkten Verhältnis zur Distanz, wobei als Proportionalitätsfaktor die Lichtgeschwindigkeit fungiert. Wird die Mehrwegausbreitung vernachlässigt, so ist die Signallaufzeit kugelförmig um die Referenzstation konstant. Der Schnittpunkt von mindestens drei dieser Körper ergibt die Position. Diese Vorgehensweise wird Trilateration genannt. Eine Alternative dazu stellt die Ermittlung der Umlaufzeit, sprich die Dauer des Signals von der Referenzstation zum Objekt und wieder zurück, dar. Dadurch entfällt die Notwendigkeit einer Zeitsynchronisation. Ebenso ist es möglich, aus den gebildeten Differenzen der absoluten

<sup>71</sup> Vgl.: Binder, F.: Aktuelle Potenziale der Integration von Ortungsdaten in die Bauwerksinformationsmodellierung. In: Festschrift zum 60. Geburtstag von Univ.-Prof. Dr.-Ing. Christoph Motzko. Hrsg.: Fenner, J. S. 42

<sup>72</sup> Vgl.: Bauer, M.: Vermessung und Ortung mit Satelliten. S. 18

<sup>73</sup> Vgl.: Mansfeld, W.: Satellitenortung und Navigation. S. 1

<sup>74</sup> Vgl.: Höher, P.: Grundlagen der digitalen Informationsübertragung. S. 694

<sup>75</sup> Vgl.: Brilakis, I.; Park, M.: Continuous localization of construction workers via integration of detection and tracking. In: Automation in Construction 72, 2016. S. 129

<sup>76</sup> Pawlowski, D.: Tracking von Bauarbeitern auf Baustellen zur Assistenz von Kranführern. Masterarbeit. Ruhr-Universität Bochum, 2019

<sup>77</sup> Vgl.: Höher, P.: Grundlagen der digitalen Informationsübertragung. S. 694

Signallaufzeiten die Lokalisierung durchzuführen. Hierbei liegen Positionen gleicher Laufzeitdifferenzen auf Hyperboloiden und der Schnittpunkt dieser beschreibt den Ort. Ein weiteres Verfahren bezieht sich auf die Ermittlung des Einfallswinkels (Angle of Arrival, AOA). Hierbei wird mittels Triangulation auf die dreidimensionale Position geschlossen. Diese Art der Ermittlung ist jedoch erfahrungsgemäß ungenauer als die zuvor besprochene.<sup>78</sup>

In der nachfolgenden Abbildung 4-7 werden für das bessere Verständnis die Trilateration und die Triangulation bildlich aufbereitet.

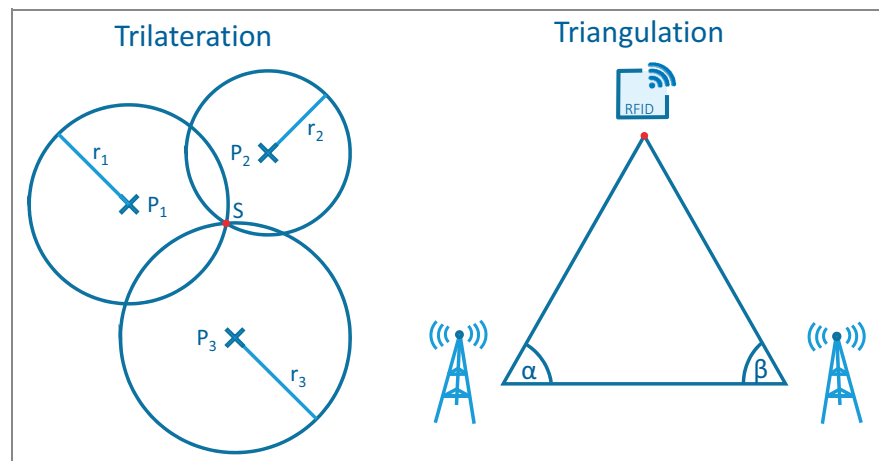


Abb. 4-7 Trilateration und Triangulation<sup>79</sup>

Bei der Bestimmung von Positionen mittels UWB können in Abhängigkeit der Anforderungen an das Ortungssystem folgende Verfahren eingesetzt werden:<sup>80</sup>

- Time-difference of Arrival (TDoA): Über die Zeitunterschiede, welche sich aus dem Aussenden des Signals vom Sensor und dem Empfangen an den Anker ergibt, wird die Position berechnet.
- Two-way Ranging (TWR): Anhand der Zeit, welche das Signal benötigt, um vom Anker zum Sensor und zurück zum Anker zu kommen, wird die Ortung durchgeführt.
- Angle of Arrival (AoA): Bei dieser Methode wird anhand des Eintreffwinkels, der Ausbreitungsrichtung und der Signalstärke des UWB-Senders die Position berechnet.
- Phase-Difference-of-Arrival (PDoA): Mittels zweier an einem Anker angebrachten Antennen wird der Phasenunterschied der empfangenen Signale bewertet und in weiterer Folge der Winkel des einfallenden Signals bestimmt.

Aufgrund diverser Schwierigkeiten bei der Ausbreitung von elektromagnetischen Wellen im Inneren von Gebäuden haben sich bei RFID-basierter Positionsbestimmung drei grundlegende Lokalisierungsprinzipien herauskristallisiert: Entfernungsmessung, Umgebungsanalyse und die Nächsten-Nachbarn-Klassifikation.<sup>81</sup>

<sup>78</sup> Vgl.: Höher, P.: Grundlagen der digitalen Informationsübertragung. S. 694ff

<sup>79</sup> In Anlehnung an: Pestic, S. et al.: BLEMAT - Context Modeling and Machine Learning for Indoor Positioning Systems. In: International Journal on Artificial Intelligence Tools. 2018. S. 3

<sup>80</sup> Vgl.: <https://kinexon.com/de/uwb-technologie>. Datum des Zugriffs: 27.07.2021

Beim Einsatz von passiven RFID-Transpondern für Lokalisierungszwecke ist die Nächste-Nachbarn-Klassifikation zu bevorzugen. Werden hingegen aktive Tags verwendet, welche selbst Signale senden und empfangen, können anspruchsvollere Positionsbestimmungsverfahren eingesetzt werden. Für die Ermittlung der Distanz, welche in weiterer Folge bei der Trilateration benötigt wird, gibt es verschiedene Ansätze. Beispielsweise können hierfür die Signalstärken, welche bei verschiedenen Lesegeräten ankommen, herangezogen werden. Ebenso ist diese Ermittlung mit Hilfe der Signallaufzeitdifferenzen möglich. Eine weitere Variante stellt die Messung der Phasendifferenz, von welcher auf die Richtung (Triangulation) geschlossen werden kann, dar.<sup>82</sup>

Die Analyse der Umgebung bietet ebenso eine Möglichkeit zur Lokalisierung. Hierfür werden mit diversen Modellansätzen die zu beurteilenden Tags mit rasterförmig fix installierten Transpondern, von denen die genaue Position bekannt ist, verglichen. Ein weiterer Ansatz stützt sich auf den beschränkten Zugriff der Lesegeräte auf die Transponder. Befindet sich ein Tag im Empfangsbereich eines Lesegerätes, wird es diesem zugerechnet und kann von anderen nicht mehr ausgelesen werden. Dadurch ist bekannt, in welchem Feld der Transponder aktuell verweilt.<sup>83</sup>

Auf der Baustelle bieten Funktechnologien ein großes Potenzial für das Orten von Ressourcen.<sup>84</sup> Mit Hilfe von UWB können beispielsweise die Positionen der Schalungselemente auf dem Baugelände effektiv bestimmt werden.<sup>85</sup> Neben dem Verfolgen der Materialien, Geräte und Arbeitskräfte während des Baugeschehens zählt jedoch auch die Ortung von Gegenständen in bereits errichteten Bauwerken zu einem wichtigen Anwendungsgebiet. Beispielhaft kann hierfür die Standortbestimmung von medizinischem Equipment in Spitälern erwähnt werden.<sup>86</sup> Ebenso greifen auch Roboter auf die RFID-Technologie in Kombination mit Sensoren zurück, um sich in Räumen zu orientieren.<sup>87</sup>

Damit die Ressourcen bestmöglich auf der gesamten Baustelle sowie deren Umgebung sowohl indoor als auch outdoor verfolgt werden können, wird oftmals die RFID-Technologie mit GPS kombiniert. Werden RFID-Reader auch außerhalb der Baustelle an bekannten Punkten installiert, wirkt sich dies unterstützend auf die von den GPS-Geräten erzielte Genauigkeit aus.<sup>88</sup> Inwieweit dies einen deutlichen Mehrwert für die Beurteilung des Bauablaufes mit sich bringt, muss für jedes Bauprojekt individuell abgeschätzt werden.

Auf der Baustelle selbst wird bei der Kombination verschiedener Ortungstechniken die RFID-Technologie häufig als Engpassortung eingesetzt. Die Konfiguration dieser Systeme ist individuell auf die benötigte Positionsgenauigkeit abzustimmen. Je höher die Anforderungen, desto dichter muss die Ortungsinfrastruktur installiert werden. Dadurch steigen in weiterer Folge die Kosten.<sup>89</sup>

<sup>81</sup> Vgl.: Bouet, M.; Santos, A.: RFID Tags: Position Principles and Localisation Techniques. Konferenz: 2008 1st IFIP Wireless Days, 2008. S. 2

<sup>82</sup> Vgl.: Bouet, M.; Santos, A.: RFID Tags: Position Principles and Localisation Techniques. Konferenz: 2008 1st IFIP Wireless Days, 2008. S. 3

<sup>83</sup> Vgl.: Bouet, M.; Santos, A.: RFID Tags: Position Principles and Localisation Techniques. Konferenz: 2008 1st IFIP Wireless Days, 2008. S. 4

<sup>84</sup> Vgl.: Shen, X.; Chen, W.; Lu, M.: Wireless Sensor Networks for Resources Tracking at Building Construction Sites. In: Tsinghua Science and Technology, 13 (S1), 2008. S. 83

<sup>85</sup> Vgl.: Norrdine, A. et al.: MQTT-Based Surveillance System of IoT Using UWB Real Time Location System. Konferenz: iThings-GreenCom-CPSCoM-SmartData-Cybermatics. IEEE, 2020. S. 216ff

<sup>86</sup> Vgl.: Shirehjini, A. A. N.; Yassine, A.; Shirmohammadi, S.: Equipment Location in Hospitals Using RFID-Based Positioning System. In: IEEE Transactions on Information Technology in Biomedicine, 16(6), 2012. S. 1058ff

<sup>87</sup> Vgl.: Choi, B. et al.: A Hierarchical Algorithm for Indoor Mobile Robot Localization Using RFID Sensor Fusion. In: IEEE Transactions on Industrial Electronics, 58 (6), 2011. S. 2226ff

<sup>88</sup> Vgl.: Du, M.; Jing, C.; Du, M.: Tag location method integrating GNSS and RFID technology. In: The Journal of Global Positioning Systems, 14(2), 2016. S. 1

<sup>89</sup> Vgl.: Binder, F.: Ereignisbasierte Steuerung bauleistungsprozesse mit Echtzeit-Ortungssystemen. Dissertation. Technischen Universität Darmstadt. 2014. S. 119ff

Neben der Wirtschaftlichkeit, welche oftmals aufgrund hoher Implementierungskosten als unerfüllt angesehen wird, zählt auch der Einfluss von Metallen und Flüssigkeiten zu den größten Schwächen beim Einsatz von elektromagnetischen Wellen.<sup>90</sup> Daraus geht hervor, dass die Art, Form und Komplexität des Bauwerks, die verwendeten Materialien sowie die Bauverfahren bedeutende Auswirkungen auf die Positionsgenauigkeit ausüben.

Binder untersucht in seiner Arbeit zwei Echtzeit-Ortungssystemimplementierungen, bei denen die Funkortung auf Basis polysensoraler Systeme durchgeführt wird. Beim Bau des Hörsaal- und Medienzentrums der TU Darmstadt wurden diese Ortungssysteme erfolgreich eingesetzt. Die Bandbreite der Genauigkeiten reichte in Abhängigkeit der Position auf der Baustelle vom Zentimeterbereich bis hin zu sieben Metern.<sup>91</sup>

Welche Positionsgenauigkeit erforderlich ist, hängt von der zu lösenden Aufgabenstellung ab. Je spezifischer die Fragestellung ist, desto präziser müssen die Messdaten erhoben werden, wodurch in weiterer Folge die Kosten steigen. Um den notwendigen Detaillierungsgrad bei arbeitsintensiven Tätigkeiten besser einschätzen zu können, ist es ratsam, wie bei einer REFA-Analyse die Gliederung in Ablaufabschnitte zu berücksichtigen. Abbildung 4-8 stellt eine solche unter näherer Betrachtung der Stahlbetonarbeiten dar.

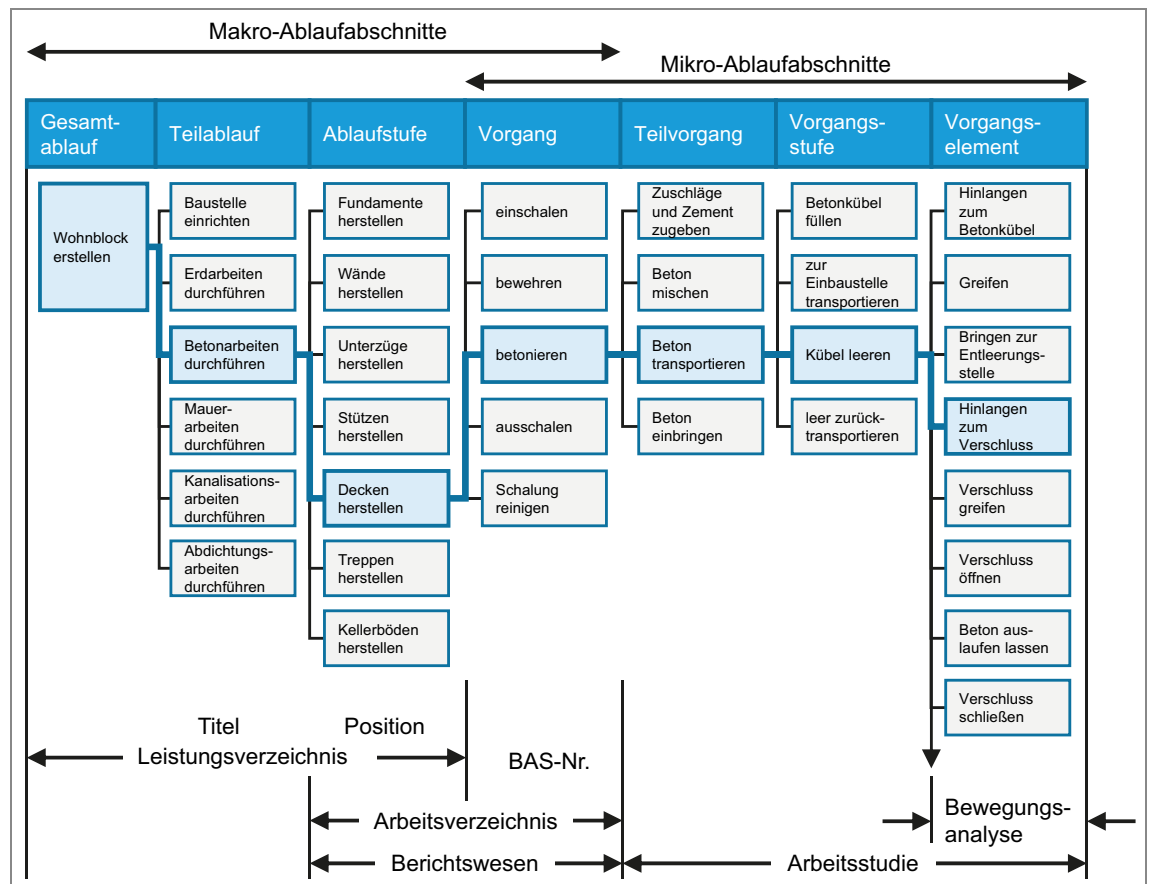


Abb. 4-8 Gliederung des Gesamtablaufes am Beispiel der Stahlbetonarbeiten<sup>92</sup>

<sup>90</sup> Vgl.: Dardouri, S. et al.: RFID-Integrated Software Platform for Construction Materials Management. Konferenz: Modular and Offsite Construction (MOC) Summit Proceedings, 2019. S. 486

<sup>91</sup> Vgl.: Binder, F.: Ereignisbasierte Steuerung baualogistischer Prozesse mit Echtzeit-Ortungssystemen. Dissertation. Technischen Universität Darmstadt. 2014. S. 118ff

Anhand der soeben gezeigten Grafik ist ersichtlich, dass ein Bestandteil eines Ablaufabschnitts durch die nachfolgenden Abschnitte immer detaillierter beschrieben wird. Gilt es nun, beispielsweise bei einem Projekt die Dauer der Stahlbetonarbeiten einer Decke automatisch zu erheben, muss im Vorhinein festgelegt werden, auf welcher Gliederungstiefe die Messwerte erhoben werden sollen. Ob die Gesamtdauer vom Herstellen der Decke oder die Summe aller dazu notwendigen Vorgangsdauern herangezogen wird, beeinflusst das Ergebnis nicht. Lediglich der Erhebungsaufwand steigt bei Betrachtung der einzelnen Vorgänge deutlich an.

Eine weitere wichtige Möglichkeit zur Positionsbestimmung auf einer Baustelle stellt die Satellitennavigation dar, bei der die Ortung eines Empfangsgerätes auf Basis von Satellitensignalen durchgeführt wird. Hierfür schicken die Satelliten über elektromagnetische Wellen die Systeminformationen, die Korrekturparameter, ihre Bahndaten zur Festlegung der Referenzpunkte und ein Zeitsignal für die Berechnung des Abstandes aus.<sup>93</sup> Letzteres ergibt sich aus der Multiplikation der Lichtgeschwindigkeit mit der Laufzeit, welche aus der Uhrzeit der Abstrahlung und jener des Empfangs berechnet wird.<sup>94</sup>

Die soeben beschriebene Laufzeitermittlung ist sehr gut mit dem Sekundenzählen zur Abschätzung der Entfernung eines Gewitters vergleichbar. Aufgrund der Tatsache, dass sich Licht mit einer Geschwindigkeit von rund 300.000.000 m/s und Schall mit 330 m/s ausbreitet, wird zuerst der Blitz gesehen und danach der Donner gehört. Beträgt die Zeitspanne zwischen diesen beiden Ereignissen beispielsweise 6 s, ergibt sich eine Entfernung zum Blitz von rund 2 km ( $6 \text{ [s]} * 330 \text{ [m/s]} = 1980 \text{ [m]}$ ).<sup>95</sup>

Hierbei ist jedoch anzumerken, dass sich das Funksignal des Satelliten mit Lichtgeschwindigkeit ausbreitet, wodurch die Anforderungen an die Exaktheit der Laufzeitmessung äußerst hoch sind. Würde eine Abweichung von nur einer Millionstel Sekunde vorliegen, wäre die Abstandsmessung bereits um 300 m daneben. Aus diesem Grund werden Atomuhren in den Satelliten verbaut.<sup>96</sup>

In weiterer Folge werden nun mit Hilfe der errechneten Distanzen Kugeln um die Positionen der Satelliten ( $x_i$ ,  $y_i$  und  $z_i$ ) gelegt und miteinander verschnitten. Die Lösung dieser sphärischen Trigonometrieaufgabe stellt die Position des Empfangsgerätes ( $x$ ,  $y$  und  $z$ ) dar. Ist die Verbindung zu vier Satelliten möglich, ergeben sich vier Gleichungen, wodurch zusätzlich noch die Zeit  $t$  des Signalempfangs errechnet werden kann. Dadurch wird in weiterer Folge eine Uhr eingespart, weil die Atomzeit aus der Auflösung der mathematischen Zusammenhänge resultiert. Nachfolgend sind die dafür notwendigen Gleichungen angeführt (Glg. (4-1), Glg. (4-2), Glg. (4-3), Glg. (4-4)).<sup>97</sup>

$$d_1 = \sqrt{(x_1 - x)^2 + (y_1 - y)^2 + (z_1 - z)^2} = c(t_1 - t) \quad (4-1)$$

$$d_2 = \sqrt{(x_2 - x)^2 + (y_2 - y)^2 + (z_2 - z)^2} = c(t_2 - t) \quad (4-2)$$

<sup>92</sup> Kummer, M.: Aggregierte Berücksichtigung von Produktivitätsverlusten bei der Ermittlung von Baukosten und Bauzeiten. Dissertation. Technische Universität Graz. 2015. S. 51

<sup>93</sup> Vgl.: Schüttler, T.: Relativistische Effekte bei der Satellitennavigation. S. 2f

<sup>94</sup> Vgl.: Dodel, H.; Häupler, D.: Satellitennavigation. S. 2

<sup>95</sup> Vgl.: Schüttler, T.: Relativistische Effekte bei der Satellitennavigation. S. 3f

<sup>96</sup> Vgl.: Schüttler, T.: Relativistische Effekte bei der Satellitennavigation. S. 4

<sup>97</sup> Vgl.: Dodel, H.; Häupler, D.: Satellitennavigation. S. 5



$$d_3 = \sqrt{(x_3 - x)^2 + (y_3 - y)^2 + (z_3 - z)^2} = c(t_3 - t) \quad (4-3)$$

$$d_4 = \sqrt{(x_4 - x)^2 + (y_4 - y)^2 + (z_4 - z)^2} = c(t_4 - t) \quad (4-4)$$

Damit das Prinzip der Satellitenortung, welches in Abbildung 4-9 gezeigt wird, umsetzbar ist, werden in der Regel folgende Bestandteile benötigt:<sup>98</sup>

- Satelliten im Weltraum: Die mit einer Uhr, einem Mikroprozessor, einem Sender und einer Antenne ausgestatteten Satelliten umkreisen in regelmäßigen Intervallen die Erde und senden mit Hilfe der soeben genannten Bestandteile elektromagnetische Wellen aus.
- Kontrollstation: Die Koordinaten der Satellitenflugbahnen werden von der auf der Erde situierten Kontrollstation überwacht und bestimmt.
- Nutzer: Die Signale von mindestens vier Satelliten müssen vom Nutzer empfangen werden, damit die Bestimmung der Position sowie der Systemzeit erfolgen kann.




Abb. 4-9 Prinzip der Satellitenortung<sup>99</sup>

Zu den derzeit wichtigsten globalen Satellitennavigationssystemen (GNSS) zählen das US-amerikanische Navstar GPS (Navigation Satellite Timing and Ranging Global Positioning System) und das russische GLONASS (Globalnaja nawigazionnaja sputnikowaja sistema). Weiters ist erwähnenswert, dass das europäische Satellitennavigationssystem Galileo, als einziges nur für zivile Nutzungszwecke geschaffen wurde.<sup>100</sup>

Bei der Auswahl eines GNSS spielt die Genauigkeit, welche von unterschiedlichen Fehlerquellen beeinflusst wird, eine bedeutende Rolle. Eine Ursache für Abweichungen ist beispielsweise die ionosphärische oder troposphärische Laufzeitverzögerung. Hierbei führen Refraktionseinflüsse der Sphären zur Verlangsamung der Signale, welche in weiterer Folge zu einem Fehler bei der Entfernungsberechnung führt. Ebenso zählen die Satel-

<sup>98</sup> Vgl.: Mischke, A.: Skript Teil 8: GNSS. Vorlesung zur Veranstaltung Vermessungskunde. S. 6

<sup>99</sup> In Anlehnung an: Schüttler, T.: Relativistische Effekte bei der Satellitennavigation. S. 4

<sup>100</sup> Vgl.: Schüttler, T.: Relativistische Effekte bei der Satellitennavigation. S. 1

liten- und Empfängeruhrenfehler, die Mehrwegeeffekte (Signal läuft über eine reflektierende Oberfläche) oder die Verteilung der Satelliten am Himmel zu möglichen Fehlerquellen.<sup>101</sup>

Damit die für einen Anwendungsfall gewünschte Genauigkeit erzielt wird, muss die dazu passende Berechnungsmethode gewählt werden. Mit dem vorhin beschriebenen Prinzip ist beispielsweise eine Ortung im Meterbereich möglich. Werden jedoch höhere Anforderungen gestellt, ist eine differenzielle Ortung durchzuführen. Auch hierbei bleibt das Grundprinzip gleich, lediglich die Anzahl der Empfänger wird auf zwei erhöht, wobei die Position eines Gerätes bekannt sein muss (Referenzempfänger). Dadurch wird es möglich, kontinuierlich die Abweichungen zwischen den SOLL- und IST- Koordinaten zu bestimmen. Diese Korrekturdaten werden daraufhin bei der Positionsbestimmung der anderen Empfänger (Rover), welche sich in der Nähe des ersten befinden, berücksichtigt. Auf Basis dieser Referenzempfänger und dem Einsatz aufwendiger und komplexer Algorithmen können Genauigkeiten im Millimeterbereich erzielt werden.<sup>102</sup>

## 4.5 Prototypische Systementwicklung

Im Zuge der prototypischen Systementwicklung werden zunächst die Anforderungen definiert, fünf verschiedene Entwürfe ausgearbeitet und abschließend beurteilt.

Aus der in Abschnitt 3.4 vorgestellten Literaturanalyse geht hervor, dass neuronale Netze bei Kosten-, Dauern- oder Produktivitätsprognosen nutzbringend eingesetzt werden können, insofern eine ausreichende Menge an Daten vorhanden ist. Mit durchschnittlich rund 330 Fällen je Datensatz (Punkt 3.4.6) stellt letzteres jedoch noch eine Herausforderung dar. Dieser gilt es, mit einem geeigneten digitalen Konzept entgegenzuwirken, damit zukünftig das volle Potenzial der künstlichen Intelligenz ausgeschöpft werden kann.

Sowohl bei der Ermittlung der Kosten, als auch bei der Vorhersage der Dauern und den zu erwartenden Produktivitäten spielt das verursachungsgerechte Zuteilen anfallender Lohnstunden eine bedeutende Rolle. Aus diesem Grund werden hierfür nachfolgend Konzepte, welche dies für die Stahlbetonarbeiten auf Basis digitaler Technologien ermöglichen, ausgearbeitet und mittels aus der Anforderungsanalyse abgeleiteter Kriterien bewertet.

### 4.5.1 Anforderungsanalyse

Zu den Muss-Zielen zählt somit das automatische Erheben der Lohnstunden von bis zu 10 Arbeitskräften gleichzeitig, auf einer Hochbaubaustelle sowohl indoor, als auch outdoor. Ebenso gehört das Zuordnen zu verschiedenen Bereichen wie beispielsweise Lager, Container oder zu errichtendes Bauwerk und das Erfassen der Wege zwischen diesen dazu. Weiters muss die Anonymität der einzelnen Arbeitskräfte während des gesamten Erhebungsprozesses durchgehend gewährleistet sein.

<sup>101</sup> Vgl.: Leica: [http://webarchiv.ethz.ch/geometh-data/downloads/GPSBasics\\_de.pdf](http://webarchiv.ethz.ch/geometh-data/downloads/GPSBasics_de.pdf). Datum des Zugriffs: 22.07.2021

<sup>102</sup> Vgl.: Bauer, M.: Vermessung und Ortung mit Satelliten. S. 69f

Neben der Anforderung, dass die ausgeteilten Tags/Gadgets sowie die am Baufeld installierte Ortungsinfrastruktur die Fachkräfte während deren Arbeiten so wenig wie möglich einschränken bzw. behindern dürfen, zählt auch das Dokumentieren der Tätigkeiten zum Soll-Ziel. Hierbei stehen das Schalen, Bewehren und Betonieren im Fokus der Betrachtung. Weiters ist anzustreben, dass die Energieversorgung kabellos erfolgt und für mindestens einen ganzen Arbeitstag ausreicht. Ebenso gilt es, bei der Geräte-/Technologieauswahl die sich ständig ändernden Baustellenbedingungen (grüne Wiese, Bodenplatte, Wände, Decke ...) sowie die Einwirkungen durch Staub, Wasser und mechanische Stöße zu berücksichtigen.

Um sicherzustellen, dass die Arbeitskräfte aufgrund abweichender Signale keinen falschen Bereichen zugeordnet werden, sollte eine hohe Genauigkeit angestrebt werden. Neben präzisen Ortungsmethoden ist hierbei auch auf die Positionierung der dafür notwendigen Infrastruktur zu achten, um Fehlsignale oder blinde Flecken (keine Positionsbestimmung möglich) zu vermeiden. Sind die Daten erhoben, gilt es, diese mittels Software oder einer dafür geeigneten Plattform aufzubereiten und die Ergebnisse zumindest als CSV-Datei bereitzustellen.

Als abschließendes Soll-Ziel ist noch die Minimierung des zeitlichen Aufwands bei der Handhabung anzuführen. Diese bezieht sich sowohl auf die Arbeitskräfte während der Ausführung der Tätigkeiten (z.B.: Batteriestand oder Signalverbindung prüfen etc.) als auch auf die Einrichtung und Betreuung des Systems während der Datenerfassung (konfigurieren, Geofences implementieren, Batterie aufladen etc.).

Im Rahmen der Kann-Ziele ist das Erfassen und Übertragen der Positionen in Echtzeit sowie eine genaue Bauteilzuordnung anzuführen. Ebenso zählen das Visualisieren der Ortungsdaten auf der Plattform oder mittels Software und eine Excel-basierte Schnittstelle dazu. Diese Aspekte wären zwar nicht zwingend notwendig, würden jedoch die Zuordnung, die Veranschaulichung der Positionen und die auf Excel aufbauende Modellbildung erleichtern.

Da es sich bei dieser Untersuchung um universitäre Forschung handelt, steht die Funktionsweise an erster Stelle, wodurch die Kosten zu den Kann-Zielen zählen. Dass die Kosten-Nutzen-Rechnung jedoch trotzdem eine Bedeutung hat, ist bei der Minimierung des zeitlichen Aufwands der Implementierung und der Betreuung (Soll-Ziele) ersichtlich.

Die in den Anforderungen definierten Nicht-Ziele beinhalten die Analyse der Daten sowie die Mustererkennung. Diese Punkte folgen zwar nach der Datenerhebung, stellen jedoch keinen Bestandteil des Erhebungskonzeptes dar. Weiters beinhalten die Systementwürfe keine ereignisbasierten Ansätze zur Steuerung aktueller baubetrieblicher Prozesse. Es werden lediglich Dauern unter Berücksichtigung ausgewählter Tätigkeiten von verschiedenen Bereichen erhoben. Schlussendlich ist nochmals festzuhalten, dass der Ortung der einzelnen Arbeitskräfte keine Überwachungsintention zu Grunde liegt.

#### 4.5.2 Systementwurf

In der Vorbereitungsphase der Datenerhebung wurden fünf Entwürfe für die Positionsbestimmung der Arbeitskräfte für einen eingeschossigen Stahlbetonbau, bestehend aus sieben Räumen, erarbeitet. Hierbei stand eine

Lösung zur automatischen Erhebung der Lohnstunden mit zusätzlicher Bereichszuordnung im Vordergrund. Da im Zuge der Auswahl möglicher Partnerunternehmen ein besonderer Wert auf die Diversität der eingesetzten Technologien gelegt wurde, gibt es keinen identen Lösungsvorschlag. Folgende fünf Ortungssysteme wurden konzeptionell entwickelt:

- RFID-basierte Zuordnung mit Bereichserkennung
- Ortung auf Basis von BLE-Beacons und Mobiltelefonen
- GNSS und BLE-Beacons mit GSM-Datenübertragung
- GPS und BLE-Beacons mit LoRaWAN-Datenübertragung
- UWB mit WLAN-Datenübertragung

Anschließend werden deren Grundprinzipien näher erläutert und der Auswahlprozess dargestellt. Die darüber hinausgehende Kombination mit Informationen bezüglich des aktuellen Wetters lässt bei jeder der fünf Systeme automatisch Regenunterbrechungen erkennen.

### **RFID-basierte Zuordnung mit Bereichserkennung**

Dieses Konzept stützt sich auf den Einsatz passiver long-range Tags im Ultrahochfrequenzbereich mit sowohl tragbaren als auch fest installierten RFID-Lesegeräten. Die Tags werden hierbei auf den Helmen der Arbeitskräfte, in den einzelnen Bauabschnitten bzw. bei Bauteilen und auf wichtigen Geräten wie beispielsweise der Kreissäge, dem Rüttler oder der Motorsäge platziert. Ausgelesen werden diese einerseits automatisch durch fest montierte Leseantennen an Schlüsselstellen wie beispielsweise dem Eingang zum Container oder zum Lager und andererseits durch mobile kleine Lesegeräte, welche die Fachkräfte während ihrer Tätigkeit am Gürtel mit sich führen und damit aktiv die Tags scannen.

Das Betätigen des Lesegerätes ist ein zusätzlicher Aufwand für die Fachkräfte, führt jedoch zu einer effektiven Zuteilung der Lohnstunden zu einem Bauteil/Abschnitt. Gleichzeitig können die eingesetzten Schlüsselgeräte miterfasst und dokumentiert werden.

Zusätzlich zum individuellen Einloggen der Arbeitskräfte am Bauteil werden die Pausenzeiten über die fest montierte Leseantenne oberhalb des Containereingangs erfasst. Ebenso können die Lageraufenthalte und Baustellenwechsel dokumentiert werden.

### **Ortung auf Basis von BLE-Beacons und Mobiltelefonen**

Diese Variante stützt sich auf einen vor Ort angebrachten BLE- Beaconraster von 5x5 m, welcher von Mobiltelefonen mittels eigener App für die Standortbestimmung der Arbeitskräfte genutzt wird. Hierbei kann eine Genauigkeit von rund 3 m erzielt werden, insofern die Rasteranordnung aufgrund spezifischer Tätigkeiten (z.B.: Aushub) nicht verändert wird. Weiters funktioniert das gesamte System kabellos und benötigt keine zusätzliche Datenübertragung wie beispielsweise WLAN, weil die Mobiltelefone der Fachkräfte die Ortungsdaten über das Mobilfunknetz weiterleiten. Um dies zu erreichen, muss jedoch jede Arbeitskraft mit einem Handy ausgestattet werden.

Für die Zuordnung der Geräte zur Fachkraft werden spezielle Beacons eingesetzt, welche die Veränderung des elektrischen Feldes messen. Dadurch kann in weiterer Folge mit Hilfe der App ermittelt werden, wie lange

sich das eingesetzte Gerät in einer bestimmten Nähe zur Arbeitskraft aufhält, eine Zuordnung der Tätigkeit ist aber nicht möglich.

Die Einhaltung des erforderlichen BLE-Beaconrasters während des gesamten Bauablaufs ist jedoch als problematisch zu sehen, da beispielsweise errichtete Stahlbetonwände die Anordnung unterbrechen. Ebenso stellt die Anbringung am Baufeld eine Herausforderung dar, weil die elektromagnetische Strahlung der Beacons leicht durch Stahlobjekte oder Wasser abgeschirmt wird. Um dem entgegenzuwirken, werden die Beacons auf Stativen, beispielsweise Holzlatten, angebracht und eingemessen.

### **GNSS und BLE-Beacons mit GSM-Datenübertragung**

Die Arbeitskräfte erhalten bei diesem Konzept ein Working-Gadget, welches mittels GNSS (Globales Navigationssatellitesystem) im Outdoor-Bereich und der Kommunikation mit BLE-Beacons in Räumen die Lohnstunden erfasst und Geofences zuordnet. Zusätzlich verfügt dieses Gerät über Druckknöpfe, wodurch die Fachkräfte deren Tätigkeiten bekanntgeben können.

Nach der morgendlichen Ausgabe der Geräte erheben diese die Positionen und senden sie via mobiler Daten über eine eingebaute SIM-Karte zur Aufbereitung weiter. Am Ende eines Tages gilt es, die Gadgets wieder einzusammeln und für den nächsten Tag aufzuladen.

Aufgrund der Tatsache, dass die Räumlichkeiten erst errichtet werden, erfolgt zunächst die Positionsbestimmung nur mittels GNSS. Hierbei erreicht das System eine Genauigkeit von unter 2 m, da bei der Datenauswertung auf verschiedene Satellitensysteme zurückgegriffen werden kann. Erst nach dem Ausschalen der Wände werden die BLE-Beacons angebracht, um die Bereichserkennung der Arbeitskräfte innerhalb der Räume zu gewährleisten.

### **GPS und BLE-Beacons mit LoRaWAN-Datenübertragung**

Diese Variante ist hinsichtlich Funktionsprinzip mit der vorherigen zu vergleichen – im Outdoor-Bereich wird GNSS und indoor BLE-Beacons eingesetzt. Der Unterschied liegt jedoch darin, dass nur auf GPS (Genauigkeit rund 10 m) zurückgegriffen werden kann und keine Druckknöpfe für das Festlegen der Tätigkeiten am Gadget vorhanden sind. Weiters erfolgt die Datenübertragung mittels LoRaWAN, welches extra für die Baustelle eingerichtet werden muss.

### **UWB mit WLAN-Datenübertragung**

Dieses Konzept setzt zur Positionsbestimmung der Arbeitskräfte Ultrabreitband (UWB) ein. Hierbei wird nicht die Signalstärke, sondern die Signallaufzeit zwischen den Tags und dem Anchor, welcher zwei Antennen besitzt, ermittelt. Ersteres trägt die Arbeitskraft mit sich, letzteres wird zunächst regengeschützt – durch spezielle Gehäuse – am Baufeld auf Stativen und nach der Errichtung der Räume im Gebäudeinneren angebracht. Mit diesem Aufbau wird zwar eine Genauigkeit von 30 cm erreicht, eine Zuordnung der Tätigkeiten ist aber nicht möglich.

Weiters basiert die Datenübertragung auf WLAN, welches für das Baufeld extra eingerichtet werden muss. Die Datenaufbereitung erfolgt jedoch im Gegensatz zu den vorherigen Varianten nicht online, sondern lokal auf einem Computer auf der Baustelle.

Damit die Anchor genügend Energie für das Erheben und Weitersenden der Daten zur Verfügung haben, müssen diese mit einer eigenen Energiequelle ausgestattet werden. Hierbei schaffen über ein USB-Netzteil angeschlossene Powerbanks (Batterien) Abhilfe.

## 4.6 Systemauswahl

Die Entscheidung, welche Variante auf der Baustelle eingesetzt wird, basiert auf den folgenden aus der Anforderungsanalyse abgeleiteten Aspekten, wobei die eingesetzte Gewichtung von oben nach unten abnimmt:

- Genauigkeit: Beurteilung der Präzision bei der Positionsbestimmung
- Behinderung Bauablauf: Ist eine Einschränkung des Baugeschehens, beispielsweise durch im Weg stehende Stative, gegeben?
- Tätigkeitserhebung: Möglichkeit zum direkten Erfassen der verrichteten Tätigkeiten Schalen, Bewehren oder Betonieren
- Aufwand Arbeitskräfte: Zeitliche Inanspruchnahme der Arbeitskräfte
- Implementierungsdauer: Aufwand beim Einrichten der einzelnen Technologien auf der Baustelle und deren Betreuung während der Herstellung der Stahlbetonarbeiten.
- Datenübertragung: Kann auf einen bereits am Baufeld vorzufindenden Funkstandard zurückgegriffen werden?
- Kosten: Hardware sowie Softwarekosten samt Implementierung

Bei den soeben vorgestellten Kriterien ist ersichtlich, dass die Funktionalität des Systems im Vordergrund steht. Dies wird auch durch die eingesetzte Gewichtung der einzelnen Aspekte verdeutlicht. In Tabelle 4-9 werden die unterschiedlichen Ergebnisse der systematischen Auswahl auf Basis der Entscheidungsmatrix nach *Hofstadler* präsentiert. Hierbei kommt ein Punktesystem zwischen 1 und 5 zur Anwendung, wobei 5 die beste Bewertung darstellt.

Bei dem Aspekt der Genauigkeit erfolgt die Reihung auf Basis der von den Herstellern angegebenen Präzision. Bei der Behinderung des Bauablaufes wirkt sich das Aufstellen notwendiger Stative unter Berücksichtigung deren Anzahl negativ auf die Punktevergabe aus.

Weil das Konzept basierend auf GNSS und BLE-Beacons mit GSM-Datenübertragung als einziges die Tätigkeiten ohne zusätzliche Hilfsmittel oder einer weiteren Modellbildung basierend auf tätigkeitstypischen Geräten (Rüttelflasche beim Betonieren) erfassen kann, bekommt nur dieses 5 Punkte. Hierbei gilt es jedoch anzumerken, dass selbst die Vergabe eines Punktes keine Änderung in der Reihung bewirkt. Die Endpunkteanzahl würde lediglich auf 3,80 sinken, wodurch der erste Platz erhalten bleibt.

Der zusätzliche Arbeitsaufwand für die Fachkräfte ist beim Einsatz der RFID-Technologie durch das aktive Scannen am größten und wird daher mit einem Punkt bewertet. Beim Verwenden der Mobiltelefone befindet sich das Aufladen der Akkus im Verantwortungsbereich der Arbeitskräfte. Weil dies jedoch am Abend außerhalb der Arbeitszeit erfolgt, werden 5 Punkte vergeben. Beim Einsatz der Gadgets mit Druckknöpfen zählt das Herausnehmen der Geräte und Ändern der Tätigkeit nicht zu den gewohnten Abläufen, wodurch ein Mehraufwand vorhanden ist, welcher mit 3 Punkten bewertet wird. Die restlichen zwei Varianten werden mit 5 Punkten beurteilt, weil während des Verrichtens der Arbeit die Geräte lediglich eingesteckt werden müssen.

Die Betreuungsintensität und Implementierungsdauer wird beim RFID-Konzept mit 3 Punkten bewertet, da die am Boden liegenden RFID-Tags häufig umzulegen bzw. zu erneuern sind. Bei der BLE-Beacon-Variante in Kombination mit dem Mobiltelefon und der UWB-Variante werden ebenfalls 3 Punkte vergeben, da es die benötigte Hardware einzumessen gilt. Die beiden GNSS-Konzepte erhalten 4 Punkte, weil die BLE-Beacons nur mit doppelseitigem Klebeband an der Wand befestigt werden.

Die Punktevergabe bei der Datenübertragung bewertet die Nutzung vorhandener Infrastruktur – in diesem Fall nur GSM – mit 5 Punkten und ein neu zu errichtendes System mit einem. Beim letzten Aspekt werden die fünf Technologien in drei Kostenklassen zusammengefasst, wobei mit sinkender Punkteanzahl die Kosten steigen.

Die Punktevergabe, die dazugehörige Gewichtung sowie die daraus resultierende Reihung sind in Tabelle 4-9 zusammengefasst. Der Risikofaktor ist bei allen Varianten gleich einzuschätzen, da die Anbieter der verschiedenen Technologien keine baustellenbezogenen Referenzprojekte vorweisen können. Unter Berücksichtigung dieser Bewertung ist somit das Konzept basierend auf GNSS und BLE-Beacons mit GSM-Datenübertragung als am vorteilhaftesten anzusehen und wird daher ausgewählt.

Entscheidungsmatrix											
Beurteilungskriterien	Gewichtung	Konzepte									
		RFID-basierte Zuordnung		BLE-Beacons und Mobiltelefone		GNSS und BLE-Beacons mit GSM		GPS und BLE-Beacons mit LoRaWan		UWB mit WLAN	
		B	C	D	E	F	G	H	I	J	K
A	[%]	Pkt.	Gesamt	Pkt.	Gesamt	Pkt.	Gesamt	Pkt.	Gesamt	Pkt.	Gesamt
Genauigkeit der Ortungstechnologie	20	1	0,20	3	0,60	4	0,80	2	0,40	5	1,00
Behinderung des Bauablaufes	20	5	1,00	2	0,40	5	1,00	5	1,00	3	0,60
Möglichkeit zur Tätigkeitserfassung	15	1	0,15	1	0,15	5	0,75	1	0,15	1	0,15
Zusätzlicher Aufwand für die Arbeitskräfte	15	1	0,15	5	0,75	3	0,45	5	0,75	5	0,75
Implementierungsdauer/Betreuungsintensivität	10	3	0,30	3	0,30	4	0,40	4	0,40	3	0,30
Datenübertragung	10	1	0,10	5	0,50	5	0,50	1	0,10	1	0,10
Kosten	10	3	0,30	3	0,30	5	0,50	5	0,50	1	0,10
<b>Gesamtpunkte:</b>			2,20		3,00		4,40		3,30		3,00
<b>Risikofaktor</b> (multiplikativ: 1 kein erhöhtes Risiko, 0 unüberwindbares Risiko):				1		1		1		1	1
<b>Endpunkteanzahl:</b>			2,20		3,00		4,40		3,30		3,00
<b>Entscheidung (Reihenfolge):</b>			5		4		1		2		3

Tab. 4-9 Entscheidungsmatrix für die Auswahl des Erhebungskonzeptes

## 5 Fallstudienbezogene Systemimplementierung

Dieses Kapitel beinhaltet die Umsetzung des vorhin ausgewählten polysensoralen Ortungskonzepts zur automatischen Ermittlung der anfallenden Lohstunden. Hierfür wird zunächst der Untersuchungsgegenstand beschrieben und die Abmessungen des Bauwerks dargestellt. Anschließend liegt der Fokus auf der Datenerhebung, welche im Zuge einer Masterarbeit<sup>1</sup> erprobt wurde. Schlussendlich folgt die Evaluierung des Systems.

### 5.1 Vorstellung des Bauprojekts

Der nachfolgende Abschnitt hat zum Ziel, einen Überblick über das vorliegende Bauprojekt zu geben, um die Rahmenbedingungen der Daten- und Informationserhebung zu verdeutlichen. Hierfür wird zunächst das Bauvorhaben beschrieben und anschließend die örtlichen Gegebenheiten vorgestellt.

Die Koralmbahn, ein Abschnitt der neuen Südstrecke in Österreich, zählt zu den wichtigsten Infrastrukturprojekten Europas. Nach der Fertigstellung ermöglicht sie die Verbindung zwischen Graz (Steiermark) und Klagenfurt (Kärnten) in nur 45 Minuten. Im Vergleich zur aktuellen Situation entspricht dies einer Zeitersparnis von 2 Stunden und 15 Minuten, wobei diese Verbesserung durch eine 130 km neue Strecke, 47 Tunnelkilometer und 100 Brücken erzielt wird.<sup>2</sup>

Einer der 12 neuen Bahnhöfe wird im Lavanttal gebaut, verknüpft dadurch die bestehende Lavanttalbahn mit der Koralmbahn und bietet somit für die dortige Region einen optimalen Anschluss an die Hochleistungsstrecke.<sup>3</sup> Im Zuge der Errichtung dieses Knotenpunktes ist auch eine Schaltstation, welche das Untersuchungsobjekt für die durchgeführte Datenerhebung darstellt, zu bauen. Sie besteht aus einer reinen Stahlbetonbauweise und ist für die Unterbringung der elektrischen Anlagen notwendig.

Bei dem Bauvorhaben Bahnhof Lavanttal errichtet die Firma Kostmann GesmbH neben diesem auch weiterer Gebäude. Um einen Eindruck von der gesamten Baustelle zu bekommen, wird die nachfolgende Abbildung 5-1 gezeigt. Hierbei ist die Schaltstation durch ein grünes Rechteck, die dortig angeordnete Lagerfläche durch den gelben Bereich und der dazugehörige Container durch die braune Fläche verdeutlicht. Über die strichlierte blaue Linie führt der Weg um das Baufeld einer weiteren Firma, welche für den Tunnelbau zuständig ist, zu den Personal-/Baucontainern (rot) sowie zur allgemeinen Lagerfläche (gelb). Die weiteren zu errichtenden Bauwerke sind durch ein violette (Betriebsgebäude) und ein blaues Rechteck (Aufnahmegebäude) dargestellt. Der gesamte blaue Weg beträgt rund 1 km, die Distanz zwischen dem Schaltgebäude und den Personal-/Baucontainern macht ca. 650 m aus.<sup>4</sup>

<sup>1</sup> Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021.

<sup>2</sup> Vgl.: <https://infrastruktur.oebb.at/de/projekte-fuer-oesterreich/bahnstrecken/suedstrecke-wien-villach/koralmbahn>. Datum des Zugriffs: 01.11.2021

<sup>3</sup> Vgl.: <https://infrastruktur.oebb.at/de/projekte-fuer-oesterreich/bahnstrecken/suedstrecke-wien-villach/koralmbahn/rund-um-den-bau/st-andrae-aich>. Datum des Zugriffs: 01.11.2021

<sup>4</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 32



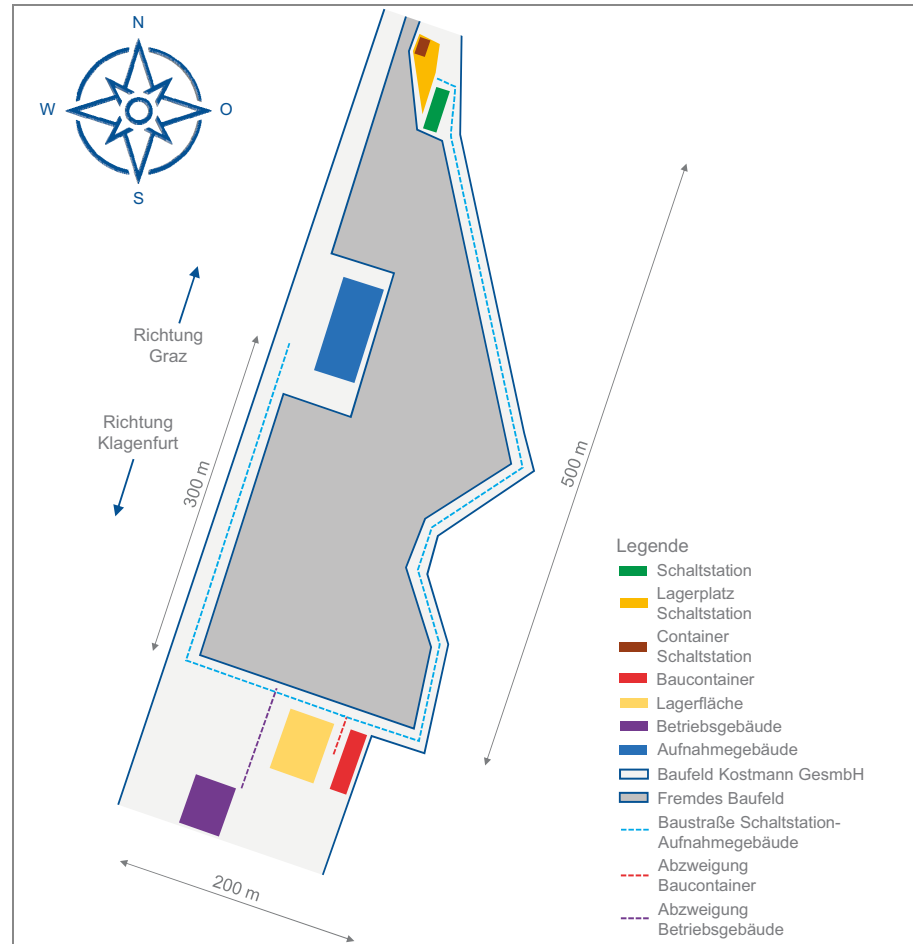


Abb. 5-1 Überblick Bauvorhaben Lavanttal<sup>5</sup>

Die in der Übersicht grün markierte Schaltstation erstreckt sich über eine Länge von 31 m und eine Breite von rund 5 m. Die Gebäudehöhe beläuft sich auf 5,5 m. Innerhalb dieser Abmessungen werden sieben große Räume mit folgenden Verwendungszwecken errichtet:<sup>6</sup>

- Anlagenräume für Sicherungs- und Telekommunikationstechnik
- Einen Niederspannungsraum
- Hochspannungsräume
- Einen Traforaum für die Weichenheizung

Im Grundriss, welcher in Abbildung 5-2 gezeigt wird, ist die Raumaufteilung ersichtlich. Hierbei bestehen sowohl die Außen- als auch die Innenwände aus 20 cm dickem Stahlbeton. An dieser Stelle ist anzumerken, dass sich dies sehr positiv auf die Datenerhebung auswirkt, weil dadurch die elektromagnetischen Wellen so stark abgeschwächt werden, dass beispielsweise ein BLE-Signal<sup>7</sup> in den Nachbarräumen nicht mehr empfangen werden kann. Somit ist in weiterer Folge bei diesem Bauprojekt mit keinen raumübergreifenden Störeinflüssen zu rechnen.

<sup>5</sup> Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 33

<sup>6</sup> Vgl.: ÖBB-Infrastruktur AG: Koralmbahn Graz - Klagenfurt, Baulos 50.3, Bahnhof Lavanttal, Baubeschreibung. S. 42

<sup>7</sup> Bluetooth-Low-Energy-Signal




Abb. 5-2 Grundriss der Schaltstation<sup>8</sup>

Alle im Bauwerk eingesetzten Bauteile werden in Abbildung 5-3 dargestellt, wobei im Zuge der Errichtung zunächst mit der Bodenplatte – aufgeteilt in 2 Betonierabschnitte – begonnen wird. Anschließend folgen in 8 Fertigungsabschnitten die Sockel und darauf aufgestellt die Wände. Weil nur die Außenwände auf den 1 m hohen Sockeln platziert werden, gilt es, die Innenwände um diese Höhe zu verlängern. Schlussendlich wird die Decke und die Attika hergestellt. Abbildung 5-4 zeigt die fertige Schaltstation.<sup>9</sup>




Abb. 5-3 Schnitt der Schaltstation<sup>10</sup>

<sup>8</sup> Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 38; Vgl.: ÖBB INFRA: Koralmbahn Graz - Klagenfurt. BF. Lavanttal. Baulos 50.3. Plan Schaltstation

<sup>9</sup> Vgl.: Kostmann GmbH: Bauzeitplan, Stand 19.02.2021

<sup>10</sup> Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 38

Abb. 5-4 Schaltstation<sup>11</sup>

## 5.2 Systembeschreibung und Funktionsweise

Wie in Kapitel 4 erläutert, basiert das Gesamtsystem zur automatischen Erhebung der Positionen der Arbeitskräfte auf einer Kombination von GNSS<sup>12</sup> und BLE-Beacons. Ersteres ermöglicht hierbei die Outdoor-Ortung. Sobald jedoch die Verbindung zu den Satelliten aufgrund der Stahlbetonwände unterbrochen wird, sind für eine genaue Bereichszuordnung die BLE-Beacons miteinzubeziehen. Die hierfür notwendige technologische Lösung wird seitens der Firma M2M Global Solutions Ltd<sup>13</sup> bereitgestellt und setzt sich aus folgenden Bestandteilen zusammen:

1. Datenerhebung:
  - Working Gadget (GPStraqer WG-1030)
  - BLE-Beacons (Blue Puck ID)
2. Datenübertragung
  - SIM-Karte (GSM-Mobilfunkstandard)
3. Datenaufbereitung
  - M2M-Onlineplattform (<https://eam.m2mgs.com/login>)

Bei dem soeben skizzierten Systemaufbau stellt das Working Gadget das Schlüsselement dar, weil es die Signale der GNSS-Satelliten und der BLE-Beacons aufnimmt und diese, versehen mit einem Zeitstempel, an die Plattform mittels eingebauter SIM-Karte weiterleitet. Nachfolgend werden die Gadgets, die Beacons und die Plattform näher beschrieben.

<sup>11</sup> Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 34

<sup>12</sup> Globales Navigationssatellitensystem

<sup>13</sup> <https://ext.m2mgs.com/>. Datum des Zugriffs: 29.12.2021

### 5.2.1 Working Gadget (GPStraqer WG-1030)

Das eingesetzte Working Gadget besteht aus einem schwarzen Kunststoffgehäuse, welches 92 mm lang, 65 mm breit und 10 mm dick ist und insgesamt 80 g wiegt. Weiters weist es fünf Druckknöpfe auf, welche individuell konfiguriert werden können und eine wichtige Rolle bei der Tätigkeitszuordnung spielen. Ebenso sind drei LED-Lampen in der Hülle integriert, um Auskunft über den Batteriestatus und über die Verbindung mittels GSM sowie GNSS zu geben.<sup>14</sup>

Hinter dem Schutzgehäuse verbergen sich unter anderem eine Batterie, welche im Standby-Modus 90 Tage auskommt, diverse elektronische Bauteile, um GNSS- und BLE-Signale zu verarbeiten, sowie ein Beschleunigungssensor. Aufgeladen wird das Gadget über eine Micro-USB-Schnittstelle und mittels diverser Sleep-Modi lässt sich die Batterielebensdauer beeinflussen. Zudem ist das Gadget vor dem Eindringen von Objekten mit einem Durchmesser größer 2,5 mm geschützt und kann in einem Temperaturbereich zwischen -20 und +60 °C bei einer maximalen Luftfeuchtigkeit von 80 % problemlos eingesetzt werden.<sup>15</sup>

Die nachfolgende Abbildung 5-5 zeigt die Vorderansicht sowie die Rückseite (ohne Gehäuse) des Gadgets und hebt die für die Anwendung wichtigen Komponenten hervor. Weiters sind die zwei vorgesehenen Befestigungsöffnungen ersichtlich. Auf diese wurde jedoch bei der Datenerhebung nicht zurückgegriffen, da die Arbeitskräfte, um nicht hängen zu bleiben, das Working Gadget eingesteckt in der Knietasche mit sich führten.




