

Martin Steinegger

# Ableitung der Beschirmung von Waldbeständen aus hochauflösenden Satellitenbildern

**MASTERARBEIT**

zur Erlangung des akademischen Grades  
Diplom-Ingenieur

Masterstudium Geomatics Science



**Technische Universität Graz**

Betreuer:

Univ.-Prof. Dr.rer.nat. Dipl.-Forstwirt Mathias Schardt  
Institut für Fernerkundung und Photogrammetrie

Graz, November 2010

Deutsche Fassung:  
Beschluss der Curricula-Kommission für Bachelor-, Master- und Diplomstudien vom 10.11.2008  
Genehmigung des Senates am 1.12.2008

## EIDESSTÄTLICHE 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)

Englische Fassung:

## STATUTORY DECLARATION

I declare that I have authored this thesis independently, that I have not used other than the declared sources / resources, and that I have explicitly marked all material which has been quoted either literally or by content from the used sources.

.....  
date

.....  
(signature)

## **Kurzfassung**

Diese Masterarbeit beschäftigt sich mit der Ermittlung des Waldmerkmals Beschirmung durch Verfahren der Fernerkundung. Zu diesen Verfahren gehört die überwachte Klassifizierung, welche aufgrund von spektralen Merkmalen Bildelemente (Pixel) Klassen zuweist. Dazu werden Informationen benötigt, die über Referenzdaten (Trainingsgebiete) gewonnen werden. Ein Teil dieser Arbeit ist der Aufnahme der Referenzdaten, dem Überschirmungsgrad von Beständen gewidmet. Die Reflexion dieser Referenzdaten wird anhand Untersuchungsgebieten auf der Basis von dreier Bilder der Satelliten Spot 4 und IRS P6 analysiert. Neben den spektralen Bildkanälen werden auch synthetisch erstellte Kanäle auf Zusammenhänge zwischen Reflexion und Beschirmung untersucht.

Eine Simulation der Beschattung von Waldbeständen mittels LIDAR - Daten bestätigt die Annahme, dass die Reflexion von Wald deutlich vom Schattenwurf der Baumkronen beeinflusst wird, der in Abhängigkeit vom Beschirmungsgrad variiert.

Ein wesentlicher Teil dieser Arbeit ist den Algorithmen der überwachten Klassifizierung gewidmet, wobei hier vier Algorithmen genauer beschrieben werden. Neben dem k-Nächsten-Nachbarn Algorithmus und der einfachen linearen Regression sind das zwei neu entwickelte Methoden, welche wie die einfache lineare Regression auf der Regressionsanalyse aufbauen. Die Methoden werden miteinander durch das statistische Verfahren der Kreuzvalidierung verglichen und deren Vorzüge bzw. deren Mängel aufgezeigt. Eine finale Klassifizierung mit einer geeigneten Methode zeigt die Tauglichkeit und Grenzen für die praktische Anwendung.

## **Abstract**

This masterthesis deals with methods of remote sensing for classifying the forest attribute crown cover. One of these methods is the supervised classification, which uses spectral characteristics of the image for classification. The spectral characteristics are received from reference data. A part of this thesis is dedicated to the acquisition of reference data. The reflection of these areas is analysed on the basis of three images of the satellites Spot 4 and IRS P6. Additionally the interrelation between reflection and crown cover is also checked by the analysis of synthetic channels. A simulation of shadowing of forest stands confirms the assumption that the reflection of forest is affected by the shadow of the trees, which depends on the crown cover.

A major part of this thesis is dedicated to four methods of the supervised classification. In addition to the k-Nearest-Neighbour algorithm and the simple linear regression there are two new developed methods, which are based on regression analysis. The four methods are compared by using the crossvalidation and preferences respectively deficits are pointed out. The final classification with an appropriate method shows the suitabilities and limits.



## Danksagung

Ich möchte mich an dieser Stelle bei Herrn Univ. Prof. Dr. Mathias Schardt für die Bereitstellung des interessanten Themas und die sehr gute Betreuung meiner Masterarbeit bedanken. Seine Anregungen waren für mich eine große Hilfestellung beim Verfassen der Arbeit.

Ebenso möchte ich mich bei meinen Arbeitskollegen Dipl. Ing. Heinz Gallaun und Andreas Wimmer für die konstruktiven Diskussionen bedanken, die in dem einen oder den anderen Punkt Eingang in meine Masterarbeit gefunden haben.

Vielen Dank auch meinen Studienkollegen, für die Gemeinschaft und Freundschaft während der Studienzeit und darüber hinaus.

Last but not least gilt ein Dankeswort meinen Eltern und Geschwistern, die mich während der gesamten Studienzeit in allen Belangen unterstützt haben.

## Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
1.1	Einführung und Problemstellung . . . . .	1
1.2	Zielsetzung . . . . .	2
1.3	Struktur der Arbeit . . . . .	2
<b>2</b>	<b>Reflexionseigenschaften von Wäldern</b>	<b>4</b>
2.1	Die Reflexion von Blattorganen . . . . .	4
2.2	Die Reflexion von Waldbeständen . . . . .	5
<b>3</b>	<b>Stand des Wissens</b>	<b>10</b>
3.1	Aufnahmemethoden der Referenzdaten . . . . .	10
3.1.1	Bestimmung der Überschirmung im Feld . . . . .	10
3.1.2	Bestimmung der Überschirmung im Feld mit Kronenraumphotos .	12
3.1.3	Bestimmung der Überschirmung aus Luftbilddaten . . . . .	13
3.1.4	Bestimmung der Überschirmung aus Laserscannerdaten . . . . .	14
3.2	Überwachte Klassifizierung . . . . .	15
3.2.1	k-Nearest-Neighbor Algorithmus . . . . .	15
3.2.2	Multiple Lineare Regression . . . . .	16
3.3	Modellbasierte Schätzung vom Kronendeckungsgrad . . . . .	16
<b>4</b>	<b>Mathematische Grundlagen</b>	<b>19</b>
4.1	Regressionsanalyse . . . . .	19
4.1.1	Das lineare Regressionsmodell . . . . .	20
4.1.2	Das logistische Regressionsmodell . . . . .	25
4.2	Hauptkomponentenanalyse . . . . .	28
4.3	Kreuzvalidierung . . . . .	31
<b>5</b>	<b>Datengrundlagen</b>	<b>33</b>
5.1	SPOT . . . . .	33
5.1.1	SPOT 4 . . . . .	34
5.1.2	SPOT 5 . . . . .	34
5.2	IRS . . . . .	35
5.2.1	IRS P6 (Resourcesat) . . . . .	37
5.3	Die Untersuchungsgebiete und die verwendeten Bilddaten . . . . .	38
5.3.1	Untersuchungsgebiet Obwalden . . . . .	38

## *Inhaltsverzeichnis*

5.3.2	Untersuchungsgebiet Niedere Tauern . . . . .	39
<b>6</b>	<b>Datenaufbereitung</b>	<b>42</b>
6.1	Vorverarbeitung der Satellitendaten . . . . .	42
6.1.1	Topographische Normalisierung . . . . .	42
6.2	Aufnahme der Trainingsgebiete . . . . .	43
6.2.1	Bestimmung der Rasterweite . . . . .	43
6.2.2	Mögliche Fehlerquellen bei der Aufnahme der Beschirmung . . . . .	45
6.3	Beschreibung der Trainingsgebiete . . . . .	45
<b>7</b>	<b>Datenanalyse</b>	<b>47</b>
7.1	Signaturanalyse . . . . .	47
7.1.1	IRS P6 Satellitenbild vom 17.07.06 . . . . .	47
7.1.2	IRS P6 Satellitenbild vom 23.06.05 . . . . .	48
7.1.3	SPOT 4 Satellitenbild vom 12.09.06 . . . . .	49
7.2	Regressionsanalyse . . . . .	51
7.2.1	Einfache lineare Regression . . . . .	51
7.2.2	Multiple lineare Regressionen . . . . .	53
7.2.3	Regressionsanalyse mit synthetischen Kanälen . . . . .	54
7.2.4	Zwei einfache lineare Regressionen . . . . .	56
7.3	Schattenwurf von Waldbeständen . . . . .	58
7.3.1	Simulation des Schattenwurfes . . . . .	59
<b>8</b>	<b>Vergleich der vier Klassifizierungsmethoden</b>	<b>64</b>
8.1	Methode der einfachen linearen Regression . . . . .	64
8.2	k-Nächste-Nachbarn Klassifizierung . . . . .	65
8.3	Zwei lineare Regressionen mit vorhergehender Stratifizierung durch die Maximum-Likelihood-Methode . . . . .	65
8.4	Zwei lineare Regressionen mit vorhergehender Stratifizierung durch die Logistische Regression . . . . .	67
8.5	Vergleich der Stratifizierungsmethoden . . . . .	68
8.6	Evaluierung der Klassifizierungsmethoden . . . . .	71
8.6.1	IRS-P6 Satellitenbild vom 17.07.06 . . . . .	71
8.6.2	IRS-P6 Satellitenbild vom 23.06.05 . . . . .	73
8.6.3	SPOT 4 Satellitenbild vom 12.09.06 . . . . .	75
8.7	Anwendung der Methoden auf verschiedene Bestandestypen . . . . .	76

## Tabellenverzeichnis

8.7.1	Anwendung der Methoden auf Nadelwälder in den Altersklassen von Jungwuchs bis Stangenholz . . . . .	76
8.7.2	Anwendung der Methoden auf Misch- und Laubwälder . . . . .	78
<b>9</b>	<b>Ergebnisse der Klassifizierung</b>	<b>80</b>
<b>10</b>	<b>Zusammenfassung und Ausblick</b>	<b>85</b>

## Tabellenverzeichnis

1	Kronenschlussgrad mit Definition . . . . .	11
2	Tasseled Cap Parameter für Spot 5 Bilder (für Juli) . . . . .	31
3	Parameter der Sensoren von Spot 1 bis Spot 3 . . . . .	34
4	Parameter der Sensoren von Spot 4 . . . . .	34
5	Parameter der Sensoren von Spot 5 . . . . .	35
6	Parameter der Sensoren von IRS P6 . . . . .	38
7	Geometrische Genauigkeit des Image 2006 Datensatzes . . . . .	40
8	Ergebnisse der Kreuzvalidierung bei der Stratifizierung . . . . .	70

## Abbildungsverzeichnis

1	Typische spektrale Reflexionskurve $R(\lambda)$ über $\lambda$ grüner Blattorgane . . .	4
2	Abhängigkeit der Signatur von dichten Buchen- und Fichtenbeständen von der Illumination im 4. Kanal des Landsat-TM (nach Schardt, 1997[18])	6
3	Abhängigkeit der mittleren Grauwerte des nahen Infrarots vom Beschirmungsgrad von Nadelbeständen (nach Schardt, 1997[18]) . . . . .	8
4	Densimeter der Firma Grube . . . . .	11
5	Stichprobenschema für die Erstellung von Kronenraumphotos (nach Buhk, 2000[2]) . . . . .	12
6	Kronenraumphoto und dessen Klassifizierung . . . . .	13
7	Vergleich der Raster mit unterschiedlichen Samplingweiten . . . . .	44
8	Verteilung der Überschirmungsgrade innerhalb alter Nadelholzbestände .	46
9	Streudiagramme von Beschirmungsgrad und Grauwerte der unterschiedlichen Kanäle des IRS Satellitenbildes vom 17.07.06 . . . . .	48
10	Streudiagramme von Beschirmungsgrad und Grauwerte der unterschiedlichen Kanäle des IRS Satellitenbildes vom 23.06.05 . . . . .	49
11	Streudiagramme von Beschirmungsgrad und Grauwerte der unterschiedlichen Kanäle des SPOT 4 Satellitenbildes vom 12.09.06 . . . . .	50
12	Schätzung der Beschirmung aus dem NIR mit einer Regression . . . . .	51
13	Schätzung der Beschirmung aus dem MIR mit einer Regression . . . . .	52
14	Schätzungen der Beschirmung durch multiple Regression . . . . .	53
15	Streudiagramme von Beschirmungsgrad und unterschiedlichen synthetischen Kanälen . . . . .	54
16	Schätzungen der Beschirmung durch unterschiedliche Modelle . . . . .	56
17	Schätzung der Beschirmung aus dem NIR mit zwei Regressionen . . . . .	57
18	Vergleich der Reflexion von Latschenbeständen und Fichtenbeständen in Abhängigkeit des Beschirmungsgrades . . . . .	58
19	Simulierte Schattenflächen eines Bestandes bei einer Sonnenelevation von $60^\circ$ . . . . .	59
20	Simulierter Anteil des Schattens des Waldes bei unterschiedlicher Sonnenelevation . . . . .	60
21	Simulierte Flächenanteile innerhalb des Waldes bei unterschiedlicher Sonnenelevation . . . . .	61
22	Schattenwurf unterschiedlicher Bestände ([12][Kane et. al]) . . . . .	62

## Abbildungsverzeichnis

23	Simulierter Anteil des Schattens eines Bestandes bei unterschiedlicher Sonnenelevation und variierender Exposition . . . . .	63
24	Visualisierung der Regressionsmethode . . . . .	68
25	Spektrale Verteilung der Straten in der IRS P6 Szene vom 17.07.06 . . . . .	69
26	Spektrale Verteilung der Straten und die Abgrenzung durch Klassifizierung ( MIR-GRÜN) . . . . .	71
27	Vergleich der Kreuzvalidierung der Methoden 1 und 2 (Satellitenbild vom 17.07.06) . . . . .	72
28	Vergleich der Kreuzvalidierung der Methoden 3 und 4 (Satellitenbild vom 17.07.06) . . . . .	73
29	Vergleich der Kreuzvalidierung der Methoden 1 und 2 (Satellitenbild vom 23.06.05) . . . . .	74
30	Vergleich der Kreuzvalidierung der Methoden 3 und 4 (Satellitenbild vom 23.06.05) . . . . .	74
31	Vergleich der Kreuzvalidierung der Methoden 1 und 2 (Satellitenbild vom 12.09.06) . . . . .	75
32	Vergleich der Kreuzvalidierung der Methoden 3 und 4 (Satellitenbild vom 12.09.06) . . . . .	76
33	Anwendung der Methoden 1 und 2 auf Nadelwälder unterschiedlicher Altersklassen . . . . .	77
34	Anwendung der Methoden 3 und 4 auf Nadelwälder unterschiedlicher Altersklassen . . . . .	77
35	Anwendung der Methoden 1 und 2 auf Misch- und Laubwälder . . . . .	78
36	Anwendung der Methoden 3 und 4 auf Misch- und Laubwälder . . . . .	79
37	Waldbestand mit 39% Beschirmung . . . . .	81
38	Waldbestand mit 32% Beschirmung . . . . .	81
39	Waldbestand mit 66% Beschirmung . . . . .	82
40	Waldbestand mit 89% Beschirmung . . . . .	83
41	Waldbestand mit 67% Beschirmung . . . . .	83

# 1 Einleitung

## 1.1 Einführung und Problemstellung

In Österreich nehmen vom Wald bestockte Flächen ungefähr 47% des Staatsgebietes ein. Diese Flächen werden aus Gründen der forstlichen Planung in Bestände eingeteilt, die sich hinsichtlich der Baumartenzusammensetzung, des Bestandesalters und des Überschirmungsgrades unterscheiden. Der Überschirmungsgrad eines Bestandes ist durch das Verhältnis der vertikal projizierten Kronenfläche zu seiner Grundfläche gegeben und erlangt durch die Verankerung in verschiedenen Walddefinitionen sowie Gesetzen an Bedeutung. So wird im österreichischen Forstrecht die Beschirmung als Kriterium herangezogen, um zwischen Wald und Nichtwald zu unterscheiden. Im Forstgesetz werden forstlich nicht genutzte Flächen mit einem Schlussgrad von weniger als 30% als Nichtwald definiert ([5, § 1 Abs. 1 Forstgesetz]). Im Gegensatz dazu bestimmt die Welternährungsorganisation FAO (Food and Agriculture Organisation) 10% als Grenze, die zwischen Wald und Nichtwald unterscheidet. Diese Unstimmigkeit zwischen den verschiedenen Definitionen stellt ein Problem dar, wenn es darum geht Waldflächen international zu vergleichen.

Die Beschirmung des Waldes ist auch aus ökologischer Sicht von Bedeutung. Unterschiedliche Schadereignisse wie Insektenfraß oder Sturmwurf äußern sich durch eine reduzierte Kronenfläche des Bestandes (vgl. Schardt, 1997[18]). Neben der Erkennung von Waldschäden kann der Beschirmungsgrad auch für die Detektion von gefährdeten Beständen herangezogen werden. So weisen gering beschirmte Flächen ebenso wie davon direkt benachbarte Bestände, ein größeres Risiko für Schadereignisse auf. Diese Bestände sind besonders anfällig für Windwurf, Windbruch und Insektenfraß. Nach der Detektion dieser Bestände können Maßnahmen ergriffen werden, die den Gefahren entgegenwirken.

Viele Schadereignisse, nicht nur Waldflächen betreffend, können mit dem Klimawandel in Verbindung gebracht werden. Um aktuelle Informationen zu Umweltbelangen (inklusive Klimawandel) und Sicherheit zu erlangen, wurde die Initiative Global Monitoring for Environment and Security (GMES) von der Europäischen Kommission (EU) und der Europäischen Weltraumorganisation (ESA) gegründet. Aus Daten, die von Erkundungssatelliten, Raum- und Bodenstationen gewonnen werden, soll ein umfassendes Bild der Erde erstellt werden, um damit die politische Entscheidungsfindung zu Umweltbelangen zu ermöglichen. Im Rahmen der Initiative GMES wurde auch das Projekt Geoland<sup>2</sup> in Auftrag gegeben. Ziel dieses Projektes ist die Entwicklung von operationellen Me-

---

<sup>1</sup>[<http://www.gmes-geoland.info>, Stand: 18.11.2010]

## 1 Einleitung

thoden und Prozessierungsketten zur Informationsgewinnung aus Fernerkundungsdaten. Zu diesen Informationen zählen auch das Waldvorkommen, der Bestandestyp und der Überschirmungsgrad. Der Überschirmungsgrad von Wald wird begleitend zum Projekt Geoland2 in dieser Arbeit behandelt.

### 1.2 Zielsetzung

Die Bestimmung von Bestandesparametern wie der Beschirmung erfolgt heutzutage vermehrt mit Fernerkundungssystemen, welche reflektierte oder ausgesendete elektromagnetische Strahlung von Objekten nutzen, um Informationen über diese zu gewinnen. Zur Ableitung forstlicher Parameter eignen sich vor allem hochauflösende Satellitenbilder, welche eine geometrische Auflösung von 10 bis 100 m aufweisen. Auch in dieser Arbeit werden hochauflösende Satellitenbilder verwendet, um den Überschirmungsgrad von Waldbeständen zu klassifizieren. Für die Methode, mit der die Beschirmung ermittelt werden soll, besteht die Anforderung, dass das Resultat einem kontinuierlichen Wert entspricht, um einen vielseitig nutzbaren Datensatz zu schaffen.

### 1.3 Struktur der Arbeit

Nach dieser Einleitung werden die Reflexionseigenschaften von Wäldern in Kapitel 2 behandelt: Beginnend mit der Reflexion einzelner Blattorgane wird danach das komplexere Rückstrahlverhalten gesamter Bestände besprochen. Im Vordergrund steht der Einfluss der Bestandesparameter Waldtyp, Altersklasse und Überschirmungsgrad auf die vom Sensor des Satelliten aufgenommene Rückstreuung.

Im Kapitel 3 „Stand des Wissens“ werden die gängigen Methoden der Fernerkundung zur Klassifizierung von Schlussgraden vorgestellt. Neben der modellbasierten Schätzung des Schlussgrades, bei der ein physikalisches Modell den Zusammenhang zwischen Bestandesparameter und Rückstreuung beschreibt, wird die übliche Vorgehensweise der überwachten Klassifizierung beschrieben. Der überwachten Klassifizierung sind zwei Teile des Kapitels gewidmet, ein Teil für die Aufnahme der Referenzdaten und ein Teil für die verschiedenen Algorithmen und Methoden zur Klassifizierung des Satellitenbildes.

Kapitel 4 widmet sich den mathematischen Grundlagen der Methoden, die in dieser Arbeit miteinander verglichen werden. Zusätzlich zur Regressionsanalyse werden die Theorien der Hauptkomponenten Transformation, der Tasseled Cap Transformation und der Kreuzvalidierung besprochen. Auf die mathematischen Grundlagen folgt das Kapitel der Datengrundlagen 5, in dem unter Anderem die Eigenschaften der Sensoren der Satelliten



## 1 Einleitung

Spot 4, Spot 5, IRS P6 beschrieben werden. Am Ende dieses Kapitels werden die Untersuchungsgebiete Obwalden und Niedere Tauern vorgestellt und das dort verfügbare Datenmaterial angeführt.

Mit der Datenaufbereitung in Kapitel 6 beginnt der praktische Teil dieser Arbeit. In diesem Kapitel wird die Vorverarbeitung der Satellitenbilder und verschiedene Verfahren zur Aufnahme der Referenzdaten beschrieben. Das darauf folgende Kapitel 7 mit dem Titel „Datenanalyse“ besteht aus der Signaturanalyse, der Regressionsanalyse und einer Simulation des Schattenwurfes von Waldbeständen. In der Signaturanalyse wird die Reflexionscharakteristik, auch Signatur genannt, von verschiedenen beschirmten Waldbeständen betrachtet. In der Regressionsanalyse werden mögliche Zusammenhänge zwischen der Signatur der Satellitenbilder und dem Beschirmungsgrad untersucht, welche durch die Simulation des Schattenwurfes erklärt werden.

In Kapitel 8 werden vier Methoden der überwachten Klassifizierung auf die Daten angewendet und deren Tauglichkeit für die gegebene Fragestellung diskutiert. Neben Standardmethoden der Fernerkundung, dem k-Nearest-Neighbor Algorithmus und der einfachen linearen Regression, werden zwei neue Methoden betrachtet und mit den Standardverfahren verglichen. Der Vergleich der Methoden geschieht einerseits visuell und andererseits statistisch durch die Kreuzvalidierung.

Nach der Wahl der geeignetsten Methode werden im Kapitel 9 „Ergebnisse und Klassifizierung“ verschiedene Ausschnitte der Klassifizierung des Überschirmungsgrades dargestellt und diskutiert. Hier wird auch auf Vor- und Nachteile der gewählten Methode eingegangen. Den Abschluss dieser Arbeit bildet Kapitel 10, in dem einerseits die gewonnenen Erkenntnisse zusammengefasst werden und andererseits eine Anregung zu möglichen weiteren Untersuchungen aufgezeigt wird.

## 2 Reflexionseigenschaften von Wäldern

Dieses Kapitel dient dem Verständnis des Rückstrahlverhaltens von Waldbeständen. Dazu werden einleitend die Reflexionseigenschaften von einzelnen Blattorganen und darauf aufbauend die Reflexion gesamter Pflanzenbestände beschrieben. Die dazu nötigen Informationen sind aus den Werken „Fernerkundung und Luftbildmessung“ (Hildebrandt, 1996 [9]) und „Beobachtungen von Waldschäden im niedersächsischen Harz mit Methoden der Fernerkundung und Aufbau eines Waldinformationssystems“ (Schardt, 1997[18]) entnommen.

