



Technische Universität Graz
Institut für Maschinelles Sehen
und Darstellen



Texturanalyse und Mustererkennung in Wetterradarbildern

Masterarbeit

Sylwia Steginska

Graz, 01. Juni 2010

durchgeführt in Zusammenarbeit mit dem Institut für Digitale Bildverarbeitung,
Joanneum Research Graz

Betreuer:

Univ.-Prof. Dipl.-Ing. Dr.techn. Horst Bischof

Dipl.-Ing. Dr.techn. Harald Ganster

Eidesstattliche Erklärung

Ich erkläre an Eides statt, dass ich die vorliegende Arbeit selbstständig verfasst, andere als die angegebenen Quellen/Hilfsmittel nicht benutzt, und die den benutzten Quellen wörtlich und inhaltlich entnommene Stellen als solche kenntlich gemacht habe.

.....

Graz, am

.....

(Unterschrift)

Zusammenfassung

Wetterradarbilder werden in Vorhersagebereich als gute Repräsentation des Niederschlags eingesetzt. Oft sind die Daten aber mit verschiedenen Fehler behaftet, was vor allem für ungeschultes Personal ein Problem bedeutet. Die vorliegende Masterarbeit beinhaltet Algorithmen aus dem Bereich Bildverarbeitung und Mustererkennung, die speziell zur Erkennung von Artefakten in Wetterradarbildern entwickelt wurden. Das Ziel war es, eine detaillierte Analyse der möglichen Störungen durchzuführen und die Methoden zu entwickeln die die automatisierte Erkennung der Fehler ermöglicht. Damit wurde eine große Unterstützung für Meteorologen und in weiterer Folge für die Fluglotsen gewonnen, die sich mit Wetterradardaten in ihrer Arbeit ständig auseinandersetzen müssen.

Die Algorithmen sind als Einzelmodule konzipiert, die in ein komplexes System kombiniert werden. Als erstes wurden mehrere Methoden der Texturbeschreibung getestet und der optimale Segmentierungsalgorithmus wurde erarbeitet. Gabor Filter Responses in Verbindung mit Region Kovarianz Deskriptor wurde als beste Methode ausgewählt. Der nächste Schritt beinhaltet die geometrische Analyse der Störungen. Dabei spielt die Hough Transformation die Hauptrolle. Zusätzlich wurde eine Tracking Algorithmus vorgeschlagen, der eine zeitliche Verlaufs-Analyse von Objekten in Wetterradarbildern erlaubt.

Die Ergebnisse der vorgestellten Algorithmen wurden anhand von Ground Truth, welche durch erfahrene Meteorologen vorbereitet wurde, validiert. Damit wurde eine objektive Aussage über die Qualität der entwickelten Methoden geliefert.

Schlüsselworte: Wetterradarbilder, Artefakte, Texturmerkmale, Textursegmentierung, Bildverarbeitung, Mustererkennung

Abstract

The weather radar images are very good means of the precipitation measurement. However, the data are often tagged with various defects, which constitutes a real problem, especially for untrained personnel. This thesis presents several computer vision algorithms which were designed specifically for detection of artifacts in weather radar images. The main goal was a detailed analysis of all possible artifacts and the development of methods which make the automated detection possible. Such a system constitutes a big support for meteorology and air traffic controllers in their daily work.

The algorithms provide a set of partial results which are combined into a more complex system. First, several texture descriptors were tested and the texture segmentation algorithm was designed. Gabor Filter Responses with the Region Covariance Descriptor were chosen as the best method. The next step comprised the geometrical analysis of the artifacts. Hough Transformation was the most significant part of it. Additionally, a tracking algorithm was presented which made it possible to analyze the lifetime of the objects in weather radar images.

The results and the quality of presented algorithms respectively are evaluated with ground truth, which was prepared by meteorology experts.

Keywords: weather radar imagery, artefacts, texture features, texture segmentation, image processing, pattern recognition

Danksagung

An dieser Stelle möchte ich mich herzlich bei allen, die mich während der Durchführung der Masterarbeit unterstützt haben, bedanken.

Vor allem möchte mich bei Herrn Dr. Heinz Mayer und Herrn Dr. Harald Ganster bedanken, die mir die Möglichkeiten geboten haben im Projekt DIBMETSAT bei Joanneum Research mitzuwirken. Ich bedanke mich sehr herzlich bei meinem Betreuer Herrn Prof. Dr. Horst Bischof, der mir viele Hinweise und zahlreichen Anregungen gegeben hat und während der gesamten Masterarbeitszeit mit hilfreicher Unterstützung zur Seite gestanden ist.

Des Weiteren bedanke ich mich bei dem ganzen Team am Institut für Bildverarbeitung der Joanneum Research für die schöne Zeit während meiner Mitarbeit am Institut.

Zu guter Letzt ein besonderes Dank noch an meine Familie und Freunde für ihre Liebe, Geduld und aufmunternden Worte.

Inhaltsverzeichnis

1. Einleitung.....	1
1.1. Projekt "DIBMETSAT"	2
1.2. Gliederung der Arbeit	3
2. Radarmeteorologie	5
2.1. Grundlagen des Wetterradars.....	5
2.2. Radarmeteorologie in Österreich	8
2.3. Fehler in Wetterradarbildern.....	11
2.4. Zusammenfassung.....	22
3. Computer Vision und Wetterradarbilder in der Literatur	24
4. Ausgewählte Methoden der Bildverarbeitung	28
4.1. Texturanalyse	29
4.2. Hough Transformation.....	38
4.3. Mathematische Morphologie	40
4.4. k-Nearest Neighbours Klassifikator.....	42
5. Texturklassifikation von Wetterradarbildern.....	43
5.1. Datensatz.....	44
5.2. Evaluierung	45
5.3. Resümee	54
6. Wetterradarbildanalyse	55
6.1. Textursegmentierung	56
6.2. Erkennung der Erfassungslücken.....	58
6.3. Erkennung der nichtmeteorologischen Echos.....	63
6.4. Resümee	82
7. Diskussion.....	83
7.1. Beschränkungen	83
7.2. Zukünftige Arbeit.....	84

Abbildungsverzeichnis

Abbildung 1: Wetterradar – Funktionsweise	6
Abbildung 2: Die vier Wetterradarstationen des österreichischen Radarverbunds	9
Abbildung 3: Wetterradar-Kompositbild - MAXCAPPI Darstellung	10
Abbildung 4: Schematische MAXCAPPI-Darstellung.....	10
Abbildung 5: Skale - Niederschlagsrate, Reflektivität, Intensität.....	11
Abbildung 6: Festechos und Wirkung des Clutter Filters.....	12
Abbildung 7: Flugzeugecho	13
Abbildung 8: Insektenschwärme.....	14
Abbildung 9: Sonnenechos	14
Abbildung 10: RLAN Echos.....	15
Abbildung 11: Brightband	16
Abbildung 12: Second-Trip Echo	17
Abbildung 13: Strahlungscharakteristik der Antenne.....	17
Abbildung 14: Tiefflugerfassungsradarecho.....	18
Abbildung 15: Kreisförmige Störungen.....	19
Abbildung 16 : Orographische Abschattung.....	20
Abbildung 17: Orographische Abschattung in Wetterradarbilder	21
Abbildung 18 : Abschattung durch schattenwerfender Gewitterturm	21
Abbildung 19: Subrefraktion und Superrefraktion	22
Abbildung 20: Berechnung der Co-Occurrence Matrizen.....	31
Abbildung 21: Gefensterter Fourier Analyse vs. Wavelet Analyse	36
Abbildung 22: LM Filterbank.....	37
Abbildung 23: Schmid Filterbank.....	37
Abbildung 24: BSF Filterbank.....	38
Abbildung 25: Hough Transformation zur Erkennung von Kreisen.	40
Abbildung 26: Niederschlag Samples.....	45
Abbildung 27: Dämpfung Samples.....	45
Abbildung 28: Artefakte Samples.....	45
Abbildung 29: Evaluation der Co-Occurrence Matrizen mit Haralick Features	47
Abbildung 30: Evaluation des Kovarianz Deskriptor mit Low Level Features.....	48
Abbildung 31: Evaluation der Gabor Filterbank Responses als Features für Kovarianz Deskriptor	48
Abbildung 32: Evaluation der Gabor Filterbank Responses als Features für Kovarianz Matrix Koeffizienten Histogramm.....	50
Abbildung 33: Evaluation der LM bzw. BSF Responses als Features für Kovarianz Deskriptor	50
Abbildung 34: Evaluation der MR8 Filterbank Responses als Features für Kovarianz Deskriptor	51
Abbildung 35: Konfusionsmatrizen für Klassifikation.....	53
Abbildung 36: Konfusionsmatrizen für Klassifikation.....	54
Abbildung 37: Beispiele für gefilterte Niederschlags- bzw. Artefaktsample	57
Abbildung 38: Beispiele für Segmentierungsergebnisse	58
Abbildung 39: Abschattungsdiagramm	59
Abbildung 40: Summenbild.....	60
Abbildung 41: Erkennung der orographischen Abschattungssektoren.....	61
Abbildung 42: Beispiele für segmentierte Dämpfungsbereiche.....	62
Abbildung 43: Kreisförmige Störungen.....	64
Abbildung 44: Linienartige Artefakten.....	64

Abbildung 45: Polarkoordinaten vs. kartesische Koordinaten.	65
Abbildung 46: Wiener Radarbereich auf dem Kompositbild	67
Abbildung 47: Der Wiener Radarbereich in Polarkoordinaten.....	67
Abbildung 48: Die Schritte zur Erkennung der linienartige Echos	68
Abbildung 49: Schematische Darstellung der sektorweisen Dilation.....	69
Abbildung 50: Die durch Hough Transformation erkannten Objekte	70
Abbildung 51: Kreisförmige Artefakte	70
Abbildung 52: Die Wanderung einer Niederschlagszelle.....	71
Abbildung 53: Die Entwicklung einer Niederschlagszelle	72
Abbildung 54: Überlebenszeitanalyse	72
Abbildung 55: FANRate Faktoren für Textursegmentierung.....	75
Abbildung 56: Anzahl der Niederschlagspixel vs. Anzahl der Niederschlagspixel, die falsch als Artefaktpixel erkannt wurden (Textursegmentierung)	76
Abbildung 57: FNNRate Faktoren für Textursegmentierung.....	76
Abbildung 58: Anzahl der Artefaktpixel vs. Anzahl der Artefaktpixel, die falsch als Niederschlag erkannt wurden (Textursegmentierung).....	77
Abbildung 59: Wetterradarbilder mit 100% Segmentierungskorrektheit	78
Abbildung 60: Wetterradarbilder mit niedriger Korrektheitsrate	78
Abbildung 61: FANRate Faktoren für gesamtes System.....	80
Abbildung 62: Anzahl der Niederschlagspixel vs. Anzahl der Niederschlagspixel, die falsch als Artefaktpixel erkannt wurden (gesamtes System)	80
Abbildung 63: FNNRate Faktoren für gesamtes System.....	81
Abbildung 64: Anzahl der Artefaktpixel vs. Anzahl der Artefaktpixel, die falsch als Niederschlag erkannt wurden (gesamtes System)	81

Tabellenverzeichnis

Tabelle 1: Artefakte und ihre Charakteristik	23
Tabelle 2: Haralick Features	32
Tabelle 3: Parameter für Co-Occurrence Matrizen und max.erreichte Korrektheitsrate.	46
Tabelle 4: Parameter für Kovarianz Deskriptor und max. erreichte Korrektheitsrate	47
Tabelle 5: Parameter von Gabor Filtern für Kovarianz Deskriptor und maximal erreichte Korrektheitsrate.....	49
Tabelle 6: Parameter von Gabor Filtern für Kovarianz Matrix Koeffizienten Histogramm und maximal erreichte Korrektheitsrate.....	51
Tabelle 7: Parameter von LM, BSF und MR8 Filterbänken und maximal erreichte Korrektheitsrate.....	52
Tabelle 8: Einfluss der Nachbaranzahl auf Resultate des k-NN Klassifikators.....	53
Tabelle 9: Durchschnittliche Rechenzeit	54
Tabelle 10: Parameter für Gabor Filterung.....	57
Tabelle 11: Überlebenszeitanalyse	79
Tabelle 12: Textursegmentierung vs. gesamtes System	82

Einleitung

Die digitale Bildverarbeitung ist ein modernes und schnell wachsendes Wissensgebiet. Sie beschäftigt sich mit dem Extrahieren von Informationen aus Bildern und findet mittlerweile Einsatz in nahezu allen Wissenschafts- und Ingenieursdisziplinen.

Diese Diplomarbeit fokussiert auf Bildverarbeitungs- und Mustererkennungsmethoden, die zur Korrektur von Wetterraddarrendaten eingesetzt werden können. Die gute Qualität von Wetterraddarrendbildern ist ein Schlüsselfaktor für genaue Wettervorhersagen und eine wesentliche Voraussetzung zur Arbeitserleichterung und Entlastung für Meteorologen und Fluglotsen.

1.1. Projekt "DIBMETSAT"

Die vorliegende Diplomarbeit ist in Rahmen des kooperativen Projekts "DIBMETSAT" Digitale Bildverarbeitung gestützte Meteorologie - Services für Air Traffic Management entstanden. Das Projekt wird durch vier Partner abgewickelt:

- Joanneum Research Forschungsgesellschaft GmbH, Institut für Digitale Bildverarbeitung - Forschung und Entwicklung im Bereich anwendungsorientierter digitaler Bildverarbeitung, maschinelles Sehen und Fernerkundung.
- AIT Austrian Institute of Technology GmbH – eines der größten österreichischen außeruniversitären Forschungsinstitute, Forschung und Entwicklung in den wichtigsten Wirtschaft- und Technologiebereichen.
- Austro Control, Österreichische Gesellschaft für Zivilluftfahrt - die operationelle Flugmeteorologie, betreibt den einzigen Wetterradarverbund in Österreich und sorgt für die Abwicklung eines sicheren und effizienten Luftverkehrs. In ihren Kompetenzen liegt Beurteilung und Vorhersage des Niederschlags, der Vereisungsgefahr, der Gewitterausdehnung und Entwicklung, wie auch deren Stärke und folglich die damit verbundenen Gefahren wie z.B. Hagel, Windscherung und Turbulenz durch Böenfronten, Fallwinde und sogar Tornados.
- MeteoServe Wetterdienst GmbH - Lieferant für meteorologische Produkte sowie für meteorologische Beratung.

Radarmeteorologie hat ein großes Einsatzspektrum, von Wettervorhersage, über frühzeitige Erkennung und Warnung vor Naturkatastrophen (Lawinen, Überflutungen) bis hin zu Flugmeteorologie.

Das Wetterradar ist ein gutes und sehr effektives Werkzeug um Wettererscheinungen festzustellen. Mittels Wetterradar lässt sich Niederschlag, sowie seine Ausdehnung, Entwicklung und Stärke in drei Dimensionen erfassen. Die Wetterradarbilder haben sehr gute räumliche (Bereich von 1 km) und zeitliche (je 5 Minuten) Auflösung. Sehr oft sind die Bilder jedoch mit verschiedenen Artefakten (nichtmeteorologische Echos und Erfassungslücken) versehen. Die Artefakte haben verschiedene Entstehungsgründe und Charakteristiken, die genauer in Kapitel 2 beschrieben werden. Das Ziel des Projektes ist es

die Qualität der Weterradarbilder zu verbessern und dadurch die Arbeit der Meteorologen bzw. der Fluglotsen zu erleichtern.

Zukünftige Weterradaranlagen werden zunehmend mit Dualer Polarisation arbeiten, was die Eliminierung von nichtmeteorologischen Echos erleichtert. Dies ist jedoch mit sehr hohen Kosten verbunden und der Einsatz im Gebirge wird erst getestet. Daher ist es sinnvoll alternative, robuste Techniken zu entwickeln, die zur Qualitätsverbesserung von Weterradarbildern eingesetzt werden können. Die Grundidee des Projekts ist es die Methoden aus dem Bereich Bildverarbeitung und Mustererkennung anzuwenden um die Störungen und fehlerhafte Bereiche zu erkennen und zu eliminieren. Dabei können folgende Teilziele formuliert werden:

- Identifizieren offensichtlicher Störsignale oder Artefakte
- Identifizieren von Lücken im Erfassungsbereich
- Auffüllen der detektierten Lücken mit Hilfe von Satellitendaten

Diese Arbeit fällt in das Themengebiet der ersten zwei Teilziele.

1.2. Gliederung der Arbeit

Die vorliegende Arbeit umfasst folgende Hauptteile:

- Einführung in Weterradarmeteorologie
Die Grundlage und Arbeitsweise von Weterradar wird kurz erläutert. Weiter wird beschrieben wie die Weterradardaten zu einem Bild zusammengefasst werden bzw. welche Störungen auf den fertigen Kompositbildern auftreten können (Kapitel 2). In Kapitel 3 wird eine kurze Zusammenfassung der Literaturrecherche zum Thema Bildverarbeitungsmethoden in der Weterradarmeteorologie präsentiert.
- Texturanalyse
In Kapitel 4 wird ein Literatur-Review zum Thema Texturbeschreibung präsentiert. Damit soll ein Blick auf verschiedene mögliche Texturbeschreibungsmethoden aus dem Bereich Bildverarbeitung geschaffen werden. Auch eine kurze theoretische

Einführung in weitere Mustererkennungsmethoden wird dargestellt. In Kapitel 5 wird ein Textur Klassifikations Experiment beschrieben das direkt auf Wetterradardaten durchgeführt wird.

- Analyse der Wetterradarbilder und Erkennung der fehlerhaften Bereichen
Es werden mehrere Algorithmen vorgestellt, deren Ziel es ist die fehlerhaften Strukturen im Wetterradarbild zu erkennen (Kapitel 6).

Im letzten Kapitel werden noch die Gedanken und Bemerkungen zusammengefasst, die während der Durchführung dieser Arbeit aufgetaucht sind und welche für weitere Arbeiten mit Wetterradarbildern nützlich sein können.

Radarmeteorologie


Dieses Kapitel gibt eine Einleitung in die Arbeitsweise von Wetterradar und stellt das österreichische Wetterradarnetz vor. Weiteres wird ein Überblick über die verschiedenen Artefakte gegeben, die auf Wetterradarbildern auftreten können.

2.1. Grundlagen des Wetterradars

In diesem Kapitel werden kurz die grundlegenden Prinzipien eines Wetterradars erläutert. Für eine detaillierte Beschreibung der Arbeitsweise sowie Unterschiede der Radarmodelle

sei auf die Fachliteratur [Hailzl (2006), Doviak and Zrnic (1984), Radartutorial (2009)] verweisen.

Das Wort Radar kommt aus dem englischen **RA**dio **D**etection **A**nd **R**anging. Das Radar dient also der Erkennung und Entfernungsmessung der Objekten. [Hailzl (2006)]. Das Funktionsprinzip ist relativ einfach. Das Radar schickt ein Primärsignal in der Form von gebündelten elektromagnetischen Wellen aus und bekommt von auf ihren Weg getroffenen Objekten reflektierte Echos zurück (siehe Abbildung 1).



Abkürzungen: h_a – Höhe der Antenne über dem Meeresspiegel
 H - Höhe des reflektierenden Volumens über dem Meeresspiegel
 h - Länge des vom Radar ausgesendeten Impulses umgerechnet von einer Zeitdauer auf eine Länge
 r - Abstand des reflektierenden Volumens vom Radar
 γ - Antennen Elevationswinkel

Abbildung 1: Wetterradar – Funktionsweise [Leitner (1999)].

Die Mikrowellen können kontinuierlich oder gepulst ausgestrahlt werden. Wetterradaranlagen arbeiten meist mit gepulsten Signalen. Das heißt, dass dieselbe Antenne sowohl zum Senden von Radiowellen, als auch zum Empfang von Echos dient [Leitner

(1999)]. Die Wellen können in verschiedenen Frequenzen geschickt werden. Für Meteorologie ist vor allem die Messung von Niederschlag (Hydrometeore) von Bedeutung und für den Einsatz wird eine Strahlungsfrequenz im Gigahertzbereich (typisch 5,6 GHz) benötigt.

Das Radar ermöglicht eine genaue Ortung von Niederschlägen, weil die Radarstrahlung in verschiedenen Elevationen (Neigungswinkel der Antenne, von 0° bis 90° möglich) und Azimuten (0-360°) erfolgt. Die Entfernung r (siehe Abbildung 1) der Hydrometeore von Antenne kann über die Laufzeit der Signale ermittelt werden.

$$r = \frac{c * \Delta t}{2} \quad (2.1)$$

mit:

c - Lichtgeschwindigkeit,

Δt - Zeit vom Strahlaussenden bis zum Empfang des Echos.