Abb. 5-5 Working Gadget<sup>16</sup>

Ebenso wird ein Mikrofon und ein Lautsprecher in der Abbildung gezeigt. Diese beiden Bauteile ermöglichen das Telefonieren bei Rückfragen oder im Falle eines Arbeitsunfalls.<sup>17</sup>

<sup>14</sup> Vgl.: <https://www.gpstraqer.com/en/wg-1030/>. Datum des Zugriffs: 14.10.2021

<sup>15</sup> Vgl.: <https://teltonika-mobility.com/product/worker-badge-plus/#features>. Datum des Zugriffs: 14.10.2021

<sup>16</sup> Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 43  
In Anlehnung an: [https://wiki.teltonika-mobility.com/view/GH5200\\_First\\_Start](https://wiki.teltonika-mobility.com/view/GH5200_First_Start)  
[https://wiki.teltonika-mobility.com/view/GH5200\\_First\\_Start](https://wiki.teltonika-mobility.com/view/GH5200_First_Start). Datum des Zugriffs: 14.12.2021

<sup>17</sup> <https://teltonika-mobility.com/product/worker-badge-plus/#features>. Datum des Zugriffs: 14.10.2021

### 5.2.2 BLE-Beacons (Blue Puck ID)

Um die Arbeitskräfte auch innerhalb geschlossener Räumlichkeiten zu erkennen, werden die Blue Puck ID Beacons der Firma ELA Innovation S.A.<sup>18</sup> eingesetzt. Je nach Konfiguration, welche über eine NFC-Schnittstelle erfolgt, weisen diese eine Lebensdauer von bis zu 20 Jahren auf und ermöglichen im offenen Feld eine Übertragungsweite von bis zu 500 m. Weiters erfüllen sie die Voraussetzungen für den Einsatz auf der Baustelle, weil sie robust, staubfest und wasserdicht sind.<sup>19</sup>

Befindet sich ein Gadget in einer mit Beacons ausgestatteten Räumlichkeit, werden die Blue Puck IDs von diesem erkannt und die dazugehörigen Identifikationsnummern an die Plattform weitergeleitet. Auf dieser erfolgt die Umwandlung der zugesendeten Informationen in Raumbezeichnungen.

Die nachfolgende Abbildung 5-6 zeigt beispielhaft die Montage eines Blue Puck IDs an einer fertigen Stahlbetonwand. Hierbei wurde der in eine Klarsichtfolie gelegte Beacon mit Klebeband auf der Bauteilinnenseite befestigt. Die Abmessungen sind Abbildung 5-7 zu entnehmen.



Abb. 5-6 Anbringung BLE-Beacon<sup>20</sup>




Abb. 5-7 Abmessungen BLE-Beacon<sup>21</sup>

<sup>18</sup> <https://elainnovation.com/en/>. Datum des Zugriffs: 14.12.2021

<sup>19</sup> Vgl.: <https://elainnovation.com/en/catalogue/blue-puck-id-en/>. Datum des Zugriffs: 14.12.2021

<sup>20</sup> Symbolfoto (oben rechts): <https://elainnovation.com/en/catalogue/blue-puck-id-en/>. Datum des Zugriffs: 14.12.2021

### 5.2.3 Datenaufbereitung

Die M2M-Plattform stellt das Werkzeug zur Datenanalyse und -aufbereitung, Filterung sowie Visualisierung dar. Weiters ermöglicht sie das Zuordnen der Ortungsdaten zu bestimmten Bereichen. Ein solcher Abschnitt wird Geofence – geographischer Zaun – genannt und beinhaltet beispielsweise den Pausencontainer, den Lagerbereich oder das Bauwerk selbst. Mit Hilfe der Plattform können die Geofences rasch erstellt werden und ermöglichen nach deren Implementierung das zeitliche Zuordnen der Arbeitskräfte, indem der Zeitpunkt des Betretens und der des Verlassens eines Abschnitts ausgegeben wird.

In Abbildung 5-8 ist die nach dem Einloggen ersichtliche Startseite der Plattform dargestellt. Die in der Mitte angezeigten Polygonzüge (violett und rot) stellen Geofences dar, welche beispielsweise durch das Setzen der Eckpunkte erstellt werden können. Für eine bessere Orientierung hilft hierbei das Einbinden der im Hintergrund liegenden Luftbildaufnahme. Der gelbe Pfeil mit der Bezeichnung WG\_0588 repräsentiert ein eingeschaltetes Gadget. Auf der linken Seite (grüner Rahmen) befindet sich die Auflistung der Working Gadgets mit integrierter Aktivitätsanzeige, bei der je nach konfigurierbarer Bewegungsintensität, in die drei Ampelfarben rot (inaktiv), gelb (stehen) und grün (bewegen) gegliedert wird. Die angezeigte Uhrzeit und der gelbe Punkt des ersten Eintrags lassen darauf schließen, dass die Arbeitskraft noch bei der Ausgabe steht. Weiters ist im gelb umrandeten Reckteck eine Push-Mitteilung zu sehen. Diese erscheint immer, wenn ein Ereignis wie beispielsweise das Auswählen der Tätigkeit Schalen stattfindet. Der untere blaue Bereich beinhaltet die Statusleiste des ausgewählten Gadgets. In diesem Menüband werden die wichtigsten Informationen wie beispielsweise Adresse, Datum und Uhrzeit, Batteriestatus, zurückgelegte Distanz oder Geschwindigkeit zusammengefasst.<sup>22</sup>

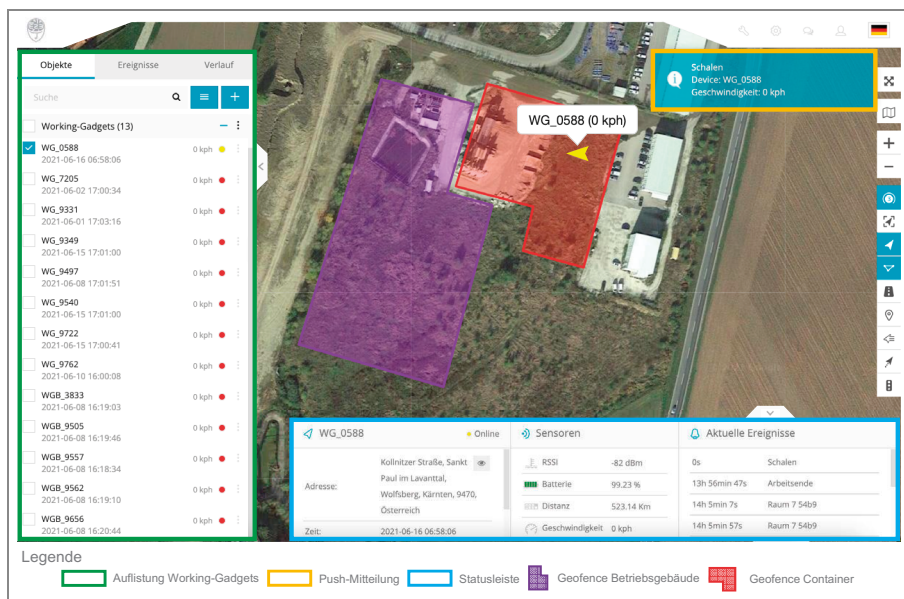


Abb. 5-8 Übersicht M2M-Plattform<sup>23</sup>

<sup>21</sup> In Anlehnung an: ela innovation: Product sheet – IDF25240E. Technical specification. S. 2

<sup>22</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 46f

<sup>23</sup> Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 47

Neben der Betrachtung der aktuellen Position ermöglicht die Plattform auch die Visualisierung des zurückgelegten Weges. Hierfür ist auf den Reiter „Verlauf“ zu wechseln und das gewünschte Working Gadget sowie der Zeitraum auszuwählen. Darauf folgend werden die einzelnen mit Zeitstempel versehenen Positionen als rote Dreiecke dargestellt und durch eine blaue Linie verbunden. Ebenso sind diesem Menü die Uhrzeiten der eingetretenen Ereignisse, die Dauern der zurückgelegten Strecken und der Stillstände zu entnehmen. Im vorliegenden Fall holt zunächst die Arbeitskraft das mit der Tätigkeit Schalen ausgegebene Gadget ab, geht nochmals kurz in den Container und befindet sich anschließend für 19 min und 26 s in Bewegung. Hierbei fährt sie zunächst zum Aufnahmegebäude, um das Transportfahrzeug zu beladen, und daraufhin zur Schaltstation. Beim Klicken auf diese Bewegungsdauer wird der dazugehörige Weg automatisch grün eingefärbt. Nach dem Eintreffen beim zu errichtenden Bauwerk zeigt die Plattform einen 10-minütigen Stillstand an. Dies bedeutet jedoch nicht, dass die Arbeitskraft keine Bewegung ausübt, sondern dass die zurückgelegte Strecke keine signifikante Veränderung bewirkt hat – wie es beispielsweise beim Ausräumen und Abladen der Geräte sowie Materialien vom Transportfahrzeug der Fall ist.



Abb. 5-9 Visualisierung des zurückgelegten Weges

Die vorhin angesprochene Tätigkeitsauswahl erfolgt über die Druckknöpfe des Working Gadgets. Immer, wenn eine Fachkraft mit einer neuen Arbeit beginnt, ist davor der passende Druckknopf zu betätigen. Dadurch wird in weiterer Folge ein Ereignis erstellt und in der Datenbank gespeichert.

Weil die Bewehrungsverlegung von einem Subunternehmer ausgeführt wird, erhält dieser eigene Working Gadgets, welche nur die Tätigkeit Bewehren und Gebäudewechsel beinhalten. Den Arbeitskräften der Firma Kostmann werden andere Gadgets, welche die Tätigkeiten Schalen, SiGe-Arbeiten,

Betonieren und Gebäudewechsel aufweisen, zugeteilt. Weiters wird durch eine Doppelbelegung einzelner Tasten am Ende der Stahlbetonarbeiten „Gebäude reinigen/räumen“ und „Betonfehlstellen ausbessern“ hinzugefügt. Das Ereignis „Gebäudewechseln“ ist darauf zurückzuführen, dass zur selben Zeit mehrerer Gebäude errichtet wurden, weshalb die Arbeitskräfte untertags zwischen den Bauwerken wechselten.<sup>24</sup>

Nachdem die Ortungsdaten zur Plattform geschickt und den Geofences zugeteilt wurden, können die veredelten Informationen in Form verschiedener Berichte heruntergeladen werden. Um eine automatisierte Zuteilung der angefallenen Lohnstunden zu den Bauteilen zu ermöglichen, greift Konegger auf den Geofence- und Event-Bericht zurück, wodurch unter anderem folgende Parameter Berücksichtigung finden:<sup>25</sup>

- Geofence-Bericht:
  1. Geofence-Name
  2. Datum und Uhrzeit beim Betreten und Verlassen des Geofence
  3. Aufenthaltsdauer im Geofence
  4. Zurückgelegte Strecke innerhalb des Geofence
  5. Höchstgeschwindigkeit innerhalb des Geofence
  6. Durchschnittsgeschwindigkeit innerhalb des Geofence
- Ereignis-Bericht:
  1. Datum und Uhrzeit des Entstehungszeitpunktes des Ereignisses
  2. Name des Ereignisses (Schalen, Bewehren, Betonieren ...)
  3. Position des Ereignisses

Zusätzlich fließen die aktuellen Wetterdaten, welche mittels einer eigens für das Bauprojekt angebrachten digitalen Wetterstation erhoben werden, mit ein. Weiters findet ein Bauteilprotokoll, welches Datum und Uhrzeit sowie das zu errichtende Bauteil (Bodenplatte, Sockel, Wand, Decke und Attika) beinhaltet, Berücksichtigung, damit über den Zeitstempel eine Verknüpfung zwischen dem Bauteil und den angefallenen Lohnstunden erstellt werden kann.<sup>26</sup>

#### 5.2.4 Funktionsweise

Abbildung 5-10 fasst die soeben beschriebenen Systembestandteile zusammen und verbildlicht den Prozess von der Datenerhebung bis hin zur Modellbildung. Während die Arbeitskraft das Working Gadget bei sich trägt, bestimmt dieses in konfigurierbaren Intervallen die Position mittels GNSS und schickt über die eingebaute SIM-Karte (GSM) die Daten an die Plattform. Diese Art der Ortung funktioniert problemlos, solange genügend Satelliten in Reichweite sind. Im freien Feld ist dies der Fall, weil auf verschiedene GNSS zurückgegriffen werden kann. Betritt jedoch die Fachkraft einen Raum, kommt es zu Störungen beim Signalempfang, weil die elektromagnetischen Wellen durch den Stahlbeton abgelenkt bzw. abgeschirmt werden. Aus diesem Grund weisen die fertigen Räume BLE-Beacons auf, welche das Working Gadget beim Betreten erkennt und als Ereignis zur Auswertung an

<sup>24</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 50ff

<sup>25</sup> Vgl.: <https://eam.m2mgs.com>. Datum des Zugriffs 10.10.2021

<sup>26</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 74



die Plattform weiterleitet. Auf dieser wird daraufhin anhand der erhobenen Identifikationsnummer der dazugehörige Raum ermittelt. Dadurch ist sichergestellt, dass auch eine Bereichszuordnung im Inneren des Bauwerks möglich ist. Abschließend gilt es, den Event- und Geofence-Bericht für den gewünschten Zeitrahmen downzuloaden und gemeinsam mit dem Bauteilprotokoll sowie dem Wetterbericht in die Excel-basierte Modellbildung einzuspielen, in der zunächst alle Informationen in einer Tabelle zusammengefasst werden.<sup>27</sup> Dieser Datensatz bildet die Grundlage für die nachfolgende, in Kapitel 6 beschriebene Klassifikation der Tätigkeiten Schalen, Bewehren und Betonieren auf Basis der Bewegungsmuster der Arbeitskräfte.

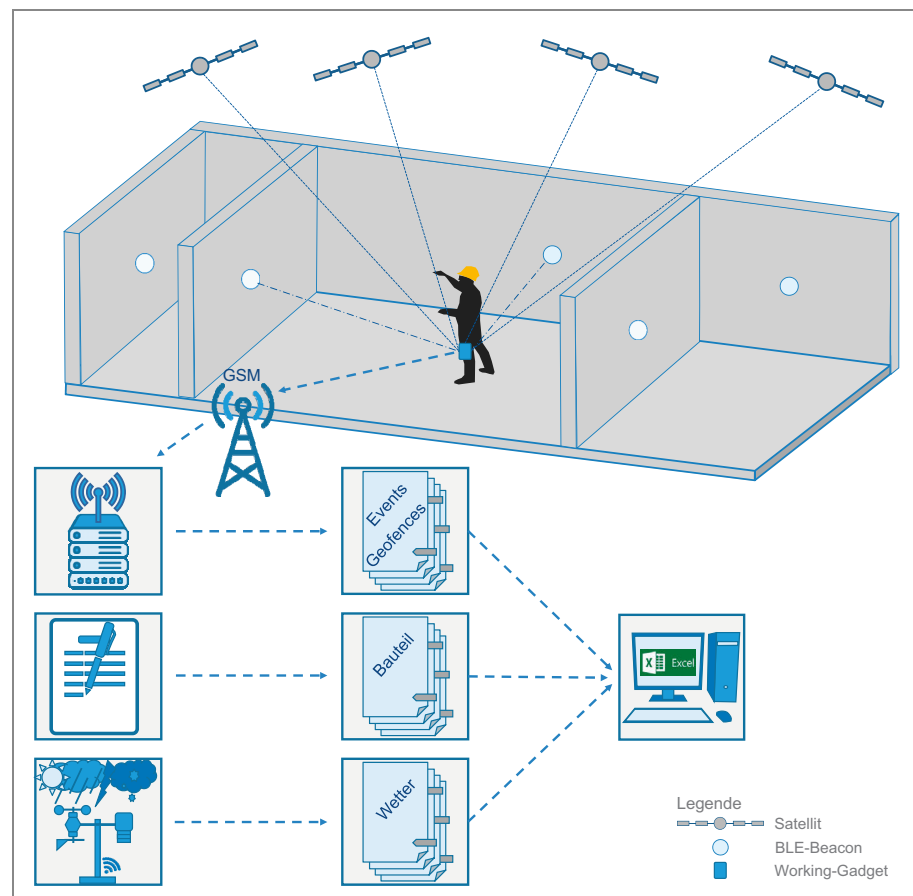


Abb. 5-10 Funktionsweise der Datenerhebung

Abschließend werden nochmals die einzelnen Prozessschritte von der Datenerhebung bis hin zur zusammengefassten Tabelle, welche als Ursprungsdatensatz für die nachfolgende Klassifikation dient, in einem Ablaufdiagramm dargestellt. Während der gesamten Datenerfassung wird hierbei täglich in der Früh das Gadget eingeschaltet, der zur ersten Tätigkeit passende Knopf gedrückt, das Ortungsgerät ausgegeben und in die Knietasche der Arbeitskraft gesteckt. Daraufhin beginnt die Fachkraft mit dem Verrichten der Arbeiten. Erfolgt ein Wechsel der Tätigkeit, ist dieser selbstständig über die Druckknöpfe bekannt zu geben. Am Ende des Arbeitstages kehrt die Mannschaft zum Personalcontainer zurück und gibt die Ortungs-

<sup>27</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 87ff

geräte ab. Diese sind in weiterer Folge in die Nähe des Arbeitende-Beacons zu legen, um das gleichnamige Ereignis auszulösen, wodurch die Lohnstundenaufzeichnung beendet ist. Über Nacht gilt es, die Working Gadgets auszuschalten und mittels Micro-USB aufzuladen. An dieser Stelle ist darauf hinzuweisen, dass die Daten anonymisiert gesammelt werden, da die Working Gadgets bei der morgentlichen Ausgabe zufällig verteilt werden. Dadurch ist nicht nachzuvollziehen, wer welches Gadget mit sich führt. Es ist lediglich bekannt, dass eine bestimmte Anzahl an Arbeitskräften auf der Baustelle ist.<sup>28</sup>

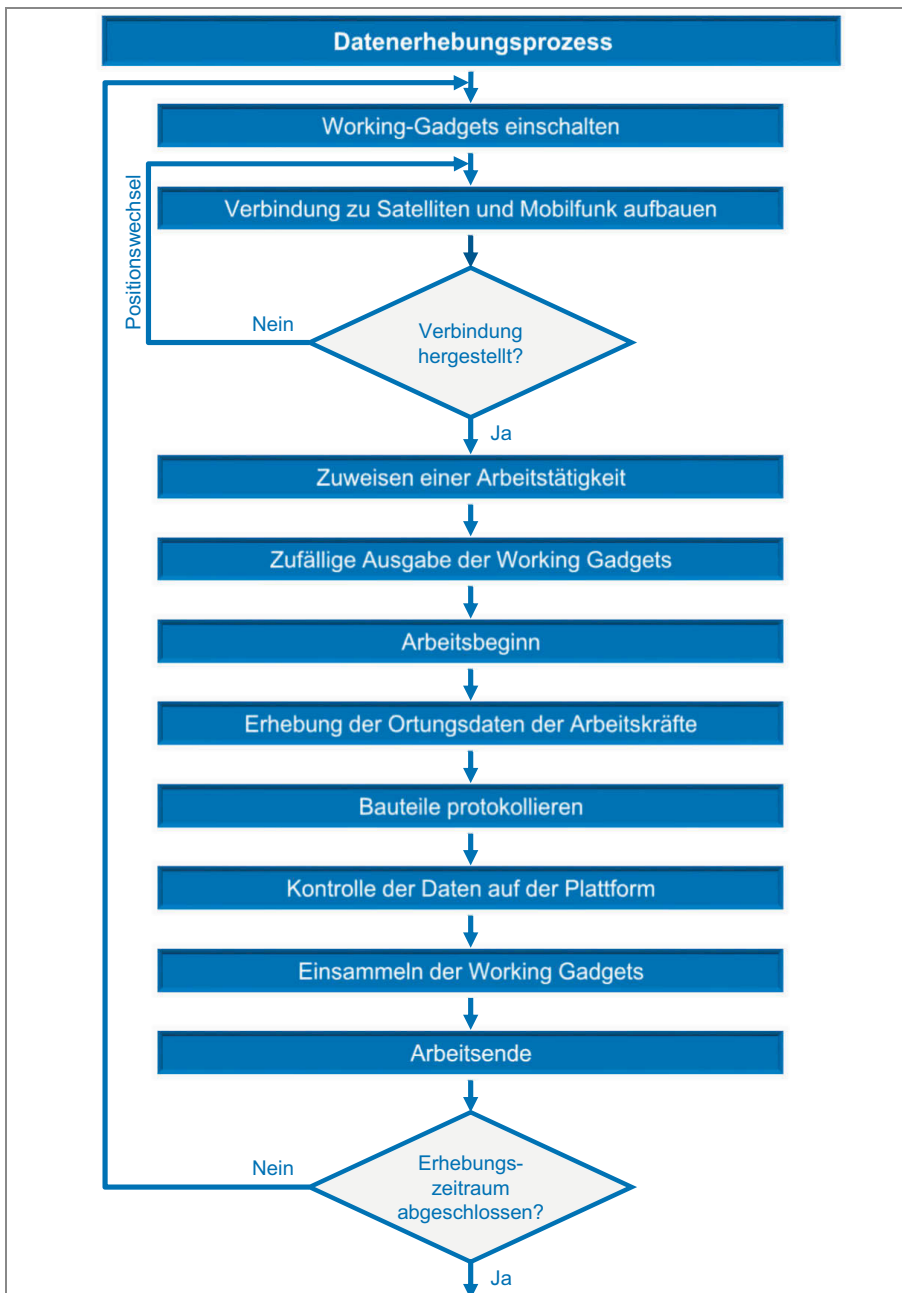


Abb. 5-11 Prozess der Datenerhebung<sup>29</sup>

<sup>28</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 90f

<sup>29</sup> Aufbauend auf: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 88

Nachdem der Zeitraum des Datenerhebungsprozesses verlassen wurde, gilt es, im nächsten Schritt die Berichte zu erzeugen (Abbildung 5-12). Hierbei sind auf der M2M-Plattform die Geofence- und Ereignisberichte zu erstellen und als Excel-File downzuloaden. Selbiges gilt auch für die Wetterdaten, welche von der Wetterstation erhoben und mittels WLAN auf einen Server geschickt werden. Abschließend müssen noch die einzelnen Bauteilprotokolle in einer Excel-Tabelle zusammengefasst und alle erstellten Berichte auf Vollständigkeit überprüft werden.<sup>30</sup>

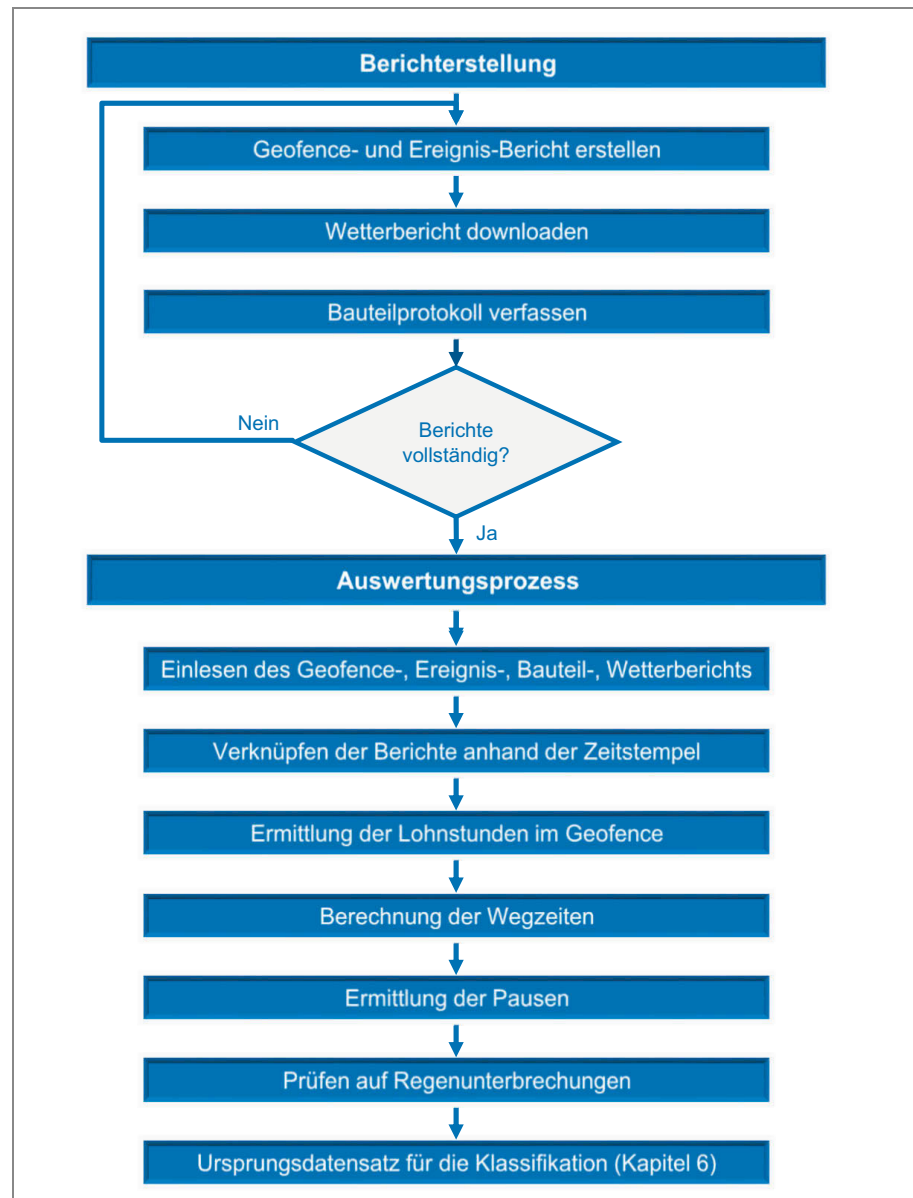


Abb. 5-12 Berichterstellungs- und Auswerteprozess<sup>31</sup>

<sup>30</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 92

<sup>31</sup> Aufbauend auf: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 89

Nach der erfolgreichen Berichtprüfung startet der Auswertungsprozess, welcher in Abbildung 5-12 vom Beginn bis zur Erstellung des Ursprungsdatensatzes (Grundlage für die Klassifikation der Tätigkeiten Schalen, Bewehren und Betonieren) abgebildet ist. Hierbei stellt das Einlesen sowie das Verknüpfen der einzelnen Einträge auf Basis der vorhandenen Zeitstempel den ersten Schritt dar. Darauf aufbauend werden die Lohnstunden im Geofence, die Wegzeiten (Dauer zwischen zwei Geofences) und die Pausen ermittelt. Letzteres beruht auf der Auswertung vom Geofence, der Aufenthaltsdauer und bestimmter BLE-Beacons. Somit befinden sich Arbeitskräfte der Firma Kostmann in der Pause, wenn diese zwischen 30 und 40 Minuten im Geofence „Container“ verbringen und eine BLE-Verbindung zu mindestens einem der zwei im Pausenraum angebrachten Beacons hergestellt wird. Schlussendlich gilt es noch, zu prüfen, ob ein Regenereignis vorliegt, bevor der Ursprungsdatensatz für die Klassifikation herangezogen werden kann. Dies geschieht mit Hilfe der Daten der Wetterstation.<sup>32</sup>

### 5.3 Systemevaluation

Die Implementierung und Erprobung des ausgewählten Konzepts zeigt, dass Lohnstunden mittels GNSS und BLE-Beacons kontinuierlich erhoben, definierten Bereichen zugeordnet und mit Hilfe der Gadget-Tasten den Tätigkeiten zugeteilt werden können. Dies erfolgt völlig automatisch. Eine bauteilbezogene Zuordnung ist jedoch bei alleiniger Anwendung dieses Erhebungskonzepts nicht durchführbar. Hierfür ist der Einsatz einer zusätzlichen Liste, welche das Verknüpfen des zu errichtenden Bauteils mit der Tätigkeit über einen Zeitstempel ermöglicht, notwendig. Eine noch in Entwicklung befindende Gadget-Version kann hierbei zukünftig Abhilfe schaffen. Bei dieser wird die Eingabe verschiedener Inputs (beispielsweise Tätigkeit und Bauteil) mittels Touchscreen erleichtert.

Die einzelnen Systemkomponenten Working-Gadget, BLE-Beacons und M2M-Onlineplattform funktionierten über einen Erhebungszeitraum von rund 3 Monaten problemlos. Lediglich ein Softwareupdate führte zu einem kurzfristigen Ausfall der Plattform, wodurch keine Daten aufgezeichnet wurden. Diese mussten händisch nachgetragen werden.

Das Gadget selbst ermittelte kontinuierlich die eigene Position und erkannte ohne Schwierigkeiten die Bluetooth-Signale in den Räumen bzw. Containern. Weiters kann mit Hilfe der Randbedingungen für die Ermittlung neuer Positionen – beispielsweise Winkeländerung, Wegänderung, Geschwindigkeitsunterschied – und der zu sendenden Paketgröße der Akkuverbrauch beeinflusst werden. Eine Echtzeitortung über 10 Stunden, bei der sofort jede Positionsänderung übermittelt wird, war bei dem vorliegenden Gadget batterie-technisch nicht möglich. Zusätzlich würden dadurch sehr große Datenmengen erzeugt werden, welche es daraufhin zu speichern und auszuwerten gilt.

Bezüglich der GNSS-Genauigkeit ist festzuhalten, dass die angegebene maximale Abweichung von 2 m<sup>33</sup> auf der grünen Wiese und beim Errichten

<sup>32</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 93

der Bodenplatte sowie der Sockel eingehalten wurde. Im Zuge der Fertigung der Außenwände vergrößerten sich jedoch die Unstimmigkeiten aufgrund der Reflexionen und Störeinflüsse der Schalung sowie der fertigen Stahlbetonwände. Daher fiel bei der Errichtung der Innenwände, welche nach den Außenwänden erfolgte, die Genauigkeit signifikant schlechter aus. Abbildung 5-13 verdeutlicht diesen Sachverhalt. Hierbei ist zu erkennen, dass zwar die Positionen nicht stimmen, aber sich die Arbeitskräfte noch im richtigen Geofence (Baufeld) befinden. Wäre dies nicht der Fall, würden die Lohnstunden fälschlicherweise den Wegzeiten (Dauer zwischen zwei Geofences) oder den Lagerarbeiten (roter Bereich) zugerechnet werden. Damit es zu weniger fehlerhaften Zuteilungen kommt, gilt es, die Geofences unter Berücksichtigung möglicher Ungenauigkeiten zu definieren.

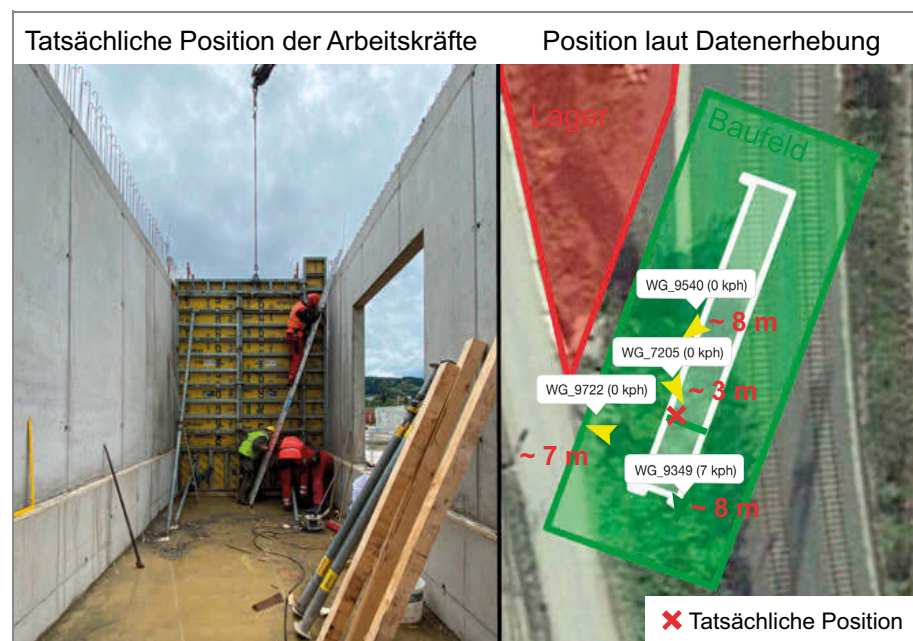


Abb. 5-13 GNSS-Genauigkeit bei der Errichtung der Innenwände

Um den GNSS-Signalsprüngen im Indoor-Bereich entgegenzuwirken, wurden BLE-Beacons an den Wänden angebracht. In den Räumlichkeiten erkennt das Working-Gadget die BLE-Signale und sendet diese an die Plattform weiter, auf der die Verknüpfung mit den Raumbezeichnungen stattfindet. Vorteilhaft bei dieser Baustelle ist, dass der Stahlbeton die in den einzelnen Räumen angebrachten BLE-Beacons gut voneinander trennt. Dadurch kann in weiterer Folge die GNSS-Position bei Empfang eines BLE-Signals überschrieben werden. Ist es jedoch nicht gewährleistet, dass kein Bluetooth-Signal den dafür vorgesehenen Bereich verlässt, muss die Signalstärke herangezogen werden, um zu beurteilen, ob die GNSS-Ortung priorisiert wird oder nicht.

Eine Behinderung des Bauablaufs ist beim Einsatz dieses Erhebungskonzeptes nicht eingetreten. Auch der Aufwand der Arbeitskräfte ist aufgrund deren Rückmeldung als minimal und unproblematisch einzustufen. Das morgentliche Abholen und abendliche Zurückgeben der Gadgets sowie das Betätigen der Druckknöpfe wurde sehr rasch angenommen. Aber nicht nur

<sup>33</sup> Vgl.: <https://www.gpstraqer.com/en/wg-1030/>. Datum des Zugriffs: 31.12.2021

die Bekanntgabe der Tätigkeiten, sondern auch der Gebäudewechsel funktionierte einwandfrei.

Weiters fiel auch bei der Implementierung und Einrichtung der Ortungsinfrastruktur nur ein geringer zeitlicher Aufwand an. Zu Beginn gilt es, die Geofences festzulegen und die verwendeten Gadgets auf der Plattform einzutragen. Anschließend werden noch die Druckknöpfe mit den gewünschten Tätigkeiten belegt. Diese Schritte benötigen bei einem mit der vorliegenden Baustelle vergleichbaren Projekt rund 3 Stunden. Daraufhin kann bereits mit der Datenerhebung begonnen werden. Während des Erhebungszeitraums ist mit einer täglichen Dauer von 10 min für den morgentlichen Ausgabeprozess und 20 min für den Einsammel- sowie Aufladeprozess zu rechnen. Für die Erstellung des Bauteilprotokolls und die überblicksmäßige Kontrolle der angefallenen Tätigkeiten muss nochmals ein zusätzlicher Aufwand von rund 15 min pro Tag eingeräumt werden. Ist der Bauprozess soweit vorangeschritten, dass einzelne räumlich abgetrennte Bereiche bereits vorhanden sind, kann mit dem Anbringen der BLE-Beacons sowie deren Implementierung auf der Plattform begonnen werden. Können keine BLE-Signale den Raum verlassen, ist dieser Prozess sehr rasch abgeschlossen. Sollten jedoch Beacons außerhalb der definierten Bereiche erkannt werden, gilt es, die Signalstärken zu ermitteln und in Bedingungen für die Bereichszuordnung (z.B.: dass die Signalstärke einen bestimmten Wert unterschreiten muss, um einem Geofence zugeteilt zu werden) zu transformieren. Dies wiederum benötigt rund 3 Stunden.

Anhand der zeitlichen Aufstellung ist ersichtlich, dass die für die Erhebung anfallenden Lohnstunden zwar nicht vernachlässigbar sind, aber auch keine schwerwiegenden Auswirkungen mit sich führen. Bei dem untersuchten Projekt würden innerhalb des 15-wöchigen Erhebungszeitraums rund 60 Stunden für die Implementierung und Betreuung des Erhebungskonzeptes anfallen. Dies macht rund 3,8 % der gesamten Stahlbeton-Lohnstunden (1.632,5 Std<sup>34</sup>) aus. Hierbei ist aber auch zu berücksichtigen, dass die Einführung dieses digitalen Erhebungskonzeptes die Dokumentationstätigkeiten wie beispielsweise das Erstellen der Bautagesberichte wesentlich erleichtert und sich die Nachkalkulation durch die aus den Lohnstunden berechneten Aufwandswerte verbessert. Die zur Veredelung der erhobenen Daten notwendige Modellbildung wird in dieser Aufstellung nicht berücksichtigt, da sie nach der Datenerfassung erfolgt und stark von der vorhandenen Software bzw. den Programmierkenntnissen der mit der Aufgabe vertrauten Person abhängt.

<sup>34</sup> Vgl.: Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021. S. 109



## 6 Exemplarische Vorgehensweise bei einer Klassifikation mittels neuronaler Netze

In diesem Kapitel wird die Anwendung neuronaler Netze anhand eines Fallbeispiels erläutert. Hierbei wird das Ziel verfolgt, mittels künstlicher Intelligenz die Tätigkeiten Schalen, Bewehren und Betonieren auf Basis von Bewegungsmustern vorherzusagen. Diese Möglichkeit bietet eine rasche Hilfestellung bzw. Kontrollfunktion beim Verknüpfen der angefallenen Lohnstunden mit den dazugehörigen Tätigkeiten.

Zu Beginn liegt der Fokus auf den Ergebnissen der Erhebung sowie dem für die weitere Verarbeitung herangezogenen Datensatz. Daraufhin werden die Datenaufbereitung und der iterative Modellbildungsprozess<sup>1</sup> beleuchtet. Hierbei werden unter Berücksichtigung des hermeneutischen Regelkreises jeweils zuerst der Datensatz genau analysiert, die künstliche Intelligenz trainiert und anschließend die Resultate diskutiert. Die Verständniserweiterung erfolgt vor allem bei der Untersuchung der Variablenverteilung, welche die Grundlage einer effektiven Modellbildung darstellt, und dem Erkenntnisgewinn aus der Beurteilung der neuronalen Netze.

Die nach jeder Modellbildungsvariante eingesetzten Testdaten überprüfen die Übereinstimmung von Wirklichkeit und Modell anhand realer Baustellenbedingungen. Dadurch ist die Validierung aller aufgestellten Modelle gegeben. Dieser Überprüfungsschritt der Modellbildung darf jedoch nicht mit den Validierungsfällen der neuronalen Netze gleichgesetzt werden. Bei letzteren handelt es sich lediglich um jene Fälle, welche aus den trainierten Modellen das beste Netz bestimmen. Somit sind diese Daten im Modellentwicklungsprozess beinhaltet und können daher nicht gleichzeitig als Validierungsergebnis im Sinne der wissenschaftlichen Erkenntnismethode herangezogen werden, weshalb dies mittels der Testdaten erfolgt. Um eine sprachliche Unterscheidung beim Einsatz dieses Begriffes sicherzustellen, wird folglich die Übereinstimmungsprüfung mit der Wirklichkeit – als wesentlicher Schritt der Modellierung – nur noch als Modellvalidierung bezeichnet.

### 6.1 Vorgehensweise und Parameterauswahl

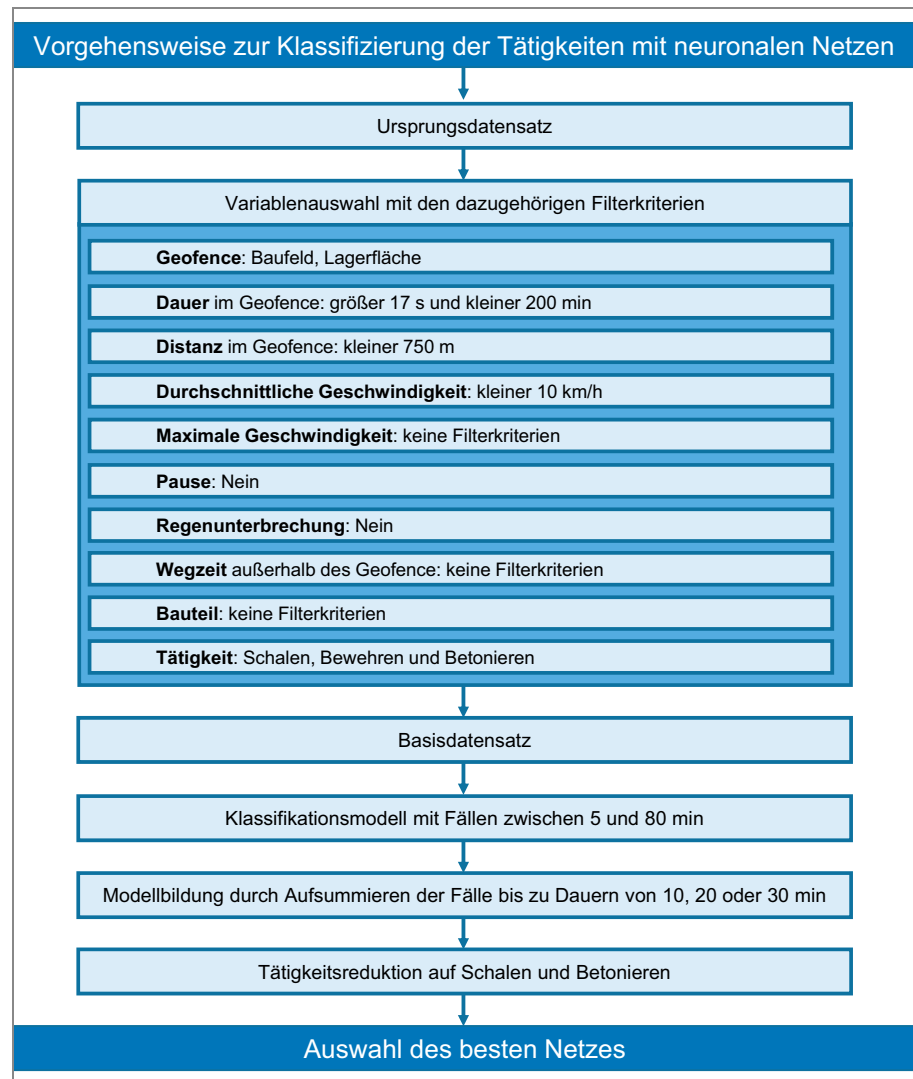
Das auf künstlicher Intelligenz basierende Modell zur Klassifikation von Tätigkeiten baut auf die Ergebnisse der vorhin beschriebenen Datenerfassung<sup>2</sup> auf. Die Zusammenstellung der hierbei erhobenen und täglich kontrollierten Daten dient als Grundlage und wird fortan als Ursprungsdatensatz bezeichnet. Von diesem ausgehend, werden zunächst signifikante Parameter ausgewählt und unter Berücksichtigung einzelner Filterkriterien zum Basisdatensatz, welcher den Ausgangspunkt für das Trainieren, Validieren und Testen der neuronalen Netze darstellt, zusammengefasst.

<sup>1</sup> Schrittweise Verbesserung des Systemverständnisses

<sup>2</sup> Im Rahmen dieser Dissertation betreute und von *Konegger* vor Ort durchgeführte Datenerfassung, Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Institut für Baubetrieb und Bauwirtschaft, TU Graz, 2021.



Abbildung 6-1 verdeutlicht die Datensatzauswahl und die Darstellung des auf den Basisdatensatz aufbauenden Modellierungsprozesses. Hierbei wird zunächst ein Klassifikationsmodell erstellt, bei dem die Dauer der einzelnen Fälle zwischen 5 und 80 Minuten liegt. Für die darauffolgende Erstellung des zweiten Modells werden hintereinanderliegende Fälle so lange aufsummiert, bis eine Dauer von 10, 20 oder 30 Minuten erreicht ist. Abschließend wird noch im Zuge der dritten Variante eine Tätigkeitsreduktion auf Schalen und Betonieren durchgeführt, um die Vorhersagen zu verbessern.



**Abb. 6-1** Vorgehensweise zur Klassifizierung der Tätigkeiten

Zu den verwendeten Variablen zählt der Geofence, welcher jenes Gebiet, in der sich die Arbeitskraft befindet, beschreibt. Dieser beinhaltet die Lagerfläche und das untersuchte Bauwerk. Der Aufenthaltsbereich bei den Containern fließt nicht in die Modellbildung mit ein. Weiters werden die darin verbrachte Zeit, sprich die Verweildauer, und die zurückgelegte Distanz jeweils als separate Variablen im Datensatz aufgenommen. Das hierbei eingesetzte Filterkriterium der Dauer bezieht sich auf den Bereich zwischen 17 s und 200 min. Zusätzlich wird die Distanz auf maximal 750 m beschränkt. Diese Bandbreiten wurden gewählt, um sicher zu stellen, dass Ausreißer keine Berücksichtigung finden.

Ebenso werden die durchschnittliche und maximale Geschwindigkeit übernommen, wobei erstere nur Werte beinhaltet, die kleiner als 10 km/h sind. Diese Grenze stützt sich auf die Überlegung, dass neben der Gehgeschwindigkeit von rund 5 km/h auch kurzes Laufen oder GNSS-Signalsprünge abgedeckt werden müssen. Letzteres ist darüber hinaus der Grund, weshalb bei der maximalen Geschwindigkeit keine Einschränkung erfolgt. In Abhängigkeit der in der Umgebung eingesetzten Materialien und Geräte springt das GNSS-Signal der Arbeitskraft aufgrund von Reflexionen mehr oder weniger oft und weit. Diese kurzzeitigen Ortswechsel führen in weiterer Folge zu höheren maximalen Geschwindigkeiten, die natürlich nicht stattgefunden haben, jedoch einen Informationsgehalt über die Umgebung in sich tragen. Beispielsweise beeinflussen Stahlschalungselemente, welche an den Einsatzort gehoben werden, das Signal stärker als der Rüttler beim Verdichten des Betons.

Neben den soeben vorgestellten Variablen, welche das Bewegungsmuster innerhalb eines Geofence beschreiben, beinhaltet der Basisdatensatz auch Spalten, welche kennzeichnen, ob eine Pause oder eine Regenunterbrechung stattgefunden hat. Für die anschließende Modellbildung werden nur Fälle (einzelne Zeile des Ursprungsdatensatzes) zugelassen, die diese beiden Parameter verneinen. Weiters wird eine Spalte für die Wegzeit, welche die Dauer zwischen Verlassen des letzten Geofence und Betreten des nächsten beschreibt, sowie den Bauteiltyp (Bodenplatte, Sockel, Wand, Decke und Attika) hinzugefügt. Um vorhersagen zu können, ob eine Arbeitskraft schalt, bewehrt oder betoniert, muss abschließend noch die dokumentierte Tätigkeit dem Datensatz beigefügt werden.

## 6.2 Basisdatensatz

Der Basisdatensatz, welcher 14.375 Einträge aufweist, beinhaltet die nach den soeben besprochenen Kriterien gefilterten Fälle des Ursprungsdatensatzes und legt somit den Grundstein für alle Modelle. Daher gilt es, diesen zunächst näher zu analysieren, um wichtige Zusammenhänge zu erkennen. Tabelle 6-1 zeigt hierfür die Aufteilung der Fallanzahl unter Berücksichtigung der einzelnen Tätigkeiten, wobei rasch ersichtlich wird, dass Schalen nahezu 76 % der Fälle ausmacht. Daher muss in weiterer Folge bei der Modellbildung mittels NeuralTools darauf geachtet werden, dass die Trainingsdaten annähernd gleich verteilt sind. Ansonsten besteht die Gefahr, dass das neuronale Netz fälschlicherweise alle Prognosen mit Schalen durchführt, weil es gelernt hat, dass diese Tätigkeit sehr oft richtig ist.

Lfd. Nr.	Tätigkeiten	Fälle
0	A	B
1	Schalen	10.898
2	Bewehren	3.112
3	Betonieren	365
4	Summe	14.375

Tab. 6-1 Fallanzahl der einzelnen Tätigkeiten

Neben dem Anteil der einzelnen Tätigkeiten gilt es, auch die Verteilung der Variablen näher zu analysieren, um Bereiche zu identifizieren, die aufgrund der Datenlage nicht für Prognosen geeignet sind. Die nachfolgende Abbildung 6-2 sowie 6-3 zeigen Histogramme der jeweiligen Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren. Die Bandbreiten beziehen sich hierbei auf eine bestmögliche Visualisierung, weshalb einzelne Maximalwerte nicht abgebildet sind.

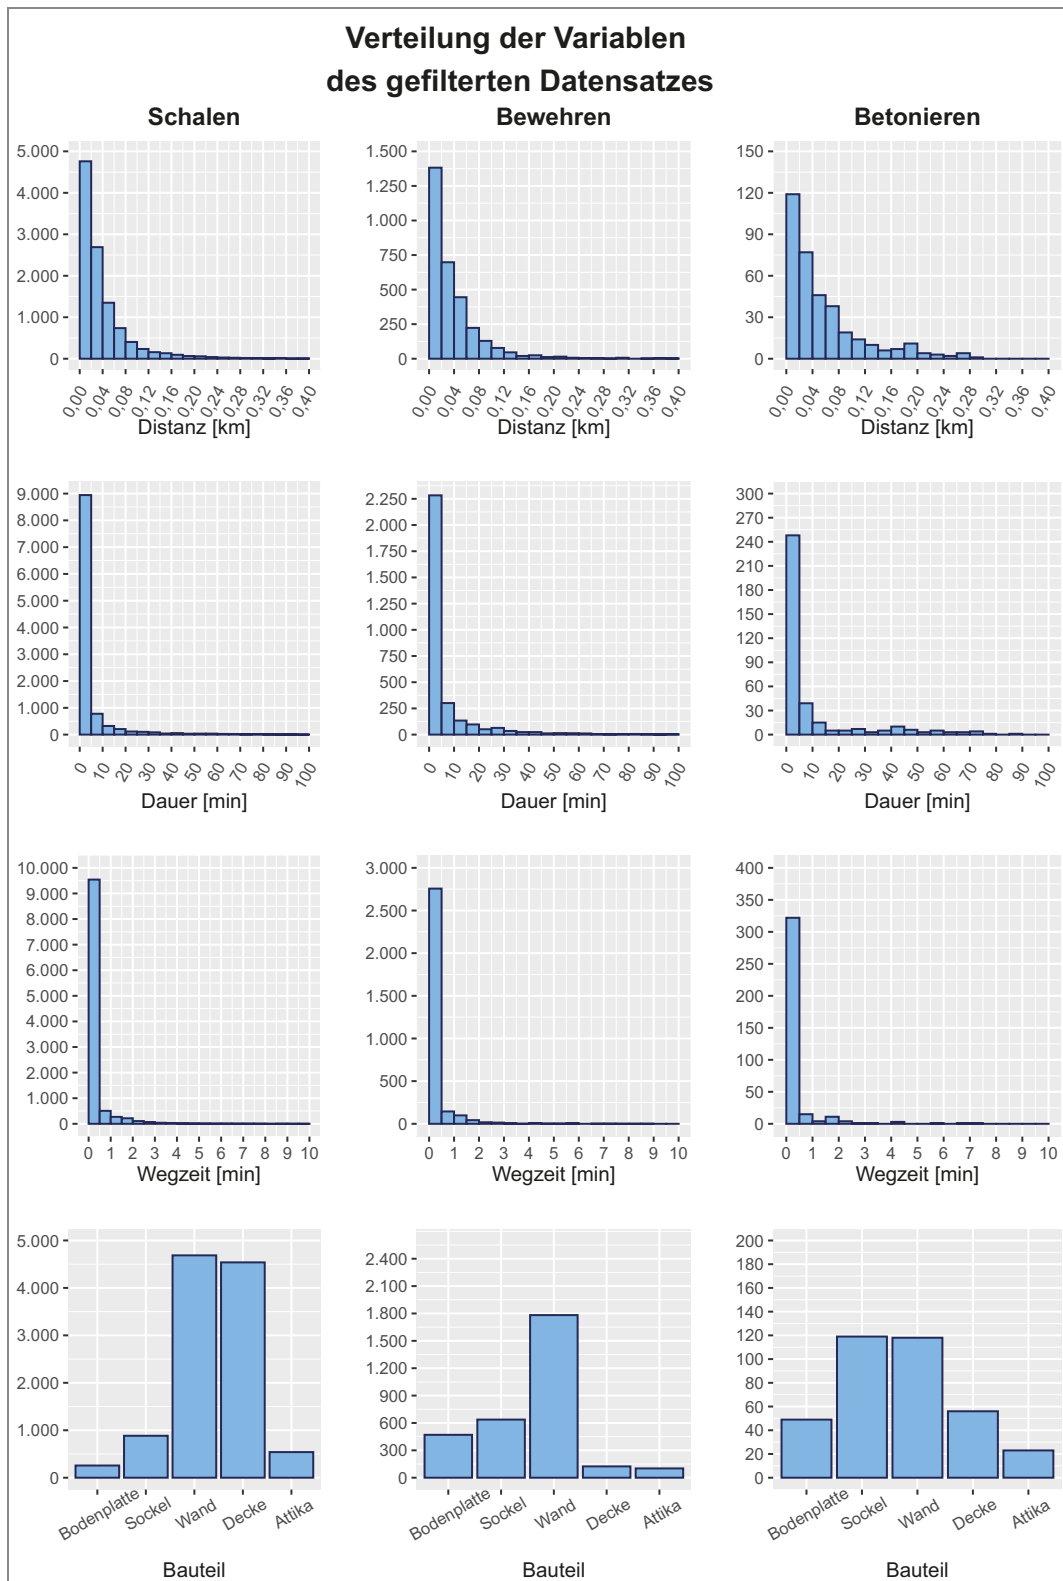
Beim Vergleich der Verteilungen ist rasch ersichtlich, dass Schalen, wie bereits zuvor beschrieben, am meisten Fälle beinhaltet, sich jedoch nicht besonders von den anderen Tätigkeiten abhebt. Für die numerischen Werte Distanz, Dauer, Wegzeit sowie durchschnittliche und maximale Geschwindigkeit bedeutet dies, dass die Verteilungen einander ähnlich sind. Dies erschwert in weiterer Folge die Modellbildung, weil sich dadurch keine eindeutige Klassenzugehörigkeit ergibt. Bei der Häufigkeitsverteilung der Bauteile ist zu erkennen, dass die Wände die meisten Einträge besitzen. Rückblickend ist dies vollkommen nachvollziehbar, weil dieser Bauteil die meisten Arbeitstage in Anspruch genommen hat.

Die im Geofence zurückgelegte Distanz weist eine Bandbreite beim Schalen von 0 bis 0,74 km, beim Bewehren von 0 bis 0,70 km und beim Betonieren von 0 bis 0,54 km auf. Zusätzlich ist anzumerken, dass rund 58 % der Fälle sowohl beim Schalen als auch beim Bewehren unter 0,04 km liegen, beim Einbringen des Betons sind es hingegen nur 45 %. Die Mittelwerte der jeweiligen Tätigkeiten betragen 0,05 km, 0,04 km und 0,07 km, wobei die Standardabweichungen 0,06 km, 0,05 und 0,07 km betragen.

Die Verweildauer im Geofence erstreckt sich beim Aufstellen der Schalungselemente von 0,18 bis 188,32 min, beim Verlegen der Bewehrungseisen von 0,18 bis 199 min und beim Betonieren von 0,18 bis 172,18 min. Auffallend ist hierbei, dass bei der ersten Tätigkeit 82 %, bei der zweiten 73 % und bei der dritten 68 % der Fälle unter 5 min liegen. Die dazugehörigen Mittelwerte betragen jeweils 4,92 min, 7,14 min und 10,25 min. Die soeben aufgezeigte extreme Schiefe der Verteilung wird auch durch die Abweichung der Mediane, welche 1,00 min, 1,44 min und 1,7 min betragen, vom Mittelwert verdeutlicht. Die jeweiligen Standardabweichungen betragen 12,96 min, 16,38 min und 20,04 min.

Die Verteilung der Wegzeit, welche die Zeitspanne zwischen dem Verlassen des letzten Geofence und dem Eintreten in einen neuen beschreibt, ist mit jener der Dauern vergleichbar. Die dazugehörigen Bandbreiten liegen beim Schalen zwischen 0 und 117,42 min, beim Bewehren zwischen 0 und 37,88 min sowie beim Betonieren zwischen 0 und 13,9 min. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 0,31 min, 0,25 min und 0,32 min. Auch bei diesen Verteilungen wird die extreme Schiefe der Daten durch die großen Unterschiede zwischen den Medianen, welche jeweils 0,03 min betragen, und den Mittelwerten bekräftigt. Die Standardabweichungen weisen eine Größe von 1,15 min, 0,98 min und 1,08 min auf.

Die durchschnittliche Geschwindigkeit, welche durch die Filterung auf 10 km/h limitiert wurde, weist als Maximum beim Schalen und Bewehren 10 km/h sowie beim Betonieren 9 km/h auf, während das Minimum aller Tätigkeiten 0 km/h beträgt. Die Mediane, welche jeweils 5 km/h ausmachen, weichen kaum von den einzelnen Mittelwerten (5,23 km/h, 4,96 km/h und 4,67 km/h) ab. Die dazugehörigen Standardabweichungen belaufen sich auf 2,03 km/h, 1,93 km/h und 1,67 km/h.



**Abb. 6-2** Verteilung der Basisdatensatzvariablen in Abhängigkeit von Schalens, Bewehren und Betonieren

Die maximale Geschwindigkeit weist ein einheitliches Minimum von 0 km/h und einen Maximalwert beim Aufstellen der Schalung von 35 km/h, beim

Verlegen der Bewehrung von 30 km/h und beim Einbringen des Betons von 24 km/h auf. Der Mittelwert und der Median betragen beim Schalen 7,9 km/h und 8,00 km/h, beim Bewehren 7,43 km/h und 7,00 km/h sowie beim Betonieren 7,54 km/h und 7,0 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 3,88 km/h, 3,76 km/h und 3,54 km/h.