### 2.1 Die Reflexion von Blattorganen

Das empirische Wissen über das Reflexionsverhalten von Blattorganen stammt von spektrophotometrischen und spektroradiometrischen Messungen. Mit einem Spektrometer werden dabei für unterschiedliche Wellenlängen  $\lambda$  die Intensitäten der aufgenommenen elektromagnetischen Strahlung bestimmt. Die von diesen Messungen abgeleiteten Werte bilden eine sogenannte Reflexionskurve.

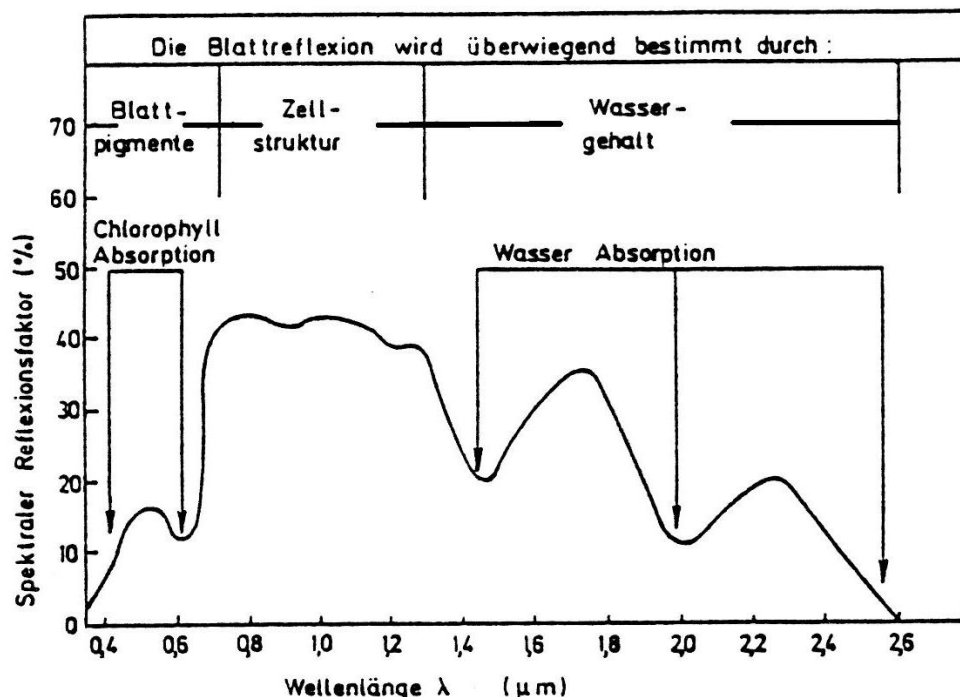


Abbildung 1: Typische spektrale Reflexionskurve  $R(\lambda)$  über  $\lambda$  grüner Blattorgane

In Abbildung 1 ist der charakteristische Verlauf einer Reflexionskurve eines Blattorganes dargestellt. Je nach Wellenlänge der eintreffenden Strahlung wird die Rückstrahlung

vornehmlich von den Blattpigmenten, der Blattstruktur oder dem Wassergehalt beeinflusst. Im sichtbaren Spektralbereich weist die Kurve durch die hohe Absorption von den Blattpigmenten wie dem Chlorophyll eine geringe Rückstrahlung im Bereich von 10 bis 20% der Eingangsstrahlung auf. Unterschiede in diesem Bereich entstehen vor allem durch den Chlorophyllgehalt im Blattorgan und dessen Oberflächenbeschaffenheit.

Im nahen Infrarot findet Absorption nur im geringen Maße statt, jedoch beeinflusst die art- und zustandsspezifische Zellstruktur den Anteil der vom Blatt transmittierten und der reflektierten Strahlung. Die Reflexionswerte weisen im nahen Infrarot eine hohe Variation auf, sie liegen im Bereich von 30 bis 70%. Besonders große Unterschiede gibt es zwischen Nadel und Laubblättern, Laubblätter reflektieren im nahen Infrarot deutlich mehr als Nadeln.

Die Rückstrahlung im mittleren Infrarot ist geprägt von den Wasserabsorptionsbanden, die sich um 1,45, 1,95 und 2,7  $\mu\text{m}$  befinden und dort für starke Einbuchtungen der Reflexionskurve sorgen. Generell korreliert die Menge des zurückgestrahlten Lichts im Wellenlängenbereich von 1,3 bis 2,6  $\mu\text{m}$  mit dem Wassergehalt des Blattorgans, was sich bei abnehmenden Wassergehalt durch zunehmende Reflexionswerte äußert.

### 2.2 Die Reflexion von Waldbeständen

Das Wissen über die Reflexion einzelner Blätter bietet eine gute Grundlage für das Verständnis der Reflexion gesamter Pflanzengesellschaften. So reflektieren entsprechend den Blattorganen, Laubbestände im nahen Infrarot stärker als Nadelbestände. Neben den Blättern wird das Rückstrahlverhalten von mehreren Faktoren bestimmt (vgl. Hildebrandt, 1996 [9]):

- die Stellung und Größe der Blattorgane,
- der Aufbau des Sprosses, bei Bäumen der Krone,
- die Dichte der Belaubung und damit das Verhältnis zwischen Reflexionsanteilen beleuchteter wie beschatteter Blätter/Nadeln, anderer Pflanzenteile und durchscheinenden Bodens und Unterwuchses,
- die phänologische Situation mit ihrem Einfluß auf die Reflexion durch den jeweiligen Belaubungszustand, aber auch durch das Blühen und Fruchttrogen,

und bei Pflanzenbeständen strukturelle Elemente der Gruppe wie

- die Zusammensetzung nach Arten und die Form der Vergesellschaftung

## 2 Reflexionseigenschaften von Wäldern

- die Dichte der Bestockung und damit auch der eventuelle Anteil der Reflexion vom Boden, von Bodenvegetation oder unterständigen Pflanzen,
- bei Wäldern und anderen Dauerkulturen das Alter bzw. die Alterszusammensetzung des Bestandes,
- die vertikale Gliederung, d. h. die Rauigkeit der Oberfläche z. B. von Waldbeständen, Buschvegetation, Plantagen usw.

Abgesehen von diesen Faktoren kann ein Bestand durch Variation der Einstrahlungsart (direkt oder diffus), dem Einstrahlungswinkel der Sonne, den Beleuchtungsverhältnissen (besonnt oder beschattet) oder dem Atmosphärenzustand (klar, dunstig) ein unterschiedliches Reflexionsverhalten aufweisen. Während ein Bestand bei diffusen Lichtverhältnissen die Tendenz zu einer gleichmäßigen, richtungsunabhängigen Reflexion aufweist, ist ein Großteil der Rückstrahlung bei direkter Einstrahlung, abhängig von der Rauigkeit des Bestandes, stärker vorwärts oder rückwärts gerichtet. Der Einfluss des Einstrahlungswinkels der Sonne auf die Reflexion kann ebenfalls nicht getrennt von den Bestandesformen betrachtet werden, wie man in Abbildung 2 erkennt.

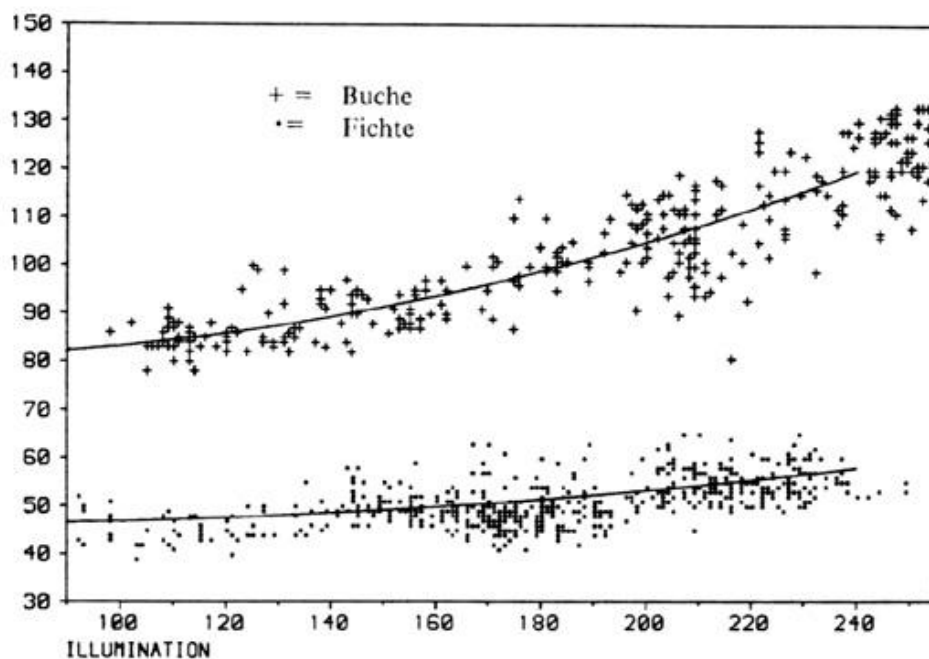


Abbildung 2: Abhängigkeit der Signatur von dichten Buchen- und Fichtenbeständen von der Illumination im 4. Kanal des Landsat-TM (nach Schardt, 1997[18])

Die Abbildung 2 verdeutlicht, dass die gerichtete Reflexion von Buchenbeständen stärker vom Einstrahlungswinkel abhängt als jene von Fichtenbeständen. Schardt [18] sieht den Grund dafür in der vertikalen Struktur des Kronendaches, und erklärt die Unterschiede durch den Anteil an vorwärtsgerichteter Reflexion, die bei Buchenbeständen durch

die geringere Rauigkeit des Kronendaches höher ist. Ergänzend ist noch zu erwähnen, dass die vom Bestand reflektierte Strahlung bei einem hohen Sonnenstand grundsätzlich größer ist als bei einem niedrigen.

Abgesehen vom Einfluss des Einstrahlungswinkels zeigt Abbildung 2 einen klar erkennbaren Unterschied der Grauwerte zwischen Buchenbeständen und Fichtenbeständen. Der 4. Kanal des Landsat-TM (Thematic Mapper) entspricht einem Wellenlängenbereich von 0,78-0,90  $\mu\text{m}$ , der zum nahen Infrarot gehört. In diesem Wellenbereich kann nicht nur zwischen Nadel-, Misch- und Laubwäldern unterschieden werden, sondern auch, bei einer geeigneten phänologischen Phase der Arten, zwischen verschiedenen Baumarten die der gleichen Ordnung (Koniferen bzw. Buchenartige) angehören. Während sich die Unterscheidung von Lärchen- und Fichtenbeständen im Hochsommer als schwierig erweist, stellt sie im Herbst und im Frühling kein Problem da.

Neben der phänologischen Phase weisen Pflanzengesellschaften im Laufe ihres Bestehens ein variierendes Rückstrahlverhalten auf. Dies äußert sich bei Nadelholzbeständen durch eine höhere Reflexion von jungen Beständen im Vergleich zu der von alten Beständen. Erwähnenswert in diesem Sinne ist auch, dass die Menge des zurückgestrahlten Lichts von Jungwuchs bis Baumholz sinkt, ab der Altersklasse Baumholz mit zunehmendem Alter jedoch stagniert und andere Faktoren wie zum Beispiel der Einfluss der Beschirmung die Reflexion maskieren (vgl. Schardt, 1997[18]). Im Gegensatz zum Nadelholz reflektiert Laubholz im sichtbaren Spektralbereich immer gleich, auch im mittleren Infrarot sind nur tendenzielle Unterschiede zu erkennen. Nur im nahen Infrarot sind sinkende Werte mit ansteigendem Alter zu beobachten.

Unterschiede in der Reflexion sind auch bei verschieden beschirmten Beständen zu erkennen. Ausgehend von einem geschlossenen Bestand sinkt mit abnehmender Beschirmung der Einfluss der Reflexion der Baumkronen, und der Einfluss von Schatten, Unterwuchs und Boden nimmt zu. Das vom Boden zurückgestrahlte Licht von gering beschirmten Beständen kann je nach Art stark variieren, ein steiniger Boden strahlt im sichtbaren Spektralbereich stärker als ein vergraster Untergrund und wirkt sich somit auch stärker auf die Reflexion des Bestandes aus. Neben dem zurückgestrahlten Licht der Baumkronen und des Bodens spielt auch die Beschattung eine große Rolle, welche durch Bestandesparameter, den Neigungswinkel des Bodens und den Einstrahlungswinkel der Sonne bestimmt wird. Schardt[18] nennt den Bestandesparameter Kronendachrauigkeit als Hauptfaktor, der sich auf die Beschattung innerhalb eines Waldbestandes auswirkt. Aus seiner Arbeit geht hervor, dass die Zunahme der Kronendachrauigkeit zu einer Zu-

## 2 Reflexionseigenschaften von Wäldern

nahme der Schattenflächen führt, was folglich die Rückstrahlung eines Waldbestandes beeinflusst.




Abbildung 3: Abhängigkeit der mittleren Grauwerte des nahen Infrarots vom Beschirmungsgrad von Nadelbeständen (nach Schardt, 1997[18])

In Abbildung 3 sind die unterschiedlichen Überschirmungsgrade von Waldbeständen gegen die Grauwerte des nahen infraroten Kanals eines Thematic Mapper Satellitenbildes aufgetragen. Die abgebildeten Zahlen entsprechen 6 verschiedenen Straten. Als Stratum wird hier eine Menge von Beständen bezeichnet, die bestimmte ähnliche Gegebenheit der Reflexion aufweisen.

1. Stratum: starke Beleuchtung / Stangen- bis mittlere Baumhölzer
2. Stratum: starke Beleuchtung / Althölzer
3. Stratum: mittlere Beleuchtung / Stangen- bis mittlere Baumhölzer
4. Stratum: mittlere Beleuchtung / Althölzer
5. Stratum: geringe Beleuchtung / Stangen- bis mittlere Baumhölzer
6. Stratum: geringe Beleuchtung / Althölzer

Bei allen Straten ist zu erkennen, dass ausgehend von einem dichten Bestand (Schlussgrad 100%) die Grauwerte bis zu einem Überschirmungsgrad von 60% sinken. Mit der

## *2 Reflexionseigenschaften von Wäldern*

Abnahme der Beschirmung nimmt die Rauigkeit des Kronendaches zu und dadurch auch die Beschattung, da die entstehenden Lücken zwischen den Baumkronen mit Schatten ausgefüllt werden. Eine weitere Abnahme des Schlussgrades ist mit einer Zunahme der Grauwerte verbunden. Die Lücken zwischen den Bäumen werden immer größer, sodass das Licht vermehrt den Waldboden oder die Bodenvegetation erreicht, wo es reflektiert wird.

### 3 Stand des Wissens

An dieser Stelle werden bestehende Methoden angeführt, die bereits für die fernerkundungsgestützte Klassifizierung des Überschirmungsgrades verwendet wurden. Die Methoden lassen sich auf Grund ihrer Ansätze in zwei Gruppen einteilen. Der eine Ansatz besteht darin, die Beschirmung über eine überwachte Klassifizierung zu bestimmen, der andere Ansatz verwendet Bestandesreflexionsmodelle für die Schätzung des Kronendeckungsgrades. Während die Zuordnung bei der überwachten Klassifizierung auf empirische Zusammenhänge basiert, wird bei Bestandesreflexionsmodellen die Rückstrahlung von Waldbeständen auf Basis von physikalischen Gegebenheiten modelliert.

Die überwachte Klassifizierung ist ein rechnergestütztes Verfahren, welches Bildinhalte regelbasiert Werteskalen oder Klassen zuordnet, die durch die spektralen Eigenschaften von Trainingsgebieten repräsentiert werden. Die Trainingsgebiete, Flächen mit bekannter Landbedeckung, werden vom Nutzer im Bild festgelegt. Die Aufnahme der Trainingsgebiete, als Arbeitsschritt der überwachten Klassifizierung, kann durch verschiedene Verfahren erfolgen, die in Kapitel 3.1 beschrieben werden. Für die Zuordnung der Bildinhalte zu Werteskalen oder Klassen existieren mehrere Methoden, denen Kapitel 3.2 gewidmet ist.

Bei der Verwendung von Bestandesreflexionsmodellen sind Trainingsgebiete nicht erforderlich, jedoch sind die Modelle zu kalibrieren. Die Ermittlung des Überschirmungsgrades mit der Hilfe von Bestandesreflexionsmodellen wird in Kapitel 3.3 beschrieben.

#### 3.1 Aufnahmemethoden der Referenzdaten

Für die Durchführung einer überwachten Klassifizierung benötigt man Referenzgebiete, welche die zu klassifizierenden Merkmale geeignet repräsentieren. In dieser Arbeit handelt es sich beim gesuchten Merkmal um den Beschirmungsgrad, der durch verschiedene Methoden ermittelt werden kann.

##### 3.1.1 Bestimmung der Überschirmung im Feld

In der Forstwirtschaft erfolgt die Bestimmung im Zuge der Bestandesaufnahme durch gutachterliche Schätzung, dabei wird zwischen den in Tabelle 1 aufgelisteten sechs Kategorien unterschieden.



### 3 Stand des Wissens

Tabelle 1: Kronenschlussgrad mit Definition

Schlussgrad:	Definition
kein Bestand	unbestockte BlöÙe/Bestandeslücke oder SchlagfläÙe/Jungwuchs
räumdig	Zwischenräume >als 2 Kronenbreiten (<30% Beschirmung)
licht	Zwischenräume 1-2 Kronenbreiten (30-50% Beschirmung)
locker	Zwischenräume >als 1 Kronenbreite (50-70% Beschirmung)
geschlossen	Kronen berühren sich (70-90% Beschirmung)
dicht	Kronen greifen ineinander, gedrängt (90-100% Beschirmung)

Eine genauere Bestimmung der Überschirmung erhält man über die terrestrische Vermessung der Krone (Kronenablotung) und einer anschließenden Auswertung. Bei der Kronenablotung werden Kronenpunkte bestimmt und senkrecht auf den Erdboden projiziert. Die Punkte werden am Boden gekennzeichnet und deren Lage in einem Plan eingetragen. Aus den einzelnen Kronenpunkten im Plan ist es ein Leichtes, die Baumkronen zu rekonstruieren und weiters die Überschirmung der Fläche als Prozentwert zu ermitteln.

Bei der Auswahl der Kronenpunkte kann man zwischen zwei Verfahren unterscheiden. Bei einem Verfahren werden die Punkte an den größten Kronenradien aufgenommen, was eine variable Anzahl von Punkten mit sich bringt. Beim anderen Verfahren werden die Kronenradien in vorgegebenen Richtungen aufgenommen, welche gleiche Winkelabstände zueinander aufweisen. In der Praxis werden häufig 4 oder 8 Kronenpunkte aufgenommen, die sich nach den Himmelsrichtungen orientieren.

Für die genaue Ablotung der Krone auf den Waldboden verwendet man einen Kronenspiegel oder Densiometer. Das in Abbildung 4 dargestellte forstliche Messgerät besteht aus einem kardanisch gelagerten Lotrohr mit eingebautem Spiegel und Visierkreuz.



Abbildung 4: Densiometer der Firma Grube

### 3.1.2 Bestimmung der Überschirmung im Feld mit Kronenraumphotos

Die Auswertung von Kronenraumphotos ermöglicht neben der Bestimmung des Beschirmungsgrades auch die Ermittlung der Kronentransparenz, die als Kronenaufriß dividiert durch die Summe der projizierten Blattoberflächen eines Baumes definiert ist. Beim Verfahren mit Kronenraumphotos werden vom Boden aus mehrere Bilder senkrecht in Richtung Kronendach aufgenommen. Dabei sind bei der Lage der Photos folgende Aspekte zu berücksichtigen (nach Buhk[2]):

- Abdeckung von mindestens der geometrischen Auflösung des verwendeten Satellitenbildes
- Vorhandensein von mindestens einer Krone in Abhängigkeit von Bestandesdichte und Kronendimension
- keine Überlappung, aber ausreichende Berücksichtigung der Variation im Bestand

Diese strikten Angaben wirken sich auf die Geometrie des Netzes der Aufnahmepunkte aus, die in einem Plan festgelegt werden. Ein Beispiel eines Aufnahmenetzes mit 17 Kronenraumphotos, skaliert für ein Satellitenbild des Landsat Thematik Mapper, ist in Abbildung 5 dargestellt. In dieser Skizze werden die Positionen der Kronenraumphotos als schwarze Quadrate, und die Abstände dazwischen, die 10 m betragen, als schwarze Linien dargestellt.




Abbildung 5: Stichprobenschema für die Erstellung von Kronenraumphotos (nach Buhk, 2000[2])

Wegen des hohen Arbeitsaufwandes, der Aufnahme und Auswertung der Bilder, wird meist eine Aufnahmekonstellation mit einer geringeren Anzahl von Kronenraumphotos verwendet. Mit 5 bzw. 9 Kronenaufnahmen bestimmt Buhk[2] die Beschirmung und Kronentransparenz von alten bzw. jungen Beständen. Um die gleiche Fläche abzudecken,

entschied er sich für eine Mindestdistanz von 20 m zwischen den Punkten. Die anschließende Zuteilung der Bildinhalte der Aufnahmen erfolgt über eine Klassifizierung durch Schwellwertbildung im blauen Kanal. Die Blätter weisen im diesem Spektralbereich eine geringe Transmission auf, was wegen des großen radiometrischen Unterschiedes zwischen Himmel und Krone eine Auswertung erleichtert. Bei der gleichzeitigen Bestimmung der Kronentransparenz werden zusätzlich durchscheinende Kronenteile klassifiziert.



(a) Digitales Kronenraumphoto



(b) Klassifiziertes Bild mit Kronen, Himmel und Kronentransparenz

Abbildung 6: Kronenraumphoto und dessen Klassifizierung

Ein Kronenraumphoto und das ausgewertete Bild werden in den Darstellungen 6(a) und 6(b) gezeigt. Im klassifizierten Bild sind 3 Kategorien zu erkennen, wobei die Zuordnung der schwarz, grau und weiß gefärbten Flächen den Klassen Krone, Himmel und transparente Krone entsprechen. Die Ableitung des Überschirmungsgrades geschieht durch eine einfache Division der Kronen und transparenten Kronenflächen durch die Gesamtfläche.

#### 3.1.3 Bestimmung der Überschirmung aus Luftbilddaten

Für die Bestimmung des Kronenschlussgrades wird häufig auf Luftbilder zurückgegriffen. Die Tatsache, dass das Kronendach auf eine Bildebene projiziert wird, vereinfacht die Bestimmung des Beschirmungsgrades. Grundsätzlich ist zu erwähnen, dass Methoden, die Bilder als Datengrundlage verwenden, einfacher und schneller sind als die Ermittlung im Feld. Schardt [18] beschreibt in seinem Werk verschiedene Verfahren zur Bestimmung der Überschirmung von Beständen aus Luftbildern.