Im Radarempfänger wird auch die reflektierte Leistung (Reflektivität, in mm^6/m^3) gemessen was wiederum die Schätzung der Regenrate (in mm/h) ermöglicht. Die Reflektivität Z ist abhängig vor allem von der Größe und Anzahl der Hydrometeore (bzw. anderen Objekten, die auch ein Echo hervorrufen können) pro Impulsvolumen und wird in mm^6/m^3 gemessen. Da sich die Größe des Impulsvolumens mit der Entfernung vom Radar vergrößert (siehe Abbildung 1) werden bei gleicher Regenintensität viel mehr Niederschlagstropfen erfasst. Diese Tatsache wurde auch bei der Berechnung der Reflektivität berücksichtigt. Die detaillierte Radargrundgleichung zur Berechnung der Reflektivität kann im [Radartutorial (2009)] gefunden werden.

In der Praxis wird die Reflektivität meistens in einer logarithmischen Einheit dBZ angegeben:

$$dBZ = 10 * \log \frac{Z}{1 mm^6/m^3} \quad (2.2)$$

Ein grundlegender Zusammenhang zwischen Reflektivität und Regenrate kann mit folgender Formel ausgedrückt werden:

$$Z = a * R^b \quad (2.3)$$

Die Faktoren a und b wurden durch langfristige Beobachtungen empirisch ermittelt und sind vom Niederschlagstyp abhängig (z.B.: für Regen im Sommer $a=300$ und $b=1,5$, für Schnee $a=1800$, $b=2,2$).

2.2. Radarmeteorologie in Österreich

Wegen der beschränkten (rund 230 km) Reichweite und den Abschattungen der Radarstrahlung (vgl. Kapitel 2.3.3) werden zur vollständigen Erfassung Österreichs mehrere Radaranlagen benötigt. Austro Control besitzt derzeit 5 Radarstationen in Österreich: in Wien (Rauchenwart), Salzburg (Feldkirchen), Patscherkofel, Zirbitzkogel und auf der Valluga. Die ersten vier bilden den österreichische Radarverbund, der auch von Austro Control GmbH betrieben wird (siehe Abbildung 2) und als Datenlieferant für die vorliegende Arbeit dient. Jede Station verfügt über ein gleiches Radargerät der Firma EEC (Enterprise Electronic Corporation, USA). Das Radar arbeitet in einem Frequenzspektrum von 5,620-5,625 GHz (G-Band) und hat eine Reichweite von etwa 230km. Die Abtastung erfolgt über 16 Elevationswinkel von $0,1^\circ$ bis 64° (ergibt 16 Abtastschichten) und es werden 360 Strahlen mit 1° Keulenbreite ausgestrahlt. Eine vollständige 360° horizontale Drehung der Antenne dauert zirka 15 Sekunden, d.h. die gesamte Abtastung (ein vollständiger Zyklus der Radarantenne in allen Elevationen und Azimuten) benötigt ungefähr 4 Minuten. Durch die weitere Datenverarbeitung ergibt sich noch eine zusätzliche Verzögerung, die ungefähr 40 Sekunden beträgt.

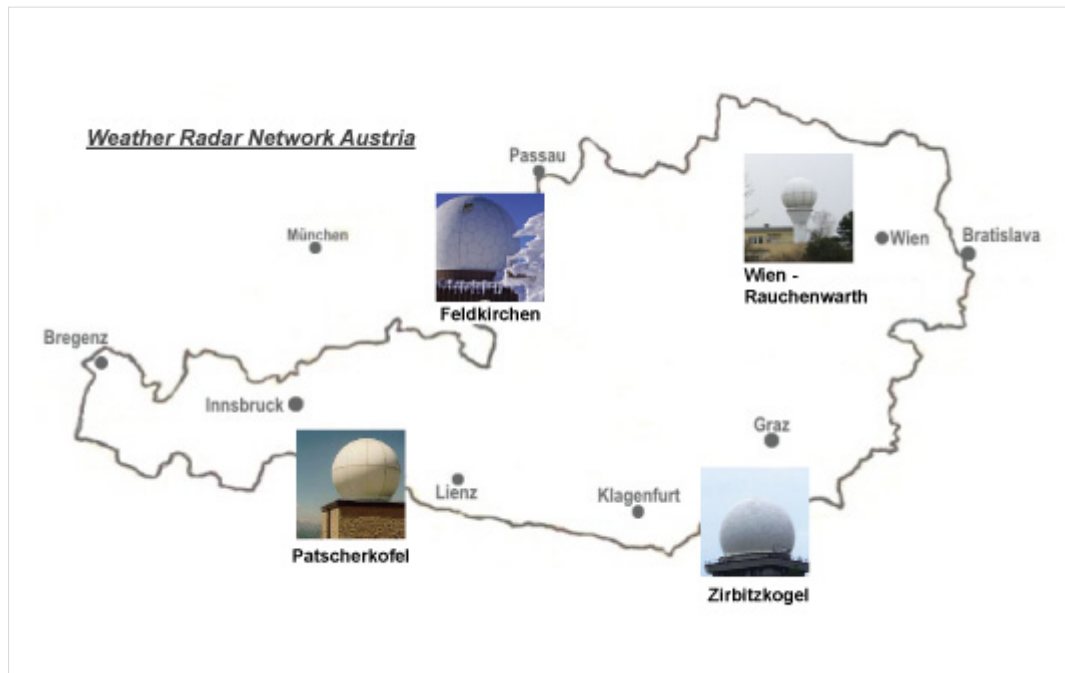


Abbildung 2: Die vier Wetterradarstationen des österreichischen Radarverbunds.

Die vier Radarstationen liefern die gesammelten dreidimensionalen Wetterradar Daten, die im nächsten Schritt zu einem einzelnen Radarbild, das ganz Österreich bedeckt, kombiniert werden (engl. *WR Austria Composite Image*, siehe Abbildung 3). Das Bild entsteht durch eine MAXCAPPI (engl. *Maximum Constant Altitude Plan Position Indicator*) Darstellung und wird jeweils in Intervallen von 5 Minuten erneuert.

In der MAXCAPPI Visualisierung wird immer in den Grundriss der größte Reflektivitätswert aller 16 Abtastschichten über einer 1x1 km Grundfläche projiziert (siehe Abbildung 3, Abbildung 4). Im Aufriss (E-W View) wird die Maximalintensität jeder Spalte und im Kreuzriss (N-S View) jeder Zeile dargestellt. Diese Methode lässt keine eindeutige Zuordnung zu. Es ist möglich dass zwei benachbarte Pixels aus Echos aus verschiedenen Höhen generiert wurden. Die MAXCAPPI Visualisierung wird hauptsächlich für Wetteranalyse verwendet, für detailliertere Analysen ist sie ungeeignet. Dafür werden andere Techniken wie z.B. VOLLCAPPI angewendet [Hailzl (2006)].

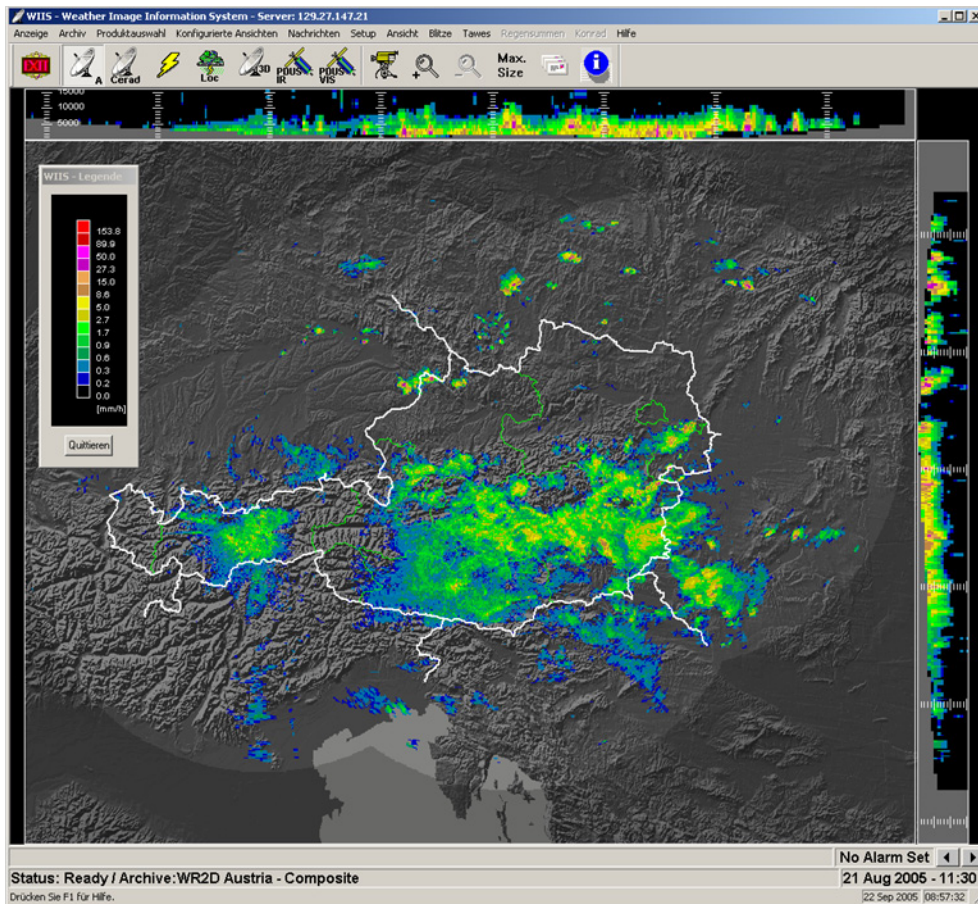


Abbildung 3: Wetterradar-Kompositbild - MAXCAPPI Darstellung.




Abbildung 4: Schematische MAXCAPPI-Darstellung [Hailzl (2006)].

Das Wetterradar-Kompositbild besitzt eine Größe von 824x648 mit einer Auflösung von 1x1 km. Die Reflektivität bzw. Niederschlagsintensität wird in 14 Intensitätsklassen unterteilt und auf dem Bild farblich dargestellt (siehe Abbildung 5).




Abbildung 5: Skale - Niederschlagsrate, Reflektivität, Intensität.

2.3. Fehler in Wetterradarbildern

Die Radarmessung ist mit einigen Schwierigkeiten verbunden, wie z.B. begrenzte Anzahl der Radarstationen, die meist gebirgige Geländestruktur in Österreich, die Radarstrahldämpfung sowie verschiedene Störsignale. Aus diesen Gründen werden nicht alle Bereiche Österreichs erfasst bzw. sind teilweise durch Artefakte gestört.

Grundsätzlich gibt es zwei Arten von Fehlern: nichtmeteorologische Echos und Lücken im Erfassungsbereich. Sie werden in den nächsten Kapiteln näher betrachtet.

2.3.1. Störsignale und nichtmeteorologische Echos

Das Wetterradar erfasst nicht nur die Echos, die ausschließlich von Niederschlägen kommen, sondern es können auch Signale von anderen Objekten erfasst werden. Diese treten als verschiedene Störungen auf den Wetterradarbildern auf. Sie beeinträchtigen dadurch die Qualität der Wetterradarbilder wesentlich und können zu falschen Interpretationen führen. Daher sollen diese aus den Bildern herausgefiltert bzw. unterdrückt werden um keine Niederschläge vorzutäuschen und die genauen meteorologischen Beurteilungen nicht zu erschweren.

2.3.1.1. Festechos

Als Festechos (sog. Clutter) bezeichnet man die Echos, die nicht von Niederschlägen sondern aufgrund der Reflektivitätseigenschaften anderer Objekte entstehen.

Diese Störungen können durch den Erdboden und seinen Bewuchs sowie anderen Festzielen am Boden wie Gebäude, Kamine oder Windkraftwerke verursacht werden. Wenn sie von einem Radarstrahl getroffen werden streuen sie einen Teil des Strahles zurück. Die in dieser Art entstehenden Artefakte nennt man Bodenechos (engl. *Ground Clutter*). Wesentlich ist es dabei, dass sich die Bodenechos von Messung zu Messung nicht verändern (bzw. nur unwesentlich).

Es existiert bereits ein Algorithmus, das diese Art von Störungen ausfiltert [Leitner (1999)] (siehe Abbildung 6, vgl. Kapitel 3). Der Algorithmus (Clutter Filter) wurde 1999 erfolgreich bei den vier Wetterradarstationen der Austro Control implementiert und befindet sich bis jetzt im Einsatz.




Abbildung 6: Festechos und Wirkung des Clutter Filters.
Links: Clutterbehaftetes Bild, Rechts: die Clutter Pixels wurden entfernt.

2.3.1.2. *Flugzeugechos*

Auch bewegliche Festziele wie z.B. Flugzeuge können Echos verursachen. Sie haben eine Geschwindigkeit ungleich null und können deswegen nicht einfach durch den Clutter-Filter entfernt werden. Meistens haben sie eine Intensitätsstufe zwischen 1 und 4 und können als Einzelpixel oder als Pixelkette erscheinen (siehe Abbildung 7), wenn sie mehrmals von einem Radarstrahl abgetastet werden.




Abbildung 7: Flugzeugecho.

2.3.1.3. *Clear Air und biologische Echos*

Das Wetterradar kann auch aus klarer, wolkenfreier Luft Signale aufnehmen. Diese sind als Clear Air Echos bezeichnet und entstehen durch Insekten, Vogelschwärme, kleine Staubpartikeln oder durch Luftturbulenzen. Die biologischen Echos sind sehr schwer von echtem Niederschlag zu unterscheiden weil sie dieselben Parameter wie leichter Regen oder Schneefälle haben können.

Das Vogelschwarmecho kann in der Radarmeteorologie sehr lästig sein. Es genügt ein Vogel pro Kubikmeter um ein großes, sich bewegendes Echo hervorzurufen und während der Migrationszeiten kann die Störungsgröße erheblich zunehmen. Die Insektenechos entstehen meistens nur in der Nähe von Wetterradarstationen [Radartutorial (2009)]. Durch die Arbeitsweise und Ortung der Radare der Austro Control werden die biologischen Echos kaum sichtbar. In Abbildung 8 wird ein Beispiel einer deutschen Radarstation gezeigt.




Abbildung 8: Insektenschwärme [Radartutorial (2009)].

2.3.1.4. *Sonnenechos*

Weitere signifikante Störungen sind Sonnenechos. Dieses Phänomen tritt auf wenn sich die Ausbreitung des Sonnenstrahls genau in der Haupttrichtung des Radarstrahls befindet. Es ist vor allem bei sehr niedrigem Lichtstand zu sehen, also hauptsächlich im Winter bei Sonnenaufgang und bei Sonnenuntergang.

Die Sonnenechos haben eine spezielle Charakteristik: sie entstehen in der Form von schmalen Streifen, mit konstanten Azimutwinkeln, die zu einer Radarstation zeigen (siehe Abbildung 9).




Abbildung 9: Sonnenechos.

2.3.1.5. *Funknetzechos*

Ähnliche Form wie Sonnenechos besitzen auch Artefakte, die durch RLAN (engl. *Radio Local Area Network*) entstehen. Die Streifenbreite kann dabei variieren, die Orientierung zeigt immer zur Radarstation (siehe Abbildung 10).




Abbildung 10: RLAN Echos.

2.3.1.6. *Brightband*

In der Schmelzzone einer Wolke, in der ein fester Niederschlag wie Schnee in einen flüssigen (Regen) übergeht ist die Reflektivität erhöht. Die Eisoberfläche des Schneekristalls wird mit einem dünnen Wasserfilm beschichtet und das Wasser reflektiert die elektromagnetischen Wellen 10-mal besser als Eis [Radartutorial (2009)]. Dieser schmelzende Schnee wird manchmal als eine ungefähr kreisrunde Zone mit sehr hohen Intensitäten (als helles Band oder aus engl. *brightband* bezeichnet) im Bereich der Radarstationen erfasst. Sie kann sehr irreführend sein und darf nicht als starker Niederschlag interpretiert werden (siehe Abbildung 11).




Abbildung 11: Brightband.

2.3.1.7. *Sekundäre Radar Echos*

Sekundäre Echos sind Störungen, die aufgrund von nicht standardmäßigen Radarfunktionen oder von Mehrfachreflexionen eines Radarstrahls entstehen. Man unterscheidet dabei Second Trip Echos und Seitenkeulenechos. Diese kommen bei G-Band Radaranlagen (die in Österreich derzeit verwendet sind) eher selten vor.

Second Trip Echos sind Echos, die aus Entfernungen außerhalb der Reichweite des Radars kommen und erst nach dem nächsten oder sogar übernächsten Impuls zurückkehren. Befindet sich z.B. ein Regenschauer in der Entfernung von 270km (bei einem Messradius von 230km), so wird das Signal erst mit dem nächsten ausgesendeten Puls aufgenommen und zu einer falschen Entfernung zugeordnet [RadarInfo (2009)]. Die Second-Trip Echos erkennt man an ihren Streifenmustern, die sich radial von der Radaranlage ausbreiten (siehe Abbildung 12).




Abbildung 12: Second-Trip Echo.

Seitenkeulenechos sind Echos, die aufgrund der Strahlungscharakteristik des Radars vorkommen können. Typische Radarstrahlbreite beträgt 1° , es kommt aber auch entlang der Nebenkeulen zu geringem Impulsausstoß (siehe Abbildung 13) was in zusätzlichen Echos resultieren kann, vor allem wenn sich in der Nähe der Station stark reflektierende Objekte befinden.

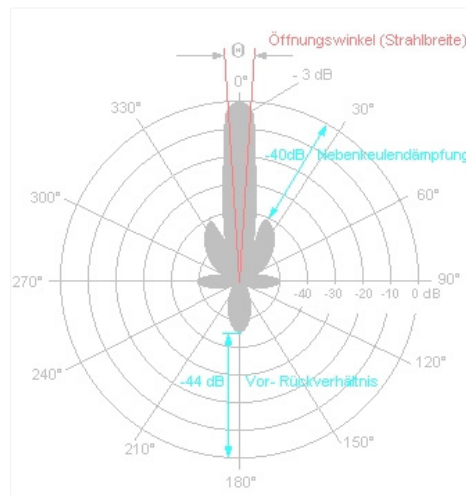


Abbildung 13: Strahlungscharakteristik der Antenne.

2.3.1.8. *Durch Militär verursachte Störungen*

Die militärisch genutzten Tiefflugradare können spezifische Störungen verursachen (siehe Abbildung 14). Die Form der Artefakte ist sehr stark von der Entfernung zur Wetterradarstation abhängig.




Abbildung 14: Tiefflugerfassungsradarecho.

An der Stelle soll noch eine andere Störung erwähnt werden, die auch durch das Militär verursacht werden kann. Es handelt sich dabei um eine Chafffreisetzung. Es werden kleine, sehr stark reflektierende Streupartikel (z.B. Aluminiumfolienstreifen oder metallüberzogene Kunststofffasern) in der Luft freigesetzt um feindliche Radare zu „verwirren“ und die Ortung von Kampfflugzeugen zu erschweren. Diese Freisetzung geschah nicht nur während Kriegszeiten, sondern auch gegenwärtig bei militärischen Flugübungen.

2.3.1.9. *Kreis- und Spiralförmige Echos*

Sehr oft sind auf Radarbildern runde oder kreisförmige Artefakte zu sehen (siehe Abbildung 15), deren Ursachen die Nebenkeuleneffekte oder Wechselwirkungen mit anderen Radarstationen sein können. Die genaue Herkunft ist aber unbekannt. Sie treten meist an der Reichweitengrenze des Radars auf.




Abbildung 15: Kreisförmige Störungen.

2.3.2. Erfassungslücken

Die zweite Fehlerart in den Radarbildern sind die Erfassungslücken. Das stellt ein sehr großes Problem dar, weil dadurch tatsächlicher Niederschlag überhaupt nicht erfasst bzw. stark unterbewertet wird. In den nächsten Kapiteln werden die Entstehungsgründe diskutiert.

2.3.2.1. Orographische Abschattungen

Diese Form der Abschattung kommt vor, wenn die Radarstrahlung durch orographische Hindernisse (Gebirge) gehemmt ist und die Niederschlagsformationen nicht erreichen kann (siehe Abbildung 16). Eine weitere Erschwernis ist es, dass sich die Abschattungsgebiete jeweils mit der Strahlungselevation ändern. Ob ein Niederschlag erfasst wurde und in welchem Ausmaß hängt also sehr stark von der Höhe der Niederschlagszellen ab und es kann vorkommen, dass nur die oberste, nicht repräsentative Niederschlagsschicht erfasst wurde.

Vor allem im Bereich Alpen kommt es dadurch zu großen Abschattungsgebieten. Die Abschattungsbereiche treten auf den Radarbildern als Kreissektoren auf (siehe Abbildung 17).