Abb. 6-3 Verteilung der Basisdatensatzvariablen in Abhängigkeit von Schalieren, Bewehren und Betonieren

Um einen Überblick über das vollständige Spektrum des Basisdatensatzes zu geben, wird Tabelle 6-2 angeführt. Im Vergleich zwischen der deskriptiven Statistik des Basisdatensatzes und jener der einzelnen Tätigkeiten stellt sich heraus, dass diese nicht auffällig voneinander abweichen. Hierbei sei aber angemerkt, dass die stark überlappenden Verteilungsfunktionen für eine präzise Modellbildung nicht förderlich sind.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Wegzeit	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[min]	[km/h]	[km/h]
0	A	B	C	D	E	F
1	Minimum	0,00	0,18	0,00	0,00	0,00
2	Maximum	0,74	199,00	117,42	10,00	35,00
3	Mittelwert	0,05	5,54	0,30	5,16	7,79
4	Median	0,03	1,08	0,03	5,00	7,00
5	Standardabweichung	0,06	14,04	1,40	2,00	3,85

Tab. 6-2 Deskriptive Statistik des Basisdatensatzes

Aus Tabelle 6-2 ist auch zu entnehmen, dass der Mittelwert bei der Wegzeit und der Dauer stärker vom jeweiligen Median abweicht, was auf die deutlich überlegene Menge an kurzzeitigen Einträgen zurückzuführen ist. Vor allem Fälle mit einer kurzen Verweildauer im Geofence sind jedoch nicht aussagekräftig, weil innerhalb von wenigen Sekunden keine tätigkeitstypischen Verhalten und Abläufe aufgezeichnet und identifiziert werden können.

Neben den numerischen Parametern gilt es, auch die Kategorievariablen zu beleuchten. Die daraus resultierenden Ergebnisse werden in Tabelle 6-3 zusammengefasst. Der Parameter Out besitzt die Ausprägung Ja oder Nein und beurteilt, ob die auf den Geofence folgende Wegzeit größer als 30 Sekunden ist. Insgesamt gibt es nur 1.761 Fälle (12,25 %), auf die ein Weg länger als eine halbe Minuten zutrifft. Von den 12.614 Wegzeiten weisen 4.897 den Wert Null auf, da die Arbeitskräfte nach dem Verlassen des Geofence gleich in den nächsten gewechselt sind.

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Out</b>		
2	Ja	1.761	12,25 [%]
3	Nein	12.614	87,75 [%]
4	<b>Wegzeit</b>		
5	kein Weg (Wert = 0)	4.897	34,07 [%]
6	<b>Geofence</b>		
7	Abschnitt	9.091	63,24 [%]
8	Lager	5.284	36,76 [%]
9	<b>Bauteil</b>		
10	Bodenplatte	775	5,39 [%]
11	Sockel	1.640	11,41 [%]
12	Wand	6.584	45,80 [%]
13	Decke	4.714	32,79 [%]
14	Attika	662	4,61 [%]

Tab. 6-3 Auswertung der Kategorievariablen des Basisdatensatzes

Die soeben beschriebene Analyse des Basisdatensatzes hat ergeben, dass für die Modellbildung weitere Einschränkungen vorzunehmen sind. Vor allem der Bereich der sehr kurzen Verweildauern beinhaltet wenig tätigkeitstypischen Informationsgehalt und muss daher aus der Modellbildung ausgeschlossen werden. Aus diesem Grund wird bei der nachfolgenden Modellvariante das Minimum der Dauer auf 5 min gesetzt. Zusätzlich beschränkt die maximale Verweildauer von 80 min die Bandbreite nach oben hin, um den sehr schwach besetzten Bereich ebenfalls nicht in die Berechnung miteinfließen zu lassen.

### 6.3 Modellbildung durch Begrenzung der Dauer

Bei der ersten Variante der Modellbildung wird zunächst der Basisdatensatz unter Berücksichtigung der Filterkriterien (5-80 min) verkleinert. Anschließend gilt es, mit Hilfe einer zufälligen Auswahl die Diskrepanz in Bezug auf die unterschiedliche Fallanzahl der einzelnen Tätigkeiten zu minimieren (Schalen: 1.894 Fälle, Bewehren: 798 Fälle und Betonieren:

114 Fälle). Weil die zufallsbedingte Fallauswahl den Fehlerwert der Prognosen beeinflusst, werden insgesamt fünf solcher Datensätze zusammengestellt, wobei die Betoniereinträge aufgrund der geringen Anzahl immer dieselben sind. Anhand dieser fünf Datensätze werden in weiterer Folge jeweils 29 neuronale Netze, welche in einer Hidden-Layer zwischen 2 und 30 Neuronen besitzen, mittels NeuralTools 8.1 trainiert und validiert. Anhand der Validierungsfälle, welche im Verhältnis 2:8 zu den Trainingsfällen stehen, wird für jeden der fünf zufällig zusammengestellten Datensätze das beste Netz bestimmt. Abschließend beurteilen die Testdaten, welche den gesamten 5-80min-Datensatz beinhalten, die Übereinstimmung zwischen Wirklichkeit und Modell.

### 6.3.1 Zufällig ausgewählter Datensatz 1

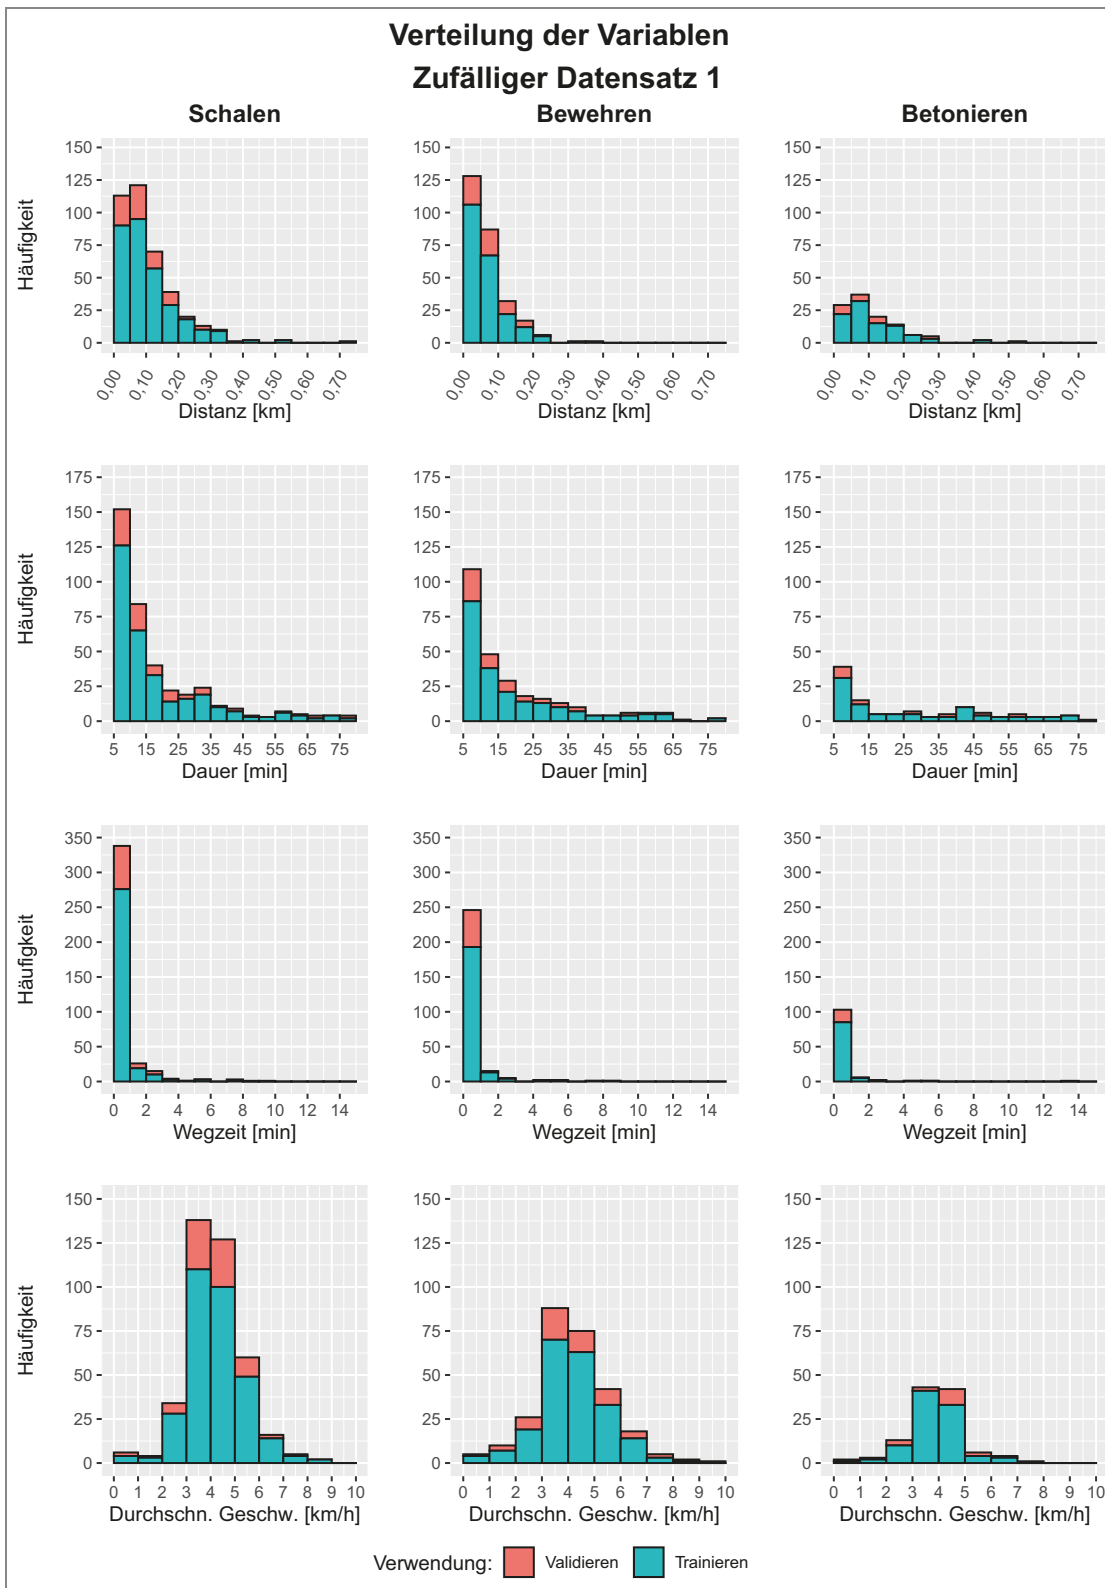
Die Verteilung der Trainings- und Validierungsfälle des ersten zufällig zusammengestellten Datensatzes wird in Tabelle 6-4 übersichtlich dargestellt. Insgesamt besteht er aus 778 Fällen, wobei 50 % die Tätigkeit Schalen, 35 % Bewehren und 15 % Betonieren beinhalten. Diese Aufteilung wurde bewusst gewählt, um einerseits die stark ausgeprägte Ungleichheit der Fallanzahlen innerhalb der Klassen abzuschwächen und andererseits diese nicht gänzlich zu eliminieren.

Lfd. Nr.	Tätigkeiten	Trainingsfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	314	78	392
2	Bewehren	214	58	272
3	Betonieren	94	20	114
4	Summe	622	156	778

Tab. 6-4 Zufälliger Datensatz 1: Trainings- und Validierungsfälle

Neben der Aufteilung der zu prognostizierenden Kategorien muss auch auf die Verteilung der Trainings- und Validierungsfälle innerhalb dieser geachtet werden. Herrschen Bereiche vor, in denen keine Daten für Validierungszwecke – oder noch schlimmer – keine Anhaltspunkte für das Training vorliegen, kann die Prognosegenauigkeit des Netzes lokal große Abweichungen aufweisen. Aus Abbildung 6-4 wird ersichtlich, dass dies beim vorliegenden Datensatz nicht der Fall ist. Sowohl die türkis eingefärbten Trainingsfälle als auch die roten Validierungsdaten weisen in den einzelnen Histogrammen eine zum gefilterten Basisdatensatz passende Verteilung und keine großräumigen Fehlstellen auf.

Die im Geofence zurückgelegte Distanz hat eine Bandbreite beim Schalen von 0 bis 0,74 km, beim Bewehren von 0 bis 0,37 km und beim Betonieren von 0 bis 0,54 km, wobei rund 24 % der Fälle beim Schalen, 36 % beim Bewehren und 17 % beim Betonieren unter 0,05 km liegen. Die Mittelwerte der jeweiligen Tätigkeiten betragen 0,11 km, 0,07 km und 0,12 km. Die Standardabweichungen weisen in gewohnter Reihenfolge der Tätigkeiten 0,09 km, 0,05 km und 0,09 km auf.



**Abb. 6-4** Zufälliger Datensatz 1: Verteilung der einzelnen Parameter

Die Verweildauer im Geofence erstreckt sich beim Aufstellen der Schalungselemente über einen Bereich von 5,02 bis 78,08 min, beim Verlegen der Bewehrungsseisen von 5,00 bis 78,98 min und beim Betonieren von 5,03 bis 78,95 min.



Weiters liegen bei der ersten Tätigkeit 39 %, bei der zweiten 40 % und bei der letzten 34 % der Fälle unter 10 min. Die dazugehörigen Mittelwerte betragen jeweils 18,67 min, 18,64 min und 26,7 min. Die abgebildete Schiefe der Verteilung wird auch durch die Abweichung der Mediane, welche 12,46 min, 12,75 min und 19,34 min betragen, vom Mittelwert verdeutlicht. Die jeweiligen Standardabweichungen betragen 16,05 min, 15,66 min und 21,15 min.

Die Wegzeit beschreibt die Zeitspanne zwischen dem Verlassen des letzten Geofence und dem Eintreten in einen neuen. Die dazugehörigen Bandbreiten liegen beim Schalen zwischen 0 und 9,37 min, beim Bewehren zwischen 0 und 8,10 min sowie beim Betonieren zwischen 0 und 13,9 min. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 0,50 min, 0,37 min und 0,42 min. Auch bei diesen Verteilungen wird die deutlich auffallende Schiefe der Daten durch die großen Unterschiede zwischen den Medianen, welche jeweils 0,03 min betragen, und den Mittelwerten bekräftigt. Die Standardabweichungen weisen eine Größe von 1,20 min, 0,98 min und 1,49 min auf.

Die durchschnittliche Geschwindigkeit weist als Maximum beim Schalen 9 km/h, beim Bewehren 10 km/h sowie beim Betonieren 8 km/h auf und das Minimum aller Tätigkeiten beträgt 0 km/h. Die Mediane, welche 5 km/h, 5 km/h und 4 km/h betragen, weichen nur geringfügig von den einzelnen Mittelwerten (4,67 km/h, 4,68 km/h und 4,38 km/h) ab. Die dazugehörigen Standardabweichungen umfassen 1,24 km/h, 1,46 km/h und 1,18 km/h.

Die maximale Geschwindigkeit weist ein einheitliches Minimum von 0 km/h und einen Maximalwert beim Aufstellen der Schalung von 28 km/h, beim Verlegen der Bewehrung von 30 km/h und beim Einbringen des Betons von 24 km/h auf. Der Mittelwert und der Median betragen beim Schalen 8,36 km/h und 8,00 km/h, beim Bewehren 7,99 km/h und 7,00 km/h und beim Betonieren 8,13 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 3,39 km/h, 3,87 km/h und 3,44 km/h.

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Out</b>		
2	Ja	142	18,25 [%]
3	Nein	636	81,75 [%]
4	<b>Wegzeit</b>		
5	kein Weg (Wert = 0)	214	27,51 [%]
6	<b>Geofence</b>		
7	Abschnitt	700	89,97 [%]
8	Lager	78	10,03 [%]
9	<b>Bauteil</b>		
10	Bodenplatte	74	9,51 [%]
11	Sockel	168	21,59 [%]
12	Wand	376	48,33 [%]
13	Decke	113	14,52 [%]
14	Attika	47	6,04 [%]

Tab. 6-5 Zufälliger Datensatz 1: Analyse der Kategorievariablen

Tabelle 6-5 verdeutlicht die Analyse der Kategorievariablen des gesamten Datensatzes. Hieraus geht hervor, dass 90 % der Fälle den Abschnitt

beinhalten und nur 10 % das Lager. Rund 28 % der Fälle weisen zwischen den Bereichen zudem keine Wegzeiten auf. Die deskriptive Statistik des ersten zufällig ausgewählten Datensatzes wird in Tabelle 6-6 dargestellt.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Wegzeit	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[min]	[km/h]	[km/h]
0	A	B	C	D	E	F
1	Minimum	0,00	5,00	0,00	0,00	0,00
2	Maximum	0,74	78,98	13,90	10,00	30,00
3	Mittelwert	0,10	19,83	0,44	4,63	8,20
4	Median	0,08	12,65	0,03	5,00	8,00
5	Standardabweichung	0,08	17,01	1,18	1,31	3,57

Tab. 6-6 Zufälliger Datensatz 1: Deskriptive Statistik

Nach der Beurteilung des Datensatzes folgt die Modellbildung. Hierfür werden 29 neuronale Netze, welche einen Input-, einen Hidden- und einen Output-Layer aufweisen, trainiert. Die dazugehörige Anzahl der Hidden-Neuronen durchläuft hierbei den Bereich von 2 bis 30. Im Zuge der Validierung wird abschließend das Netz mit dem geringsten prozentualen Fehleranteil ausgewählt, wobei das beste Netz des ersten Datensatzes 24 Hidden-Neuronen und einen Fehleranteil von 42,95 % besitzt. Die nachfolgende Tabelle 6-7 fasst die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle zusammen.

Bestes Netz: 24 Hidden-Neuronen	
Training	
Anzahl Fälle	622
Falsche Prognosen	22,19 [%]
Validieren	
Anzahl Fälle	156
Falsche Prognosen	42,95 [%]

Tab. 6-7 Zufälliger Datensatz 1: Bestes Netz

Weiters ist es wichtig, darauf zu achten, wie die falschen Klassifizierungen auf die einzelnen Tätigkeiten verteilt sind, um beurteilen zu können, ob die künstliche Intelligenz einen allgemeingültigen Zusammenhang gefunden hat oder auch nicht. Tabelle 6-8 und 6-9 beinhalten hierfür die Aufteilung der falschen Vorhersagen unter Berücksichtigung von Schalen, Bewehren und Betonieren. Im Training schneiden das Aufstellen der Schalung und das Verlegen der Bewehrung deutlich besser ab als das Einbringen von Beton.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	279	31	4	11,15 [%]
2	Bewehren	36	172	6	19,63 [%]
3	Betonieren	36	25	33	64,89 [%]

Tab. 6-8 Zufälliger Datensatz 1: Klassifikationsmatrix Trainieren

Beim Validieren verschlechtert sich jedoch besonders die Tätigkeit Bewehren. Dies bedeutet in weiterer Folge, dass das neuronale Netz die Bewehrungs-Trainingsbeispiele zwar gelernt hat, aber die gefundenen Zusammenhänge nicht für alle Validierungsdaten zutreffen.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	57	19	2	26,92 [%]
2	Bewehren	26	27	5	53,45 [%]
3	Betonieren	9	6	5	75,00 [%]

Tab. 6-9 Zufälliger Datensatz 1: Klassifikationsmatrix Validieren

Um die Ergebnisinterpretation des besten neuronalen Netzes aus dem ersten zufälligen Datensatz abzuschließen, wird nachfolgend in Abbildung 6-5 die Auswirkungsanalyse der einzelnen Parameter gezeigt. Hierbei ist auffallend, dass alle Variablen bis auf Geofence und Out zwischen 13,5 % und 15,6 % liegen. Somit konnte die künstliche Intelligenz keine Leitvariablen, sprich Haupteinflussfaktoren, identifizieren.




Abb. 6-5 Zufälliger Datensatz 1: Auswirkungsanalyse

Um eine bessere Vergleichbarkeit der fünf zufällig gewählten 5-80min-Datensätze zu gewährleisten, weist die Beschreibung der nachfolgenden vier Datensätze ebenfalls den gleichen Aufbau wie der des soeben beschriebenen auf. An dieser Stelle wird jedoch angemerkt, dass Datensatz 1 das beste aller fünf Ergebnisse erzielt hat.

### 6.3.2 Zufällig ausgewählter Datensatz 2

Die Verteilung der Trainings- und Validierungsfälle des zweiten zufällig zusammengestellten Datensatzes wird in Tabelle 6-10 veranschaulicht. Insgesamt besteht dieser aus 769 Fällen, wobei 48 % die Tätigkeit Schalen, 37 % Bewehren und 15 % Betonieren beinhalten. Diese Aufteilung ist mit der des vorherigen Datensatzes vergleichbar.

Lfd. Nr.	Tätigkeiten	Trainingsfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	295	74	369
2	Bewehren	225	61	286
3	Betonieren	95	19	114
4	Summe	615	154	769

Tab. 6-10 Zufälliger Datensatz 2: Trainings- und Validierungsfälle

Nachfolgend wird auf die Verteilung der Trainings- und Validierungsfälle eingegangen, um potenzielle Bereiche zu identifizieren, in denen keine ausreichende Menge an Daten vorhanden ist, wodurch die Prognosegenauigkeit des Netzes negativ beeinflusst wird. Aus Abbildung 6-6 wird ersichtlich, dass dies beim vorliegenden Datensatz nicht der Fall ist. Sowohl die türkis eingefärbten Trainingsfälle als auch die roten Validierungsdaten weisen in den einzelnen Histogrammen eine zum gefilterten Basisdatensatz passende Verteilung und keine großräumigen Fehlstellen auf.

Die hierbei im Geofence zurückgelegte Distanz umfasst eine Bandbreite beim Schalen von 0 bis 0,41 km, beim Bewehren von 0 bis 0,44 km und beim Betonieren von 0 bis 0,54 km. Weiters liegen rund 27 % der Fälle beim Schalen und 36 % beim Bewehren unter 0,05 km, beim Einbringen des Betons sind es hingegen nur 17 %. Die Mittelwerte der jeweiligen Tätigkeiten betragen 0,10 km, 0,07 km und 0,12 km, wobei die Standardabweichungen 0,08 km, 0,06 und 0,09 km betragen.

Die Verweildauer im Geofence erstreckt sich beim Aufstellen der Schalungselemente über einen Bereich von 5,00 bis 77,27 min, beim Verlegen der Bewehrungseisen von 5,00 bis 75,72 min und beim Betonieren von 5,03 bis 78,95 min. Auffallend ist hierbei, dass bei der ersten Tätigkeit 42 %, bei der zweiten 38 % und bei der letzten 34 % der Fälle unter 10 min liegen. Die dazugehörigen Mittelwerte betragen jeweils 18,52 min, 19,08 min und 26,70 min. Die erkennbare Schiefe der Verteilung wird auch durch die Abweichung der Mediane, welche 11,60 min, 12,88 min und 19,34 min betragen, vom Mittelwert verdeutlicht. Die jeweiligen Standardabweichungen beziffern sich auf 16,08 min, 15,78 min und 21,15 min.

Die Bandbreiten der Wegzeiten liegen beim Schalen zwischen 0 und 8,70 min, beim Bewehren zwischen 0 und 9,00 min sowie beim Betonieren zwischen 0 und 13,90 min. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 0,43 min, 0,30 min und 0,42 min. Auch bei diesen Verteilungen wird die extreme Schiefe der Daten durch die großen Unterschiede zwischen den Medianen, welche beim Schalen 0,05 min und beim Bewehren sowie Betonieren jeweils 0,03 min betragen, und den Mittelwerten bekräftigt. Die Standardabweichungen weisen eine Größe von 1,01 min, 0,89 min und 1,49 min auf.

Die durchschnittliche Geschwindigkeit beinhaltet als Maximum beim Schalen 10 km/h, beim Bewehren 9 km/h und beim Betonieren 8 km/h, während das Minimum aller Tätigkeiten 0 km/h beträgt. Die Mediane, welche 5 km/h, 5 km/h und 4 km/h betragen, weichen kaum von den einzelnen Mittelwerten (4,59 km/h, 4,65 km/h und 4,38 km/h) ab. Die dazugehörigen Standardabweichungen umfassen 1,17 km/h, 1,32 km/h und 1,18 km/h.

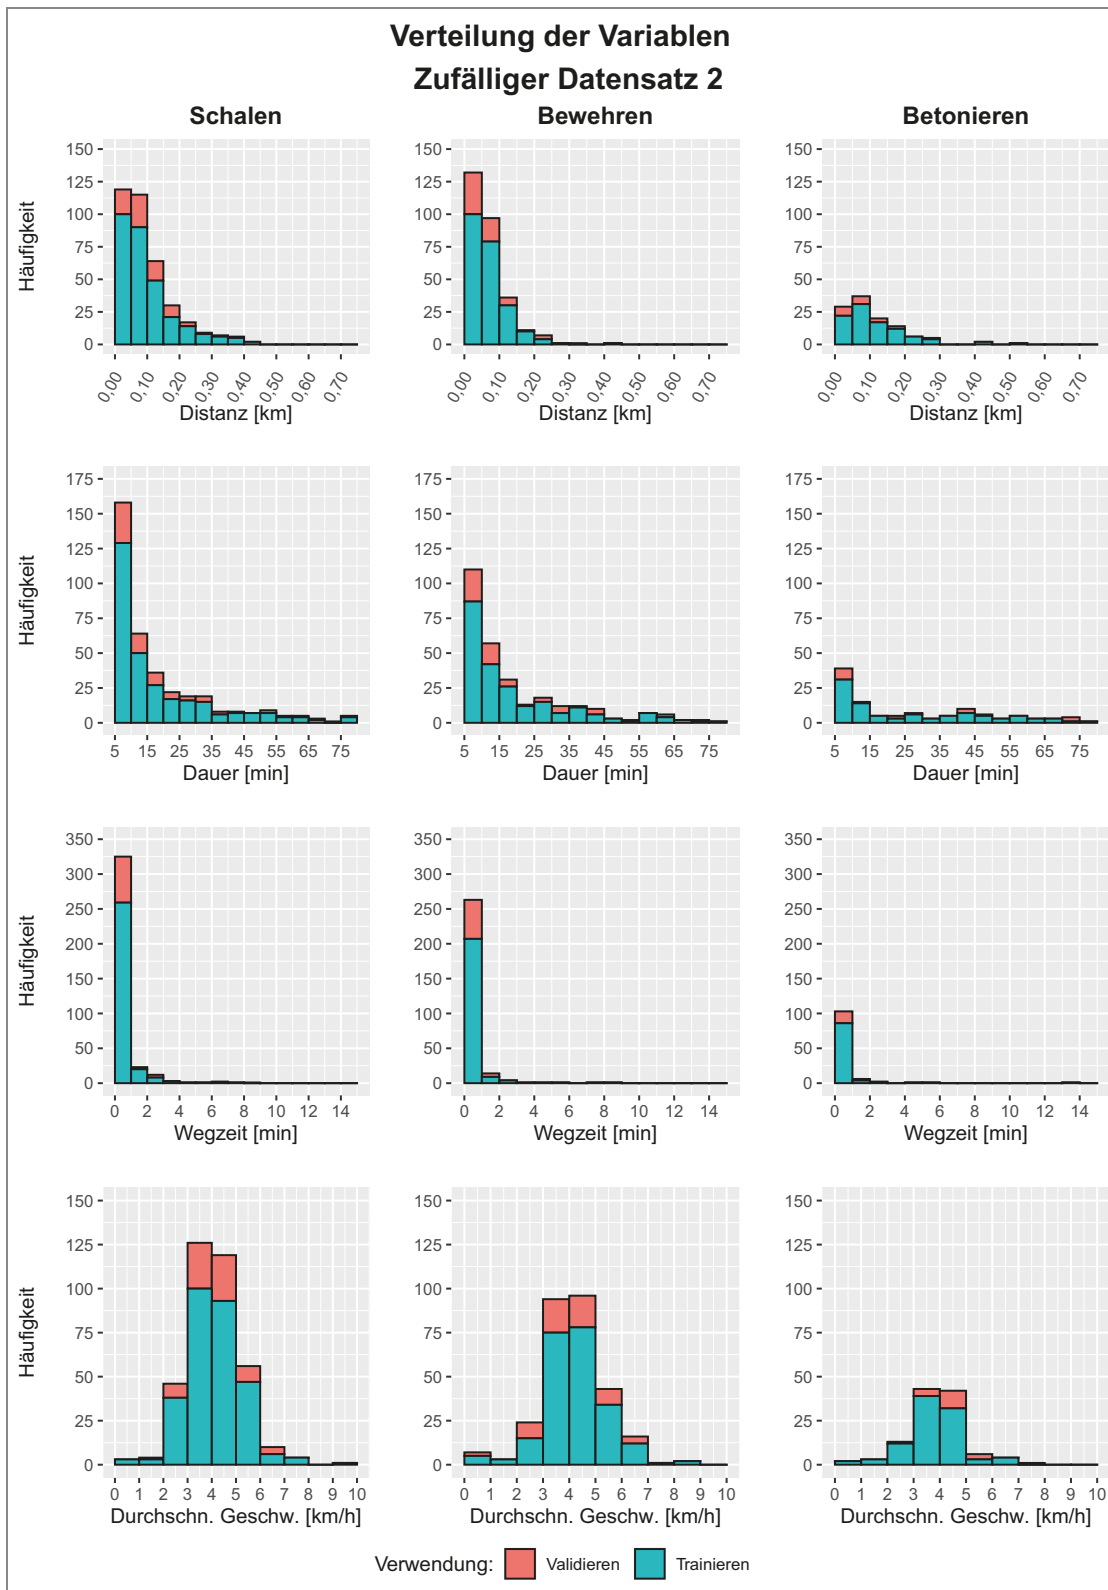


Abb. 6-6 Zufälliger Datensatz 2: Verteilung der einzelnen Parameter

Die maximale Geschwindigkeit weist ein einheitliches Minimum von 0 km/h und einen Maximalwert beim Aufstellen der Schalung von 35 km/h, beim Verlegen der Bewehrung von 30 km/h und beim Einbringen des Betons von

24 km/h auf. Der Mittelwert und der Median betragen beim Schalen 8,44 km/h und 8,00 km/h, beim Bewehren 7,83 km/h und 7,00 km/h und beim Betonieren 8,13 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 3,72 km/h, 3,64 km/h und 3,44 km/h.

Die deskriptive Statistik des zweiten zufällig ausgewählten Datensatzes wird in Tabelle 6-11 dargestellt. Weiters verdeutlicht Tabelle 6-12 die dazugehörige Analyse der Kategorievariablen. Hierbei ist ersichtlich, dass 88 % der Fälle den Abschnitt beinhalten und nur 12 % das Lager. Rund 28 % der Fälle weisen zwischen den Bereichen keine Wegzeiten auf.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Wegzeit	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[min]	[km/h]	[km/h]
0	A	B	C	D	E	F
1	Minimum	0,00	5,00	0,00	0,00	0,00
2	Maximum	0,54	78,95	13,90	10,00	35,00
3	Mittelwert	0,09	19,94	0,38	4,58	8,17
4	Median	0,07	12,50	0,03	5,00	8,00
5	Standardabweichung	0,08	17,06	1,06	1,23	3,66

Tab. 6-11 Zufälliger Datensatz 2: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Out</b>		
2	Ja	125	16,25 [%]
3	Nein	644	83,75 [%]
4	<b>Wegzeit</b>		
5	kein Weg (Wert = 0)	216	28,09 [%]
6	<b>Geofence</b>		
7	Abschnitt	679	88,30 [%]
8	Lager	90	11,70 [%]
9	<b>Bauteil</b>		
10	Bodenplatte	78	10,14 [%]
11	Sockel	163	21,20 [%]
12	Wand	379	49,28 [%]
13	Decke	101	13,13 [%]
14	Attika	48	6,24 [%]

Tab. 6-12 Zufälliger Datensatz 2: Analyse der Kategorievariablen

Nach der Beurteilung des Datensatzes folgt wieder die Modellbildung. Hierfür werden 29 neuronale Netze, welche jeweils einen Input-, einen Hidden- und einen Output-Layer aufweisen, trainiert. Die dazugehörige Anzahl der Hidden-Neuronen durchläuft hierbei einen Bereich von 2 bis 30. Im Zuge der Validierung wird abschließend das Netz mit dem geringsten prozentualen Fehleranteil ausgewählt. Das beste Netz des zweiten Datensatzes besitzt 4 Hidden-Neuronen und einen Fehleranteil von 40,91 %. Die nachfolgende Tabelle 6-13 fasst die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle zusammen.

<b>Bestes Netz: 4 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	615
Falsche Prognosen	36,42 [%]
<b>Validieren</b>	
Anzahl Fälle	154
Falsche Prognosen	40,91 [%]

Tab. 6-13 Zufälliger Datensatz 2: Bestes Netz

Weiters ist es wichtig, darauf zu achten, wie die falschen Klassifizierungen auf die einzelnen Tätigkeiten verteilt sind. Tabelle 6-14 und 6-15 beinhalten hierfür die Aufteilung der falschen Vorhersagen unter Berücksichtigung von Schalen, Bewehren und Betonieren. Sowohl beim Trainieren als auch beim Validieren ist sofort ersichtlich, dass die künstliche Intelligenz keinen allgemeingültigen Zusammenhang gefunden hat, da die Tätigkeit Betonieren nicht erlernt wurde. Das neuronale Netz teilt nur in Schalen oder Bewehren ein. Aus diesem Grund ist diese Variante der Modellbildung nicht einsetzbar.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	245	50	0	16,95 [%]
2	Bewehren	79	146	0	35,11 [%]
3	Betonieren	71	24	0	100,00 [%]

Tab. 6-14 Zufälliger Datensatz 2: Klassifikationsmatrix Trainieren

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	58	16	0	21,62 [%]
2	Bewehren	28	33	0	45,90 [%]
3	Betonieren	8	11	0	100,00 [%]

Tab. 6-15 Zufälliger Datensatz 2: Klassifikationsmatrix Validieren

Um die Ergebnisinterpretation des besten neuronalen Netzes aus dem zweiten zufälligen Datensatz abzuschließen, wird in Abbildung 6-7 die Auswirkungsanalyse der einzelnen Parameter gezeigt. Hierbei ist auffallend, dass die künstliche Intelligenz die Distanz und das Bauteil als Leitvariablen identifiziert hat. Die beiden Haupteinflussfaktoren weisen dabei rund 17 % auf. Wie auch bei Datensatz 1 sind bei der Auswirkungsanalyse die Variablen Out und Geofence an unterster Stelle.




Abb. 6-7 Zufälliger Datensatz 2: Auswirkungsanalyse

### 6.3.3 Zufällig ausgewählter Datensatz 3

Die Verteilung der Trainings- und Validierungsfälle des dritten zufällig zusammengestellten Datensatzes wird in Tabelle 6-16 veranschaulicht. Insgesamt besteht er aus 750 Fällen, wobei 51% die Tätigkeit Schalen, 34 % Bewehren und 15 % Betonieren beinhalten. Diese Aufteilung ist den vorherigen sehr ähnlich, wodurch die Vergleichbarkeit gewährleistet ist.

Lfd. Nr.	Tätigkeiten	Trainingsfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	306	76	382
2	Bewehren	203	51	254
3	Betonieren	91	23	114
4	Summe	600	150	750

Tab. 6-16 Zufälliger Datensatz 3: Trainings- und Validierungsfälle

Nachfolgend wird auf die Verteilung der Trainings- und Validierungsfälle eingegangen, um potenzielle Bereiche zu identifizieren, in denen keine ausreichende Menge an Daten vorhanden ist. Aus Abbildung 6-8 wird ersichtlich, dass der vorliegende Datensatz keine schwerwiegenden Lücken in den einzelnen Bandbreiten beinhaltet. Sowohl die türkis eingefärbten Trainingsfälle als auch die roten Validierungsdaten weisen in den einzelnen Histogrammen eine zum gefilterten Basisdatensatz passende Verteilung und keine großräumigen Fehlstellen auf.

Die im Geofence zurückgelegte Distanz hat eine Bandbreite beim Schalen von 0 bis 0,56 km, beim Bewehren von 0 bis 0,32 km und beim Betonieren von 0 bis 0,54 km, wobei rund 25 % der Fälle beim Schalen, 40 % beim Bewehren und 17 % beim Betonieren unter 0,05 km liegen. Die Mittelwerte der jeweiligen Tätigkeiten betragen 0,11 km, 0,07 km sowie 0,12 km und die Standardabweichungen weisen in gewohnter Reihenfolge der Tätigkeiten 0,09 km, 0,05 km und 0,09 km auf.



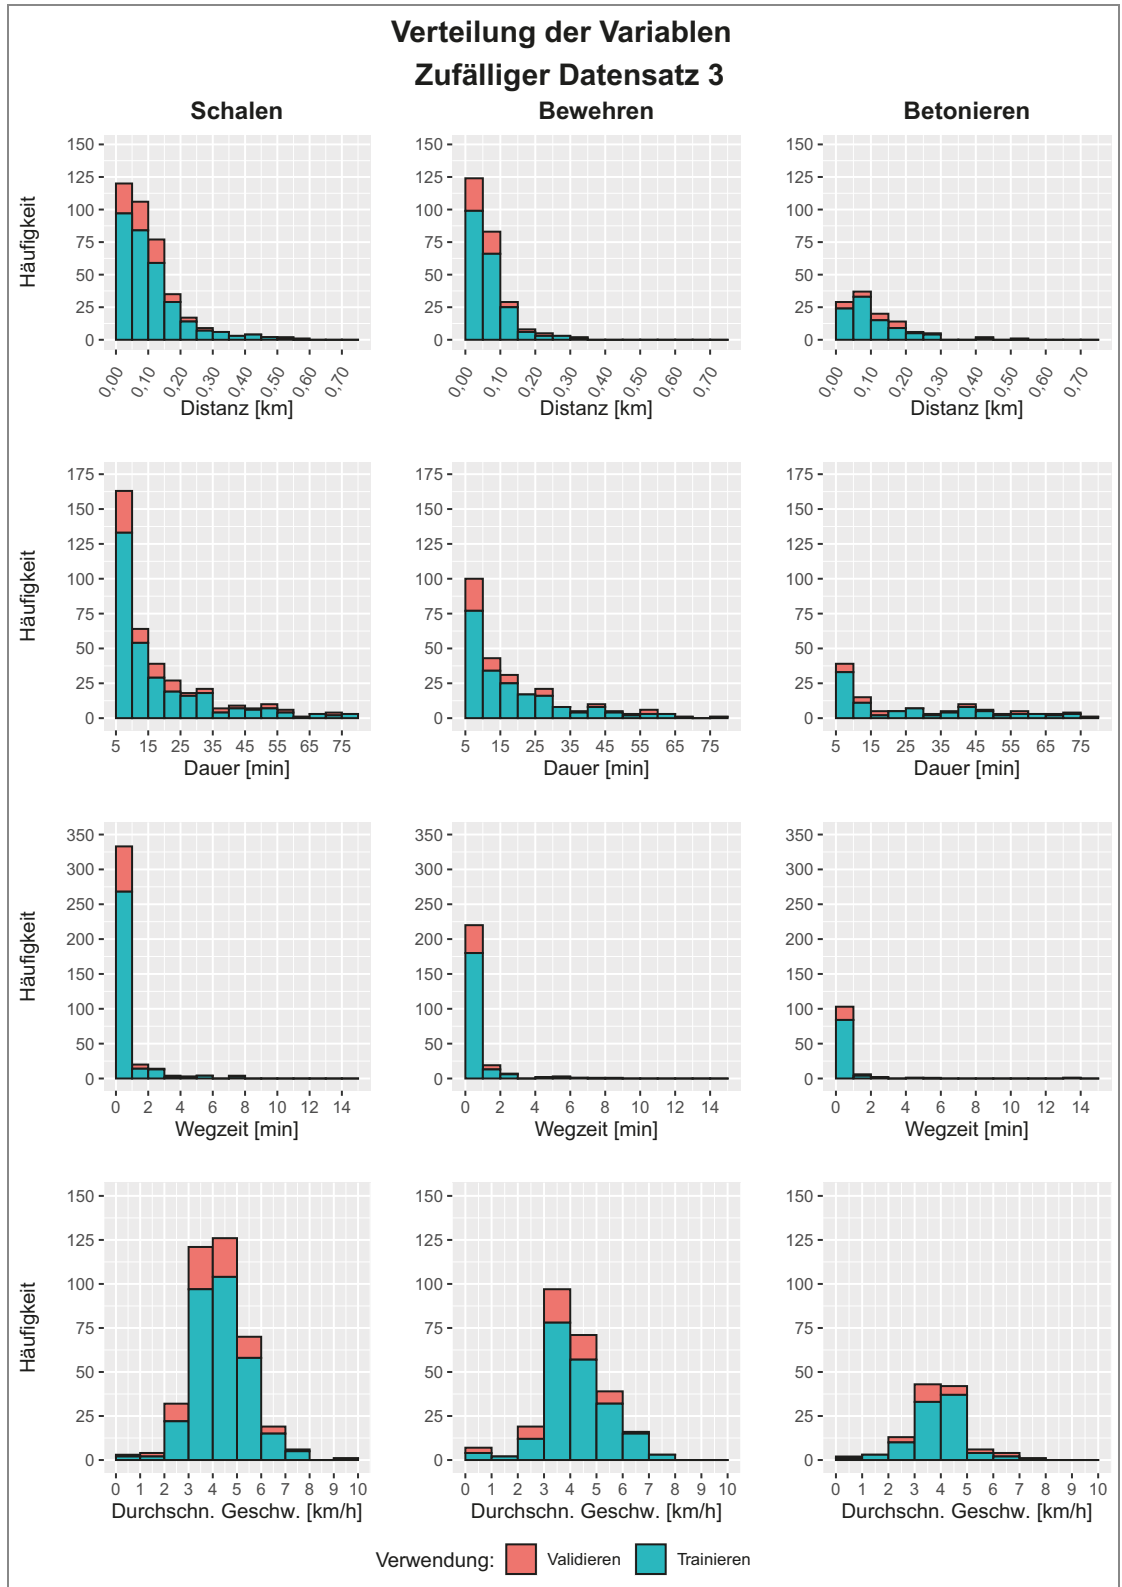


Abb. 6-8 Zufälliger Datensatz 3: Verteilung der einzelnen Parameter

Die Verweildauer im Geofence erstreckt sich beim Aufstellen der Schalungselemente über einen Bereich von 5,02 bis 77,82 min, beim Verlegen der Bewehrungsseisen von 5,00 bis 78,00 min und beim Betonieren von 5,03 bis 78,95 min. Hierbei ist anzumerken, dass bei der ersten Tätigkeit 43 %, bei der zweiten 39 % und bei der letzten 34 % der Fälle unter 10 min liegen, wobei die dazugehörigen Mittelwerte 18,47 min, 18,50 min und 26,70 min betragen. Die abgebildete Schiefe der Verteilung wird auch durch die Abweichung der Mediane, welche 11,84 min, 13,79 min und 19,34 min ausmachen, vom Mittelwert verdeutlicht. Die jeweiligen Standardabweichungen betragen 15,79 min, 14,53 min und 21,15 min.

Die Bandbreite der Wegzeit liegt beim Schalen zwischen 0 und 7,95 min, beim Bewehren zwischen 0 und 8,10 min sowie beim Betonieren zwischen 0 und 13,90 min. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 0,48 min, 0,48 min und 0,42 min. Auch bei diesen Verteilungen wird die deutlich auffallende Schiefelage der Daten durch die großen Unterschiede zwischen den Medianen, welche 0,03 min, 0,04 min und 0,03 min betragen, und den Mittelwerten bekräftigt. Die Standardabweichungen weisen eine Größe von 1,15 min, 1,16 min und 1,49 min auf.

Die durchschnittliche Geschwindigkeit umfasst als Maximum beim Schalen 10 km/h, beim Bewehren 8 km/h sowie beim Betonieren 8 km/h, wobei das Minimum aller Tätigkeiten 0 km/h beträgt. Die Mediane, welche 5 km/h, 5 km/h und 4 km/h betragen, weichen nur geringfügig von den einzelnen Mittelwerten (4,79 km/h, 4,63 km/h und 4,38 km/h) ab und die dazugehörigen Standardabweichungen machen 1,20 km/h, 1,33 km/h und 1,18 km/h aus.

Die maximale Geschwindigkeit weist ein einheitliches Minimum von 0 km/h und einen Maximalwert beim Aufstellen der Schalung von 35 km/h, beim Verlegen der Bewehrung von 25 km/h und beim Einbringen des Betons von 24 km/h auf. Der Mittelwert und der Median machen beim Schalen 8,80 km/h und 8,00 km/h, beim Bewehren 7,70 km/h und 7,00 km/h und beim Betonieren 8,13 km/h und 8,00 km/h aus. Die dazugehörigen Standardabweichungen belaufen sich auf 3,86 km/h, 3,25 km/h und 3,44 km/h.

Die deskriptive Statistik des gesamten Datensatzes wird in Tabelle 6-17 dargestellt. Weiters verdeutlicht Tabelle 6-18 die dazugehörige Analyse der Kategorievariablen, wobei 91 % der Fälle den Abschnitt beinhalten und nur 9 % das Lager. Rund 29 % der Fälle weisen zwischen den Bereichen keine Wegzeiten auf.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Wegzeit	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[min]	[km/h]	[km/h]
0	A	B	C	D	E	F
1	Minimum	0,00	5,00	0,00	0,00	0,00
2	Maximum	0,56	78,95	13,90	10,00	35,00
3	Mittelwert	0,10	19,73	0,47	4,67	8,33
4	Median	0,07	12,85	0,03	5,00	8,00
5	Standardabweichung	0,08	16,59	1,21	1,25	3,64

Tab. 6-17 Zufälliger Datensatz 3: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Out</b>		
2	Ja	139	18,53 [%]
3	Nein	611	81,47 [%]
4	<b>Wegzeit</b>		
5	kein Weg (Wert = 0)	219	29,20 [%]
6	<b>Geofence</b>		
7	Abschnitt	680	90,67 [%]
8	Lager	70	9,33 [%]
9	<b>Bauteil</b>		
10	Bodenplatte	75	10,00 [%]
11	Sockel	164	21,87 [%]
12	Wand	352	46,93 [%]
13	Decke	111	14,80 [%]
14	Attika	48	6,40 [%]

Tab. 6-18 Zufälliger Datensatz 3: Analyse der Kategorievariablen

Nach der Beurteilung des Datensatzes folgt wieder die Modellbildung. Hierfür werden 29 neuronale Netze, welche jeweils einen Input-, einen Hidden- und einen Output-Layer aufweisen, trainiert. Die dazugehörige Anzahl der Hidden-Neuronen umspannt hierbei den Bereich von 2 bis 30. Im Zuge der Validierung wird abschließend das Netz mit dem geringsten prozentualen Fehleranteil ausgewählt, wobei das beste Netz des dritten Datensatzes 3 Hidden-Neuronen und einen Fehleranteil von 40,00 % besitzt. Die nachfolgende Tabelle 6-19 fasst die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle zusammen.

<b>Bestes Netz: 3 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	600
Falsche Prognosen	37,00 [%]
<b>Validieren</b>	
Anzahl Fälle	150
Falsche Prognosen	40,00 [%]

Tab. 6-19 Zufälliger Datensatz 3: Bestes Netz

Weiters ist es wichtig, darauf zu achten, wie die falschen Klassifizierungen auf die einzelnen Tätigkeiten verteilt sind. Die Tabellen 6-20 und 6-21 beinhalten hierfür die Aufteilung der falschen Vorhersagen unter Berücksichtigung von Schalen, Bewehren und Betonieren. Sowohl beim Trainieren als auch beim Validieren ist sofort ersichtlich, dass die künstliche Intelligenz ebenfalls keinen allgemeingültigen Zusammenhang gefunden hat, da die Tätigkeit Betonieren nicht erlernt wurde. Somit teilt das neuronale Netz nur in Schalen oder Bewehren ein, wodurch diese Variante der Modellbildung nicht zielführend ist.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	251	55	0	17,97 [%]
2	Bewehren	76	127	0	37,44 [%]
3	Betonieren	50	41	0	100,00 [%]

Tab. 6-20 Zufälliger Datensatz 3: Klassifikationsmatrix Trainieren

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	61	15	0	19,74 [%]
2	Bewehren	22	29	0	43,14 [%]
3	Betonieren	14	9	0	100,00 [%]

Tab. 6-21 Zufälliger Datensatz 3: Klassifikationsmatrix Validieren

Um die Ergebnisinterpretation des besten neuronalen Netzes aus dem zweiten zufälligen Datensatz abzuschließen, wird nachfolgend in Abbildung 6-9 die Auswirkungsanalyse der einzelnen Parameter gezeigt. Hierbei ist auffallend, dass die künstliche Intelligenz die Distanz, die maximale Geschwindigkeit und das Bauteil als Leitvariablen identifiziert hat. Die drei Haupteinflussfaktoren weisen rund 18,5 % auf. Wie auch bei den vorherigen Datensätzen sind bei der Auswirkungsanalyse die Variablen Geofence und Out an unterster Stelle, wobei Out mit 2,5 % deutlich abgeschlagen ist.




Abb. 6-9 Zufälliger Datensatz 3: Auswirkungsanalyse

#### 6.3.4 Zufällig ausgewählter Datensatz 4

Die Verteilung der Trainings- und Validierungsfälle des vierten zufällig zusammengestellten Datensatzes wird in Tabelle 6-22 veranschaulicht. Insgesamt besteht dieser aus 732 Fällen, wobei 49% die Tätigkeit Schalen, 36% Bewehren und 15 % Betonieren beinhalten.

Lfd. Nr.	Tätigkeiten	Trainingsfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	284	72	356
2	Bewehren	213	49	262
3	Betonieren	89	25	114
4	Summe	586	146	732

Tab. 6-22 Zufälliger Datensatz 4: Trainings- und Validierungsfälle

Nachfolgend wird auf die Verteilung der Trainings- und Validierungsfälle eingegangen, um potenzielle Bereiche zu identifizieren, in denen keine ausreichende Menge an Daten vorhanden ist, wodurch die Prognosegenauigkeit des Netzes an dieser Stelle große Abweichungen aufweisen kann. Aus Abbildung 6-10 wird ersichtlich, dass dies beim vorliegenden Datensatz nicht der Fall ist. Sowohl die türkis eingefärbten Trainingsfälle als auch die roten Validierungsdaten weisen in den einzelnen Histogrammen eine zum gefilterten Basisdatensatz passende Verteilung und keine großräumigen Fehlstellen auf.

Die hierbei im Geofence zurückgelegte Distanz weist eine Bandbreite beim Schalen von 0 bis 0,45 km, beim Bewehren von 0 bis 0,38 km und beim Betonieren von 0 bis 0,54 km auf. Weiters liegen rund 24 % der Fälle beim Schalen und 37 % beim Bewehren unter 0,05 km, beim Einbringen des Betons sind es nur 17 %. Die Mittelwerte der jeweiligen Tätigkeiten betragen 0,10 km, 0,07 km und 0,12 km, wobei die Standardabweichungen 0,08 km, 0,05 und 0,09 km ausmachen.

Die Verweildauer im Geofence erstreckt sich beim Aufstellen der Schalungselemente über einen Bereich von 5,00 bis 76,93 min, beim Verlegen der Bewehrungseisen von 5,00 bis 78,00 min und beim Betonieren von 5,03 bis 78,95 min. Auffallend ist hierbei, dass bei der ersten Tätigkeit 38 %, bei der zweiten 42 % und bei der letzten 34 % der Fälle unter 10 min liegen. Die dazugehörigen Mittelwerte betragen jeweils 19,43 min, 18,42 min sowie 26,70 min und die erkennbare Schiefe der Verteilung wird durch die Abweichung der Mediane, welche sich auf 13,73 min, 12,93 min und 19,34 min beziffern, vom Mittelwert verdeutlicht. Die jeweiligen Standardabweichungen betragen 15,34 min, 14,92 min und 21,15 min.

Die Bandbreiten der Wegzeiten liegen beim Schalen zwischen 0 und 7,25 min, beim Bewehren zwischen 0 und 9,00 min sowie beim Betonieren zwischen 0 und 13,90 min. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 0,45 min, 0,39 min und 0,42 min. Auch bei diesen Verteilungen wird die extreme Schiefe der Daten durch die großen Unterschiede zwischen den Medianen, welche beim Schalen 0,04 min und beim Bewehren sowie Betonieren jeweils 0,03 min betragen, und den Mittelwerten bekräftigt. Die Standardabweichungen weisen eine Größe von 1,05 min, 1,07 min und 1,49 min auf.

Die durchschnittliche Geschwindigkeit beinhaltet als Maximum beim Schalen 9 km/h, beim Bewehren 10 km/h und beim Betonieren 8 km/h, während das Minimum aller Tätigkeiten 0 km/h beträgt. Die Mediane, welche 5 km/h, 4 km/h und 4 km/h betragen, weichen kaum von den einzelnen Mittelwerten (4,58 km/h, 4,58 km/h und 4,38 km/h) ab. Die dazugehörigen Standardabweichungen sind 1,15 km/h, 1,31 km/h und 1,18 km/h.

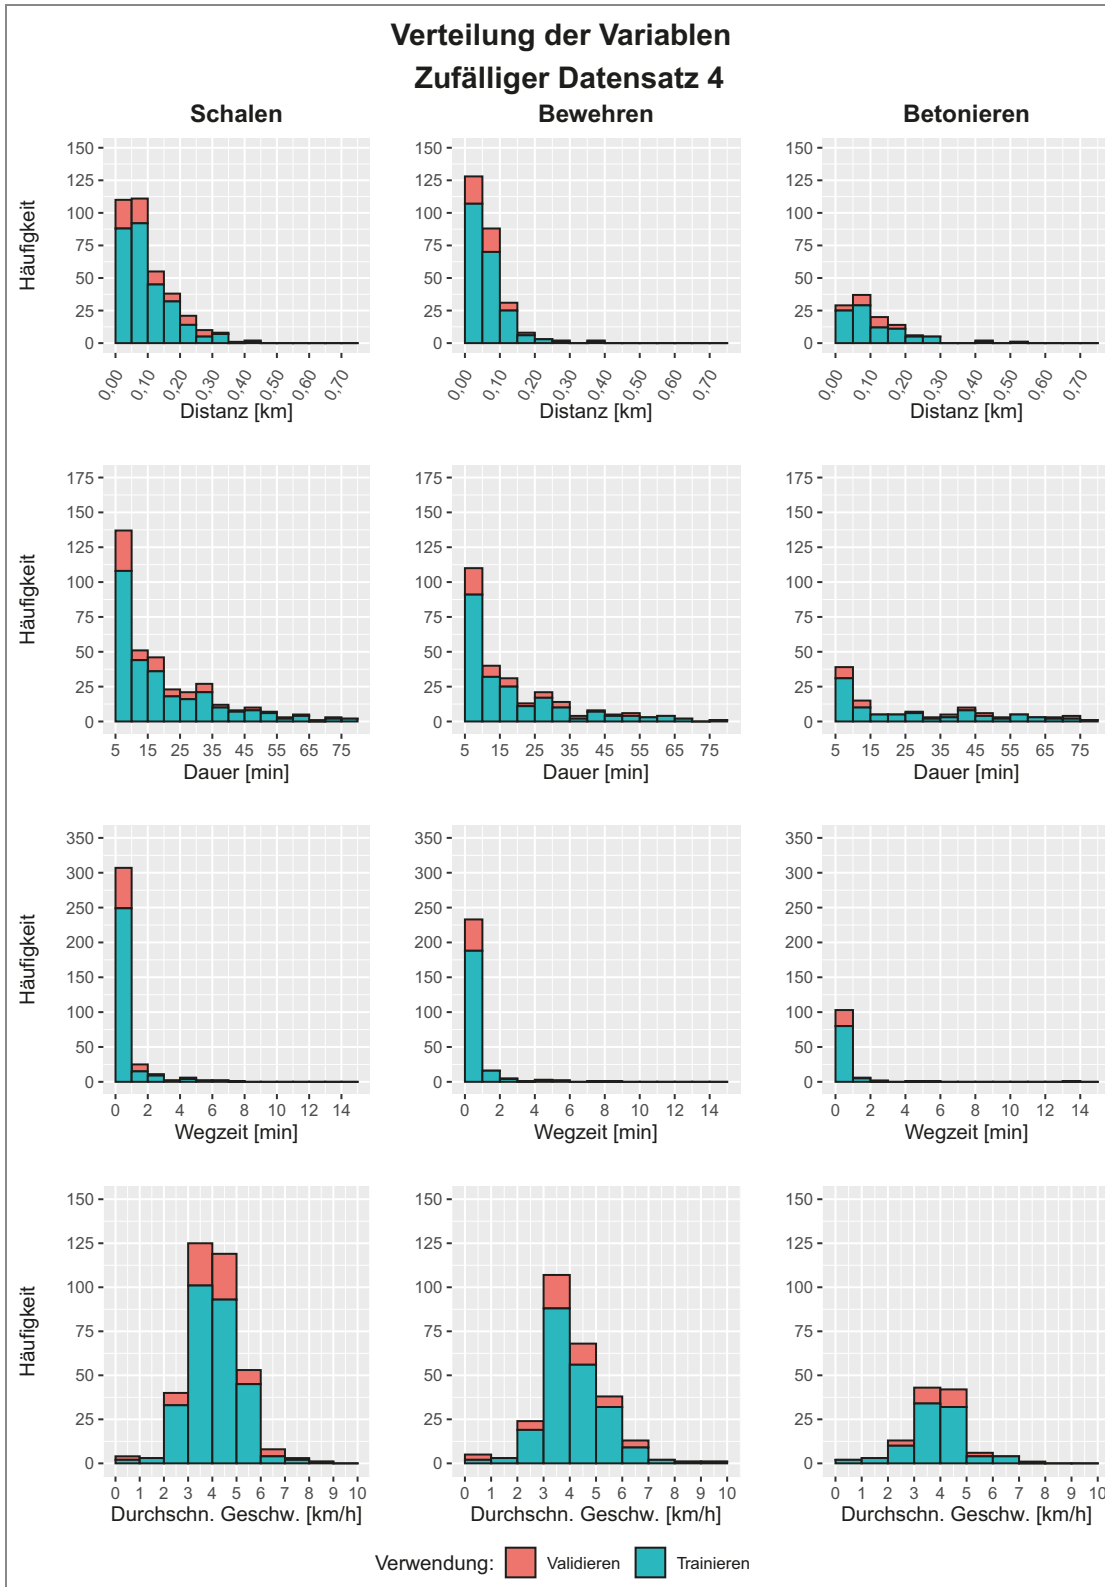


Abb. 6-10 Zufälliger Datensatz 4: Verteilung der einzelnen Parameter

Die maximale Geschwindigkeit weist ein einheitliches Minimum von 0 km/h und einen Maximalwert beim Aufstellen der Schalung von 28 km/h, beim Verlegen der Bewehrung von 30 km/h und beim Einbringen des Betons von

24 km/h auf. Der Mittelwert und der Median betragen beim Schalen 8,12 km/h und 8,00 km/h, beim Bewehren 7,54 km/h und 7,00 km/h sowie beim Betonieren 8,13 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 3,13 km/h, 3,49 km/h und 3,44 km/h.