- Die genaueste Methode ist die Abzeichnung oder auch Digitalisierung des Kronendaches aus sehr hochauflösenden Bildern. Bei diesem Verfahren ergibt sich der Beschirmungsgrad eines Bestandes aus dem Verhältnis der Fläche der digitalisierten Kronendächer zur Bestandesgrundfläche. Durch die flächenhafte Aufnahme des

Kronendaches bleibt die Information über die Wuchsverteilung erhalten, was für viele Fragestellungen von Bedeutung ist. Ein großer Nachteil dieser Methode ist der große Zeitaufwand, den die Digitalisierung mit sich bringt.

- Ein weiteres Verfahren zur Ermittlung des Beschirmungsgrades ist durch die Verwendung eines Punktrasters gegeben. Bei diesem Verfahren wird ein regelmäßiges Punktraster über das Luftbild gelegt und für jeden Punkt wird entschieden, ob dieser im Bild auf einer Baumkrone liegt oder sich auf dem Gelände befindet. Der Schlussgrad eines Bestandes ergibt sich somit aus dem Verhältnis der Anzahl der attributierten Kronenpunkte zur Gesamtanzahl der Punkte im Raster.
- Beschirmungsgrade können auch durch die Verwendung von Kronendichteskalen geschätzt werden. Eine Kronendichteskala besteht aus mehreren schematisierten Darstellungen von Baumkronengruppen, welche abhängig vom Beschirmungsgrad aufsteigend geordnet sind. Bei der Auswertung werden die Trainingsgebiete dieser Skala zugeordnet. Hier ist zu erwähnen, dass diese Methode bezüglich Genauigkeit sowie Zeitaufwand sehr von der Erfahrung des Interpreten abhängig ist.
- In der Praxis wird auch die einfache gutachterliche Schätzung für die Bestimmung der Beschirmung verwendet. Aus den beschriebenen Verfahren in Kapitel 3.1.3 ist dieses das schnellste, dafür aber auch das ungenaueste.

#### 3.1.4 Bestimmung der Überschirmung aus Laserscannerdaten

Flugzeuggetragene Laserscanner werden für die Akquisition von Distanzdaten verwendet, die im Üblichen der Generierung von Oberflächenmodellen dienen, welche eine Grundlage für die Bestimmung des Schlussgrades darstellen. Das Prinzip der Laserscannermessung besteht darin, dass der Scanner Laserimpulse in Richtung Objekt aussendet und die Zeitdauer misst, die der Impuls für seinen Weg vom Scanner zum Objekt und zurück benötigt. Aus der Zeitdauer und der Lichtgeschwindigkeit wird die Distanz zum Objekt berechnet, die bei bekannter Ausrichtung des Scanners eine Positionsberechnung des Objektes ermöglicht. Aus den Positionsdaten lassen sich Oberflächenmodell und Geländemodell ableiten. Die Differenz zwischen Geländemodell und Oberflächenmodell liefert ein Bestandeshöhenmodell, aus dem je nach geometrischer Auflösung und Genauigkeit verschiedene Bestandesparameter abgeleitet werden können. So erhält man für einen abgegrenzten Bereich des Waldes den Schlussgrad durch Division der Kronenfläche durch die Gesamtfläche. Weitere Parameter wie mittlere Höhe und Oberhöhe können auf ähnlichem Weg ermittelt werden.

## 3.2 Überwachte Klassifizierung

Auf Basis der Reflexionswerte der Klassen, repräsentiert durch die Trainingsgebiete im Satellitenbild, werden die Pixel des Bildes einer Klasse oder einem Wert zugewiesen. Die Zuordnung kann durch unterschiedliche Klassifizierungsmethoden erfolgen, wobei nicht alle Methoden immer gleich gut geeignet sind. Die Aufgabenstellung dieser Arbeit erfordert, dass die resultierenden Beschirmungsgrade kontinuierlichen Prozenten entsprechen, um damit Waldkarten nach unterschiedlichen Nomenklaturen erstellen zu können. Wie in der Einleitung erwähnt wurde, weisen verschiedene Nomenklaturen Unterschiede bei der Definition von Wald auf. Während bei der FAO (Food and Agriculture Organization) Flächen ab einer Beschirmung von 10% als Wald gelten, ist laut dem österreichischen Forstgesetz ein Schlussgrad von 30% erforderlich. Während ein kontinuierlicher Beschirmungsgrad bezüglich verschiedenen Nomenklaturen flexibel verwendbar ist, sind Methoden, deren Ergebnisse eine Klassenzugehörigkeit ergeben, nicht geeignet. Klassen, die feste Beschirmungsgradgrenzen aufweisen, sind nur in Ausnahmefällen mit einzelnen Nomenklaturen kompatibel. Im Folgenden werden nur Methoden beschrieben, die eine kontinuierliche Beschirmung als Ergebnis liefern.

### 3.2.1 k-Nearest-Neighbor Algorithmus

Dieses Verfahren basiert auf der Nearest-Neighbor Methode, bei der ein zu bestimmendes Pixel die Kategorie des spektral ähnlichsten Referenzgebietes zugewiesen bekommt. Dieses Gebiet wird als nächster Nachbar bezeichnet und über die Distanz im spektralen Merkmalsraum bestimmt, in welchem die Pixel mit ihren Grauwerten als Positionsvektoren vertreten sind. Im Gegensatz zur Nearest-Neighbor Methode verwendet die k-Nearest-Neighbor Methode, die Kategorien der  $k$  nächsten Nachbarn für die Entscheidungsfindung. Diese Tatsache ermöglicht es dem Algorithmus, Mischklassen zu erstellen, die nicht durch Trainingsgebiete abgedeckt sind. Die Verwendung einer variablen Zahl von nächsten Nachbarn  $k$  und eine Variation der Gewichtung der Distanzen ermöglicht dem Nutzer, dieses Verfahren zu modifizieren.

Die Eignung der  $kNN$  Methode für die Ermittlung von Bestandesparametern auf Basis von Bildern des Satelliten Landsat TM wurde von Franco-Lopes et. al. [6] untersucht. Sie bestimmten mit der  $kNN$  Methode die Bestandesparameter Mischungsverhältnis von Nadel- und Laubholz, die Basisfläche und den Bestandesvorrat. Ein Hauptaugenmerk dieser Arbeit lag beim Vergleich von Modellen mit unterschiedlichen Eingangsparametern, der Gewichtung der Distanz und der Anzahl der verwendeten nächsten Nachbarn. Das Resultat dieser Studie war, dass dieses parameterfreie Verfahren noch einer weite-

ren Entwicklung bedarf, jedoch bereits Ergebnisse liefert, deren Qualität mit der von auf Statistik beruhenden Verfahren vergleichbar ist.

#### 3.2.2 Multiple Lineare Regression

Die Methoden der linearen und multiplen linearen Regression sind in der Anwendung der Fernerkundung stark verbreitet und wurden bereits mehrmals für die Schätzung von Bestandesparametern verwendet. Beide Ausprägungen der linearen Regression werden in Kapitel 4.1.1 genauer behandelt, da sie der Durchführung des praktischen Teils dienen.

Unter Anderem wurde die lineare Regression von Carreiras et. al.[3] für die Schätzung des Überschirmungsgrades von Eichenwäldern in Portugal verwendet. Die Aufnahme der Referenzdaten erfolgte aus Luftbildern mit der in Kapitel 3.1.3 beschriebenen Stichprobenmethode. Mit den Überschirmungsgraden der Trainingsgebiete, den Kanälen eines Landsatbildes und davon abgeleiteten Vegetationsindizes wurden verschiedene Regressionsmodelle erstellt und miteinander verglichen. Der NDVI (normalisierter Differenz Vegetationsindex), der aus den Kanälen des nahen und mittleren Infrarots gebildet wird, liefert die besten Ergebnisse der verwendeten Vegetationsindizes. Die geringsten Abweichungen zwischen den Referenzdaten und den berechneten Beschirmungen wurden jedoch mit einer multiplen linearen Regression und mit den vier originalen spektralen Kanälen des Landsatbildes erzielt.

#### 3.3 Modellbasierte Schätzung vom Kronendeckungsgrad

Zahlreiche unterschiedlich komplexe Bestandesreflexionsmodelle ermöglichen eine näherungsweise Beschreibung des Rückstrahlverhaltens von Waldflächen. Eine Invertierung dieser Modelle liefert aus gemessenen Reflexionswerten einen Schätzwert für verschiedene Bestandesparameter. Das FLIM (Forest Light Interaction Model) liefert zum Beispiel den Kronendeckungsgrad und die Kronentransparenz als Ergebnis einer Invertierung. Dieses von Rosema[15] entwickelte Modell basiert auf der Annahme, dass die Reflexion des Bestandes von vier Signaturkomponenten bestimmt wird. Diese Komponenten sind die "beleuchtete Krone", die "beschattete Krone", der "beleuchtete Boden" und der "beschattete Boden", welche in ihrer prozentuellen Verteilung von Bestandesparametern, dem Einstrahlungswinkel der Sonne und der Geländeneigung abhängen. Das FLIM beschreibt die pixelweise Reflexion des Bestandes  $R$  durch die Kronenreflexion bei unendlicher optischer Dicke  $R_c$ , der Reflexion des Untergrundes  $R_g$ , einem Kronen-Faktor  $C$  und dem Grund-Faktor  $G$ .

$$R = R_c C + R_g G. \quad (1)$$

Die zwei Faktoren  $C$  und  $G$  enthalten geometrische Zusammenhänge zwischen den vier Signaturkomponenten und indirekt auch die biophysikalischen Parameter Kronentransparenz und Kronendeckungsgrad. Um diese Faktoren reproduzieren zu können, müssen zuerst die Kronenreflexion bei unendlicher optischer Dicke und die Reflexion des Untergrundes bestimmt werden. Rosema[15] schlägt dafür die visuelle Satellitenbildinterpretation vor, bei der im Satellitenbild Referenzflächen für die Reflexionswerte  $R_c$  und  $R_g$  ausgewählt werden. Bei der Kronenreflexion bei unendlicher optischer Dicke ist darauf zu achten, dass diese von der Baumart abhängig ist und somit spezifisch für jede Baumart bestimmt werden muss.

Für die Inversion des FLIM und die Ableitung der Faktoren  $C$  und  $G$  werden je Waldflächeneinheit, welche durch die geometrische Auflösung des Satellitenbildes bestimmt ist, zwei unabhängige Reflexionsmessungen benötigt. Als Messungen scheinen das nahe Infrarot und das mittlere Infrarot geeignet.

$$C = (R_g^m R^n - R_g^n R^m) / (R_g^m R_c^n - R_g^n R_c^m)$$

$$G = -(R_c^m R^n - R_c^n R^m) / (R_g^m R_c^n - R_g^n R_c^m)$$

Die vorangestellten Formeln zeigen die analytische Lösung des Kronen-Faktors  $C$  und des Grund-Faktors  $G$ , wobei die hochgestellten Buchstaben  $n$  und  $m$  für die Reflexionsmessungen des nahen und des mittleren Infrarotes stehen. Nach der Berechnung von Kronen-Faktor und Grund-Faktor wird mit diesen Werten, dem Neigungswinkel, dem Einstrahlungswinkel und einem Maß der mittleren Kronenform die Beschirmung und die Kronentransparenz bestimmt. Der genaue Ablauf dieser Auswertung und die dazugehörigen Formeln sind im Werk "A new forest light interaction model in support of forest monitoring" zu finden (Rosema, 1992 [15]).

Unabhängig von Rosemas Arbeit verwendete Buhk [2] das FLIM für Untersuchungen von Laub- und Nadelbeständen im deutschen Südschwarzwald und verifizierte die Ergebnisse mit terrestrisch aufgenommenen Bestandesdaten. Dabei konnte er für die meisten untersuchten Bestände nur schwache oder keine Zusammenhänge zwischen den Ergebnissen des FLIM und den in der Natur erhobenen Daten erkennen. Buhk nennt mehrere Ursachen für diese Unterschiede: Jener Faktor, der die Qualität des Modells am meisten beeinflusst, ist die Ermittlung der Reflexion von Untergrund und der Krone bei unendli-

cher optischer Dichte. Für beide Größen können nur Näherungswerte gefunden werden, da bei der geometrischen Auflösung von den verwendeten Satellitenbildern meist nur eine Mischung von Signaturen in den einzelnen Pixeln enthalten ist. Dabei ist die Bestimmung der Reflexion der Krone bei unendlicher optischer Dichte besonders fehlerbehaftet, da die Rückstrahlung durch die beschatteten Kronenteile verfälscht wird. Anbetracht der Ergebnisse und unter Berücksichtigung der Arbeiten anderer Autoren stellt er schlussendlich fest, dass dieses Modell nur für spektral relativ homogene Waldtypen einsetzbar ist, was im geneigten Gelände auf Grund der reliefbedingten Beleuchtungsunterschiede nicht der Fall ist.



## 4 Mathematische Grundlagen

Für den praktischen Teil der Arbeit waren gewisse mathematischen Kenntnisse erforderlich, die in diesem Kapitel wiedergegeben werden. Da mit der Regressionsanalyse bereits gute Ergebnisse in der forstlichen Fernerkundung erzielt wurden, bildet diese die Grundlage des praktischen Teils dieser Arbeit, weshalb hier die Grundlagen beschrieben werden. Obwohl davon ausgegangen werden kann, dass die einfache lineare Regression zum Basiswissen zählt, wird sie hier als Einleitung für die weiteren Regressionsmethoden verwendet. Neben den Regressionsmethoden werden hier die Hauptkomponenten Transformation, die damit verwandte Tasseled Cap Transformation und die Kreuzvalidierung bearbeitet. Bei der Hauptkomponenten Transformation und der Tasseled Cap Transformation werden die originalen Grauwerte der Satellitenbilder in synthetische Kanäle transformiert, die wiederum mit der Regressionsanalyse untersucht werden. Die Kreuzvalidierung dient im praktischen Teil dieser Arbeit dem unabhängigen Vergleich der verschiedenen Methoden, mit denen der Überschirmungsgrad ermittelt wird. Die Informationen zu diesen Themen stammen aus den Werken „Regression“ (Härdle, 2007 [10]) und „Angewandte Statistik“ (Sachs, 2006 [17]) und „Multivariate Analysemethoden“ (Backhaus, 1996[1]).

### 4.1 Regressionsanalyse

Die Regressionsanalyse ist ein Verfahren der Statistik, bei der ein Zusammenhang zwischen einer Zielvariablen  $y$  und ein oder mehreren beschreibenden Variablen (Kovariablen)  $x$  untersucht wird. Die in der Regressionsanalyse verwendeten Modelle unterscheiden sich überwiegend durch die Typen der Ziel- und Kovariablen, welche stetig, binär oder kategorial sein können. Alle Modelle verbindet die grundlegende Annahme, dass die Zielgröße eine Zufallsvariable ist, deren Erwartungswert durch einen funktionalen Zusammenhang mit den Kovariablen beschrieben werden kann.

$$E(y|x_1, \dots, x_k) = f(x_1, \dots, x_k) \quad (2)$$

Da die Realisierung der Zielvariablen  $y$  einer Zufallsvariablen entspricht, besteht die Zielvariable neben einer systematischen Komponente ( $y = E(y|x_1, \dots, x_k)$ ) auch aus einer stochastischen Komponente  $\epsilon$ .

$$y = E(y|x_1, \dots, x_k) + \epsilon = f(x_1, \dots, x_k) + \epsilon \quad (3)$$

Mit der Regressionsanalyse wird die systematische Komponente bestimmt und vom sto-

chastischen Teil getrennt. Für die Bestimmung der systematischen Komponente benötigt man, neben der Realisierung der Zielvariablen und den zugehörigen Kovariablen, ein passendes Modell.

### 4.1.1 Das lineare Regressionsmodell

Unter den Regressionsmodellen ist das klassisch lineare das einfachste. Für dieses Modell gelten die Annahmen, dass die systematische Komponente  $f$  eine Linearkombination der Kovariablen ist und dass die stochastische Komponente  $\epsilon$  einen additiven Beitrag zur Realisierung der Zielvariablen  $y$  leistet. Mit diesen Annahmen und der Gleichung 3 erhält man die lineare Regression, die in der Formel 4 dargestellt ist. Sie besteht aus der Zielvariablen  $y$ , den Kovariablen  $x$ , den Regressionskoeffizienten  $\beta$  und der stochastischen Komponente  $\epsilon$ .

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \epsilon \quad (4)$$

Eine Unterteilung der linearen Regression erfolgt über die Anzahl der Kovariablen. Bei einer Kovariablen spricht man von einer einfachen linearen Regression, bei zwei oder mehreren handelt es sich um eine multiple lineare Regression. Für beide Formen gelten folgende Annahmen, welche die Kovariablen und die stochastische Komponente (Störgröße) betreffen.

- Der Erwartungswert der stochastischen Komponente ist Null.
- Der Varianz der stochastischen Komponente ist homoskedastisch (konstante Varianz) und unkorreliert.
- Die Kovariablen sind untereinander linear unabhängig.

Wird zusätzlich von einer Normalverteilung der Störgröße ausgegangen, handelt es sich um eine lineare Normalregression. Die Berechnung der Regressionsparameter der linearen Modelle kann durch verschiedene Methoden erfolgen, hier wird jedoch nur die gebräuchlichste beschrieben.

### Schätzung der Parameter

Die Berechnung der Regressionskoeffizienten erfordert Zielvariablen  $y$  und zugehörigen Kovariablen  $x$ , wobei mindestens gleich viele Beobachtungen benötigt werden als Parameter zu schätzen sind. Die Schätzung der Koeffizienten eines linearen Modells erfolgt

üblicherweise über die Methode der kleinsten Quadrate. Bei dieser Methode werden die Koeffizienten so gewählt, dass die Quadrate der Residuen  $\varepsilon$  ein Minimum ergeben.

$$KQ(\beta) = \sum_{i=1}^n (y_i - x'_i \beta)^2 = \sum_{i=1}^n \varepsilon_i^2 = \varepsilon' \varepsilon \quad (5)$$

Gleichung 5 entspricht einem Optimierungsproblem, bei dem das Minimum der Funktion gesucht wird. Für die Lösung dieser Extremwertaufgabe wird die Formel umgeformt in

$$KQ(\beta) = \varepsilon' \varepsilon = (Y - X\beta)'(Y - X\beta) = y'y - 2y'X\beta + \beta X'X\beta,$$

und nach  $\beta$  differenziert.

$$\frac{\partial KQ(\beta)}{\partial \beta} = -2X'y + 2X'X\beta$$

Nach dem Nullsetzen der Ableitung und anschließender Umformung erhält man die Normalgleichung 6.

$$X'X\beta = X'y \quad (6)$$

Aus der Normalgleichung folgt die Schätzung für die Koeffizienten  $\hat{\beta}$  und dem Erwartungswert von  $\hat{y}$ . Das Dach über den Variablen weist darauf hin, dass es sich hier um Schätzungen handelt, die von den wahren Werten abweichen können.

$$\begin{aligned} \hat{\beta} &= (X'X)^{-1} X'y \\ \hat{y} &= X(X'X)^{-1} X'y \end{aligned}$$

Eine weitere Methode zur Schätzung der Parameter ist die Maximum Likelihood Methode, die im Kapitel 4.1.2 besprochen wird.

### Modellgüte und statistische Tests

Nach der Approximation eines möglichen funktionalen Zusammenhanges durch eine Regression sind die Anpassung und die Koeffizienten auf ihre Güte zu überprüfen. Die Modellgüte kann durch das Bestimmtheitsmaß quantifiziert werden, welches das Quadrat der Abweichung der geschätzten  $\hat{y}$  Zielgröße von der gemittelten Zielgröße  $\bar{y}$  verwendet.

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^n \hat{\varepsilon}_i^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

$R^2$  beschreibt die vom Modell erklärte Streuung und weist wegen der Skalierung mit der Gesamtstreuung einen Wertebereich zwischen 0 und 1 auf. Generell ist zu sagen, dass je größer das Bestimmtheitsmaß ist, desto besser ist die Anpassung durch das Modell. In den Extremfällen  $R^2 = 0$  bzw.  $R^2 = 1$  wird keine bzw. die gesamte Streuung durch das Regressionsmodell erklärt. Für den sinnvollen Vergleich der Modelle mit  $R^2$  müssen folgende Voraussetzungen gelten:

- In allen Modellen wird die gleiche Zielgröße  $y$  verwendet, d.h. der Vergleich von Modellen mit den Zielgrößen  $y$  und  $\log(y)$  ist nicht möglich.
- In allen Modellen ist die Zahl der Regressionskoeffizienten gleich.
- Alle Modelle besitzen eine Konstante  $\beta_0$ .

Bei der Aufnahme einer neuen Kovariablen ins Modell wird das Gütemaß stets größer, ausgenommen die neue Kovariable besitzt keinerlei Korrelation zu der Zielvariablen und den anderen Kovariablen. An dieser Stelle sei auch erwähnt, dass das Bestimmtheitsmaß als quadrierter empirischer Korrelationskoeffizient zwischen den Beobachtungen  $y$  und den Schätzwerten  $\hat{y}$  aufgefasst werden kann. Im Falle der einfachen linearen Regression gilt auch  $R^2 = r_{xy}^2$ . Das korrigierte Bestimmtheitsmaß wird für den Vergleich von Modellen verwendet, die eine unterschiedliche Anzahl von Koeffizienten  $p$  aufweisen und ist definiert durch

$$\bar{R}^2 = 1 - \frac{n-1}{n-p}(1 - R^2). \quad (8)$$

Für die Bewertung der Regressionsmodelle werden auch statistische Tests verwendet, bei denen aufgestellte Hypothesen auf ihre Gültigkeit überprüft werden. Eine Hypothese ist in diesem Fall eine Behauptung über Eigenschaften von Zufallsvariablen. Voraussetzung für die Erstellung von exakten Tests ist die gültige Annahme von normalverteilten Störgrößen, dennoch ist wegen ihrer Robustheit auch eine Anwendung auf Modelle mit näherungsweise normalverteilten Störgrößen möglich.

Für das weitere Verständnis wird hier kurz der Ablauf eines statistischen Tests wiedergegeben. Um einen signifikanten funktionalen Zusammenhang zwischen einer Zielvariablen und ein oder mehreren Kovariablen nachzuweisen, wird folgende Vorgehensweise verwendet.

### 1. Hypothesenbildung

Ausgehend von der Annahme der Existenz eines Zusammenhangs erfolgt die Erstellung zweier Hypothesen. Dabei handelt es sich um die Nullhypothese  $H_0$ , die

## 4 Mathematische Grundlagen

getestet wird, und die Alternativhypothese  $H_A$ , die der Menge der alternativen Annahmen entspricht. Die Nullhypothese lautet

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_n = 0,$$

dadurch ergibt sich für die Alternativhypothese, dass mindestens ein Koeffizient ungleich Null ist.

### 2. Wahl des Signifikanzniveaus

Das Signifikanzniveau  $\alpha$  entspricht der maximal zulässigen Irrtumswahrscheinlichkeit, der Wahrscheinlichkeit, die Nullhypothese zu verwerfen, obwohl diese korrekt ist. Üblicherweise wird eine Irrtumswahrscheinlichkeit von 5% angenommen.