2.3.2.2. Dämpfungen

Die Radarstrahlung wird unter gewissen Umständen gedämpft was wiederum die Genauigkeit der Niederschlags erfassung beeinträchtigt und zu Unterschätzungen führt. Es handelt sich hier um Ausbreitungsdämpfung (Dämpfung im Niederschlag) und Entfernungsdämpfung (entfernungsbedingte Abschwächung des Signals). Die Ausbreitungsdämpfung kann Aufgrund starken Niederschlagszellen entstehen, die sich auf dem Weg der Radarstrahlung befinden. Damit wird das Signal hinter den Zellen abgeschwächt (siehe Abbildung 18).

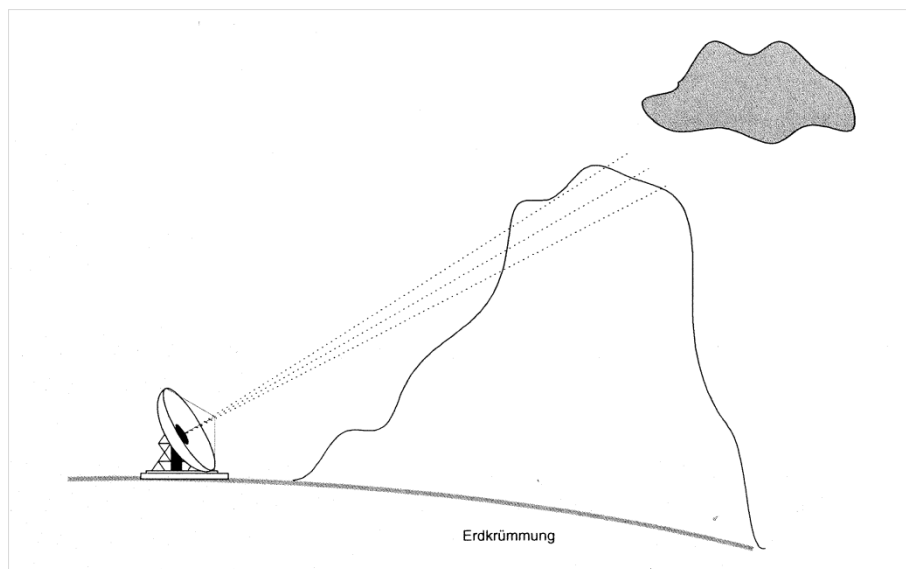


Abbildung 16 : Orographische Abschattung – schematische Darstellung [Leitner (1999)].




Abbildung 17: Orographische Abschattung in Wetterradarbildern.




Abbildung 18 : Abschattung durch schattenwerfender Gewitterturm.

2.3.3. Anomale Ausbreitung

Theoretisch breiten sich die Radarstrahlen geradlinig aus. Aufgrund von Erdkrümmung entfernen sich also die Strahlen immer mehr von Erdoberfläche. In einer Entfernung von 200 km hat der Radarstrahl bei einer Elevation von 0° die Höhe von zirka 3,5km. Daher werden weiter entfernte Wolken bzw. andere Objekte nur dann erfasst wenn sie eine entsprechende Höhe aufweisen.

In der realen Atmosphäre kommt noch der Brechungsindex dazu, der vom Luftdruck, vom Wasserdampfgehalt und der Lufttemperatur abhängt [Reiber (2009)]. Dadurch kommt es zu zwei extremen Phänomenen: Subrefraktion und Superrefraktion (siehe Abbildung 19).

Bei der Subrefraktion wird der Radarstrahl von der Erdoberfläche weg gebrochen und die Radarreichweite wird dadurch verringert. Die weiter entfernten Niederschlagsgebiete werden nicht oder nur teilweise registriert.

Bei der Superrefraktion wird der Radarstrahl zur Erdoberfläche hin gelenkt und der Radarhorizont vergrößert sich. Im Extremfall kann der Strahl den Boden erreichen und Bodenechos erzeugen (an den Stellen wo das sonst nicht möglich wäre) bzw. die sonst üblichen Bodenechos werden meist verstärkt.

Die beiden Effekte werden auch „anomale Ausbreitungen“ (engl. *anomale propagations*) benannt.




Abbildung 19: Subrefraktion und Superrefraktion.

Ein Reichweiteverlust ist nicht so störend wie die Überreichweite und wird selten bemerkt. Die Superrefraktion stellt aber ein größeres Problem dar. Dadurch wird das Bodenecho massiv verstärkt und ist auch für erfahrenen Meteorologen sehr irreführend.

2.4. Zusammenfassung

Dieses Kapitel hat einen Überblick über die Wetterradar Funktionsweise, Wetterradarbilder und mögliche auftretende Störungen gegeben. An dieser Stelle werden noch alle Artefakte und ihre Charakteristik in tabellarischen Form zusammengefasst (Tabelle 1).

	Struktur und Geometrie	Intensität	Auftreten
Flugzeug	Einzelpixel oder Pixelkette	1-4	beliebig
Biologische Echos	„Geflechte“ Muster	niedrig	Durch die niedrige Flughöhe (max. 2 km) am markantesten in der Nähe der Stationen
Sonne	Linienartig, schmalkonisch, konstante Azimutwinkel, zeigt zur Radarstation	niedrig	Bereich 270-0° bzw. 180°-270°
Funknetz (RLAN)	Linienartig, Breite kann variieren	Unteres Drittel	beliebig
Brightband	„Fleck“ mit höherer Intensität	Abhängig von der Höhe der Null Grad Grenze und dem Tropfen-spektrum	Rund um und über der Radarstation (fließender Übergang)
Second Trip Echos	Bei variierender Pulsrate als radiale Streifenmuster erkennbar, ansonsten nicht von echtem Niederschlag unterscheidbar.	Gesamte Bandbreite	Vor allem bei Superrefraktion und hohen Gewitterzellen außerhalb der eindeutigen Radarreichweite
Seitenkeulenechos	Verschiedene Erscheinungsformen, teilweise zeitlich fluktuierend.	Gesamte Bandbreite abhängig vom reflektierenden Niederschlag	beliebig
Tiefflugradar	Kegelförmig, zeigt zur Radarstation	Gesamtes Spektrum, verrauscht	beliebig
Chaff-freisetzung	Beliebig, manchmal verwellende Streifen	Unteres Drittel	Sehr, sehr selten
Kreisförmige Echos	Radiale Kreisbogen	1-8	Meistens Rand des Erfassungsbereichs
Superrefraktion	beliebig	beliebig	Bei stabiler Schichtung der Atmosphäre
Erfassungslücken	Kreissectoren, die sich auf dem Kompositbild überlappen können	keine	Immer gleich (hinter Hindernissen, z.B.: Berg), abhängig von der Elevation

Tabelle 1: Artefakte und ihre Charakteristik.

Computer Vision und Wetterradarbilder in der Literatur

Die Thematik der Wetterradarbildverarbeitung ist in der Literatur nicht sehr verbreitet. Grundsätzlich gibt es sehr wenige Autoren, die sich stärker mit dem Thema auseinandergesetzt haben. Die wichtigsten Artikel kommen von Thomas Leitner, Markus Peura und Valiappa Lakshmanan. Die Arbeiten werden im Folgenden kurz dargestellt.

[Leitner (1999)] hat in seiner Dissertation einen Algorithmus zur Bodenechoentfernung vorgeschlagen. Es ist eine „multitemporale, mehrparametrische, Bildverarbeitungsmethode“, die in Radarstationen der Austro Control seit 1999 Einsatz gefunden hat (vgl. Kapitel 2.3.2.2). Der Autor verbindet in dem Algorithmus mehrere Ideen. Es werden nicht nur ein einzelnes Radarbild sondern eine Reihe von zeitlich aufeinanderfolgenden Radarbildern betrachtet („multitemporale“) und es wurde nicht nur Reflektivität sondern mehrere Parameter, also Reflektivität, radiale

Geschwindigkeit und die spektrale Breite einbezogen („mehrparametrig“). Trotz hoher Komplexität der Methode wurde sie erfolgreich eingesetzt. Sehr wichtig ist, dass die Qualität des Wetterradarbildes nicht beeinträchtigt wurde, d.h. es wurden keine Pixel entfernt die eine wesentliche Rolle für eine meteorologische Beurteilung hätten.

[Peura (2002)] konzentriert sich in seiner Arbeit auf Echos, die durch Funknetze, Sonne, Flugzeuge, Vögel oder Insekten verursacht worden sind. Er schlägt ein Set von verschiedenen Methoden vor, das jeweils auf eine andere Störung fokussiert. Die von Peura entwickelten Algorithmen sind seit 2002 im Meteorologischen Institut in Finnland eingesetzt.

Die Hauptkomponenten der Algorithmen sind Techniken zur Erkennung von verschiedenen graphischen Primitiven wie z.B. Ausdehnung, Orientierung oder Steilheit. Es wurden auch Morphologie und Fuzzy Logik eingesetzt. Die einzelnen Algorithmen sind relativ einfach aufgebaut. Zum Beispiel basiert die Methode zur Erkennung des biologischen Echo nur auf Intensitätsschwellwerten. Die Echos wurden anhand eines gewissen Umkreises innerhalb von Radarzentren und niedrigen Reflektivitäten bestimmt. Das ist eine ziemlich naive Methode, da es keine Möglichkeit gibt zwischen biologischen Echos und einem tatsächlichem leichten Niederschlag zu unterscheiden. Die durch die Sonne bzw. RLAN entstandenen Störungen wurden nur aufgrund ihre geometrischen Eigenschaften (linienartig, Schwellwert über die Länge) erkannt. Nur deutliche Echos können dadurch identifiziert werden und die kleineren Störungen werden nicht erkannt.

[Lakshmanan and Zhang (2009)] fokussieren ihre Arbeit auf die Artefakte in den Wetterradarbildern, die durch Insekten, Vogelschwärmen und Fledermäusen verursacht werden. Es wurde ein Algorithmus vorgeschlagen, der auf Bildsegmentierung und Neuronalen Netzen basiert. Sie weisen in ihrer Arbeit auf, dass für die Detektion der meisten Artefakte wie Clutter oder RLAN Echos die auf Texturanalyse basierten Methoden reichen können, für das Identifizieren der biologischen Echos ist das nicht genug. Sie verwenden zur Erkennung dieser Echos die Eigenschaften die auch von [Peura (2002)] verwendet wurden, machen sich aber zusätzlich die Dopplergeschwindigkeit zunutze. Das erlaubt eine bessere Differenzierung zwischen störenden biologischen Echos und leichtem Niederschlag.

[Lakshmanan (2001)] beschäftigt sich vor allem mit der Segmentierung von Wetterradarbildern und Infrarot Satellitenbildern. Im Rahmen seiner Dissertation entwickelt er ein hierarchisches, mehrstufiges Textur-Segmentierungsverfahren (basiert auf K-Means Clustering) und vergleicht es

mit traditionellen Segmentierungsmethoden wie z.B. Watershed, Edgeflow (Gabor Filter), Markov Random Field. Der Segmentierungsalgorithmus wurde weiter entwickelt und in [Lakshmanan et al. (2008)] zur automatisierten Erkennung und Klassifikation der Gewitterzellen eingesetzt.

Die Methoden der Textur Analyse wurden von [Hu et al. (2008)] eingesetzt. Die Autoren untersuchen anhand von Co-Occurrence Matrizen die Unterschiede in Wetterradarbildern aus Ningxia und Süd-China. Aus den resultierenden Haralick Features (vgl. Kapitel 4.1.1.1) lassen sich Schlüsse auf die Niederschlagscharakteristiken in den beiden Regionen ziehen.

[Gill (2007)] entwickelte ein Algorithmus zur Clutter Entfernung. Seine Methode, Elevation angle Dependent Co-Occurrence Matrix EDCM basiert ebenso auf Co-Occurrence Matrizen.

Wie am Anfang des Kapitels gesagt wurde, existieren nicht viele Arbeiten, die sich direkt mit Artefakten in Wetterradarbildern beschäftigen. Das hat mehrere Gründe. Erstens ist eine Unterscheidung zwischen Artefakten und Niederschlag sehr schwierig, selbst für erfahrene Meteorologen, und weiters müssen eventuell andere Daten zusätzlich analysiert werden wie z.B. Bodenmessungen oder Satellitenbilder. Deswegen stellt ein automatisiertes System noch größere Herausforderungen. Zweitens gibt es keine universellen Bezeichnungen für die verschiedenen Artefakte bzw. Niederschlag. Ihre Charakteristik kann je nach eingesetzten Gerät und Anwendungsort abweichend sein. Was typisch im Sinne der meteorologischen Erscheinungen für z.B. China ist, muss nicht für Österreich gelten. Dasselbe gilt für z.B. biologische Echos oder für die Erfassungslücken, die stark von der Struktur des Geländes abhängig sind. Die Literaturrecherchen haben gezeigt, dass alle oben genannten Autoren versuchen ihre Ziele vor allem durch die Analyse der Textur und Geometrie zu erzielen. Es wurden auch andere Kriterien herangezogen wie z.B. Zeitfaktor für Detektion des Festechos ([Leitner (1999)]) oder Dopplergeschwindigkeit um bessere Klassifikation des biologischen Echos ([Lakshmanan and Zhang (2009)]) zu ermöglichen. Die Problematik der Artefakte in Wetterradarbildern ist von existierenden Arbeiten nicht vollständig abgedeckt. Keiner der benannten Autoren hat eine komplette Lösung geliefert bzw. die vorgeschlagene Algorithmen sind nicht optimal oder eignen sich nicht für den Einsatz auf den Bildern der österreichischen Wetterradarmeteorologie. Die vorliegende Arbeit präsentiert mehrere Algorithmen für die Erscheinungsformen beim österreichischen Radar Netzwerk. Jede Störungsart wurde genau analysiert (siehe Kapitel 2.3) um

eine optimale Erkennungsmethode entwickeln zu können. Dabei stellen die in dem Kapitel benannte Arbeiten eine Motivation und Inspiration dar.

Ausgewählte Methoden der Bildverarbeitung

Für Meteorologen von großer Bedeutung sind Texturunterschiede und geometrische Eigenschaften von Niederschlägen und Artefaktstrukturen. Aufgrund dieser können sie die Wettererscheinungen richtig identifizieren. Um sie auf den Bildern automatisch zu erkennen werden auch geeignete Werkzeuge aus dem Bereich Bildverarbeitung und Mustererkennung gebraucht. In diesem Kapitel werden verschiedene Methoden vorgestellt, die sich als sinnvoll zur Wetterradarbildverarbeitung erwiesen haben.

Den Schwerpunkt bildet die Texturanalyse. Die Texturanalyse ist in vielen Bereichen anwendbar: Klassifikation, Segmentierung, Textur Synthese (Kompression) oder 'shape from texture'. In vielen Applikationen spielt die Textur eine Hauptrolle, vor allem in Inspektion und in der Fernerkundung. Sie findet Einsatz in Dokument-Verarbeitung (z.B. für die Detektion von Textblöcken), sowie auch in der medizinischen Bildverarbeitung. Sie hat das Ziel solche

Bildmerkmale zu liefern, die oben genannte Aufgaben wie Klassifikation oder Segmentierung bestmöglich durchzuführen ermöglichen. Die Unterscheidung zwischen Niederschlag und störenden Echos auf Wetterradarbildern kann auch aufgrund derer Texturunterschiede differenziert werden.

Den Abschluß des Kapitels bildet die Beschreibung zusätzlicher Bildbearbeitung-Methoden (Hough Transformation und morphologische Operatoren), die sich wertvoll für die Analyse der Wetterradarbildern erwiesen haben. Die Hough Transformation ist ein sehr gutes Werkzeug zur Erkennung der geometrischen Strukturen (Linien, Kreisen) auf dem Bild. Nichtmeteorologische Echos besitzen häufig deutliche geometrische Eigenschaften (z.B. die kreisförmige Störungen). Diese können daher durch Hough Transformation identifiziert werden.

4.1. Texturanalyse

Textur ist einfach zu unterscheiden und zu erkennen wenn wir sie sehen, aber es ist sehr schwer sie eindeutig zu definieren. Dieses Problem findet seine Widerspiegelung in der Vielzahl von verschiedenen Definitionen in der wissenschaftlichen Literatur [Tuceryan and Jain (1998)]. Das zeigt, dass es keine eindeutige Bestimmung gibt, die im Allgemeinen gültig wäre und die Definition ist immer von einer bestimmten Applikation abhängig. Im vorliegenden Dokument wird Textur als eine homogene Bildregion mit einer konstanten oder leicht variierenden statistischen, lokalen Charakteristik verstanden.

Historisch wurden die Methoden zur Textur Analyse in zwei Gruppen geteilt: statistische und strukturelle [Sonka et al. (1999)]. Die statistische Beschreibung gibt eine quantitative Charakteristik der Textur. Demzufolge werden dafür die Statistiken der ersten, zweiten und höheren Ordnung verwendet. Die einfachsten sind hier die Statistiken der ersten Ordnung (z.B. Mittelwert, Varianz) die lediglich die Informationen über Intensitäten liefern und keine aussagekräftigen Angaben über Eigenschaften der Textur geben. Weiters werden die Statistiken zweiter Ordnung verwendet, die schon eine Aussage über Pixelinteraktionen geben aber manchmal auch keine eindeutige und endgültige Entscheidung über Unterschiedlichkeit der verschiedenen Texturen treffen lassen.

In der strukturellen Analyse wird die Textur anhand von Texturelements (engl. *texels*, *primitives*, *subpatterns*) und Anordnungsregeln zwischen diesen beschrieben. Dementsprechend erfolgt die

Analyse in zwei Schritten: erstens müssen die Texels eindeutig definiert werden und zweitens muss die Anordnungsspezifikation festgelegt werden. Die strukturelle Analyse eignet sich gut für reguläre, „hand-made“ Texturen. Das Hauptproblem ist dabei das Definieren bzw. das Auffinden der geeigneten Texels. Deswegen eignet sich die Methode nicht oder nur beschränkt für Analyse natürlichen Texturen, die große Zufälligkeit und Differenzierung aufweisen.

Gegenwärtig findet man in der Literatur eine Reihe anderer Ansätze. [Tuceryan and Jain (1998)] schlagen eine Erweiterung der existierende Textur Analyse Taxonomie um weitere zwei Gruppen vor: Modell basierte Methoden und Methoden der Signalverarbeitung. Die bekannten modelbasierte Methoden sind Markov Random Fields und Fraktale Modelle. Die ersten basieren auf der Annahme, dass ein Bildpixel direkt von seiner lokalen Nachbarschaft abhängig ist und unabhängig von dem Rest des Bildes. Durch MRF werden die lokalen Charakteristiken zu einem Model zusammengefasst [Clausi (2001), Louis (2004)]. Die Fraktal basierten Modelle machen sich die Theorie der Fraktale zunutze. Fraktale sind geometrische Gebilde, die aus durch Faktor s verkleinerten Kopien von sich selbst bestehen [Mandelbrot (1991)]. Die zentrale Rolle in der fraktalen Geometrie spielt die fraktale Dimension. Bei einer Untersuchung der Textur wird neben fraktaler Dimension typischerweise auch noch die Lakunarität (engl. *lacunarity*) verwendet, ein Maß, das beschreibt wie das Fraktal den Raum erfüllt. Sie nimmt kleine Werte an, wenn die Dichte des Fraktals klein ist und größere Werte bei Grobkörnigkeit des Fraktals [Bourke (2009)]. Obwohl die fraktale Geometrie ein sehr interessantes Konzept darstellt, wurde sie nicht sehr oft in der Textur Analyse benutzt. [Varma and Garg (2007)] zeigen, dass die Problematik in der Verwendung globaler Textur Features besteht.

4.1.1. Statistische Textur-Analyse

Die statistischen Analysemethoden beschreiben die Textur in der Form, die sich weiter direkt zur Mustererkennung eignet. Normalerweise wird jede Textur mittels eines Merkmalsvektors beschrieben, der einen Punkt in einem mehrdimensionalen Raum darstellt [Sonka et al. (1999)].

Die frühen Arbeiten beschäftigten sich vor allem mit Autokorrelation Features, Co-Occurrence Matrizen, kantenbasierte Features [Sutton and Hall (1972)], Primitive Length [Galloway (1975)], [Gisolfi et al. (1986)] und Laws' Energy Features [Laws (1979)]. [Sharma and Singh (2000)] vergleichen in ihrem Bericht alle 5 Methoden. Sie verwenden für ihr Experiment die [Maestex (2009)] Bilddatenbank, die Bilder aus 4 verschiedenen Klassen enthält: Asphalt, Beton, Gras und Fels. Die besten Klassifikationsresultate wurden mit *k-nearest neighbour* unter Einsatz der Co-Occurrence Features erreicht, gefolgt von Autokorrelation Features.