Die deskriptive Statistik des vierten zufällig ausgewählten Datensatzes wird in Tabelle 6-23 dargestellt. Weiters verdeutlicht Tabelle 6-24 die dazugehörige Analyse der Kategorievariablen. Hierbei ist anzumerken, dass 90 % der Fälle den Abschnitt beinhalten und nur 10 % das Lager. Rund 29 % der Fälle weisen zwischen den Bereichen keine Wegzeiten auf.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Wegzeit	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[min]	[km/h]	[km/h]
0	A	B	C	D	E	F
1	Minimum	0,00	5,00	0,00	0,00	0,00
2	Maximum	0,54	78,95	13,90	10,00	30,00
3	Mittelwert	0,09	20,20	0,42	4,55	7,92
4	Median	0,07	13,68	0,03	4,00	7,50
5	Standardabweichung	0,08	16,49	1,14	1,21	3,32

Tab. 6-23 Zufälliger Datensatz 4: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Out</b>		
2	Ja	125	17,08 [%]
3	Nein	607	82,92 [%]
4	<b>Wegzeit</b>		
5	kein Weg (Wert = 0)	215	29,37 [%]
6	<b>Geofence</b>		
7	Abschnitt	660	90,16 [%]
8	Lager	72	9,84 [%]
9	<b>Bauteil</b>		
10	Bodenplatte	79	10,79 [%]
11	Sockel	148	20,22 [%]
12	Wand	369	50,41 [%]
13	Decke	95	12,98 [%]
14	Attika	41	5,60 [%]

Tab. 6-24 Zufälliger Datensatz 4: Analyse der Kategorievariablen

Nach der Beurteilung des Datensatzes folgt wieder die Modellbildung. Hierfür werden 29 neuronale Netze, welche einen Input-, einen Hidden- sowie einen Output-Layer aufweisen, trainiert und die dazugehörige Anzahl der Hidden-Neuronen durchläuft den Bereich von 2 bis 30. Im Zuge der Validierung wird abschließend das Netz mit dem geringsten prozentualen Fehleranteil ausgewählt, wobei das beste Netz des zweiten Datensatzes 4 Hidden-Neuronen und einen Fehleranteil von 40,91 % besitzt. Die nachfolgende Tabelle 6-13 fasst die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle zusammen.

<b>Bestes Netz: 9 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	586
Falsche Prognosen	33,62 [%]
<b>Validieren</b>	
Anzahl Fälle	146
Falsche Prognosen	41,10 [%]

Tab. 6-25 Zufälliger Datensatz 4: Bestes Netz

Weiters ist es wichtig, darauf zu achten, wie die falschen Klassifizierungen auf die einzelnen Tätigkeiten verteilt sind. Die Tabellen 6-26 und 6-27 beinhalten hierfür die Aufteilung der falschen Vorhersagen unter Berücksichtigung von Schalen, Bewehren und Betonieren. Sowohl beim Trainieren als auch beim Validieren ist sofort ersichtlich, dass die künstliche Intelligenz keinen allgemeingültigen Zusammenhang gefunden hat, da die Tätigkeit Betonieren nicht zielführend erlernt wurde. Das neuronale Netz teilt fast nur in Schalen oder Bewehren ein, lediglich einem Fall wird Betonieren zugeschrieben. Aus diesem Grund ist diese Variante der Modellbildung nicht einsetzbar.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	234	47	3	17,61 [%]
2	Bewehren	58	154	1	27,70 [%]
3	Betonieren	47	41	1	98,88 [%]

Tab. 6-26 Zufälliger Datensatz 4: Klassifikationsmatrix Trainieren

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	53	19	0	26,39 [%]
2	Bewehren	15	33	1	32,65 [%]
3	Betonieren	14	11	0	100,00 [%]

Tab. 6-27 Zufälliger Datensatz 4: Klassifikationsmatrix Validieren

Um die Ergebnisinterpretation des besten neuronalen Netzes aus dem vierten zufälligen Datensatz abzuschließen, wird in Abbildung 6-11 die Auswirkungsanalyse der einzelnen Parameter gezeigt. Hierbei ist ersichtlich, dass die künstliche Intelligenz die Distanz als Leitvariable identifiziert hat. Dieser Haupteinflussfaktor weist rund 18,7 % auf und liegt mit rund 2,5 % Vorsprung vor dem Zweitgereihten. Wie auch bei den vorherigen Datensätzen liegen bei der Auswirkungsanalyse die Variablen Out und Geofence mit 5,5 % bzw. 5,0 % an unterster Stelle.






Abb. 6-11 Zufälliger Datensatz 4: Auswirkungsanalyse

### 6.3.5 Zufällig ausgewählter Datensatz 5

Die Verteilung der Trainings- und Validierungsfälle des fünften und letzten zufällig zusammengestellten Datensatzes wird in Tabelle 6-28 veranschaulicht. Insgesamt besteht dieser aus 788 Fällen, wobei 50 % die Tätigkeit Schalen, 36 % Bewehren und 14 % Betonieren beinhalten.

Lfd. Nr.	Tätigkeiten	Trainingfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	316	78	394
2	Bewehren	227	53	280
3	Betonieren	87	27	114
4	Summe	630	158	788

Tab. 6-28 Zufälliger Datensatz 5: Trainings- und Validierungsfälle

Nachfolgend wird auf die Verteilung der Trainings- und Validierungsfälle eingegangen, um potenzielle Bereiche zu identifizieren, in denen keine ausreichende Menge an Daten vorhanden ist, wodurch dort die Prognosegenauigkeit des Netzes große Abweichungen aufweisen kann. Aus Abbildung 6-12 wird ersichtlich, dass dies beim vorliegenden Datensatz nicht der Fall ist. Sowohl die türkis eingefärbten Trainingsfälle, als auch die roten Validierungsdaten weisen in den einzelnen Histogrammen eine zum gefilterten Basisdatensatz passende Verteilung und keine großräumigen Fehlstellen auf.

Die im Geofence von den Arbeitskräften zurückgelegte Distanz hat eine Bandbreite beim Schalen von 0 bis 0,38 km, beim Bewehren von 0 bis 0,37 km und beim Betonieren von 0 bis 0,54 km, wobei rund 24 % der Fälle beim Schalen, 34 % beim Bewehren und 17 % beim Betonieren unter 0,05 km liegen. Die Mittelwerte der jeweiligen Tätigkeiten betragen 0,10 km, 0,07 km sowie 0,12 km und die Standardabweichungen weisen in gewohnter Reihenfolge der Tätigkeiten 0,07 km, 0,05 km und 0,09 km auf.

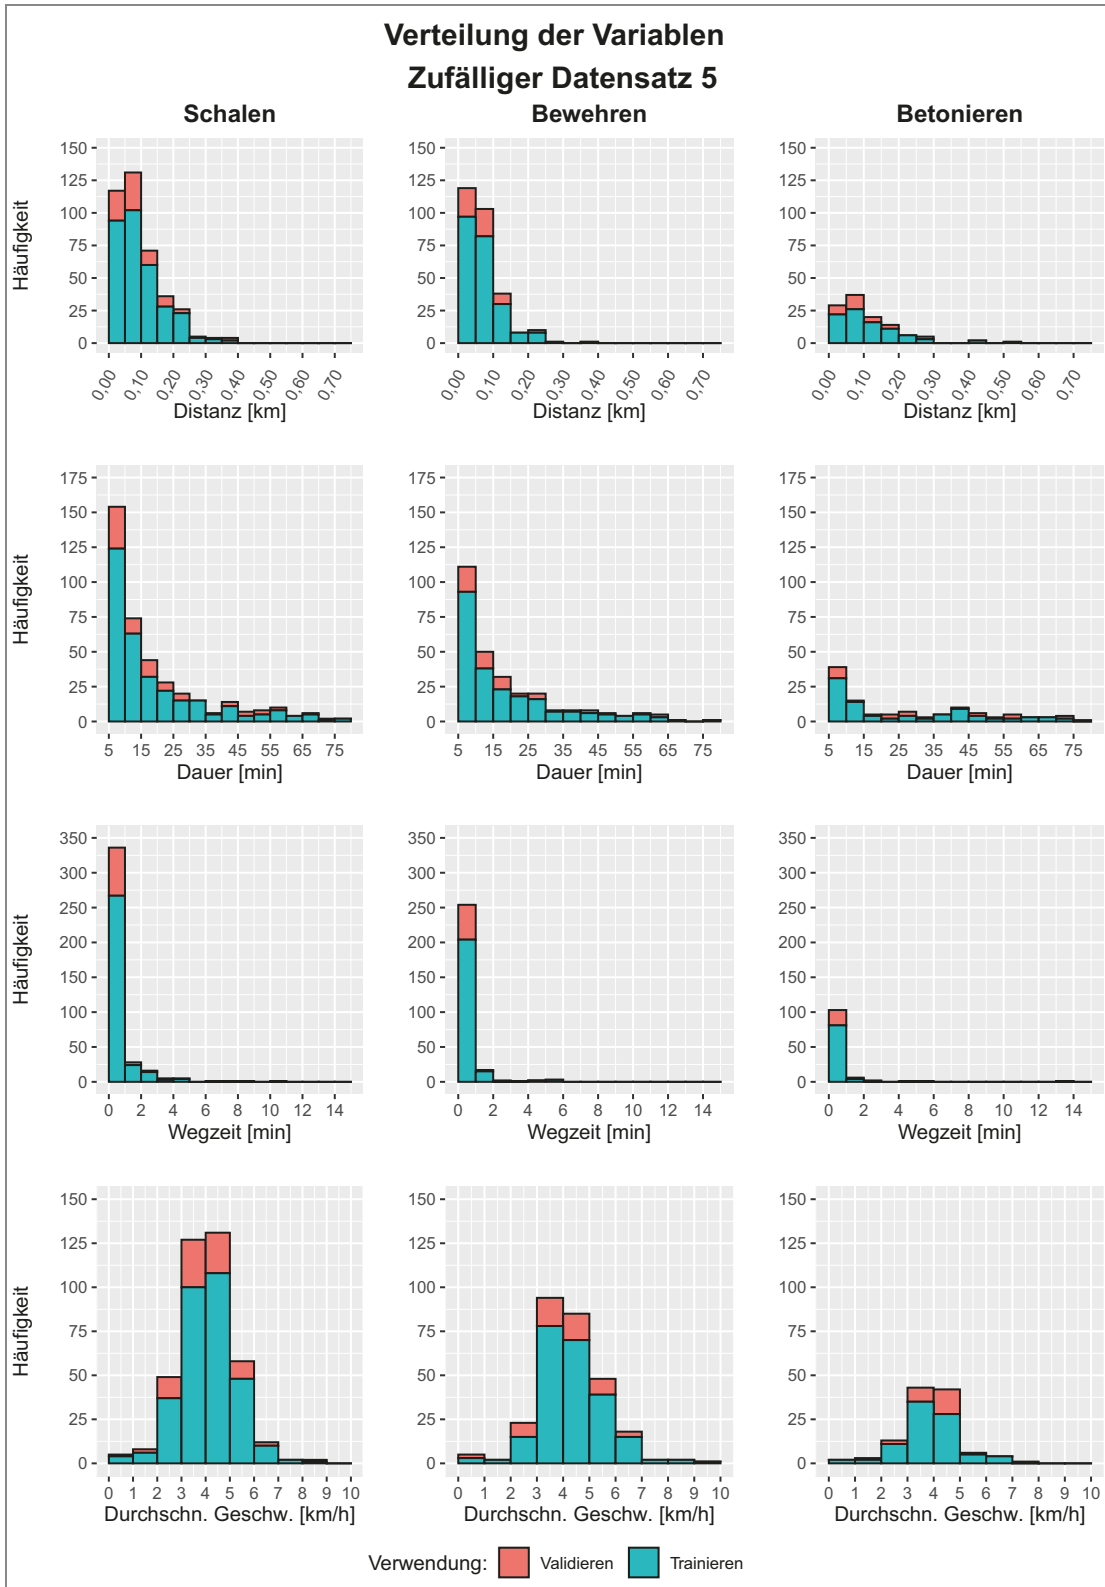


Abb. 6-12 Zufälliger Datensatz 5: Verteilung der einzelnen Parameter

Die Verweildauer im Geofence erstreckt sich beim Aufstellen der Schalungselemente über einen Bereich von 5,00 bis 77,57 min, beim Verlegen der Bewehrungsseisen von 5,08 bis 76,88 min und beim Betonieren von 5,03 bis

78,95 min. Hierbei ist anzumerken, dass bei der ersten Tätigkeit 39 %, bei der zweiten 40 % und bei der letzten 34 % der Fälle unter 10 min liegen. Die dazugehörigen Mittelwerte betragen jeweils 19,07 min, 18,33 min und 26,70 min. Die abgebildete Schiefe der Verteilung wird durch die Abweichung der Mediane, welche 12,72 min, 12,98 min und 19,34 min betragen, vom Mittelwert verdeutlicht. Die jeweiligen Standardabweichungen machen 16,25 min, 14,77 min und 21,15 min aus.

Die Bandbreite der Wegzeit liegt beim Schalen zwischen 0 und 10,77 min, beim Bewehren zwischen 0 und 37,88 min sowie beim Betonieren zwischen 0 und 13,90 min. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 0,48 min, 0,44 min und 0,42 min. Auch bei diesen Verteilungen wird die deutlich auffallende Schiefelage der Daten durch die großen Unterschiede zwischen den Medianen, welche jeweils 0,03 min, betragen, und den Mittelwerten bekräftigt. Die Standardabweichungen weisen eine Größe von 1,17 min, 2,38 min und 1,49 min auf.

Die durchschnittliche Geschwindigkeit umfasst als Maximum beim Schalen 9 km/h, beim Bewehren 10 km/h sowie beim Betonieren 8 km/h. Das Minimum aller Tätigkeiten beträgt 0 km/h und die Mediane, welche 5 km/h, 5 km/h und 4 km/h ausmachen, weichen nur geringfügig von den einzelnen Mittelwerten (4,55 km/h, 4,76 km/h und 4,38 km/h) ab. Die dazugehörigen Standardabweichungen betragen 1,23 km/h, 1,32 km/h und 1,18 km/h.

Die maximale Geschwindigkeit weist ein einheitliches Minimum von 0 km/h und einen Maximalwert beim Aufstellen der Schalung von 35 km/h, beim Verlegen der Bewehrung von 30 km/h und beim Einbringen des Betons von 24 km/h auf. Der Mittelwert und der Median beziffern sich beim Schalen auf 8,21 km/h und 8,00 km/h, beim Bewehren auf 8,09 km/h und 7,50 km/h sowie beim Betonieren auf 8,13 km/h und 8,00 km/h, während sich die dazugehörigen Standardabweichungen auf 3,44 km/h, 3,58 km/h und 3,44 km/h belaufen.

Die deskriptive Statistik des fünften zufällig ausgewählten Datensatzes wird in Tabelle 6-29 dargestellt. Weiters verdeutlicht Tabelle 6-30 die dazugehörige Analyse der Kategorievariablen. Hierbei ist ersichtlich, dass 90 % der Fälle den Abschnitt beinhalten und nur 10 % das Lager. Rund 32 % der Fälle weisen zwischen den Bereichen keine Wegzeiten auf.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Wegzeit	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[min]	[km/h]	[km/h]
0	A	B	C	D	E	F
1	Minimum	0,00	5,00	0,00	0,00	0,00
2	Maximum	0,54	78,95	37,88	10,00	35,00
3	Mittelwert	0,09	19,91	0,46	4,60	8,15
4	Median	0,08	13,06	0,03	5,00	8,00
5	Standardabweichung	0,07	16,80	1,74	1,26	3,49

Tab. 6-29 Zufälliger Datensatz 5: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Out</b>		
2	Ja	137	17,39 [%]
3	Nein	651	82,61 [%]
4	<b>Wegzeit</b>		
5	kein Weg (Wert = 0)	250	31,73 [%]
6	<b>Geofence</b>		
7	Abschnitt	709	89,97 [%]
8	Lager	79	10,03 [%]
9	<b>Bauteil</b>		
10	Bodenplatte	69	8,76 [%]
11	Sockel	168	21,32 [%]
12	Wand	398	50,51 [%]
13	Decke	103	13,07 [%]
14	Attika	50	6,35 [%]

Tab. 6-30 Zufälliger Datensatz 5: Analyse der Kategorievariablen

Nach der Beurteilung des Datensatzes folgt wieder die Modellbildung. Hierfür werden 29 neuronale Netze, welche jeweils einen Input-, einen Hidden- und einen Output-Layer aufweisen, trainiert. Die dazugehörige Anzahl der Hidden-Neuronen durchläuft hierbei den Bereich von 2 bis 30. Im Zuge der Validierung wird abschließend das Netz mit dem geringsten prozentualen Fehleranteil ausgewählt, wobei das beste Netz des fünften Datensatzes 12 Hidden-Neuronen und einen Fehleranteil von 43 % besitzt. Die nachfolgende Tabelle 6-31 fasst die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle zusammen.

<b>Bestes Netz: 12 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	630
Falsche Prognosen	33,17 [%]
<b>Validieren</b>	
Anzahl Fälle	158
Falsche Prognosen	43,04 [%]

Tab. 6-31 Zufälliger Datensatz 5: Bestes Netz

Weiters ist es wichtig, darauf zu achten, wie die falschen Klassifizierungen auf die einzelnen Tätigkeiten verteilt sind. Die Tabellen 6-32 und 6-33 beinhalten hierfür die Aufteilung der falschen Vorhersagen unter Berücksichtigung von Schalen, Bewehren und Betonieren. Im Training schneiden das Aufstellen der Schalung und das Verlegen der Bewehrung deutlich besser ab als das Einbringen von Beton. Mit einem Fehleranteil von rund 84 % liegt das Betonieren weit abgeschlagen an letzter Stelle. Beim Validieren verschlechtern sich alle drei Tätigkeiten.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	269	40	7	14,87 [%]
2	Bewehren	87	138	2	39,21 [%]
3	Betonieren	47	26	14	83,91 [%]

Tab. 6-32 Zufälliger Datensatz 5: Klassifikationsmatrix Trainieren

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	60	16	2	23,08 [%]
2	Bewehren	25	27	1	49,06 [%]
3	Betonieren	12	12	3	88,89 [%]

Tab. 6-33 Zufälliger Datensatz 5: Klassifikationsmatrix Validieren

Um die Ergebnisinterpretation des besten neuronalen Netzes aus dem fünften zufälligen Datensatz abzuschließen, wird nachfolgend die Auswirkungsanalyse der einzelnen Parameter in Abbildung 6-13 gezeigt. Hierbei wird deutlich, dass die künstliche Intelligenz die durchschnittliche und die maximale Geschwindigkeit als Leitvariablen identifiziert hat. Die beiden Haupteinflussfaktoren weisen 17,4 % und 16,3 % auf. Wie auch bei allen anderen Datensätzen sind bei der Auswirkungsanalyse die Variablen Out und Geofence an unterster Stelle.




Abb. 6-13 Zufälliger Datensatz 5: Auswirkungsanalyse

### 6.3.6 Modellvalidierung mittels Testdaten

Um abschließend die Übereinstimmungen von Wirklichkeit und Modell zu überprüfen sowie einen Vergleich untereinander zu ermöglichen, wird nachfolgend jedes der fünf Modelle am gesamten 5-80min-Datensatz getestet und die Verteilung der hierfür eingesetzten Fälle in Tabelle 6-34 veranschaulicht. Insgesamt besteht dieser aus 2.806 Fällen, wobei 68% die Tätigkeit Schalen, 28 % Bewehren und 4 % Betonieren beinhalten. Die vorlie-

gende Aufteilung verdeutlicht nochmals die Wichtigkeit der bei der Modellbildung durch eine zufällige Auswahl herbeigeführten Fallreduktion der Tätigkeiten Schalen und Bewehren.

Lfd. Nr.	Tätigkeiten	Testfälle
0	A	B
1	Schalen	1.894
2	Bewehren	798
3	Betonieren	114
4	Summe	2.806

Tab. 6-34 5-80min-Datensatz: Testfälle

Nachfolgend wird in Abbildung 6-14 die Verteilung der Testfälle gezeigt, wobei die überwiegende Dominanz der Tätigkeit Schalen nicht zu übersehen ist. Weiters zeichnet sich im zwischen 5-80 Minuten eingeschränkten Verweilbereich keine klassenspezifische Verteilung der einzelnen Tätigkeiten ab.

Die hierbei im Geofence von einer Arbeitskraft zurückgelegte Distanz weist eine Bandbreite beim Schalen von 0 bis 0,74 km, beim Bewehren von 0 bis 0,44 km und beim Betonieren von 0 bis 0,54 km auf. Weiters liegen rund 24 % der Fälle beim Schalen und 38 % beim Bewehren unter 0,05 km. Beim Einbringen des Betons beläuft sich dieser Anteil auf 17 %. Die Mittelwerte der jeweiligen Tätigkeiten betragen 0,11 km, 0,07 km und 0,12 km, wobei sich die Mediane auf 0,08 km, 0,06 km und 0,09 km belaufen. Die dazugehörigen Standardabweichungen machen 0,09 km, 0,06 km und 0,09 km aus.

Die Verweildauer im Geofence erstreckt sich beim Aufstellen der Schalungselemente über einen Bereich von 5,00 bis 79,78 min, beim Verlegen der Bewehrung von 5,00 bis 78,98 min und beim Betonieren von 5,03 bis 78,95 min. Auffallend ist hierbei, dass bei der ersten Tätigkeit 41 %, bei der zweiten 38 % und bei der letzten 34 % der Fälle unter 10 min liegen. Die dazugehörigen Mittelwerte machen jeweils 19,01 min, 18,98 min und 26,70 min aus. Die in Abbildung 6-14 ersichtliche Schiefe der Verteilung wird auch durch die Abweichung der Mediane, welche 12,23 min, 13,74 min und 19,34 min betragen, vom Mittelwert hervorgehoben. Die jeweiligen Standardabweichungen ergeben 16,45 min, 15,23 min und 21,15 min.

Die Bandbreiten der Wegzeiten liegen beim Schalen zwischen 0 und 36,73 min, beim Bewehren zwischen 0 und 37,88 min sowie beim Betonieren zwischen 0 und 13,90 min. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 0,48 min, 0,40 min und 0,42 min. Auch bei diesen Verteilungen wird die extreme Schiefe der Daten durch die großen Unterschiede zwischen den Medianen, welche sich jeweils auf 0,03 min belaufen, und den Mittelwerten bekräftigt. Die Standardabweichungen weisen eine Größe von 1,47 min, 1,64 min und 1,49 min auf.

Die durchschnittliche Geschwindigkeit umfasst als Maximum beim Schalen 10 km/h, beim Bewehren 10 km/h und beim Betonieren 8 km/h, während sich das Minimum aller Tätigkeiten auf 0 km/h beläuft. Die Mediane, welche 5 km/h, 5 km/h und 4 km/h betragen, weichen geringfügig von den einzelnen Mittelwerten (4,64 km/h, 4,66 km/h und 4,38 km/h) ab. Die dazugehörigen Standardabweichungen beziffern sich mit 1,19 km/h, 1,33 km/h und 1,18 km/h.

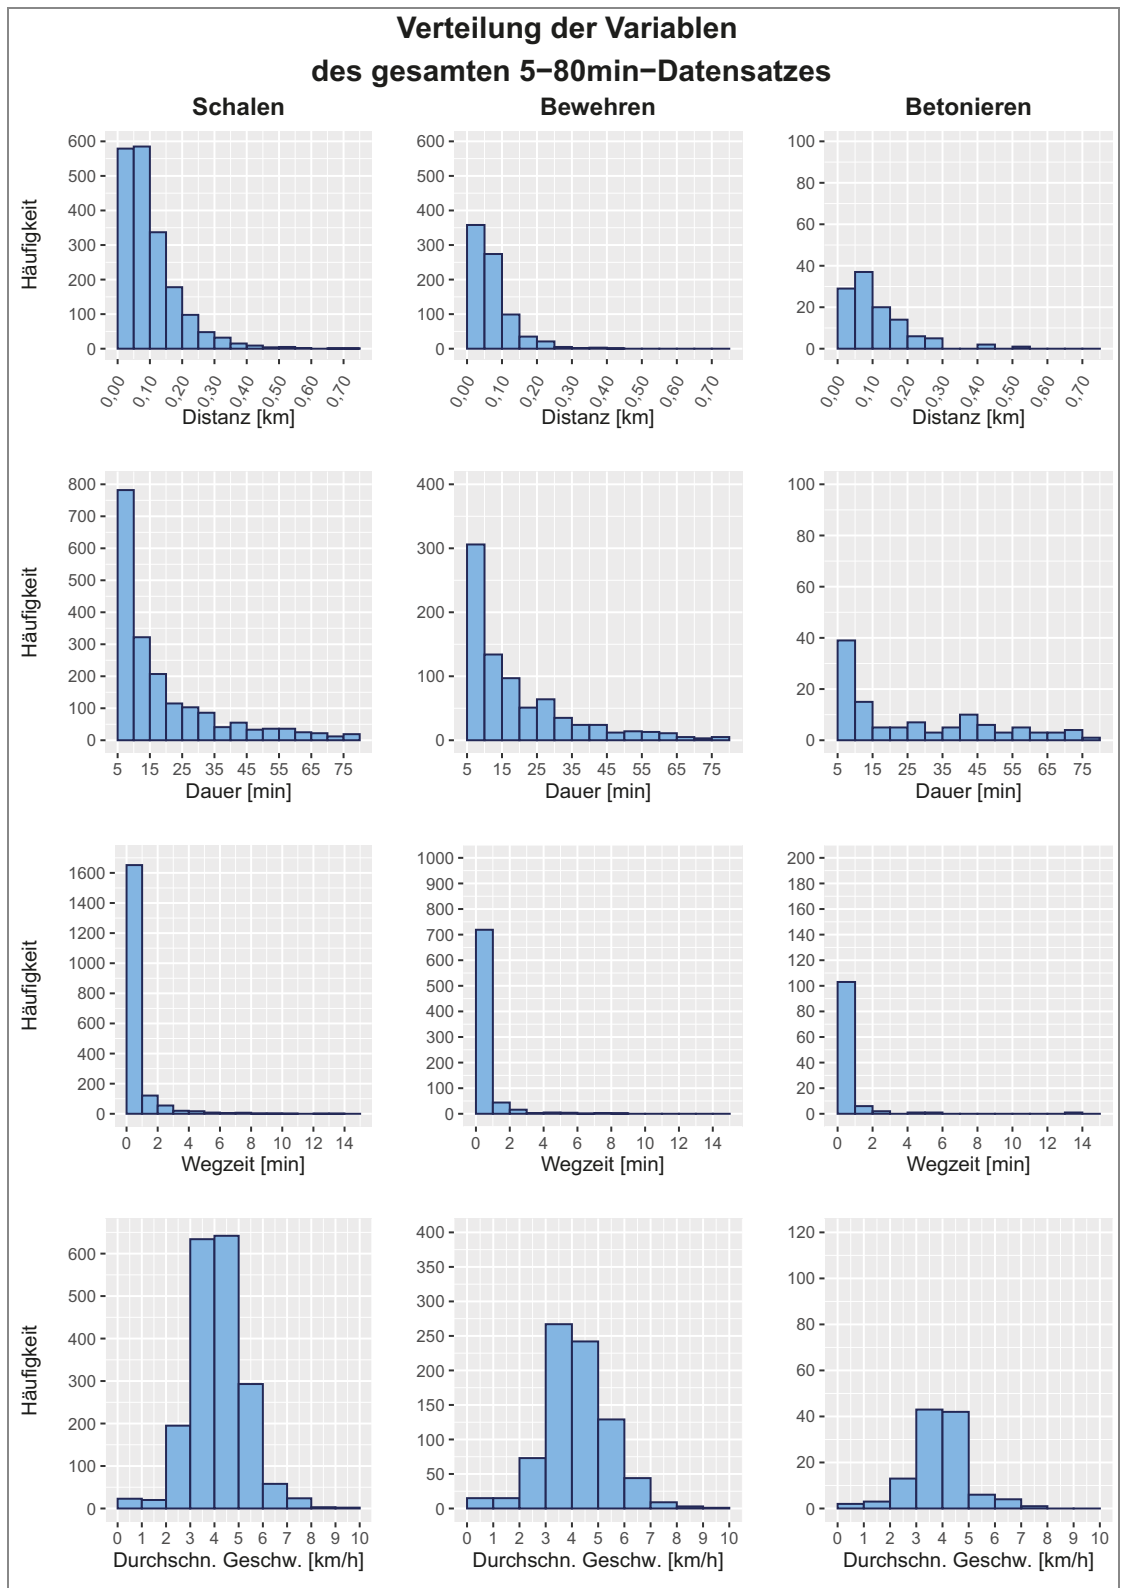


Abb. 6-14 5-80min-Datensatz: Verteilung der einzelnen Parameter

Die maximale Geschwindigkeit weist ein einheitliches Minimum von 0 km/h und einen Maximalwert beim Aufstellen der Schalung von 35 km/h, beim Verlegen der Bewehrung von 30 km/h und beim Einbringen des Betons von

24 km/h auf. Der Mittelwert und der Median betragen beim Schalen 8,34 km/h und 8,00 km/h, beim Bewehren 7,90 km/h und 7,00 km/h und beim Betonieren 8,13 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 3,37 km/h, 3,39 km/h und 3,44 km/h.

Die deskriptive Statistik des Testdatensatzes wird in Tabelle 6-35 dargestellt. Vergleichend mit den dazugehörigen Tabellen 6-6, 6-11, 6-17, 6-23 und 6-29 der einzelnen zufällig ausgewählten Trainings- und Validierungsfällen ist festzustellen, dass die Test-Bandbreite der Distanz nur in Datensatz 1 abgedeckt wird. Das Maximum der übrigen liegt bei rund 0,55 km, wohingegen die Spektren der Dauern kaum voneinander abweichen, was auf die gleichverteilte Auswahl zurückzuführen ist. Bei den Wegzeiten liegt das Maximum im Testdatensatz bei 37,88 min und ist nur mit jenem aus Datensatz 5 ident. Der Maximalwert der übrigen liegt bei 13,90 min. Die durchschnittliche sowie die maximale Geschwindigkeit decken sich in deren Bandbreiten hingegen sehr gut.

Tabelle 6-36 verdeutlicht die dazugehörige Analyse der Kategorievariablen. Hierbei ist ersichtlich, dass 90 % der Fälle den Abschnitt beinhalten und nur 10 % das Lager. Rund 29 % der Daten weisen zwischen den Bereichen keine Wegzeiten auf. Im Vergleich zu den Verteilungen der zufällig ausgewählten Datensätze (Tabelle 6-5, 6-12, 6-18, 6-24 und 6-30) ist keine auffallende Abweichung festzustellen.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Wegzeit	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[min]	[km/h]	[km/h]
0	A	B	C	D	E	F
1	Minimum	0,00	5,00	0,00	0,00	0,00
2	Maximum	0,74	79,78	37,88	10,00	35,00
3	Mittelwert	0,10	19,32	0,46	4,63	8,21
4	Median	0,07	12,68	0,03	5,00	8,00
5	Standardabweichung	0,08	16,40	1,52	1,23	3,39

Tab. 6-35 5-80min-Datensatz: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Out</b>		
2	Ja	499	17,78 [%]
3	Nein	2.307	82,22 [%]
4	<b>Wegzeit</b>		
5	kein Weg (Wert = 0)	809	28,83 [%]
6	<b>Geofence</b>		
7	Abschnitt	2.525	89,99 [%]
8	Lager	281	10,01 [%]
9	<b>Bauteil</b>		
10	Bodenplatte	228	8,13 [%]
11	Sockel	534	19,03 [%]
12	Wand	1.411	50,29 [%]
13	Decke	466	16,61 [%]
14	Attika	167	5,95 [%]

Tab. 6-36 5-80min-Datensatz: Analyse der Kategorievariablen



Um die beste Abbildung der Wirklichkeit auszuwählen, gilt es, den Fehleranteil falscher Prognosen innerhalb der Testdaten miteinander zu vergleichen. Hierfür wird nachfolgend Abbildung 6-15 gezeigt, welche neben dem prozentualen Anteil falscher Vorhersagen der Testdaten auch die der Validierungsfälle beinhaltet. Rasch ist hieraus ersichtlich, dass aufgrund der geringen Abweichungen innerhalb der Testdaten – Schwankungsbereich zwischen 32-35 % – kein eindeutiger Gewinner heraussticht. Auch die bei der Netzauswahl eingesetzten Validierungsfälle weisen nur kleine Unterschiede zwischen 40-43 % auf.




Abb. 6-15 5-80min-Datensatz: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze




Abb. 6-16 5-80min-Datensatz: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze

Neben der Gesamtbetrachtung müssen auch die falschen Vorhersagen innerhalb der einzelnen Tätigkeitsklassen der Testdaten beurteilt werden. Abbildung 6-16 veranschaulicht diese, wobei sofort ersichtlich wird, dass die künstliche Intelligenz, welche mittels Datensatz 1 trainiert wurde, am besten abschneidet. Vor allem die Klassifikation aus den Modellen 2,3 und 4 ist für jegliche Anwendung ungeeignet, da die Tätigkeit Betonieren nicht erkannt wird. Das in der Grafik abgebildete Ergebnis verdeutlicht nochmals sehr gut, welche Wichtigkeit diese Analyse besitzt. Würden die Fehler der einzelnen Tätigkeiten nicht berücksichtigt werden und die Auswahl des Netzes nur auf dem Gesamtfehler basieren, wäre eine künstliche Intelligenz ausgewählt worden, welche zwar mit drei Klassen trainiert wurde, aber nur zwei davon erkennen kann.

Auf Basis der Auswertung ist schlussfolgernd festzustellen, dass das neuronale Netz aus Datensatz 1, welches 24 Neuronen in dem Hidden-Layer aufweist, die Wirklichkeit am besten abbildet. Mit einem prozentualen Testfehleranteil von 33 % stellt es jedoch kein für die Praxis verwendbares Prognosemodell dar. Aus diesem Grund wird nach dem abschließenden Vergleich der einzelnen Auswirkungsanalysen eine auf die neuen Erkenntnisse aufbauende Modellbildung vorgestellt.

Tabelle 6-37 veranschaulicht den prozentualen Einfluss der einzelnen Variablen, wobei die Reihung der Einträge auf Basis von Datensatz 1 geschieht. Auffallend ist hierbei, dass der Geofence sowie Out immer die letzten zwei Plätze und die Distanz am öftersten Rang 1 belegen. Die maximale Geschwindigkeit ist nur im ersten Datensatz auf Platz eins, bei den anderen ist sie auf Rang 2 oder 3 anzutreffen. Weiters wird beim ausgewählten Modell die durchschnittliche Geschwindigkeit gegenüber den Datensätzen 2, 3 und 4 deutlich besser eingestuft, dafür schneidet im Vergleich die Variable Bauteil schlechter ab. Dauer und Wegzeit liegen bei allen Varianten im unteren Mittelfeld.

Lfd. Nr.	Parameter	Datensatz 1		Datensatz2		Datensatz 3		Datensatz 4		Datensatz 5	
		Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung
0	A	B	C	D	E	F	G	H	I	J	K
1	Max. Geschw.	1	15,61 [%]	3	14,32 [%]	2	18,58 [%]	3	15,46 [%]	2	16,30 [%]
2	Distanz	2	15,55 [%]	1	17,24 [%]	1	18,75 [%]	1	18,65 [%]	4	14,84 [%]
3	Durchschn. Geschw.	3	15,28 [%]	6	13,10 [%]	6	9,53 [%]	5	14,37 [%]	1	17,40 [%]
4	Wegzeit	4	14,57 [%]	4	13,98 [%]	5	10,28 [%]	6	10,18 [%]	5	14,33 [%]
5	Bauteil	5	14,21 [%]	2	17,19 [%]	3	18,46 [%]	2	16,07 [%]	3	14,90 [%]
6	Dauer	6	13,51 [%]	5	13,79 [%]	4	14,26 [%]	4	14,73 [%]	6	13,45 [%]
7	Geofence	7	6,09 [%]	8	4,90 [%]	7	7,65 [%]	8	5,04 [%]	8	4,08 [%]
8	Out	8	5,17 [%]	7	5,50 [%]	8	2,49 [%]	7	5,51 [%]	7	4,70 [%]

Tab. 6-37 5-80min-Datensatz: Vergleich der Auswirkungsanalyse

Zusammenfassend ist festzuhalten, dass Datensatz 1 das beste Modell hervor gebracht hat, dieses jedoch nicht zufriedenstellend ist. Einen Grund hierfür stellen die sehr ähnlichen Verteilungen der Variablen unter Berücksichtigung der einzelnen Tätigkeiten untereinander dar (Abbildung 6-14). Weiters erschweren die Ungleichheit der Fallanzahl je Tätigkeit und die große Menge kurzer Dauern das Finden eines allgemeinen Zusammenhanges. Dies ist auch aus dem Rang der Verweildauer, welche zwischen Platz 4 und 6 liegt, abzulesen. Nachfolgend wird diesen Herausforderungen mit einer neuen Modellbildung entgegengewirkt, bei der Dauern aufsummiert werden, damit tätigkeitstypische Bewegungsmuster besser erkannt werden können.

#### 6.4 Modellbildung basierend auf Abbruchkriterien

Auf Basis baubetrieblicher und ortungstechnischer Überlegungen sollte die Dauer bei der Klassifizierung der Tätigkeiten eine ähnlich wichtige Rolle spielen wie die zurückgelegte Distanz. Erst aus der Kombination dieser beiden Variablen ist es möglich, zu beurteilen, ob 300 Meter in einem Geofence viel oder wenig sind. Wird diese Strecke beispielsweise von einer Arbeitskraft innerhalb von 5 Minuten bewältigt, handelt es sich hierbei um eine bewegungsaktive Tätigkeit. Wird diese Distanz innerhalb einer Stunde zurückgelegt, ist die Fachkraft sehr lokal gebunden. Weiters spielt es für das Erkennen von tätigkeitstypischen Verhaltensmustern eine wichtige Rolle, dass eine ausreichende Verweildauer – nicht nur wenige Minuten – vorliegt.

Die Auswirkungsanalysen der vorherigen Modellbildungen zeigen, dass die künstliche Intelligenz die soeben beschriebene Überlegung nicht berücksichtigt. Zudem wird den Lageraufenthalten (Variable Geofence) und den Wegen (Variable Out) in keinen der Analysen Bedeutung zugemessen. Ebenso erschwert die überwiegende Anzahl an Fällen, welche nur eine Dauer zwischen 5-10 Minuten aufweisen, das Erstellen zuverlässiger Vorhersagen. Um diesen Phänomenen entgegenzuwirken, werden bei der nachfolgenden Modellerstellung hintereinanderliegende Fälle so lange aufsummiert, bis die Dauern eine gewisse Zeitgrenze erreichen oder überschreiten. Hierbei stellen die Abbruchkriterien, 10, 20 und 30 Minuten, die Basis für das Zusammenstellen der neuen drei Datensätze dar, anhand derer in weiterer Folge die neuronalen Netze trainiert und validiert werden. Damit sich das Ungleichgewicht der tätigkeitsbezogenen Fälle weniger auf das Prognoseergebnis auswirkt, werden wiederum die Schalungs- und Bewehrungsfälle zufällig ausgewählt. An dieser Stelle ist anzumerken, dass die Unterschiede der einzelnen prozentualen Anteile im Vergleich zu den vorherigen zufälligen Datensätzen 1-5 noch stärker reduziert werden. Dies soll vor allem dem übermäßigen Erlernen der Tätigkeit Schalen entgegenwirken.

Die Grundlage der neuen Datenaufbereitung bildet der Basisdatensatz. Ausgehend von diesem werden die einzelnen hintereinanderliegenden Fälle, welche nach der Uhrzeit sortiert sind, miteinander in Verbindung gebracht, wenn sie vom selben Gadget, am selben Tag, mit identer Tätigkeit und am selben Bauteil stattgefunden haben. Ist dies der Fall, werden die aufeinander folgenden Fälle so lange miteinander kombiniert, bis das jeweilige Abbruchkriterium (10, 20 oder 30 Minuten) erreicht oder überschritten ist. Hierbei werden die einzelnen Dauern und Distanzen aufsummiert, die Anzahl der Lagerbesuche sowie der Wege außerhalb des Geofence gezählt und die nach der Zeit gewichtete durchschnittliche Geschwindigkeit sowie die maximale Geschwindigkeit ermittelt.

Nachfolgend wird auf die drei Datensätze, welche die Abbruchkriterien von 10, 20 und 30 Minuten beinhalten, und die darauf aufbauende Modellbildung eingegangen. Um die jeweiligen Auswirkungen dieser drei Kriterien besser zu verdeutlichen, weist die zu Beginn der kommenden Abschnitte verfasste Datenanalyse immer Vergleiche zum vorherigen Datensatz auf. Weiters ist es wichtig, hervorzuheben, dass die künstliche Intelligenz nicht auf Basis der jeweiligen gesamten Fälle Zusammenhänge zu finden versucht, sondern als Grundlage die zufällig daraus ausgewählten Schalungs- und Bewehrungs-

sowie alle Betoniereinträge dienen. Die abschließende Modellvalidierung erfolgt wieder mit dem Testdatensatz, welcher sämtliche Fälle beinhaltet.

Diese Vorgehensweise wurde deshalb gewählt, um die stark voneinander abweichenden Fallanzahlen der Tätigkeiten Schalen, Bewehren und Betonieren auszugleichen. Somit wird jeweils für die drei Abbruchkriterien ein Subdatensatz erstellt, welcher die ausgewählten Fälle beinhaltet und dadurch die Grundlage für das Trainieren und Validieren (Fallaufteilung von 80:20) liefert. Zusätzlich werden je Subdatensatz fünf verschiedene, ebenfalls zufällig gewählte Einteilungen von Trainings- und Validierungsfällen untersucht, um deren Einfluss auf das Prognoseergebnis festzustellen. Diese fünf Varianten werden jeweils am Ende des Abschnitts vergleichend dargestellt, wobei zuvor im Fließtext nur das neuronale Netz mit dem geringsten Fehleranteil näher beleuchtet wird. Nachdem diese Vorgehensweise für alle drei Datensätze in den jeweiligen Unterpunkten beschrieben worden ist, wird abschließend ein Vergleich zwischen den drei besten Ergebnissen präsentiert, um das zielführendste Abbruchkriterium zu bestimmen.

#### 6.4.1 Subdatensatz mit 10-minütigem Abbruchkriterium

Der erste Subdatensatz, welcher 841 Zeilen aufweist, beinhaltet die zufällig ausgewählten Schalungs- und Bewehrungsfälle aus der Modellbildung basierend auf dem 10-minütigen Abbruchkriterium sowie alle dazugehörigen Betoniereinträge. Insgesamt werden hieraus fünf Varianten aus unterschiedlichen Trainings- und Validierungsdaten erstellt, welche die Ausgangsbasis für die Prognosemodelle darstellen. Tabelle 6-38 zeigt für Variante 4, welche den geringsten Fehlerwert (siehe Abschnitt 6.4.2) aufweist, die Aufteilung der einzelnen Tätigkeiten. Hierbei wurde darauf geachtet, dass die Abweichungen der einzelnen Fallanzahlen von Schalen, Bewehren und Betonieren im Vergleich zur vorherigen Modellbildung minimiert werden, damit vor allem der Schaleinfluss aufgrund seiner mengenmäßigen Überlegenheit reduziert wird. Das Aufstellen der Schalung deckt 39 %, das Verlegen der Bewehrung 35 % und das Einbringen des Betons 26 % der Fälle ab. Die Aufteilung zwischen Trainings- und Validierungsdaten beträgt bei allen Tätigkeiten rund 80:20.

Lfd. Nr.	Tätigkeiten	Trainingsfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	265	65	330
2	Bewehren	240	52	292
3	Betonieren	168	51	219
4	Summe	673	168	841

Tab. 6-38 Subdatensatz 1: Fallanzahl der einzelnen Tätigkeiten (Variante 4)

Neben dem Anteil der einzelnen Tätigkeiten gilt es, auch die Verteilung der Variablen näher zu analysieren. Zu den Inputparametern zählen Distanz, Dauer, Anzahl der Wege, Anzahl der Lagerbesuche, durchschnittliche und maximale Geschwindigkeit sowie die Art des Bauteils. Um einen Eindruck von der Datenlage zu bekommen, zeigen Abbildung 6-17 und Abbildung 6-18 die Verteilung der jeweiligen Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren. Die Trainingsfälle sind hierbei türkis und die Validierungsfälle rot eingefärbt.

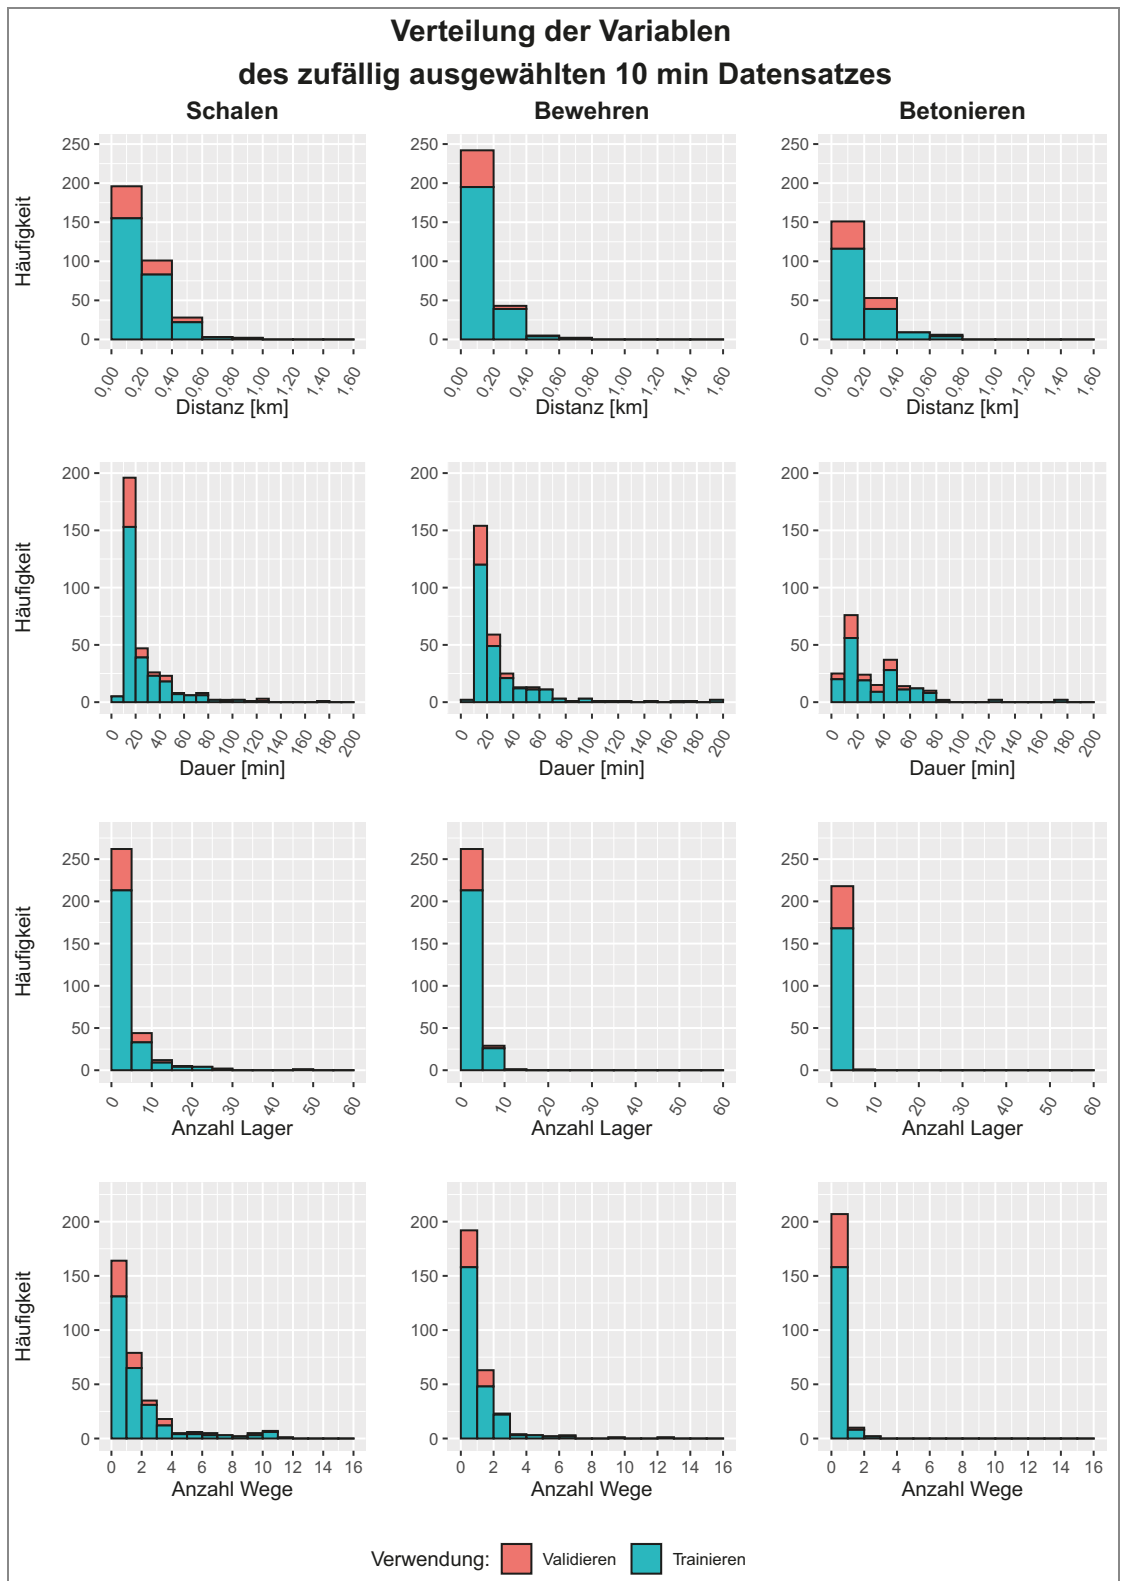



Abb. 6-17 Subdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalens, Bewehren und Betonieren

Der Vergleich der einzelnen Histogramme zeigt, dass sich Schalens nicht mehr durch eine überdurchschnittliche Fallanzahl hervorhebt. Im Gegensatz zum

Basisdatensatz reduziert das Aufsummieren hintereinanderliegender Einträge die Fallanzahl und verschiebt die Häufigkeitsverteilungen nach oben. Eine offensichtliche Abgrenzung der Klassen untereinander ergibt sich jedoch nicht.



**Abb. 6-18** Subdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalens, Bewehren und Betonieren

Die Distanz, welche die Arbeitskräfte im Geofence zurücklegen, hat eine Bandbreite beim Schalens von 0 bis 0,93 km, beim Bewehren von 0 bis 0,76 km und beim Betonieren von 0 bis 0,74 km. Die Mittelwerte der jeweiligen Tätigkeiten beziffern sich auf 0,20 km, 0,13 km und 0,18 km, wobei die dazugehörigen Mediane 0,17 km, 0,10 km und 0,15 km betragen. Die Standardabweichungen weisen in gewohnter Reihenfolge der Tätigkeiten 0,14 km, 0,10 km und 0,14 km auf.

Die Verweildauer im Geofence erstreckt sich beim Schalens von 1,23 bis 172,84 min, beim Bewehren von 7,34 bis 199,00 min und beim Betonieren von 0,73 bis 174,23 min, während die dazugehörigen Mittelwerte 25,36 min, 28,49 min und 31,83 min betragen. Die abgebildete Schiefe der Verteilung wird wiederum durch die Abweichung der Mediane, welche sich auf 15,65 min, 18,54 min und 22,19 min belaufen, vom Mittelwert verdeutlicht. Die jeweiligen Standardabweichungen machen 22,86 min, 27,65 min und 26,73 min aus.

Die Anzahl der Lagerbesuche während der dazugehörigen Dauer im Geofence liegt beim Schalens zwischen 0 und 47, beim Bewehren zwischen 0 und 11 sowie beim Betonieren zwischen 0 und 6. Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 4,00, 2,54 und 0,91 Besuche. Die Mediane belaufen sich beim Schalens und Bewehren auf 2 Lagerbesuche und beim Betonieren auf einen. Die Standardabweichungen weisen eine Größe von 5,00, 2,00 sowie 1,17 auf. Bei der Analyse dieses Parameters wird ersichtlich,

dass vor allem das Aufstellen der Schalung mit vielen Lagerbesuchen verbunden ist.

Neben den Lagerarbeiten wird auch die Anzahl der außerhalb vom Geofence zurückgelegten Wege aufsummiert. Ein Weg ist dadurch charakterisiert, dass zwischen dem Verlassen des letzten Geofence und dem Betreten des nächsten – beispielsweise vom Baufeld zum Container – ein Zeitfenster entsteht, welches mit einem Weg gleichzusetzen ist. Die Summe der Wege beinhaltet somit die gesamte Anzahl der Strecken, die von der Fachkraft außerhalb des Geofence zurückgelegt werden. An dieser Stelle ist aber hervorzuheben, dass nicht jeder Lagerbesuch einen davor zurückgelegten Weg als Voraussetzung hat. In manchen Bereichen liegen die beiden Geofence-Zäune so dicht aneinander, sodass keine Wegzeiten gemessen werden.

Das Spektrum der Anzahl der Wege erstreckt sich beim Schalen von 0 bis 12 Wege, beim Verlegen der Bewehrung von 0 bis 13 und beim Einbringen des Betons von 0 bis 3. Die jeweiligen Mittelwerte betragen 2,22, 1,39 und 0,42 Wege, wobei sich die Mediane auf 2, 1 und 0 beziffern. Auch bei dieser Variablen ist zu erkennen, dass die Schalarbeiten im Vergleich zu den anderen Tätigkeiten bewegungsintensiver sind. Die Standardabweichungen machen 2,36, 1,49 und 0,62 Wege aus.

Die durchschnittliche Geschwindigkeit verläuft beim Schalen zwischen 1,85 und 8 km/h, beim Bewehren zwischen 0 und 7,76 km/h sowie beim Betonieren zwischen 0 und 8 km/h. Die Mittelwerte, welche 4,78 km/h, 4,67 km/h und 4,4 km/h ausmachen, weichen nur geringfügig von den einzelnen Medianen (4,82 km/h, 4,96 km/h und 4,21 km/h) ab. Die dazugehörigen Standardabweichungen sind 1,00 km/h, 1,08 km/h und 1,11 km/h.

Die maximale Geschwindigkeit erstreckt sich beim Aufstellen der Schalung über eine Bandbreite von 3 bis 28 km/h, beim Verlegen der Bewehrung von 0 bis 21 km/h und beim Einbringen des Betons von 0 bis 24 km/h. Der Mittelwert und der Median beziffern sich beim Schalen auf 10,27 km/h und 9,00 km/h, beim Bewehren auf 9,07 km/h und 9 km/h sowie beim Betonieren auf 9,05 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 3,86 km/h, 3,37 km/h und 3,73 km/h.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Anzahl Lager	Anzahl Wege	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[-]	[-]	[km/h]	[km/h]
0	A	B	C	D	E	F	G
1	Minimum	0,00	0,73	0,00	0,00	0,00	0,00
2	Maximum	0,93	199,00	47,00	13,00	8,00	28,00
3	Mittelwert	0,17	28,13	2,69	1,46	4,64	9,54
4	Median	0,14	17,87	2,00	1,00	4,76	9,00
5	Standardabweichung	0,13	25,75	3,61	1,89	1,07	3,71

Tab. 6-39 Subdatensatz 1: Deskriptive Statistik

Um einen Überblick über die Bandbreite des gesamten ersten Subdatensatzes zu geben, wird Tabelle 6-39 angeführt. Dabei ist zu erkennen, dass vor allem bei der Dauer der Mittelwert vom Median stark abweicht, was auf die deutlich überlegene Menge an kürzeren Einträgen (unter 20 Minuten) zurückzuführen ist.