### 3. Wahl der Prüfgröße

Bei der Wahl einer geeigneten Prüfgröße  $T$  ist zu beachten, dass diese einerseits von den gegebenen Hypothesen abhängt und andererseits, dass ihre Verteilung bekannt sein muss. Die Prüfgröße lautet für das Beispiel

$$T = \frac{n-p}{k} \frac{R^2}{1-R^2}, \quad (9)$$

mit der Anzahl der Beobachtungen  $n$ , der Anzahl der geschätzten Koeffizienten  $p$  und der Anzahl der Restriktionen  $k$ . Der Zusammenhang zwischen der Nullhypothese und der Testgröße ist über das bereits besprochene Bestimmtheitsmaß  $R^2$  gegeben, und die Verteilung der Testgröße entspricht der Fisher-Verteilung ( $F$ -Verteilung).

### 4. Festlegung des Ablehnungsbereiches

Der Ablehnungsbereich  $K_\alpha$  und sein Komplement, der Annahmebereich  $\bar{K}_\alpha$ , werden unter Einhaltung des Signifikanzniveaus aus der zu verwendenden Wahrscheinlichkeitsverteilung berechnet. Da die Testgröße eine  $F$ -verteilte Zufallsvariable ist, wird für die Berechnung des Ablehnungsbereiches ebenso die Fisher-Verteilung verwendet. Zusätzlich werden die Freiheitsgrade des Chi-Quadrat-verteilten Bestimmtheitsmaßes und das Signifikanzniveau  $\alpha$  benötigt.

### 5. Testentscheidung

Wenn der geschätzte Wert  $\hat{t}$  der Testgröße  $T$  in den kritischen Bereich  $K_\alpha$  fällt, wird die Nullhypothese abgelehnt und die Alternativhypothese angenommen. Befindet sich der beobachtete Wert im Annahmebereich  $\bar{K}_\alpha$ , wird die Nullhypothese

bestätigt. Bei der Ablehnung der Nullhypothese des Beispiels ergibt sich, dass mindestens eine Kovariable einen signifikanten Einfluss auf die Zielvariable ausübt.

Statistik Software liefert bei der Regressionsanalyse üblicherweise die Testgröße  $T$ , die zwei Bestimmtheitsmaße  $R^2$  und  $\bar{R}^2$  und für jeden Koeffizienten aus der Regression die Prüfgröße  $t$ . Diese Prüfgröße wird aus der Student-t-Verteilung berechnet und beschreibt die Signifikanz der Koeffizienten, wobei ein betragsmäßig geringer Wert dieser Prüfgröße auf einen geringen Einfluss der Kovariablen auf die Zielvariable hinweist. Bei einer Irrtumswahrscheinlichkeit von 5% liegt die Prüfgröße (zweiseitiger Test) bei einem Freiheitsgrad von  $\infty$  von 1,96. Aufgrund des Freiheitsgrades von  $\infty$  entspricht dieser Wert dem der Normalverteilung.

Die Qualität der Koeffizienten einer multiplen linearen Regression wird auch von der Multikollinearität bestimmt. Als Kollinearität wird eine vorhandene Korrelation zweier Kovariablen bezeichnet, bei der Korrelation mehrerer Variablen spricht man von Multikollinearität. Mit zunehmender Korrelation der Kovariablen wird die Schätzung der Regressionsparameter ungenauer, bis eine Berechnung dieser ohne Eingriff unmöglich wird. Weiters wird durch Multikollinearität die Interpretation des Modells erschwert, da bestehende Zusammenhänge nicht mehr eindeutig einer Kovariablen zugeschrieben werden können. Multikollinearität kann durch den Varianzinflationsfaktor  $VIF_j$  bestimmt werden, der bei einem Wert  $> 10$  auf ein Kollinearitätsproblem hinweist.

$$VIF_j = \frac{1}{1 - R_j^2} \quad (10)$$

Formel 10 zeigt den funktionalen Zusammenhang zwischen Bestimmtheitsmaß  $R^2$  und Varianzinflationsfaktor  $VIF$ . Am Index  $j$  ist erkenntbar, dass es sich um den Varianzinflationsfaktor der  $j$ ten Kovariable handelt, welcher vom Bestimmtheitsmaß abhängt. Dieses Bestimmtheitsmaß zeigt den funktionalen Zusammenhang zwischen der  $j$ ten und den andern Kovariablen.

Einer vorhandenen Multikollinearität kann man folgendermaßen begegnen:

- *Weglassen einiger betroffener Kovariablen:* Dieses Vorgehen wird in der Praxis am häufigsten verwendet, obwohl es in der Fachliteratur meist kritisiert wird.
- *Bildung einer gemeinsamen (gut interpretierbaren) Variablen aus den betroffenen Variablen:* Dabei werden betroffene Variablen durch andere ersetzt, die sich aus den originalen berechnen lassen. Neben Linearkombinationen von Variablen werden auch Ratiovariablen wie zum Beispiel die Vegetationsindizes verwendet.

- *Ridge-Regression*: Dieses Verfahren stellt eine Modifikation der Schätzmethode der kleinsten Quadrate dar, welche durch den Tuning Parameter  $\lambda$  und der Einheitsmatrix  $I$  erweitert wird.

$$\hat{\beta} = (X'X + \lambda I)^{-1}X'y \quad (11)$$

- *Hauptkomponententransformation*: Bei diesem Verfahren werden nicht die Kovariablen, sondern geeignete Linearkombinationen dieser für die Regressionsanalyse verwendet. Die Hauptkomponentenanalyse wird in Kapitel 4.2 beschrieben.

#### 4.1.2 Das logistische Regressionsmodell

Wie alle Regressionsmodelle verbindet auch das logistische Modell die Linearkombination der Kovariablen über eine Link-Funktion mit der Zielvariablen. Da das logistische Regressionsmodell eine binäre Zielvariable verwendet, ist eine Modellierung durch eine lineare Funktion ungeeignet. Die Eigenschaft, dass der Erwartungswert  $E(y)$  einer binomial verteilten Zufallsvariablen bei einem Versuch der Wahrscheinlichkeit  $\pi_i$  des Auftretens von  $y_i = 1$  entspricht, führt uns zur Ausgangssituation

$$\pi_i = P(y_i = 1) = F(\eta_i) = F(\beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik}). \quad (12)$$

Bei der Erstellung einer geeigneten Linkfunktion  $F$  für (12), ist zu berücksichtigen, dass der lineare Prediktor  $\eta$ , der im Wertebereich zwischen  $-\infty$  und  $\infty$  definiert ist, auf das Intervall  $[0,1]$  abzubilden ist. Dazu wird zuerst die Wahrscheinlichkeit in eine Chance umgewandelt, welche als Quotient aus Wahrscheinlichkeit und Gegenwahrscheinlichkeit definiert ist. Logarithmiert man anschließend die Chance, erhält man als Ergebnis die Logit-Linkfunktion.

$$g(\pi) = \log\left(\frac{\pi}{1-\pi}\right) = \eta = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k \quad (13)$$

Die inverse der Logit-Linkfunktion  $g$  wird Responsefunktion  $h$  bezeichnet, welche schließlich den Anforderungen entspricht und den linearen Prediktor  $\eta$  auf den Erwartungswert der Zielvariablen abbildet.

$$h(\eta) = \pi = \frac{\exp(\eta)}{1 + \exp(\eta)} \quad (14)$$

Das logistische Regressionsmodell kann so erweitert werden, dass auch Zielvariablen mit mehreren Kategorien geschätzt werden können. Diese erweiterten Modelle werden je nach Ordnungsstruktur der Kategorien der Zielvariablen multinomiale und ordinale Regressionsmodelle bezeichnet. Während beim ordinalen Regressionsmodell die Katego-

rien der Größe nach geordnet werden können, sind die Klassen der Zielvariablen beim multinomialen Regressionsmodell ungeordnet.

Das multinomiale Regressionsmodell modelliert Chancen zwischen den Kategorien  $r = 1, \dots, q$  und der Referenzkategorie  $c$ . Dabei ergibt sich die Wahrscheinlichkeit der Kategorie  $r$  durch

$$\pi_r = \frac{\exp(x' \beta_r)}{1 + \sum_{s=1}^q \exp(x' \beta_s)}, \quad (15)$$

und für die Wahrscheinlichkeit der Referenzkategorie gilt demnach

$$\pi_c = \frac{1}{1 + \sum_{s=1}^q \exp(x' \beta_s)} = 1 - \pi_1 - \dots - \pi_q. \quad (16)$$

Während die Versuche einer binären Zufallsvariablen einer Binomialverteilung unterliegen, weisen die Versuche einer mehrkategorialen Zufallsvariablen eine Multinomialverteilung auf, welche eine Verallgemeinerung der Binomialverteilung darstellt.

### Schätzung der Parameter

Die Schätzung der Parameter geschieht für logistische Regressionsmodelle üblicherweise mit der Maximum Likelihood Methode. Bei dieser Methode werden jene Regressionskoeffizienten  $\beta$  bestimmt, welche die Wahrscheinlichkeit maximieren, bei gegebenen Kovariablen die zugehörigen Realisierungen der Zielvariablen zu erhalten. Die Likelihood  $L(\beta)$  entspricht im Fall des logistischen Regressionsmodells dem Produkt der diskreten Dichten der binären Zielvariablen.

$$L(\beta) = \prod_{i=1}^n L_i(\beta) = \prod_{i=1}^n \pi_i^{y_i} (1 - \pi_i)^{1-y_i} \quad (17)$$

Um eine Maximum Likelihood Schätzung für die Koeffizienten zu erhalten, muss die Likelihood-Funktion nach  $\beta$  abgeleitet werden. Da die Differentierung der logarithmierten Likelihood das gleiche Ergebnis (Maximum) liefert und ihre Ableitung um vieles einfacher ist, wird zuerst die Log-Likelihood  $l(\beta)$  gebildet, die sich aus der Summe der einzelnen Log-Likelihood Beiträge  $l_i(\beta)$  zusammensetzt.

$$l(\beta) = \sum_{i=1}^n l_i(\beta) = \sum_{i=1}^n \{y_i \eta_i - \log(1 + \exp(x'_i))\} \quad (18)$$

Nach der Ableitung der Log-Likelihood nach  $\beta$  erhält man die Score-Funktion, in welcher die Nullstelle einem Maximum der Likelihood  $L(\beta)$  entspricht .



$$s(\hat{\beta}) = \sum_{i=1}^n x_i \left[ y_i - \frac{\exp(x_i' \hat{\beta})}{1 + \exp(x_i' \hat{\beta})} \right] = 0 \quad (19)$$

Da die zu berechnenden Koeffizienten  $\hat{\beta}$  in der Score-Funktion nicht linear enthalten sind, muss dieses Gleichungssystem iterativ gelöst werden. Üblicherweise wird der Fisher-Scoring-Algorithmus zur iterativen Berechnung verwendet, welcher im Buch „Regression“ (Härdle, 2007 [10]) beschrieben ist.

### Modellgüte und statistische Tests

Für die Bestimmung der Güte des Regressionsmodells und einzelner Parameter existieren ebenso wie für lineare Regressionsmodelle qualitätsbezeichnende Koeffizienten und statistische Test. Die Likelihood-Quotienten-Statistik, die Wald-Statistik oder die Score-Statistik werden zum Testen von linearen Hypothesen verwendet. Alle drei Verfahren basieren auf der Likelihood Methode und mit ihnen wird unter anderem der Test auf Signifikanz der zugehörigen Kovariablen durchgeführt. Der bekannteste qualitätsbezeichnende Koeffizient ist das Akaikes Informationskriterium  $AIC$ , welches einen Vergleich von Modellen mit verschiedenen Prediktoren und Parametern ermöglicht.

$$AIC = -2l(\hat{\beta}) + 2p \quad (20)$$

Das  $AIC$  setzt sich aus dem Log-Likelihood Betrag  $l(\hat{\beta})$  des Modells und der Anzahl der geschätzten Parameter  $p$  zusammen. Je geringer dieser Wert ist, desto besser ist das Modell spezifiziert. Zu komplexe Modelle werden beim  $AIC$  mit dem Faktor  $2p$  bestraft.

Das in Kapitel 4.1.1 besprochene Bestimmtheitsmaß  $R^2$  kann für die logistische Regression nicht verwendet werden, da es sich bei der Zielvariablen um eine binäre Variable handelt. Analog zu  $R^2$  wurden jedoch Pseudo-Bestimmtheitsmaße (Pseudo- $R^2$ ) entwickelt, welche die Güte des Regressionsmodells quantifizieren. Das bekannteste und meist verwendete Pseudo-Bestimmtheitsmaß wurde von McFadden veröffentlicht. Dieses Maß lässt sich aus den Log-Likelihood Beträgen des Intercept-Modells (Modell nur mit der Konstanten) und eines alternativen Modells (Modell mit mehrere Kovariablen) bestimmen.

$$McFadden's R^2 = 1 - \frac{-2l(\hat{\beta})}{-2l_0(\hat{\beta})} = 1 - \frac{l(\hat{\beta})}{l_0(\hat{\beta})} \quad (21)$$

Formeln 20 und 21 weisen beide den Ausdruck  $-2l(\hat{\beta})$  auf, welcher bei kleinen Werten für eine gute Anpassung an die Daten spricht. Ist dieser Wert kleiner als der des

Intercept-Modells  $-2l_0(\hat{\beta})$ , ist das Pseudo-Bestimmtheitsmaß größer, was besagt, dass das durch zusätzliche Kovariablen erweiterte Modell eine bessere Anpassung aufweist als das Intercept-Modell. Analog zum Bestimmtheitsmaß finden sich Werte zwischen 0 (kein Zusammenhang) und 1 (perfekter Zusammenhang), wobei der Wert 1 auch bei perfektem Zusammenhang bei diesem Maß nicht erreicht werden kann. Da dieses Maß einer nicht linearen Skala entspricht, zeigen Werte  $> 0,2$  bereits von einer guten Anpassung.

## 4.2 Hauptkomponentenanalyse

Die Hauptkomponentenanalyse (Principal Component Analysis) ist ein Verfahren der multivariaten Statistik und wird verwendet, um Datensätze zu strukturieren und zu vereinfachen. Mit diesem Verfahren werden Variablen eines Datensatzes in einer Linearkombination transformiert. Der neue Datensatz hat die Eigenschaften, dass die Variablen untereinander unkorreliert und nach ihrer Varianz sortiert sind. Auf dieses Verfahren wird auch bei der Regressionsanalyse zurückgegriffen, wenn die Multikollinearität bei der Berechnung zu einem Problem wird.

Obwohl keine Annahmen über die Verteilung der Ausgangsvariablen bestehen, wird für die folgende Interpretation eine multivariate Normalverteilung angenommen. Für die Datengrundlage, bestehend aus einem  $k$ -dimensionalen Zufallsvektor  $Y^t = (Y_1, \dots, Y_k)$  mit dem Erwartungswert  $\mu$  und der Kovarianz  $\Sigma$ , soll durch Hauptkomponentenanalyse ein neuer Variablenvektor  $Z^t = (Z_1, \dots, Z_k)$  gefunden werden. Dabei muss jedes  $Z_j$  als Linearkombination der Ausgangsdaten  $Y$  und eines konstanten Vektors  $a_j^t = (a_{1j}, a_{2j}, \dots, a_{mj})$  darstellbar sein.

$$Z_j = a_{1j}Y_1 + a_{2j}Y_2 + \dots + a_{kj}Y_k = a_j^t Y$$

Für die erste Hauptkomponente  $a_1$  gilt, dass sie die größtmögliche Varianz aufweist und die Nebenbedingung  $a_1^t a_1 = 1$  einhält. Die Gleichung 22 zeigt die zu maximierende Zielfunktion.

$$Var(Z_1) = Var(a_1^t Y) = a_1^t \Sigma a_1 \tag{22}$$

Um die Zielfunktion unter der gleichzeitigen Einhaltung der Nebenbedingung maximieren zu können, muss die Nebenbedingung in die Zielfunktion eingebaut werden. Dies erreicht man mit der Methode der Lagrange Multiplikatoren. Bei dieser Methode wird eine Lagrange-Funktion  $L(y, \lambda)$  gebildet, die aus der zu maximierenden Funktion  $f(y_1, \dots, y_k)$ , dem Lagrange Multiplikator  $\lambda$  und der Nebenbedingung  $g(y_1, \dots, y_k) = c$

#### 4 Mathematische Grundlagen

besteht.

$$L(y, \lambda) = f(y) - \lambda[g(y) - c] \quad (23)$$

Nach dem Einsetzen der Zielfunktion und der Nebenbedingung in die definierte Lagrange-Funktion erhält man für die erste Hauptkomponente die Gleichung

$$L(a_1) = a_1^t \Sigma a_1 - \lambda(a_1^t a_1 - 1). \quad (24)$$

Formel 24 beinhaltet Zielfunktion und Nebenbedingung. Um das Maximum dieser Funktion zu finden, wird sie nach  $a_1$  abgeleitet und danach Null gesetzt.

$$(\Sigma - \lambda I)a_1 = 0. \quad (25)$$

Das obige Gleichungssystem hat genau eine nichttriviale, das heißt vom Nullvektor abweichende Lösung, wenn die Matrix  $(\Sigma - \lambda I)$  singulär ist. Da die Determinante einer singulären Matrix Null ist, ergibt sich Formel:

$$\det(\Sigma - \lambda I) = 0 \quad (26)$$

Bei der Auflösung der Formel 26 nach  $\lambda$  kommt man zum Schluss, dass es nur eine von Null verschiedene Lösung gibt, wenn  $\lambda$  ein Eigenwert der Matrix  $\Sigma$  ist. Die Matrix  $\Sigma$  besitzt mehrere Eigenwerte, von denen der Größte ausgewählt wird. Der Eigenwert  $\lambda_1$  gehört zum Eigenvektor  $a_1$ , welcher der ersten Hauptkomponente entspricht.

Für die Bestimmung der zweiten Hauptkomponente nimmt man an, dass diese orthogonal auf die erste Hauptkomponente steht und in die Richtung der maximalen Varianz zeigt. Für die zweite Hauptkomponente haben wir folglich zusätzlich zur Normierungsbedingung  $a_2^t a_2 = 1$  die Bedingung, dass  $Z_2$  und  $Z_1$  unkorreliert sein sollen.

$$\text{Cov}(Z_2, Z_1) = \text{Cov}(a_2^t Y, a_1^t Y) = E[a_2^t (Y - \mu)(Y - \mu)^t a_1] = a_2^t \Sigma a_1 = a_2^t a_1 = 0 \quad (27)$$

Für die Maximierung der Varianz  $a_2^t \Sigma a_2$  unter den Nebenbedingungen  $a_2^t a_2 = 1$  und  $a_2^t a_1 = 0$ , benötigt man zwei Lagrange-Multiplikatoren  $\lambda$  und  $\delta$ , die man zusammen mit den Nebenbedingungen und der zu maximierenden Funktion zu 28 formt.

$$L(a_2) = a_2^t \Sigma a_2 - \lambda(a_2^t a_2 - 1) - \delta a_2^t a_1 \quad (28)$$

Nach dem Ableiten nach  $a_2$  der vorigen Funktion erhält man die Gleichung 29, der man

den Funktionswert Null zuweist.

$$\frac{\partial L}{\partial a_2} = 2(\Sigma - \lambda I)a_2 - \delta a_1 = 0 \quad (29)$$

Durch eine Multiplikation des Vektors  $a_1^t$  mit der vorigen Formel und dem Einsetzen von  $a_1^t a_2 = 0$  und  $a_1^t a_1 = 1$  erhält man die Gleichung

$$2a_1^t \Sigma a_2 - 2\lambda a_1^t a_2 - \delta a_1^t a_1 = 2a_1^t \Sigma a_2 - \delta = 0.$$

Da aus Gleichung 27 folgt, dass der Term  $a_1^t \Sigma a_2$  wegen der bedingten Unkorreliertheit Null ist, muss auch der Lagrange-Multiplikator  $\delta$  dem Wert Null entsprechen. Setzt man die neu gewonnene Erkenntnis in Formel 29 ein, erhält man

$$(\Sigma - \lambda I)a_2 = 0. \quad (30)$$

Diese Gleichung entspricht, bis auf den Index der Hauptkomponente, der Gleichung 25. Ähnliche Überlegungen wie für die erste Hauptkomponente führen zum Ergebnis, dass die zweite Hauptkomponente einem Eigenvektor der Kovarianzmatrix entspricht. Bei der Bestimmung der weiteren Hauptkomponenten kommt man zum Schluss, dass die j-te Hauptkomponente der Eigenvektor ist, der zum j-ten Eigenwert der Matrix  $\Sigma$  gehört. Gleichung 31 stellt die Beziehung zwischen der Kovarianzmatrix  $\Sigma$ , der Matrix der Eigenwerte  $\Lambda$  und der Matrix der Eigenvektoren  $A$  dar.

$$\Sigma = A\Lambda A^t \quad (31)$$

Da die einzelnen Hauptkomponenten orthogonal zueinander sind, ist auch die resultierende Matrix  $A$ , die sogenannte Ladungsmatrix orthogonal. Die Ladungsmatrix besteht aus den Faktorladungen, die eine Maßgröße für den Zusammenhang zwischen den ursprünglichen Variablen  $Y$  und den transformierten Variablen  $Z$  sind.

### Tasseled Cap Transformation

Die Tasseled Cap Transformation baut auf den Grundlagen der Hauptkomponentenanalyse auf. Bei diesem Verfahren werden die Grauwerte des Bildes, ebenfalls durch eine Linearkombination dieser, in die spektralen Indikatoren Brightness, Greenness und Yellowness oder Wetness transformiert. Die Transformation wurde ursprünglich für Bilder des Satelliten Landsat von Kauth und Thomas (1976 [13]) entwickelt und später von Ivits Wasser (Ivits [11]) für Bilder des Satelliten Spot 5 berechnet. Tabelle 2 zeigt ein Beispiel für Transformationsparameter, welche kombiniert mit den Grauwerten eines

Spot 5 Bildes die jeweiligen Indikatoren ergeben.

Tabelle 2: Tasseled Cap Parameter für Spot 5 Bilder (für Juli)

	GRÜN	ROT	NIR	MIR
Brightness (B)	0,414	0,660	0,319	0,539
Greenness (G)	-0,058	-0,313	0,939	-0,128
Wetness (W)	0,299	0,463	0,059	-0,832

Für die Berechnung der Transformationsparameter werden Referenzgebiete benötigt, welche helle und dunkle Erdböden, lockere und dichte Vegetation und Wasserflächen im Bild repräsentierten. Die Transformationsparameter, mit denen der Brightness Indikator berechnet wird, bilden den Brightness Richtungsvektor, der dem normierten Differenzvektor aus den Grauwertvektoren von dunklen und hellen Erdböden entspricht. Der Greenness Richtungsvektor steht normal auf den Brightness Vektor und zeigt von lockerer nach dichter Vegetation. Der Wetnessvektor erweitert die orthonormale Basis und zeigt in Richtung der spektralen Reflexion von Wasserflächen.