4.1.1.1. Grey Level Co-Occurrence Matrix GLCM

Co-Occurrence Matrix ist zweifellos die bekannteste statistische Methode zur Textur Analyse. Die GLCM beschreibt die Häufigkeit der Grauwertkombinationen und die Relation zwischen den Bildpunkten. In der Praxis werden aus der Matrix die Haralick Merkmale berechnet (Tabelle 2). Eine Erweiterung der Co-Occurrence Matrix für Farbbilder sind die Korrelogramme.

Die GLCM wurde erstmals 1973 von [Haralick et al. (1973)] zur Texturklassifikation vorgeschlagen. Seitdem wurde ihre Leistungsfähigkeit im Bereich Textur Analyse mehrmals bewiesen [Sharma and Singh (2000)] und findet den Einsatz immer noch in vielen Applikationen. GLCM wurde mehrmals und erfolgreich zur Bildanalyse in der Fernerkundung eingesetzt [Haralick et al. (1973)], [Rignot and Kwok (1990)], [Kaleschke (2003)], [Xiaomei and Chenghu (1998)]. [Clausi and Jernigan (2000)] vergleichen Co-Occurrence, Markov Random Field und Gabor Filterung zur Klassifikation von Meereis auf SAR-Bildern, wobei die besten Klassifikationsergebnisse mit dem Einsatz der GLCM erzielt wurden. [Gill (2007)] entwickelte einen Algorithmus zur Clutter Entfernung in Wetterradarbildern, der ebenso auf Co-Occurrence Matrizen basiert. [Hu et al. (2008)] verwendet die GLCM um die Texturunterschiede in Niederschlägen aus verschiedenen Orten zu untersuchen.

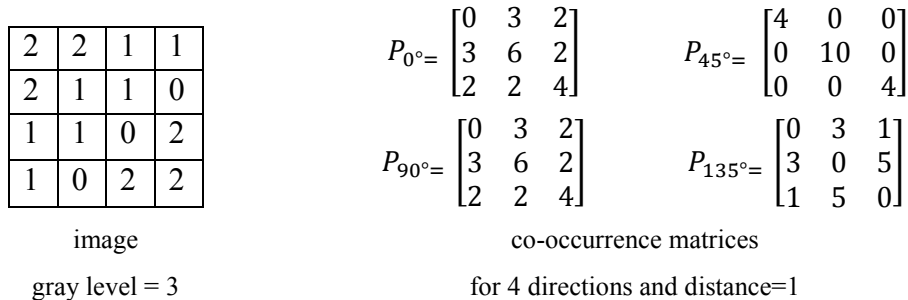


Abbildung 20: Berechnung der Co-Occurrence Matrizen.

Die Grundidee der Co-Occurrence Matrix (Gray Level Co-Occurrence Matrizen - GLCM) basiert auf den Häufigkeiten des Auftretens einer Pixelkonfiguration. Diese Konfiguration wird durch die Textur bestimmt. Sie ändert sich schnell bei feinen Texturen und langsam bei groben Texturen. Die Co-Occurrence Matrix besteht aus den Werten $P(a, b)$, die die absolute Auftrittshäufigkeit der Konfiguration zweier Pixels mit Farbe a und b , getrennt voneinander durch Abstand d und Winkel θ , beschreibt. In Abbildung 20 wird die Co-Occurrence Berechnung demonstriert. Die Klassifizierung der Textur erfolgt nach Haralick Merkmalen, die in der Tabelle 2 zusammengefasst wurden.

4.1.1.2. Region Kovarianz Deskriptor

Region Kovarianz Deskriptor ist ein weiteres statistisches Verfahren, das man zur Textur Analyse einsetzen kann. Der Ansatz ist relativ neu in der Bildverarbeitung, er wurde zuerst für Personentracking und Klassifikation durch [Porikli et al. (2005)] eingesetzt.

Energie	$\sum_{a,b} P^2(a, b)$
Entropie	$\sum_{a,b} P(a, b) \log P(a, b)$
Maximale Wahrscheinlichkeit	$\max_{a,b} P(a, b)$
Kontrast	$\sum_{a,b} (a - b)^2 P(a, b)$
Inverse difference moment	$\sum_{a,b;a \neq b} \frac{P(a, b)}{(a - b)^2}$
Korrelation	$\sum_{a,b} \frac{(a - \mu)(b - \mu)P(a, b)}{\sigma^2}$ mit $\mu = \sum_{a,b} a P(a, b)$
Homogenität	$\sum_{a,b} \frac{P(a, b)}{1 + a - b }$

Tabelle 2: Haralick Features.

Die Kovarianz Matrizen werden aus verschiedenen Features (z.B. Intensitäten, erste und zweite Ableitungen) innerhalb einer Region berechnet und auf ähnliche Weise wie Histogramme verwendet. Dabei ist zu beachten, dass sie keine Elemente des euklidischen Raums sind und deswegen nicht direkt in jedem Klassifikator eingesetzt werden können. Aufgrund dieser Tatsache

erfolgt die Distanzberechnung mit Hilfe z.B. der Förstner Metrik [Förstner and Moonen (1999)] oder Kullback-Leibler Divergenz [Kullback and Leibler (1951)]. Eine andere Möglichkeit wäre die Approximation der Kovarianz Matrix, was wiederum die Distanzkalkulation im euklidischen Raum ermöglicht [Kluckner et al. (2009)], [Kluckner and Bischof (2009)]. Um die schnelle und effiziente Berechnung zu ermöglichen werden die Kovarianz Matrizen mit Hilfe von Integralbildern berechnet [Porikli and Tuzel (2006)].

Die Leistungsfähigkeit des Kovarianz Deskriptors hängt unmittelbar von den eingesetzten Features ab. Untersuchungen in diesem Bereich zeigen, dass die meistens verwendeten Features Bildintensitäten, Koordinaten und Kanteninformationen sind. [Tou et al. (2009)] schlagen das Anwenden von Gabor Filter Outputs als Merkmalsbilder für den Kovarianz Deskriptor vor. Es wurde dadurch eine Erkennungsrate von 91.86% bei einem Experiment mit 32 Texturen aus der Bilderdatenbank [Brodatz (2009)] erreicht was ein sehr gutes Ergebnis darstellt. Zum Vergleich haben die Autoren in einem früheren Experiment mit demselben Datensatz beim Einsatz einer kombinierte Methode von GLCM und Gabor Filter ein Resultat von 88.52% erreicht [Tou et al. (2007)]. [Donoser (2007)], [Donoser and Bischof (2008)] entwickelten einen robusten Segmentierungsalgorithmus, der ebenso auf Kovarianzmatrizen basiert. [Kluckner and Bischof (2009)] verwendeten den Kovarianz Deskriptor im Zusammenhang mit Random Forest Klassifikator zur Segmentierung von Luftbildern.

Aus mathematischer Sicht ist die Kovarianz eine Maßzahl für die Beziehung zwischen zwei statistischen Merkmalen X und Y :

$$\text{cov}(X, Y) = E[(X - E[X]) * (Y - E[Y])] \quad (4.1)$$

wobei E den Erwartungswertoperator bezeichnet.

Die Kovarianzmatrix wird paarweise aus allen Kovarianzen des Zufallsvektors

$X=(X_1, X_2, \dots, X_n)$ aufgebaut:

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \dots & \sigma_{1n} \\ \vdots & \ddots & \vdots \\ \sigma_{n1} & \dots & \sigma_n^2 \end{bmatrix} \quad (4.2)$$

wobei $\sigma_i^2 = (X_i - \mu)^2$ bzw. $\sigma_{ij} = \text{cov}(X_i, X_j)$ mit $i, j = 1..n$. Die Diagonale der Matrix besteht aus allen Varianzen σ_i^2 . Die Kovarianzmatrix ist symmetrisch.

Die Kovarianz Matrix ist im euklidischen Raum nicht definiert. Deswegen ist es für die Klassifizierung notwendig eine andere Distanzberechnung anzuwenden. Eine Möglichkeit ist die durch [Förstner and Moonen (1999)] vorgeschlagene Metrik. Die Ähnlichkeit zwischen zwei Matrizen A und B wird folgendermaßen berechnet:

$$dist(A, B) = \sqrt{\sum_{i=1}^n \ln^2 \lambda_i(A, B)} \quad (4.3)$$

wobei $\lambda_i(A, B)$ die Eigenwerte von A und B sind.

4.1.2. Die Methoden der Signalverarbeitung

In der psychophysischen Forschung wurde gezeigt, dass ein Bild im menschlichen Gehirn einer Frequenzanalyse unterzogen wird. Das Bild wird in visuellem Kortex in Frequenz- und Orientierungskomponenten zerlegt [Tuceryan and Jain (1998)]. Diese Tatsache legte den Grundstein zum Einsetzen der Filter bzw. Filterbänke in der Textur Analyse und führt direkt zur Idee der Multiskalenanalyse. Das Einsetzen der Filterbänke ermöglicht die Betrachtung von Texturen in verschiedenen Frequenzen und Skalen.

In den nächsten Unterkapiteln werden verschiedene Filterungsmöglichkeiten gezeigt.

4.1.2.1. *Fourier Transformation*

Die Fourier Transformation zerlegt das Signal in Frequenzkomponenten und gehört zu den wichtigsten Werkzeugen der Signalverarbeitung. Die Transformation ist aber nicht immer optimal, die größte Einschränkung besteht darin, dass sie aus stetigen Funktionen (Sinus und Kosinus) aufgebaut ist. Außerdem geht die Information über Zeitverlauf bzw. Ortsinformation in einem zweidimensionalen Raum verloren [Hubbard (1997)]. Die Fourier Transformation ermöglicht eine globale Analyse des Bildes, die meisten Applikationen verlangen aber auch die räumlichen Informationen.

In der Bildverarbeitung wird eine Diskrete Fourier Transformation (DFT) verwendet, die auf zwei Dimensionen erweitert wurde:

$$f_{j_1, j_2} = \sum_{k_2=0}^{n_2-1} \sum_{k_1=0}^{n_1-1} x_{k_1 k_2} \cdot e^{\left(-i \frac{2\pi}{n_1} j_1 k_1\right)} \cdot e^{\left(-i \frac{2\pi}{n_2} j_2 k_2\right)} \quad (4.4)$$

In der Bildverarbeitung wird diese verwendet um die sich wiederholenden Störungen, die nur in einer gewissen Frequenz auftreten, zu eliminieren. Ansonsten wird die Transformation sehr oft dazu benutzt, die Faltungsoperation auf dem Bild durchzuführen. Die Reduktion der Faltung im Fourierraum zu einer Multiplikationsoperation lässt alle Kernelfilterungen deutlich schneller durchführen.

4.1.2.2. *Gabor Filterbänke*

Die Gabor Funktion kann als Modell von menschlichen rezeptiven Feldern angesehen werden. Gabor ähnliche Felder befinden sich auch in visuellen Kortex, die für verschiedene Frequenzen und Orientierungen verantwortlich sind.

Die Gabor Filterung wurde erstmals durch [Turner (1986)] und [Clark and A.C.Bovik (1987)] zur Textursegmentierung eingesetzt. Seither wurde für die Methode noch mehrmals ihre Leistungsfähigkeit im Bereich Bildsegmentierung und Klassifikation bewiesen [Jain and Farrokhnia (1990), Hammouda and Jernigan (2000)] und immer noch ist die Gabor Filterung eine aktuelle und oft verwendete Methode zur Texturanalyse. Dabei gilt es zu beachten, dass die Resultate der Segmentierung oder Klassifikation sehr stark von den verwendeten Filterparametern abhängig sind. Dieses Problem wurde in [Grigorescu et al. (2002), Claudi and Jernigan (2000), Tsai et al. (2001)] und [Moreno et al. (2005)] ausführlich diskutiert. Häufig wurde die Gabor Filterbank mit anderen Ansätzen kombiniert. [Tou et al. (2007)] schlägt vor die Gabor Features zusammen mit Co-Occurrence Features zu verwenden und erzielt somit eine signifikante Steigerung der Erkennungsrate. [Tou et al. (2009)] nutzt die Gaborbilder als Input für den Kovarianz Deskriptor.

Mathematisch gesehen wird der Gabor Filter als gefensterter Fourier Transformation beschrieben. Das Fenster wird normalerweise mit Hilfe der Gaußfunktion gebildet und dann mit der oszillierenden Funktion in verschiedenen Frequenzen durchgeführt. Das Signal wird „fensterweise“ analysiert, somit kann die Ortsinformation erhalten werden. Die Formel der Gabor Funktion lautet:

$$g_{\theta, f, \sigma_x, \sigma_y}(x, y) = \exp\left(-\frac{x'^2}{2\sigma_x^2} - \frac{y'^2}{2\sigma_y^2}\right) \cos(2\pi x' f) \quad (4.5)$$

mit

$$x' = x \cos \theta + y \sin \theta, y' = y \cos \theta - x \sin \theta.$$

4.1.2.3. *Wavelets Familien*

Wavelets sind eine Erweiterung der Fourier Transformation. Mit ihrer Hilfe ist es möglich das Signal gleichzeitig in der Frequenz- sowie in der Zeitebene zu untersuchen [Johns (2003)].

Die Wavelets verhalten sich genau umgekehrt wie die gefensterterte Fourier Transformation. Hier ändert sich die Fensterbreite und die Anzahl der Oszillationen bleibt unverändert (siehe Abbildung 21). Das Ausdehnen bzw. Zusammenziehen der Wavelets erfolgt mittels einer Skalierungsfunktion.




Abbildung 21: Gefensterter Fourier Analyse vs. Wavelet Analyse
 Oben: Bei der gefensterterten Fourier Analyse wird die Fensterbreite konstant gehalten und die Anzahl der Oszillationen variiert.
 Unten: ein Mutter Wavelet (links) kann gedehnt oder gestaucht werden; dadurch lassen sich die Signale über unterschiedliche Skalen untersuchen.

Für die Multiskalenanalyse werden Wavelets mit unterschiedlichen Skalen verwendet. Sie bilden eine sogenannte Wavelets Familie - eine Menge von Wavelets, die Mutter-Wavelets und ihre Töchter (Mutter-Wavelets, die durch Skalierung und Translation geändert wurden) enthält. Die „großen“ Wavelets können die groben Informationen extrahieren und die „kleinen“ Wavelets die Details. In der Bildverarbeitung wird die Diskrete Wavelet Transformation verwendet.

4.1.2.4. *Andere Filterbänke*

Motiviert durch psychophysische Forschung versuchten [Malik and Perona (1990)] ein Modell der menschlichen visuellen Wahrnehmung zu entwickeln. Sie verwendeten eine Filterbank, die aus zwei polysymmetrischen und sechs gerichteten Gauß Filtern besteht. Die ersten zwei Filter

entsprechen den einfachen Zellen der Netzhaut, die anderen sechs modellieren die komplexen Zellen, die auf Linienstücke bestimmter Orientierung reagieren [Pinz (1997)].

[Varma and College (2004)] vergleichen in ihrer Arbeit die Nützlichkeit der verschiedenen Filterantworten für Klassifizierung. Das Experiment wurde auf einem Datensatz mit verschiedenen Textilt Texturen durchgeführt und es wurden dafür folgende Filterbänke eingesetzt:

- Leung-Malik Set LM [Leung and Malik (2001)] – das Set wird aus 48 Filtern zusammengesetzt, die eine Analyse in mehreren Skalen und Richtungen ermöglicht. Die Leung-Malik Filterbank besteht aus 8 Laplacian of Gaussian Filtern, 4 low-pass Gauß Filter und 36 Filtern, die aus erster und zweiter Ableitung von Gaussian in 6 Richtungen und 3 Skalen gebildet wurden (siehe Abbildung 22).




Abbildung 22: LM Filterbank besteht aus insgesamt 48 Filter: erste und zweite Ableitung von Gauß Filter in 6 Richtungen und 3 Skalen, 8 Laplacian of Gaussian, 4 low-pass Gauß Filter [Leung and Malik (2001)].

- Schmid Set [Schmid (2001)] – diese Filterbank besteht aus 13 rotationsinvarianten „Gabor-like“ Filtern. Die Filter sind in Abbildung 23 dargestellt.




Abbildung 23: Schmid Filterbank besteht aus 13 rotationsinvarianten Filtern [Schmid (2001)].

- Maximum Response Set MR8 [Varma and College (2004)] – das Set ist von einer Filterbank (Basis Filterbank BSF, siehe Abbildung 24) abgeleitet, die aus 38 Filtern besteht: 1 Gaussian Filter, 1 Laplacian of Gaussian Filter, 18 Kantenfilter (in 6 Richtungen, 3 Skalen) und 18 Balkenfilter (in 6 Richtungen, 3 Skalen). Diese Filterbank ist sehr ähnlich zu dem Leung-Malik Set, wobei der MR8 Set gebildet wird, indem man die maximalen Filterantworten in jeder Richtung summiert. Der Output der Filterbank wird dadurch auf 8 Bilder reduziert. Durch diese Filterresponsesummierung wird auch Rotationsinvarianz erzielt.




Abbildung 24: BSF Filterbank besteht aus 2 anisotropische Filter in 6 Richtungen und 3 Skalen und 2 rotationsinvariante Filter (Gauß und Laplacian of Gaussian) [Varma and College (2004)].

Die besten Resultate erzielen die Autoren [Varma and College (2004)] unter Einsatz von BSF, MR8 und LM Filterbänke. Der große Vorteil von MR8 ist dabei, dass sie nur 8 Filteroutputs ergibt. Weiters wird eine große Vielfalt an Texturen abgedeckt indem sie isotropische und anisotropische Filterungen ermöglicht.

4.2. Hough Transformation

Die Hough Transformation ist ein Standardverfahren zur Erkennung von geometrischen Objekten. Die Transformation wurde von Hough erfunden und 1962 patentiert [Hough (1962)]. Ursprünglich war sie zur Erkennung von Geraden gedacht, es ist aber möglich mittels dieses Verfahrens jede beliebige parametrisierbare geometrische Figur zu erkennen [Sonka et al. (1999), Duda and Hart (1972)]. Es ist ebenfalls möglich auch nicht parametrisierbare Formen zu finden indem man eine formabhängige Lookup Tabelle errechnet [Ballard (1981)]. Diese Verfahren werden als generalisierte Hough Transformation bezeichnet.

Zur Erkennung der parametrisierbaren Figuren wird ein Parameterraum (Hough-Raum, Akkumulator) geschaffen, in den für jeden Bildpunkt, der auf einer Kante liegt alle möglichen Parameter eingetragen wurden. D.h. jedes mögliche Objekt im Bildraum wird durch einen Punkt im Hough Raum dargestellt. Die Maxima im Hough Raum repräsentieren die Parameter der gesuchten Figuren.

Die Laufzeit des Algorithmus nimmt sehr stark mit der Anzahl der Parameter zu, deswegen wird sie meist nur zur Erkennung einfacher Geometrien wie Linien und Kreise eingesetzt. Zur Geradenerkennung wird eine Parametergleichung in folgender Form verwendet:

$$d = x \cdot \cos \alpha + y \cdot \sin \alpha \quad (4.6)$$

Dabei sind x und y die Koordinaten der detektierten Kantenpunkte und α und d die Variablen, die gefunden werden sollen.

Die Kreise werden mit folgender Gleichung beschrieben:

$$(x - a)^2 + (y - b)^2 = c^2 \quad (4.7)$$

wobei die Variablen a, b, c durch Transformation bestimmt werden sollen. In Abbildung 25 ist das Erkennungsverfahren für Kreise schematisch dargestellt.

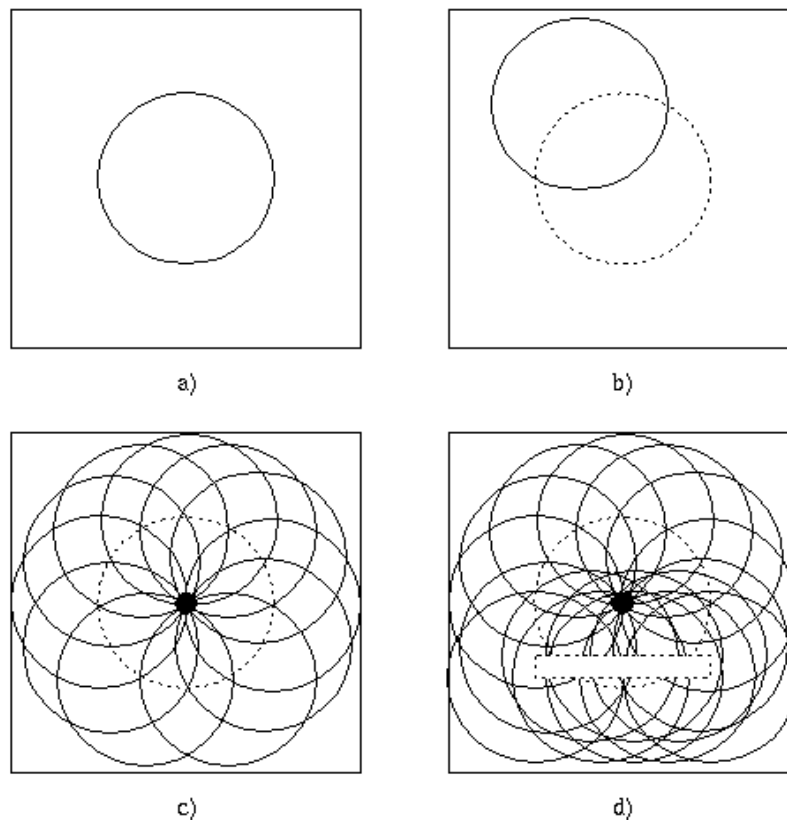


Abbildung 25: Hough Transformation zur Erkennung von Kreisen.
 a) originales Bild, b) für jedes Kantenpixel wurde ein potenzieller Kreis mit dem Radius r definiert, c) Zentrum vom Kreis wird durch das am meisten vorkommende Pixel bestimmt d) der Kreis wird richtig erkannt auch wenn die Information teilweise fehlt [Sonka et al. (1999)].