Neben den numerischen Parametern gilt es, auch die unterschiedlichen Bauteiltypen zu analysieren. Tabelle 6-40 fasst die Verteilung innerhalb

dieser zusammen. Mit 46 % überwiegen die Wände deutlich, wobei der Sockel mit 22 %, die Decke mit 17 % und die Bodenplatte mit 10 % im Mittelfeld liegen. Die Attika hingegen ist nur mit 5 % vertreten.

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Bauteil</b>		
2	Bodenplatte	86	10,23 [%]
3	Sockel	186	22,12 [%]
4	Wand	386	45,90 [%]
5	Decke	141	16,77 [%]
6	Attika	42	4,99 [%]

Tab. 6-40 Subdatensatz 1: Auswertung der Kategorievariablen

Der soeben vorgestellte Datensatz wird nachfolgend als Basis für die Modellbildung herangezogen. Hierfür gilt es, zunächst die Trainings- und Validierungsfälle im Verhältnis von 80:20 zuzuweisen und anschließend die künstliche Intelligenz zu trainieren, wobei alle sieben Parameter als Inputvariable berücksichtigt werden. Um eine bessere Vergleichbarkeit zu gewährleisten, werden wie bei den vorherigen Modellen zwischen 2 und 30 Hidden-Neuronen in einem Layer eingesetzt und abschließend anhand der Validierungsdaten das beste neuronale Netz ausgesucht. Damit der Einfluss der zu Beginn festgelegten Trainingsdaten besser beurteilt werden kann, wird der gesamte Prozess insgesamt fünf Mal durchgeführt und die Ergebnisse der einzelnen Varianten einander gegenüber gestellt.

Hierbei erzielt Variante 4 mit einem neuronalen Netz, welches 30 Hidden-Neuronen und beim Validieren einen Fehleranteil von 29 % aufweist, das beste Resultat. Die nachfolgende Tabelle 6-41 fasst die falschen Prognosen unter Berücksichtigung von Trainings- und Validierungsfällen zusammen.

<b>Bestes Netz: 30 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	673
Falsche Prognosen	17,38 [%]
<b>Validieren</b>	
Anzahl Fälle	168
Falsche Prognosen	28,57 [%]

Tab. 6-41 Subdatensatz 1: Bestes Netz

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	222	34	9	16,23 [%]
2	Bewehren	37	196	7	18,33 [%]
3	Betonieren	13	17	138	17,86 [%]

Tab. 6-42 Subdatensatz 1: Klassifikationsmatrix Trainieren



Die Tabellen 6-42 und 6-43 beinhalten die Aufteilung der falschen Vorhersagen unter Berücksichtigung der einzelnen Tätigkeiten. Beim Training schneiden Schalen, Bewehren und Betonieren in einem Bereich zwischen 16 und 18 % sehr ähnlich ab. Beim Validieren verschlechtern sich alle drei Tätigkeiten, wobei besonders das Bewehren mit einem 38-prozentigen Fehleranteil auffallend hervorsteicht.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	48	12	5	26,15 [%]
2	Bewehren	16	32	4	38,46 [%]
3	Betonieren	5	6	40	21,57 [%]

Tab. 6-43 Subdatensatz 1: Klassifikationsmatrix Validieren

Abbildung 6-19 verkörpert die Auswirkungsanalyse der einzelnen Parameter. Hierbei ist erkennbar, dass die künstliche Intelligenz keine eindeutige Leitvariable identifiziert hat. Die Distanz (16,08 %) liegt zwar an erster Stelle, jedoch dicht gefolgt von der durchschnittlichen Geschwindigkeit (15,67 %) und der Anzahl der Lagerbesuche (15,63 %). Dem Parameter Bauteil wird die geringste Bedeutung (11,39 %) zugemessen.




Abb. 6-19 Subdatensatz 1: Auswirkungsanalyse

### 6.4.2 Modellvalidierung des 10-minütigen Abbruchkriteriums mittels der Testdaten

Für die Überprüfung der Ähnlichkeit zwischen Modellbildung und Wirklichkeit werden alle Netze anhand eines Testdatensatzes beurteilt. Dieser beinhaltet sämtliche Fälle, welche aus der Modellbildung basierend auf dem 10-minütigen Abbruchkriterium stammen.

Um die Testergebnisse besser nachzuvollziehen zu können, wird dieser Datensatz nachfolgend näher beleuchtet. Insgesamt beinhaltet er 4.978 Fälle, wobei die genauere Aufteilung mit Berücksichtigung der einzelnen Tätigkeiten in Tabelle 6-44 ersichtlich ist.

Lfd. Nr.	Tätigkeit	Testfälle
0	A	B
1	Schalen	3.442
2	Bewehren	1.317
3	Betonieren	219
4	Summe	4.978

Tab. 6-44 Testdatensatz 1: Fallanzahl der einzelnen Tätigkeiten

Die Abbildungen 6-20 und 6-21 stellen die Verteilungen der Variablen Distanz, Dauer, Anzahl Lager sowie Wege, durchschnittliche und maximale Geschwindigkeit der Testfälle (gesamter 10-minütiger Datensatz) dar. Ein typisches Merkmal für eine Klassifizierung wie bei Subdatensatz 1 ist nicht zu erkennen, die Überlegenheit der schalungsspezifischen Fälle sticht jedoch hervor.

Die Distanz weist eine Bandbreite beim Schalen von 0 bis 1,02 km, beim Bewehren von 0 bis 1,01 km sowie beim Betonieren von 0 bis 0,74 km auf und die dazugehörigen Mittelwerte betragen 0,20 km, 0,14 km und 0,18 km, wobei sich die Mediane auf 0,16 km, 0,11 km und 0,15 km belaufen. Die Standardabweichungen weisen in selbiger Reihenfolge der Tätigkeiten 0,14 km, 0,12 km und 0,14 km auf.

Die Dauer umspannt beim Schalen eine Bandbreite von 0,78 bis 191,17 min, beim Bewehren von 0,62 bis 199,00 min und beim Betonieren von 0,73 bis 174,23 min. Die dazugehörigen Mittelwerte beziffern sich auf 25,51 min, 27,54 min sowie 31,83 min und die Mediane, welche sich auf 15,97 min, 17,77 min und 22,19 min belaufen, weichen wie bei Subdatensatz 1 deutlich von den Mittelwerten ab. Die Standardabweichungen machen 23,87 min, 25,99 min und 26,73 min aus.

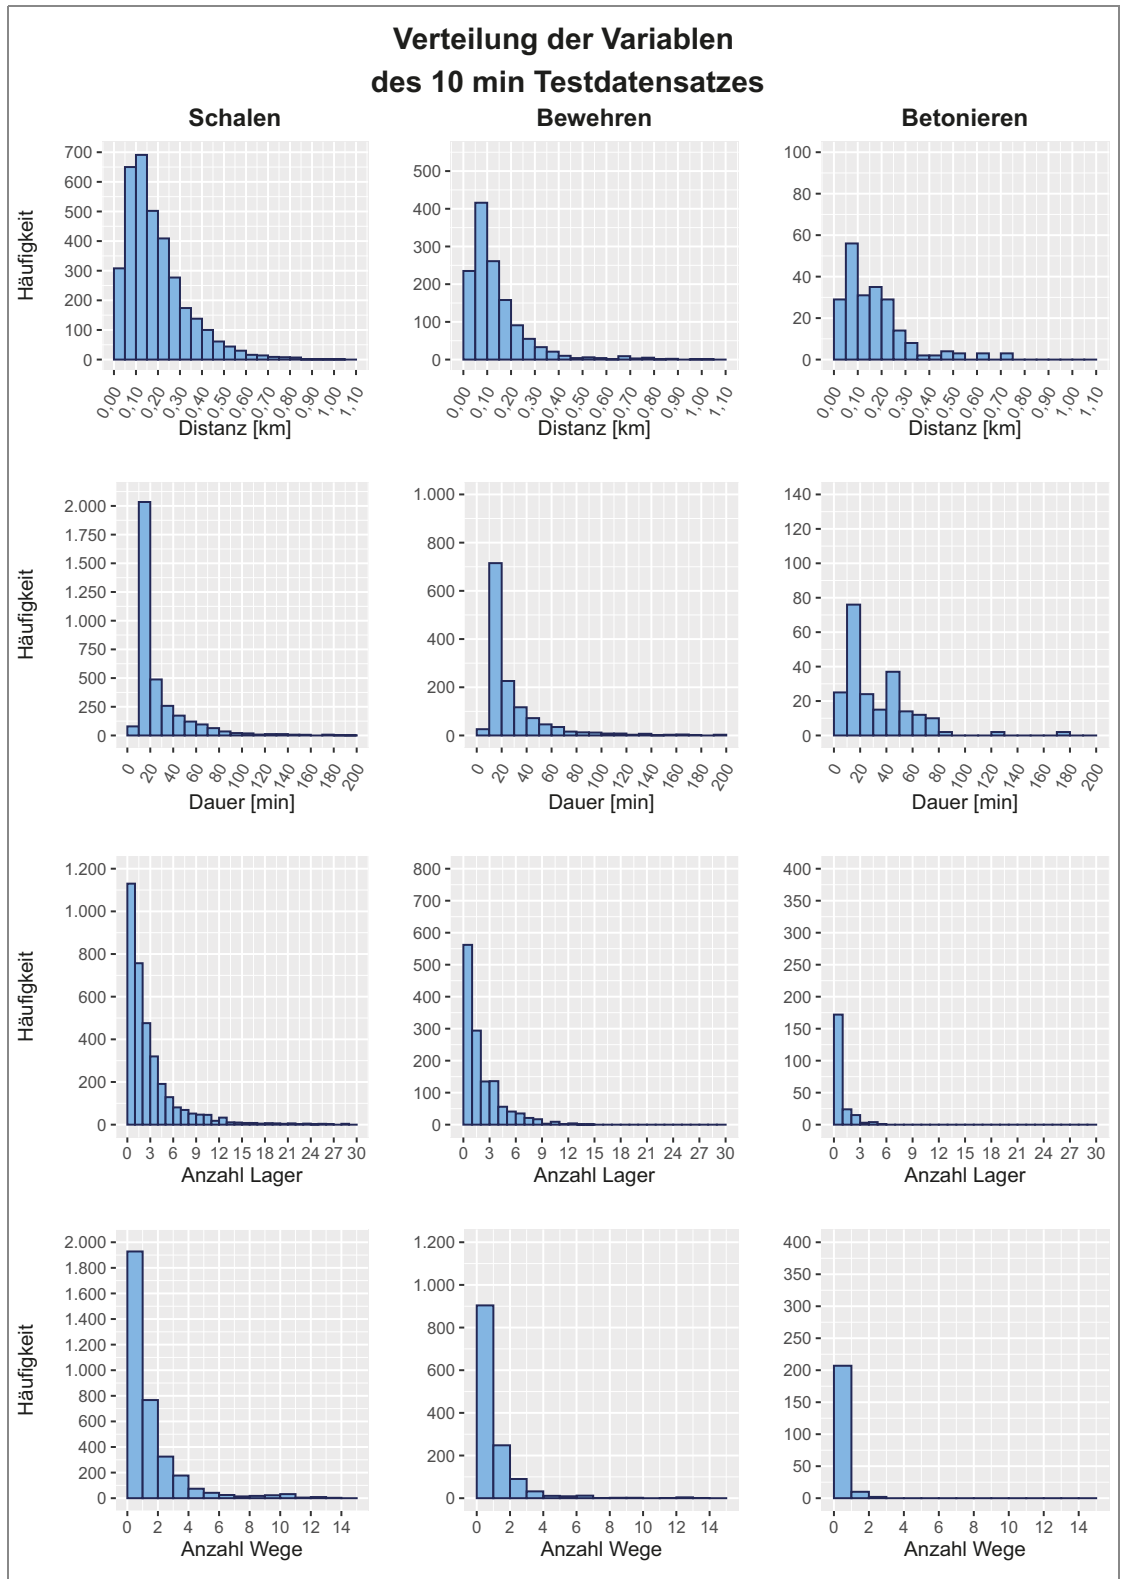
Die Anzahl der Lageraufenthalte liegt beim Schalen zwischen 0 und 47, beim Bewehren zwischen 0 und 15 sowie beim Betonieren zwischen 0 und 6. Die Mittelwerte je Tätigkeit betragen 3,52, 2,58 und 0,91 Betretungen des Lagers. Die Mediane belaufen sich beim Hantieren mit der Schalung und beim Verlegen der Bewehrung auf 2 Lagerbesuche sowie beim Betonieren auf einen, während die Standardabweichungen eine Größe von 3,98, 2,21 und 1,17 aufweisen. Auch bei Betrachtung des gesamten Datensatzes wird ersichtlich, dass vor allem das Aufstellen der Schalung mit vielen Lagerbesuchen verbunden ist.

Die Bandbreite der Anzahl der Wege erstreckt sich beim Schalen sowie beim Bewehren auf 0 bis 14 und beim Einbringen des Betons auf 0 bis 3. Die jeweiligen Mittelwerte belaufen sich auf 1,90, 1,36 und 0,42 Wege, wobei die Mediane 1, 1 und 0 ausmachen. Die dazugehörigen Standardabweichungen betragen 2,00, 1,53 und 0,62 Wege.


Die durchschnittliche Geschwindigkeit liegt beim Schalen und Bewehren in einem Bereich zwischen 0 und 10 km/h, sowie beim Betonieren in einer Bandbreite zwischen 0 und 8 km/h. Die Mittelwerte, welche 4,72 km/h, 4,71 km/h und 4,40 km/h betragen, weichen nur geringfügig von den einzelnen Medianen (4,90 km/h, 4,94 km/h und 4,21 km/h) ab und die dazugehörigen Standardabweichungen belaufen sich auf 1,11 km/h, 1,18 km/h und 1,11 km/h.

Die maximale Geschwindigkeit deckt bei den Schalarbeiten eine Bandbreite von 0 bis 35 km/h, beim Verlegen der Bewehrung von 0 bis 30 km/h und beim Einbringen des Betons von 0 bis 24 km/h ab. Der Mittelwert und der Median

machen beim Schalen 10,18 km/h und 10,00 km/h, beim Bewehren 9,48 km/h und 9 km/h sowie beim Betonieren 9,05 km/h und 8,00 km/h aus. Die Standardabweichungen belaufen sich auf 3,84 km/h, 3,90 km/h und 4,11 km/h.



**Abb. 6-20** Testdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalung, Bewehren und Betonieren



**Abb. 6-21** Testdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren

Um einen Überblick über die gesamte Bandbreite des Testdatensatzes zu geben und damit diese mit der des Subdatensatzes (Tabelle 6-39) verglichen werden kann, wird Tabelle 6-45 angeführt. Die direkte Gegenüberstellung ergibt, dass keine deutliche Diskrepanz innerhalb der jeweiligen Bandbreiten zu erkennen ist. Somit wird das Modell nicht in jenem Wertebereich getestet, in dem das neuronale Netz keine Daten für den Trainingsprozess zur Verfügung hat. Erwähnenswerte kleinere Abweichungen sind nur bei der Geschwindigkeit zu identifizieren. Bei der durchschnittlichen Geschwindigkeit beträgt das Maximum im Subdatensatz 8 km/h und im Testdatensatz 10 km/h, bei der maximalen Geschwindigkeit belaufen sich diese beiden Werte auf 28 km/h und 35 km/h.

Selbiges gilt es auch bei der Verteilung der Bauteile, welche in Tabelle 6-46 gezeigt werden, zu analysieren. Wie vorhin sind auch bei diesem Vergleich mit Tabelle 6-40 keine Abweichungen, welche einen Einfluss auf die Anwendbarkeit des neuronalen Netzes haben, festzustellen.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Anzahl Lager	Anzahl Wege	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[-]	[-]	[km/h]	[km/h]
0	A	B	C	D	E	F	G
1	Minimum	0,00	0,62	0,00	0,00	0,00	0,00
2	Maximum	1,02	199,00	47,00	14,00	10,00	35,00
3	Mittelwert	0,18	26,32	3,16	1,69	4,70	9,94
4	Median	0,15	16,59	2,00	1,00	4,89	9,00
5	Standardabweichung	0,14	24,63	3,56	1,88	1,13	3,85

**Tab. 6-45** Testdatensatz 1: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Bauteil</b>		
2	Bodenplatte	358	7,19 [%]
3	Sockel	837	16,81 [%]
4	Wand	2.488	49,98 [%]
5	Decke	1.004	20,17 [%]
6	Attika	291	5,85 [%]

Tab. 6-46 Testdatensatz 1: Auswertung der Kategorievariablen

Abbildung 6-22 verdeutlicht, dass Variante 4 bei der Überprüfung der Übereinstimmung von Wirklichkeit und Modell mit 38 % am besten abschneidet. Auch das Fehlerminimum der Validierungsfälle (29%) ist bei dieser zu finden.

Weiters ist, wie zu Beginn dieses Abschnitts angemerkt, in Abbildung 6-22 der Einfluss der zufällig ausgewählten Trainings- und Validierungsfälle ersichtlich. Dieser verursacht zwar innerhalb der Validierungsfälle eine Bandbreite von 7 %, das Testdatenergebnis weist jedoch nur eine Schwankungsbreite von 2 % auf, wodurch somit ein geringfügiger Einfluss vorhanden ist.

Bei den prozentuellen Testfehleranteilen (Abbildung 6-23) in Abhängigkeit der einzelnen Tätigkeiten wirkt sich hingegen die Wahl der Trainingsfälle deutlich stärker aus. Die Schularbeiten schwanken hierbei zwischen 19 % und 28 %, das Verlegen der Bewehrung liegt zwischen 38 % und 51 % und das Einbringen des Betons zwischen 37 % und 42 %.





Abb. 6-22 Testdatensatz 1: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze



**Abb. 6-23** Testdatensatz 1: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze

Abschließend veranschaulicht Tabelle 6-47 noch den prozentualen Einfluss der einzelnen Variablen, wobei die Reihung der Einträge auf Basis von Variante 4 geschieht. Erwähnenswert ist hierbei, dass die Distanz, die durchschnittliche Geschwindigkeit und die Anzahl der Lagerbesuche auch bei den übrigen Varianten nahezu immer unter den ersten vier Rängen angeordnet sind. Selbiges gilt auch für die zweite Hälfte der Tabelle. Weiters weist das beste neuronale Netzes (Variante 4) die geringste Einflussbandbreite (11,39-16,08 %) auf. Die maximale Auswirkung des Parameters Anzahl Lager liegt bei 23,03 % und ist bei Variante 1 anzutreffen, welche den größten prozentuellen Fehler bei der Betrachtung der Bewehrungsarbeiten (Abbildung 6-23) innehat.

Lfd. Nr.	Parameter	Variante 4		Variante 1		Variante 2		Variante 3		Variante 5	
		Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung
0	A	B	C	D	E	F	G	H	I	J	K
1	Distanz	1	16,08 [%]	3	16,41 [%]	4	13,40 [%]	1	17,67 [%]	1	20,48 [%]
2	Durchschn. Geschw.	2	15,67 [%]	6	11,06 [%]	2	16,82 [%]	2	15,29 [%]	2	16,69 [%]
3	Anzahl Lager	3	15,63 [%]	1	23,03 [%]	1	18,98 [%]	4	14,33 [%]	3	16,22 [%]
4	Dauer	4	14,45 [%]	5	12,13 [%]	7	11,39 [%]	6	13,17 [%]	7	10,85 [%]
5	Anzahl Wege	5	13,87 [%]	2	17,20 [%]	6	11,47 [%]	3	15,15 [%]	5	11,29 [%]
6	Max. Geschw.	6	12,91 [%]	7	7,41 [%]	3	15,55 [%]	5	13,27 [%]	6	11,26 [%]
7	Bauteil	7	11,39 [%]	4	12,76 [%]	5	12,40 [%]	7	11,12 [%]	4	13,22 [%]

**Tab. 6-47** Subdatensatz 1: Vergleich der Auswirkungsanalyse

### 6.4.3 Subdatensatz mit 20-minütigem Abbruchkriterium

Dem zweiten Subdatensatz liegt das 20-minütige Abbruchkriterium zu Grunde, wodurch die einzelnen Fälle des Basisdatensatzes bis zum Erreichen oder Überschreiten der Verweildauer von 20 Minuten aufsummiert werden. Weil nach dieser Datenaufbereitung die Anzahl der Betonierfälle im Vergleich zu den anderen Tätigkeiten wie auch in den vorherigen Abschnitten sehr gering ausfällt, wählt ein Zufallsgenerator die Einträge für die Schalarbeiten und für die Bewehrungsarbeiten aus. Die Betonierfälle werden zur Gänze übernommen.

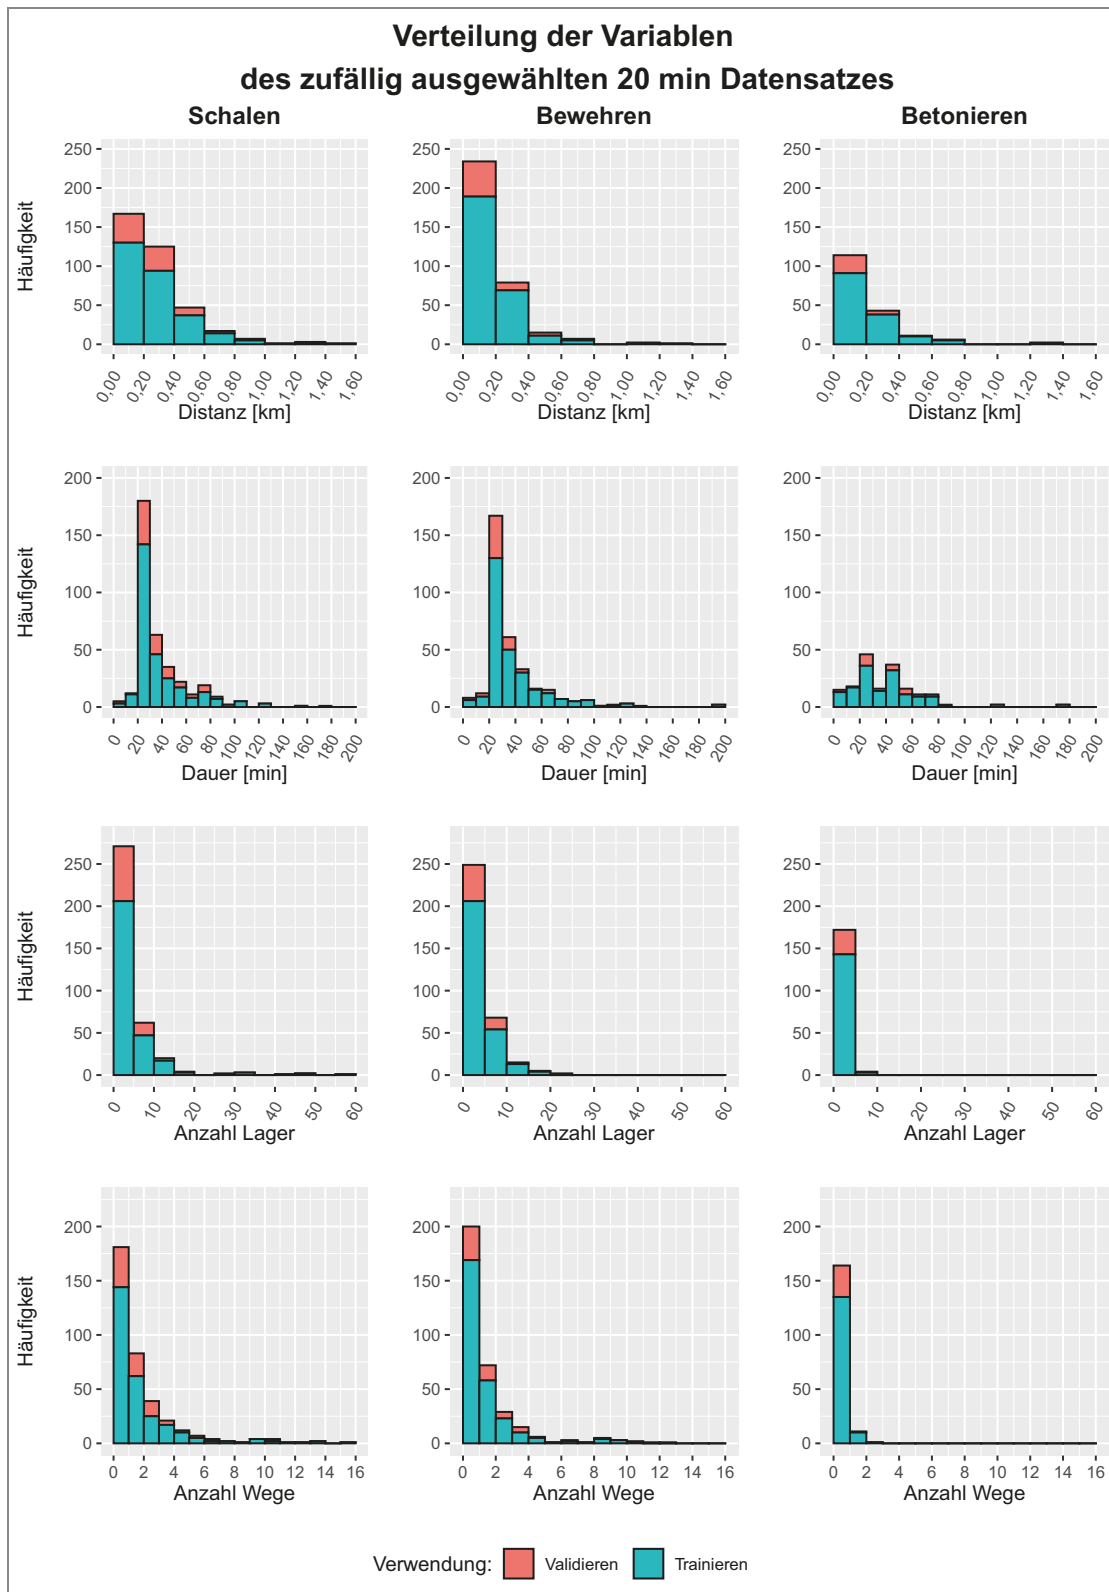
Insgesamt werden aus diesem 883 Fälle großen Subdatensatz fünf Varianten aus unterschiedlichen Trainings- und Validierungsdaten erstellt, welche für die Prognosemodelle herangezogen werden. Tabelle 6-48 fasst nochmals für Variante 5, welche den geringsten Fehlerwert (siehe Abschnitt 6.4.4) aufweist, die Aufteilung der einzelnen Tätigkeiten zusammen. Das Aufstellen der Schalung deckt dabei 42 %, das Verlegen der Bewehrung 38 % und das Einbringen des Betons 20 % der Fälle ab. Im Vergleich zu Subdatensatz 1 ist der Anteil der Betoniertätigkeiten durch die Verdopplung des Abbruchkriteriums von 219 auf 176 Fälle gesunken, was einer 20-prozentigen Reduktion entspricht. Die Aufteilung zwischen Trainings- und Validierungsdaten beträgt bei allen Tätigkeiten 80:20.

Lfd. Nr.	Tätigkeiten	Trainingsfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	283	85	368
2	Bewehren	277	62	339
3	Betonieren	146	30	176
4	Summe	706	177	883

Tab. 6-48 Subdatensatz 2: Fallanzahl der einzelnen Tätigkeiten (Variante 5)


Um die Datenlage der Variablen Distanz, Dauer, Anzahl der Wege, Anzahl der Lagerbesuche sowie durchschnittliche und maximale Geschwindigkeit zu verdeutlichen, zeigen Abbildung 6-24 und Abbildung 6-25 die Verteilung der jeweiligen Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren. Die Trainingsfälle weisen hierbei eine türkise und die Validierungsfälle eine rote Färbung auf. Das Aufsummieren hintereinanderliegender Einträge senkt die Fallanzahl und verschiebt die Häufigkeitsverteilungen nach oben. Eine offensichtliche Abgrenzung der Klassen untereinander ist dabei nicht zu erkennen.

Die von den Arbeitskräften zurückgelegte Distanz schwankt beim Schalen zwischen 0,01 und 1,58 km, beim Bewehren zwischen 0,01 und 1,95 km und beim Betonieren zwischen 0,01 bis 1,35 km, demnach vergrößern sich die einzelnen Bandbreiten im Vergleich zu Subdatensatz 1 um 0,65 km, 1,19 km und 0,61 km. Die Mittelwerte der jeweiligen Tätigkeiten belaufen sich auf 0,28 km, 0,19 km und 0,21 km, wobei die dazugehörigen Mediane mit 0,22 km, 0,13 km und 0,18 km beziffert sind. Die Standardabweichungen betragen in gewohnter Reihenfolge der Tätigkeiten 0,14 km, 0,10 km und 0,14 km. Auch anhand dieser statistischen Kenngrößen ist festzustellen, dass die zurückgelegte Distanz positiv mit der Verweildauer korreliert.



**Abb. 6-24** Subdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalens, Bewehren und Betonieren





**Abb. 6-25** Subdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalens, Bewehren und Betonieren

Die Dauer selbst deckt beim Schalens den Bereich zwischen 2,45 und 178,15 min, beim Bewehren zwischen 0,98 und 196,20 min sowie beim Betonieren zwischen 0,73 bis 174,23 min ab und die dazugehörigen Mittelwerte belaufen sich auf 37,14 min, 36,68 min sowie 38,58 min. Die abgebildete Schiefe der Verteilung zeichnet sich wiederum durch die Abweichung der Mediane, welche 29,01 min, 28,75 min und 37,92 min betragen, vom Mittelwert ab und die jeweiligen Standardabweichungen belaufen sich auf 23,26 min, 24,71 min sowie 26,53 min. Vor allem im Mittelwert und im Median spiegelt sich die Verdopplung des Abbruchkriteriums wieder. Beide Kennwerte steigen im Vergleich zu Subdatensatz 1 deutlich an.

Mit der längeren Aufenthaltsdauer steigt nachvollziehbarer Weise auch die Anzahl der Lagerbesuche. Das Maximum dieser beläuft sich beim Schalens auf 77 (+30 Besuche im Vergleich zum Subdatensatz 1), beim Bewehren auf 25 (+14 Besuche) sowie beim Betonieren auf 7 (+1 Besuch). Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 5,25, 4,19 und 0,98 Lageraufenthalte, während die Mediane beim Schalens und Bewehren 3 Lagerbesuche und beim Betonieren 0 Besuche ausmachen. Die Standardabweichungen beziffern sich auf 8,18, 3,99 sowie 1,48. Bei der Analyse dieses Parameters wird ersichtlich, dass vor allem beim Hantieren mit der Schalung und beim Verlegen der Bewehrung die Lagerbesuche zunehmen, hingegen wirkt sich das 20-minütige Abbruchkriterium beim Betonieren deutlich weniger aus.

Der Maximalwert der Anzahl der Wege beläuft sich beim Schalens auf 26, beim Verlegen der Bewehrung auf 13 und beim Einbringen des Betons auf 3 Wege. Die jeweiligen Mittelwerte betragen 2,51, 1,78 und 0,43 Strecken,

wobei die Mediane die Werte 2, 1 und 0 annehmen und die Standardabweichungen 3,41, 2,1 und 0,64 Wege ausmachen. Bei diesen Variablen ist festzuhalten, dass die Erhöhung von 10 auf 20 Minuten nur zu einem geringfügigen Anstieg der Anzahl der Wege führt.

Die durchschnittliche Geschwindigkeit weist beim Schalen eine Bandbreite zwischen 1,00 und 7,88 km/h, beim Bewehren zwischen 1,00 und 8,29 km/h sowie beim Betonieren zwischen 0 und 8,00 km/h auf. Die Mittelwerte, welche 4,63 km/h, 4,64 km/h und 4,34 km/h ausmachen, weichen nur geringfügig von den einzelnen Medianen (4,62 km/h, 4,69 km/h und 4,04 km/h) ab. Die dazugehörigen Standardabweichungen betragen 0,97 km/h, 1,02 km/h und 1,10 km/h.

Die maximale Geschwindigkeit reicht beim Hantieren mit der Schalung über eine Bandbreite von 1 bis 30 km/h, beim Verlegen der Bewehrung von 0 bis 30 km/h und beim Einbringen des Betons von 0 bis 24 km/h. Der Mittelwert und der Median belaufen sich beim Schalen auf 10,76 km/h und 10,00 km/h, beim Bewehren auf 9,83 km/h und 9 km/h sowie beim Betonieren auf 9,05 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen betragen 4,21 km/h, 3,96 km/h und 3,84 km/h. Bei beiden Geschwindigkeiten zeigt sich, dass kein bemerkenswerter Unterschied zu Subdatensatz 1 vorliegt.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Anzahl Lager	Anzahl Wege	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[-]	[-]	[km/h]	[km/h]
0	A	B	C	D	E	F	G
1	Minimum	0,01	0,73	0,00	0,00	0,00	0,00
2	Maximum	1,95	196,20	77,00	26,00	8,29	30,00
3	Mittelwert	0,23	37,25	3,99	1,82	4,58	10,06
4	Median	0,18	29,43	2,00	1,00	4,57	9,00
5	Standardabweichung	0,21	24,51	6,08	2,68	1,02	4,10

Tab. 6-49 Subdatensatz 2: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Bauteil</b>		
2	Bodenplatte	96	10,87 [%]
3	Sockel	174	19,71 [%]
4	Wand	435	49,26 [%]
5	Decke	114	12,91 [%]
6	Attika	64	7,25 [%]

Tab. 6-50 Subdatensatz 2: Auswertung der Kategorievariablen

Einen Überblick über die Bandbreite des gesamten zweiten Subdatensatzes veranschaulicht Tabelle 6-49. Dabei ist zu erkennen, dass vor allem bei der Dauer der Mittelwert vom Median stark abweicht. Im Vergleich zu Subdatensatz 1 liegen speziell bei der Distanz, der Dauer und der Anzahl der Lagerbesuche deutliche Erhöhungen der Werte vor, während die Geschwindigkeiten nahezu unverändert bleiben.

Um neben den numerischen Parametern auch die unterschiedlichen Bauteiltypen zu analysieren, fasst Tabelle 6-50 die Verteilung innerhalb dieser

zusammen. Mit 49 % kommen dabei die Wände am häufigsten vor, wobei die Attika mit 7 % das Schlusslicht bildet. Der Sockel mit 20 %, die Decke mit 13 % und die Bodenplatte mit 11 % liegen dazwischen.

Nach der Datensatzanalyse folgt die auf künstlicher Intelligenz basierende Modellbildung, welche alle sieben soeben vorgestellten Parameter berücksichtigt. Hierfür werden zunächst wieder die Trainings- und Validierungsfälle im Verhältnis von 80:20 aufgeteilt. Um den Einfluss der zu Beginn festgelegten Trainingsdaten besser beurteilen zu können, wird abermals der gesamte Prozess fünf Mal durchgeführt. Daraufhin werden für jede der fünf Varianten 29 neuronale Netze, welche zwischen 2 und 30 Hidden-Neuronen aufweisen, trainiert und anhand der Validierungsdaten das Beste ausgewählt.

Hierbei erzielt Variante 5 mit einem neuronalen Netz, welches 23 Hidden-Neuronen beinhaltet und beim Beurteilen der 177 Validierungsfälle einen Fehleranteil von 33 % aufweist, das beste Resultat. Die nachfolgende Tabelle 6-51 fasst die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle zusammen.

<b>Bestes Netz: 23 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	706
Falsche Prognosen	18,70 [%]
<b>Validieren</b>	
Anzahl Fälle	177
Falsche Prognosen	32,77 [%]

Tab. 6-51 Subdatensatz 2: Bestes Netz

Die Tabellen 6-52 und 6-53 verdeutlichen die Aufteilung der falschen Vorhersagen unter Berücksichtigung der einzelnen Tätigkeiten. Beim Training schneiden Schalen und Bewehren im Bereich zwischen 15 und 18 % sehr ähnlich ab, lediglich Betonieren liegt bei 26,03 %. Beim Validieren verschlechtern sich alle drei Tätigkeiten, wobei besonders Bewehren mit einem Anteil falscher Prognosen von 39 % und Betonieren von 40 % auffallen.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	239	39	5	15,55 [%]
2	Bewehren	38	227	12	18,05 [%]
3	Betonieren	22	16	108	26,03 [%]

Tab. 6-52 Subdatensatz 2: Klassifikationsmatrix Trainieren

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	63	19	3	25,88 [%]
2	Bewehren	21	38	3	38,71 [%]
3	Betonieren	8	4	18	40,00 [%]

Tab. 6-53 Subdatensatz 2: Klassifikationsmatrix Validieren

Abbildung 6-26 stellt die Auswirkungsanalyse der einzelnen Parameter dar. Hierbei befindet sich die Distanz mit 18,18 % auf Platz eins. Mit rund 3 % Rückstand liegt die Anzahl der Lagerbesuche auf Platz 2, dicht gefolgt von der maximalen und durchschnittlichen Geschwindigkeit (14,86 %, 13,65 %). Dem Parameter Bauteil wird abermals die geringste Bedeutung (12,13 %) zuteil.




Abb. 6-26 Subdatensatz 2: Auswirkungsanalyse

#### 6.4.4 Modellvalidierung des 20-minütigen Abbruchkriteriums mittels der Testdaten

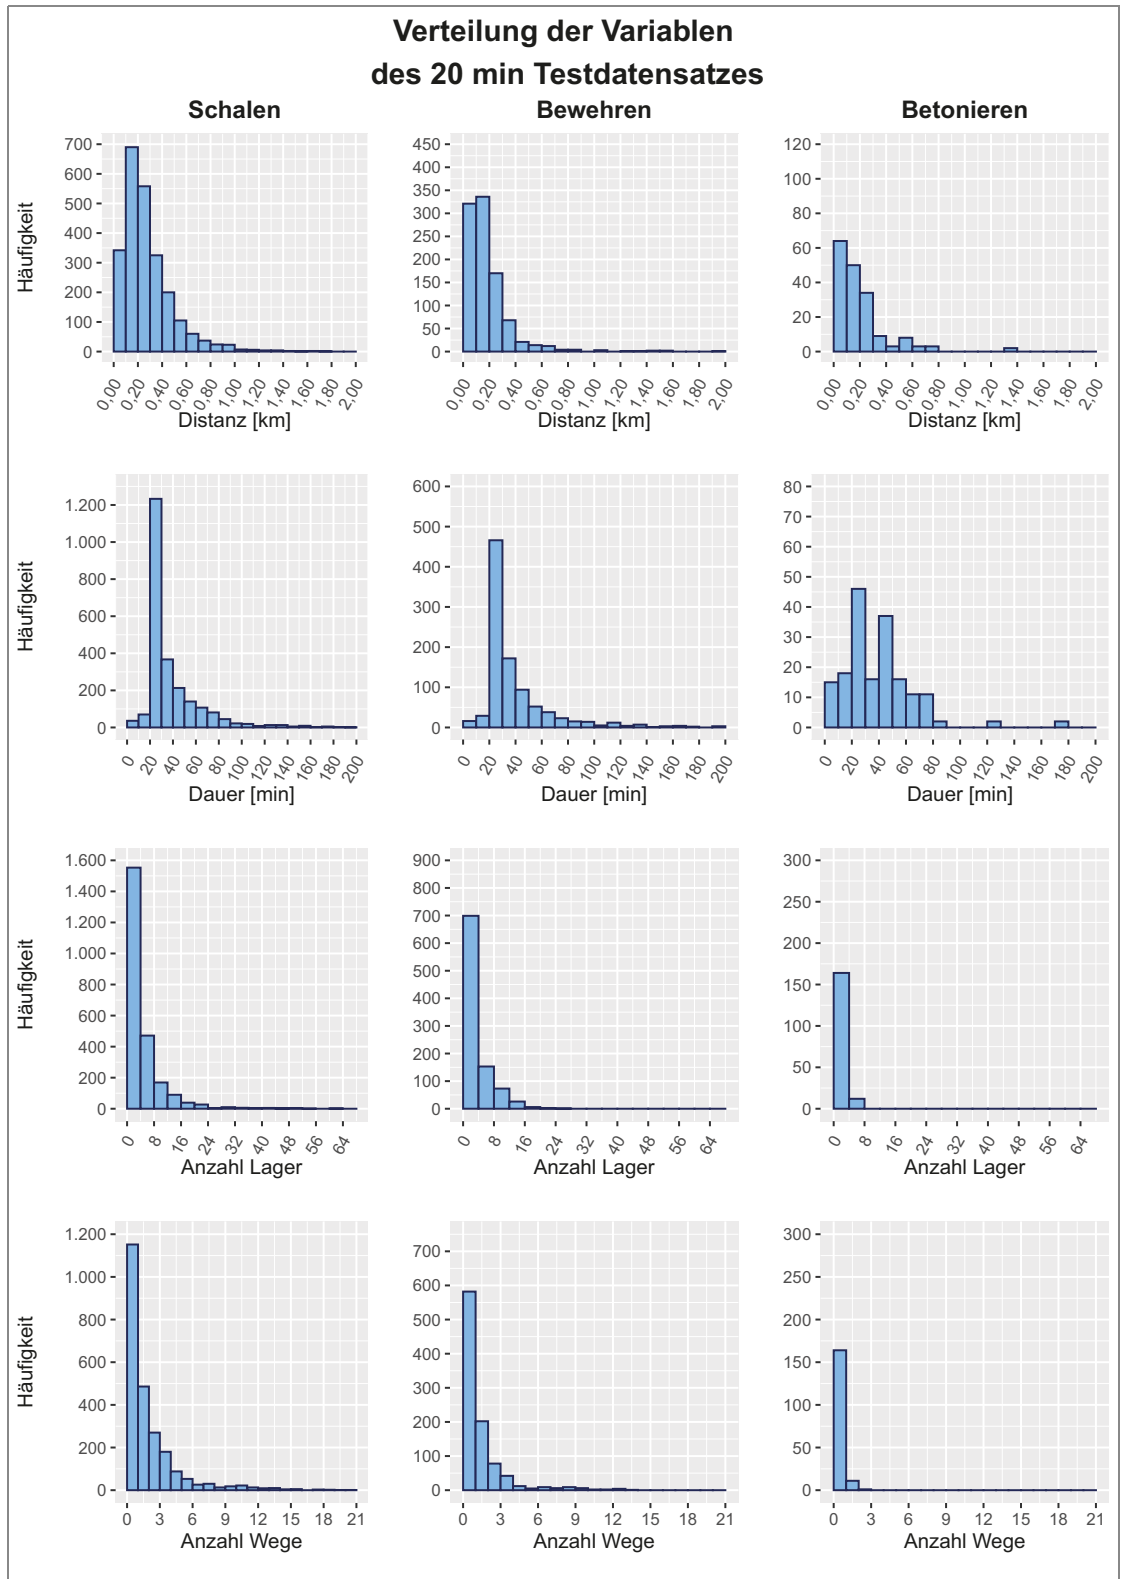
Um die Modelle auf deren Übereinstimmung mit der Wirklichkeit zu prüfen, gilt es, die erlernten Zusammenhänge der neuronalen Netze anhand von Testdaten zu beurteilen. Diese beinhalten alle Fälle, welche aus der mit dem 20-minütigen Abbruchkriterium versehenen Datenaufbereitung resultieren. Die genauere Aufteilung unter Berücksichtigung der einzelnen Tätigkeiten wird in Tabelle 6-54 veranschaulicht. Im Vergleich zu Testdatensatz 1 reduziert sich die Anzahl beim Schalen um fast 40 %, beim Bewehren um rund 27 % und beim Betonieren um ca. 20 %.

Lfd. Nr.	Tätigkeit	Testfälle
0	A	B
1	Schalen	2.391
2	Bewehren	960
3	Betonieren	176
4	Summe	3.527


Tab. 6-54 Testdatensatz 2: Fallanzahl der einzelnen Tätigkeiten

Abbildung 6-27 verkörpert die Verteilungen der Variablen Distanz, Dauer, Anzahl Lager sowie Wege und Abbildung 6-28 die durchschnittliche sowie maximale Geschwindigkeit der Testfälle (gesamter 20-minütiger Datensatz). Ein klassentypisches Merkmal ist wie bei den vorherigen Datensätzen nicht

zu erkennen. Weiters sind die schalungsspezifischen Fälle den anderen Tätigkeiten immer noch überlegen, jedoch ist deren Dominanz durch die Datenaufbereitung gesunken.



**Abb. 6-27** Testdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalens, Bewehren und Betonieren



**Abb. 6-28** Testdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren

Die Distanz erstreckt sich beim Schalen über einen Wertebereich von 0 bis 1,79 km (+0,77 km im Vergleich zu Testdatensatz 1), beim Bewehren von 0 bis 1,95 km (+0,94 km) und beim Betonieren von 0 bis 1,35 km (+0,61 km). Die gleichgereihten Mittelwerte belaufen sich auf 0,28 km, 0,19 km und 0,21 km, wobei die Mediane 0,23 km, 0,14 km und 0,18 km betragen. Die Standardabweichungen beziffern sich auf 0,21 km, 0,18 km und 0,20 km. Anhand dieser statistischen Kennwerte ist erkennbar, dass durch die Erhöhung des Abbruchkriteriums größere Distanzen angesammelt werden. Jedoch geht mit diesem Effekt auch eine Erhöhung der Streuung innerhalb der Variablen einher.

Die Dauer liegt beim Schalen zwischen 0,78 und 191,17 min, beim Bewehren zwischen 0,62 und 199,00 min sowie beim Betonieren zwischen 0,73 und 174,23 min. Die dazugehörigen Mittelwerte belaufen sich auf 37,15 min, 38,54 min und 38,58 min. Die Mediane machen 27,66 min, 28,85 min und 37,92 min aus und die Standardabweichungen betragen 25,02 min, 27,21 min und 26,53 min. Die Auswirkungen der Abbruchkriteriumsverdopplung sind beim Mittelwert und beim Median deutlich zu erkennen. Beide statistischen Kennwerte weisen eine Erhöhung von rund 10 Minuten im Vergleich zu Testdatensatz 1 auf.

Die maximale Anzahl der Lageraufenthalte liegt beim Schalen bei 83 Besuchen (+36 Lagerbesuche im Vergleich zu Testdatensatz 1), beim Bewehren bei 25 (+10) sowie beim Betonieren bei 7 (+1). Die Mittelwerte belaufen sich unter Berücksichtigung der einzelnen Tätigkeiten in gewohnter Reihenfolge auf 5,12, 3,82 und 0,98 Aufenthalte und die Mediane betragen

beim Schalen und Bewehren 3 sowie beim Betonieren 0 Lagerbesuche. Die Standardabweichungen machen 6,70, 3,61 und 1,48 aus.

Das Spektrum der Anzahl der Wege liegt beim Schalen zwischen 0 und 26 (+12 Wege im Vergleich zu Testdatensatz 1), beim Verlegen der Bewehrung zwischen 0 und 14 (+0) und beim Einbringen des Betons zwischen 0 und 3. Die jeweiligen Mittelwerte belaufen sich auf 2,45, 1,68 und 0,43 Strecken, wobei die Mediane 2, 1 und 0 ausmachen und die Standardabweichung 2,87, 2,00 und 0,64 beträgt. Die deutlichste Änderung ist bei der Tätigkeit Schalen zu identifizieren. Neben dem gestiegenen Maximalwert erhöhen sich durch die Verwendung des 20-minütigen Abbruchkriteriums auch der dazugehörige Mittelwert und der Median.

Die durchschnittliche Geschwindigkeit erstreckt sich beim Schalen über einen Bereich von 0 und 10 km/h, beim Bewehren von 0 und 9 km/h und beim Betonieren von 0 und 8 km/h. Die Mittelwerte, welche 4,65 km/h, 4,69 km/h und 4,34 km/h ausmachen, weisen nur geringfügige Abweichungen zu den einzelnen Medianen (4,70 km/h, 4,84 km/h und 4,04 km/h) auf und die dazugehörigen Standardabweichungen betragen 1,00 km/h, 1,06 km/h und 1,10 km/h. Werden diese Kennwerte jenen aus Testdatensatz 1 gegenübergestellt, liegen keine bedeutenden Abweichungen vor. Daraus ergibt sich, dass die Erhöhung des Abbruchkriteriums keinen Einfluss auf die durchschnittliche Geschwindigkeit hat.

Die Bandbreite der maximalen Geschwindigkeit liegt beim Schalen zwischen 0 und 35 km/h, beim Verlegen der Bewehrung zwischen 0 und 30 km/h sowie beim Einbringen des Betons zwischen 0 und 24 km/h. Der Mittelwert und der Median betragen beim Schalen 10,74 km/h und 10,00 km/h, beim Bewehren 9,94 km/h und 9,00 km/h sowie beim Betonieren 9,02 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 3,96 km/h, 3,86 km/h und 3,84 km/h. Auch bei der maximalen Geschwindigkeit bewirkt die 20-minütige Datenaufbereitung keine bedeutende Änderung.

Um die Beschreibung des zweiten Testdatensatzes abzuschließen, wird nachfolgend in Tabelle 6-55 ein Überblick über dessen deskriptive Statistik und in Tabelle 6-56 die Verteilung der Bauteiltypen gezeigt. Im Abgleich mit Subdatensatz 2 (Tabelle 6-49) lassen sich keine bedenklichen Bereiche identifizieren, in denen die Maximalwerte der einzelnen Parameter weit voneinander abweichen. Wird diese deskriptive Statistik jener aus Tabelle 6-45, welche den Testdatensatz 1 beschreibt, gegenübergestellt, so zeigt sich, dass die Distanz, die Dauer, die Anzahl der Lagerbesuche sowie der Wege zugenommen haben. Hierbei sticht vor allem die Erhöhung des Maximums der Lagerbesuche von 47 auf 83 ins Auge. Der relative Anteil der einzelnen Bauteiltypen ist sowohl mit jenen aus Tabelle 6-46 (Testdatensatz 1) als auch mit jenen aus 6-50 (Subdatensatz 2) vergleichbar.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Anzahl Lager	Anzahl Wege	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[-]	[-]	[km/h]	[km/h]
0	A	B	C	D	E	F	G
1	Minimum	0,00	0,62	0,00	0,00	0,00	0,00
2	Maximum	1,95	199,00	83,00	26,00	10,00	35,00
3	Mittelwert	0,25	37,60	4,56	2,14	4,64	10,44
4	Median	0,20	28,20	3,00	1,00	4,70	10,00
5	Standardabweichung	0,21	25,72	5,93	2,64	1,03	3,96

Tab. 6-55 Testdatensatz 2: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Bauteil</b>		
2	Bodenplatte	250	7,09 [%]
3	Sockel	652	18,49 [%]
4	Wand	1.736	49,22 [%]
5	Decke	648	18,37 [%]
6	Attika	241	6,83 [%]

Tab. 6-56 Testdatensatz 2: Auswertung der Kategorievariablen

Der Vergleich der Testdatenfehler untereinander (Abbildungen 6-29) unter Berücksichtigung der tätigkeitsspezifischen Unterschiede (Abbildung 6-30) ergibt, dass Variante 5 die Wirklichkeit am besten abbildet. Auf den ersten Blick möge hierbei Variante 2 als die geeignetste erscheinen, doch bei genauerer Analyse der falschen Vorhersagen wird deutlich, dass Variante 5 zu bevorzugen ist.




Abb. 6-29 Testdatensatz 2: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze






Abb. 6-30 Testdatensatz 2: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze

Bei der Beurteilung des Einflusses der zufällig ausgewählten Trainings- und Validierungsfälle von Subdatensatz 2 ist festzuhalten, dass beim 20-minütigen Abbruchkriterium die Schwankungsbreite der Testdaten zwischen 34 und 42 % liegt und jene der Validierungsfälle sich über eine Bandbreite von 31 und 36 % erstreckt. Somit ist bei diesen fünf Varianten der Einfluss der ausgewählten Trainings- und Validierungsdaten größer als jener bei Testdatensatz 1.

Als Abschluss dieser Analyse zeigt Tabelle 6-57 den prozentualen Einfluss der einzelnen Variablen, wobei die Reihung der Einträge auf Basis des Modells von Variante 5 geschieht. Das beste neuronale Netz identifiziert hierbei die zurückgelegte Distanz mit 18,18 % als Leitvariable. An zweiter Stelle ist die Anzahl der Lagerbesuche mit 15,24 % vorzufinden und auch die übrigen Varianten weisen diesen zwei Parametern eine sehr hohe Bedeutung zu. Weiters wird ersichtlich, dass diese Sensitivitätsanalyse ebenfalls wie beim Ergebnis von Testdatensatz 1 (Tabelle 6-47) an erster Stelle die Distanz und an letzter Stelle das Bauteil sieht.

Lfd. Nr.	Parameter	Variante 5		Variante 1		Variante 2		Variante 3		Variante 4	
		Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung
0	A	B	C	D	E	F	G	H	I	J	K
1	Distanz	1	18,18 [%]	2	16,38 [%]	2	16,19 [%]	2	15,78 [%]	1	17,55 [%]
2	Anzahl Lager	2	15,24 [%]	1	17,53 [%]	1	20,08 [%]	1	16,77 [%]	3	14,85 [%]
3	Max. Geschw.	3	14,86 [%]	4	14,47 [%]	5	11,81 [%]	3	14,80 [%]	5	13,37 [%]
4	Durchschn. Geschw.	4	13,68 [%]	3	14,72 [%]	7	10,30 [%]	4	14,42 [%]	2	15,63 [%]
5	Dauer	5	13,65 [%]	7	11,70 [%]	3	15,43 [%]	6	12,90 [%]	4	13,65 [%]
6	Anzahl Wege	6	12,25 [%]	6	11,70 [%]	6	11,70 [%]	5	13,54 [%]	6	12,67 [%]
7	Bauteil	7	12,13 [%]	5	13,49 [%]	4	14,50 [%]	7	11,79 [%]	7	12,27 [%]

Tab. 6-57 Subdatensatz 2: Vergleich der Auswirkungsanalyse

### 6.4.5 Subdatensatz mit 30-minütigem Abbruchkriterium

Abschließend wird noch ein dritter Subdatensatz vorgestellt, um den Einfluss des 30-minütigen Abbruchkriteriums zu analysieren. Dieser weist 612 Zeilen auf, wobei die Schal- und Bewehrungsfälle wieder zufällig ausgewählt und die Betonierfälle zur Gänze übernommen wurden. Wie bei den vorherigen Abschnitten bildet der zusammengestellte Datensatz die Grundlage für fünf Varianten, welche sich jeweils in den ausgewählten Trainings- und Validierungsdaten unterscheiden. Tabelle 6-58 zeigt für Variante 2, welche den geringsten Fehlerwert innerhalb der fünf Varianten (siehe Abschnitt 6.4.6) besitzt, die Aufteilung der einzelnen Tätigkeiten. Das Aufstellen der Schalung umfasst mit 220 Fällen 36 %, das Verlegen der Bewehrung mit 237 Fällen 39 % und das Einbringen des Betons mit 155 Fällen 25 % des Datensatzes. Die Aufteilung zwischen Trainings- und Validierungsdaten beträgt bei allen Tätigkeiten rund 80:20. Im Vergleich zum vorherigen Subdatensatz 2 (Tabelle 6-48) lässt sich erkennen, dass die 50-prozentige Erhöhung des Abbruchkriteriums – von 20 auf 30 Minuten – zu einer Reduktion der Betonierfälle von 12 % führt.

Lfd. Nr.	Tätigkeiten	Trainingsfälle	Validierungsfälle	Gesamt
0	A	B	C	D
1	Schalen	172	48	220
2	Bewehren	189	48	237
3	Betonieren	129	26	155
4	Summe	490	122	612

Tab. 6-58 Subdatensatz 3: Fallanzahl der einzelnen Tätigkeiten (Variante 2)

Um einen Einblick in den Datensatz, welcher die Inputparameter Distanz, Dauer, Anzahl der Wege, Anzahl der Lagerbesuche, durchschnittliche und maximale Geschwindigkeit sowie die Art des Bauteils beinhaltet, zu bekommen, zeigen Abbildung 6-31 und 6-32 die Verteilungen der jeweiligen Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren. Die Trainingsfälle sind hierbei türkis und die Validierungsfälle rot eingefärbt.

Bei der Distanz ist der größte Einfluss der Datenaufbereitung zu erkennen. Mit der Zunahme des Abbruchkriteriums reduzieren sich die Verteilungsspitzen innerhalb der Histogramme im Bereich zwischen 0 und 0,22 km deutlich, eine offensichtliche Abgrenzung der Klassen untereinander ergibt sich jedoch nicht.

Die Maximalwerte der Distanz, welche die Arbeitskräfte im Geofence zurücklegen, beträgt beim Schalen 1,21 km, beim Bewehren 1,92 km und beim Betonieren 1,47 km. Die Mittelwerte der jeweiligen Tätigkeiten belaufen sich auf 0,35 km, 0,24 km und 0,23 km, wobei die dazugehörigen Mediane 0,30 km, 0,18 km und 0,18 km ausmachen. Die Standardabweichungen weisen in gewohnter Reihenfolge der Tätigkeiten 0,25 km, 0,20 km und 0,21 km auf. Im Vergleich zu Subdatensatz 2, bei dem sich die Maximalwerte in gewohnter Reihenfolge auf 1,58 km, 1,95 km und 1,35 km belaufen, ist festzustellen, dass sich die Bandbreite vor allem beim Schalen reduziert, die Mittelwerte und Mediane jedoch steigen. Somit ist diese Reduktion auf die zufallsbedingte Auswahl der Fälle zurückzuführen und der Trend, dass bei längeren Verweildauern größere Distanzen zurückgelegt werden, ist deutlich zu erkennen.