### 4.3 Kreuzvalidierung

Um einen verlässlichen Wert für die Qualität eines statistischen Modells zu bekommen, gibt es verschiedene Verfahren. Meist werden dafür methodenspezifische Kennzahlen benutzt, wie das Bestimmtheitsmaß bei der linearen Regression oder das Akaike Informationskriterium bei der logistischen Regression. Um jedoch unterschiedliche Methoden miteinander vergleichen zu können, wird ein unabhängiges Verfahren benötigt. Die drei bekanntesten sind das Bootstrap, das Jackknife und das Cross-Validation (Kreuzvalidierung) Verfahren. In dieser Arbeit wurde auf die Kreuzvalidierung zurückgegriffen, da diese Methode auch bei einem kleinen Datensatz ein verlässliches Ergebnis liefert. Die Informationen, die hier wiedergegeben werden, stammen aus dem Werk „A Leisurely Look at the Bootstrap, the Jackknife, and Cross-Validation“ (Bradley und Gong, 1983 [4]) und aus verschiedenen Webseiten. Von der Kreuzvalidierung gibt es drei Ausprägungen:

- Einfache Kreuzvalidierung
- Stratifizierte Kreuzvalidierung
- Leave-One-Out-Kreuzvalidierung

Der grundlegende Ablauf aller Ausprägungen besteht darin, dass aus einem bestehenden Sample von  $n$  Einheiten, bestehend aus erklärenden Variablen  $x$  und zu erklärenden Variablen  $y$ ,  $k$  Teilmengen aufbereitet werden. Von diesen  $k$  Teilmengen werden  $k - 1$

ausgewählt, die für die Berechnung des Modells verwendet werden. Die verbleibende Teilmenge der Samples wird verwendet, um die Güte des Modells zu testen. Das geschieht, indem mit den erklärenden Variablen  $x$  ein Resultat  $\hat{y}$  geschätzt wird. Dieser Vorgang wird  $k$ -mal wiederholt, damit jede Teilmenge einmal zur Validierung verwendet wird. Aus den beobachteten  $y$  und den berechneten Variablen  $\hat{y}$  wird folglich der quadratische Mittelwert des Fehlers bestimmt, der besser durch den englischen Namen Root Mean Square Error (RMSE) bekannt ist.

Die Unterschiede der drei Ausprägungen liegt in der Wahl der Teilmengen. Während die einfache Kreuzvalidierung  $k$  Teilmengen bildet, welche aus mehr als einem Datensatz bestehen, gibt man sich bei der Leave-One-Out Kreuzvalidierung mit einem zufrieden. Die stratifizierte Kreuzvalidierung verwendet ebenfalls mehr als einen Datensatz als Teilmenge. Der Unterschied zu der einfachen Kreuzvalidierung liegt darin, dass die Datensätze innerhalb der Teilmengen nicht zufällig gewählt werden. Bei der stratifizierten Kreuzvalidierung wird darauf geachtet, dass jede der  $k$  Teilmengen annähernd eine Gleichverteilung besitzt. Bei zwei Klassen würde jede Teilmenge aus Datensätzen, die zur Hälfte der Klasse  $A$  und zur Hälfte der Klasse  $B$  zugehören, bestehen.

Bei einem kleinen Datensatz ist die Leave-One-Out Kreuzvalidierung den beiden anderen Formen vorzuziehen, da die Bestimmung des Modells mit einem Maximum an Daten erfolgen kann. Da die Aufnahme von Referenzdaten für die unüberwachte Klassifizierung meist sehr zeitintensiv ist und dadurch eine geringere Zahl erfasst wird, ist die Leave-One-Out Kreuzvalidierung für die Methoden der Fernerkundung besonders geeignet. Auch in dieser Arbeit wird diese Ausprägung der Kreuzvalidierung verwendet.

## 5 Datengrundlagen

In diesem Kapitel werden jene Daten besprochen, welche in dieser Arbeit verwendet wurden. Dabei handelt es sich um Luftbilder für die Aufnahme von Trainingsgebieten, hochauflösenden Satellitenbildern für die Klassifizierung der Waldflächen und Laserscannerdaten für eine Simulation des Schattenwurfes von Waldbeständen, wobei diese Simulation nur dem besseren Verständnis der Signaturen im Satellitenbild dient.

Die Beschirmung der Trainingsgebiete kann in Bildern bestimmt werden, in denen einzelne Baumkronen deutlich sichtbar sind. Abhängig von der Größe der Baumkrone schwankt die Anforderung an die geometrische Auflösung der Bilder. Grundsätzlich sind Satellitenbilder mit einer Auflösung von weniger als 2 Metern genauso als Referenzdatensatz geeignet wie Luftbilder. Die Klassifizierung kann einerseits mit Luftbildern, andererseits mit hochauflösenden (von 10 bis 100 m) Fernerkundungsdaten erfolgen. Da die Bestimmung der Beschirmung in Luftbildern sehr aufwändig ist, wird die Klassifizierung üblicherweise mit hochauflösenden Fernerkundungsdaten durchgeführt. Im Gegensatz zu Luftbildern sind in hochauflösenden Satellitenbildern keine einzelne Baumkronen zu erkennen. Ein Bildelement (Pixel) eines Satellitenbildes kann mehrere Baumkronen, den Schatten der Kronen und Boden dazwischen erfassen. Aus der Reflexion dieser Objekte ist der Anteil der Kronenfläche und damit der Überschirmungsgrad zu bestimmen. In den folgenden Abschnitten werden die Satellitensysteme Spot (Satellite Pour l'Observation de la Terre)<sup>1</sup> und IRS (Indian Remote Sensing)<sup>2</sup> beschrieben, von welchen die verwendeten Satellitenbilder stammen.

### 5.1 SPOT

Das Satellitensystem Spot wurde von der französischen Raumfahrtagentur (Centre national d'études spatiales - CNES) in Kooperation mit den Staaten Belgien und Schweden entwickelt. Der erste Satellit Spot 1 wurde am 22. Februar 1986 mit der europäischen Trägerrakete Ariane in seiner 820 km hohen, sonnensynchronen Umlaufbahn platziert. Für eine Umrundung der Erde benötigte der Satellit 101 min und hatte somit eine Wiederholrate von 26 Tagen. Die temporäre Auflösung wurde durch die Schwenkfähigkeit des Satelliten von 27° erhöht. Das Orbitdesign wurde auch für alle weiteren Satelliten des Spot-Programms verwendet, so auch für die Satelliten Spot 2 und Spot 3, welche am 22. Jänner 1990 beziehungsweise am 26. September 1993 ihre Mission starteten. Von den drei Satelliten ist nur noch Spot 2 einsatzfähig und nimmt Bilder von der Erde auf.

---

<sup>1</sup><http://www.spotimage.com>, Stand: 18.11.2010]

<sup>2</sup><http://www.isro.org>, Stand: 18.11.2010]

## 5 Datengrundlagen

In Tabelle 3 sind die sensorspezifischen Parameter der HRV (High Resolution Visible) Sensoren aufgelistet. Jeder der Satelliten wurde beim Start mit zwei dieser Sensoren ausgerüstet, wobei jeder dieser Sensoren in zwei verschiedenen Modi betrieben werden kann.

Tabelle 3: Parameter der Sensoren von Spot 1 bis Spot 3

HRV-Modus	panchromatisch	multispektral		
		rot	grün	nir
geometrische Auflösung [m]	10	20	20	20
spektrale Auflösung [nm]	500-730	500-590	610-680	780-890
radiometrische Auflösung [bits]	8	8	8	8
Schwadbreite [km]	60	60	60	60

### 5.1.1 SPOT 4

Am 24. März 1998 startete der vierte Satellit der Spotreihe seine Mission. Der Satellit ist ausgerüstet mit zwei baugleichen Sensoren, die in 2 verschiedenen Modi betrieben werden können. Diese HRVIR (High Resolution Visible Infra Red) Sensoren (siehe Tabelle 4) zeichnen zusätzlich zum HRV Sensor elektromagnetische Strahlung im mittleren Infrarot auf.

Tabelle 4: Parameter der Sensoren von Spot 4

HRVIR-Modus	panchromatisch	multispektral			
		rot	grün	nir	mir
geometrische Auflösung [m]	10	20	20	20	20
spektrale Auflösung [nm]	610-680	500-590	610-680	780-890	1580-1750
radiometrische Auflösung [bits]	8	8	8	8	8
Schwadbreite [km]	60	60	60	60	60

Weiters trägt der Satellit einen Sensor mit der geringen geometrischen Auflösung von 1 km für umweltbezogene Anwendungen. Dieser Scanner, der als Vegetations Instrument bezeichnet wird, tastet die Erde in vier verschiedenen spektralen Bereichen ab. Bis auf den ersten Kanal gleicht der Sensor den spektralen Spezifikationen des HRVIR Sensors. Der erste Kanal hingegen nimmt Wellenlängen im Bereich von 450-520 nm auf. Bei einer Schwadbreite von 2250 km kann täglich jeder Erdteil vom Satelliten aus aufgenommen werden.

### 5.1.2 SPOT 5

Mit der Ariane-4 Rakete wurde am 4. Mai 2002 der Spot 5 Satellit in seinem Orbit abgesetzt. Wie alle anderen funktionalen Satelliten des französischen Raumfahrtprogramms



## 5 Datengrundlagen

befindet sich auch der Spot 5 Satellit in einer 820 km hohen sonnensynchronen Umlaufbahn. An Bord des fünften Spotsatelliten befinden sich vier verschiedene Sensoren. Der Sensor Vegetation Instrument 2 ist seinem Vorgänger Vegetation Instrument 1, der sich an Bord des Spot 4 Satelliten befindet, nachempfunden, welcher bereits im Kapitel 5.1.1 beschrieben wurde.

Die zwei HRG (High Resolution Geometry) Sensoren ermöglichen eine Aufnahme von hochauflösenden multispektralen und sehr hochauflösenden panchromatischen Bildern. Die Sensoren sind zum Nadir leicht geneigt angebracht. Während der multispektrale Sensor gegen die Flugrichtung ausgerichtet ist, sind die monochromatischen Sensoren in Flugrichtung geneigt. Da die monochromatischen Sensoren durch ihre unterschiedliche Ausrichtung untereinander nur leicht versetzte Bilder der Erdoberfläche aufnehmen, ist es möglich, eine Fusionierung dieser Bilder zu rechnen. Ein Versatz der Bilder von 3,5 Pixel in Flugrichtung und 0,5 Pixel normal dazu ermöglicht eine Verbesserung der geometrischen Auflösung von 5 m auf 2,5 m. Weitere Kennwerte der HRG Sensoren sind der Tabelle 5 zu entnehmen.

Tabelle 5: Parameter der Sensoren von Spot 5

<b>HRG-Modus</b>	<b>panchromatisch</b>	<b>multispektral</b>			
		rot	grün	nir	mir
geometrische Auflösung [m]	5	10	10	10	10
spektrale Auflösung [nm]	480-710	500-590	610-680	780-890	1580-1750
radiometrische Auflösung [bits]	8	8	8	8	8
Schwadbreite [km]	60	60	60	60	60

Der Spot 5 Satellit trägt im Gegensatz zu seinen Vorgängern einen eigenen Sensor für Stereoaufnahmen an Bord. Dieser HRS (High Resolution Stereo) Sensor erzeugt panchromatische Aufnahmen (490-690 nm) in zwei unterschiedlichen Richtungen mit einer geometrischen Auflösung von 10 m. Die Teleskope des Sensors sind vom Nadir aus gesehen 20° in und gegen die Flugrichtung des Satelliten geneigt. Da eine gleichzeitige Aufnahme in beide Richtungen nicht möglich ist, können nur Stereoszenen mit einer maximalen Abmessung von 600\*120 km erzeugt werden.

### 5.2 IRS

Die indische Raumfahrtbehörde ISRO (Indian Space Research Organisation) leitet das Satellitenprogramm IRS (Indian Remote Sensing). Das Ziel dieses Programms ist die bildhafte Erkundung der Erde für die unterschiedlichsten Anwendungen. Der erste Satellit des Programms mit dem Namen IRS 1A wurde am 17. März 1988 in seine Umlaufbahn geschickt. Ihm folgte IRS 1B, der am 29. August 1991 gestartet wurde. Beide Satelliten

## 5 Datengrundlagen

befanden sich in einem 905 km hohen sonnensynchronen Orbit. Während IRS 1A 1992 seine Mission beenden musste, konnte IRS 1B seine Mission bis 1999 fortsetzen. Jeder der baugleichen Satelliten trug drei Sensoren an Bord, LISS-I, LISS-IIA und LISS-IIB. Diese LISS Sensoren besitzen 2048 linear angeordnete CCD-Detektoren, die Strahlung im Bereich von 450-520 nm, 520-590 nm, 620-680 nm und 770-860 nm aufnehmen. Die geometrische Auflösung wird durch Höhe und Brennweite der Sensoren bestimmt. Während der Sensor LISS-I eine Auflösung von 72,5 m bei einer Schwadbreite von 148 km lieferte, konnte bei den beiden anderen Sensoren eine geometrische Auflösung von 36,25 m erreicht werden. Die LISS-II Sensoren nahmen nebeneinander liegende Landstreifen auf, wobei ein 3 km breiter Streifen von beiden Sensoren abgedeckt wurde. Im Jahr 1993 sollte mit IRS 1E (IRS P1) ein weiterer, etwas modifizierter Satellit das IRS Programm erweitern, dieser Satellit konnte jedoch nicht in seiner Umlaufbahn platziert werden.

Am 15. Oktober 1994 beförderte erstmals eine indische Trägerrakete mit PSLV-D2 erfolgreich einen Satelliten in seinen Orbit. Zuvor mussten die indischen Trabanten mit ausländischen Raketen in ihre Umlaufbahn geschickt werden. Die Rakete PSLV-D2 platzierte den Satellit IRS P2 in eine 820 km hohe sonnensynchrone Umlaufbahn. Die geringere Höhe der Umlaufbahn führte zu einer höheren geometrischen Auflösung bei gleicher Sensorarchitektur. Um den Satellit IRS 1C am 28. Dezember 1995 in die richtige Umlaufbahn zu bringen, musste ein weiteres Mal eine russische Trägerrakete verwendet werden. Bei gleicher Umlaufbahn und mit verbesserten Sensoren lieferte IRS 1C höher aufgelöste Bilder als IRS P2. An Bord des Trabanten befanden sich ein panchromatischer Sensor und zwei multispektrale Sensoren LISS-III und WiFS. Die geometrische Auflösung des panchromatischen Sensors liegt bei 5,8 m und nimmt elektromagnetische Wellen im Bereich von 500-750 nm auf. Der LISS-III Sensor ist im grünen (520-590 nm), roten (620-680 nm), nahen infraroten (770-860 nm) und mittleren infraroten (1550-1700 nm) Spektralbereich wirksam. Die geometrische Auflösung liegt bei den ersten drei Kanälen bei 23,5 m und bei dem mittleren Infrarotkanal bei 70 m. Mit dem WiFS Sensor, der spektral die Kanäle Rot und Infrarot abdeckt, konnten bei einer Auflösung von 188 m Schwadbreiten von 810 km abgedeckt werden. Die Bilddaten werden vom Satelliten aus an drei Bodenstationen gesendet. Wenn Bilder außerhalb der Reichweite von Shadnagar (Indien), Norman (Oakland) und Neustrelitz (Deutschland) aufgenommen werden, können diese Daten, auf einem Speichermedium, das sich im Satelliten befindet, zwischengespeichert werden. Um die Datenmenge und die temporäre Auflösung zu erhöhen, wurde der baugleiche Satellit IRS 1D mit einer indischen Trägerrakete am 29. September

1997 in seinen leicht elliptischen Orbit entsendet.

Am 27. Mai 1999 wurde IRS P4 (Oceansat 1) in seinen Orbit geschickt. Die sonnensynchrone Umlaufbahn von Oceansat liegt in 720 km Höhe. Wie schon der Name verrät, wurde dieser Satellit speziell für die Meereserkundung ausgerüstet. Mit dem Start des Satelliten TES (Technology Experiment Satellite) am 22. Oktober 2001 sollten neue Technologien für zukünftige Satelliten getestet werden. Nähere Informationen zu Oceansat, TES und den anderen Satelliten finden sie auf der Internetseite der indischen Raumfahrtbehörde ISRO<sup>1</sup>.

Der Satellit IRS P5 kreist seit dem 5. Mai 2005 in einer 620 km hohen sonnensynchronen Bahn um die Erde und liefert mit seinen beiden panchromatischen Sensoren Bilder mit einer geometrischen Auflösung von 2,5 m. Während der eine Sensor mit einem Winkel von 26° vom Nadir aus in Flugrichtung zeigt, zeigt der andere Sensor mit 6° gegen die Flugrichtung. Die Ausrichtung der Sensoren ermöglicht stereoskopische Aufnahmen der Erdoberfläche. Cartosat 2 folgte Cartosat 1 am 10. Jänner 2007 in den Weltraum. Im Gegensatz zu seinem Vorgängermodell trägt Cartosat 2 nur einen panchromatischen Sensor. Er liefert Bilder von 1 m geometrischer Auflösung im Spektralbereich von 500-850 nm. Am 28. April 2008 wurden gleichzeitig mehrere Satelliten mit der Trägerrakete PSLV-C9 (Polar Satellite Launch Vehicle) gestartet. Neben den indischen Trabanten Cartosat 2A und IMS 1 war die Trägerrakete Beförderungsmittel für 8 Nanosatelliten. Cartosat 2A weist zu seinem Vorgänger Cartosat 2 keine großen Veränderungen auf, und befindet sich genauso wie dieser in einer 630 km hohen sonnensynchronen Bahn. Der Satellit ist Träger der zwei optischen Sensoren Mx (Multi-spectral camera) und HySI (Hyper-Spectral Imager). Beide Sensoren sind im roten und nahen infraroten Spektralbereich aufnahmefähig. Die Mx Kamera liefert in vier Kanälen Bilder mit einer geometrischen Auflösung von 37 m. Die hyperspektrale Kamera HySI produziert Bilder mit einer Auflösung von 506 m in 64 verschiedenen Spektralbereichen.

### 5.2.1 IRS P6 (Resourcesat)

Der Satellit IRS P6 wurde am 17. Oktober 2003 mit der indischen Trägerrakete PSLV-C5 in seiner Umlaufbahn platziert. Bei der Umlaufbahn handelt es sich um einen 820 km hohen, polaren sonnensynchronen Orbit mit einer Inklination von 98,76° zum Äquator. Bei einer Umlaufzeit von 101,35 min ergibt sich eine Wiederholrate von 24 Tagen. Der Satellit trägt 3 verschiedenen Sensoren an Bord, zwei LISS (Linear Imaging Self Scanner)

---

<sup>1</sup><http://www.isro.org>, Stand: 18.11.2010]

Sensoren und einen AWiFS (Advanced Wide Field Sensor). Die Scanner unterscheiden sich hauptsächlich von der geometrischen Auflösung der erzeugten Bilder. In Tabelle 6 sind die Kennzahlen der unterschiedlichen Sensoren aufgelistet.

Tabelle 6: Parameter der Sensoren von IRS P6

<b>SENSOR:</b>	<b>LISS-IV</b>	<b>LISS-III</b>	<b>AWiFS</b>
geometrische Auflösung [m]	5.8	23.5	56
spektrale Auflösung [nm]	520-590	520-590	520-590
	620-680	620-680	620-680
	770-860	770-860	770-860
		1550-1700	1550-1700
radiometrische Auflösung [bits]	7	7	10
Schwadbreite [km]	23,9 MX Modus	141	740
	70,3 PAN Modus		

### 5.3 Die Untersuchungsgebiete und die verwendeten Bilddaten

Die Definition des Untersuchungsgebietes spielt insofern eine Rolle, da standortspezifische Gegebenheiten die Reflexion von Waldbeständen beeinflussen. Zum Beispiel gestaltet sich die Klassifizierung von Waldbeständen eines geneigten Geländes schwieriger als von Beständen in der Ebene, da topographische Effekte die Rückstrahlung maskieren. Neben den topographischen Effekten ist auch die Baumartenzusammensetzung von der Wahl des Untersuchungsgebietes abhängig. Schlussendlich wurden aufgrund der Datenlage zwei Untersuchungsgebiete bestimmt.

#### 5.3.1 Untersuchungsgebiet Obwalden

Das erste Untersuchungsgebiet liegt in Obwalden in der Zentralschweiz in montaner (800-1500 m) bis subalpiner (1500-2500 m) Höhe. Für dieses Gebiet sind ein Geländemodell und ein Oberflächenmodell im Rasterformat vorhanden, welche beide vom Joanneum Research zur Verfügung gestellt wurden. Das Oberflächenmodell wurde aus Laserscannerdaten erstellt, die aus dem Winter 2007 stammen. Aufgrund der fehlenden Metadaten können keine Angaben zur Genauigkeit der Modelle gegeben werden. Die ursprüngliche geometrische Auflösung des Oberflächenmodells entspricht 0,5 m in der horizontalen Richtung, gegeben durch die Rasterweite und 1 cm in vertikaler Richtung dargestellt durch den Grauwert. Das Geländemodell, das ebenfalls aus Laserscannerdaten abgeleitet wurde, ist in der vertikalen Richtung genauso hoch aufgelöst, jedoch ist die horizontale Auflösung des Modells mit 2 m geringer als jenes des Oberflächenmodells. Beide Modelle wurden im Vorfeld der Auswertungen auf eine geometrische Auflösung

von 0,5 m in horizontaler Richtung und 1 dm in vertikaler Richtung gebracht. Die Auflösung von 1 dm in vertikaler Richtung wurde gewählt, um die Form der Baumkronen zu erhalten, obwohl die erzielbare Genauigkeit von Laserscannerdaten im ebenen Gelände bei  $\pm 1$  dm liegt und davon ausgegangen werden kann, dass diese Genauigkeit im Wald nicht erreicht wird. Mit diesem Oberflächenmodell aus Obwalden wurden einerseits eine Simulation zur Bestimmung der Rasterweite und andererseits eine Simulation zur Bestimmung des Schattenwurfes von Waldbeständen durchgeführt.

### 5.3.2 Untersuchungsgebiet Niedere Tauern

Das zweite Untersuchungsgebiet liegt in den Niederen Tauern, die sich über die österreichischen Bundesländer Salzburg und Steiermark erstrecken. Für dieses Gebiet liegen ein digitales Geländemodell, Infrarotluftbilder und Satellitenbilder aus dem Image 2006 Datensatz vor. Die Daten wurden vom Joanneum Research im Rahmen des Projektes Geoland 2 zur Verfügung gestellt.

Das digitale Geländemodell, das vom BEV (Bundesamt für Eich und Vermessungswesen)<sup>1</sup> stammt, weist eine Rasterweite von 25 m auf. Die Höhengenaugkeit des digitalen Geländemodells entspricht für Siedlungsgebiete, Agrarflächen, versiegelte Flächen und Gewässer  $\pm 1$  bis  $\pm 5$  m, für Ödland und Gletscher  $\pm 5$  bis  $\pm 10$  m und  $\pm 10$  bis  $\pm 25$  m für Wald und Hochgebirge.