4.3. Mathematische Morphologie

Mathematische Morphologie hat ein breites Einsatzspektrum und wurde überall dort verwendet wo die Gestalt eine wichtige Rolle spielt. Morphologische Operationen werden vor allem für die Bildvorverarbeitung (Noise Filterung), für das Extrahieren von Objektstrukturen (Skelettierung, Bestimmung der Konvexe Hülle, Verdickung und Verdünnung), Segmentierung sowie für Quantitative Beschreibung verwendet [Sonka et al. (1999)]. Sie können sowohl auf den binären als auch auf Grauwertbildern eingesetzt werden. Die morphologische Operation ist eine nicht lineare Transformation vom Bildobjekt unter Verwendung des sogenannten Strukturelements. Die grundlegenden Operationen sind Dilation und Erosion, woraus weitere abgeleitet werden (Opening, Closing, Hit or Miss).

Dilation wird oft als *grow* oder *fill* Operation bezeichnet. Sie wird verwendet um kleine Löcher im Bild auszufüllen oder die Figurgestalten zu verbreiten. Für binäre Bilder ist die Dilation folgendermaßen definiert:

$$A \oplus B = \{p \in \varepsilon^2 : p = x + b, x \in X \text{ und } b \in B\} \quad (4.8)$$

Wobei A das binäre Bild bezeichnet und B das Strukturelement ist. Die Dilation $A \oplus B$ ist die Menge von allen möglichen paarweisen Vektoradditionen der Punkte von A und B .

Erosion dagegen schrumpft das Bildobjekt und kann mittels folgender Formel ausgedrückt werden:

$$A \ominus B = \{p \in \varepsilon^2 : p + b \in X \text{ für jede } b \in B\} \quad (4.9)$$

Diese Formel sagt, dass jeder Punkt von einem Binärbild getestet wird und das Resultat jene Punkte sind für die alle mögliche Additionen $p+b$ auch zu X gehören. Mit andere Worten wird bei der Erosion geprüft ob das Strukturelement vollständig in das Bildobjekt reinpasst; wenn ja wird das Pixel in die erodierten Menge einbezogen, wenn nicht wird es als Hintergrund markiert. Erosion wurde verwendet um das Objekt zu vereinfachen bzw. um ein komplexeres Objekt in mehrere einfachere Objekte aufzuteilen.

Dilation und Erosion sind nicht invers. Aus den zwei Basisoperation lassen sich folgende zwei ableiten: Opening und Closing, wobei der Unterschied in der Ausführungsreihenfolge liegt. Closing $A \bullet X$ vom Binärbild A mit dem Strukturelement X besteht zuerst aus Dilation und danach Erosion und wird folgendermaßen bezeichnet:

$$A \bullet X = (A \oplus X) \ominus X \quad (4.10)$$

Opening $A \circ X$ vom Binärbild A mit dem Strukturelement X besteht zuerst aus Erosion und danach Dilation und wird wie folgt ausgedrückt:

$$A \circ X = (A \ominus X) \oplus X \quad (4.11)$$

Hit or Miss Operation (bezeichnet mit dem Symbol \odot) wird zum Aussuchen gewisser lokaler Muster eingesetzt, die mittels Strukturelement definiert wurden. Damit können z.B. Ecken oder Endpunkte von Geraden im Bild aufgefunden werden. Wenn C und D ($X = C, D$) die

Strukturelemente und A das Binärbild bezeichnen, wird die Hit or Miss Transformation wie folgt definiert:

$$A \odot X = (A \ominus C) \cap (A^c \ominus D) \quad (4.12)$$

wobei A^c Komplement von A ist.

4.4. k-Nearest Neighbours Klassifikator

k -Nearest Neighbours Klassifikator (k -NN) ist ein Klassifikationalgorithmus, wobei die Klassenzuordnung auf Grund von kleinsten Distanzen zu Trainingssamples im Featureerraum und Mehrheitsentscheidung innerhalb der k nächsten Nachbarn vorgenommen wird [Duda et al. (2000)]. Das k ist typischerweise eine kleine positive Ganzzahl. Spezialfall ist wenn $k = 1$, dann wird das gegebene Objekt zu der Klasse seines nächsten Nachbarn zugewiesen. Die Auswahl der besten k -Größe ist von den verwendeten Daten abhängig. Größere k -Werte können das Rauschen in den Daten reduzieren.

Für die Klassifikation können verschiedenen Metriken eingesetzt werden. Das am meisten verwendete Abstandsmaß ist die euklidische Distanz:

$$dist(a, b) = \sqrt{\sum_{i=1}^n (a_i - b_i)^2} \quad (4.13)$$

wobei a und b Merkmalsvektoren sind und n die Länge der Vektoren.

Die Trainingsphase beim k -NN Klassifikator besteht aus simplen Abspeichern aller Trainingsbeispiele. Dieses Verfahren wird auch als "lazy learning" bezeichnet.

Texturklassifikation von Weterradarbildern

In diesem Kapitel werden die Methoden aus dem Bereich Texturanalyse in einem Klassifikations-Experiment direkt auf den Weterradarbildern angewendet. Den Schwerpunkt der Analyse bilden zwei Methoden: Co-Occurrence Matrizen und Region Kovarianz Deskriptor. Die Leistung des Region Kovarianz Deskriptors wurde in Zusammenhang mit verschiedenen Texturmerkmalen getestet, von einfachen Features wie Farbe und erste und zweite Ableitungen bis zu verschiedenen Filter Responses.

Die Co-Occurrence Matrix wurde in den Test einbezogen, weil es eine Methode ist, die schon mehrmals erfolgreich in der Texturanalyse, insbesondere in der Analyse von Satellitenbildern bzw. Fernerkundung eingesetzt wurde. Die Vermutung liegt nahe dass sich damit ebenso gute Ergebnisse beim Klassifizieren von Weterradarbildern erzielen lassen. Der größte Nachteil dieser

Methode ist ihre Komplexität. Im Fall von Grauwertbilder mit 256 Intensitätswerten müssen normalerweise die Co-Occurrence Matrizen in der Größe von 256x256 erstellt werden. Dafür braucht man entsprechend Rechenzeit und Speicherkapazitäten. Im Fall von Wetterrada**r**bildern existiert dieses Problem aber nicht, da die eingesetzten Wetterrada**r**bilder maximal 14 Intensitätswerte besitzen.

Der Kovarianz Deskriptor wurde in den letzten Jahren häufig eingesetzt und es wurde gezeigt dass sich damit sehr gute Klassifikationsergebnisse erzielen lassen. [Donoser (2007)] entwickelt eine robuste Segmentierungsmethode, die auf dem Kovarianz Deskriptor basiert und im Vergleich mit anderen Segmentierungsverfahren das beste Resultat liefert.

Wie schon im vorherigen Kapitel erwähnt wurde hängt die Leistung des Kovarianz Deskriptor unmittelbar von den eingesetzten Features ab; deswegen wurden hier mehrere Möglichkeiten getestet. Dabei wurde erwartet dass die in Texturanalyse bewährten Ansätze wie Gabor Filterung bzw. die Filterbänke von Malik und Leung (vgl. Kapitel 4.1.2) die Leistung der Kovarianz Deskriptor deutlich steigern lassen. Inwieweit sich die Erwartungen bewahrheiten zeigen die folgenden Tests.

5.1. Datensatz

Im Rahmen des Projekts DIBMETSAT wurde vom Projektpartner eine Datensammlung zur Verfügung gestellt, die Wetterrada**r**bilder von insgesamt einem Jahr enthält. Es handelt sich um Kompositbilder (vgl. Kapitel 2.2), die in Zeitintervallen von 5 Minuten gespeichert wurden. Das Hauptziel der Arbeit ist die nichtmeteorologischen Echos von Niederschlag möglichst gut zu differenzieren. Es ist nicht vordergründig eine Aussage zu liefern, um welche Art der Artefakte es sich genau handelt. Der Niederschlag selbst kann wiederum durch Dämpfung gestört werden (vgl. Kapitel 2.3.1). Aus diesen Gründen wurden drei Klassen definiert: Niederschlag, Niederschlagsdämpfung und Artefakte (nichtmeteorologische Echos). Aus den Bildern wurden Samples ausgeschnitten, die die 3 Klassen repräsentieren. Verwendet wurden insgesamt 460 Samples: 100 für Niederschlags-, 100 für gedämpfte Niederschlags- und 260 für die Artefaktsklasse (100 Samples mit kreisförmigen Störungen, 100 Samples mit linienartigen Störungen und 60 Samples für alle anderen möglichen Störungerscheinungen; für Beispielbilder siehe Abbildung 26, Abbildung 27, Abbildung 28). Die Experimente wurden mit verschiedenen großen Samples durchgeführt, so dass sich auch eine Aussage über die optimale Größe von Nachbarschaften in den untersuchten Bildern machen lässt.




Abbildung 26: Niederschlag Samples




Abbildung 27: Dämpfung Samples



Abbildung 28: Artefakte Samples.

5.2. Evaluierung

Die Versuche wurden jeweils mit demselben Datensatz durchgeführt, unter Einsatz von *Leave One Out* Kreuzvalidierung (engl. *Leave One Out Cross Validation*) und Nearest Neighbours Klassifikator.

Die Kreuzvalidierung ist ein Testverfahren aus der Statistik bzw. der Datenanalyse, wobei die aus N Instanzen bestehende Datensammlung in k Teilmengen T_1, \dots, T_k , mit $k \leq N$, aufgeteilt wird. Danach wird der Test k -mal durchgeführt, jeweils mit verschiedenen Testmengen T_1, \dots, T_k . Die verbleibende $k-1$ Teilmengen $\{T_1, \dots, T_k\} \setminus \{T_i\}$ werden als Trainingsmengen verwendet. *Leave One Out* Kreuzvalidierung ist ein Spezialfall der Kreuzvalidierung mit $k=N$.

Die Klassifikation erfolgt mittels k-NN Klassifikator unter Einsatz von zwei Metriken: Förstner Metrik für Kovarianz Deskriptor und euklidische Metrik für histogrammbasierten Ansätze (vgl. Kapitel 4.1, 4.4).

5.2.1. Co-Occurrence Haralick Features

Die Co-Occurrence Matrizen wurden für 4 Richtungen und für verschiedene Distanzen berechnet. Aus den Matrizen wurden die sechs Haralick Features (Energie, Entropie, Wahrscheinlichkeit, Kontrast, IDM, Korrelation) berechnet und zu einem Feature Vektor zusammengesetzt.

$$fv = [En(d,\varphi) \ Ent(d,\varphi) \ Prob(d,\varphi) \ Co(d,\varphi) \ Idm(d,\varphi) \ Cor(d,\varphi) \ ...]$$

Co-Occurrence Matrizen für Haralick Features			
	Dimension	Parameter	Korrektheit
CO (1)	72 (Hist.)	Distanzen $d = \{2, 6, 12\}$ Richtung $\varphi = \{0, 45, 90, 135\}$	0.8674
CO (2)	72 (Hist.)	Distanzen $d = \{5, 10, 15\}$ Angle $\varphi = \{0, 45, 90, 135\}$	0.8587

Tabelle 3: Parameter für Co-Occurrence Matrizen und maximal erreichte Korrektheitsrate.

Die beste Klassifikationsrate wurde bei Samplegrößen zwischen 25 und 37 Pixel (ca. 85% für CO(1) und 84% für CO(2)) und für 85 und 97 Pixels (ca. 87 % für CO(1), 85% für CO(2)) erzielt. Die Abbildung 29 zeigt auch, dass die Resultate für kleinere Distanzwerte besser sind.

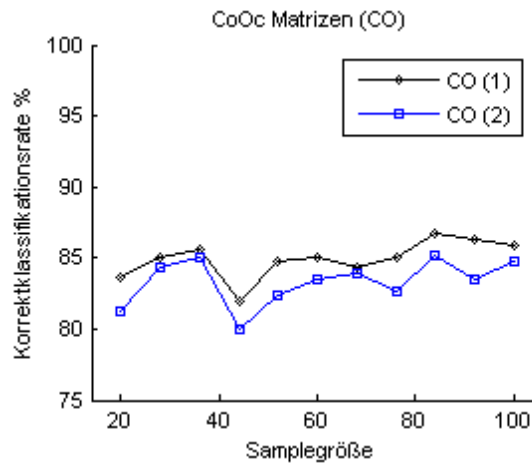


Abbildung 29: Evaluation der Co-Occurrence Matrizen mit Haralick Features für verschiedenen Samplegröße.

5.2.2. Low Level Features für Kovarianz Deskriptor

Der Kovarianz Deskriptor wird meistens mit Intensitäten und ersten bzw. zweiten Ableitungen vom Bild verbunden [Porikli and Kocak (2006)], [Donoser and Bischof (2008)]. Die maximale Klassifikationsrate, die mit dem Ansatz in unserem Versuch erzielt wurde, beträgt 91,5 % bei einer Samplegröße von 45x45 Pixel (siehe Abbildung 30, Tabelle 4). Im Hinblick darauf, dass nur 5 Features angewendet wurden stellt das ein relativ gutes Ergebnis dar.

$$fv = [G \quad Ix' \quad Iy' \quad Ix'' \quad Iy'']$$

Low Level Features für Kovarianz Deskriptor			
	Dimension	Features	Korrektheit
EC	5	Intensität, erste und zweite Ableitung	0.9152

Tabelle 4: Parameter für Kovarianz Deskriptor und maximal erreichte Korrektheitsrate.

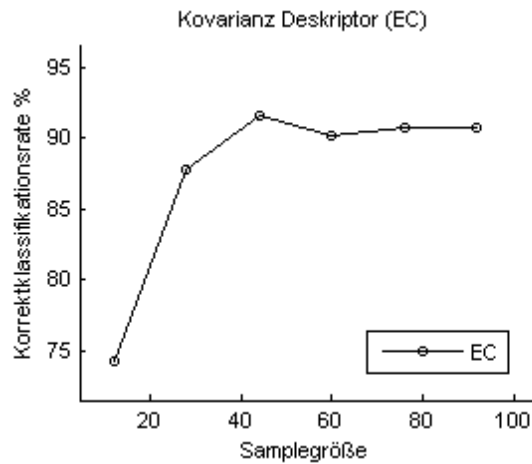


Abbildung 30: Evaluation des Kovarianz Deskriptor mit Low Level Features.

5.2.3. Gabor Filterbank

In diesem Test wurden die Gabor Filterbänke zweimal in Betracht gezogen. Zuerst wurden die Gabor Filter Responses direkt als Input für den Kovarianz Deskriptor verwendet. Die maximale Klassifikationsrate beträgt 97 % bei Samplegröße 57x57 Pixel (siehe Abbildung 31 , Tabelle 5). Dieses Ergebnis ist aber mit hohen Rechenzeiten verbunden, da die Kovarianz Matrix für 36 Feature Bilder erstellt werden muss. Bei halber Anzahl der Features ist die Klassifikationsrate um ca. 1.5 % gesunken, die Laufzeit ist aber um den Faktor 3.5 verkürzt.

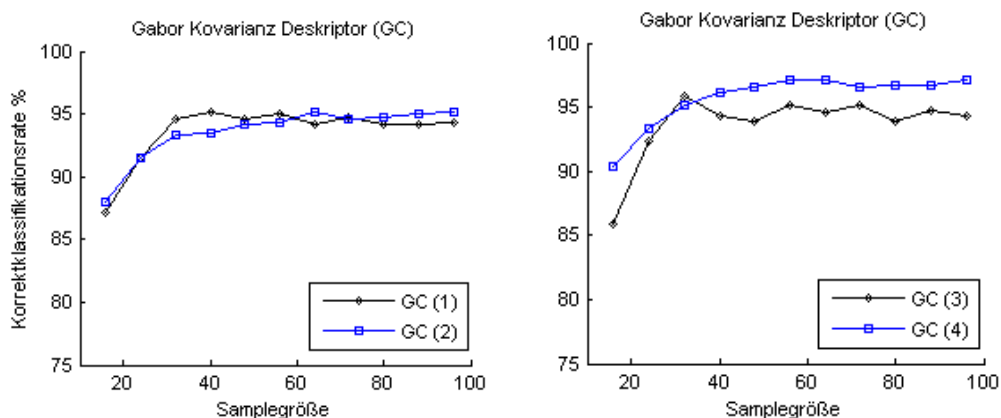


Abbildung 31: Evaluation der Gabor Filterbank Responses als Features für Kovarianz Deskriptor.

Gabor Kovarianz Deskriptor			
Filter	Dimension	Parameter	Korrektheit
GC (1)	18	Skalen(σ_x, σ_y) = {(7,7)} Orientierung θ = {0,30,60,90,120,150} Frequenzen = {1/6, 1/3, 1/2}	0.956
GC (2)	18	Skalen (σ_x, σ_y) = {(15,15)} Orientierung θ = {0,30,60,90,120,150} Frequenzen = {1/15, 1/5, 1/3}	0.956
GC (3)	36	Skalen (σ_x, σ_y) = {(5,5), (7,7)} Orientierung θ = {0,30,60,90,120,150} Frequenzen = {1/6, 1/3, 1/2}	0.959
GC (4)	36	Skalen (σ_x, σ_y) = {(7,7), (15,15)} Orientierung θ = {0,30,60,90,120,150} Frequenzen = {1/15, 1/5, 1/3}	0.972

Tabelle 5: Parameter von Gabor Filtern für Kovarianz Deskriptor und maximal erreichte Korrektheitsrate.

Der zweite Versuch war durch das Verfahren von [Porikli and Kocak (2006)] motiviert. In dieser Testserie wurde untersucht inwieweit sich die Klassifikationsergebnisse ändern, wenn anstatt der Kovarianzmatrix, nur die Koeffizienten der Kovarianzmatrix, konkateniert zur einem Feature Vektor, verwendet werden. Da die Kovarianzmatrix symmetrisch ist werden in dem Histogramm nur die eindeutigen Koeffizienten gespeichert. Das Histogramm hat insgesamt $d(d+1)/2$ Werte. Für die Klassifikation wurde euklidische Metrik eingesetzt.

$$\Sigma = \begin{pmatrix} \sigma^2_1 & \cdots & \sigma_{1n} \\ \vdots & \ddots & \vdots \\ \sigma_{n1} & \cdots & \sigma^2_n \end{pmatrix} \rightarrow fv = [\sigma^2_1, \dots, \sigma^2_n, \sigma_{12}, \dots, \sigma_{nn-1}, \dots, \sigma_1]$$

Im Vergleich zum Kovarianz Deskriptor schneiden die Kovarianz Koeffizienten Histogramme durchschnittlich um 6% schlechter ab. Die maximale Klassifikationsrate bei diesen Versuchen beträgt 92% (für 49x49 Pixel große Samples).




Abbildung 32: Evaluation der Gabor Filterbank Responses als Features für Kovarianz Matrix Koeffizienten Histogramm.

5.2.1. Leung Malik und Basis Filterbänke

Die LM und BSF (sowie MR8, die von BSF abgeleitet sind, vgl. Kapitel 4) Filterbänke wurden ebenso mit verschiedenen Parametern getestet. Zuerst wurden die Filter mit den originalen Parametern angewendet, die auch von [Varma and College (2004)] in ihrer Dissertation benutzt wurden. Im nächsten Test wurden die Skalenparameter schrittweise verkleinert. Wie in Abbildung 33 bzw. Tabelle 6 ersichtlich schneiden die kleineren Skalen bei BSF und LM Filtern besser ab, die Klassifikationsrate ist um ca. 1% gestiegen. Für MR8 hat die Parameteränderung kaum Verbesserung gebracht.