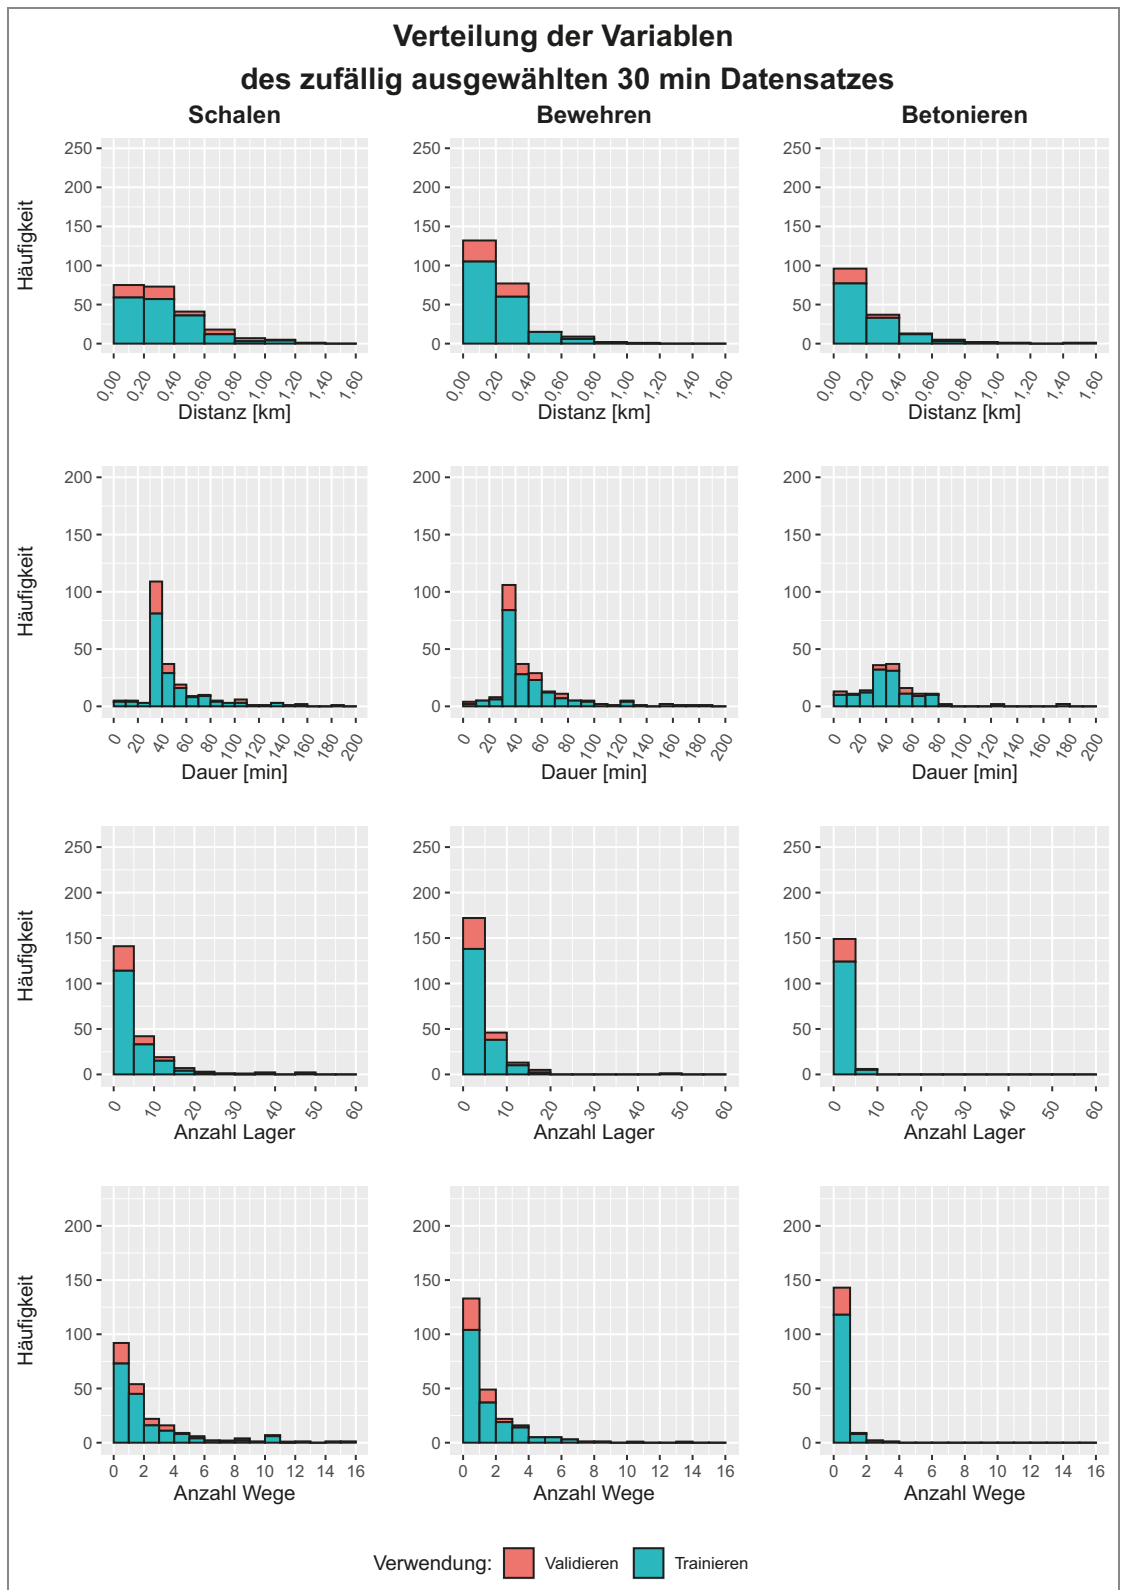



Abb. 6-31 Subdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalung, Bewehrung und Betonieren



**Abb. 6-32** Subdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren

Die Verweildauer im Geofence erstreckt sich beim Schalen über einen Bereich von 5,15 bis 183,55 min, beim Bewehren von 6,64 bis 180,62 min und beim Betonieren von 0,73 bis 174,23 min. Die dazugehörigen Mittelwerte betragen 47,42 min, 49,19 min und 42,57 min, wobei sich die Mediane auf 37,41 min, 39,66 min und 41,23 min belaufen. Die jeweiligen Standardabweichungen machen 27,51 min, 28,45 min und 26,23 min aus. Bei diesem Parameter ist festzustellen, dass sich Subdatensatz 2 und Subdatensatz 3 deutlich in den gestiegenen Mittelwerten und Medianen unterscheiden.

Die Anzahl der Lagerbesuche während des Aufenthalts im Geofence liegt beim Schalen zwischen 0 und 94 (+17 Besuche im Vergleich zum Subdatensatz 2), beim Bewehren zwischen 0 und 47 (+27 Besuche) sowie beim Betonieren zwischen 0 und 10 (+3 Besuche). Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 6,77, 4,44 sowie 1,11 Besuche und die Mediane belaufen sich beim Schalen auf 4, beim Bewehren auf 3 und beim Betonieren auf einen Lagerbesuch. Die Standardabweichungen weisen eine Größe von 10,59, 4,57 sowie 1,74 Lageraufenthalten auf. Bei der Analyse dieses Parameters wird ersichtlich, dass die Anzahl der Lagerbesuche – verglichen mit Subdatensatz 2 – steigt, wobei das Aufstellen der Schalung mit den meisten Besuchen, gefolgt von der Tätigkeit Bewehren, verbunden ist.

Die Bandbreite bei der Anzahl der Wege erstreckt sich beim Schalen auf 0 bis 17, beim Verlegen der Bewehrung auf 0 bis 14 und beim Einbringen des Betons auf 0 bis 4. Die jeweiligen Mittelwerte betragen 2,73, 1,80 und 0,46 Wege, wobei sich die Mediane mit 2, 1 und 0 beziffern. Die Standardabweichungen

chungen machen 3,10, 1,93 und 0,72 Wege aus. Vergleichend mit Subdatensatz 2 ist festzustellen, dass es bei diesem Parameter zu keinen bedeutenden Abweichungen kommt.

Die durchschnittliche Geschwindigkeit verläuft beim Schalen zwischen 0 und 7,85 km/h, beim Bewehren zwischen 1,28 und 8,31 km/h sowie beim Betonieren zwischen 0 und 8 km/h. Die Mittelwerte, welche 4,59 km/h, 4,59 km/h und 4,33 km/h ausmachen, weichen nur geringfügig von den einzelnen Medianen (4,63 km/h, 4,71 km/h und 4,02 km/h) ab und die dazugehörigen Standardabweichungen betragen jeweils 0,95 km/h, 1,05 km/h und 1,07 km/h. Beim Vergleich dieses Parameters ist kein signifikanter Unterschied zu Subdatensatz 2 festzustellen.

Die maximale Geschwindigkeit erstreckt sich beim Aufstellen der Schalung über eine Bandbreite von 0 bis 28 km/h, beim Verlegen der Bewehrung von 3 bis 30 km/h und beim Einbringen des Betons von 0 bis 24 km/h. Der Mittelwert und der Median beziffern sich beim Schalen auf 10,94 km/h und 11,00 km/h, beim Bewehren auf 10,28 km/h und 10 km/h sowie beim Betonieren auf 9,15 km/h und 8,00 km/h und die dazugehörigen Standardabweichungen belaufen sich auf 3,88 km/h, 4,12 km/h und 3,88 km/h. Auch bei dieser Variablen ist keine merkwürdige Abweichung zu Subdatensatz 2 zu verzeichnen.

Um einen Überblick über die Bandbreite des gesamten Subdatensatzes 3 zu geben, wird Tabelle 6-59 angeführt. Es ist zu erkennen, dass sich vor allem bei der Dauer der Mittelwert vom Median unterscheidet. Diese Abweichung ist auch schon bei Subdatensatz 2 zu erkennen und hat sich nicht geändert. Ein weiterer Unterschied der beiden Datensätze liegt in den merklich gestiegenen Mittelwerten von Distanz, Dauer und Anzahl der Lagerbesuche.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Anzahl Lager	Anzahl Wege	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[-]	[-]	[km/h]	[km/h]
0	A	B	C	D	E	F	G
1	Minimum	0,00	0,73	0,00	0,00	0,00	0,00
2	Maximum	1,92	183,55	94,00	17,00	8,31	30,00
3	Mittelwert	0,28	46,88	4,44	1,79	4,52	10,23
4	Median	0,21	39,41	2,00	1,00	4,49	9,50
5	Standardabweichung	0,23	27,69	7,35	2,40	1,03	4,03

Tab. 6-59 Subdatensatz 3: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Bauteil</b>		
2	Bodenplatte	45	7,35 [%]
3	Sockel	132	21,57 [%]
4	Wand	317	51,80 [%]
5	Decke	81	13,24 [%]
6	Attika	37	6,05 [%]

Tab. 6-60 Subdatensatz 3: Auswertung der Kategorievvariablen

Neben den numerischen Parametern werden auch die unterschiedlichen Bauteiltypen analysiert. Tabelle 6-60 fasst die Verteilung innerhalb dieser

zusammen. Mit 52 % überwiegen die Wände deutlich, wobei der Sockel mit 22 %, die Decke mit 13 % und die Bodenplatte mit 7 % im Mittelfeld liegen. Die Attika hingegen ist nur mit 6 % vertreten. Eine bedeutende Abweichung zu den vorherigen Subdatensätzen (Tabelle 6-40 und Tabelle 6-50) ist nicht zu erkennen.

Der soeben vorgestellte Datensatz wird nachfolgend als Basis für die Modellbildung herangezogen. Hierbei werden zunächst die Trainings- und Validierungsfälle im Verhältnis von 80:20 aufgeteilt und anschließend die künstliche Intelligenz darauf trainiert und validiert. Wie bei den vorherigen Modellen beinhalten die neuronalen Netze zwischen 2 und 30 Hidden-Neuronen in einem Layer. Damit der Einfluss der zu Beginn festgelegten Trainingsdaten besser beurteilt werden kann, wird der gesamte Prozess insgesamt fünf Mal durchgeführt und die Ergebnisse der einzelnen Varianten einander gegenübergestellt.

Hierbei erzielt Variante 2 mit einem neuronalen Netz, welches 7 Hidden-Neuronen und beim Validieren einen Fehleranteil von 31 % aufweist, das beste Resultat. Die nachfolgende Tabelle 6-61 fasst die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle zusammen.

<b>Bestes Netz: 7 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	490
Falsche Prognosen	24,08 [%]
<b>Validieren</b>	
Anzahl Fälle	122
Falsche Prognosen	31,15 [%]

Tab. 6-61 Subdatensatz 3: Bestes Netz

Die Tabellen 6-62 und 6-63 beinhalten die Aufteilung der falschen Vorhersagen unter Berücksichtigung der einzelnen Tätigkeiten. Beim Training schneiden Schalen und Betonieren mit 18,6 und 19,19 % sehr ähnlich ab, Bewehren erzielt jedoch hierbei bereits einen Anteil falscher Prognosen von 32,28 %. Beim Validieren verschlechtern sich alle drei Tätigkeiten, wobei besonders der Fehler beim Betonieren um 16 % steigt.

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	139	26	7	19,19 [%]
2	Bewehren	55	128	6	32,28 [%]
3	Betonieren	18	6	105	18,60 [%]

Tab. 6-62 Subdatensatz 3: Klassifikationsmatrix Trainieren

Lfd. Nr.	Richtige Klasse	Vorhersagen			Anteil falscher Prognosen
		Schalen	Bewehren	Betonieren	
0	A	B	C	D	E
1	Schalen	37	10	1	22,92 [%]
2	Bewehren	16	30	2	37,50 [%]
3	Betonieren	4	5	17	34,62 [%]

Tab. 6-63 Subdatensatz 3: Klassifikationsmatrix Validieren

Abbildung 6-33 verkörpert die Auswirkungsanalyse der einzelnen Parameter. Wie auch bei den zuvor besten neuronalen Netzen liegt die Distanz (20,49 %) an erster Stelle und wird von der Anzahl der Lagerbesuche (18,60 %) und der Dauer (15,97 %) gefolgt. Der maximalen Geschwindigkeit wird die geringste Bedeutung (10,08 %) zugemessen.




Abb. 6-33 Subdatensatz 3: Auswirkungsanalyse

#### 6.4.6 Modellvalidierung des 30-minütigen Abbruchkriteriums mittels der Testdaten

Damit eine Überprüfung zwischen Wirklichkeit und Modell stattfinden kann, werden diese nachfolgend mittels Testdatensatz beurteilt. Dieser beinhaltet sämtliche Fälle, welche aus der Modellbildung basierend auf dem 30-minütigen Abbruchkriterium stammen. Um die Testergebnisse und die Auswirkung der Änderung des Abbruchkriteriums besser nachvollziehen zu können, wird dieser Datensatz zunächst wieder erläutert. Insgesamt beinhaltet er 2.755 Fälle, wobei die genauere Aufteilung unter Berücksichtigung der einzelnen Tätigkeiten in Tabelle 6-64 ersichtlich ist. Im Vergleich zu Testdatensatz 2 reduziert sich die Gesamtanzahl der Einträge um 22 % (-772 Fälle), wobei die Tätigkeit Schalen ein Minus von 23 %, Bewehren von 22 % und Betonieren eine Verminderung von 12 % verzeichnet.

Lfd. Nr.	Tätigkeit	Testfälle
		A
1	Schalen	1.847
2	Bewehren	753
3	Betonieren	155
4	Summe	2.755

Tab. 6-64 Testdatensatz 3: Fallanzahl der einzelnen Tätigkeiten

Die Abbildungen 6-34 und 6-35 stellen die Verteilungen der Variablen Distanz, Dauer, Anzahl Lager sowie Wege und die durchschnittliche sowie maximale Geschwindigkeit des gesamten 30-minütigen Datensatzes dar. Ein typisches Merkmal für eine Klassifizierung ist abermals nicht zu erkennen. Die Überlegenheit der schalungsspezifischen Fälle ist im Vergleich zu den vorherigen Testdatensätzen am geringsten.

Die Distanz weist eine Bandbreite beim Schalen von 0 bis 2,27 km (+0,48 km im Vergleich zu Testdatensatz 2), beim Bewehren von 0 bis 2,80 km (+0,85 km) und beim Betonieren von 0 bis 1,47 km (+0,12 km) auf. Die dazugehörigen Mittelwerte betragen 0,36 km, 0,24 km und 0,23 km, wobei sich die Mediane auf 0,28 km, 0,18 km und 0,18 km belaufen. Die Standardabweichungen weisen in selbiger Reihenfolge der Tätigkeiten 0,28 km, 0,24 km und 0,21 km auf. Durch die Erhöhung des Abbruchkriteriums von 20 auf 30 Minuten ist – wie es zu erwarten war – der Mittelwert der Distanz wiederum gestiegen.

Die Dauer umspannt beim Schalen eine Bandbreite von 0,78 bis 191,17 min, beim Bewehren von 0,62 bis 219,05 min und beim Betonieren von 0,73 bis 174,23 min und die dazugehörigen Mittelwerte beziffern sich auf 46,82 min, 49,23 min und 42,57 min. Die Mediane, welche sich auf 37,63 min, 39,42 min und 42,23 min belaufen, weichen besonders beim Schalen und Bewehren von den jeweiligen Mittelwerten ab, während die Standardabweichungen 25,89 min, 29,10 min und 26,23 min ausmachen. Beim Vergleich des Mittelwerts mit dem Median von Testdatensatz 2 zeigt sich deutlich, dass das 30-minütige Abbruchkriterium zu einer Verlängerung der Aufenthaltsdauern führt.

Die Anzahl der Lageraufenthalte liegt beim Schalen zwischen 0 und 94 (+11 Lagerbesuche im Vergleich zu Testdatensatz 2), beim Bewehren zwischen 0 und 49 (+24) sowie beim Betonieren zwischen 0 und 10 (+3). Die Mittelwerte betragen unter Berücksichtigung der einzelnen Tätigkeiten 6,82, 5,16 sowie 1,11 und die Mediane belaufen sich beim Hantieren mit der Schalung auf 4 Lagerbesuche, beim Verlegen der Bewehrung auf 3 sowie beim Betonieren auf einen Besuch. Die Standardabweichungen weisen eine Größe von 9,75, 5,81 und 1,74 auf. Die vorliegende deskriptive Statistik zeigt sehr schön, dass die Erhöhung des Abbruchkriteriums auf 30 Minuten zu einer Steigerung der Lageraufenthalte führt.

Die Bandbreite der Anzahl der Wege erstreckt sich beim Schalen auf 0 bis 25 Wege (-1 Weg im Vergleich zu Testdatensatz 2), beim Verlegen der Bewehrung auf 0 bis 14 (+0) und beim Einbringen des Betons auf 0 bis 4 (+1). Die jeweiligen Mittelwerte belaufen sich auf 2,74, 1,84 und 0,46 Strecken, wobei die Mediane 2, 1 und 0 ausmachen und die Standardabweichungen 3,02, 2,02 und 0,72 Wege betragen. Auch wenn der erste Eindruck beim Betrachten der Bandbreiten nicht darauf schließen lässt, steigen im Vergleich zu Testdatensatz 2 dennoch der Mittelwert und der Median leicht an.



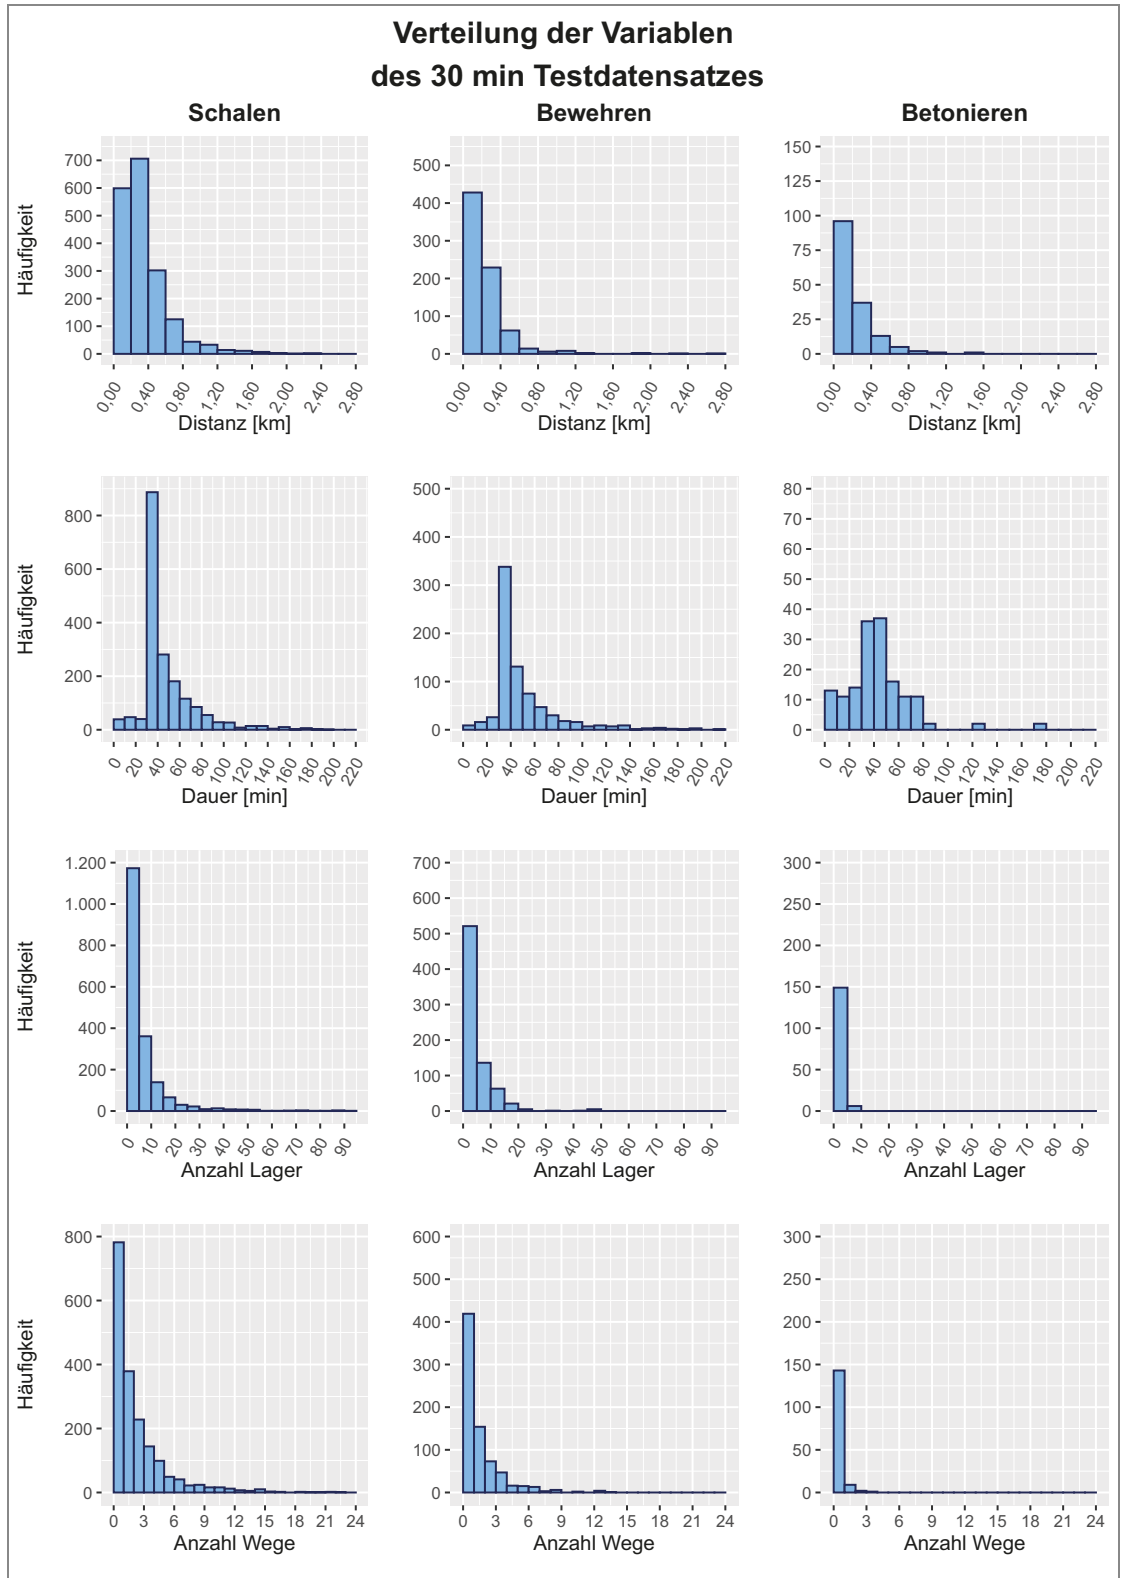



Abb. 6-34 Testdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren



**Abb. 6-35** Testdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren

Die durchschnittliche Geschwindigkeit bezieht sich beim Schalen auf den Bereich zwischen 0 und 10 km/h, beim Bewehren zwischen 1,28 und 9 km/h sowie beim Betonieren zwischen 0 und 8 km/h. Die Mittelwerte, welche 4,63 km/h, 4,68 km/h und 4,33 km/h betragen, weichen nur geringfügig von den einzelnen Medianen (4,65 km/h, 4,75 km/h und 4,02 km/h) ab. Die dazugehörigen Standardabweichungen belaufen sich auf 0,95 km/h, 1,00 km/h und 1,07 km/h. Wie es anhand der vorherigen Datensatzanalysen zu erwarten war, kommt der Änderung des Abbruchkriteriums bei der Geschwindigkeit keine Bedeutung zu.

Die maximale Geschwindigkeit deckt bei den Schalarbeiten eine Bandbreite von 0 bis 35 km/h, beim Verlegen der Bewehrung von 0 bis 30 km/h und beim Einbringen des Betons von 0 bis 24 km/h ab. Der Mittelwert und der Median belaufen sich beim Schalen auf 11,12 km/h und 11,00 km/h, beim Bewehren auf 10,42 km/h und 10 km/h sowie beim Betonieren auf 9,15 km/h und 8,00 km/h. Die dazugehörigen Standardabweichungen belaufen sich auf 4 km/h, 3,98 km/h und 3,88 km/h. Auch bei diesem Parameter wirkt sich im Vergleich zu Testdatensatz 2 das 30-minütige Abbruchkriterium nicht aus.

Um einen Überblick über die gesamte Bandbreite des Testdatensatzes 3 zu geben und damit dieser mit der des Subdatensatzes 3 (Tabelle 6-59) verglichen werden kann, wird Tabelle 6-65 angeführt. Die direkte Gegenüberstellung ergibt, dass beim Maximum der Distanz eine große Abweichung vorliegt – dieser Wert beträgt beim dritten Subdatensatz 1,92 km und beim dazugehörigen Testdatensatz 2,80 km. Hinzu kommt, dass der Mittelwert und der Median der Testfälle über jenen des Subdatensatzes liegen. Bei einer

tiefgreifenden Analyse ist festzustellen, dass insgesamt 5 Testfälle (3 bei Schalen und 2 bei Bewehren) außerhalb der Trainingsdaten liegen. Da dies jedoch nur für 2 Promille des Testdatensatzes zutrifft, ist von keinem signifikanten Einfluss auf das Testergebnis auszugehen, weshalb diese Testfälle nicht herausgenommen werden. Vergleichend mit Testdatensatz 2 ist festzustellen, dass die Änderung des Abbruchkriteriums eine besondere Auswirkung auf die zurückgelegte Distanz und die Dauer mit sich führt. Beide Parameter steigen merklich an.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Anzahl Lager	Anzahl Wege	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[-]	[-]	[km/h]	[km/h]
0	A	B	C	D	E	F	G
1	Minimum	0,00	0,62	0,00	0,00	0,00	0,00
2	Maximum	2,80	219,05	94,00	25,00	10,00	35,00
3	Mittelwert	0,32	47,24	6,05	2,37	4,63	10,82
4	Median	0,24	38,42	3,00	2,00	4,66	10,00
5	Standardabweichung	0,27	26,87	8,67	2,76	0,98	4,02

Tab. 6-65 Testdatensatz 3: Deskriptive Statistik

Auch die Verteilung der Bauteile (Tabelle 6-66) gilt es zu analysieren. Beim Vergleich mit Subdatensatz 3 (Tabelle 6-60) sind keine Abweichungen, welche einen Einfluss auf die Anwendbarkeit des neuronalen Netzes haben, festzustellen.


Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Bauteil</b>		
2	Bodenplatte	191	6,93 [%]
3	Sockel	516	18,73 [%]
4	Wand	1.345	48,82 [%]
5	Decke	493	17,89 [%]
6	Attika	210	7,62 [%]

Tab. 6-66 Testdatensatz 3: Auswertung der Kategorievariablen


Abbildung 6-36 verdeutlicht, dass die bereits zuvor vorgestellte Variante 2 den geringsten Fehler bei den Testfällen (36 %) aufweist und somit die Wirklichkeit am besten abbildet. Die anderen Netze schwanken zwischen 38 % und 40 %. Weiters lässt die Abbildung erkennen, dass der geringste Validierungsfehler nicht zwingend zum geeignetsten neuronalen Netz führen muss.

Der Einfluss der zufällig bestimmten Trainings- und Validierungsfälle ist ebenso in Abbildung 6-36 ersichtlich. Hierbei ist festzuhalten, dass die Auswahl zwar zu einer Schwankungsbreite beim Validieren von 6 % führt, dies aber keine bedeutende Auswirkung auf die Testfälle zeigt.

Bei den prozentuellen Testfehleranteilen in Abhängigkeit der einzelnen Tätigkeiten wirkt sich hingegen die Wahl der Trainingsfälle deutlich größer aus. Die Schalarbeiten schwanken hierbei zwischen 38 % und 46 %, das Verlegen der Bewehrung zwischen 26 % und 41 % und das Einbringen des Betons zwischen 16 % und 21 %.



**Abb. 6-36** Testdatensatz 3: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze



**Abb. 6-37** Testdatensatz 3: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze

Abschließend veranschaulicht Tabelle 6-67 noch den prozentualen Einfluss der einzelnen Variablen, wobei die Reihung der Einträge auf Basis von Variante 2 geschieht. Erwähnenswert ist hierbei, dass die Distanz fast durchgehend auf Rang 1 verweilt. Auch die Anzahl der Lagerbesuche (Rang 2) und die Dauer (Rang 3) werden bei den fünf Varianten mit einer ähnlich hohen Wichtigkeit eingeschätzt. Weiters weist das beste neuronale Netz (Variante 2) die größte Einflussbandbreite (10,08-20,49 %) auf. Bezüglich der letzten drei Parameter –

Bauteil, Anzahl der Wege und maximale Geschwindigkeit – ist festzuhalten, dass keine Einigkeit vorherrscht. Variante 2 sieht beispielsweise das Bauteil deutlich besser als die übrigen neuronalen Netze, bei der Anzahl der Wege hingegen ist dies genau umgekehrt. Der Vergleich mit der Sensitivitätsanalyse basierend auf Subdatensatz 2 (Tabelle 6-57) ergibt auf den ersten zwei Rängen die selben Parameter. Ebenso befindet sich die Anzahl der Wege bei beiden auf Rang 6, die letztgereichte maximale Geschwindigkeit (Rang 7) ist jedoch beim Subdatensatz 2 auf Rang 3 anzutreffen.

Lfd. Nr.	Parameter	Variante 2		Variante 1		Variante 3		Variante 4		Variante 5	
		Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung	Rang	Auswirkung
0	A	B	C	D	E	F	G	H	I	J	K
1	Distanz	1	20,49 [%]	5	13,81 [%]	1	16,46 [%]	1	19,28 [%]	1	18,92 [%]
2	Anzahl Lager	2	18,60 [%]	4	13,84 [%]	3	15,47 [%]	2	17,35 [%]	2	15,96 [%]
3	Dauer	3	15,97 [%]	3	15,98 [%]	2	15,69 [%]	3	14,45 [%]	4	14,08 [%]
4	Durchschn. Geschw.	4	13,15 [%]	2	16,07 [%]	6	13,09 [%]	4	13,09 [%]	5	12,79 [%]
5	Bauteil	5	11,28 [%]	6	11,87 [%]	7	12,05 [%]	7	11,54 [%]	7	11,70 [%]
6	Anzahl Wege	6	10,43 [%]	1	18,07 [%]	4	13,89 [%]	5	12,57 [%]	3	14,67 [%]
7	Max. Geschw.	7	10,08 [%]	7	10,37 [%]	5	13,34 [%]	6	11,71 [%]	6	11,88 [%]


Tab. 6-67 Subdatensatz 3: Vergleich der Auswirkungsanalyse

#### 6.4.7 Vergleich der Modellvalidierungen basierend auf dem 10-, 20- und 30-minütigen Abbruchkriterium

In diesem Abschnitt werden die Modellvalidierungsergebnisse der ausgewählten neuronalen Netze, welche jeweils auf Basis der vorhin vorgestellten Datensätze erstellt und beurteilt wurden, einander gegenübergestellt, um den Einfluss des Abbruchkriteriums sichtbar zu machen.

Abbildung 6-38 zeigt den prozentualen Anteil der falschen Prognosen bei den jeweiligen Validierungs- und Testdaten der drei neuronalen Netze, die einen Hidden-Layer besitzen. Die dazugehörige Neuronenanzahl beträgt beim ersten 30, beim zweiten 23 und beim dritten 7 Neuronen.

Bei der Auswahl der besten Modellierung gilt es, den Fehler der Testdaten und für die Ergebnisstabilität dessen Abstand zu jenem der Validierungsfällen zu beurteilen. Das KI-Modell mit dem 10-minütigen Abbruchkriterium weist hierbei die größte Differenz (9 %) zwischen den beiden Fehlerwerten auf und das 20-minütige Modell mit einem Prozent die geringste. Weiters ist bei diesem neuronalen Netz der Testfehler, welcher 34 % beträgt, im Gegensatz zu den anderen am kleinsten. Aus diesem Grund ist das neuronale Netz basierend auf dem 20-minütigen Datensatz zu bevorzugen, wobei festzuhalten ist, dass die Änderung des Abbruchkriteriums nur kleine Auswirkungen zur Folge hat.



**Abb. 6-38** Gegenüberstellung der besten neuronalen Netze basierend auf den drei Datensätzen mit 10-, 20- und 30-minütigem Abbruchkriterium

Wird das soeben ausgewählte neuronale Netz dem besten aus dem ersten Modellierungsschritt (Abbildung 6-15, Datensatz 1) gegenübergestellt, zeigt sich, dass bei Betrachtung des Testfehlers keine Verbesserung vorliegt. Werden jedoch die Differenzen zwischen den Test- und Validierungsfehlern sowie die prozentualen Fehleranteile unter Berücksichtigung der Tätigkeiten näher beleuchtet, ist der Vorteil der Datenaufbereitung mittels Abbruchkriterium zu erkennen. Beim ersten Aspekt reduziert sich die Abweichung von 10 % auf 1 %. Bei den tätigkeitsbezogenen Unterschieden (Abbildung 6-16 und 6-37) stellt sich heraus, dass das beste neuronale Netz basierend auf dem 5-80min-Datensatz, welches einen Fehleranteil beim Schalen von 29 %, beim Bewehren von 40 % und beim Betonieren von 67 % aufweist, dem Modell mit dem 20-minütigen Abbruchkriterium (Fehleranteil Schalen: 33 %, Bewehren: 38 % und Betonieren 28 %) deutlich unterliegt.

Weil die Aufbereitung des Basisdatensatzes zwar zu einem besseren Prognosemodell geführt hat, aber der Testfehler noch nicht in einem praxistauglichen Bereich liegt, wird im nachfolgenden Abschnitt das auf die 20-minütige Datenaufbereitung trainierte neuronale Netz weiter verfeinert.

## 6.5 Tätigkeitsreduktion auf Schalen und Betonieren

Beim untersuchten Bauprojekt wurden – wie es in Österreich häufig üblich ist – die Bewehrungsarbeiten an ein Subunternehmen vergeben. Somit mussten die Arbeitskräfte der Baufirma nur die Tätigkeiten Schalen und Betonieren durchführen. Um diese Umstände auch in der Modellbildung zu beachten, wird nachfolgend vor dem Trainieren der künstlichen Intelligenz eine Tätigkeitsreduktion auf Schalen und Betonieren durchgeführt. Die Ausgangsbasis bildet hierbei der Datensatz, welcher das 20-minütige Abbruchkriterium beinhaltet, da dieser zuvor die besten Ergebnisse erzielt hat.

Nach der Eliminierung der Tätigkeit Bewehren beinhaltet der gesamte Datensatz 2.391 Fälle für die Schalarbeiten und 176 fürs Betonieren. Damit für die abschließende Modellvalidierung nicht nur unbekannte Schaltätigkeiten zur Verfügung stehen, sind die Betoniereinträge zufällig aufzuteilen, wobei ein Verhältnis von 80:20 angestrebt wird. Somit ergeben sich 138 Betonierfälle für das Trainieren und Validieren der neuronalen Netze und 38 unbekannte Einträge fürs Testen. Die 147 Schaleinträge für den Modellerstellungsprozess werden zufällig in der Größenordnung ähnlich der Betonierfälle ausgewählt. Die Verteilung der einzelnen Parameter ist in Abbildung 6-39 dargestellt.

Der Maximalwert der von den Arbeitskräften zurückgelegten Distanz beläuft sich beim Hantieren mit der Schalung auf 1,18 km und beim Verlegen der Bewehrung auf 1,35 km. Die Mittelwerte machen 0,26 und 0,21 km aus, wobei die Mediane einen Wert von 0,23 und 0,18 km aufweisen. Die Standardabweichungen ergeben bei beiden Tätigkeiten jeweils 0,19 km.

Die Dauer deckt beim Schalen den Bereich zwischen 1,23 und 191,17 min, und beim Betonieren zwischen 0,73 bis 174,23 min ab und die dazugehörigen Mittelwerte machen 37,58 und 38,41 min aus. Die abgebildete Schiefe der Verteilung zeichnet sich wiederum durch die Abweichung der Mediane, welche 28,41 und 37,12 min betragen, vom Mittelwert ab. Die jeweiligen Standardabweichungen beziffern 27,09 und 27,05 min.

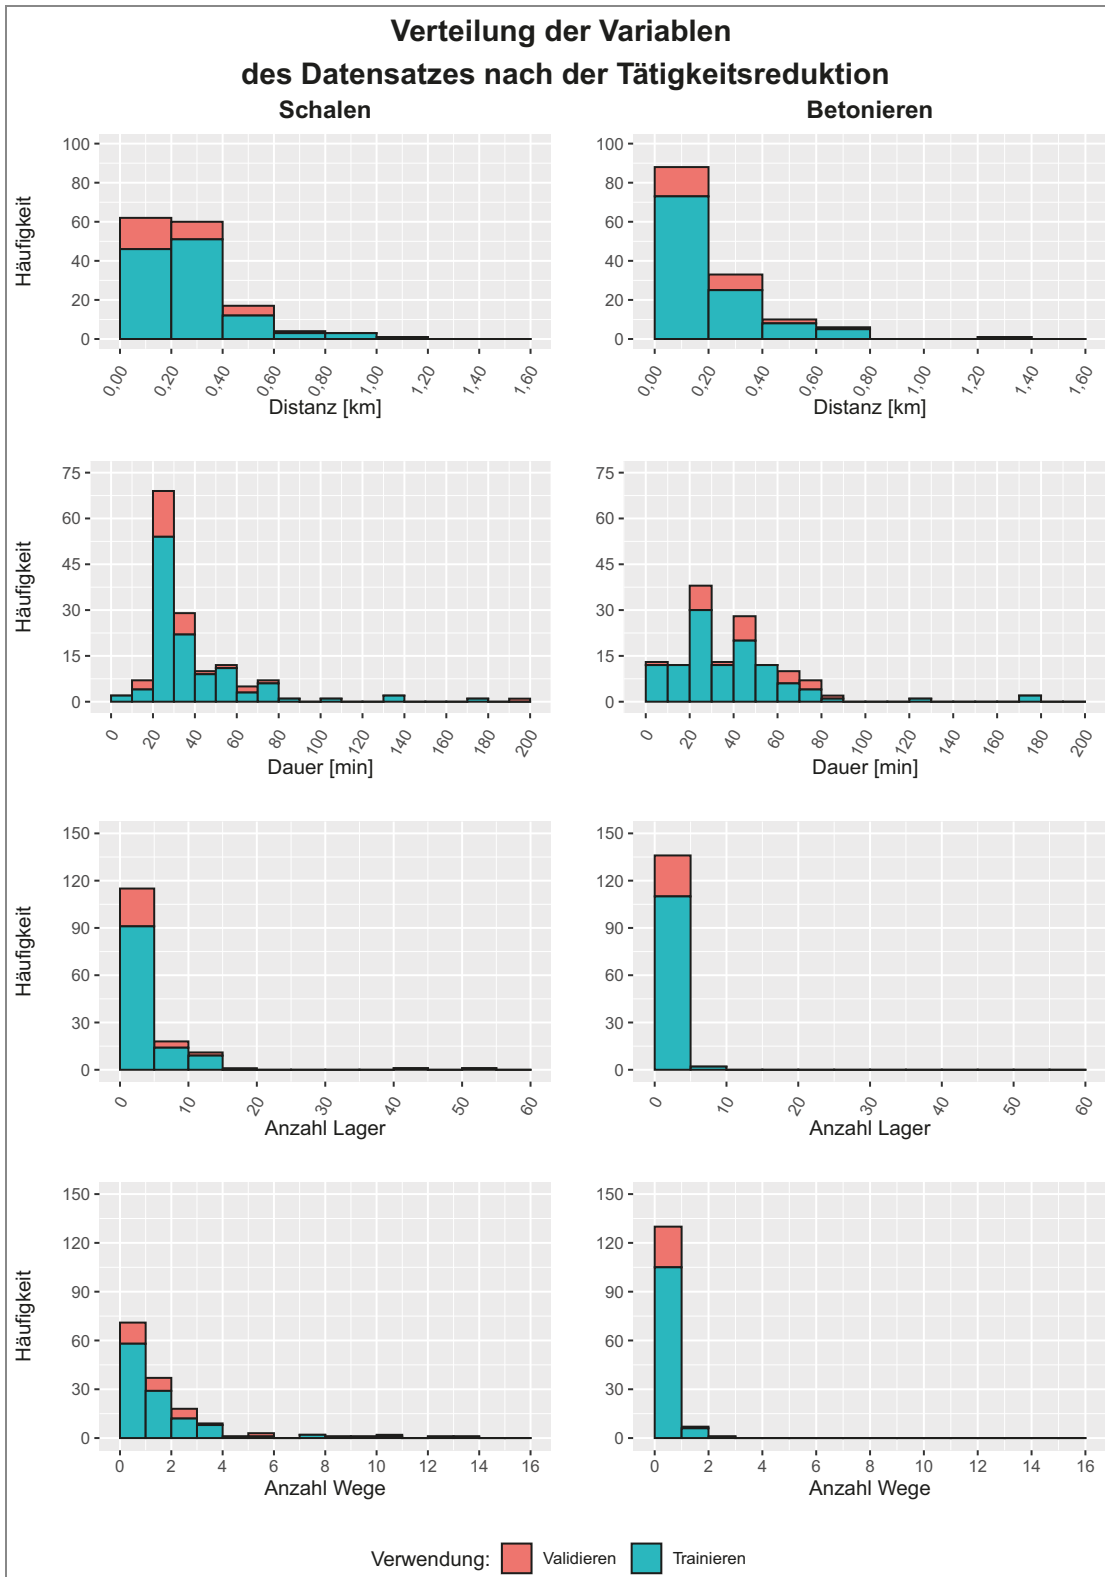
Das Maximum der Lageraufenthalte beläuft sich beim Schalen auf 52 und beim Betonieren auf 7 Besuche, während die Mittelwerte unter Berücksichtigung der zwei Tätigkeiten in gewohnter Reihenfolge 4,40 und 0,99 Aufenthalte betragen. Die Mediane weisen beim Schalen 2 Lagerbesuche und beim Betonieren 0 Besuche auf und die Standardabweichungen beziffern sich auf 6,26 und 1,47 Aufenthalte.

Die Anzahl der Wege spannt beim Schalen ein Spektrum von 0 bis 14 Wege und beim Betonieren von 0 bis 3 auf. Die jeweiligen Mittelwerte betragen 2,16 und 0,43 Wege, wobei die Mediane die Werte auf 2 und 0 annehmen und die Standardabweichungen 2,43 sowie 0,62 ausmachen.

Die durchschnittliche Geschwindigkeit weist beim Schalen eine Bandbreite zwischen 0,94 und 7,10 km/h und beim Betonieren zwischen 0 und 8,00 km/h auf. Die Mittelwerte, welche 4,59 und 4,36 km/h ausmachen, weichen nur geringfügig von den einzelnen Medianen (4,65 und 4,09 km/h) ab und die dazugehörigen Standardabweichungen betragen 0,96 und 1,06 km/h.


Die maximale Geschwindigkeit reicht beim Hantieren mit der Schalung über eine Bandbreite von 1 bis 35 km/h und beim Einbringen des Betons von 0 bis

24 km/h. Der Mittelwert und der Median belaufen sich beim Schalen auf 10,5 und 10,00 km/h sowie beim Betonieren auf 9,04 und 8,00 km/h, wobei die dazugehörigen Standardabweichungen 4,41 und 3,84 km/h betragen.



**Abb. 6-39** Tätigkeitsreduktion: Verteilung der Parameter in Abhängigkeit von Schalen und Betonieren





**Abb. 6-40** Tätigkeitsreduktion: Verteilung der Parameter in Abhängigkeit von Schalens und Betonieren

Die nachfolgende Tabelle 6-68 gibt wie bei den vorherigen Analysen einen Überblick über die deskriptive Statistik des gesamten Datensatzes. Hierbei stammen die Maxima von der Dauer, der Anzahl der Lager sowie der Wege und der maximalen Geschwindigkeit von den Schalungsarbeiten. Weiters sind in Kombination mit der Betrachtung von Abbildung 6-39 bei der Anzahl der Lageraufenthalte und der Wege klassentypische Merkmale zu erkennen. Um neben den numerischen Parametern auch die unterschiedlichen Bauteiltypen zu analysieren, fasst Tabelle 6-69 die Verteilung innerhalb dieser zusammen. Mit 44 % kommen dabei die Wände am häufigsten vor, hingegen ist die Bodenplatte mit 7 % an letzter Stelle gereiht. Der Sockel liegt mit 24 %, die Decke mit 16 % und die Attika mit 10 % dazwischen.

Lfd. Nr.	Statistische Kennwerte	Distanz	Dauer	Anzahl Lager	Anzahl Wege	Durchschn. Geschw.	Max. Geschw.
		[km]	[min]	[-]	[-]	[km/h]	[km/h]
0	A	B	C	D	E	F	G
1	Minimum	0,01	0,73	0,00	0,00	0,00	0,00
2	Maximum	1,35	191,17	52,00	14,00	8,00	35,00
3	Mittelwert	0,24	37,98	2,75	1,32	4,48	9,79
4	Median	0,19	30,02	1,00	1,00	4,47	9,00
5	Standardabweichung	0,19	27,07	4,92	1,99	1,02	4,21

**Tab. 6-68** Tätigkeitsreduktion: Deskriptive Statistik

Lfd. Nr.	Ausprägung	Anzahl	Relativer Anteil
0	A	B	C
1	<b>Bauteil</b>		
2	Bodenplatte	19	6,67 [%]
3	Sockel	67	23,51 [%]
4	Wand	124	43,51 [%]
5	Decke	47	16,49 [%]
6	Attika	28	9,82 [%]

Tab. 6-69 Tätigkeitsreduktion: Auswertung der Kategorievariablen

Nach der Datensatzanalyse folgt die auf künstlicher Intelligenz basierende Modellbildung, welche alle sieben der soeben vorgestellten Parameter berücksichtigt. Hierbei fungieren die zufällig ausgewählten Trainings- und Validierungsfälle – wieder im Verhältnis von 80:20 – als Lernhilfe für die 29 neuronalen Netze, welche zwischen 2 und 30 Neuronen in einem Hidden-Layer aufweisen.

Der niedrigste Validierungsfehlerwert von 12,28 % wird mit einem neuronalen Netz basierend auf 3 Hidden-Neuronen erzielt. Weiters weicht dieser nur geringfügig von jenem der Trainingsdaten (10,09 %) ab, was in weiterer Folge die Gefahr von Overfitting aufgrund der kleineren Datensatzgröße abwendet. Die nachfolgende Tabelle 6-70 stellt die falschen Prognosen unter Berücksichtigung der Trainings- und Validierungsfälle nochmals überblicksmäßig dar.

<b>Bestes Netz: 3 Hidden-Neuronen</b>	
<b>Training</b>	
Anzahl Fälle	228
Falsche Prognosen	10,09 [%]
<b>Validieren</b>	
Anzahl Fälle	57
Falsche Prognosen	12,28 [%]

Tab. 6-70 Tätigkeitsreduktion: Bestes Netz

Die Tabellen 6-71 und 6-72 verdeutlichen die Aufteilung der falschen Vorhersagen unter Berücksichtigung der einzelnen Tätigkeiten. Beim Training weist Schalen mit 5 % einen niedrigeren Fehlerwert als die Betonierarbeiten mit 15 % auf. Bei der Beurteilung der Validierungsdaten ergibt sich jedoch, dass beide gleich gut abschneiden. Im Vergleich zu den vorherigen Modellbildungen (Tabelle 6-9, Tabelle 6-53) sticht dieses neuronale Netz deutlich hervor.

Lfd. Nr.	Richtige Klasse	Vorhersagen		Anteil falscher Prognosen
		Schalen	Betonieren	
0	A	B	C	D
1	Schalen	110	6	5,17 [%]
2	Betonieren	17	95	15,18 [%]

Tab. 6-71 Tätigkeitsreduktion: Klassifikationsmatrix Trainieren

Lfd. Nr.	Richtige Klasse	Vorhersagen		Anteil falscher Prognosen
		Schalen	Betonieren	
0	A	B	C	D
1	Schalen	27	4	12,90 [%]
2	Betonieren	3	23	11,54 [%]

Tab. 6-72 Tätigkeitsreduktion: Klassifikationsmatrix Validieren

Abbildung 6-41 stellt noch die Auswirkungsanalyse der einzelnen Parameter dar. Hierbei liegt die Anzahl der Lagerbesuche mit 20,24 % deutlich auf Platz eins. Mit rund 3,5 % Rückstand rangiert die Anzahl der Wege auf Platz 2, gefolgt vom Bauteil und der durchschnittlichen Geschwindigkeit (14,76 %, 14,53 %). Die Reihung der ersten zwei Plätze hat sich bereits bei der Analyse der Trainings- und Validierungsdaten durch die klassenspezifischen Merkmale angekündigt. Sehr auffallend ist aber dennoch, dass den Parametern Dauer (13,24 %), Distanz (11,07 %) und maximale Geschwindigkeit (9,31 %) im Gegensatz zu den vorherigen Modellen nur eine sehr geringe Bedeutung zugerechnet wird.




Abb. 6-41 Tätigkeitsreduktion: Auswirkungsanalyse


### 6.5.1 Modellvalidierung von Schalen und Betonieren mittels der Testdaten

Abschließend wird das soeben vorgestellte, beste neuronale Netz auf die Übereinstimmung von Wirklichkeit und Modell überprüft. Die dafür eingesetzten Testdaten beinhalten 2.567 Fälle, welche aus der 20-minütigen Datenaufbereitung resultieren. Die dazugehörige Verteilung wurde bereits in Abschnitt 6.4.3 in den Abbildungen 6-27 und 6-28 erläutert.

Das auf Baustellendaten basierende Ergebnis der Modellvalidierung sticht im Vergleich zu den vorherigen Modellen deutlich hervor. Die Elimination der Tätigkeit Bewehren führt schlussendlich zu einem Anteil falscher Prognosen von nur 15,2 %, wodurch sich dieses neuronale Netz eindeutig von den anderen abhebt und als bestes der erstellten Modelle hervorgeht. Bei

genauerer Analyse der nicht richtigen Vorhersagen fallen 15 % auf das Schalen und 16 % aufs Betonieren. Der Vergleich mit dem Fehlerwert der Validierungsfälle, welche bei der Netzauswahl eingesetzt wurden, ist in Abbildung 6-42 ersichtlich.

Aus der Modellvalidierung geht hervor, dass die Elimination der Bewehrungstätigkeit zu einer Fehlerverringering bei reiner Betrachtung der Schal- und Betoniertestdaten von 32,5 %<sup>3</sup> auf 15 % führt. Dieser erzielte Anteil falscher Prognosen ist unter Berücksichtigung der Komplexität der Aufgabe als sehr gut zu bewerten, weshalb der iterative Modellbildungsprozess an dieser Stelle beendet wird.



**Abb. 6-42** Testdatensatz 3: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze

Die anhand des soeben vorgestellten Klassifizierungsbeispiels veranschaulichte Vorgehensweise verdeutlicht die Wichtigkeit des iterativen Modellierungsprozesses. Hierbei ist vor allem die Datenanalyse und die Berücksichtigung der Parametereinflüsse wesentlich. Die daraus gewonnenen Erkenntnisse bilden die Grundlage des nächsten Modellierungsschrittes. Somit steht der Mensch – unersetzbar aufgrund seiner kreativ-konzeptionellen Fähigkeiten – an der Spitze des Modellierungsprozesses.

Weiters zeigt das abschließende Modell, dass neuronale Netze für die Klassifizierung von Tätigkeiten basierend auf Dauer, Distanz, Anzahl der Wege und Lagerbesuche sowie durchschnittlicher und maximaler Geschwindigkeit eingesetzt werden können. Durch das Erreichen eines solchen Fehlerwertes ist ein für die Baustelle relevanter Kontrollmechanismus zum Überprüfen der durchgeführten Tätigkeiten geschaffen.

Im Zuge der auf dieser Arbeit aufbauenden Forschungstätigkeiten gilt es, den Datensatz um mindestens zehn weitere Bauvorhaben mit Hilfe des vorgestellten Erhebungskonzeptes zu vergrößern. Dadurch können baustellenspe-

<sup>3</sup> Dieser Testfehler des 20-minütigen Modells unterscheidet sich zu dem aus Abschnitt 6.4.4, weil die Bewehrungsfälle nicht berücksichtigt werden.

zifische Einflüsse wie beispielsweise Bauwerksgeometrie oder Entfernung zum Lager von der künstlichen Intelligenz berücksichtigt werden. Somit bildet diese Erweiterung der Variablenbandbreiten die Basis für eine baustellenübergreifende Modellanwendung. Wie in Kapitel 2 erläutert, sollten die Testdaten bzw. die Prognosen immer im Bereich der Trainingsfälle angeordnet sein, um die Gefahr von falschen Vorhersagen zu minimieren. Aus diesem Grund müssen die vorhin erarbeiteten Modellierungsschritte, welche sich im Rahmen der Modellvalidierung (nur 15 % falsche Vorhersagen) als zielführend herausgestellt haben, zunächst auf einen umfangreicheren Datensatz angewendet werden, damit ein allgemeingültiges Klassifikationsmodell erstellt werden kann.

## 6.6 Zusammenfassung des Modellbildungsprozesses

Die vorherigen Abschnitte zeigen sehr deutlich, dass für den effektiven und effizienten Einsatz neuronaler Netze eine gezielte Datenaufbereitung mit einschließlicher Analyse (iterativer Prozess) unverzichtbar ist. Nur die detaillierte Einsicht in die Datenlage ermöglicht das Identifizieren wichtiger Parameter sowie das Implementieren neuer Variablen. Weil zu Beginn die geeignetste Modellierungsvariante nicht offensichtlich ist, müssen hierbei immer verschiedene Ansätze ausprobiert und miteinander verglichen werden.

Ausgehend vom Basisdatensatz, welcher unterschiedliche Bewegungsmuster in Form ausgewählter Parameter und den dazugehörigen Tätigkeiten beinhaltet, werden schrittweise verschiedene Modellbildungsansätze vorgestellt, künstliche Intelligenzen trainiert, neuronale Netze ausgewählt und anhand der Testdaten auf deren Übereinstimmung mit der Wirklichkeit (Modellvalidierung) überprüft. Durch diese iterative Vorgehensweise, welche in Abbildung 6-43 zusammengefasst ist, kann schlussendlich nach der Tätigkeitsreduktion auf Schalen und Betonieren mittels eines neuronalen Netzes, welches drei Neuronen im Hidden-Layer aufweist, der Prognosefehler auf 15 % gesenkt werden.