Die Farbinfrarotluftbilder wurden am 28. August 2004 von der Firma Arge Digitalplan<sup>2</sup> aufgenommen. Für die geometrische Entzerrung wurden Passpunkte herangezogen, die vor der Befliegung mittels Tafeln signalisiert wurden. Die Lagegenauigkeit, die durch Kontrollpunkte verifiziert wurde, ergab eine Standardabweichung von 0,15 m in X-Richtung und 0,17 m in Y-Richtung. Die Standardabweichung der Kontrollpunkte in der Höhe betrug 0,16 m.

Der Image 2006 Datensatz wird von der ESA für die wissenschaftliche Verwendung im Rahmen von GMES (Global Monitoring for Environment and Security) zur Verfügung gestellt. Die Szenen des Datensatzes sind bereits vom Deutschen Zentrum für Luft- und Raumfahrt und der Euromap Gesellschaft radiometrisch und geometrisch vorverarbeitet worden und werden im Prozessierungslevel-2A angeboten. Bei diesem Prozessierungsgrad sind radiometrische Störungen wie Unregelmäßigkeiten im Bild aufgrund inhomogener Detektorempfindlichkeit bereits korrigiert. Weiters sind die Satellitenbilder orthorektifiziert, wobei abhängig vom Sensor zwei verschiedene Methoden verwendet wurden.

<sup>1</sup><http://www.bev.gv.at>, Stand: 18.11.2010]

<sup>2</sup><http://www.adp.co.at>, Stand: 18.11.2010]

- Für die Bilder der Spot-Satelliten wurde die Methode der direkten Georeferenzierung verwendet. Diese Methode basiert auf einem Line-of-Sight Modell, welches die einzelnen Bildpunkte kollinear auf die Erdoberfläche projiziert und dort mit einem Höhenmodell schneidet. Die erzeugten 3D Punkte werden darauf mit einer geeigneten Transformation in ihre Zielabbildung gebracht. Die benötigte Satellitenposition wird durch verschiedene Messsysteme bestimmt. Zum Einsatz kommen vor allem Sternensensoren, Inertiale Navigationssysteme, GPS und DORIS (Doppler Orbitography and Radiopositioning Integrated by Satellite). Weiters werden Passpunkte herangezogen, um die Genauigkeit der Position und der Scannerausrichtung der Satelliten zum Aufnahmezeitpunkt zu erhöhen.
- Für die Verortung der Bilder des IRS-P6 Satelliten wird ein Modell verwendet, das die einzelnen Bildpunkte über rationale polynomiale Funktionen mit der Abbildung auf der Erdoberfläche in Verbindung bringt. Die so erreichte geringe Genauigkeit der Georeferenzierung wird durch eine anschließende affine Transformation über Passpunkte verbessert.

Die für den Aufbau des Image 2006 Datensatzes verwendeten Methoden und Ergebnisse können im Bericht „IMAGE2006 European Coverage, Methodology and Results“ (Müller u.a., 2009 [16]) nachgelesen werden, in dem auch Tabelle 7 zu finden ist, welche die Genauigkeit der Orthorektifizierung der Satellitenbilder angibt.

Tabelle 7: Geometrische Genauigkeit des Image 2006 Datensatzes

Satellit	Coverage	Scenen [n]	RMSE <sub>x</sub> [m]	RMSE <sub>y</sub> [m]	RMSE <sub>xy</sub> [m]	ICPs [n]
SPOT 4 & 5	Coverage 1	20	12,16	9,98	15,73	3585
SPOT 4 & 5	Coverage 2	15	11,29	9,45	14,72	8085
IRS P6	Coverage 1	12	10,35	9,1	13,78	22234
IRS P6	Coverage 2	15	10,53	8,84	13,75	14051

Neben den Genauigkeitsangaben den RMSE (Root Mean Squared Error) sind aus der Tabelle noch die Gruppenzugehörigkeit (Coverage), die Anzahl der Szenen und die Anzahl der verwendeten unabhängigen Kontrollpunkte (ICPs) zu entnehmen. Die Gruppenzugehörigkeit weist auf den Aufnahmezeitpunkt der Satellitenszene hin, während Bilder der Gruppe Coverage 1 in der Vegetationsperiode aufgenommen wurden, stammen Coverage 2 Bilder vornehmlich aus der Zeit vom Herbst bis Frühling. Aus dem Coverage 1 Datensatz wurden drei Satellitenbilder verwendet:

1. IRS P6 Satellitenbild vom 23.06.05

## *5 Datengrundlagen*

2. IRS P6 Satellitenbild vom 17.07.06
3. Spot 4 Satellitenbild vom 12.09.06

Mit den Satellitenbildern der Niederen Tauern wurden alle Analysen und Klassifizierungen von verschieden beschirmtten Waldbeständen durchgeführt.

## 6 Datenaufbereitung

Mit diesem Kapitel beginnt der praktische Teil dieser Arbeit, der die Vorverarbeitung der Satellitenbilder, die Aufnahme und die Beschreibung der Referenzgebiete enthält. Für die Aufnahme und Bearbeitung der Daten wurden die Softwarepakete Erdas Imagine, Arc Info, Matlab und Impact verwendet. Impact (Image Processing And Classification Toolkit), die einzige Software, die nicht kommerziell erhältlich ist, wurde am Joanneum Research für Anwendungen der Fernerkundung entwickelt. Mit dieser Software wurde die topographische Normalisierung der Satellitenbilder (siehe. 6.1.1) durchgeführt.

### 6.1 Vorverarbeitung der Satellitendaten

Die Satellitenbilder, die bereits zum Teil vorverarbeitet waren, wurden im Datum des Militärgeographischen Instituts (MGI) und in der Lambertprojektion bezogen. Die geometrische Genauigkeit der Bilder (vgl. Tabelle 7) war im Bereich des Untersuchungsgebietes Niedere Tauern zufriedenstellend. Auch die Radiometrie wies keine ersichtlichen Mängel auf, lediglich von der Topographie verursachte radiometrische Unterschiede waren zu erkennen.

#### 6.1.1 Topographische Normalisierung

Aufgrund der topographischen Situation in den Untersuchungsgebieten ist eine Korrektur des reflektierten Signals notwendig. Abhängig von der Neigung des Geländes zur Sonneneinstrahlung gibt es Reflexionsunterschiede. Dabei besitzen zur Sonne geneigte Flächen eine höhere Reflexion als die von der Sonne abgeneigten Flächen. Um diesen vom Einstrahlwinkel hervorgerufenen Unterschied nicht in die Klassifikation einfließen zu lassen, müssen die Satellitenbilder vorher topographisch normalisiert werden.

Für die topographische Normalisierung wurden bereits mehrere Verfahren entwickelt, darunter auch die Minnaert Korrektur (Minnaert 1941, [14]). Diese Methode verwendet die Hangneigung ( $e$ ), den lokalen Einstrahlungswinkel ( $i$ ) und den Grauwert des unkorrigierten Bildes ( $L$ ) für die Berechnung des normalisierten Reflexionswertes ( $L_n$ ).

$$L_n = L \cdot \left( \frac{\cos(e)}{\cos(i)} \right)^k \quad (32)$$

In Formel 32 ist abgesehen vom normalisierten Reflexionswert ( $L_n$ ) auch die Minnaert Konstante  $k$  unbekannt. Sie beschreibt, inwieweit eine Oberfläche von den Lambertschen Reflexionsverhältnissen (diffusen Reflexion) abweicht. Die Werte  $k$  befinden sich im Bereich zwischen 0 und 1, wobei der Wert 1 einer diffusen Reflexion entspricht. Die Minnaert



Konstanten werden für die verschiedenen Oberflächen (Landbedeckungen) durch lineare Regression zwischen den Reflexionswerten der Satellitenszene und den entsprechenden lokalen Einfallswinkeln berechnet. Der Nachteil dieser Methode ist, dass im Vorhinein bekannt sein muss, um welche Landbedeckung es sich handelt, darum wird in der Praxis meist von nur einer Landbedeckungsklasse ausgegangen.

Gallaun [8] modifizierte die Methode, indem er iterativ die Landbedeckung, die Minnaert Konstante und das korrigierte Bild bestimmte. Der erste Schritt des Verfahrens besteht aus einer unüberwachten Klassifizierung des zu kalibrierenden Bildes, was einer automatisierten Zuordnung von Pixel zu Klassen entspricht. Für diese erste Klassifizierung werden anstatt Originalkanäle, Ratiokanäle herangezogen, da diese eine geringere Abhängigkeit der Beleuchtung von der Topographie zeigen. Für die resultierenden Klassen und die verschiedenen spektralen Kanäle werden anschließend die Minnaert Konstanten bestimmt. Mit den Konstanten, den Grauwerten und den Winkeln wird ein erstes korrigiertes Bild gerechnet, welches die Grundlage für eine weitere unüberwachte Klassifizierung ist. Nun werden die Schritte Klassifizierung, Bestimmung der Konstanten und Normalisierung des Bildes wiederholt durchgeführt. Das Ergebnis des iterativen Prozesses ist das topographisch normalisierte Bild.

Die Software IMPACT beinhaltet neben der originalen Minnaert Korrektur auch die von Gallaun modifizierte, welche für die topographische Normalisierung der Satellitenbilder verwendet wurde.

### 6.2 Aufnahme der Trainingsgebiete

Die Aufnahme der Referenzgebiete erfolgte mit dem Punktrasteransatz, da sich bei dieser Methode die erzielbare Genauigkeit der Auswertung und der Arbeitsaufwand die Waage halten. Bei diesem Ansatz wird im Bild ein regelmäßiger Punktraster über das Referenzgebiet gelegt und bestimmt, ob sich der Einzelpunkt auf einer Baumkrone oder am Boden befindet. Die Beschirmung eines Bestandes ergibt sich aus dem Verhältnis der Kronenpunkte zur Gesamtpunktzahl in der Referenzfläche.

#### 6.2.1 Bestimmung der Rasterweite

Vor der Erstellung der Raster war es notwendig, einen geeigneten Abstand zwischen den einzelnen Punkten zu wählen. Da dazu keine Angaben in der Literatur zu finden waren, wurden Raster mit unterschiedlichen Samplingweiten erzeugt und deren Auswertung einander gegenüber gestellt. Für den Vergleich der Raster wurde aus dem Oberflächenmodell aus Obwalden eine Baumkronenkarte erstellt. Dabei wurden die pixelweisen Höhen des

Oberflächenmodells über einen Schwellwert den Klassen Boden und Baumkrone zugeordnet. Pixel, die Höhen  $\geq 5$  m entsprechen, wurden der Klasse Baumkrone zugewiesen und Pixel, die eine Höhe unter 5 m repräsentieren, wurden der Klasse Boden zugeordnet. Die Baumkronenkarte wurde danach in 96 quadratische 1 ha große Bestandesflächen aufgeteilt, für welche jeweils die Referenzbeschilderung berechnet wurde. Innerhalb einer Bestandesfläche entspricht die Referenzbeschilderung dem Quotienten aus Baumkronenpixel und Gesamtpixel. Für alle quadratischen Bestandesflächen wurden darauf die Raster mit unterschiedlichen Punktabständen erzeugt, wobei der geringste Abstand der doppelten geometrischen Auflösung der Baumkronenkarte entsprach, welche eine Auflösung von 0,5 m aufwies. Nach der Zuweisung der Punkte zu den Klassen konnte für jede Waldfläche für die verschiedenen Raster mit deren Kronenpunkten und Bodenpunkten die Überschirmung bestimmt werden. Aus den unterschiedlichen Ergebnissen pro Bestandesfläche wurde die Varianz und die Standardabweichung der Überschirmungsgrade berechnet.

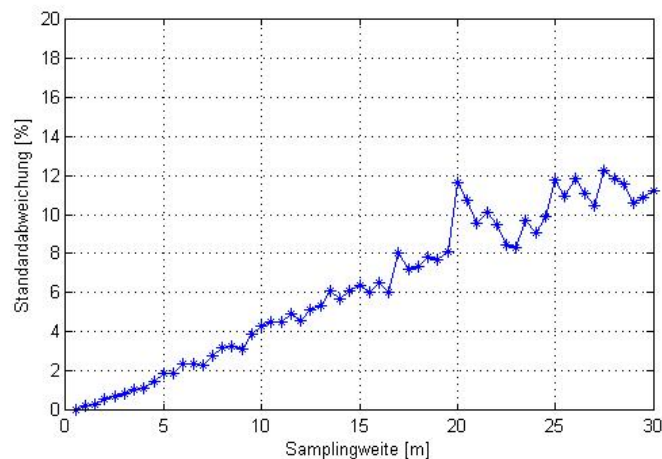


Abbildung 7: Vergleich der Raster mit unterschiedlichen Samplingweiten

Bei dieser Simulation hat sich gezeigt, dass mit zunehmender Distanz zwischen den Rasterpunkten auch die Abweichung zum Referenzwert steigt. Bei einer Samplingweite von 5 m erhält man eine Abweichung von 2% und bei 10 m von 4%. Aufgrund der Resultate der Simulation wurden für die spätere Aufnahme der Referenzgebiete Raster mit einer Samplingweite von 4 m verwendet, da eine Auswertung mit dieser Rasterweite zu einer hohen Genauigkeit führt und sich der Arbeitsaufwand in Grenzen hält. Diese Samplingweite ist für eine praktische Anwendung nicht zu empfehlen, da durch die anderen Fehlerquellen diese hohe Genauigkeit nicht gehalten werden kann und der Aufwand zu

groß wäre.

### 6.2.2 Mögliche Fehlerquellen bei der Aufnahme der Beschirmung

Bei der visuellen Auswertung von Bilddaten treten vom Anwender verursachte Fehlinterpretationen auf, welche minimiert werden können, wenn die Fehlerquellen bekannt sind. Im Sinne der Bestimmung des Überschirmungsgrades erhält man eine größere Differenz zum Referenzwert, wenn man die Messung nicht im Zenit durchführt. In diesem Fall wird der Schlussgrad meist überschätzt, weil bestehende Bestandeslücken durch die schräg abgebildeten Kronen verdeckt werden. Eine Unterschätzung des Schlussgrades erhält man, wenn man den beschatteten Anteil der Krone nicht als diesen erkennt und als Boden klassifiziert. Dabei ist bei einem niedrigen Sonnenstand durch die starke Beschattung der Krone mit einem größeren Fehler zu rechnen als bei einem hohen Sonnenstand. Bei der Auswahl der Referenzgebiete wurde darauf geachtet, dass nur Bestandesflächen in der Mitte des Bildes verwendet wurden und beschattete Kronenteile bei der Attributierung berücksichtigt wurden.

### 6.3 Beschreibung der Trainingsgebiete

Für diese Arbeit wurden über 200 Trainingsgebiete (Referenzgebiete) ausgewählt, welche die vorkommenden Waldtypen im Bereich der Niederen Tauern so gut wie möglich abdecken. Unter den Trainingsgebieten finden sich folgende Straten von Bestandesformen:

- Nadelholz im Alter von Jungwuchs bis Stangenholz (0-60 Jahre)
- Nadelholz im Alter von Baumholz bis Altholz (60-100 Jahre)
- Mischwald im Alter von Baumholz bis Altholz (60-100 Jahre)
- Kahlschlagflächen
- Latschenwald
- Grünerlenwald

Aufgrund der flächenhaften Verteilung der Waldtypen sind in dieser Arbeit die Beschirmungsgrade von Nadelholzbeständen im Alter von Baumholz bis Altholz von besonderem Interesse und werden deshalb vornehmlich für Analysen verwendet. Die Nadelholzbestände sind durch 93 Gebiete vertreten und werden hauptsächlich aus den Baumarten Fichte, Lärche und zu geringem Teil auch aus der Zirbe gebildet. Die Verteilung der Beschirmungsgrade innerhalb dieser Gebiete ist in Abbildung 8 veranschaulicht.




Abbildung 8: Verteilung der Überschirmungsgrade innerhalb alter Nadelholzbestände

Die Schlussgrade, die mit der im Kapitel beschriebenen Methode ermittelt wurden, sind in 10 Klassen zu 10%-Stufen eingeteilt und in Abbildung 8 dargestellt. Die Anzahl der Bestände der Klassen ähneln einer Gleichverteilung. Lediglich die Klasse von 0 bis 10% zeigt eine große Abweichung von der mittleren Anzahl der Trainingsgebiete, welche durch die rote Linie gekennzeichnet ist. Eine Gleichverteilung kommt in der Natur kaum vor, da Pflanzenbestände bemüht sind, den gesamten Kronenraum auszunutzen und deshalb mehr höher beschirmte Bestände vorkommen.

Die Nadelholzbestände der Trainingsgebiete befinden sich in eine Höhe von 1.000 bis 1.900 m, wobei ein Großteil der lockeren Bestände in den höheren Lagen liegen. Aufgrund der schlechter werdenden Wuchsbedingungen mit zunehmender Höhe und der einhergehenden Abnahme der Anzahl der Bäume werden geschlossene Bestände immer seltener. Der Einfluss der höhenabhängigen Reflexionsunterschiede wird in dieser Arbeit jedoch vernachlässigt, weshalb die ungleichmäßige Verteilung der Höhen nicht beachtet wird. Unterschiede der Rückstrahlung, die aufgrund des Geländeneigung entstehen, wurden bereits durch die topograpische Normalisierung reduziert.

## 7 Datenanalyse


In diesem Kapitel soll geklärt werden, ob und welche Zusammenhänge zwischen der Reflexion und verschiedenen beschirmten Beständen bestehen. Für die Bestimmung des Zusammenhanges werden Signaturanalyse und Regressionsanalyse verwendet. Zusätzlich wird eine Schattensimulation verwendet, um den Zusammenhang zwischen Reflexion und Überschirmungsgrad zu erklären.

### 7.1 Signaturanalyse


Um den Beschirmungsgrad getrennt von den anderen reflexionswirksamen Bestandesattributen zu betrachten, wird die Signaturanalyse mit dem Stratum Nadelholz im Alter von Baumholz bis Altholz durchgeführt, jenem Stratum mit den meisten Trainingsgebieten. Die Beschirmungsgrade der Bestände, gegeben als georeferenzierte Polygone, wurden den Grauwerten dreier Satellitenbilder gegenübergestellt. Die Darstellung erfolgt mit Diagrammen, bei denen für jedes Trainingsgebiet auf der X-Achse der Überschirmungsgrad und auf der Y-Achse der mittlere Grauwert des jeweiligen spektralen Kanals aufgetragen ist. Für eine einheitliche Darstellung wurde für jeden Kanal individuell ein konstanter Wert addiert.

#### 7.1.1 IRS P6 Satellitenbild vom 17.07.06


Zum Zeitpunkt der Aufnahme des Bildes wies die Sonne für das Bildzentrum ein Azimuth von  $150,10^\circ$  und einen Höhenwinkel von  $61,05^\circ$  auf. Da die Szene im Untersuchungsgebiet ohne Wolken ist, konnten alle 93 Trainingsgebiete für die Signaturanalyse verwendet werden.



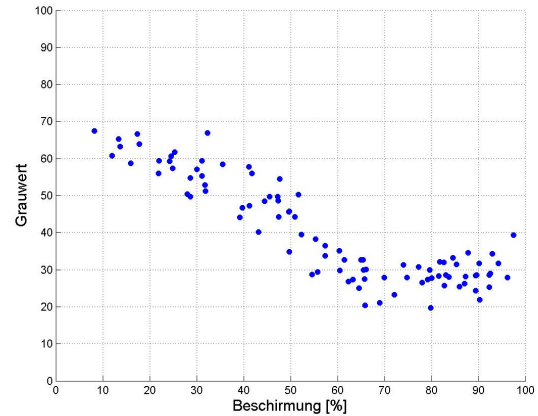
(a) Grüner Kanal



(b) Roter Kanal



(c) Naher Infraroter Kanal



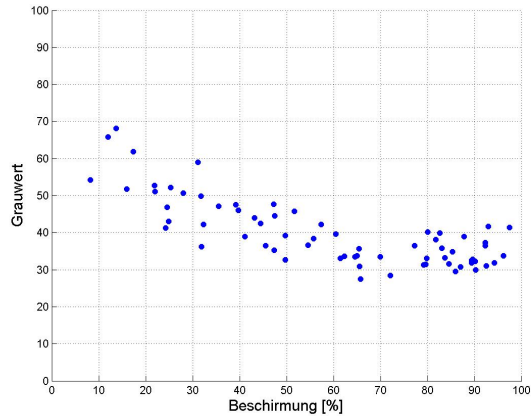
(d) Mittlerer Infraroter Kanal

Abbildung 9: Streudiagramme von Beschirmungsgrad und Grauwerte der unterschiedlichen Kanäle des IRS Satellitenbildes vom 17.07.06


Die geringste Variation der Grauwerte tritt im roten Kanal auf, bei diesem sind kaum Zusammenhänge zwischen Grauwert und der Beschirmung zu finden. Hingegen sind bei den Kanälen des grünen, des nahen infraroten (NIR) und des mittleren infraroten (MIR) Spektralbereichs starke Abhängigkeiten zu erkennen. Die größte Sensitivität weist der 3. Kanal des IRS Satellitenbildes auf, bei dem der gleiche charakteristische Verlauf zu erkennen ist, den auch das bereits gezeigte Diagramm 3 (vgl. Schardt, 1997 [18]) zeigt. Dieser Verlauf ist gekennzeichnet durch eine Abnahme der Grauwerte bei zunehmendem Überschirmungsgrad bis etwa 65% und mit einem darauffolgenden Ansteigen der Grauwerte bis zu einem Schlussgrad von 100%. Auch im 1. und im 4. Kanal ist dieses Verhalten erkennbar, jedoch ist die Ausprägung geringer. Die Streuung der mittleren Grauwerte bei konstantem Überschirmungsgrad ist ebenfalls beim nahen infraroten Kanal am größten. Die Werte variieren durchgehend über den gesamten Verlauf mit 20 bis 30 Grauwerten, was eine Zuweisung der Grauwerte zu einem Überschirmungsgrad schwierig macht.

### 7.1.2 IRS P6 Satellitenbild vom 23.06.05


Für das Satellitenbild vom 23. Juni 2005 sind von den 93 Trainingsgebieten nur 68 für die Signaturanalyse verwendbar, da die restlichen Gebiete von Wolken bzw. Wolken Schatten verdeckt sind. Mit einem Azimuth von  $151,16^\circ$  und einem Höhenwinkel von  $63,05^\circ$  vom Bildmittelpunkt zur Sonne ist der Sonnenstand bei der Aufnahme der Szene nur geringfügig anders als bei der IRS-Szene vom Juli des Jahres 2006.