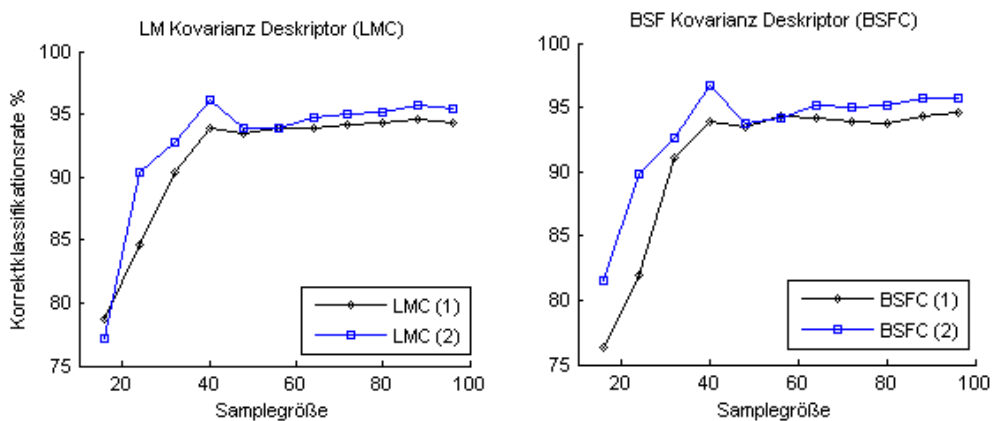


Abbildung 33: Evaluation der LM bzw. BSF Responses als Features für Kovarianz Deskriptor.

Gabor Kovarianz Matrix Koeffizienten Histogramm			
	Dimension	Parameter	Korrektheit
GCH (1)	171(Hist.)	Skalen $(\sigma_x, \sigma_y) = \{(7,7)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Frequenzen = $\{1/6, 1/3, 1/2\}$	0.9000
GCH (2)	171(Hist.)	Skalen $(\sigma_x, \sigma_y) = \{(15,15)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Frequenzen = $\{1/15, 1/5, 1/3\}$	0.9174
GCH (3)	666(Hist.)	Skalen $(\sigma_x, \sigma_y) = \{(5,5), (7,7)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Frequenzen = $\{1/6, 1/3, 1/2\}$	0.9065
GCH (4)	666(Hist.)	Skalen $(\sigma_x, \sigma_y) = \{(7,7), (15,15)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Frequenzen = $\{1/15, 1/5, 1/3\}$	0.8935

Tabelle 6: Parameter von Gabor Filtern für Kovarianz Matrix Koeffizienten Histogramm und maximal erreichte Korrektheitsrate.

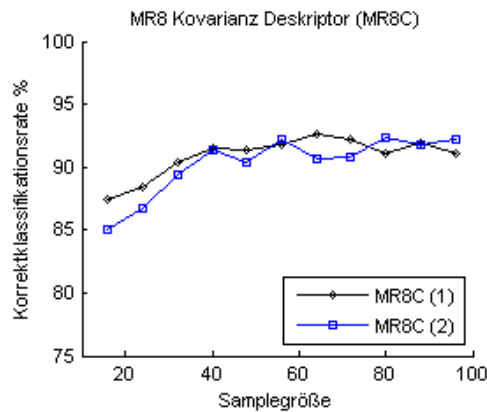


Abbildung 34: Evaluation der MR8 Filterbank Responses als Features für Kovarianz Deskriptor.

Filter Responses für Kovarianz Deskriptor			
Filter	Dimension	Parameter	Korrektheit
LM (1)	48	Skalen $(\sigma_x, \sigma_y) = \{(\sqrt{2}, 3\sqrt{2}), (2,6), (2\sqrt{2}, 6\sqrt{2})\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ 4 Gaussian Filter mit $\sigma = \{\sqrt{2}, 2, 2\sqrt{2}, 4\}$ 8 LOG Filtern mit σ und 3σ	0.950
LM (2)	48	Skalen $(\sigma_x, \sigma_y) = \{(1,3), (\sqrt{2}, 3\sqrt{2}), (2,6)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ 4 Gaussian Filter mit $\sigma = \{1, \sqrt{2}, 2, 2\sqrt{2}\}$ 8 LOG Filtern mit σ und 3σ	0.961
BSF (1)	38	Skalen $(\sigma_x, \sigma_y) = \{(1,3), (2,6), (4,12)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Gaussian Filter mit $\sigma = 10$ LOG Filter mit $\sigma = 10$	0.946
BFS (2)	38	Skalen $(\sigma_x, \sigma_y) = \{(0.5,1.5), (1,6), (2,6)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Gaussian Filter mit $\sigma = 5$ LOG Filter mit $\sigma = 5$	0.967
MR8 (1)	8	Skalen $(\sigma_x, \sigma_y) = \{(1,3), (2,6), (4,12)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Gaussian Filter mit $\sigma = 10$ LOG Filter mit $\sigma = 10$	0.926
MR8 (2)	8	Skalen $(\sigma_x, \sigma_y) = \{(0.5,1.5), (1,6), (2,6)\}$ Orientierung $\theta = \{0,30,60,90,120,150\}$ Gaussian Filter mit $\sigma = 5$ LOG Filter mit $\sigma = 5$	0.928

Tabelle 7: Parameter von LM, BSF und MR8 Filterbänken und maximal erreichte Korrektheitsrate.

5.2.2. Einfluss der Nachbaranzahl auf k-NN Ergebnisse

Bei den Methoden, die in den obigen Tests gute Ergebnisse erzielt haben, wurde zusätzlich der Einfluss des Parameters k für k-NN Klassifikation untersucht. Die Versuche wurden für jene Samplegröße durchgeführt, welche die maximale Korrektheit im vorherigen Test erzielt hat. Die Resultate sind in der Tabelle 8 zusammengefasst.

	$k=1$	$k=3$	$k=5$	$k=7$
GC (1) Sample 39x39	0.9587	0.9478	0.9435	0.9261
GC (4) Sample 57x57	0.9717	0.9652	0.9478	0.9370
BFS (2) Sample 41x41	0.9674	0.9413	0.9391	0.9152
LM (2) Sample 41x41	0.96087	0.9370	0.9130	0.9174

Tabelle 8: Einfluss der Nachbaranzahl auf Resultate des k-NN Klassifikators.

Die besten Ergebnisse wurden immer bei $k = 1$ beobachtet. Bei der Analyse der Konfusionsmatrizen zeigt sich dass die Klassifikationsrate für Artefakte sinkt, die Unterscheidung zwischen Niederschlag und Niederschlagsdämpfung bleibt aber gleich oder wird sogar minimal besser. Das kann darauf hinweisen dass es zwischen Artefaktsklasse und Niederschlags- bzw. Niederschlagsdämpfung weniger Überlappungen im Merkmalsraum gibt, aber zwischen Niederschlags- und Niederschlagsdämpfungsklasse mehr Überlappungen bestehen (siehe Abbildung 35, Abbildung 36).

	Niederschlag	Dämpfung	Artefakt
Niederschlag	94	6	0
Dämpfung	7	92	1
Artefakt	2	3	255

Abbildung 35: Konfusionsmatrizen für Klassifikation mit GC(1) und k-NN mit $k=1$.

	Niederschlag	Dämpfung	Artefakt
Niederschlag	95	6	4
Dämpfung	5	93	8
Artefakt	0	1	248

Abbildung 36: Konfusionsmatrizen für Klassifikation mit GC(1) und k-NN mit $k=3$.

In der unten stehenden Tabelle 9 sind Rechenzeiten zusammengefasst, die zur Klassifizierung benötigt wurden, in Abhängigkeit von der Anzahl der Features bzw. eingesetzten Methode. Die angegebenen Zeiten entsprechen der Durchführung des Tests mit dem gesamten Testsatz. Die Tests wurden im MATLAB durchgeführt.

Dimension*	Hist.171	Hist.666	Cov.5	Cov.8	Cov.18	Cov.38	Cov.48
Zeit	<i>0.24 sec.</i>	<i>0.86 sec.</i>	<i>5 sec.</i>	<i>7 sec.</i>	<i>15 sec.</i>	<i>55 sec.</i>	<i>98 sec.</i>

*Die Bezeichnung *Hist.171* steht für histogrammbasierten Methode mit 171 Features, *Cov.5* steht für auf Kovarianz Deskriptor basierten Methode mit 5 Features, usw.

Tabelle 9: Durchschnittliche Rechenzeit, die zur Durchführung der Klassifikation benötigt wurde.

5.3. Resümee

In diesem Kapitel wurden mehrere Methoden aus dem Bereich Textur Analyse evaluiert. Die Ergebnisse haben die Erwartung bestätigt, dass der Kovarianz Deskriptor im Zusammenhang mit den Filterdatenbanken sehr gute Resultate liefert. Wichtig für die Klassifikation ist die Nachbarschaft, die berücksichtigt werden soll. Für diese Ansätze oszilliert die optimale Nachbarschaftsgröße bei der Größe von 40 Pixel. Die Erkenntnisse aus den oben beschriebenen Experimenten bilden die Grundlagen zur Auswahl der Methoden und Parameter für den komplexen Algorithmus zur Analyse der Wetterradarbilder.

Weterradarbildanalyse

In diesem Kapitel werden die Methoden zur Weterradarbildanalyse vorgestellt, beginnend mit der Beschreibung des Segmentierungsalgorithmuses. Das segmentierte Bild ist Ausgangspunkt für die Erkennung von Artefakten und Niederschlagsdämpfung. Anschließend wird die Methode für die Erkennung der Erfassungslücken beschrieben. Den Abschluß bildet der Workflow zur Erkennung der nichtmeteorologischen Echos.

Die Fundamente für den Algorithmen entstammen der Arbeitsweise der Meteorologen. In ähnlicher Weise wie die Meteorologen die Bilder analysieren, wobei das Bild jeweils in drei Aspekten betrachtet bzw. untersucht wird:

- Analyse der Textur
- geometrische Analyse
- Überlebenszeitanalyse der Erscheinungen.

Diese drei Aspekte sind wichtig sowohl für die Erkennung der Artefakte als auch für das Detektieren der Erfassungslücken. In beiden Fällen spielt die Zeitanalyse eine Schlüsselrolle. Die Niederschläge besitzen eine bestimmte „zeitliche“ Charakteristik, sie wachsen oder schrumpfen kontinuierlich, existieren über eine relativ lange Zeitspanne und ihre Bewegung erfolgt in Windrichtung. Die Artefakte hingegen treten willkürlich und überraschend auf. Die Erfassungslücken, die aufgrund von geographischen Hindernissen entstehen sind durch Wiederholbarkeit charakterisiert.

6.1. Textursegmentierung

Die Segmentierung des Wetterrada**r**bilds ist der erste Schritt zur weiteren Analyse. Damit werden Echopixel in drei Klassen aufgeteilt: Niederschlag, gedämpfter Niederschlag und Artefakte. Das segmentierte Bild soll direkt die Informationen über Dämpfungsbereiche liefern (vgl. Kapitel 6.2.2) und stellt die Basis für den Algorithmus zur Erkennung der nichtmeteorologischen Echos dar (vgl. Kapitel 6.3).

Jedem Bildpixel wurde eine Klasse zugeordnet (Niederschlag, Niederschlagsdämpfung oder Artefakte), die das Pixel und seine Umgebung am besten repräsentiert. Die Klassifizierung erfolgt mit Nearest Neighbour Klassifikator. Auf Grund der begrenzten Anzahl von Ground Truth Daten wurden die Training Samples manuell direkt aus den bereitgestellten Kompositbilder hergestellt. Das Sampleset von Kapitel 5 wurde um weitere Beispiele erweitert. Es ergab sich eine Menge von insgesamt 1600 Samples für alle drei Klassen. In der Trainingsphase wurden die s Samples von jedem Klassensubset randomisiert ausgesucht.

$$\begin{aligned}S_{Niederschlag} &= 150 \\S_{Dämpfung} &= 80 \\S_{Artefakt} &= 200\end{aligned}$$

Zur Textursegmentierung wurden Kovarianz Deskriptor und Gabor Filter Responses ausgewählt. Dieses Tandem hat ein gutes Ergebnis beim Deskriptor Vergleich in dem vorherigen Kapitel erzielt und wurde als optimal für diese Aufgabe angesehen. Das Bild wurde einer Filterung in sechs Orientierungen und 3 Frequenzen unterzogen (Tabelle 10). Es wurde nur ein Skale

verwendet, da die Filterung in mehreren Skalen die Klassifikationsrate nur wenig aber die Berechnungszeit deutlich erhöht (vgl. Kapitel 5). Damit ergeben sich 18 Filteroutputs, die als Features für die Segmentierung eingesetzt werden. Die Trainingsamples wurden ebenso gefiltert und gespeichert.

Die Versuche in dem vorherigen Kapitel haben gezeigt dass die optimale Nachbarschaftsgröße für Klassifizierung mit dem Kovarianz Deskriptor und Gabor Filtern bei diesem Parameter 39 Pixel beträgt.

σ_x	σ_y	Orientierung θ	Frequenzen
7	7	{0,30,60,90,120,150}	{1/6, 1/3, 1/2}

Tabelle 10: Parameter für Gabor Filterung.




Abbildung 37: Beispiele für gefilterte Niederschlags- bzw. Artefaktssample.

Die Klassifizierung wird nur für Bildpixel mit Intensität größer 0 durchgeführt. Die Bildpixel mit dem Wert 0 beziehen sich auf Hintergrund ("freier Himmel").




Abbildung 38: Beispiele für Segmentierungsergebnisse.
Links: originales Bild, rechts: segmentiertes Bild.

6.2. Erkennung der Erfassungslücken

Erfassungslücken können grundsätzlich zwei Ursachen haben. Erstens kann die Radarstrahlung durch geographische Hindernisse gehemmt werden (orographische Abschattung). Weiters kann der Radarstrahl durch z.B. starke Niederschlagszellen, die sich in seinem Strahlweg befinden abgeschwächt werden und dahinter liegender Niederschlag wird in dem Fall nicht in voller Stärke erfasst (vgl. Kapitel 2).

6.2.1. Orographische Abschattung

Die orographischen Abschattungen sind durch Wiederholbarkeit charakterisiert. Diese Störungen sind meist durch die geographische Gestaltung des Gelände bedingt und treten deswegen immer

auf denselben Stellen im Bild (vgl. Kapitel 2) auf. Es existieren Abschattungsdiagramme mit Markierung dieser Bereiche (siehe Abbildung 39).

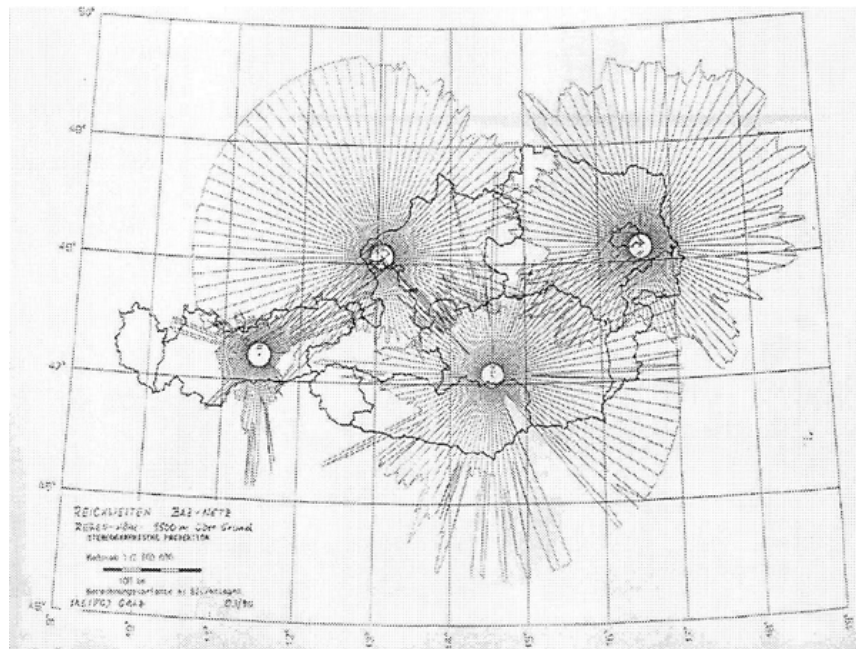


Abbildung 39: Abschattungsdiagramm für die vier Wetterradarstationen der Austro Control für die Schicht 1500m über Grund [Köck (1999)].

Das Problem dabei besteht darin, dass die orographischen Abschattungsgebiete sich mit der Höhe ändern, das heißt dass für eine genaue Bestimmung es notwendig ist radarelevationsabhängige Abschattungsdiagramme zu verwenden. Für diese Arbeit sind solche Diagramme wenig hilfreich, da nur Kompositbilder zur Verfügung stehen und die Höheninformation von Niederschlagszellen deswegen nicht vorhanden ist.




Abbildung 40: Summenbild.

Die Bereiche lassen sich aber approximieren indem ein Radarsummenbild über ein längeres Zeitintervall erstellt wird. In der Abbildung 40 wird ein solches Bild angezeigt. Es wurde durch Summieren der Kompositbilder von einem Jahr erzeugt. Die dunkleren Kreissegmente weisen auf orographischen Abschattungen hin. Die meisten befinden sich in dem Bereich der Radarstationen am Patscherkofel und bei Salzburg, da sich dort hohe Alpenketten befinden. Alle mögliche Abschattungssektoren wurden aus das Summenbild extrahiert und ihre Polarkoordinaten gespeichert.

Die Aufgabe war es die abgeschatteten Kreissegmente in dem Kompositbild zu detektieren. Dabei sollten nur diese Segmente detektiert werden, die in gegebenen Zeitpunkt wirklich betroffen waren und nicht alle potenziell möglichen. Dafür zeigt sich wiederum die Transformation in Polarkoordinaten als gute Hilfe. Die Kreissektoren werden in Polarkoordinaten zu Streifen. Die Abschattung sind in Bereichen zu finden, wo starke Gradienten (Formel 4.17) in der horizontalen Richtung auftreten und eine Gerade formen (siehe Abbildung 41).

$$\nabla F_x = \frac{\partial F}{\partial x} \quad (4.17)$$

Liegt die Gerade in dem Bereich der vorher gespeicherten Sektoren wird der Sektor als betroffener Abschattungsbereich markiert.




Abbildung 41: Erkennung der orographischen Abschattungssektoren. Oben: Kompositbild, Bereich einer Radarstation; links oben: Transformation in Polarkoordinaten; links unten: Gradientenbild; rechts: gefundener Abschattungssektor.

Diese Methode wurde anhand von 10 plausiblen Beispielbildern getestet und in allen Fällen wurden die Sektoren richtig erkannt.

6.2.2. Niederschlagsdämpfung

Das Identifizieren der Niederschlagsdämpfung soll mittels Bildsegmentierung erfolgen. Die Aufgabe ist besonders schwierig, da die Dämpfungsbereiche nur in wenigen Fällen eindeutig definierbar sind. Aus demselben Grund ist die "pixelweise" Erstellung der Ground Truth für Dämpfungsbereiche praktisch unmöglich, was wiederum die Auswahl der richtigen Trainingssamples und die Evaluierung der Ergebnisse erschwert.




Abbildung 42: Beispiele für segmentierte Dämpfungsbereiche.
Links: originales Bild mit markierten Dämpfungsbereichen,
rechts: segmentiertes Bild

Um die Qualität der segmentierten Dämpfungsbereiche beurteilen zu können, wurden von Meteorologen 15 Bilder ausgewählt worin eindeutige Dämpfungsbeispiele markiert werden konnten. Die Vergleiche haben gezeigt, dass die Segmentierung nur in wenigen Fällen die betroffenen Bereiche richtig erkannt hat (siehe Abbildung 42). Das ist keine Überraschung in Anbetracht der oben erwähnten Erschwernisse. Eine mögliche Lösung für das Problem ist eine sorgfältige Aufbereitung von mehreren plausiblen Dämpfungsbeispielen durch Meteorologen. Damit kann die Trainingsphase beim Klassifizieren besser durchgeführt werden. Im Laufe der Arbeit hat sich aber gezeigt dass solche Bearbeitungen sehr aufwendig und damit auch mit großen Kosten verbunden sind.

6.3. Erkennung der nichtmeteorologischen Echos

Die Erkennung der nichtmeteorologischen Echos erfolgt in drei Schritten. Zuerst wird das gesamte Bild segmentiert. Danach werden die geometrischen Eigenschaften berechnet und anschließend wird das Bild der zeitlichen Analyse unterzogen.

6.3.1. Bildsegmentierung

Erster Schritt zur Erkennung der Artefakte ist die Bildsegmentierung (vgl. 6.1). Dabei sind zwei Klassen von Bedeutung: Artefakte und nicht Artefakte (Niederschlag und Niederschlagsdämpfung werden als eine Klasse betrachtet). Die Resultate der Textursegmentierung könnten anhand Ground Truth gemessen werden und werden im Kapitel 6.3.5 genau diskutiert.