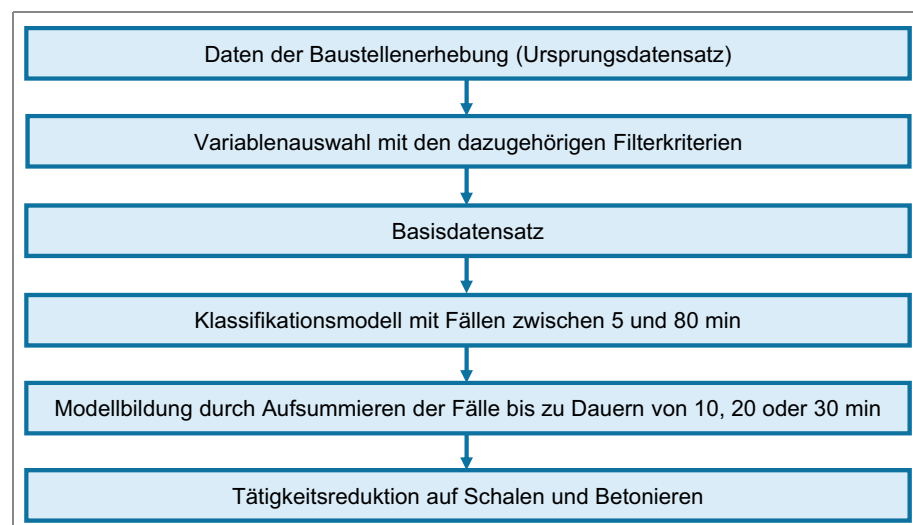


Abb. 6-43 Modellierungsprozess

Aufgrund der Tatsache, dass das Erkennen der einzelnen Tätigkeiten bei den Stahlbetonarbeiten auf Basis von Bewegungsmustern keine triviale Aufgabe darstellt, ist bei der vorhandenen Datenlage eine Reduktion des Prognosefehlers auf 15 % als sehr positiv hervorzuheben. Somit wurde mit dem Aufsummieren der Dauern bis 20 Minuten mit gleichzeitiger Elimination der Bewehrungsarbeiten eine geeignete Vorgehensweise gefunden, um den Zusammenhang zwischen den erhobenen Ortungsdaten und den Tätigkeiten zu modellieren.

Weiters lässt sich ein neuronales Netz mit dem vorliegenden Anteil an richtigen Prognosen bereits sehr gut zur automatischen Überprüfung der von den Arbeitskräften auf der Baustelle eingegebenen Tätigkeiten einsetzen. Dies wirkt sich in weiterer Folge positiv auf den für die Kontrolle notwendigen Zeitaufwand der für die Erhebung beauftragten Person aus.

Bevor der allgemeine Einsatz in der Praxis erfolgen kann, muss jedoch noch zunächst der vorhandene Datensatz durch weitere Hochbauprojekte vergrößert werden. Dadurch wird sichergestellt, dass eine ausreichende Variablenbandbreite für die nachweislich zielführende Modellierung der Tätigkeitsklassifikation Schalen und Betonieren vorliegt.

Abschließend ist noch anzumerken, dass durch die Einbindung weiterer Stahlbetonarbeiten nicht nur die allgemeine Anwendbarkeit verbessert, sondern auch zusätzliches Wissen erlernt wird. Um den durch andere Bauvorhaben vergrößerten Datensatz in der Modellbildung berücksichtigen zu können, gilt es, zwar immer ein neues neuronales Netz zu erstellen, jedoch kann dadurch der Fehleranteil weiter gesenkt werden.

Ebenso ist es zu empfehlen, einen weiteren Parameter, welcher die gerade von der Arbeitskraft eingesetzten Geräte beinhaltet, im Datensatz aufzunehmen. Ist beispielsweise eine Kreissäge im Einsatz, steigt die Wahrscheinlichkeit dafür, dass die Fachkraft die Tätigkeit Schalen durchführt. Selbiges gilt für den Einsatz des Rüttlers beim Einbringen des Betons.



## 7 Zusammenfassung

Die Begegnung mit künstlicher Intelligenz findet praktisch tagtäglich statt – sei es beim Einsatz von Sprachassistenten, bei personalisierter Werbung, Musikvorschlägen, dem Übersetzen von Texten oder der Bilderkennung. Im Baubetrieb und in der Bauwirtschaft hat sich diese neue Technologie jedoch noch nicht etabliert. Die vorliegende Dissertation ergründet diesen Sachverhalt und zeigt Lösungsmöglichkeiten für die auf der Baustelle anzufindenden Herausforderungen auf.

Hierfür werden im Rahmen einer Vorstudie der Bogen von der künstlichen Intelligenz zu den neuronalen Netzen gespannt und die für die Anwendung notwendigen theoretischen Grundlagen erläutert. Ein besonderes Augenmerk liegt auf der Funktionsweise, dem Netzaufbau und den mathematischen Zusammenhängen. Weiters beinhaltet das zweite Kapitel die Vorstellung des anwenderorientierten Programmes NeuralTools sowie zwei darauf aufbauende Beispiele, welche anhand der Prognose des Gesamtaufwandswertes und der Vorhersage des Aufwandswertes für Bewehrungsarbeiten die wichtigsten Schritte erläutern. Hierbei werden der Einfluss der Inputparameterverteilungen sowie die Gefahr vor außerhalb der Trainingsdaten angeordneten Testfällen aufgezeigt. Ebenso liegt der Fokus auf dem Unterschied zwischen den Trainings- und Validierungsfehlern, um Overfitting – das Finden eines nicht allgemeingültigen Zusammenhanges – zu erkennen.

Die anschließende Hauptstudie beinhaltet Anwendungen künstlicher Intelligenz, wobei zunächst bauferne Bereiche wie beispielsweise Verkauf, Marketing, Medizin, Call Center oder Automobilindustrie beleuchtet werden. Die Behandlung von baubetrieblichen und bauwirtschaftlichen Einsatzmöglichkeiten beginnt mit der Erläuterung der Herangehensweise im Umgang mit neuronalen Netzen. Daraufhin werden unter Berücksichtigung der Projektphasen jeweils für den Auftraggeber sowie Auftragnehmer Anwendungen vorgestellt. Daran anknüpfend wird spezifisch auf mögliche Inputparameter bei Produktivitätsprognosen im Tunnelbau und bei Stahlbetonarbeiten eingegangen. Den Abschluss des Kapitels bildet die durchgeführte Literaturanalyse mit dem Schwerpunkt auf Kosten-, Dauer- und Produktivitätsprognosen. Die Auswertung dieser verdeutlicht, dass für die Baustelle unbedingt ein automatischer Datenerhebungsprozess notwendig ist, da die untersuchten neuronalen Netze nur auf einer geringen Datenmenge beruhen (Mittelwert: 326 Fälle, Median: 115 Fälle).

Aufbauend auf den Erkenntnissen der Hauptstudie beschäftigt sich die Detailstudie mit digitalen Datenerhebungstechnologien. Um dem vorhin identifizierten Datenmangel entgegenzuwirken, setzt sich dieses Kapitel zum Ziel, automatisch die Lohnstunden unter Berücksichtigung des Erbringungsortes und der durchgeführten Tätigkeit zu erheben. Hierfür werden zunächst die Grundlagen von Sensoren, Ortungstechnologien und der Datenübertragung erläutert sowie fünf verschiedene Ortungskonzepte basierend auf RFID, BLE-Beacons, GNSS, GPS und UWB erarbeitet. Abschließend zeigt die Entscheidungsmatrix anhand aus der Anforderungsanalyse abgeleiteter Beurteilungskriterien, welche Variante auszuwählen ist.



Die darauffolgende Phase des Systembaus beinhaltet die Implementierung des ausgesuchten Konzepts auf einer Baustelle und die dazugehörige Evaluierung während der Stahlbetonarbeiten. Das Untersuchungsobjekt stellt ein eingeschossiges, aus sieben Räumen bestehendes Bauwerk dar, welches sich über eine Länge von 30 m und eine Breite von 5 m erstreckt. Als Ergebnis geht dabei hervor, dass mittels der eingesetzten Gadgets problemlos die Lohnstunden erhoben, die Tätigkeiten dokumentiert und die Arbeitskräfte den Bereichen zugeordnet werden können. Somit wird ein erfolgreicher Ansatz basierend auf globalen Navigationssatellitensystemen und BLE-Beacons für das automatische sowie verursachungsgerechte Erfassen der Lohnstunden gezeigt.

Das sechste Kapitel verdeutlicht die Vorgehensweise sowie das Potenzial der neuronalen Netze am Beispiel einer Klassifikation, welche das Ziel verfolgt, die Tätigkeiten Schalen, Bewehren und Betonieren anhand der erhobenen Bewegungsmuster zu erkennen. Hierfür werden zunächst bedeutende Parameter von der automatischen Datenerhebung ausgewählt und über Filterkriterien, welche die Elimination von Ausreißern sicherstellen, zum Basisdatensatz zusammengeführt. Dieser bildet die Ausgangslänge für den weiteren iterativen Modellierungsprozess. Im ersten Schritt wird die Aufenthaltsdauer im Geofence auf den Bereich zwischen 5 und 80 Minuten begrenzt. Die große Anzahl von unter 10-minütigen Dauern ermöglicht jedoch kein zufriedenstellendes Erkennen von tätigkeitstypischen Bewegungsmustern, weshalb im nächsten Modellierungsschritt die einzelnen Datensatzeinträge bis zum Erreichen eines bestimmten Abbruchkriteriums aufsummiert werden. Dies führt im Zuge der Modellvalidierung zu einer deutlichen Verbesserung des Prognosefehlers innerhalb der verschiedenen Tätigkeiten.

Das beste Ergebnis wird jedoch nach der Tätigkeitselimination der Bewehrungsarbeiten erzielt. Dieser Modellierungsschritt ist darauf zurückzuführen, dass während der Datenerhebung das Eigenpersonal der Baufirma nur Schal- und Betoniertätigkeiten durchgeführt hat. Bei der abschließenden Beurteilung der Übereinstimmung zwischen Wirklichkeit und Modell weisen die Testdaten lediglich einen 15-prozentigen Anteil falscher Prognosen auf. Dadurch wird gezeigt, dass mittels neuronaler Netze die auf der Baustelle verrichteten Tätigkeiten auf Basis der Bewegungsmuster erkannt werden können. Weiters ermöglicht das Erreichen eines in dieser Größenordnung liegenden Fehlerwertes eine automatische Überprüfung, ob die durchgeführten Tätigkeiten auch bekanntgegeben wurden.

## 7.1 Beantwortung der Forschungsfragen

Die am Beginn dieser Arbeit definierten Forschungsfragen werden nachfolgend zusammenfassend beantwortet, wobei für tiefergehende Details die angeführten Kapitel zu beachten sind.

### 1. Bei welchen Aufgabenstellungen aus dem Bauwesen kann künstliche Intelligenz auf Basis des überwachten Lernens zielführend eingesetzt werden?

Neuronale Netze aus dem Bereich Supervised Learning eignen sich für numerische Prognosen oder Klassifizierungen. Optimierungsaufgaben können hingegen nicht gelöst werden, weil die künstliche Intelligenz nur

die im Datensatz vorhandenen Zusammenhänge erlernen und kein darüberhinausgehendes Wissen erwerben kann. Nichtsdestotrotz ergeben sich durch die zwei zuvor genannten Nutzungsfelder unzählige Anwendungsmöglichkeiten, welche Kapitel 3 unter Berücksichtigung der einzelnen Projektphasen für Auftraggeber und Auftragnehmer ausführlich beleuchtet. Exemplarisch können hierfür die Vorhersage von Kosten, Dauern, Aufwands- und Leistungswerten oder die Bauverfahrensauswahl angeführt werden. Darüber hinaus ist es möglich, die Prognosen ständig mit dem voranschreitenden Projektfortschritt zu konkretisieren. Zunächst erstellt die künstliche Intelligenz beispielsweise grobe Kostenschätzungen auf Basis der Bauwerksart, des Bruttorauminhalts und des Bauortes, welche mit der Bekanntgabe weiterer Details wie den Mengen oder Materialien verfeinert werden können. Dadurch ist ein unterstützendes Werkzeug bei der Projektsteuerung gegeben, das bei aktiver Nutzung des Wissensspeichers auch zukünftige Bauvorhaben positiv beeinflusst.

## **2. Welchen Einfluss üben die Datensatzgröße sowie die Auswahl der Trainings- und Testfälle auf das Ergebnis aus?**

Je mehr Daten neuronalen Netzen zur Verfügung stehen, desto größer ist das Repertoire, um Wissen zu erlernen. Die im zweiten Kapitel beschriebenen Beispiele behandeln diese Fragestellung und verdeutlichen, dass mit zunehmender Datensatzgröße der Prognosefehler sinkt, weil eine größere Anzahl an allgemeingültigen Zusammenhängen erkannt wird.

Neben der grundsätzlichen Datensatzgröße spielen jedoch auch die Verteilung der einzelnen Parameter und die ausgewählten Trainingsfälle eine wesentliche Rolle. Vor allem bei der Modellvalidierung mittels Testdaten gilt es, darauf zu achten, ob diese in den Bandbreiten der für das Training zur Verfügung gestandenen Daten liegen. Ist dies nicht der Fall, hat das neuronale Netz keine umliegenden Anhaltspunkte, wodurch der Fehlerwert in Abhängigkeit der Komplexität der Aufgabenstellung unterschiedlich stark ansteigt.

## **3. Welche Voraussetzungen müssen für die Anwendung bei baubetrieblichen und bauwirtschaftlichen Fragestellungen erfüllt sein, damit effektive und effiziente Vorhersagen getroffen werden können?**

Als Grundvoraussetzung ist das Vorhandensein einer ausreichenden Datenmenge, bestehend aus Inputparametern und dem dazugehörigen Output, anzuführen. Der Begriff „ausreichend“ ist in diesem Zusammenhang nicht eindeutig definierbar, weil er stark von der Art der Vorhersage und der Anzahl sowie Auswahl der Inputparameter beeinflusst wird. Weiters übt die Bandbreite der Variablen einen großen Einfluss auf die Prognosegenauigkeit aus. Ist beispielsweise die Vorhersage von Baukosten im Hochbau zu modellieren, wirkt sich ein vorheriges Gliedern in Wohnbau und Bürobau positiv auf die Datensatzgröße aus, weil dieser Parameter aufgrund der separierten Betrachtungsweise nicht mehr erlernt werden muss. Ebenso sind mögliche Erhebungsfehler zu berücksichtigen. Weisen die einzelnen Parameter beispielsweise Messfehler auf, benötigt das neuronale Netz wiederum eine größere Datenmenge, damit die daraus folgenden Auswirkungen erlernt werden können. Dies veranschau-

licht ein Beispiel im zweiten Kapitel. Schlussendlich spielt auch der gewünschte Fehlerwert eine entscheidende Rolle, weil eine größere Anzahl an richtigen Klassifizierungen bzw. genaueren Prognosen durch mehr Daten gefördert wird.

Daraus wird ersichtlich, dass für die Entfaltung des gesamten Potenzials neuronaler Netze ein automatischer Datenerhebungsprozess unumgänglich ist. Durch den Einsatz digitaler Technologien ist sichergestellt, dass die Daten kontinuierlich erhoben und in weiterer Folge nutzbringend von der künstlichen Intelligenz veredelt werden können. Weiters stellt das fortlaufende Sammeln von Daten sicher, dass sich das Modell jederzeit aktualisieren kann, wodurch neue Gegebenheiten Berücksichtigung finden.

**4. Welches polysensorale System eignet sich bei Hochbaubaustellen, um automatisch die für die Vorhersage benötigten Einflussparameter zu erheben?**

Für das automatische Erheben der Inputparameter steht eine große Auswahl an Sensoren (z.B.: Druck-, Beschleunigungs-, Abstands- oder Temperatursensor) und Ortungstechnologien (z.B.: RFID, UWB, GNSS oder BLE) zur Verfügung, deren Funktionsweisen im vierten Kapitel erläutert werden. Je nach Aufgabenstellung gilt es, die passenden Systemkomponenten auszusuchen und miteinander zu kombinieren. Hierbei ist die Datenübertragung auf Funk auszulegen, damit keine zusätzlichen Kabel auf der Baustelle verlegt werden müssen.

Sind beispielsweise die Lohnstunden mit gleichzeitiger Tätigkeits- und Bereichsdokumentation zu erfassen, eignet sich das vorgestellte, auf einer Baustelle erprobte Gadget. Dieses bestimmt im Outdoorbereich die Position der Arbeitskraft mittels GNSS und indoor mit Hilfe von BLE-Beacons. Durch das Drücken der vorhandenen Knöpfe können zusätzlich die durchgeführten Tätigkeiten bekannt gegeben werden. Die Datenübertragung läuft hierbei über das Mobilfunknetz, wodurch für das Working Gadget lediglich eine SIM-Karte benötigt wird. Dieses System wurde auf einer Hochbaubaustelle während der Stahlbetonarbeiten evaluiert und erfüllt die vorgegebenen Anforderungen in jeglicher Hinsicht.

**5. Welche Schrittfolge gilt es, bei der Implementierung einer Prognose oder Klassifizierung auf Basis neuronaler Netze einzuhalten und welche Herausforderungen können hierbei auftreten?**

Eine auf künstlicher Intelligenz basierende Vorhersage beginnt immer mit einer Zielformulierung, welche den gewünschten Output und den maximal zulässigen Fehlerwert definiert. Daraufhin gilt es, bedeutende Einflussfaktoren zu identifizieren, wobei unter anderem auf internes Wissen oder auf Fachliteratur zurückgegriffen werden kann. Dieser Schritt ist vor allem bei kleinen Datensätzen wichtig, weil durch diese Vorauswahl dem neuronalen Netz das Erlernen des Unterschieds zwischen einflussreichen und weniger bedeutenden Parametern erleichtert wird.

Basierend auf den Überlegungen zu den Inputparametern ist anschließend ein Datensatz – im Idealfall automatisch erhoben – zusammenzustellen, welcher die Grundlage für den iterativen Modellierungs-

prozess darstellt. Hierbei sind die Parameterverteilungen zu analysieren sowie neuronale Netze zu trainieren und auf deren Übereinstimmung mit der Wirklichkeit zu prüfen, wobei die gewonnenen Erkenntnisse fortlaufend in den Modellierungsprozess integriert werden. Weiters sind Sensitivitätsanalysen zu empfehlen, weil dadurch die Nachvollziehbarkeit und das Verständnis hinsichtlich der Einflussfaktoren steigt.

Unabhängig davon, ob hierbei auf fertige KI-Lösungen oder eigens programmierte Netze zurückgegriffen wird, muss darauf geachtet werden, dass kein Overfitting eintritt. Dieser Gefahr kann durch Vergleichen der Trainingsfehler mit den Validierungs-/Testfehlern entgegengewirkt werden, weil dadurch sofort ersichtlich wird, ob das neuronale Netz allgemeingültige oder nur datensatzspezifische Zusammenhänge gefunden hat. Wird schlussendlich der maximal vertretbare Fehlerwert unterschritten, ist das auf künstlicher Intelligenz basierende Modell bereit für Vorhersagen innerhalb der Trainings- und Testdatenbandbreiten.

## 7.2 Nutzen der Arbeit

Zu Beginn der vorliegenden Arbeit werden die theoretischen Grundlagen nachvollziehbar aufbereitet. Die daraus resultierende fundierte Verstehensumgebung schafft in weiterer Folge die Voraussetzung für den nutzenbringenden Einsatz neuronaler Netze. Weiters verdeutlichen zwei Beispielprognosen, wie das vorgestellte Wissen umzusetzen ist und welche Gefahren auftreten können. Hierbei werden der Einfluss von Overfitting sowie die Auswirkung von außerhalb der Trainingsdaten durchgeführten Vorhersagen nachdrücklich herausgearbeitet.

Die vorgestellten Anwendungsmöglichkeiten verdeutlichen die Vielfältigkeit des Einsatzes künstlicher Intelligenz, wobei die baufernen Beispiele nur einen Rahmen für das Potenzial dieser Errungenschaft skizzieren. Die Überführung zu baubetrieblichen und bauwirtschaftlichen Fragestellungen erfolgt unter Berücksichtigung der Projektphasen, wobei für jede Phase sowohl auftraggeber- als auch auftragnehmerseitige Anwendungsbereiche vorgestellt werden. Die darauffolgenden Einflussfaktoren dienen als Ideengeber und ermöglichen eine einfachere Inputparameterauswahl. Die durchgeführte Literaturanalyse mit dem Schwerpunkt auf Kosten-, Dauer- und Produktivitätsprognosen zeigt sehr deutlich, dass bereits viele erfolgsversprechende Anwendungsmöglichkeiten existieren, die aktuelle Datenlage jedoch eine Herausforderung darstellt. Die mittlere Datensatzgröße von 326 Fällen ist gegenüber anderen Branchen sehr gering. Ebenso geht aus der Auswertung der Publikationen hervor, dass Deep Learning bei Kosten-, Dauer- oder Produktivitätsprognosen wenig verbreitet ist (durchschnittlich 17 Neuronen in einem Hidden-Layer).

Um die für Vorhersagen zur Verfügung stehenden Fälle zu steigern, gilt es, digitale Erhebungskonzepte auf der Baustelle zu implementieren. Hierfür beinhaltet Kapitel 4 die theoretischen Grundlagen von Sensoren, Ortungstechnologien und Datenübertragungsmöglichkeiten. Mit Hilfe dieses Wissens können die ausgearbeiteten Konzepte zur automatischen Lohnstundenerhebung inklusive Bereichszuordnung problemlos nachvollzogen werden. Bei der Auswertung der Konzepte kristallisiert sich anhand der Bewertungskri-

terien heraus, dass globale Navigationssatellitensysteme in Kombination mit Beacons basierend auf Bluetooth Low Energy eine zielsichere Erhebungsmöglichkeit darstellen. Die Umsetzung dieses Konzepts auf der Baustelle erfüllt alle Erwartungen, wodurch im Zuge dieser Arbeit ein geeignetes System zur automatischen Lohnstundenerhebung gefunden wurde. Ein weiterer Nutzen des untersuchten Ortungssystems ist, dass neben der Bereichszuordnung auch die Erfassung der Tätigkeiten manuell erfolgen kann. Hierfür müssen die Arbeitskräfte lediglich die Druckknöpfe am Working Gadget betätigen.

Aufbauend auf den Erhebungswerten des Feldversuches veranschaulicht die Dissertation im sechsten Kapitel den Weg der Datenanalyse und den iterativen Modellbildungsprozess basierend auf neuronalen Netzen. Hierbei wird der Ablauf anhand der Klassifikation einzelner Tätigkeiten unter Berücksichtigung von Bewegungsmustern gezeigt. Ebenso kristallisiert sich als Nutzen heraus, dass basierend auf zurückgelegter Distanz, Dauer, Anzahl der Wege und Lagerbesuche, Bauteil sowie durchschnittlicher und maximaler Geschwindigkeit die Tätigkeiten Schalen und Betonieren mittels neuronaler Netze erfolgreich (nur 15 % falsche Zuordnungen) unterschieden werden können. Ein schlussendlich erzielter Fehlerwert dieser Größe ermöglicht den Einsatz des Modells als Kontrollfunktion, um zu überprüfen, ob die Fachkräfte die richtige Tätigkeit ausgewählt haben.

Die vorliegende Arbeit beinhaltet somit den gesamten Transformationsprozess des automatisch erhobenen Verfügungswissens in Orientierungswissen basierend auf künstlicher Intelligenz. Hierbei werden die Anwendungsmöglichkeiten und das Potenzial der neuronalen Netze klar herausgearbeitet und es wird unmissverständlich gezeigt, dass ein digitaler Datenerhebungsprozess die Voraussetzung für effektive und effiziente Vorhersagen darstellt. Die systematische Aufbereitung der theoretischen Grundlagen, die Umsetzung des ausgewählten Systems zur verursachungsgerechten Lohnstundenerhebung sowie die darauffolgende Modellierung beinhalten alle wichtigen Prozessschritte, um mittels neuronaler Netze zielsichere Vorhersagen zu erstellen. Aufgrund der soeben beschriebenen, schrittweise aufbereiteten Vorgehensweise ist diese Dissertation auch als Handlungsanleitung zu empfehlen.

### 7.3 Ausblick und weiterer Forschungsbedarf

Ein Rückblick in die Vergangenheit zeigt, dass sich die digitalen Technologien im 21. Jahrhundert sehr schnell weiterentwickelt haben. Dieser Fortschritt ist auch im Bereich der künstlichen Intelligenz im Bauwesen anhand der Anzahl der jährlichen Publikationen, welche sich innerhalb der letzten 10 Jahre fast verfünffacht haben, ablesbar.<sup>1</sup> Wird dieser Trend für die Zukunft fortgeschrieben, ist keine Verlangsamung des technischen Fortschritts in Sicht. Daher gilt es, sich der Digitalisierung nicht zu verschließen, sondern deren Vorteile zu erkennen und auf der Baustelle in Nutzen zu transformieren. Weiters ist es für das Ausschöpfen des gesamten Potenzials wesentlich, nicht nur auf eine singuläre Zukunftstechnologie zu setzen, sondern die

<sup>1</sup> Vgl.: Darko, A. et al.: Artificial intelligence in the AEC industry: Scientometric analysis and visualization of research activities. In: Automation in Construction, 112, 103081, 2020

Kombination verschiedenartiger Technologien anzustreben. Hierbei spielt beispielsweise die vernetzte Anwendung von Internet of Things<sup>2</sup> (IoT), künstlicher Intelligenz (KI) und Building Information Modeling<sup>3</sup> (BIM) eine wesentliche Rolle im Bauwesen, weil dadurch die Daten automatisch erhoben, zielsicher aufbereitet und verursachungsgerecht auf Plattformen – als zentraler Dreh- und Angelpunkt<sup>4</sup> – gespeichert werden können.

Auch die vorliegende Dissertation sieht die Notwendigkeit eines digitalen Datenerhebungsprozesses als Grundlage für den effektiven Einsatz neuronaler Netze. Aus diesem Grund wird ein Konzept für die Lohnstundenerfassung mit gleichzeitiger Bereichs- und Tätigkeitszuordnung auf einer Baustelle implementiert und während der Stahlbetonarbeiten evaluiert. Das eingesetzte System basiert outdoor auf Satellitenortung und indoor auf BLE-Beacons, während die Dokumentation der Tätigkeiten mittels auf den Gadgets vorhandener Druckknöpfe erfolgt. Mit diesem Konzept ist jedoch keine automatische Verknüpfung der erhobenen Dauern mit den einzelnen Bauteilen möglich. Daher wird für Folgeprojekte empfohlen, die sich derzeit noch in Entwicklung befindende Gadgetversion einzusetzen. Diese verfügt über einen Touchscreen, wodurch die Arbeitskräfte neben der Tätigkeit auch das zu bearbeitende Bauteil dokumentieren können. Weiters gilt es, den Kran mit den bereits eingesetzten Gadgets auszustatten. Durch das Anbringen dieser an der Kranflasche können die mit einem BLE-Beacon versehenen angehängten Geräte bzw. Materialien detektiert und deren Positionen ermittelt werden. Dies ermöglicht in weiterer Folge das automatische Verknüpfen zwischen der Betonlieferung und dem Bauteil. Ebenso sind zukünftig die tätigkeitstypischen Geräte mit Beacons auszustatten, um einerseits deren Einsatzdauer und andererseits einen wesentlichen Parameter für die Klassifikation der durchgeführten Arbeiten zu erheben.

Das hierfür trainierte neuronale Netz zeigt, dass das Unterscheiden der Tätigkeiten Schalen und Betonieren mittels Dauer, Distanz, Anzahl der Wege und Lagerbesuche sowie durchschnittlicher und maximaler Geschwindigkeit möglich ist. Damit die vorgestellten Modellierungsschritte zukünftig in ein baustellenübergreifendes Modell überführt werden können, gilt es jedoch zunächst, diese Daten bei weiteren Bauvorhaben zu erheben, damit die künstliche Intelligenz lernt, die baustellenspezifischen Einflüsse wie beispielsweise verschiedene Bauwerksgeometrien oder unterschiedliche Entfernungen zum Lager richtig einzuschätzen.

Neben dem Fokus auf der automatischen Datenerhebung sind auch zukünftig die sich ständig weiterentwickelnden physischen Computerbestandteile für das Erstellen neuronaler Netze zu beachten. Neuromorphe Hardware stellt beispielsweise eine Neuerung dar, die für den Einsatz künstlicher Intelligenz auf der Baustelle von Interesse sein könnte. Die ereignisbasierte Funktionsweise dieser Chips ermöglicht eine direkte Implementierung von gepulsten neuronalen Netzen, wodurch ein deutlich verringerter Energieverbrauch erzielt wird. In Kombination mit neuartigen Konvertierungsmethoden<sup>5</sup>, welche die Grundlage für die Generierung von leistungsstarken,

<sup>2</sup> Nordine, A.; Motzko, C.: An internet of things based transportation cart for smart construction site. Konferenz: iThings-GreenCom-CPSCCom-SmartData-Cybermatics. IEEE, 2020. S. 160-167

<sup>3</sup> Sundermeier, M.; Beidersandwich, P.; Theuring, F.: Ökonomische Potenziale von Building Information Modeling (BIM) im Spannungsfeld von Branchenstruktur und Beschaffungspraxis. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. S. 589-619

<sup>4</sup> Gralla, M.; Lenz, L. T.: Digitalisierungspotenziale im Rahmen der Kostenermittlung von Bauleistungen – Digitaler Schatten – Analytik – Cyber-physische Systeme – Plattformen. In: Aktuelle Entwicklungen in Baubetrieb, Bauwirtschaft und Bauvertragsrecht – 50 Jahre Institut für Baubetrieb und Bauwirtschaft der TU Graz. Hrsg.: Hofstadler, C. S. 799

gepulsten neuronalen Netzen darstellen, zeichnet sich eine vielversprechende Zukunft für KI-unterstützte, batteriebetriebene Geräte auf der Baustelle ab.

Bei all den technologiegetriebenen Bestrebungen gilt es, schlussendlich nochmals darauf hinzuweisen, dass der Mensch unverzichtbar an der Spitze der Prozessinteraktionen mit der Digitalisierung steht. Das Konzept der multisystemischen Hybridpyramide nach *Hofstadler* stellt dies unmissverständlich dar und bildet die Grundlage für eine fundierte Erstellung, Anwendung und Interpretation der Modelle.<sup>6</sup> Die Einführung digitaler Technologien ist somit als Unterstützung des menschlichen Handelns zu verstehen. Damit geht zwar einher, dass sich zukünftig die Prozesse auf der Baustelle – beispielsweise durch ein automatisches Vorfüllen der Bautagesberichte – ändern werden, aber die mitwirkenden Personen bleiben hierbei aufgrund ihrer kreativ-konzeptionellen Fähigkeiten unersetzbar.

<sup>5</sup> Stöckl, C.; Maass, C.: Optimized spiking neurons can classify images with high accuracy through temporal coding with two spikes. In: *Nature Machine Intelligence* 3, 2021. S. 230-238

<sup>6</sup> Vgl.: Hofstadler, C.: Multisystemische Hybridpyramide für den agilen Baubetrieb – System- und Prozessinteraktionen mit der Digitalisierung. In: *Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices*. Hrsg.: Hofstadler, C.; Motzko, C. S. 13ff

## 8 Literaturverzeichnis

Das Literaturverzeichnis ist in folgende Abschnitte unterteilt:

- Bücher und Buchkapitel
- Zeitschriften- und Fachartikel
- Internetquellen
- Masterarbeiten und Dissertationen
- Tagungs- und Kongressschriften
- Vorträge, Präsentationen, Workshop- und Vorlesungsunterlagen
- Dokumentationen und Interviews
- Anwenderinformationen, Produktbeschreibungen und Normen

### 8.1 Bücher und Buchkapitel

- Banse, G.: Erfindungen im Spannungsfeld von Methodik, Heuristik und Kreativität. In: Johann Beckmann und die Folgen. Erfindungen – Versuch der historischen, theoretischen und empirischen Annäherung an einen vielschichtigen Begriff. Hrsg.: Banse, G.; Müller H. Münster, New York. Waxmann Verlag, 2001. (ISBN 3-8309-1091-6)
- Bauer, M.: Vermessung und Ortung mit Satelliten. 7. Auflage. Berlin. Wichmann, 2018. (ISBN 978-3-87907-634-5)
- Binder, F.: Aktuelle Potenziale der Integration von Ortungsdaten in die Bauwerksinformationsmodellierung. In: Festschrift zum 60. Geburtstag von Univ.-Prof. Dr.-Ing. Christoph Motzko. Hrsg.: Fenner, J. Institut für Baubetrieb der Technischen Universität Darmstadt, 2017. (ISBN 978-3-941925-29-8)
- Bishop, C. M.: Neural Networks for Pattern Recognition. Oxford. Clarendon Press, 1995.
- Bünthe, C.: Künstliche Intelligenz – die Zukunft des Marketing. Wiesbaden. Springer Gabler, 2018. (ISBN 978-3-658-23318-1)
- Colhoun O.: WLAN. In: Lexikon der Medizinischen Laboratoriumsdiagnostik. Hrsg.: Gressner, A.M.; Arndt, T. 3. Auflage. Berlin Heidelberg. Springer-Verlag, 2019. (ISBN 978-3-662-48985-7)
- Czichos, H.: Mechatronik Grundlagen und Anwendungen technischer Systeme. 3. Auflage. Wiesbaden. Springer Vieweg, 2015. (ISBN 978-3-658-09949-7)
- Dodel, H.; Häupler, D.: Satellitennavigation. 2. Auflage. Berlin Heidelberg. Springer-Verlag, 2010. (ISBN 978-3-540-79443-1)
- Ertel, W: Grundkurs Künstliche Intelligenz. 4. Auflage. Wiesbaden. Springer Vieweg, 2016. (ISBN 978-3-658-13548-5)



- Eyth, M.: Zur Philosophie des Erfindens (1903). In: Eyth, M.: Lebendige Kräfte. Sieben Vorträge aus dem Gebiete der Technik. 4. Auflage. Berlin. Verlag von Julius Springer, 1924.
- Friedrich M.: Intelligenz aus philosophischpsychologischer Sicht. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. Darmstadt. wbg, 2021 (ISBN 978-3-534-40600-5)
- Girmscheid, G.: Forschungsmethodik in den Baubetriebswissenschaften. 2. Auflage. Zürich. Eigenverlag des IBB an der ETH Zürich, 2007. (ISBN 978-3-906800-10-3)
- Gladden, W.: Performance Measurement Controlling mit Kennzahlen. 6. Auflage. Wiesbaden. Springer Gabler, 2014. (ISBN 978-3-658-05137-2)
- Goodfellow, I.; Bengio, Y.; Courville, A.: Deep Learning. MIT Press, 2016. (Online: <https://www.deeplearningbook.org/contents/mlp.html>. Datum des Zugriffs: 14.07.2020)
- Gralla, M.; Lenz, L. T.: Digitalisierungspotenziale im Rahmen der Kostenermittlung von Bauleistungen – Digitaler Schatten – Analytik – Cyberphysische Systeme – Plattformen. In: Aktuelle Entwicklungen in Baubetrieb, Bauwirtschaft und Bauvertragsrecht – 50 Jahre Institut für Baubetrieb und Bauwirtschaft der TU Graz. Hrsg.: Hofstadler, C. Springer Vieweg, 2019. (ISBN 978-3-658-27430-6)
- Gralla, M.; Weist, K. C.: Komplexitätsbeherrschung durch Anwendung dynamisch-interdisziplinärer BIM-Modelle – Ein Lösungsansatz für die Fabrikplanung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. Wiesbaden. Springer Vieweg, 2021. (ISBN 978-3-658-34106-0)
- Gupta, N.: Inside Bluetooth Low Energy. 2. Auflage. Boston London. Artech House, 2016. (ISBN 978-1-63081-089-4)
- Gürtler, O.: Künstliche Intelligenz als Weg zur wahren digitalen Transformation. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. Hrsg: Buxmann, P.; Schmidt, H. Berlin. Springer Gabler, 2019. (ISBN 978-3-662-57567-3)
- Heichele, T.: Künstliche Intelligenz im Lichte der Technikphilosophie. Ein Überblick unter besonderer Berücksichtigung des Mensch-Natur-Technik-Verhältnisses. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. Darmstadt. wbg, 2021 (ISBN 978-3-534-40600-5)
- Helmus, M.; Kelm, A.; Laußat, L.; Meins-Becker, A.: RFID-Baugistikleitstand. Wiesbaden. Vieweg+Teubner Verlag, 2011. (ISBN 978-3-8348-1577-4)
- Hering, E.; Schönfelder, G.: Sensoren in Wissenschaft und Technik Funktionsweise und Einsatzgebiete. 2. Auflage. Wiesbaden. Springer Vieweg, 2018. (ISBN 978-3-658-12561-5)
- Hesse, S.; Schnell, G.: Sensoren für die Prozess- und Fabrikautomation. 6. Auflage. Wiesbaden. Springer Vieweg, 2014. (ISBN 978-3-658-05866-1)
- Herbrich, R.: Künstliche Intelligenz bei Amazon Spitzentechnologie im Dienste des Kunden. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. Hrsg: Buxmann, P.; Schmidt, H. Berlin. Springer Gabler, 2019. (ISBN 978-3-662-57567-3)

- Hilbert, M.; Neukart, F.; Ringlstetter, C.; Seidel, C.; Sichler, B.: KI-Innovation über das autonome Fahren hinaus. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. Hrsg: Buxmann, P.; Schmidt, H. Berlin. Springer Gabler, 2019. (ISBN 978-3-662-57567-3)
- Hildesheim, W.; Michelsen, D.: Künstliche Intelligenz im Jahr 2018 – Aktueller Stand von branchenübergreifenden KI-Lösungen: Was ist möglich? Was nicht? Beispiele und Empfehlungen. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. Hrsg: Buxmann, P.; Schmidt, H. Berlin. Springer Gabler, 2019. (ISBN 978-3-662-57567-3)
- Hofstadler, C.: Produktivität im Baubetrieb. Berlin. Springer Vieweg, 2014. (ISBN 978-3-642-41632-3)
- Hofstadler, C.; Kummer, M.: Chancen- und Risikomanagement in der Bauwirtschaft. Berlin. Springer Vieweg, 2017. (ISBN 978-3-662-54318-4)
- Hofstadler, C.: Multisystemische Hybridpyramide für den agilen Baubetrieb – System- und Prozessinteraktionen mit der Digitalisierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. Wiesbaden. Springer Vieweg, 2021. (ISBN 978-3-658-34106-0)
- Höher, P.: Grundlagen der digitalen Informationsübertragung. 2. Auflage. Wiesbaden. Springer Vieweg, 2013. (ISBN 978-3-8348-1784-6)
- Hompel, M.; Heidenblut V.: Taschenlexikon Logistik. 3. Auflage. Berlin Heidelberg. Springer-Verlag, 2011. (ISBN 978-3-642-19944-8)
- Kafka, T.: Neuronale Netze. Grundlagen. Frechen. mitp, 2017 (ISBN: 9783958456075)
- Kern, C.: Anwendung von RFID-Systemen. 2. Auflage. Berlin Heidelberg. Springer-Verlag, 2007. (ISBN-10 3-540-44477-7)
- Krüger, S.: Die KI-Entscheidung – Künstliche Intelligenz und was wir daraus machen. Wiesbaden. Springer, 2021
- Leukert, B.; Müller, J.; Noga, M.: Das intelligente Unternehmen: Maschinelles Lernen mit SAP zielgerichtet einsetzen. In: Künstliche Intelligenz Mit Algorithmen zum wirtschaftlichen Erfolg. Hrsg: Buxmann, P.; Schmidt, H. Berlin. Springer Gabler, 2019. (ISBN 978-3-662-57567-3)
- Linnemann, M.; Sommer, A.; Leufkes, R.: Einsatzpotentiale von LoRaWAN in der Energiewirtschaft. Wiesbaden. Springer Vieweg, 2019. (ISBN 978-3-658-26916-6)
- Mansfeld, W.: Satellitenortung und Navigation – Grundlagen und Anwendung globaler Satellitennavigationssysteme. Wiesbaden. Springer Fachmedien, 1998. (ISBN 978-3-528-06886-8)
- Mainzer, K.: Künstliche Intelligenz – Wann übernehmen die Maschinen?. 2. Auflage. Berlin. Springer-Verlag, 2019. (ISBN 978-3-662-58045-5)
- Meixner, U.: Bewusstseinsintelligenz und Künstliche Intelligenz. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. Darmstadt. wbg, 2021 (ISBN 978-3-534-40600-5)
- Motzko, C.; Mehr, O.; Klingenberger, J.; Binder, F.: Grundlagen des Bauprozessmanagements. In: Praxis des Bauprozessmanagements – Termine, Kosten und Qualität zuverlässig steuern. Hrsg.: Motzko, C. Berlin. Ernst & Sohn, 2013. (ISBN 978-3-433-03007-3)

- Precht, R.: Jäger, Hirten, Kritiker. München. Wilhelm Goldmann Verlag, 2020 (ISBN 978-3-442-15998-7)
- Rich, E.; Knight, K.; Nair S. B.: Artificial Intelligence. 3. Auflage. New Delhi. Tata McGraw- Hill, 2009. (ISBN 978-0-07-008770-5)
- Richter, S.: Statistisches und maschinelles Lernen. Berlin. Springer Spektrum, 2019. (ISBN 978-3-662-59353-0)
- Ropohl, G.: Philosophie der Erfindung. In: Johann Beckmann und die Folgen. Erfindungen – Versuch der historischen, theoretischen und empirischen Annäherung an einen vielschichtigen Begriff. Hrsg.: Banse, G.; Müller H. Münster, New York. Waxmann Verlag, 2001. (ISBN 3-8309-1091-6)
- Rosengrün, S.: Was ist KI und wenn ja, wie viele? – Vier Rätsel einer Philosophie der künstlichen Intelligenz. In: Natürliche und Künstliche Intelligenz im Anthropozän, Hrsg.: Rathmann, J.; Voigt, U. Darmstadt. wbg, 2021 (ISBN 978-3-534-40600-5)
- Sauter, M.: Grundkurs Mobile Kommunikationssysteme. 2. Auflage. Wiesbaden. Vieweg & Sohn Verlag, 2006. (ISBN 978-3-8348-0199-9)
- Schmidt, J.; Klüver, C.; Klüver, J.: Programmierung naturanaloger Verfahren. 1. Auflage. Wiesbaden. Vieweg+Teubner Verlag, 2010. (ISBN 978-3-8348-0822-6)
- Schnellenbach-Held, M.; Karczewski, B.; Kühn, O.: Intelligente Brücke - Machbarkeitsstudie für ein System zur Informationsbereitstellung und ganzheitlichen Bewertung in Echtzeit für Brückenbauwerke. In: Brücke- und Ingenieurbau Heft B 105, Seite: 1-128. Hrsg.: Bundesanstalt für Straßenwesen. 2014. (ISBN 978-3-95606-090-8)
- Schüttler, T.: Relativistische Effekte bei der Satellitennavigation. Wiesbaden. Springer Vieweg, 2018. (ISBN 978-3-658-22160-7)
- Stöckl, R.; Hofstadler, C.: Neuronale Netze im Baubetrieb und in der Bauwirtschaft – Systematische Modellierung und Implementierung. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. Wiesbaden. Springer Vieweg, 2021. (ISBN 978-3-658-34106-0)
- Sundermeier, M.; Beidersandwich, P.; Theuring, F.: Ökonomische Potenziale von Building Information Modeling (BIM) im Spannungsfeld von Branchenstruktur und Beschaffungspraxis. In: Agile Digitalisierung im Baubetrieb – Grundlagen, Innovationen, Disruptionen und Best Practices. Hrsg.: Hofstadler, C.; Motzko, C. Wiesbaden. Springer Vieweg, 2021. (ISBN 978-3-658-34106-0)
- Tamm, G.; Tribowski, C.: RFID. Informatik im Fokus. Hrsg.: Günther, O.; Karl, W.; Lienhart, R.; Zeppenfeld, K. Berlin Heidelberg. Springer-Verlag, 2010. (ISBN 978-3-642-11459-5)
- Werner, M.: Nachrichtentechnik. 7. Auflage. Wiesbaden. Vieweg+Teubner Verlag, 2010. (ISBN 978-3-8348-095-6)
- Wittpahl, V.: Künstliche Intelligenz Technologie | Anwendung | Gesellschaft. Berlin. Springer Vieweg, 2019. (ISBN 978-3-662-58041-7)

## 8.2 Zeitschriften- und Fachartikel

- Aidan, I. A.; Al-Jeznawi, D.; Al-Zwaniy, F. M. S.: Predicting Earned Value Indexes in Residential Complexes' Construction Projects Using Artificial Neural Network Model. In: International Journal of Intelligent Engineering and Systems, Vol. 13, No. 4, Seite 248-259. 2020. (<https://doi.org/10.22266/ijies2020.0831.22>)
- Alaloul, W. S.; Liew, M. S.; Zawawi, N. A. W.; Mohammed, B. S.; Adamu, M.: An Artificial neural networks (ANN) model for evaluating construction project performance based on coordination factors. In: Cogent Engineering, Vol. 5, No. 1, Seite 1-18. 2018. (<https://doi.org/10.1080/23311916.2018.1507657>)
- AL-Zwainy, F. M. S.; Rasheed, H. A.; Ibraheem, H. F.: Development of the construction productivity estimation model using artificial neural network for finishing works for floors with marble. In: ARPN Journal of Engineering and Applied Sciences, Vol. 7, No. 6, Seite 714-722. 2012. (<https://www.researchgate.net/publication/288719846>)
- Arafa, M.; Alqedra, M.: Early Stage Cost Estimation of Buildings Construction Projects using Artificial Neural Network. In: Journal of Artificial Intelligence, Vol. 4, No. 1, Seite 63-75. 2011. (<https://doi.org/10.3923/jai.2011.63.75>)
- Athalye, A.; Engstrom, L.; Ilyas, A.; Kwok, K.: Synthesizing robust adversarial examples. In: arXiv, Version 3, Seite 1-19. 2018. (<https://arxiv.org/abs/1707.07397>)
- Ayhan, B. U.; Tokdemir, O. B.: Accident Analysis for Construction Safety Using Latent Class Clustering and Artificial Neural Networks, In: Journal of Construction Engineering and Management, Vol. 146, No. 3, Seite 1-14. 2020. ([https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001762](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001762))
- Bala, K.; Bustani, S.; Waziri, B.: A computer-based cost prediction model for institutional building projects in Nigeria: An artificial neural networks approach. In: Journal of Engineering, Design and Technology, Vol. 12, No. 4, Seite 518-529. 2014. (<https://doi.org/10.1108/JEDT-06-2012-0026>)
- Bhokha, S.; Ogunlana, S. O.: Application of artificial neural network to forecast construction duration of buildings at the predesign stage. In: Engineering, Construction and Architectural Management, Vol. 6, No. 2, Seite 133 -144. 1999. (<http://dx.doi.org/10.1108/eb021106>)
- Berinato, S.: In Facebooks KI-Fabrik. In: Harvard Business manager 11/2017. Seite 36-43. 2017.
- Brilakis, I.; Park, M.: Continues localization of construction workers via integration of detection and tracking. In: Automation in Construction, Vol. 72, Seite 129-142. 2016. (<https://doi.org/10.1016/j.autcon.2016.08.039>)
- Brynjolfsson, E.; McAfee, A.: Von Managern und Maschinen. In: Harvard Business Manager. Digitalisierung. Edition 3/2018.
- Chandanshive, V. B.; Kambekar, A. R.: Estimation of Building Construction Cost Using Artificial Neural Networks. In: Journal of Soft Computing in Civil Engineering, Vol. 3, No. 1, Seite 91-107. 2019. (<http://dx.doi.org/10.22115/SCCE.2019.173862.1098>)

- Changwei, Y.; Zanghao, L.; Xueyan, G.; Wnying, Y.; Jing, J.; Liang, Z.: Application of BP Neural Network Model in Risk Evaluation of Railway Construction, In: Complexity, Vol. 2019, Article ID 2946158, Seite 1-12. 2019. (<https://doi.org/10.1155/2019/2946158>)
- Chaudhuri, N.; Gupta, G.; Wamsi, V.; Bose, I.: On the platform but will they buy? Predicting customers' purchase behavior using deep learning. In: Decision Support Systems, Vol. 149, ID 11362, Seite 1-10. 2021. (<https://doi.org/10.1016/j.dss.2021.113622>)
- Choi, B.; Lee, J. W.; Lee, J. J.; Park, K. T.: A Hierarchical Algorithm for Indoor Mobile Robot Localization Using RFID Sensor Fusion. In: IEEE Transactions on industrial electronics, Vol. 58, No. 6, Seite 2226-2235. 2011. (<https://doi.org/10.1109/TIE.2011.2109330>)
- Chua, D. K. H.; Kog, Y. C.; Loh, P. K.; Jaselskis, E. J.: Model for Construction Budget performance - Neural Network Approach. In: Journal of Construction Engineering and Management, Vol. 123, Nr. 3, Seite 214-222. 1997. ([https://doi.org/10.1061/\(ASCE\)0733-9364\(1997\)123:3\(214\)](https://doi.org/10.1061/(ASCE)0733-9364(1997)123:3(214)))
- Cybenko, G.: Approximation by superpositions of a sigmoidal function. In: Mathematics of Control, Signals, and Systems, Vol. 2, No. 4, Seite 303-314. 1989.
- Darko, A.; Chan, A.; Adabre, M.; Edwards, D.; Hosseini, R.; Ameyaw, E.: Artificial intelligence in the AEC industry: Scientometric analysis and visualization of research activities. In: Automation in Construction, Vol. 112, ID 103081, Seite 1-19. 2020. (<https://doi.org/10.1016/j.autcon.2020.103081>)
- Dikmen, S. U.; Sonmez, M.: An artificial neural networks model for the estimation of formwork labour. In: Journal of engineering and management, Vol. 17, No. 3, Seite 340-347. 2011. (<https://doi.org/10.3846/13923730.2011.594154>)
- Dimitriou, L.; Marinelli, M.; Fragkakis, N.: Early Bill-of-Quantities Estimation of Concrete Road Bridges: An Artificial Intelligence-Based Application. In: Public Works Management & Policy, Vol. 23, No. 2, Seite 127-149. 2018. (<https://doi.org/10.1177/1087724X17737321>)
- Du, M.; Jing, C.; Du, M.: Tag location method integrating GNSS and RFID technology. In: The Journal of Global Positioning Systems, Vol. 14, No. 2, Seite 1-6. 2016. (<https://doi.org/10.1186/s41445-016-0002-8>)
- Ebrahimi, S.; Raoufi, M.; Fayek, A. R.: Framework for Integrating an Artificial Neural Network and a Genetic Algorithm to Develop a Predictive Model for Construction Labor Productivity, In: Construction Research Congress 2020, Seite 58-66. 2020. (<https://doi.org/10.1061/9780784482865.007>)
- Elbeltagi, E.; Hosny, O.; Abdel-Razek, R.; El-Fitory, A.: Conceptual Cost Estimate of Libyan Highway Projects Using Artificial Neural Network, In: International Journal of Engineering Research and Applications, Vol. 4, No. 8, Seite 55-66. 2014. (<https://core.ac.uk/download/pdf/25787395.pdf>)
- El-Kholy, A. M.: Towards The Development of an Index to Measure the Performance of Multi-Productivity Areas. In: International Journal of Engineering Research And Application, Vol. 6, No. 7, Seite 1-14. 2016. ([http://www.ijera.com/papers/Vol6\\_issue7/Part%20-4/A06070401014.pdf](http://www.ijera.com/papers/Vol6_issue7/Part%20-4/A06070401014.pdf))

- El-Sawalhi, N.; Hajar, J. A.: Development of Awarding System for Construction Contractors in Gaza Strip Using Artificial Neural Network (ANN). In: *Journal of Construction Engineering and Project Management*, Vol. 6, No. 3, Seite 1-7. 2016. (<https://doi.org/10.6106/JCEPM.2016.6.3.001>)
- El-Sawy, I.; Hosny, H.; Razek, M. A.: A Neural Network Model for Construction Projects Site Overhead Cost Estimating in Egypt. In: *International Journal of Computer Science Issues*, Vol. 8, No. 3, Seite 273-283. 2011. (<https://arxiv.org/abs/1106.1570v1>)
- Esteva, A.; Kuprel, B.; Novoa, R. A.; Ko, J.; Swetter, S. M.; Blau, H. M.; Thrun, S.: Dermatologist-level classification of skin cancer with deep neural networks. In: *Nature*, Vol. 542, No. 7639, Seite 115-118. 2017. (<https://doi.org/10.1038/nature21056>)
- Ezeldin, A.; Sharara, L.: Neural Networks for Estimating the Productivity of Concreting Activities. In: *Journal of Construction Engineering and Management*, Vol. 132, No. 6, Seite 650-656. 2006. ([https://doi.org/10.1061/\(ASCE\)0733-9364\(2006\)132:6\(650\)](https://doi.org/10.1061/(ASCE)0733-9364(2006)132:6(650)))
- Fan, S.-L.; Yeh, I.-C.; Chi, W.-S.: Improvement in Estimating Durations for Building Projects Using Artificial Neural Network and Sensitivity Analysis. In: *Journal of Construction Engineering and Management*, Vol. 147, No. 7, Seite 1-9. 2021. ([https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0002036](https://doi.org/10.1061/(ASCE)CO.1943-7862.0002036))
- Ferreira, R. P.; Martiniano, A.; Napolitano, D.; Farias, E. B. P.; Sassi, R. J.: Artificial Neural Network and their Application in the Prediction of Absenteeism at Work, In: *International Journal of Recent Scientific Research*, Vol. 9, No. 1, Seite 23332-23334. 2018. (<http://dx.doi.org/10.24327/ijrsr>)
- Garcia de Soto, B.; Adey, B. T.: Preliminary Resource-based Estimates Combining Artificial Intelligence Approaches and Traditional Techniques. In: *Procedia Engineering* Vol. 164, Seite 261-268. 2016. (<https://doi.org/10.1016/j.proeng.2016.11.618>)
- Gardner, B. J.; Gransberg, D. D.; Rueda J. A.: Stochastic Conceptual Cost Estimation of Highway Projects to Communicate Uncertainty Using Bootstrap Sampling, In: *ASCE – ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, Vol. 3, No. 3, Seite 1-9. 2017. (<https://doi.org/10.1061/AJRUA6.0000895>)
- Golizadeh, H.; Sadeghifam, A. N.; Aadal, H.; Majid, M. Z. A.: Automated tool for predicting duration of construction activities in tropical countries. In: *KSCCE Journal of Civil Engineering*, Vol. 20, No. 1, Seite 12-22. 2016. (<https://doi.org/10.1007/s12205-015-0263-x>)
- Golnaraghi, S.; Zangenemadar, Z.; Moselhi, O.; Alkass, S.: Application of Artificial Neural Network(s) in Predicting Formwork Labor Productivity, In: *Advanced in Civil Engineering*, Vol. 2019, Article ID 5972620, Seite 1-11. 2019. (<https://doi.org/10.1155/2019/5972620>)
- Gunduz, M.; Sahin, H. B.: An early cost estimation model for hydroelectric power plant projects using neural networks and multiple regression analysis. In: *Journal of Civil Engineering and Management*, Vol. 21, No. 4, Seite 470-477. 2015. (<https://doi.org/10.3846/13923730.2014.890657>)
- Günaydin, H. M.; Dogan, S. Z.: A neural network approach for early cost estimation of structural systems of buildings. In: *International Journal of*

- Project management, Vol. 22, No. 7, Seite 595-602. 2004. (<https://doi.org/10.1016/j.ijproman.2004.04.002>)
- Eykholt, K.; Evtimov, I.; Fernandes, E.; Li, B.; Rahmati, A.; Xiao, C.; Prakash, A.; Kohno, T.; Song, D.: Robust Physical-World Attacks on Deep Learning Visual Classification. In: arXiv, Version 5, Seite 1-11. 2018. (<https://arxiv.org/abs/1707.08945>)
- Haddad, E.: Construction Productivity Estimation Model Using Artificial Neural Network for Foundations Work in Gaya Strip Construction Sites. In: International Journal of Advanced Engineering Research and Science, Vol. 4, No. 7, Seite 50-62. 2017. (<https://dx.doi.org/10.22161/ijaers.4.7.9>)
- Heravi, G.; Eslamdoost, E.: Applying Artificial Neural Networks for Measuring and Predicting Construction-Labor Productivity. In: Journal of Construction Engineering and Management, Vol. 141, No. 10, Seite 1-11. 2015. ([https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001006](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001006))
- Hola, B.; Schabowicz, K.: Estimation of earthworks execution time cost by means of artificial neural networks. In: Automation in Construction, Vol. 19, No. 5, Seite 570-579. 2010. (<https://doi.org/10.1016/j.autcon.2010.02.004>)
- Haberfellner, R.; Stelzmann, E.: Systems Engineering: neu überdacht. In: WINGbusines, 3/08, Seite 18-25. 2008.
- Hakami, W.; Hassan, A. : Preliminary Construction Cost Estimate in Yemen by Artificial Neural Network, In: Baltic Journal of Real Estate Economics and Construction Management, Vol. 7, No. 1, Seite 110-122. 2019. (<https://doi.org/10.2478/bjreecm-2019-0007>)
- Hong, Y.; Hamman, A. W. A.; Akbarnezhad, A.; Arashpour, M.: A neural network approach to predicting the net costs associated with BIM adoption, In: Automation in Construction, Vol. 119, Seite 1-16. 2020. (<https://doi.org/10.1016/j.autcon.2020.103306>)
- Hornik, K.; Stinchcombe, M., White, H.: Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. In: Neural networks, Volume 3, Issue 5, Seite 551-560. 1990.
- Hyari, A. H.; Al-Daraiseh, A.; El-Mashaleh, M.: Conceptual Cost Estimation Modul for Engineering Services in Public Construction Projects. In: Journal of Management in Engineering, Vol. 32, No. 1, Seite 1-9. 2016 ([https://doi.org/10.1061/\(ASCE\)ME.1943-5479.0000381](https://doi.org/10.1061/(ASCE)ME.1943-5479.0000381))
- Juszczczyk, M.; Lesniak, A.: Modelling Construction Site Cost Index Based on Neural Network Ensembles. In: Symmetry, Vol. 11, No. 3, Seite 1-18. 2019. (<https://doi.org/10.3390/sym11030411>)
- Juszczczyk, M.; Lesniak, A.; Zima, K.: ANN Based Approach for Estimation of Construction Costs of Sports Fields. In: Complexity, Vol. 2018, Article ID 7952434, Seite 1-11. 2018. (<https://doi.org/10.1155/2018/7952434>)
- Juszczczyk, M.; Zima, K.; Lelek, W.: Forecasting of sports fields construction costs aided by ensembles of neural networks. In: Journal of Civil Engineering and Management, Vol. 25, No. 7, Seite 715-729. 2019. (<https://doi.org/10.3846/jcem.2019.10534>)
- Karatas, A.; Al-Sharif, S.: Schedule and Cost Forecasting Model for Nuclear Power Plant Projects, In: Construction Research Congress 2020, Seite 721-729. 2020. (<https://doi.org/10.1061/9780784482889.076>)