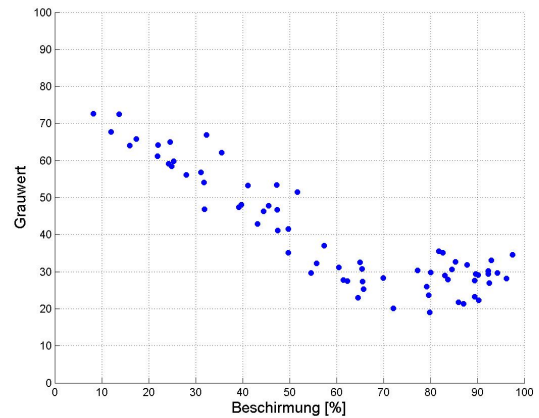
(a) Grüner Kanal



(b) Roter Kanal



(c) Naher Infraroter Kanal



(d) Mittlerer Infraroter Kanal


Abbildung 10: Streudiagramme von Beschirmungsgrad und Grauwerte der unterschiedlichen Kanäle des IRS Satellitenbildes vom 23.06.05

Auch in Abbildung 10 ist bei den dargestellten Diagrammen der typische, vom Überschirmungsgrad abhängige Verlauf der Grauwerte im nahen Infrarot am deutlichsten ausgeprägt. Die systematische Verteilung der Grauwerte des 3. und des 4. Kanals des IRS Satellitenbildes sind von denen der Juliszene des Jahres 2006 kaum zu unterscheiden. Der grüne und der rote Kanal weisen hingegen eine stärkere Variation der Grauwerte auf. Weiters ist diesmal auch beim roten Kanal der charakteristische Verlauf zu sehen, der jedoch im Vergleich zu den anderen spektralen Kanälen gering ausfällt.


### 7.1.3 SPOT 4 Satellitenbild vom 12.09.06

Mit einer Sonnenelevation von  $45.94^\circ$  bei der Aufnahme des Bildes ist der Höhenwinkel um fast  $20^\circ$  geringer als der bei den beiden IRS-Szenen. Aufgrund der vom geringen


Sonnenstand verursachten Schlagschatten und der geringeren Abdeckung der Spot-Szene sind nur 66 Trainingsgebiete bei diesen Diagrammen enthalten.




(a) Grüner Kanal



(b) Roter Kanal



(c) Naher Infraroter Kanal



(d) Mittlerer Infraroter Kanal

Abbildung 11: Streudiagramme von Beschirmungsgrad und Grauwerte der unterschiedlichen Kanäle des SPOT 4 Satellitenbildes vom 12.09.06

Die Streudiagramme der Abbildung 11 sind verschieden zu den vorher besprochenen. Der Grund dafür ist der Aufnahmezeitpunkt vom 12. September 2006. Einerseits befinden sich die Pflanzen zu diesem Zeitpunkt in einer anderen Vegetationsperiode und andererseits ist der Sonnenstand bei gleicher Tageszeit deutlich geringer als im Hochsommer. Die von der Phänologie bedingten Reflexionsunterschiede, die bereits in Kapitel 2 besprochen wurden, äußern sich besonders stark bei der Lärche, bei der sich die Nadeln im Herbst verfärben. Die deutlich schwächere Variation der Grauwerte im grünen Kanal lässt auf einen geringeren Chlorophyllgehalt in den Blattorganen schließen. Weiters ist durch den geringeren Sonnenstand ein verstärkter Schattenwurf der Bäume gegeben, der




sich direkt auf die Reflexionswerte auswirkt. So kommt es dazu, dass Bestände mit 55% Beschirmung ein Reflexionsminimum aufweisen und durch die starke Selbstbeschattung der Kronen kein erheblicher Anstieg der Reflexionswerte beobachtet werden kann.

## 7.2 Regressionsanalyse


In diesem Teil des Kapitels soll geklärt werden, ob ein linearer Zusammenhang zwischen Grauwert und Beschirmungsgrad besteht und ob dieser in einem Satellitenbild bestimmt werden kann. Da für das IRS-Satellitenbild vom 17.07.06 die meisten Trainingsgebiete existieren, wird dieses Bild für die Regressionsanalyse herangezogen. Die folgenden Analysen beziehen sich auf diese Satellitenszene, außer es wird gesondert darauf hingewiesen. Neben der Regressionsanalyse der einzelnen Kanäle werden auch Regressionsmodelle untersucht, die mehrere Kanäle enthalten. Weiters werden auch synthetische Kanäle mit Hilfe der Regressionsanalyse untersucht.

### 7.2.1 Einfache lineare Regression

In der Signaturanalyse wurde festgestellt, dass die größte Variation der Grauwerte im nahen Infrarot auftritt. Bei der Bestimmung der Regressionsgeraden für die Beschirmung als Zielvariable und den Grauwerten des nahen infraroten Kanals als beschreibende Zielvariable erhält man ein Bestimmtheitsmaß  $R^2$  von 0,69. Auch der Fischer Test (F-Test) zeigt mit einer berechneten Testgröße von 204 und einer Irrtumswahrscheinlichkeit von 0%, dass ein signifikanter Zusammenhang zwischen der Zielvariablen und dem Kronenbedeckungsgrad besteht.



(a) Beschirmung, Grauwerte und Regressionsgerade



(b) Schätzwerte der Regression

Abbildung 12: Schätzung der Beschirmung aus dem NIR mit einer Regression

Beim Streudiagramm 12(a) ist auf der X-Achse der Beschirmungsgrad und auf der Y-Achse der Grauwert des nahen Infrarotes aufgetragen. Die Wahl der Achsen entspricht den bisherigen Darstellungen, ist jedoch bei der Regressionsanalyse unüblich, da die Zielvariable in diesem Fall auf der X-Achse aufgetragen ist. Die schwarze Linie entspricht der Regressionsgeraden, die eine Schätzung für den Überschirmungsgrad darstellt. Es ist zu erkennen, dass die Gerade die Beschirmung bis 65% gut beschreibt, über diesem Wert jedoch eine falsche Schätzung abgibt. In Abbildung 12(b) ist der beobachtete gegen den von der Regressionsgeraden berechneten Beschirmungsgrad aufgetragen. Die schwarze Linie stellt in diesem Fall die optimale Schätzung dar. Wie auch in 12(a) zu erkennen ist, ist eine gute Anpassung bis zu einem Überschirmungsgrad von 65% gegeben, obwohl im oberen Bereich der Kronenbedeckungsgrad bereits überschätzt wird. Danach unterschätzt die Regressionsgerade zunehmend die Zielvariable.

Bei der Regressionsanalyse der anderen Kanäle fällt auf, dass das MIR mit einem Bestimmtheitsmaß von 0,78 das beste Ergebnis liefert. Die Regressionen mit dem grünen und dem roten Kanal liefern Bestimmtheitsmaße von 0,66 und 0,47.

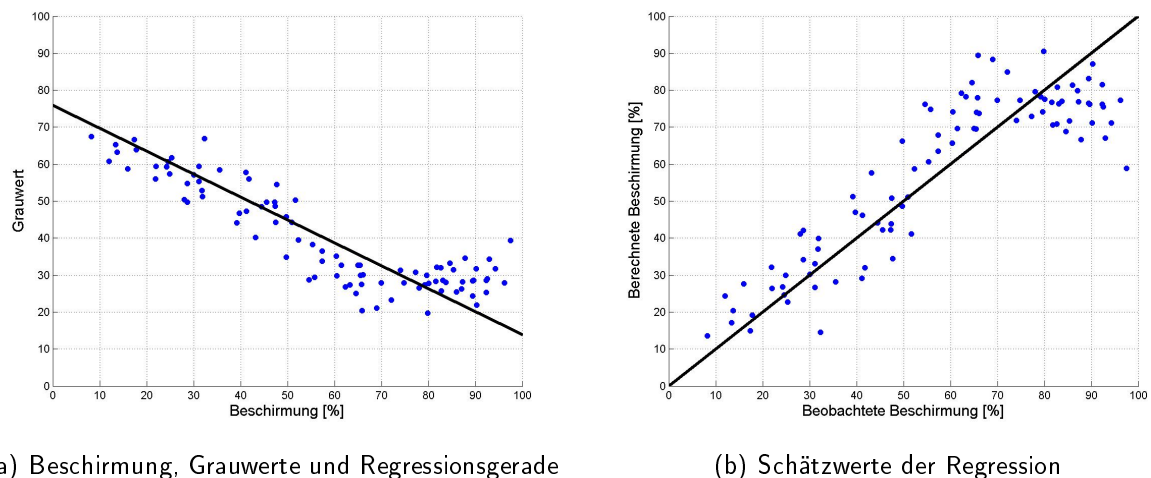



Abbildung 13: Schätzung der Beschirmung aus dem MIR mit einer Regression

Bei der Regressionsanalyse des MIR mit dem Überschirmungsgrad ist das gleiche Verhalten wie zuvor zu sehen. Bis zu einem Kronenbedeckungsgrad von 65% ist die Anpassung der Regression gegeben, darüber unterschätzt sie die Beschirmung. Dieses Verhalten weist auf eine unzureichende Modellierung durch die Regression hin. Die Schwierigkeiten der Modellierung der Regression liegen in der Mehrdeutigkeit der Grauwerte. Der Grauwert von 30 des MIR-Kanals repräsentiert zum Beispiel mehrere Bestände mit Überschirmungsgraden von 55 bis 100%, wie in Abbildung 13(a) zu erkennen ist.

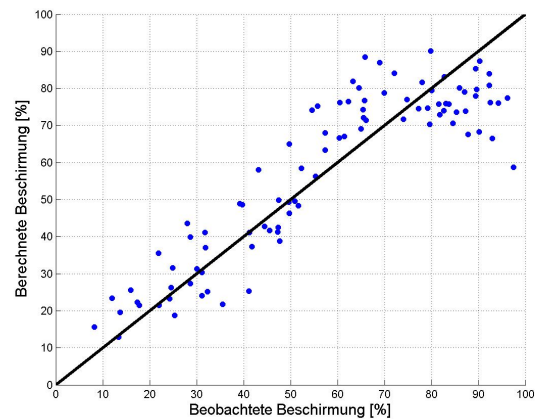
### 7.2.2 Multiple lineare Regressionen

Durch die Verwendung mehrerer Kovariablen wird erwartet, dass das Regressionsmodell die Zielvariable, den Beschirmungsgrad, besser beschreibt. Bei der Regressionsanalyse mit zwei unabhängigen Variablen, dem NIR und dem MIR Kanal, erhält man ein Bestimmtheitsmaß  $R^2$  von 0,79 und ein korrigiertes Bestimmtheitsmaß  $\bar{R}^2$  von 0,78, was bedeutet, dass die Hinzunahme des NIR Kanals zum Modell keine Verbesserung bringt. Der t-Test zeigt mit einer Prüfgröße von -0.87, dass der Koeffizient des nahen infraroten Kanals bei einer angenommenen Irrtumswahrscheinlichkeit von 5%, nicht signifikant von Null unterschiedlich ist. Das bedeutet, dass der Beitrag des NIR-Kanals am Ergebnis unbedeutend ist und vom Regressionsmodell ausgeschlossen werden kann.

Unbeachtet des vorhergehenden Ergebnisses wurde ein weiteres Regressionsmodell aufgestellt, welches die drei Kanäle Grün, NIR und MIR als Kovariablen enthält. Dieses Modell liefert ein korrigiertes Bestimmtheitsmaß von 0,79 und eine Standardabweichung von 11,39%. Der t-Test zeigt bei einem Signifikanzniveau von 95%, dass abgesehen vom Koeffizienten des nahen Infrarotes alle anderen einen entscheidenden Beitrag im Regressionsmodell leisten. Weiters weisen die Variationsinflationsindices auf eine zu hohe Multikollinearität hin, wobei der NIR-Kanal mit 12.44 den größten Wert aufweist. Wie bereits erwähnt wurde, stellt die Multikollinearität ab einem  $VIF$  von  $> 10$  ein Problem dar.



(a) Regression mit den Kanälen NIR und MIR



(b) Regression mit den Kanälen GRÜN, NIR und MIR

Abbildung 14: Schätzungen der Beschirmung durch multiple Regression

Veranschaulicht man die berechneten Werte im Bezug auf die beobachteten Überschirmungsgrade ist erkennbar, dass die Aufnahme mehrerer Kovariablen in das Regressionsmodell nicht zum gewünschten Ergebnis führt.

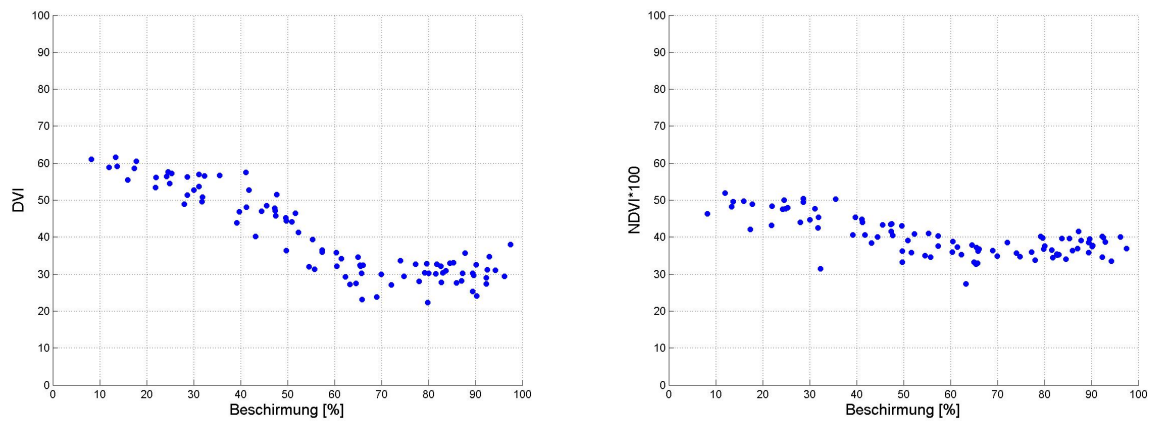
### 7.2.3 Regressionsanalyse mit synthetischen Kanälen

Da die originalen spektralen Kanäle den Kronenbedeckungsgrad nur unzureichend beschreiben, wird die Regressionsanalyse auch für synthetische Kanäle durchgeführt. In dieser Untersuchung wurden der Differenz Vegetations Index (DVI) und der Normalisierte Differenz Vegetations Index (NDVI) verwendet, da diese die am häufigsten verwendeten Indizes sind.

$$DVI = NIR - ROT$$

$$NDVI = \frac{NIR - ROT}{NIR + ROT}$$

Der NDVI kann durch seine Normierung nur Werte zwischen -1 und +1 annehmen, und wird für die Darstellung mit 100 multipliziert. Die synthetischen Grauwerte wurden für die Darstellung mit einer Additionskonstante erweitert.



(a) Streudiagramm DVI-Beschirmungsgrad

(b) Streudiagramm NDVI-Beschirmungsgrad

Abbildung 15: Streudiagramme von Beschirmungsgrad und unterschiedlichen synthetischen Kanälen

Die Regressionsanalyse der künstlichen Kanäle liefert die Bestimmtheitsmaße 0,68 für den *DVI* und 0,50 für den *NDVI*. Die Anpassung der Regression durch diese Vegetationsindizes ist schlechter als die durch das NIR und das MIR. Dies ist damit zu begründen, dass Information durch die Differenz- und Quotientenbildung eliminiert werden.


Weitere Indizes stammen aus der Tasseled Cap Transformation für Spot 5 Bilder. (Ivits-Wasser, 2008 [11]). Da die Sensoren der Satelliten Spot 5, Spot 4 und IRS ähnliche spektrale Aufnahmecharakteristiken aufweisen (vgl. Tabellen 4,5 und 6), wird diese Transformation auch für die Spot 4 und IRS Satellitenbilder verwendet. Für die IRS-Szene vom 17.07.06 werden die Transformationsparameter von Tabelle 2 für die Berechnung

der spektralen Indizes verwendet.

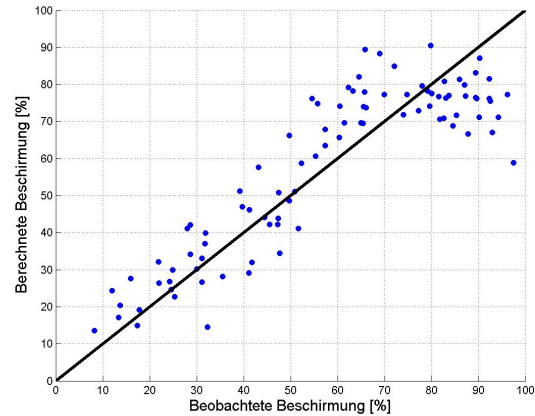
Die Regressionsanalyse dieser drei synthetischen Kanäle ergab die Bestimmtheitsmaße von 0,75 für die Brightness, 0,66 für die Greenness und 0,79 für die Wetness. Die Wetness zeigt die beste Anpassung der Regression an die Beschirmung. Dabei ist zu erwähnen, dass von den Transformationsparametern der Wetness die größte Ladung mit dem Wert von -0,83 beim Kanal MIR vorkommt. Da die anderen Indizes beim MIR geringere Ladungen aufweisen, und das MIR als Kovariable die best angepasste Regression liefert, ist es nicht verwunderlich, dass die Wetness das größte Bestimmtheitsmaß aufweist.

Bei einer multiplen linearen Regression mit 2 Kovariablen erhalten wir die beste Lösung für die Kombination Greenness und Wetness mit einem korrigierten Bestimmtheitsmaß von 0,80. Danach folgt die Kombination Brightness und Wetness mit einem  $\bar{R}^2$  von 0,79 und letztere mit 0,75. Multikollinearität spielt nur bei der multiplen Regression mit den Variablen Brightness und Greenness mit einem Varianzinflationsfaktor von 11,70 eine Rolle. Der Korrelation zwischen den beiden Variablen liegt bei 0,96. Die geringste Korrelation besteht zwischen den synthetischen Kanälen Greenness und Wetness, mit einem Korrelationskoeffizienten von -0,84, was dennoch hoch negativ korreliert ist. Die Verwendung aller drei synthetischen Kanäle liefert kein besseres Ergebnis, lediglich die Variationsinflationfaktoren steigen alle deutlich über 10. Obwohl die Tasseled Cap Transformation mit dem Greenness Kanal einen Indikator für die Dichte der Vegetation enthält, sind die erzielten Ergebnisse schlechter als jene mit den originalen Kanälen. Verwunderlich ist auch, dass von den Indikatoren die Greenness die schlechteste Anpassung an die Beschirmung liefert.

Da immer wieder das Problem der Multikollinearität auftaucht, wurden mit Hilfe der Hauptkomponentenanalyse, die in Kapitel 4.2 beschrieben ist, neue Kovariablen erzeugt, die zueinander orthogonal sind. Bei der Verwendung aller Hauptkomponenten für die Regressionsanalyse erhält man ein korrigiertes Bestimmtheitsmaß von 0,80, was dem Maximum der bestimmmbaren Streuung entspricht. Im Vergleich dazu liefert die lineare Regression mit der ersten Hauptkomponenten als Kovariable bereits ein  $R^2$  von 0,73. Dieser Wert ist jedoch geringer als das Bestimmtheitsmaß der linearen Regression mit dem MIR als Kovariable. Der maximale Wert des korrigierten Bestimmtheitsmaßes von 0,8 weist bereits auf eine sehr gute Anpassung hin, jedoch ist in Abbildung 16 zu erkennen, dass auch die multiple Regression von synthetischen Kanälen einen systematischen Fehler bei dichten Beständen liefert.



(a) Multiple lineare Regression mit allen Hauptkomponenten




(b) Lineare Regression mit MIR

Abbildung 16: Schätzungen der Beschirmung durch unterschiedliche Modelle

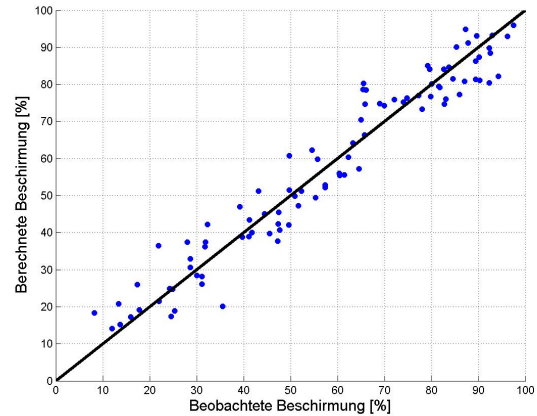
In Abbildung 16 ist zum Vergleich neben dem Diagramm des besten Schätzergebnisses nochmals das Resultat aus der einfachen linearen Regression mit dem mittleren infraroten Kanal als Kovariable dargestellt. Beide Modelle überschätzen zunehmend bis 80% die tatsächliche Beschirmung und unterschätzen diese von 75 bis 100%. Da die Schätzung der Beschirmung, vor allem von dichten Beständen, durch die linearen Regressionsmodelle nicht zufriedenstellend ist, wird untersucht, ob eine partielle Bestimmung des Überschirmungsgrades eine bessere Anpassung liefert (siehe Kapitel 7.2.4).

#### 7.2.4 Zwei einfache lineare Regressionen

Wie bereits festgestellt wurde, ist der Verlauf der Grauwerte, ausgehend von einer unbestockten Fläche mit zunehmendem Schlussgrad durch einen Abfall und ab einem Schlussgrad von etwa 65% durch einen Anstieg gekennzeichnet. Diese Begebenheit regt dazu an, zwei Regressionsgeraden zu verwenden. Eine Gerade, die den Überschirmungsgrad von 0 bis 65% beschreibt und eine andere Gerade, die dichte Bestände aus den Grauwerten schätzt. Dabei hat sich gezeigt, dass sich mit dem nahen infraroten Kanal als Kovariable für die untere Ausgleichsgerade ein Bestimmtheitsmaß von 0,84 ergibt. Die obere Regression hat wie zu erwarten ein geringeres Bestimmtheitsmaß, mit dem Wert von 0,55 weist dieses jedoch auf einen starken Zusammenhang zwischen dem NIR und dem Schlussgrad hin. Auch die geschätzten Standardabweichungen sind mit 6,22% (lockere Bestände) und 6,51% (dichte Bestände) deutlich geringer als die des bisher besten Ergebnisses (11,23% bei der multiplen linearen Regression mit allen Hauptkomponenten).



(a) Beschirmung, Grauwerte und Regressionsgeraden



(b) Schätzwerte der Regressionen

Abbildung 17: Schätzung der Beschirmung aus dem NIR mit zwei Regressionen

In Abbildung 17 sind zwei Diagramme dargestellt, welche die Anpassung der beiden Regressionsgeraden ersichtlich machen. Beim ersten Diagramm sind die Referenzschlussgrade gegen die Grauwerte des nahen Infrarots aufgetragen und zusätzlich durch die beiden Ausgleichsgeraden ergänzt. Im Diagramm 17 sind die Referenzschlussgrade den aus der Regression geschätzten Schlussgraden gegenübergestellt. Hier bezeichnet die schwarze Linie die optimale Schätzung. Wie zu erkennen ist die Anpassung der Geraden an die Daten sehr gut.