6.3.2. Geometrische Analyse

Die meisten Artefakte weisen deutliche geometrische Eigenschaften auf. Die kreisförmigen Störungen erscheinen als Teile der Kreise und deren Zentren sind in der Nähe von Radarstationen platziert (siehe Abbildung 43). Die Störungen, die durch RLAN oder Sonne verursacht worden sind erscheinen auf dem Kompositbild in der Form von linienartigen Strukturen, die zu der Wetterradarstation gerichtet sind (vgl. Kapitel 2, siehe Abbildung 44).




Abbildung 43: Kreisförmige Störungen. Mit weißem Punkt wurde die Radarstation markiert.




Abbildung 44: Linienartige Artefakten zeigen zu Radarstationen.

Diese Eigenschaften stellen sehr wichtige und hilfreiche Informationen dar. Es wurden zwei Möglichkeiten zur Erkennung der geometrischen Artefakte in Betracht bezogen. Mit Hilfe der Hough Transformation werden die kreisförmigen Störungen gefunden. Die linienartige Störungen wurden mit morphologischen Operatoren in Polar Koordinaten gefunden. Das Anwenden der

Morphologie zur Erkennung der linienartigen Störungen statt Hough Transformation ist durch Einfachheit und Zeiteffizienz erklärt.

6.3.2.1. Polarkoordinaten vs. kartesische Koordinaten

Die vom Radar gelieferten Daten liegen in Polarkoordinaten vor. In weiteren Vorbereitungsschritten werden sie ins kartesische Koordinatensystem umgewandelt und zu einem Kompositbild zusammengefasst. Wie im nächsten Unterkapitel beschrieben lassen sich manche Störungen in Polarkoordinaten leichter erkennen. Das könnte noch einfacher werden wenn die Rohdaten in Polarkoordinaten und einzeln für jede Station zur Verfügung stehen. Die Umwandlung in kartesische Koordinaten bewirkt einen deutlichen Informationsverlust, besonders in der Nähe der Radarstation wo ein Pixel im kartesischen Koordinatensystem von mehreren Strahlen überdeckt wird (siehe Abbildung 45).




Abbildung 45: Polarkoordinaten vs. kartesische Koordinaten [Leitner (1999)].

Die Umrechnung von Polarkoordinaten in kartesischen Koordinaten erfolgt:

$$x = r * \cos \varphi \quad (4.13)$$

$$y = r * \sin \varphi$$

Für die Umrechnung von kartesischen Koordinaten zurück in Polarkoordinaten gilt:

$$\begin{aligned} r &= \sqrt{(x^2 + y^2)} \\ \varphi &= \operatorname{atan2}(y, x) \end{aligned} \quad (4.14)$$

Die Funktion $\operatorname{atan2}$ wird wie folgt definiert:

$$\operatorname{atan2}(y, x) = \begin{cases} \arctan \frac{y}{x}, & \text{für } x > 0 \\ \arctan \frac{y}{x} + \pi, & \text{für } x < 0, y \geq 0 \\ \arctan \frac{y}{x} - \pi, & \text{für } x < 0, y < 0 \\ \frac{\pi}{2}, & \text{für } x = 0, y > 0 \\ -\frac{\pi}{2}, & \text{für } x = 0, y < 0 \\ 0, & \text{für } x = 0, y = 0 \end{cases} \quad (4.15)$$

6.3.2.2. *Erkennung von linienartigen Störungen*

Die Störungen, die durch RLAN oder Sonne verursacht worden sind erscheinen in Polar Koordinaten als senkrechte, dünne Linie, in kartesischen Koordinaten als Kreissektoren (siehe Abbildung 46, Abbildung 47) gerichtet zur Wetterradarstation. Man kann die Linien in Polar Koordinaten mit Hilfe einfacher morphologischer Operationen extrahieren und dann wiederum die betroffenen Kreissektoren im kartesischen Raum markieren. Zuerst muss das Bild in Polarkoordinaten transformiert werden und weil das Kompositbild aus insgesamt vier Radarbildern zusammengesetzt ist muss diese Transformation viermal wiederholt werden, jeweils für einen anderen Radarbereich.




Abbildung 46: Wiener Radarbereich auf dem Kompositbild. Rot markiert wurde das linienartige Echo.




Abbildung 47: Der Wiener Radarbereich in Polarkoordinaten. Das Echo ist als lange, senkrechte Linie sichtbar.

Das Bild wird nun in ein Binärbild konvertiert. Der Schwellwert wurde folgendermaßen definiert:

$$i'_{x,y} = \begin{cases} 0 & \text{wenn } i_{x,y} = 0 \\ 1 & \text{wenn } i_{x,y} > 0 \end{cases} \quad (4.16)$$

Im Vorverarbeitungsschritt werden mittels morphologische Closing bzw. Opening (vgl. Kapitel 4.3) kleine Löcher gefüllt bzw. die breiten Objekte ausgefiltert. Mit Hilfe von Opening mit einem linienartigen senkrechten Strukturelement werden anschließend die Artefakte extrahiert (siehe Abbildung 48).




Abbildung 48: Die Schritte zur Erkennung der linienartige Echos.
 Links oben: Radarbereich in Polarkoordinaten,
 rechts oben: Konvertierung zum Binärbild
 links unten: die breiten Objekte werden ausgefiltert
 rechts unten: die Linie wurde extrahiert.

Als Artefakte wurden nur Linien, die mindestens eine Länge von 50 Pixel haben, anerkannt. Das bewirkt, dass manche kleineren Störungen aussortiert werden, aber gibt die Garantie, dass keine, etwas mehr ausgedehnte Niederschlagsstruktur, sogenannter Strichregen, fälschlicherweise als Artefakt behandelt werden. Diese linienartigen Niederschlagsstrukturen können eine Länge von bis zu 30 km haben und die empirische Versuche haben gezeigt dass ein Schwellwert über 50 Pixel einen optimalen und sicheren Wert ergibt.

6.3.2.3. Erkennung der kreisförmigen Störungen

Die kreisförmigen Störungen bestehen oft aus mehreren kleinen Objekten, die zusammen visuell als kreisförmigen Gebilde erscheinen. Da für die Hough Transformation die Qualität und Anzahl der aus dem Bild extrahierten Konturen wesentlich ist wurde hier ein spezieller morphologischer Vorverarbeitungsschritt nötig. Das Bild wurde in ein Binärbild umgewandelt und es wurde eine Dilation durchgeführt. Um die Kreisstrukturen nicht zu zerstören wird sie jeweils getrennt für jeden Radarbereich sektorweise in 5° Schritten durchgeführt. Das kleine linienartige (1x6 Pixel) Strukturelement wird jeweils entsprechend um 5° gedreht (siehe Abbildung 49).




Abbildung 49: Schematische Darstellung der sektorweisen Dilation. Das Bild wird in α -breiten Sektoren zerlegt und mit einem entsprechend geneigten Strukturelement s dilatiert.

Die Parameterberechnung der Hough Transformationen kann beschränkt werden, da die kreisförmigen Störungen nur in der zweiten Hälfte der Radarreichweite hervortreten. Auch die Zentren der Kreise oszillieren nur in einem gewissen Radius um die Radarzentren. Es wurde beobachtet dass dieser Radius durchschnittlich 30 Pixel beträgt. Die durch Hough Transformation erkannten Objekte wurden wiederum aussortiert und nur jene belassen die hohen Exzentrizitätsfaktor und Ausdehnung besitzen. Die Artefakte betreffen nur einen Teil des umschriebenen Kreises und weisen deswegen einen hohen Exzentrizitätsfaktor auf (siehe Abbildung 50, 51). Die Testanalyse an einem Set mit 30 plausiblen Bildern haben den Wert für die optimale Exzentrizitätsschwelle auf 0.975 gesetzt. Damit wurde gewährleistet, dass die Niederschlagsstrukturen, die sich in dem Bereich der Kreise befinden nicht als Artefakte aufgenommen werden. Die Exzentrizität eines Kreises (damit ist ein Kreis verstanden, der das einzelne Objekt beschreibt) ist 0, die einer Ellipse zwischen 0 und kleiner 1, für eine Linie beträgt sie 1.

$$ECC = \frac{\sqrt{a^2 - b^2}}{a} \quad (4.17)$$

wobei a die Länge der Hauptachse und b der Nebenachse einer Ellipse ist.

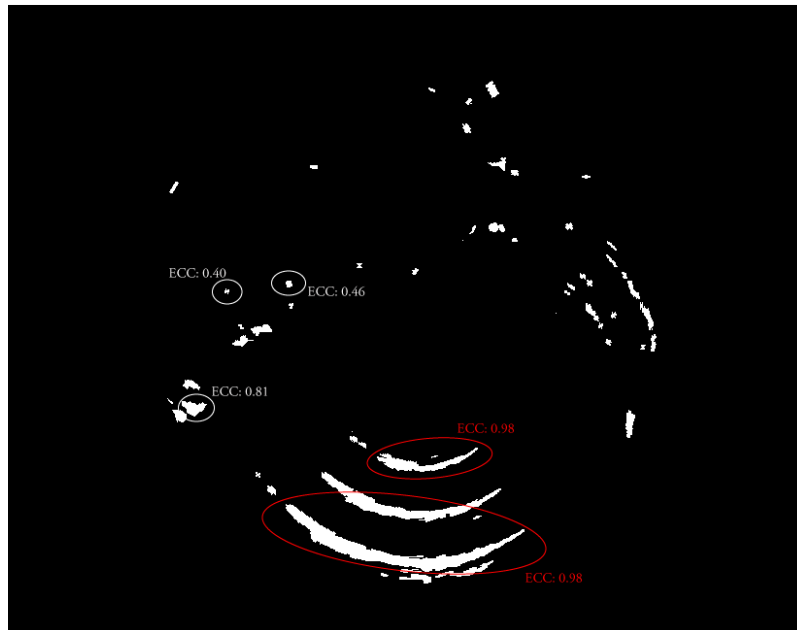


Abbildung 50: Die durch Hough Transformation erkannten Objekte und ihre Exzentrizitätswerte.




Abbildung 51: Kreisförmige Artefakte.

6.3.3. Überlebenszeitanalyse

Wie schon kurz erwähnt besitzen die Artefakte eine gewisse Erscheinungcharakteristik. Meistens treten sie willkürlich auf einzelnen Frames hervor oder überleben nur sehr kurz (Abbildung 52). Die Niederschlagserscheinungen hingegen wachsen oder schrumpfen stufenweise und ihr Lebenszyklus breitet sich über mehrere Bildframes aus (siehe Abbildung 53). Um diesen Überlebenszyklus zu untersuchen wurde ein Algorithmus entwickelt, der die Objekte durch mehrere Bilder in absteigender Zeitreihenfolge verfolgt. Dieser basiert auf drei Hauptannahmen:

- die Wetterradarbilder werden in Zeitintervallen von 5 Minuten geliefert und in diesen Zeitintervallen können sich die Niederschlagsobjekte nur in eine gewisse Distanz verlagern. Die Geschwindigkeit der Niederschlagsobjekte ist von vielen Faktoren abhängig, wie z.B. Höhe über Meeresspiegel, Größe und Art des Objektes (Gewitterzellen, Hagelzellen) oder Windgeschwindigkeit. Zur Vereinfachung wurde eine konstante maximale Distanz von 7 Pixel angenommen, das entspricht ungefähr 84km/h.
- die Niederschlagsobjekten wachsen oder verkleinern sich stufenweise, sie können sich aufspalten oder zusammenschließen. Es wurde angenommen das Niederschlagsobjekt kann sich maximal um 0.6-fache der Fläche verkleinern. Für neuen Niederschlagszellen wurde eine maximale Anfangsgröße auf 15 Pixel beschränkt.
- die durchschnittliche Intensitätswert innerhalb eines Niederschlagsobjekts ändert sich von Frame zu Frame maximal um 2 Stufen.




Abbildung 52: Die Wanderung einer Niederschlagszelle durch drei Frames. Das Zeitintervall zwischen den Frames beträgt 5 Minuten, rot wurde das Zentrum der Niederschlagszelle angezeichnet.




Abbildung 53: Die Entwicklung einer Niederschlagszelle durch sechs Frames. Das Zeitintervall zwischen den Frames beträgt 5 Minuten.




Abbildung 54: Überlebenszeitanalyse. Rot wurden die Artefakte markiert, weiß die Niederschlagszellen.

Ziel dieser Analyse ist es, die segmentierten Artefaktbereiche zu verifizieren und jene zu eliminieren, die fälschlicherweise als Artefakt klassifiziert wurden und tatsächlich einem echten Niederschlag entsprechen.

Der Algorithmus funktioniert folgendermaßen:

- nehme das segmentierte und das originale Bild zu Zeitpunkt t
- für jedes Objekt, das als Artefakt erkannt wurde, bestimme den potenziellen Bereich, in den sich das Objekt bewegen kann
- nehme das Bild zum Zeitpunkt $t - 1$ und berechne die Größe und durchschnittliche Intensität der Echos i' in dem Bereich, der in Zeitpunkt t bestimmt wurde. Das Objekt wurde als "gefunden" markiert wenn es die vorher aufgelistete Grundsätze erfüllt
- weise $t = t - 1$ zu und wiederhole bis zum Zeitpunkt $t - t_{max}$.

Wurde das Objekt durch die ganze Zeitkette vollständig verfolgt wird es als Niederschlagszelle anerkannt.

Die durchschnittliche Intensität i' der Echos in einem gewissen Bereich wurde wie folgt definiert:

$$i' = \frac{1}{n} \sum_{k=1}^n i_k \quad (4.18)$$

wobei n Anzahl aller Pixel mit Intensität größer 0 in dem untersuchten Bereich bezeichnet.

6.3.4. Fusion

Alle drei Module, die oben beschrieben wurden, wurden zu einem System fusioniert. Die Hauptidee bei der Entwicklung des gesamten System war es durch zusätzliche Features, die Segmentierungsergebnisse zu verbessern bzw. zu verifizieren. Es ist notwendig, dass so viel als möglich Artefaktstrukturen identifiziert werden und gleichzeitig keine wichtigen Niederschlagszellen falsch klassifiziert werden.

Das Ausgangspunkt ist ein segmentiertes Bild. Die Bereiche, die in dem segmentierten Bild als Artefakte markiert wurden, werden mit den geometrischen Masken für linienartige und kreisförmige Störungen laut folgender Regel gegenübergestellt:

$$P_{art} = P(SEG_{art}) \cap P(GEOM_{art}) \quad (4.19)$$

Wenn das P_{art} gleich 1 wird, werden die entsprechenden Bereiche nicht weiter untersucht, sondern sofort als Artefakt markiert. Dadurch, dass die kreisförmigen und linienartigen Artefakte auch fallweise länger überleben ist die Überlebensanalyse in diesem Fall nicht mehr plausibel. Aufgrund ihrer eindeutigen geometrischen Charakteristik wurden sie trotzdem richtig als nichtmeteorologisches Echo behandelt.

Alle anderen potenziellen Artefaktobjekte werden der Überlebensanalyse unterzogen.

6.3.5. Bewertung

Die Resultate der Artefakt Erkennung wurden anhand der Ground Truth Daten bewertet. Für die Ground Truth wurden insgesamt 106 Bilder aus den bereitgestellten Daten ausgewählt, die möglichst gut das gesamte Spektrum von verschiedenen Störungserscheinungen bzw. Niederschlagsstrukturen abdeckt und eine plausible Aussage über die Leistung der Algorithmen machen lässt. Die ausgesuchten Bilder wurden manuell bearbeitet und die Ground Truth wurde durch Meteorologen verifiziert.

Es wurden mehrere Qualitätsfaktoren berechnet:

FAN = Anzahl der Niederschlagspixel, die falsch als Artefakte erkannt wurden

$$\mathbf{FANRate} = \frac{\text{Anzahl der Niederschlagspixel, die falsch als Artefakte erkannt wurden}}{\text{Anzahl alle Niederschlagspixel}}$$

FNN = Anzahl der Artefaktpixel die nicht als Artefakt erkannt wurden

$$\mathbf{FNNRate} = \frac{\text{Anzahl der Artefaktpixel die falsch als Niederschlag erkannt wurden}}{\text{Anzahl alle Artefaktpixel}}$$

$$\mathbf{KorrektRate} = \frac{\text{Anzahl der richtig erkannten Pixel}}{\text{Anzahl aller Pixel} > 0}$$

Von Belang ist es zu wissen welche Resultate die Textursegmentierung selbst liefert und inwieweit sich die Ergebnisse ändern wenn alle drei Module fusioniert werden. Der Vergleich wird in den nächsten Kapiteln dargestellt.

6.3.5.1. *Bewertung der Textursegmentierung*

Insgesamt wurden 106 segmentierte Bilder evaluiert. Die durchschnittliche Korrektheitsrate für textursegmentierte Bilder beträgt 83,5%. FAN Rate beträgt durchschnittlich 14,2% und FNN Rate 4%. Die Ergebnisse sind in den Abbildungen 55, 56, 57 und 58 dargestellt. In der Abbildung 56 (bzw. 58) wurde der FAN Faktor (bzw. FNN Faktor) der Anzahl aller Niederschlagspixel (bzw. Artefaktpixel) gegenübergestellt. Die Abbildung 55 bzw. 57 zeigt FAN bzw. FNN Rate.




Abbildung 55: FANRate Faktoren für Textursegmentierung.




Abbildung 56: Anzahl der Niederschlagspixel vs. Anzahl der Niederschlagspixel, die falsch als Artefaktpixel erkannt wurden (Textursegmentierung).




Abbildung 57: FNNRate Faktoren für Textursegmentierung.




Abbildung 58: Anzahl der Artefaktpixel vs. Anzahl der Artefaktpixel, die falsch als Niederschlag erkannt wurden (Textursegmentierung).

Der Faktor FNNR zeigt deutlich, dass die Störungen insgesamt sehr gut erkannt werden. Der Faktor FANR sagt aber, dass relativ viele Niederschlagspixel fälschlicherweise als Artefakt klassifiziert wurden. Das perfekte Ergebnis wäre wenn gleichzeitig Faktoren FANR und FNNR gleich 0 wären (es entspricht 100% Korrektheitsrate). Das trifft bei insgesamt 4 Bilder zu, die in der Abbildung 59 zu sehen sind. Wie abgebildet handelt es sich um relativ einfache Beispiele, wobei hauptsächlich Artefakte auftreten, fast keine Niederschlagszellen.

Bei komplexeren Beispielen wurden auch schlechtere Ergebnisse erzielt. Bei Bild 15 (siehe Abbildung 60) beträgt die Korrektheitsrate weniger als 50%. Es werden 56% (insgesamt 2475 Pixel) von allen Niederschlagspixel fälschlicherweise als Artefakte klassifiziert. Bei Bild 48 beträgt die Korrektheitsrate schon 76%, aber insgesamt 3289 Pixel wurden falsch als Niederschlagspixel klassifiziert. Viele davon sind kleine Niederschlagszellen, deren Unterscheidung von Artefaktpixel nicht so eindeutig ist und erst durch eine zeitliche Verfolgung unterscheidbar werden.




Abbildung 59: Wetterrada**r**bilder mit 100% Segmentierungskorrektheit.




Abbildung 60: Wetterrada**r**bilder mit niedriger Korrektheitsrate. Rot wurden Niederschlagzellen markiert, die falsch als Artefakte klassifiziert wurden.

6.3.5.2. *Bewertung des fusionierten System*

In dem Kapitel werden die Ergebnisse des gesamten System vorgestellt. Für die Evaluierung mussten die 106 Bilder in zwei Sets aufgeteilt werden, da nicht alle Beispiele in der Bildkette mit Zeitintervallen von 5 Minuten geliefert wurden. Bei manchen Beispielen ergaben sich 10 oder 15

minütigen Lücken. Das heißt natürlich, dass der Tracking Algorithmus für Überlebenszeitanalyse nicht mehr korrekt funktionieren wird. Es konnte damit aber auch untersucht werden wie robust der gesamte Algorithmus gegen eventuelle Bildausfälle ist. Es gibt 44 Bilderserien, die ununterbrochen in Zeitintervallen von 5 Minuten vorhanden sind und 62 Bilderserien mit unvollständiger Zeitkette.

Die durchschnittliche Korrektheitsrate bei den Bildern in ununterbrochenen Zeitketten beträgt 97,80%, in unterbrochenen 94,8%. Das sind die Ergebnisse für das gesamte System mit Überlebenszeitanalyse über zwei Frames. Werden mehrere Frames in Betracht bezogen ändern sich die Rates jeweils um kleine Bruchteile. Die Ergebnisse für das Tracking über mehrere Frames sind in der Tabelle 11 zusammengefasst.