- Kareem, G.: Productivity estimation model for bricklayer in construction projects using Neural Network. In: *Al-Qadisiyah Journal for Engineering Sciences*, Vol. 9, No. 2, Seite 183-199. 2016. (<https://qu.edu.iq/journaleng/index.php/JQES/article/view/454>)
- Kassem, M.; Mahamedi, E.; Rogage, K.; Duffy, K.; Huntingdon, J.: Measuring and benchmarking the productivity of excavators in infrastructure projects: A deep neural network approach. In: *Automation in Construction*, Vol. 124, ID 103532, Seite 1-15. 2021. (<https://doi.org/10.1016/j.autcon.2020.103532>)
- Lee, C. H.; Yoon H.: Medical big data: promise and challenges. In: *Kidney Research and Clinical Practice*, Vol. 36, No. 1, Seite 3-11. 2017. (<https://doi.org/10.23876/j.krcp.2017.36.1.3>)
- Lesniak, A.; Juszczak, M.: Prediction of site overhead costs with the use of artificial neural network based model. In: *Archives of Civil and Mechanical Engineering*, Vol. 18, No. 3, Seite 973-982. 2018. (<https://doi.org/10.1016/j.acme.2018.01.014>)
- Liu, L.; Liu, D.; Wu, H.; Wang, X.: The Prediction of Metro Shield Construction Cost Based on a Backpropagation Neural Network Improved by Quantum Particle Swarm Optimization. In: *Advances in Civil Engineering*, Vol. 2020, ID 6692130, Seite 1-15. 2020. (<https://doi.org/10.1155/2020/6692130>)
- Leung, A. W. T.; Tam, C. M.; Liu, D. K.: Comparative study of artificial neural networks and multiple regression analysis for predicting hoisting times of tower cranes. In: *Building and Environment*, Vol. 36, No. 4, Seite 457-467. 2001. ([https://doi.org/10.1016/S0360-1323\(00\)00029-9](https://doi.org/10.1016/S0360-1323(00)00029-9))
- Luu, V. T.; Kim, S. Y.: Neural Network Model for Construction Cost Prediction of Apartment Projects in Vietnam. In: *Korean Journal of Construction Engineering and Management*, Vol. 10, No.3, Seite 139-147. 2009. (<https://www.researchgate.net/publication/264113646>)
- Maya, R.; Hassan, B.; Hassan, A.: Develop an artificial neural network (ANN) model to predict construction projects performance in Syria. In: *Journal of King Sauda University-Engineering Sciences*, Seite 1-6. 2021 (<https://doi.org/10.1016/j.jksues.2021.05.002>)
- Matel, E.; Vahdatikhaki, F.; Hosseinyalamdary, S.; Evers, S.; Voordijk, H.: An artificial neural network approach for cost estimation of engineering services. In: *International Journal of Construction Management*, Seite 1-14. 2019. (<https://doi.org/10.1080/15623599.2019.1692400>)
- Meng, Z.; Li, Z.: RFID Tag as a Sensor - A Review on the Innovative Designs and Applications. In: *Measurement Science Review*, Vol. 16, No. 6, Seite 305-315. 2016. (DOI: 10.1515/msr-2016-0039)
- Mensah, I.; Adjei-Kumi, T.; Nani, G.: Duration determination for rural roads using the principal component analysis and artificial neural network. In: *Engineering, Construction and Architectural Management*, Vol. 23, No. 5, Seite 638-656. 2016. (<https://doi.org/10.1108/ECAM-09-2015-0148>)
- Mohammadfam, I.; Soltanzadeh, A.; Moghimbeigi, A.; Savareh, B. A.: Use of Artificial Neural Networks (ANNs) for the Analysis and Modeling of Factors That Affect Occupational Injuries in Large Construction Industries. In: *Electronic Physician*, Vol. 7, No. 7, Seite 1515-1522. 2015. (<http://dx.doi.org/10.19082/1515>)



- Mohammed, S. R.; Tofan, A. S.: Neural networks for estimating the ceramic productivity of walls. In: *Journal of Engineering*, Vol. 17, No. 2, Seite 200-217. 2011. (<https://www.researchgate.net/publication/330910761>)
- Muqueem, S.; Idrus, A.; Khamidi, M. F.; Ahmad, J. B.; Zakaria, S. B.: Construction Labor Production Rates Modeling using Artificial Neural Network. In: *Journal of Information Technology in Construction (ITcon)*, Vol. 16, Seite 713-726. 2011. (<http://www.itcon.org/2011/42>)
- Naik, G. M.; Radhika, V. S. B.: Time and Cost Analysis for Highway Road Construction Project Using Artificial Neural Networks. In: *KICEM Journal of Construction Engineering and Project Management*, Vol. 4, No. 3, Seite 26-31. 2015. (<https://doi.org/10.6106/JCEPM.2015.5.1.026>)
- Najafi, A.; Kong, R. T. L.: Productivity analysis of precast concrete operations by artificial neural networks. In: *ARNP Journal of Engineering and Applied Sciences*, Vol. 11, No. 17, Seite 10512-10521. 2016. ([http://www.arnjournals.org/jeas/resea-ch\\_papers/rp\\_2016/jeas\\_0916\\_4946.pdf](http://www.arnjournals.org/jeas/resea-ch_papers/rp_2016/jeas_0916_4946.pdf))
- Omotayo, T.; Bankole, A.; Olubunmi Olanipekun, A.: An Artificial Neural Network Approach to Predicting Most Applicable Post-Contract Cost Controlling Techniques in Construction Projects. In: *Applied Sciences*, Vol. 10, No. 15, Seite 1-24. 2020. (<https://doi.org/10.3390/app10155171>)
- Oshodi, O. S.; Ejohwomu, O. A.; Famakin, I. O.; Cortez, P.: Comparing univariate techniques for tender price index forecasting: Box-Jenkins and neural network model. In: *Construction Economics and Building*, Vol. 17, No. 3, Seite 109-123. 2017. (<http://dx.doi.org/10.5130/AJCEB.v17i3.5524>)
- Patel, D. A.; Jha, K. N.: Neural Network Model for the Prediction of Safe Work Behavior in Construction Projects. In: *Journal of Construction Engineering and Management*, Vol. 141, No. 1, Seite 1-13. 2015. ([https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000922](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000922))
- Pesic, S.; Tomic, M.; Ilovic, O.; Radovanovic, M.; Ivanovic, M.; Boskovic, M.: BLEMAT - Context Modeling and Machine Learning for Indoor Positioning Systems. In: *International Journal on Artificial Intelligence Tools*, Seite 1-25. 2018. (<https://doi.org/10.13140/RG.2.2.12686.61763>)
- Petroutsatou, K.; Georgopoulos, E.; Lambropoulos, S.; Pantouvakis, J. P.: Early Cost Estimation of Road Tunnel Construction Using Neural Networks. In: *Journal of Construction Engineering and Management*, Vol. 138, No. 6, Seite 679-687. 2012. ([https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000479](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000479))
- Petruseva, S.; Zujo, V.; Zileska-Pancovska, V.: Neural Network Prediction Model for Construction Project Duration. In: *International Journal of Engineering Research and Technology (IJERT)*, Vol. 2, No. 11, Seite 1646-1654. 2013. (<https://www.ijert.org/neural-network-prediction-model-for-construction-project-duration-2>)
- Pewdum, W.; Rujiranyong, T.; Sooksatra, V.: Forecasting final budget and duration of highway construction projects. In: *Engineering, Construction and Architectural Management*, Vol. 16, No. 6, Seite 544-557. 2009. (<https://doi.org/10.1108/09699980911002566>)
- Roth, F.; Kohler, K.: KI verändert auch das Risikomanagement. In: *IT-Security* 5/19. Seite 22-24. 2019

- Russakovsky, O.; Deng, J.; Su, H.; Krause, J.; Satheesh, S.; Ma, S.; Huang, Z.; Karpathy, A.; Khosla, A.; Bernstein, M.; Berg, A. C.; Fei-Fei, L.: ImageNet Large Scale Visual Recognition Challenge. In: arXiv, Version 3, Seite 1-43. 2015. (<https://arxiv.org/abs/1409.0575>)
- Schmitz, R.; Werner, R.; Rösch, T.: Künstliche Intelligenz in der Endoskopie: Neuronale Netze und maschinelles Sehen – Techniken und Perspektiven. In: Gastroenterol, Vol. 57, No. 6, Seite 767-780. 2019. (<https://doi.org/10.1055/a-0891-4032>)
- Shehab, T.; Farooq, M.; Sandhu, S.; Nguyen, T.H.; Nasr, E.: Cost Estimating Models for Utility Rehabilitation Projects: Neural Networks versus Regression. In: Journal of Pipeline Systems Engineering and Practice, Vol. 1, No. 3, Seite 104-110. 2010. ([https://doi.org/10.1061/\(ASCE\)PS.1949-1204.0000058](https://doi.org/10.1061/(ASCE)PS.1949-1204.0000058))
- Shen, X.; Chen, W.; Lu, M.: Wireless Sensor Networks for Resources Tracking at Building Construction Sites. In: Tsinghua science and technology, Vol. 13, No. S1, Seite 78-83. 2008. ([https://doi.org/10.1016/S1007-0214\(08\)70130-5](https://doi.org/10.1016/S1007-0214(08)70130-5))
- Shiha, A.; Dorra, E. M.; Nassar, K.: Neural Networks Model for Prediction of Construction Material Prices in Egypt Using Macroeconomic Indicators. In: Journal of Construction Engineering and Management, Vol. 146, No. 3, Seite 1-16. 2020. ([https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001785](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001785))
- Shirehjini, A. A. N.; Yassine, A.; Shirmohammadi, S.: Equipment Location in Hospitals Using RFID-Based Positioning System. In: IEEE Transactions on Information Technology in Biomedicine, Vol. 16, No. 6, Seite 1058-1069. 2012. (DOI: 10.1109/TITB.2012.2204896)
- Schütz, M.; Hofstadler, C.: Anwendung des Systems Engineering auf die Arbeitsvorbereitung von Bauprojekten. In: Bautechnik 89, Heft 11. Ernst & Sohn Verlag für Architektur und technische Wissenschaften GmbH & Co. KG, Berlin. 2012
- Sonmez, R.; Rowings, J. E.: Construction Labor Productivity Modeling with Neural Networks. In: Journal of Construction Engineering and Management, Vol. 124, No. 6, Seite 498-504. 1998. ([https://doi.org/10.1061/\(ASCE\)0733-9364\(1998\)124:6\(498\)](https://doi.org/10.1061/(ASCE)0733-9364(1998)124:6(498)))
- Stöckl, C.; Maass, C.: Optimized spiking neurons can classify images with high accuracy through temporal coding with two spikes. In: Nature Machine Intelligence, Vol. 3, Seite 230-238. 2021. (<https://doi.org/10.1038/s42256-021-00311-4>)
- Szegedy, C.; Vanhoucke, V.; Ioffe, S.; Shlens, J.: Rethinking the Inception Architecture for Computer Vision. In: arXiv, Version 3, Seite 1-10. 2015. (<https://arxiv.org/abs/1512.00567>)
- Tatari, O.; Kucukvar, M.: Cost premium prediction of certified green buildings: A neural network approach, In: Building and Environment, Vol. 46, No. 5, Seite 1081-1086. 2011. (<https://doi.org/10.1016/j.buildenv.2010.11.009>)
- Tijanac, K.; Car-Pušić, D; Šperac, M.: Cost estimation in road construction using artificial neural network. In: Neural Computing and Applications, Vol. 32, Seite 9343-9355. 2020. (<https://doi.org/10.1007/s00521-019-04443-y>)
- Ulrich, P.; Hill, W.: Wissenschaftstheoretische Grundlagen der Betriebswirtschaftslehre (Teil1). WiSt Heft 7. 1976

- Wahlster, W.: Künstliche Intelligenz: Digitales Verstehen. In: Naturwissenschaftliche Rundschau. 72. Jahrgang, Heft 9/10. Wissenschaftliche Verlagsgesellschaft Stuttgart. 2019
- Weng, S. F.; Reps, J.; Kai, J.; Garibaldi J. M.; Qureshi N.: Can machine-learning improve cardiovascular risk prediction using routine clinical data?. In: PLOS ONE, Vol. 12, No. 4, Seite 1-14. 2017. (<https://doi.org/10.1371/journal.pone.0174944>)
- Wilmot, C. G.; Mei, B.: Neural Network Modeling of Highway Construction Costs. In: Journal of Construction Engineering and Management, Vol. 131, No. 7, Seite 765-771. 2005. ([https://doi.org/10.1061/\(ASCE\)0733-9364\(2005\)131:7\(765\)](https://doi.org/10.1061/(ASCE)0733-9364(2005)131:7(765)))
- Yadav, R.; Vyas, M.; Vyas, V.; Agrawal, S.: Cost Estimation Model (Cem) for Residential Building using Artificial Neural Network. In: International Journal of Engineering Research & Technology (IJERT), Vol. 5, No. 1, Seite 430-432. 2016. (<https://doi.org/10.17577/IJERTV5IS010431>)
- Yeh, I-C.: Quantity Estimating of Building with Logarithm-Neuron Networks, In: Journal of Construction Engineering and Management, Vol. 124, No. 5, Seite 374-380. 1998. ([https://doi.org/10.1061/\(ASCE\)0733-9364\(1998\)124:5\(374\)](https://doi.org/10.1061/(ASCE)0733-9364(1998)124:5(374)))
- Xie, Q.; Luong, M.; Hovy, E.; Le, Q. V.: Self-training with Noisy Student improves ImageNet classification. In: arXiv, Version 2, Seite 1-16. 2020. (<https://arxiv.org/abs/1911.04252>)
- Zahurul, S.; Mariun, N.; Grozescu, I. V.; Hanamoto, T.; Mitani, Y.; Othman, M. L.; Hizam, H.; Abidin, I. Z.: Future strategic plan analysis for integrating distributed renewable generation to smart grid through wireless sensor network: Malaysia prospect. In: Renewable and Sustainable Energy Reviews, 53, Seite 978-992. 2016. (<https://doi.org/10.1016/j.rser.2015.09.020>)
- Zihang, D.; Hanxiao, L.; Quoc, L. V.; Mingxing, T.: CoAtNet: Marrying Convolution and Attention for All Data Sizes. In: arXiv, Version 2, Seite 1-18. 2021. (<https://arxiv.org/abs/2106.04803>)

### 8.3 Internetquellen

- Amazon: Künstliche Intelligenz. <https://aws.amazon.com/de/machine-learning/what-is-ai/>. Datum des Zugriffs: 03.08.2020
- Bundesnetzagentur: RFID, das kontaktlose Informationssystem. <https://emf3.bundesnetzagentur.de/pdf/RFID-BNetzA.pdf>. Datum des Zugriffs 19.05.2020
- Duden: Sensor. <https://www.duden.de/rechtschreibung/Sensor>. Datum des Zugriffs: 08.05.2020
- Duden: Intelligenz. <https://www.duden.de/rechtschreibung/Intelligenz>. Datum des Zugriffs: 03.08.2020
- Elektronik Kompendium: Übertragungsmedium. <https://www.elektronik-kompendium.de/sites/kom/0211192.htm>. Datum des Zugriffs: 24.06.2020

- Fraunhofer IPMS: Mit RFID-Sensorik in die Cloud. [https://www.silicon-saxony.de/fileadmin/user\\_upload/RFID-Seite/RFID-Sensorik-d\\_Web.pdf](https://www.silicon-saxony.de/fileadmin/user_upload/RFID-Seite/RFID-Sensorik-d_Web.pdf). Datum des Zugriffs: 29.05.2020
- FU Berlin: Grundlagen der Graphentheorie: <http://www.inf.fu-berlin.de/lehre/WS08/mafi1/skript5.pdf>. Datum des Zugriffs: 21.08.2020
- Heyer, G.: Teilgebiete der Informatik. Universität Leipzig. <https://www.informatik.uni-leipzig.de/lehre/Heyer9900/kap1/sld013.htm>. Datum des Zugriffs: 02.07.2020
- Hildesheim, W.; Scheunert, S.: Ask Mercedes: Chatbot statt Betriebsanleitung. <https://www.ibm.com/de-de/blogs/think/2017/11/30/ask-mercedes-chatbot-statt-betriebsanleitung/>. Datum des Zugriffs: 03.04.2020
- <https://elainnovation.com/en/catalogue/blue-puck-id-en/>. Datum des Zugriffs: 14.12.2021
- <https://teltonika-mobility.com/product/worker-badge-plus/#features>. Datum des Zugriffs: 14.10.2021
- [https://wiki.teltonika-mobility.com/view/GH5200\\_First\\_Start](https://wiki.teltonika-mobility.com/view/GH5200_First_Start). Datum des Zugriffs: 14.12.2021
- <https://www.br.de/kultur/pre-crime-predictive-policing-bayerische-polizei-verbrechen-verhindern-100.html>. Datum des Zugriffs: 18.12.2021
- <https://www.gpstraquer.com/en/wg-1030/>. Datum des Zugriffs: 14.10.2021
- <https://www.labsix.org/physical-objects-that-fool-neural-nets/>. Datum des Zugriffs: 22.06.2020
- <https://www.eff.org/ai/metrics>. Datum des Zugriffs: 22.06.2020
- <https://www.de.digital/DIGITAL/Navigation/DE/Lagebild/Indikatorentool/indikatorentool.html>. Datum des Zugriffs: 14.11.2021
- IBM Deutschland: IBM Watson – Anwendungsbeispiele 2019. [https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=2ahUKewiYz\\_7MvoAhXttYsKHaZnCywQFjAAegQIBhAB&url=https%3A%2F%2Fwww-03.ibm.com%2Fpress%2Fde%2Fde%2Fattachment%2F54981.wss%3FfileId%3DATTACH\\_FILE1%26fileName%3DIBM\\_Watson\\_Anwendungsbeispiele\\_2019.pdf&usq=AOvVaw2i5-jXw40eFVUb4Y7uCyZT](https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=2ahUKewiYz_7MvoAhXttYsKHaZnCywQFjAAegQIBhAB&url=https%3A%2F%2Fwww-03.ibm.com%2Fpress%2Fde%2Fde%2Fattachment%2F54981.wss%3FfileId%3DATTACH_FILE1%26fileName%3DIBM_Watson_Anwendungsbeispiele_2019.pdf&usq=AOvVaw2i5-jXw40eFVUb4Y7uCyZT). Datum des Zugriffs: 03.04.2020
- IDTechEx: <https://www.idtechex.com/de/research-report/rfid-forecasts-players-and-opportunities-2019-2029/700>. Datum des Zugriffs 19.05.2020
- IDTechEx: <https://www.idtechex.com/de/research-report/rfid-forecasts-players-and-opportunities-2018-2028/642>. Datum des Zugriffs 19.05.2020
- ImageNet: <http://www.image-net.org/challenges/LSVRC/2012/>. Datum des Zugriffs: 07.04.2020
- Keras: <https://keras.io/>. Datum des Zugriffs: 15.04.2020
- Kubota, T.: Stanford algorithm can diagnose pneumonia better than radiologists. <https://news.stanford.edu/2017/11/15/algorithm-outperforms-radiologists-diagnosing-pneumonia/>. Datum des Zugriffs: 06.04.2020
- Leica: [http://webarchiv.ethz.ch/geometh-data/downloads/GPSBasics\\_de.pdf](http://webarchiv.ethz.ch/geometh-data/downloads/GPSBasics_de.pdf). Datum des Zugriffs: 22.07.2021
- Langenscheidt, Wörterbuch: <https://de.langenscheidt.com/latein-deutsch/sensus>. Datum des Zugriffs: 08.05.2020

- Lexikon der Mathematik: Signumfunktion. online: <https://www.spektrum.de/lexikon/mathematik/signumfunktion/9749>. Datum des Zugriffs: 25.08.2020
- LoRaWan: <https://www.lora-wan.de/>. Datum des Zugriffs: 29.07.2021
- McKinsey: Smartening up with Artificial Intelligence (AI) - What's in it for Germany and its Industrial Sector?. <https://www.mckinsey.com/~media/McKinsey/Industries/Semiconductors/Our%20Insights/Smartening%20up%20with%20artificial%20intelligence/Smartening-up-with-artificial-intelligence.ashx>. Datum des Zugriffs: 02.04.2020
- Raghu, D.: RFID 2018-2028: RAIN and NFC Market Status, Outlook and Innovations. [https://rainrfid.org/wp-content/uploads/2018/03/IDTechEx-RFID-March-\\_Distribute.pdf](https://rainrfid.org/wp-content/uploads/2018/03/IDTechEx-RFID-March-_Distribute.pdf). Präsentationsfolien. Datum des Zugriffs: 19.05.2020.
- Rey, G. D.; Beck, F.: Neuronale Netze. <http://www.neuronalesnetz.de/>. Datum des Zugriffs: 13.08.2020
- RFID Grundlagen Das RFID Informationsportal: RFID Reichweite. <https://www.rfid-grundlagen.de/reichweite.html>. Datum des Zugriffs: 19.05.2020
- RFID Grundlagen Das RFID Informationsportal: RFID Frequenzen. <https://www.rfid-grundlagen.de/frequenzen.html>. Datum des Zugriffs: 19.05.2020
- Summers, R. M.: NIH Clinical Center provides one of the largest publicly available chest x-ray datasets to scientific community. <https://www.nih.gov/news-events/news-releases/nih-clinical-center-provides-one-largest-publicly-available-chest-x-ray-datasets-scientific-community>. Datum des Zugriffs: 06.04.2020
- TensorFlow: <https://www.tensorflow.org/>. Datum des Zugriffs: 15.04.2020
- Wölbert, C.: Das sind die Stars auf der Agritechnica. In: Hannoversche Allgemeine. am 17.11.2017. <https://www.haz.de/Nachrichten/Wirtschaft/Niedersachsen/Das-sind-die-Stars-auf-der-Agritechnica-2017-in-Hannover>. Datum des Zugriffs: 01.04.2020
- Youtube: Google Duplex: A.I. Assistant Calls Local Businesses To Make Appointments. <https://www.youtube.com/watch?v=D5VN56jQMWM>. Datum des Zugriffs: 03.04.2020
- Melski, A.: Grundlagen und betriebswirtschaftliche Anwendung von RFID. Arbeitsbericht Nr. 11/2006 Hrsg.: Schumann, M. Institut für Wirtschaftsinformatik, Georg-August-Universität Göttingen. Online unter: [http://webdoc.sub.gwdg.de/ebook/serien/lm/arbeitsberichte\\_wi2/2006\\_11.pdf](http://webdoc.sub.gwdg.de/ebook/serien/lm/arbeitsberichte_wi2/2006_11.pdf). Datum des Zugriffs: 19.05.2020
- ZigBee Alliance: <https://zigbeealliance.org/solution/zigbee/>. Datum des Zugriffs: 26.06.2020

#### 8.4 Masterarbeiten und Dissertationen

- Binder, F.: Ereignisbasierte Steuerung baulogistischer Prozesse mit Echtzeit-Ortungssystemen. Dissertation. Darmstadt. Schriftenreihe des Instituts für Baubetrieb, D68. Hrsg: Motzko, C. Technischen Universität Darmstadt. 2014. (ISBN 978-3-941925-19-9)

- Dehner, H.-U.: Interferenzuntersuchungen für inkohärente Multiband Ultra-Breitband (UWB) Übertragung. Dissertation. Karlsruhe. Forschungsberichte aus dem Institut für Nachrichtentechnik des Karlsruher Instituts für Technologie, Band 27. Hrsg: Jondral, F. Karlsruher Instituts für Technologie. 2012. (ISSN 1433-3821)
- Fasching, M.: Ausarbeitung von Baustellendaten – Bewehrungsarbeiten. Masterprojekt. Graz. Institut für Baubetrieb und Bauwirtschaft der Technischen Universität Graz. 2020.
- Konegger, M.: Automatisches Erfassen anfallender Lohnstunden mittels globaler Navigationssatellitensysteme und BLE-Beacons. Masterarbeit. Graz. Institut für Baubetrieb und Bauwirtschaft der Technische Universität Graz. 2021.
- Kummer, M.: Aggregierte Berücksichtigung von Produktivitätsverlusten bei der Ermittlung von Baukosten und Bauzeiten. Dissertation. Graz. Institut für Baubetrieb und Bauwirtschaft der Technischen Universität Graz. 2015.
- Mehr, O.: Polysensorale Bauprozessidentifikation durch kognitive Systeme. Dissertation. Darmstadt. Schriftenreihe des Instituts für Baubetrieb, D58. Hrsg: Motzko, C. Technischen Universität Darmstadt. 2012. (ISBN 978-3-941925-09-0)
- Pawlowski, D.: Tracking von Bauarbeitern auf Baustellen zur Assistenz von Kranführern. Masterarbeit. Bochum. Lehrstuhl für Informatik im Bauwesen an der Ruhr-Universität Bochum. 2019.
- Stöckl, R.: Einsatzmöglichkeiten von neuronalen Netzen im Baubetrieb und in der Bauwirtschaft. Masterarbeit. Graz. Institut für Baubetrieb und Bauwirtschaft an der Technischen Universität Graz. 2018.

## 8.5 Tagungs- und Kongressbeiträge

- Ahiaga-Dagbui, D. D; Smith, S. D.: Neural networks for modelling the final target cost of water projects. Konferenz: Procs 28th Annual ARCOM Conference. Hrsg.: Smith, S.D. Seite 307-316. Edinburgh, United Kingdom. Association of Researchers in Construction Management, 2012. (<https://doi.org/10.13140/2.1.3660.6402>)
- Bouet, M.; Santos, A.: RFID Tags: Position Principles and Localisation Techniques. Konferenz: 2008 1st IFIP Wireless Days. Seite 1-5. Dubai, United Arab Emirates. IEEE, 2008. (<https://doi.org/10.1109/WD.2008.4812905>)
- Dardouri, S.; Dakhli, Z.; Rabenantoandro, A. Z.; Lafhaj, Z.: RFID-Integrated Software Platform for Construction Materials Management. Konferenz: Modular and Offsite Construction (MOC) Summit Proceedings. Seite 479-487. Banff, Alberta, Canada. 2019. (<https://doi.org/10.29173/mocs129>)
- Els Shakour, H. A.; Abdel-Razek, R. H.; Abdel-Samad, D.: Predicting Production Rate of Pouring Ready-Mixed Concrete Using Neural Networks. Konferenz: Sixth Alexandria International Conference on Structural and Geotechnical Engineering (AICSGE). Vol.1, Seite 15-30. Structural Engineering Dept. Faculty of Engineering Alexandria University Alexandria, 2007. (<https://www.researchgate.net/publication/260594402>)

- Fernandes, L. L. A.; Rocha, M. J.; Costa, D. B.: Prediction of environmental performance indicators for construction sites based on artificial Neural Networks, Konferenz: Proc. 27th Annual Conference of the International Group for Lean Construction (IGLC) Hrsg.: Pasquire, C.; Hamzeh, F.R. Seite 1413-1424. Dublin, Ireland. IGLC, 2019. (<https://doi.org/10.24928/2019/0248>)
- Hofstadler, C.: Multisystemic modeling to improve forecast accuracy in construction management. Konferenz: 10th International Structural Engineering and Construction Conference, ISEC 2019, Seite 1-6. Chicago, USA. ISEC Press, 2019. (ISBN: 9780996043762)
- Hofstadler, C.; Kummer, M.: Risiken und Chancen der Mischpreiskalkulation. Konferenz: Tagungsband – 13. Grazer Baubetriebs- und Bauwirtschafts-symposium – Preisermittlung und Vergabe in der Bauwirtschaft – Baubetriebliche, bauwirtschaftliche und rechtliche Aspekte. Hrsg.: Heck, D.; Mauerhofer, G.; Hofstadler, C. Seite 49-92. Graz, Österreich. Verlag der Technischen Universität Graz, 2015. (ISBN 978-3-85125-385-9)
- Issa, R. R. A.: Application of Artificial Neural Networks to predicting construction material prices. Konferenz: Proceedings of the 8th International Conference on Computing in Civil and Building Engineering (ICCCBE-VIII) 2000. Hrsg.: Fruchter, R.; Peña-Mora, F.; Roddis, W.M.K. Seite 1129-1132. Stanford, California. ASCE, 2000. ([https://doi.org/10.1061/40513\(279\)147](https://doi.org/10.1061/40513(279)147))
- Lenz, L. T.; Weist, K. C.; Winkels, J.; Graefenstein, J.; Gralla, M.: Multi-criteria decision support in construction management: life cycleoriented investigation of the economic efficiency. Konferenz: 2021 European Conference on Computing in Construction, Seite 132-139. Online eConference, 2021. (<http://dx.doi.org/10.35490/EC3.2021.147>)
- Liu, J.; Chen, J.; Tang, K.: A Method for Estimation of the On-Site Construction Waste Quantity of Residential Projects. Konferenz: International Conference on Construction and Real Estate Management 2018. Hrsg: Wang, Y. et al. Seite 225-231. Charleston, South Carolina. ASCE, 2018. (<https://doi.org/10.1061/9780784481738.027>)
- Muqueem, S.; Idrus, A. B.; Khamidi, M. F.; Zakaria, S. B.: Development of Construction Labor Productivity Estimation Model using Artificial Neural Network. Konferenz: 2011 National Postgraduate Conference. Seite 1-6. Perak, Malaysia. IEEE, 2011. (<https://doi.org/10.1109/NatPC.2011.6136353>)
- Muqueem, S.; Idrus, A. B.; Khamidi, M. F.; Zakaria, S. B.: Prediction Modeling of Construction Labor Production Rates using Artificial Neural Network. Konferenz: 2011 2nd International Conference on Environmental Science and Technology, IPCBEE. Vol.6, Seite 32-26. Singapore. IACSIT Press, 2011. (<https://www.academia.edu/31203253>)
- Norr dine, A.; Motzko, C.: An internet of things based transportation cart for smart construction site. Konferenz: 2020 International Conferences on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData) and IEEE Congress on Cybermatics (Cybermatics), Seite 160-167. Rhodos, Griechenland. IEEE, 2020. (ISBN 978-1-7281-7648-2)

- Norrdine, A.; Kasmi, Z.; Ahmed, K.; Motzko, C.; Schiller, J.: MQTT-Based Surveillance System of IoT Using UWB Real Time Location System. Konferenz: 2020 International Conferences on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData) and IEEE Congress on Cybermatics (Cybermatics), Seite 216-221. Rhodos, Griechenland. IEEE, 2020. (ISBN 978-1-7281-7648-2)
- Varga, A. K.: ZigBee based wireless sensor networks. Konferenz: Proceedings of the International scientific conference on advances in mechanical engineering, Seite 173-177. Hrsg.: Bodzas, S.; Mankovits, T. Debrecen, Hungary. University of Debrecen, 2014. (ISBN 978-963-473-751-3)
- Wang, X.; Peng, Y.; Lu, L.; Lu, Z.; Bagheri, M.; Summers, R. M.: ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases. Konferenz: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Seite 2097-2106. Honolulu, HI, USA. IEEE, 2017. (<https://doi.org/10.1109/CVPR.2017.369>)

## 8.6 Vorträge, Präsentationen, Workshop- und Vorlesungsunterlagen

- Banse, G.: Idee-Entwurf-Gestaltung I. Der (schwierige) Weg zum (technischen) Neuen I. Inter-University Research Seminar. Technische Universität Graz. 04.12.2019.
- Banse, G.: Idee-Entwurf-Gestaltung II. Der (schwierige) Weg zum (technischen) Neuen II. Inter-University Research Seminar. Technische Universität Graz. 04.12.2019.
- Hofstadler, C.: Systematisches Denken und Handeln, Wissenschaftliches Arbeiten. Vorlesungsfolien von Baubetrieb FS. Technische Universität Graz. 2017.
- Hofstadler, C.: Einleitung und Grundlagen. Vorlesungsfolien von Chancen- und Risikomanagement in der Bauwirtschaft, Technische Universität Graz. 2018.
- Hofstadler, C.: Grundlagen zur Projekt- und Baustellenanalyse. Vorlesungsfolien von Baubetrieb und Exkursion, Technische Universität Graz. 2020
- Hofstadler, C.: Baubetriebliche und bauwirtschaftliche Bedeutung. Vorlesungsfolien von Produktivität im Baubetrieb. Technische Universität Graz. 2020.
- Hofstadler, C.: Grundlagen zur Produktivität im Baubetrieb. Vorlesungsfolien von Produktivität im Baubetrieb, Technische Universität Graz. 2021
- Mischke, A.: Skript Teil 8: GNSS. Vorlesung zur Veranstaltung Vermessungskunde. Hochschule Bochum. 2020



## 8.7 Dokumentationen und Interviews

Interview mit Widl, A.; Fuchs, R.; Steckenreiter, T.; Knapp, P.: Best of both Worlds. In: Industriearmaturen & Dichtungstechnik 4/2017, Seite 1-6. [https://www.samsongroup.com/fileadmin/user\\_upload/SAM%20DIGITAL/interview\\_industriearmaturen\\_4-2017.pdf](https://www.samsongroup.com/fileadmin/user_upload/SAM%20DIGITAL/interview_industriearmaturen_4-2017.pdf). Datum des Zugriffs: 08.04.2020.

Wolff, T.; Yogeshwar, R.: Der große Umbruch. Doku vom Westdeutschen Rundfunk. In: ORF2, Eco Spezial am 09.04.2020 um 22:30-23:05. 2020.

## 8.8 Anwenderinformationen, Produktbeschreibung und Normen

DIN ISO 5725-1:1997-11: Genauigkeit (Richtigkeit und Präzision) von Meßverfahren und Meßergebnissen – Teil 1: Allgemeine Grundlagen und Begriffe

Ela innovation: Product sheet – IDF25240E. Technical specification. <https://elainnovation.com/wp-content/uploads/2020/10/FP-Blue-PUCK-ID-07B-EN.pdf>. Datum des Zugriffs: 31.01.2022.

ÖBB-Infrastruktur AG: Koralmbahn Graz - Klagenfurt, Baulos 50.3, Bahnhof Lavanttal, Baubeschreibung.

Palisade Corporation: Benutzerhandbuch, NeuralTools. Neuralnetz-Add-In für Microsoft Excel. Version 7, 2015.

ZigBee Alliance: ZigBee Specification. ZigBee Document 05-3474-21. <https://zigbeealliance.org/wp-content/uploads/2019/11/docs-05-3474-21-0csg-zigbee-specification.pdf>. Datum des Zugriffs: 26.06.2020.

## Abkürzungsverzeichnis

Abb.	Abbildung(en)
AoA	Angle of Arival
AG	Auftraggeber
AN	Auftragnehmer
AW <sub>BT</sub>	Aufandswert der Betonierarbeiten [Std/m <sup>3</sup> ]
AW <sub>BW</sub>	Aufandswert der Bewehrungsarbeiten [Std/t]
AW <sub>S</sub>	Aufandswert der Schalarbeiten [Std/m <sup>2</sup> ]
AW <sub>STB</sub>	Gesamt-Aufandswert der Stahlbetonarbeiten [Std/m <sup>3</sup> ]
BLE	Bluetooth Low Energy
bw <sub>g,bwk</sub>	Bewehrungsgrad [t/m <sup>3</sup> ]
CDMA	Codemultiplexverfahren
DMS	Dehnungsmessung
FDMA	Frequenzmultiplexverfahren
Glg.	Gleichung(en)
GSM	Global System for Mobile Communications
GNSS	Globale Navigationssatellitensysteme
HF	Hochfrequenter Bereich
KI	Künstliche Intelligenz
LF	Niederfrequenter Bereich
Lfd. Nr.	Laufende Nummer
M. abs. F.	Mittlerer absoluter Fehler
MKF	Mehrkostenforderung
ML	Machine Learning
MW	Mittelwert
NTC	Negative Temperature Coefficient
PD <sub>oA</sub>	Phase Difference of Arrival
PPH	Projektphase
PTC	Positive Temperature Coefficient
Rel. F.	Relativer Fehler
RMS	Root Mean Squared (Wurzel aus der mittleren Quadratsumme)
SE	Systems Engineering
s <sub>g,bwk</sub>	Schalungsgrad [m <sup>2</sup> /m <sup>3</sup> ]
SIM	Subscriber Identity Module (Chipkarte für Mobiltelefone)
Std	Lohnstunde(n)
Stk	Stück
TDMA	Zeitmultiplexverfahren
TD <sub>oA</sub>	Time Difference of Arrival

TWR	Two Way Ranging
UHF	Ultrahochfrequenter Bereich
UWB	Ultra Breitband
z.B.	Zum Beispiel
2G	Zweite Generation (Mobilfunkstandard)

## Abbildungsverzeichnis

Abb. 1-1	Fehlerquote Bilderkennung.....	2
Abb. 1-2	Transformation von Verfügungswissen in Orientierungswissen .....	3
Abb. 1-3	Gliederung der Wissenschaft.....	5
Abb. 1-4	Hermeneutische Methode – Wissenswachstumsspirale .....	7
Abb. 1-5	Bestandteile eines Systems.....	8
Abb. 1-6	Vorgehensmodell Systems Engineering.....	9
Abb. 1-7	Ideensuchraum .....	10
Abb. 1-8	Einteilung der Erfindungen nach Eyth .....	10
Abb. 1-9	Gliederung der Arbeit.....	13
Abb. 2-1	Transformation von Verfügungswissen in Orientierungswissen .....	16
Abb. 2-2	Zeitliche Veränderung bei der Datenerhebung .....	16
Abb. 2-3	Neuronale Netze für die Transformation von Verfügungswissen in Orientierungswissen .....	17
Abb. 2-4	Multisystemische Hybridpyramide .....	18
Abb. 2-5	Kennzahlenarten.....	19
Abb. 2-6	Einteilung des maschinellen Lernens .....	22
Abb. 2-7	Schematischer Aufbau eines neuronalen Netzes.....	25
Abb. 2-8	Schematische Darstellung von Netzstrukturen.....	26
Abb. 2-9	Signumfunktion .....	29
Abb. 2-10	Lineare Aktivierungsfunktion mit oberer und unterer Schranke.....	30
Abb. 2-11	Schematische Darstellung einer sigmoiden Funktion .....	30
Abb. 2-12	Schematische Darstellung des Tangens-Hyperbolicus .....	31
Abb. 2-13	Schematische Vorgehensweise.....	39
Abb. 2-14	Fehlerverlauf des Testdatensatzes.....	40
Abb. 2-15	Fehlerverlauf der Validierungsfälle je Datensatz .....	41
Abb. 2-16	Fehlerverlauf der Trainings- und Validierungsfälle .....	43
Abb. 2-17	RMS-Fehlerverlauf der Validierungsfälle und des Testdatensatzes .....	43
Abb. 2-18	Mittlerer absoluter Fehlerverlauf der Testdaten und Validierungsfälle .....	44
Abb. 2-19	Testdaten außerhalb des Trainingsdatenbereiches .....	44
Abb. 2-20	Mittlerer absoluter Fehlerverlauf der Testdatenbereiche .....	45
Abb. 2-21	Fehlerverlauf des Testdatensatzes unter Berücksichtigung mit Abweichungen behafteter Trainingsdaten .....	46

Abb. 2-22	RMS-Fehler aus dem Testdatensatz und der Validierungsfälle .....	47
Abb. 2-23	Mittlerer absoluter Fehler des Testdatensatzes und der Validierungsfälle .....	47
Abb. 2-24	Fehlerverlauf Trainings- und Validierungsfälle.....	48
Abb. 2-25	Beginn des Datensatzes für die Aufwandswertprognose von Bewehrungsarbeiten .....	49
Abb. 2-26	Verteilung der Durchmesser der Längsbewehrung .....	49
Abb. 2-27	Verteilung des Gewichtes der Längsbewehrung .....	50
Abb. 2-28	Verteilung des Gewichtes der Bügelbewehrung .....	50
Abb. 2-29	Verteilung der Arbeitsgruppengröße.....	51
Abb. 2-30	Verteilung der Verringerung der Krankkapazitäten.....	51
Abb. 2-31	Verteilung der Temperatur .....	52
Abb. 2-32	Verteilung der täglichen Arbeitszeit .....	52
Abb. 2-33	Verteilung der Lichtverhältnisse.....	52
Abb. 2-34	Verteilung der Aufwandswerte der Bewehrungsarbeiten.....	53
Abb. 2-35	Fehlerverlauf der Trainings- und Validierungsfälle .....	54
Abb. 2-36	Verteilung der Aufwandswerte des Testdatensatzes.....	54
Abb. 2-37	Fehlerverlauf der Validierungs- und Testfälle .....	55
Abb. 2-38	Verteilung der Aufwandswerte des Testdatensatzes.....	55
Abb. 3-1	Allgemeine Herangehensweise für Prognosen oder Klassifizierungen im Bereich Supervised Learning.....	65
Abb. 3-2	Demonstrativer Aufbau eines Datensatzes.....	66
Abb. 3-3	Einfluss der Programmtiefe.....	67
Abb. 3-4	Projektphasen .....	69
Abb. 3-5	Auftraggeberseitige Anwendungsmöglichkeiten in PPH 1 und PPH 3 .....	71
Abb. 3-6	Auftraggeberseitige Anwendungsmöglichkeiten in PPH 4 und PPH 5 .....	72
Abb. 3-7	Auftragnehmerseitige Anwendungsmöglichkeiten in PPH 3.....	74
Abb. 3-8	Auftragnehmerseitige Anwendungsmöglichkeiten in PPH 4.....	77
Abb. 3-9	Produktionswürfel nach Hofstadler .....	80
Abb. 3-10	Einflüsse auf die Produktivität – demonstrative Darstellung.....	84
Abb. 3-11	Mögliche Input- und Outputparameter im Tunnelbau .....	86
Abb. 3-12	Einflussfaktoren für den Aufwandswert von Schalarbeiten .....	87
Abb. 3-13	Einflussfaktoren für den Aufwandswert von Bewehrungsarbeiten .....	88

Abb. 3-14	Einflussfaktoren für den Aufwandswert von Betnoierarbeiten .....	89
Abb. 3-15	Histogramm des Trainingsanteils .....	110
Abb. 3-16	Histogramm der Inputparameteranzahl .....	110
Abb. 3-17	Histogramm der Datenursprungsanzahl bei Projekten .....	111
Abb. 3-18	Histogramm der Neuronen bei einem Hidden-Layer .....	111
Abb. 3-19	Histogramm über die Datensatzgröße .....	112
Abb. 4-1	Wirkungsweise eines Sensors .....	116
Abb. 4-2	Verdeutlichung von genau durch präzise und richtig .....	118
Abb. 4-3	Datenrate und Reichweite ausgewählter Funktechnologien .....	123
Abb. 4-4	RFID-Komponenten .....	124
Abb. 4-5	Transpondereinteilung anhand der Energiequelle .....	125
Abb. 4-6	Einteilung anhand der Reichweite .....	127
Abb. 4-7	Trilateration und Triangulation .....	134
Abb. 4-8	Gliederung des Gesamtablaufes am Beispiel der Stahlbetonarbeiten .....	136
Abb. 4-9	Prinzip der Satellitenortung .....	138
Abb. 5-1	Überblick Bauvorhaben Lavanttal .....	146
Abb. 5-2	Grundriss der Schaltstation .....	147
Abb. 5-3	Schnitt der Schaltstation .....	147
Abb. 5-4	Schaltstation .....	148
Abb. 5-5	Working Gadget .....	149
Abb. 5-6	Anbringung BLE-Beacon .....	150
Abb. 5-7	Abmessungen BLE-Beacon .....	150
Abb. 5-8	Übersicht M2M-Plattform .....	151
Abb. 5-9	Visualisierung des zurückgelegten Weges .....	152
Abb. 5-10	Funktionsweise der Datenerhebung .....	154
Abb. 5-11	Prozess der Datenerhebung .....	155
Abb. 5-12	Berichterstellung- und Auswerteprozess .....	156
Abb. 5-13	GNSS-Genauigkeit bei der Errichtung der Innenwände .....	158
Abb. 6-1	Vorgehensweise zur Klassifizierung der Tätigkeiten .....	162
Abb. 6-2	Verteilung der Basisdatensatzvariablen in Abhängigkeit von Schalen, Bewehren und Betonieren .....	165
Abb. 6-3	Verteilung der Basisdatensatzvariablen in Abhängigkeit von Schalen, Bewehren und Betonieren .....	166
Abb. 6-4	Zufälliger Datensatz 1: Verteilung der einzelnen Parameter .....	169
Abb. 6-5	Zufälliger Datensatz 1: Auswirkungsanalyse .....	172

Abb. 6-6	Zufälliger Datensatz 2: Verteilung der einzelnen Parameter .....	174
Abb. 6-7	Zufälliger Datensatz 2: Auswirkungsanalyse .....	177
Abb. 6-8	Zufälliger Datensatz 3: Verteilung der einzelnen Parameter .....	178
Abb. 6-9	Zufälliger Datensatz 3: Auswirkungsanalyse .....	181
Abb. 6-10	Zufälliger Datensatz 4: Verteilung der einzelnen Parameter .....	183
Abb. 6-11	Zufälliger Datensatz 4: Auswirkungsanalyse .....	186
Abb. 6-12	Zufälliger Datensatz 5: Verteilung der einzelnen Parameter .....	187
Abb. 6-13	Zufälliger Datensatz 5: Auswirkungsanalyse .....	190
Abb. 6-14	5-80min-Datensatz: Verteilung der einzelnen Parameter .....	192
Abb. 6-15	5-80min-Datensatz: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze .....	194
Abb. 6-16	5-80min-Datensatz: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze .....	194
Abb. 6-17	Subdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	198
Abb. 6-18	Subdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	199
Abb. 6-19	Subdatensatz 1: Auswirkungsanalyse .....	202
Abb. 6-20	Testdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	204
Abb. 6-21	Testdatensatz 1: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	205
Abb. 6-22	Testdatensatz 1: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze .....	206
Abb. 6-23	Testdatensatz 1: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze .....	207
Abb. 6-24	Subdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	209
Abb. 6-25	Subdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	210
Abb. 6-26	Subdatensatz 2: Auswirkungsanalyse .....	213
Abb. 6-27	Testdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	214
Abb. 6-28	Testdatensatz 2: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	215
Abb. 6-29	Testdatensatz 2: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze .....	217

Abb. 6-30	Testdatensatz 2: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze .....	218
Abb. 6-31	Subdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	220
Abb. 6-32	Subdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	221
Abb. 6-33	Subdatensatz 3: Auswirkungsanalyse .....	224
Abb. 6-34	Testdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	226
Abb. 6-35	Testdatensatz 3: Verteilung der Parameter in Abhängigkeit von Schalen, Bewehren und Betonieren ....	227
Abb. 6-36	Testdatensatz 3: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze.....	229
Abb. 6-37	Testdatensatz 3: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der Tätigkeiten innerhalb der einzelnen Datensätze .....	229
Abb. 6-38	Gegenüberstellung der besten neuronalen Netze basierend auf den drei Datensätzen mit 10-, 20- und 30-minütigem Abbruchkriterium .....	231
Abb. 6-39	Tätigkeitsreduktion: Verteilung der Parameter in Abhängigkeit von Schalen und Betonieren .....	233
Abb. 6-40	Tätigkeitsreduktion: Verteilung der Parameter in Abhängigkeit von Schalen und Betonieren .....	234
Abb. 6-41	Tätigkeitsreduktion: Auswirkungsanalyse .....	236
Abb. 6-42	Testdatensatz 3: Prozentualer Anteil der falschen Prognosen in Abhängigkeit der einzelnen Datensätze .....	237
Abb. 6-43	Modellierungsprozess .....	238





## Tabellenverzeichnis

Tab. 2-1	Verteilung der Inputparameter .....	38
Tab. 2-2	Beginn eines Datensatzes .....	39
Tab. 2-3	Gegenüberstellung linearer Prädiktor und neuronales Netz .....	42
Tab. 2-4	Anzahl der Neuronen des besten Netzes je Datensatz ....	42
Tab. 2-5	Relativer Fehler außerhalb liegender Testdaten .....	45
Tab. 3-1	Tabellarische Übersicht der Publikationen – Teil 1 .....	105
Tab. 3-2	Tabellarische Übersicht der Publikationen – Teil 2 .....	106
Tab. 3-3	Tabellarische Übersicht der Publikationen – Teil 3 .....	107
Tab. 3-4	Tabellarische Übersicht der Publikationen – Teil 4 .....	108
Tab. 3-5	Tabellarische Übersicht der Publikationen – Teil 5 .....	109
Tab. 4-1	Exemplarische Auflistung messbarer Einflüsse .....	117
Tab. 4-2	Exemplarische Auflistung der Sensorarten .....	118
Tab. 4-3	Digitale Erhebungsmöglichkeiten ausgewählter Parameter .....	119
Tab. 4-4	Vergleich ZigBee, Bluetooth, WLAN, , , .....	122
Tab. 4-5	Merkmale der Transpondereinteilung anhand der Energiequelle .....	126
Tab. 4-6	Einteilung anhand der Frequenzen .....	128
Tab. 4-7	Vergleich Barcode und RFID .....	131
Tab. 4-8	Sensormerkmale in Abhängigkeit von der Frequenz .....	132
Tab. 4-9	Entscheidungsmatrix für die Auswahl des Erhebungskonzeptes .....	144
Tab. 6-1	Fallanzahl der einzelnen Tätigkeiten .....	163
Tab. 6-2	Deskriptive Statistik des Basisdatensatzes .....	166
Tab. 6-3	Auswertung der Kategorievariablen des Basisdatensatzes .....	167
Tab. 6-4	Zufälliger Datensatz 1: Trainings- und Validierungsfälle ..	168
Tab. 6-5	Zufälliger Datensatz 1: Analyse der Kategorievariablen ...	170
Tab. 6-6	Zufälliger Datensatz 1: Deskriptive Statistik .....	171
Tab. 6-7	Zufälliger Datensatz 1: Bestes Netz .....	171
Tab. 6-8	Zufälliger Datensatz 1: Klassifikationsmatrix Trainieren ...	171
Tab. 6-9	Zufälliger Datensatz 1: Klassifikationsmatrix Validieren ...	172
Tab. 6-10	Zufälliger Datensatz 2: Trainings- und Validierungsfälle ..	173
Tab. 6-11	Zufälliger Datensatz 2: Deskriptive Statistik .....	175
Tab. 6-12	Zufälliger Datensatz 2: Analyse der Kategorievariablen ...	175
Tab. 6-13	Zufälliger Datensatz 2: Bestes Netz .....	176

Tab. 6-14	Zufälliger Datensatz 2: Klassifikationsmatrix Trainieren ...	176
Tab. 6-15	Zufälliger Datensatz 2: Klassifikationsmatrix Validieren ...	176
Tab. 6-16	Zufälliger Datensatz 3: Trainings- und Validierungsfälle ...	177
Tab. 6-17	Zufälliger Datensatz 3: Deskriptive Statistik .....	179
Tab. 6-18	Zufälliger Datensatz 3: Analyse der Kategorievariablen ...	180
Tab. 6-19	Zufälliger Datensatz 3: Bestes Netz .....	180
Tab. 6-20	Zufälliger Datensatz 3: Klassifikationsmatrix Trainieren ...	181
Tab. 6-21	Zufälliger Datensatz 3: Klassifikationsmatrix Validieren ...	181
Tab. 6-22	Zufälliger Datensatz 4: Trainings- und Validierungsfälle ...	182
Tab. 6-23	Zufälliger Datensatz 4: Deskriptive Statistik .....	184
Tab. 6-24	Zufälliger Datensatz 4: Analyse der Kategorievariablen ...	184
Tab. 6-25	Zufälliger Datensatz 4: Bestes Netz .....	185
Tab. 6-26	Zufälliger Datensatz 4: Klassifikationsmatrix Trainieren ...	185
Tab. 6-27	Zufälliger Datensatz 4: Klassifikationsmatrix Validieren ...	185
Tab. 6-28	Zufälliger Datensatz 5: Trainings- und Validierungsfälle ...	186
Tab. 6-29	Zufälliger Datensatz 5: Deskriptive Statistik .....	188
Tab. 6-30	Zufälliger Datensatz 5: Analyse der Kategorievariablen ...	189
Tab. 6-31	Zufälliger Datensatz 5: Bestes Netz .....	189
Tab. 6-32	Zufälliger Datensatz 5: Klassifikationsmatrix Trainieren ...	190
Tab. 6-33	Zufälliger Datensatz 5: Klassifikationsmatrix Validieren ...	190
Tab. 6-34	5-80min-Datensatz: Testfälle .....	191
Tab. 6-35	5-80min-Datensatz: Deskriptive Statistik .....	193
Tab. 6-36	5-80min-Datensatz: Analyse der Kategorievariablen .....	193
Tab. 6-37	5-80min-Datensatz: Vergleich der Auswirkungsanalyse ...	195
Tab. 6-38	Subdatensatz 1: Fallanzahl der einzelnen Tätigkeiten (Variante 4) .....	197
Tab. 6-39	Subdatensatz 1: Deskriptive Statistik .....	200
Tab. 6-40	Subdatensatz 1: Auswertung der Kategorievariablen .....	201
Tab. 6-41	Subdatensatz 1: Bestes Netz .....	201
Tab. 6-42	Subdatensatz 1: Klassifikationsmatrix Trainieren .....	201
Tab. 6-43	Subdatensatz 1: Klassifikationsmatrix Validieren .....	202
Tab. 6-44	Testdatensatz 1: Fallanzahl der einzelnen Tätigkeiten .....	203
Tab. 6-45	Testdatensatz 1: Deskriptive Statistik .....	205
Tab. 6-46	Testdatensatz 1: Auswertung der Kategorievariablen .....	206
Tab. 6-47	Subdatensatz 1: Vergleich der Auswirkungsanalyse .....	207
Tab. 6-48	Subdatensatz 2: Fallanzahl der einzelnen Tätigkeiten (Variante 5) .....	208
Tab. 6-49	Subdatensatz 2: Deskriptive Statistik .....	211

Tab. 6-50	Subdatensatz 2: Auswertung der Kategorievariablen .....	211
Tab. 6-51	Subdatensatz 2: Bestes Netz .....	212
Tab. 6-52	Subdatensatz 2: Klassifikationsmatrix Trainieren .....	212
Tab. 6-53	Subdatensatz 2: Klassifikationsmatrix Validieren .....	212
Tab. 6-54	Testdatensatz 2: Fallanzahl der einzelnen Tätigkeiten .....	213
Tab. 6-55	Testdatensatz 2: Deskriptive Statistik .....	217
Tab. 6-56	Testdatensatz 2: Auswertung der Kategorievariablen .....	217
Tab. 6-57	Subdatensatz 2: Vergleich der Auswirkungsanalyse .....	218
Tab. 6-58	Subdatensatz 3: Fallanzahl der einzelnen Tätigkeiten (Variante 2) .....	219
Tab. 6-59	Subdatensatz 3: Deskriptive Statistik .....	222
Tab. 6-60	Subdatensatz 3: Auswertung der Kategorievariablen .....	222
Tab. 6-61	Subdatensatz 3: Bestes Netz .....	223
Tab. 6-62	Subdatensatz 3: Klassifikationsmatrix Trainieren .....	223
Tab. 6-63	Subdatensatz 3: Klassifikationsmatrix Validieren .....	223
Tab. 6-64	Testdatensatz 3: Fallanzahl der einzelnen Tätigkeiten .....	224
Tab. 6-65	Testdatensatz 3: Deskriptive Statistik .....	228
Tab. 6-66	Testdatensatz 3: Auswertung der Kategorievariablen .....	228
Tab. 6-67	Subdatensatz 3: Vergleich der Auswirkungsanalyse .....	230
Tab. 6-68	Tätigkeitsreduktion: Deskriptive Statistik .....	234
Tab. 6-69	Tätigkeitsreduktion: Auswertung der Kategorievariablen .....	235
Tab. 6-70	Tätigkeitsreduktion: Bestes Netz .....	235
Tab. 6-71	Tätigkeitsreduktion: Klassifikationsmatrix Trainieren .....	235
Tab. 6-72	Tätigkeitsreduktion: Klassifikationsmatrix Validieren .....	236