	2 Frames	3 Frames	4 Frames	5 Frames
ununterbrochene Zeitketten	97.80	97.87	97.61	97.41
unterbrochene Zeitketten	94.78	94.25	93.71	96.62

Tabelle 11: Überlebenszeitanalyse - verschiedene Anzahl der Frames.

In Abbildungen 61, 62, 63 und 64 werden noch die verschiedenen Qualitätsfaktoren in visueller Form zusammengefasst (die Zusammenstellung wurde für die Resultate mit Überlebenszeitanalyse über 2 Frames durchgeführt), so dass der Vergleich mit der der Textursegmentierung gemacht werden kann. Daraus ergibt sich deutlich, dass der Verlust der wichtigen Niederschlagszellen möglichst reduziert wird. Die Anzahl der Niederschlagspixel, die falsch als Artefakte klassifiziert wurden konnte damit auf lediglich 0.01% reduziert (ununterbrochen Zeitketten) werden.

Um unterscheiden zu können bei welchem Bild es sich um eine ununterbrochene oder unterbrochene Zeitkette handelt wurden in der unten stehenden Abbildungen zur Darstellung zwei Farbkodierungen verwendet (leicht Grau entspricht den Bilder in unterbrochenen Zeitketten und dunkleres Grau in vollständigen).




Abbildung 61: FANRate Faktoren für gesamtes System.




Abbildung 62: Anzahl der Niederschlagspixel vs. Anzahl der Niederschlagspixel, die falsch als Artefaktpixel erkannt wurden (gesamtes System).

Die Abbildungen 61 bzw. 62 zeigen deutlich, dass die Anzahl falsch klassifizierter Niederschlagspixel im Vergleich zur reinen Textursegmentierung deutlich gesunken ist. In Abbildungen 63 und 64 ist aber zu erkennen dass die Anzahl der Artefaktpixel, die nicht richtig erkannt wurden, gestiegen ist. Das hat die Ursache vor allem in der längeren Überlebenszeit

mancher Artefakte. Es gibt aber auch einige Beispiele wo dieser Faktor gesunken ist. Dafür sind die zusätzlichen geometrischen Features verantwortlich.




Abbildung 63: FNNRate Faktoren für gesamtes System.




Abbildung 64: Anzahl der Artefaktpixel vs. Anzahl der Artefaktpixel, die falsch als Niederschlag erkannt wurden (gesamtes System).

In Tabelle 12 werden durchschnittliche Faktorenwerte der Textursegmentierung dem fusionierten System gegenübergestellt. Die Werte des gesamten Systems beziehen sich auf die Auswertung aller Beispiele (unterbrochene und ununterbrochene Zeitketten) und Überlebenszeitanalyse über 2 Frames. Insgesamt ist die Leistung im Vergleich zur reinen Textursegmentierung um knapp 13%

gestiegen. Im Allgemeinen hat sich die FNN Rate verschlechtert, d.h. die richtig segmentierten Artefaktpixel wurden nach der weiteren Analyse als Niederschlag markiert. Wichtiger ist es aber dass die FAN Rate von 14,2 auf nur mehr 2 Prozent gesunken ist. Damit wurde gewährleistet, dass keine bedeutenden Niederschlagszellen fälschlicherweise als Artefakte markiert wurden.

	Textursegmentierung	gesamtes System*
<i>FANRate</i>	14.2	2.09
<i>FNNRate</i>	4	15.22
<i>Korrektheit</i>	83.5	96.03

*um den allgemeinen Vergleich zu ermöglichen wurden hier die Durchschnittsraten von allen Bildern gebildet ohne Differenzierung zwischen ununterbrochenen und unterbrochenen Zeitketten.

Tabelle 12: Textursegmentierung vs. gesamtes System.

6.4. Resümee

In diesem Kapitel wurden die Methoden zur Artefakt Erkennung in Wetterradarbildern dargestellt. Die entscheidende Bedeutung bei der Entwicklung aller Methoden war vor allem eine genaue Analyse der Thematik und Problemstellung. Jede Art der Störung bzw. des Niederschlags hat eigene spezifische Charakteristiken.

Bei der Erkennung der Artefakte wurde einer Korrektheitsrate von fast 98% erzielt. Es muss dabei die Voraussetzung erfüllt werden, dass die Bilder in einer ununterbrochenen Kette in Zeitintervallen von 5 Minuten geliefert werden. Kommt es zu einem Bildausfall dazwischen sinkt die Korrektheitsrate auf 95%, was aber immer noch ein relativ gutes Resultat darstellt und die Robustheit des Systems bestätigt.

Orographische Abschattungssektoren lassen sich auch gut mit der vorgestellten Methode erkennen. Für eine genaue Schätzung der abgeschatteten Bereiche ist aber eine 3D Lösung notwendig, da sich die Abschattung mit der Höhe ändert.

Diskussion

In der vorliegenden Arbeit wurde gezeigt, dass durch die Adaptierung der klassischen Bildverarbeitungsansätze und trotz vieler Beschränkungen plausible Methoden zum Identifizieren der Störungen in der Weterradarbilder gefunden werden konnten. Natürlich sind weitere Arbeiten sehr sinnvoll und von großer Bedeutung, da in dem Bereich der Weterradarbilderverbesserung noch viel gemacht werden sollte.

7.1. Beschränkungen

Die Durchführung der Arbeit wurde durch folgende Faktoren erschwert. Die größte Beschränkung bei der Arbeit bestand darin, dass nur Kompositbilder zur Verfügung gestanden haben. Damit

wurde der Informationsgehalt deutlich reduziert bzw. sind durch den Maximumprojektionsprozess verloren gegangen. Es konnten keine elevationsabhängigen Daten verwendet werden. Zweiter damit verbundene Nachteil ist, dass die Bilder aus allen vier Radarstationen zu einem vereinigt wurden. Die Rohdaten in Polarkoordinaten würden einen viel besseren und einfacheren Workflow ermöglichen.

Das zweite große Problem war es, dass es keine bzw. nur wenig Ground Truth gegeben hat. Das hat einen negativen Einfluss auf die Erstellung der Training Samples, bzw. beeinträchtigt das genaue Auswählen der verschiedenen Parameter. Dabei ist zu erwähnen, dass alternative Möglichkeiten zur Erstellung bzw. zur Erleichterung der Erstellung der Ground Truth in Betracht bezogen werden können, wie z.B. das Anwenden der sogenannten Wolkenmasken (engl. *Cloud Mask*). Da die verwendete Ground Truth subjektiv erstellt wurde, sollte diese unabhängig von mehreren Meteorologen verifiziert oder erstellt werden. Durch die Mehrfachbewertung lassen sich eindeutige Fälle leichter identifizieren.

7.2. Zukünftige Arbeit

Für die zukünftige Arbeit bei der Verbesserung der Wetterradarbilder wäre eine 3D Analyse von Bedeutung. Manche Artefakte, wie z.B. das Brightband erfordern die Bekanntheit und Analyse der elevationsabhängigen Radardaten, weil es in einem charakteristischen schichtenweisen Übergang entsteht. Es ist davon auszugehen, dass sich damit auch viele andere Artefakte besser erkennen lassen, die sich auf dem Kompositbild mit Niederschlag überlappen, aber sich tatsächlich auf anderen Elevationen befinden können.

Die orographische Abschattungen auf Kompositbildern lassen sich auch nur in einem gewissen Ausmaß identifizieren. Die 3D Modelle für die Abschattungsbereiche würden bei diesem Problem die Möglichkeiten wesentlich erweitern und die Genauigkeit der erkannten Bereiche deutlich verbessern.

Ansonsten ist es wichtig, dass die Daten so schnell wie möglich in der ganzen Verarbeitungskette greifbar sind. Damit ist gemeint, dass es von Vorteil ist mit Rohdaten in Polarkoordinaten, unabhängig für jede Radarstation zu arbeiten. Wie in den vorherigen Kapitel gezeigt, sind manche

Störungen in Polarkoordinaten viel einfacher zu erkennen bzw. zu extrahieren als in kartesischen Koordinaten.

Die in dieser Arbeit vorgestellten Methoden können natürlich auch noch erweitert bzw. verbessert werden. Es wäre z.B. interessant die Textur Features in anderen Klassifikatoren einzusetzen wie Support Vector Machine oder Random Forest Klassifikator. Zur Erkennung der Niederschlagsdämpfung wäre es noch möglich andere Informationen einzubeziehen, wie z.B. die Lage der starken Gewitterzellen hinsichtlich der Radarstrahlung.

Quellenverzeichnis

- [Ballard (1981)] D.H. Ballard (1981). *Generalizing the Hough transform to detect arbitrary shapes*. Pattern Recognition, Vol. 13, 1981, pp. 111-122.
- [Bourke (2009)] Bourke, P. (2009). *Fractals*
<http://local.wasp.uwa.edu.au/~pbourke/fractals>
- [Brodatz (2009)] Brodatz (2009). *Brodatz database*.
<http://www.ux.uis.no/~tranden/brodatz.html>
- [Clark and A.C.Bovik (1987)] Clark, M. and A.C.Bovik (1987). *Texture segmentation using gabor modulation / demodulation*. Pattern Recognition Letters Vol. 6, Issue 4, pp. 261-267
- [Clausi (2001)] Clausi, D. (2001). *Comparison and fusion of co-occurrence, gabor, and mrf texture features for classification of sar sea ice imagery*. Atmosphere & Oceans 39 (4), pp. 183–194.
- [Clausi and Jernigan (2000)] Clausi, D. A. and M. E. Jernigan (2000). *Designing gabor filters for optimal texture separability*. Pattern Recognition 33(11), pp. 1835–1849.
- [Donoser (2007)] Donoser, M. (2007). *Advanced segmentation and tracking algorithms and their application to 3D paper structure analysis*. Ph. D. thesis, Graz University of Technology.
- [Donoser and Bischof (2008)] Donoser, M. and H. Bischof (2008). *Using covariance matrices for unsupervised texture segmentation*. 19th International Conference on ICPR, pp. 1–4.
- [Doviak and Zrníc (1984)] Doviak, R. J. and D. S. Zrníc (1984). *Doppler radar and weather observations*. Academic Press.
- [Duda and Hart (1972)] Duda, R. O. and P. E. Hart (1972). *Use of the hough transformation to detect lines and curves in pictures*. Technical report, Artificial Intelligence Center.
- Duda et al. [2000] Duda R. O., P. E. Hart, and D. G. Stork (2000), *Pattern Classification*, 2nd edition, Wiley-Interscience
- [Förstner and Moonen (1999)] Förstner, W. and B. Moonen (1999). *A metric for covariance matrices*. Technical report, Dept. of Geodesy and Geoinformation, Stuttgart University.

- [Galloway (1975)] Galloway, M. (1975, June). *Texture analysis using gray level run lengths*. Computer Graphics and Image Processing, Vol. 4, Issue 2, pp. 172–179.
- [Gill (2007)] Gill, R. S. (2007). *Sea clutter removal using radar elevation dependent second order texture parameters*. DMI scientific report.
- [Gisolfi et al. (1986)] Gisolfi, A., S. Vitulano, and A. Cacace (1986). *Texture and structure*. In V. Cappelini and R. Marconi (Eds.), *Advances in Image Processing and Pattern Recognition*, pp. 179–183. Amsterdam.
- [Grigorescu et al. (2002)] Grigorescu, S., N. Petkov, and P. Kruizinga (2002, October). *Comparison of texture features based on gabor filters*. IEEE Transactions on Image Processing, Vol. 11 Issue 10, pp. 1160–1167.
- [Hailzl (2006)] Hailzl, G. (2006). *Radarmeteorologie*. Vorlesung Skriptum.
- [Hammouda and Jernigan (2000)] Hammouda, K. and P. E. Jernigan (2000). *Texture segmentation using gabor filters*. University of Waterloo, Ontario, Canada.
- [Haralick et al. (1973)] Haralick, R., K. Shanmugam, and I. Dinstein (1973, November). *Textural features for image classification*. IEEE, Vol.3, Issue 6, pp. 610–621.
- [Hough (1962)] Hough, P. (1962). *A method and means for recognizing complex patterns*. U.S. Patent 3,069,654
- [Hu et al. (2008)] Hu, W., X. Huang, and Y. Li (2008, May). *Texture analysis on weather radar images of severe convective precipitation in the arid area of ningxia*. In Congress on Image and Signal Processing, 2008 CISP '08, Vol. 2, pp. 150–154.
- [Hubbard (1997)] Hubbard, B. B. (1997). *Wavelets. Die Mathematik der kleinen Wellen*. Birkhäuser Verlag.
- [Jain and Farrokhnia (1990)] Jain, A. K. and F. Farrokhnia (1990). *Unsupervised texture segmentation using gabor filters*. In Systems, Man and Cybernetics, 1990. Conference Proceedings., IEEE International Conference on, pp. 14–19.
- [Johns (2003)] Johns, M. (2003). *Anwendung von wavelets in der biometrischen authentikation*. Master's thesis, Universität Hamburg.
- [Kaleschke (2003)] Kaleschke, L. (2003). *Fernerkundung des Meereises mit passiven und aktiven Mikrowellensensoren*. Ph. D. thesis, Universität Bremen.
- [Kluckner and Bischof (2009)] Kluckner, S. and H. Bischof (2009). *Semantic classification by covariance descriptors within a randomized forest*. In

- Proceedings of the IEEE International Conference on Computer Vision, Workshop on 3D Representation for Recognition (3dRR-09).
- [Kluckner et al. (2009)] Kluckner, S., T.Mauthner, and H.Bischof (2009). *A covariance approximation on euclidean space for visual tracking*. In Proc. 33rd Workshop of the Austrian Association for Pattern Recognition.
- [Kullback and Leibler (1951)] Kullback, S. and R.A. Leibler (1951). *On information and sufficiency*. The annals of mathematical statistics, Vol. 22, pp. 79–86.
- [Lakshmanan (2001)] Lakshmanan, V. (2001). *A Hierarchical, Multiscale Texture Segmentation Algorithm for Real-World Scenes*. Ph. D. thesis, U. Oklahoma.
- [Lakshmanan et al. (2008)] Lakshmanan, V., T.Smith, and R.Rabin (2008). *Automated real-time extraction of storm properties from gridded fields*. In Preprints, Fifth European Conference on Radar in Meteorology and Hydrology ERAD 2008, Finnish Meteorological Institute.
- [Lakshmanan and Zhang (2009)] Lakshmanan, V. and J.Zhang (2009). *Censoring biological echoes in weather radar images*. In 4th International Conference on Fuzzy Systems and Knowledge Discovery, Vol.5, pp. 491-495.
- [Laws (1979)] Laws, K. (1979). *Texture energy measures*. In USC Computer Vision, pp. 57-51.
- [Leitner (1999)] Leitner, T. (1999). *Clutter-Erkennung und -Unterdrückung in Wetterradar-Bildern mit multitemporaler mehrparametrischer Bildverarbeitung*. Ph. D. thesis, Technische Universität Graz.
- [Leung and Malik (2001)] Leung, T. and J. Malik (2001). *Representing and recognizing the visual appearance of materials using three-dimensional textons*. Journal of Int.J.Comput. Vision 43, pp. 29-44, Kluwer Academic Publishers, Hingham USA.
- [Louis (2004)] Louis, S. B. (2004). *Texture Classification Using Non-Parametric Markov Random Fields*. Ph. D. thesis, School of Informatics University of Edinburgh.
- [Maestex (2009)] Maestex (2009). *Maestex database*
<http://www.cssip.uq.edu.au/staff/meastex/meastex.html>
- [Malik and Perona (1990)] Malik, J. and P. Perona (1990, May). *Preattentive texture discrimination with early vision mechanisms*. Journal of the Optical Society of America A: Optics, Image Science, and Vision, Vol. 7, Issue 5, pp. 923–932.

- [Mandelbrot (1991)] Mandelbrot, B. (1991). *Die fraktale Geometrie der Natur*. Birkhäuser Verlag.
- [Moreno et al. (2005)] Moreno, P., A. Bernardino, and J. Santos Victor (2005). *Gabor parameter selection for local feature detection*. Proc. IBPRIA - 2nd Iberian Conference on Pattern Recognition and Image Analysis (Springer).
- [Peura (2002)] Peura, M. (2002). *Anomaly detection and removal in radar images (ANDRE.)* Final project report, *Finnish Meteorological Institute*
- [Pinz (1997)] Pinz, A. (1997). *Bildverstehen*. Springer-Verlag KG.
- [Porikli and Kocak (2006)] Porikli, F. and T. Kocak (2006). *Robust license plate detection using covariance descriptor in a neural network framework*. Proceedings of the IEEE International Conference on Video and Signal Based Surveillance, pp. 107.
- [Porikli and Tuzel (2006)] Porikli, F. and O.Tuzel (2006). *Fast construction of covariance matrices for arbitrary size image windows*. Image Processing, 2006 IEEE International Conference, pp. 1581–1584.
- [Porikli et al. (2005)] Porikli, F., O.Tuzel, and P.Meer (2005). *Covariance tracking using model update based on lie algebra*. In Proc. IEEE Conf. on Computer Vision and Pattern Recognition, pp. 728-735
- [RadarInfo (2009)] RadarInfo (2009), <http://radar-info.fzk.de>
- [Radartutorial (2009)] Radartutorial (2009), <http://www.radartutorial.eu>
- [Randen and Hus(1999)] Randen, T. and J. H. Hus(1999, April). *Filtering for texture classification: A comparative study*. IEEE Trans. Pattern Anal. Mach. Intell., Vol. 21, Issue 4, pp. 291–310.
- [Reiber (2009)] Reiber (2009). *Interpretation von Radarbildern* <http://www.drmreiber.de>
- [Rignot and Kwok (1990)] Rignot, E. and R.Kwok (1990). *Extraction of textural features in sar images: Statistical model and sensitivity*. Geoscience and Remote Sensing Symposium, 1990. IGARSS '90. 'Remote Sensing Science for the Nineties', 10th Annual International, pp. 1979-1982.
- [Schmid (2001)] Schmid, C. (2001). *Constructing models for content-based image retrieval*. Computer Vision and Pattern Recognition, IEEE Computer Society Conference Vol. 2, pp. 39-45.

- [Sharma and Singh (2000)] Sharma, M. and S.Singh (2000). *Evaluation of texture methods for image analysis*. Proceedings of the 7th Australian and New Zealand Intelligent Information Systems Conference, pp. 117–121.
- [Sonka et al. (1999)] Sonka, M., V.Hlavac, and R.Boyle (1999). *Image Processing, Analysis and Computer Vision*. PWS Publishing, Pacific Grove, CA.
- [Sutton and Hall (1972)] Sutton, R. and E. Hall (1972, July). *Texture measures for automatic classification of pulmonary disease*. IEEE Transactions on Computers Vol. 21, Issue 7, pp. 667–676.
- [Tou et al. (2007)] Tou, J.Y., Y.H. Tay, and P.Y. Lau (2007). *Gabor filters and grey-level co-occurrence matrices in texture classification*. MMU International Symposium on Information and Communications Technologies, M2USIC 2007
- [Tou et al. (2009)] Tou, J.Y., Y.H. Tay, and P.Y. Lau (2009). *Gabor filters as feature images for covariance matrix on texture classification problem*. ICONIP 2008, Part II, LNCS 5507, pp. 745–751.
- [Tsai et al. (2001)] Tsai, D., S.Wu, and M.Chen (2001, April). *Optimal gabor filter design for texture segmentation using stochastic optimization*. Image and Vision Computing Vol. 19, Issue 5, pp. 299–316.
- [Tuceryan and Jain (1998)] Tuceryan, M. and A.K. Jain (1998). *Texture analysis, The Handbook of Patern Recognition and Computer Vision edited by C. H. Chen, L. F. Pau, P.S.P. Wang (eds.)*, pp. 207-248, World Scientific Publishing Co.
- [Turner (1986)] Turner, M.R. (1986). *Texture discrimination by gabor functions*. Biological Cybernetics Vol. 55, Issue 2-3, pp. 71–82, Springer Verlag
- [Umarani and Radhakrishnan (2007)] Umarani, C. and S. Radhakrishnan (2007). *Combined statistical and structural approach for unsupervised texture classification*. ICGST International Journal on Graphics, Vision and Image Processing 07, pp. 31–36.
- [Varma and College (2004)] Varma, M. and J.College (2004). *Statistical Approaches To Texture Classification*. Ph. D. thesis, Robotics Research Group, Department of Engineering Science, University of Oxford.
- [Varma and Garg (2007)] Varma, M. and R. Garg (2007, October). *Locally invariant fractal features for statistical texture classification*. Proceedings of the IEEE 11th International Conference on Computer Vision, pp. 1-8.

[Xiaomei and Chenghu (1998)] Xiaomei, Y. and Z.Chenghu (1998). *Recognition of flooded area in radar image using texture feature analysis*. Asian Conference on Remote Sensing ACRS'98, pp. P22-1 - P22-6