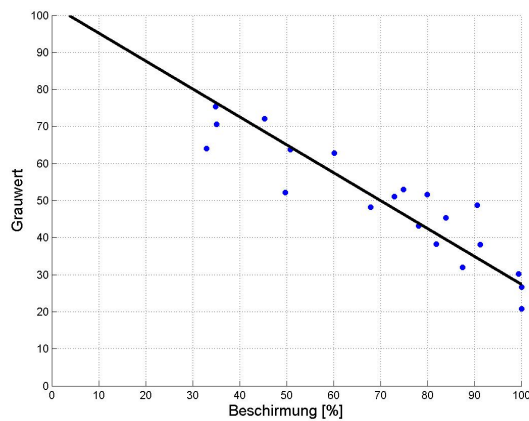
Bei den weiteren Regressionsanalysen mit den Kanälen des IRS P6 Satellitenbildes vom 17.07.06 wurde mit einer Ausnahme für jeden Kanal ein signifikanter Zusammenhang zwischen Überschirmungsgrad und Grauwert nachgewiesen. Kein Zusammenhang konnte bei der Ausgleichsgeraden der dichten Bestände für die Grauwerte des MIR Kanals festgestellt werden. Da die berechnete Prüfgröße  $\hat{t}$  mit 1,78 geringer ist als die aus der Fisher-Verteilung (4,09) ermittelte, wird die Nullhypothese, dass kein Zusammenhang besteht, mit einer Irrtumswahrscheinlichkeit  $\alpha$  von 5%, angenommen.

Bei der IRS P6 Szene vom 23.06.05 sowie beim Spot 4 Satellitenbild wurde beobachtet, dass ebenfalls beide Regressionsgeraden des NIR Kanals im unteren und im oberen Bereich einen hochsignifikanten Zusammenhang zwischen Grauwert und Beschirmungsgrad aufweisen. Während die Beschirmung bis 65% bei beiden Szenen durch den Grauwert jedes einzelnen Kanals durch eine Regression bestimmbar ist, sind Zusammenhänge bei dichten Beständen nur beim NIR Kanal gegeben.

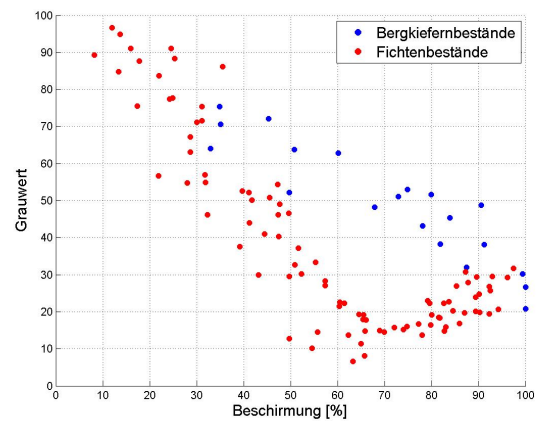
### 7.3 Schattenwurf von Waldbeständen

In diesem Abschnitt wird der Schattenwurf von Waldbeständen und dessen Einfluss auf die Signatur von Fernerkundungsdaten betrachtet.

Die Signatur von Beständen wird stark von der Beschattung beeinflusst, welche in Abhängigkeit vom Einstrahlungswinkel und verschiedenen Bestandesparametern variiert. Vor allem die Kronendachrauigkeit, die durch die vertikale Struktur des Kronendaches und durch den Überschirmungsgrad gegeben ist, hat maßgeblichen Einfluß auf den Schattenwurf von Waldbeständen. Die Fichte, die im Untersuchungsgebiet flächenmäßig am stärksten vertretene Baumart, bildet Bestände mit einem sehr rauen Kronendach und weist aus diesem Grund einen verhältnismäßig hohen Schattenwurf in den Beständen auf. Im Gegensatz zur Fichte bilden Latschen Bestandesformen mit einer geringeren Rauigkeit des Kronendaches, was neben der geringen Wuchshöhe dieser Baumart zu einem geringen Maß an Beschattung im Bestand führt.



(a) Beschirmung, Grauwerte (NIR) und Regressionsgerade



(b) Beschirmung und Grauwerte (NIR)

Abbildung 18: Vergleich der Reflexion von Latschenbeständen und Fichtenbeständen in Abhängigkeit des Beschirmungsgrades

In den Abbildungen 18 sind zwei Diagramme dargestellt, welche die Reflexion von unterschiedlich beschirmten Latschen- und Fichtenbeständen im Satellitenbild vom 17.07.06 wiedergeben. Links ist der Beschirmungsgrad von Latschenbeständen gegen den Mittelwert der Grauwerte des NIR aufgetragen. Die Regressionsgerade, die die Grauwerte bestmöglich den Beschirmungsgraden der Latschenflächen anpasst, ist durch die schwarze Linie gegeben. Im rechten Diagramm sind die Grauwerte von Latschen- und Fichtenwäldern aufgetragen, wobei die Kennzeichnung der Baumart durch die Farbgebung erfolgt. Es ist zu erkennen, dass die Beschirmungsgrade und die Reflexionswerte von Latschen, im Gegensatz zu denen von Fichtenbeständen, linear abhängig sind. Dieser Unterschied



ist durch die verschieden stark ausgeprägte Beschattung zu erklären, welche bei Fichtenbeständen vermehrt auftritt, und zu dem bereits beschriebenen Reflexionsminimum des von der Beschirmung abhängigen Grauwertverlaufes führt.

### 7.3.1 Simulation des Schattenwurfes

Um den vom Einstrahlungswinkel der Sonne abhängigen Schattenwurf von Beständen zu analysieren, wird das aus LIDAR-Daten erstellte Oberflächenmodell eines Fichtenwaldes aus Obwalden herangezogen. Das Oberflächenmodell im Rasterformat, das die Höhe der Oberfläche als Grauwert darstellt, wurde für die Simulationen um die Höhe des Geländes reduziert. Das resultierende Oberflächenmodell wies in Folge nur noch die Höhen der Bäume auf.

Mit Hilfe der Software ArcMap wurden mit dem Oberflächenmodell zwei Simulationen durchgeführt. Einmal wurde der Schattenwurf eines ebenen Waldes und ein anderes Mal eines im geneigten Gelände befindlichen Waldes für verschiedene Sonnenstände simuliert. Für die Gegenüberstellung des Überschirmungsgrades mit dem Flächenanteil des Schattens wurde das Höhenmodell mit einem Raster unterteilt. Die 1 Hektar Rastermaschen und die aus LIDAR-Daten erstellte Baumkronenkarte mit simuliertem Schattenwurf für die Sonnenelevation von  $60^\circ$  sind in Abbildung 19 dargestellt. In dieser Karte entspricht die grüne Farbe der besonnten Kronenfläche, graue Pixel der beschatteten Kronenteile und die schwarze Farbe dem Schatten am Boden.




Abbildung 19: Simulierte Schattenflächen eines Bestandes bei einer Sonnenelevation von  $60^\circ$

Für die erste Untersuchung wurden Schattenflächen eines ebenen Waldes für Sonnenele-

vationen von  $45$  bis  $63^\circ$  simuliert. Die Berechnung des flächenmäßigen Anteils beleuchteter Kronen, des Kronenschattens (Schatten auf der Krone) und des Bodenschattens erfolgte für  $455$  Rastermaschen. Der simulierte Schattenwurf der einzelnen Waldeinheiten ist für die Sonnenelevationen von  $60^\circ$  und  $45^\circ$  in den Diagrammen 20(a) und 20(b) dargestellt.

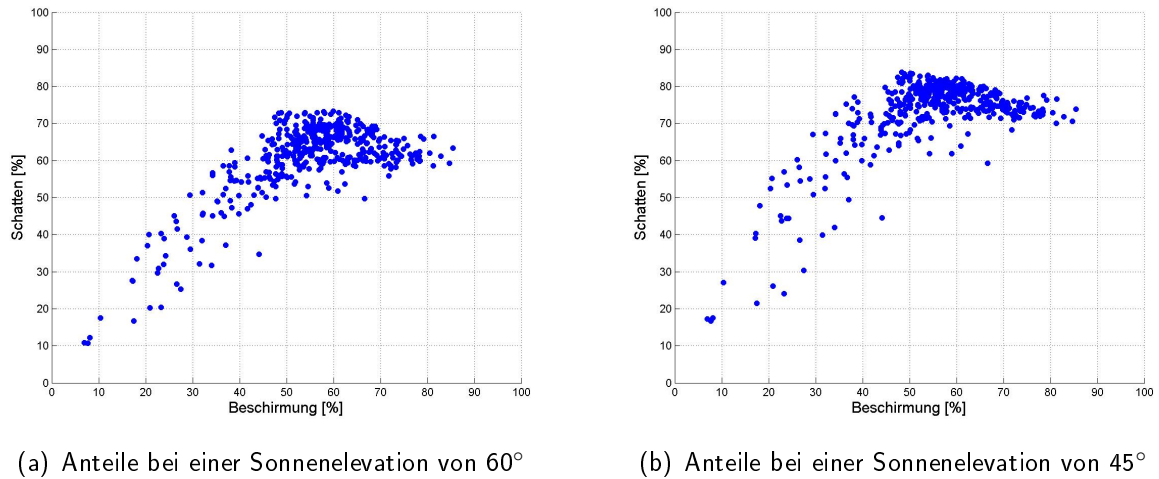


Abbildung 20: Simulierter Anteil des Schattens des Waldes bei unterschiedlicher Sonnenelevation

Wie zu erwarten, ist der Anteil des Schattens bei einem Einstrahlungswinkel von  $45^\circ$  höher als bei einem Winkel von  $60^\circ$ . Weiters ist bei den Diagrammen 20(a) und 20(b) zu erkennen, dass sich die maximalen Schattenanteile bei verschiedenen Beschirmungen befinden. Während der größte Schattenwurf bei einer Sonnenelevation von  $60^\circ$  bei einem Schlussgrad von  $60\%$  auftritt, ist bei einer Sonnenelevation von  $45^\circ$  ein Maximum bei circa  $50\%$  zu erkennen. Eine weitere Differenzierung in Boden- und Kronenschatten liefert eine Aussage über deren unterschiedliche Abhängigkeit zur Sonnenelevation.

Bei den Graphiken 21(a) und 21(b) ist der Schlussgrad der Waldeinheiten auf der X-Achse und der flächenmäßige Anteil der verschiedenen Bedeckungsarten auf der Y-Achse aufgetragen. Bei den Bedeckungsarten, die zusammen  $100\%$  der Fläche ausmachen, wird zwischen beschatteter und besonnener Krone sowie beschattetem und besonnem Boden unterschieden. Der Anteil der Kronenfläche, der dem Beschirmungsgrad entspricht, wird durch den grauen Hintergrund dargestellt. Die Kronenfläche teilt sich in eine beschattete und eine besonnte Fläche, wobei der Anteil des Schattens einer Waldeinheit als schwarzer Punkt aufgetragen ist und dessen prozentueller Wert direkt auf der Y-Achse abgelesen werden kann. Den Anteil der besonnenen Krone dieser Waldeinheit erhält man, indem man den beschatteten Anteil der Krone vom Beschirmungsgrad subtrahiert, was dem Bereich zwischen den schwarzen Punkten und der schwarzen Linie entspricht, welche

## 7 Datenanalyse

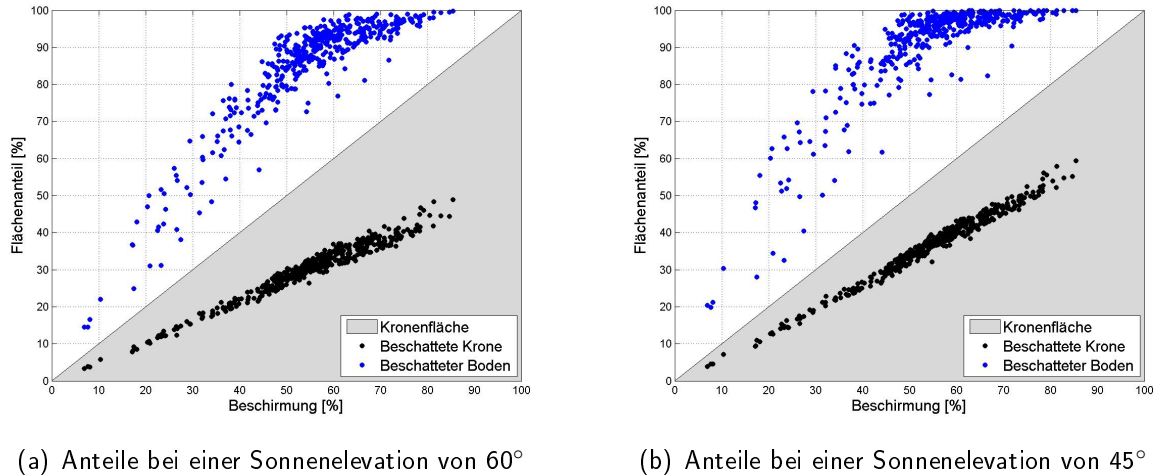


Abbildung 21: Simulierte Flächenanteile innerhalb des Waldes bei unterschiedlicher Sonnenelevation

die Kronenfläche begrenzt. Die Bodenfläche wird in weißer Farbe mit einem schwarz hinterlegtem Raster dargestellt. Aufbauend auf dem Prinzip der aufsummierten Anteile ist der Schatten am Boden als blaue Punkte, über der Linie, die den Beschirmungsgrad darstellt, aufgetragen. Die Fläche des besonnten Bodens ergänzt die Summe der Anteile auf 100%.

Bei der Betrachtung von Abbildung 21 ist zu erkennen, dass der vom Beschirmungsgrad abhängige Anteil des Kronenschattens einer Geraden gleicht, während der Anteil des am Boden befindlichen Schattens keinen systematischen Verlauf erkennen lässt. Vergleicht man jene beiden Graphiken, die einen unterschiedlichen Einstrahlungswinkel der Sonne zeigen, entdeckt man einen stärkeren Anstieg des Verlaufes des Kronenschattens bei der Elevation von  $45^\circ$  im Vergleich zum Sonnenwinkel von  $60^\circ$ . Auch der Anteil des am Boden befindlichen Schattens steigt bei einem niederen Sonnenstand stärker mit zunehmendem Schlussgrad als bei einer hohen Sonnenelevation. Beim Vergleich der Abbildungen 20 und 21 ergibt sich die Erkenntnis, dass das Maximum des Gesamtschattens nicht dem Maximum des Bodenschattens entspricht, welcher für eine Sonnenelevation von  $60^\circ$  in etwa bei einem Beschirmungsgrad von 50% auftritt. Wie vorher bereits festgestellt wurde, befindet sich das Maximum des Gesamtschattens bei einer Sonnenelevation von  $60^\circ$  in etwa beim Schlussgrad von 60%, was jenem Schlussgrad gleicht, bei dem die letzte besonnte Bodenfläche vom Schatten eingenommen wird. Die große Variation der Schattenanteile innerhalb gleicher Beschirmungsgrade, welche durch verschiedene Bestandesstrukturen entstehen, erlaubt keine weiteren Deutungen.





Abbildung 22: Schattenwurf unterschiedlicher Bestände ([12][Kane et. al])

In den schematischen Darstellungen von verschiedenen Beständen in der Abbildung 22 wird auf den unterschiedlich starken Schattenwurf bedingt durch Bestandesstruktur, Exposition und Hangneigung hingewiesen. Ein homogener Bestand (a) verursacht bei gleichem Kronenschlussgrad generell einen geringeren Schattenwurf als ein stark vertikal strukturierter Bestand (b). Neben der Bestandesstruktur spielt auch die Exposition und die Hangneigung eine maßgebende Rolle. Bestände, die sich auf Hängen befinden, die der Sonne zugewandt sind, verursachen weniger Schatten als Bestände mit von der Sonne abgewandten Expositionen. Um die Annahme zu verifizieren, dass die Hangneigung diesen Effekt verstärkt, wurden verschiedene konstant geneigte Geländemodelle erzeugt, die mit dem Oberflächenmodell des verebneten Bestandes aus Obwalden erweitert wurden. Für diese digitalen Oberflächen von Bestandesflächen wurden für mehrere Sonnenelevationen Schattenmodelle gerechnet. Der flächenmäßige Anteil der jeweiligen Schatten wurde für 182 Waldeinheiten ermittelt und dem Beschirmungsgrad gegenübergestellt.

Die zwei Diagramme 23(a) und 23(b) zeigen die Differenzen des Schattenwurfes von Waldflächen, die sich im geneigten Gelände befinden zu dem eines Waldes in der Ebene. Wie bereits bei der Interpretation der schematischen Darstellungen der Abbildung 22 angeführt war, weisen südlich exponierte Waldflächen weniger Schatten auf als nördlich exponierte Waldflächen. Des weiteren ist auch die Hangneigung bestimmend, in welchem Maße der Bestand reflektiert. Vergleicht man die beiden Diagramme, die durch unter-



(a) Schattenanteil bei einer Sonnenelevation von  $60^\circ$     (b) Schattenanteil bei einer Sonnenelevation von  $45^\circ$

Abbildung 23: Simulierter Anteil des Schattens eines Bestandes bei unterschiedlicher Sonnenelevation und variierender Exposition

schiedliche Einstrahlungswinkel der Sonne entstanden sind, erkennt man große Ähnlichkeiten bei südexponierten Hängen. Bei diesen ist die Differenz des Schattenanteils fast über den gesamten Beschirmungsgrad konstant, lediglich gering bestockte Flächen weisen kleinere Differenzen auf. Die Differenzen der Schatten bei unterschiedlichen Hangneigungen sind bei der Sonnenelevation von  $60^\circ$  geringer als beim Einstrahlungswinkel von  $45^\circ$ .

Wie in der Signaturanalyse festgestellt wurde, existiert ein Reflexionsminimum bei Beständen, die in etwa zu 65% beschirmt sind. Mit der Schattensimulation konnte belegt werden, dass die Beschattung dieses Minimum verursacht und dass der Beschirmungsgrad bei dem das Reflexionsminimum auftritt, von Sonnenelevation und Hangneigung bestimmt wird.

## 8 Vergleich der vier Klassifizierungsmethoden

In diesem Kapitel werden vier Methoden verglichen, diskutiert und die beste ausgewählt, mit der im Anschluss eine überwachte Klassifizierung durchgeführt wird. Von diesen Methoden wurden bereits zwei im Kapitel 3 als gängige Verfahren der Fernerkundung vorgestellt. Die beiden anderen Methoden entstanden im Zuge dieser Arbeit und liefern ebenfalls einen kontinuierlichen Beschirmungsgrad als Ergebnis.

1. Methode der einfachen linearen Regression
2. Methode der k-Nächsten-Nachbarn (kNN Methode)
3. Methode der zwei linearen Regressionen mit vorhergehender Stratifizierung durch die Maximum-Likelihood-Methode (wird in Folge auch als Hybridmethode bezeichnet)
4. Methode der zwei linearen Regressionen mit vorhergehender Stratifizierung durch die logistische Regression (wird in Folge auch als Regressionsmethode bezeichnet)

Nach einer kurzen Beschreibung des Ablaufes der Methoden 1 bis 4 folgt der Vergleich der Algorithmen, die zur Stratifizierung der Methoden 3 und 4 verwendet werden. Aus der Datenanalyse geht hervor, dass der Überschirmungsgrad besser durch zwei Regressionen beschrieben wird. Das setzt voraus, dass für jedes Pixel bekannt ist, mit welchem der beiden Regressionen der Schlussgrad berechnet wird, was nach einer Stratifizierung der Pixel verlangt. Nach diesem Einschub der Stratifizierung erfolgt die Evaluierung der Methoden mit der Kreuzvalidierung der Referenzdaten.

### 8.1 Methode der einfachen linearen Regression

Im Zuge der Regressionsanalyse wurde bereits der Schlussgrad der Referenzgebiete mit der Methode der einfachen linearen Regression bestimmt. Hier wird beschrieben, wie man eine überwachte Klassifizierung eines Satellitenbildes mit der linearen Regression durchführt. Dazu sind zwei Arbeitsschritte erforderlich:

1. Schätzung der Regressionskoeffizienten aus den Referenzdaten (Trainingsgebieten)
2. Berechnung der Beschirmung mit den geschätzten Koeffizienten und den Grauwerten des Satellitenbildes

Mit den vorhandenen Referenzdaten, dem Überschirmungsgrad als Zielvariable und dem mittleren Infrarot des entsprechenden Bildes als Kovariable, werden zuerst die Koeffizienten  $\beta_0$  und  $\beta_1$  bestimmt. Als Kovariable wurde der MIR Kanal gewählt, da bei den

einfachen Regressionsmodellen mit diesem Kanal das beste Ergebnis erzielt wurde. Im zweiten Schritt erfolgt die pixelweise Bestimmung der Beschirmung mit der aufgestellten Regressionsgleichung des gesamten Bildes. Um ein darstellbares Ergebnis zu erhalten, sind zwei Nachbearbeitungen erforderlich. Einerseits müssen Pixel, die keinen Wald repräsentieren, den Beschirmungsgrad Null erhalten und andererseits müssen Beschirmungsgrade, die im Wald kleiner als 0% oder größer als 100% sind, auf 0% bzw. 100% gesetzt werden.

### 8.2 k-Nächste-Nachbarn Klassifizierung

Eine weitere Methode, die dazu geeignet scheint, den Beschirmungsgrad in Satellitenbildern zu bestimmen, ist die k-Nächste-Nachbarn (kNN) Methode. Wie im Kapitel 3 bereits beschrieben wurde, repräsentieren die Trainingsgebiete im Parameterraum der Grauwerte des Satellitenbildes deren Klasse, welche in diesem speziellen Fall der Beschirmungsgrad ist. Bei der Ermittlung des Schlussgrades im Satellitenbild wird zuerst die Distanz im Parameterraum vom zu klassifizierenden Pixel zu allen Trainingsgebieten bestimmt und darauf der Überschirmungsgrad aus den  $k$  nächsten Nachbarn errechnet.

Durch verschiedene Einstellungen kann die Methode der  $k$  nächsten Nachbarn auf spezielle Anforderungen zugeschnitten werden. Neben der Anzahl der nächsten Nachbarn ist es auch möglich, zwischen mehreren Distanzmaßen zu wählen. Es ist ebenso zulässig, anstatt der euklidischen Distanz die Mahalanobis-Distanz zu verwenden. Am häufigsten werden die euklidische Distanz und die 3 nächsten Nachbarn für die Klassifizierung verwendet, so auch für diese Arbeit. Eine zusätzliche Möglichkeit, das Ergebnis der Klassifizierung zu beeinflussen, ist die Wahl der Gewichtung der  $k$  nächsten Nachbarn. Neben der Berechnung des arithmetischen Mittelwertes der  $k$  nächsten Schlussgrade besteht auch die Möglichkeit, die Schlussgrade in Abhängigkeit von der Distanz zu gewichten. In dieser Arbeit wurde die Beschirmung der Pixel aus den Schlussgraden der 3 nächsten Nachbarn, gewichtet mit der inversen quadratischen Distanz, ermittelt. Bei der Klassifizierung eines Satellitenbildes ist im Falle, dass bei den Referenzgebieten unbestockte Flächen fehlen, das Ausmaskieren von Nichtwaldflächen im Ergebnis erforderlich.

### 8.3 Zwei lineare Regressionen mit vorhergehender Stratifizierung durch die Maximum-Likelihood-Methode

Kapitel 7 führte zur Feststellung, dass der Verlauf der Beschirmung in Abhängigkeit von den Grauwerten besser durch zwei Ausgleichsgeraden beschrieben wird. Bei der Verwendung zweier Regressionen ist jedoch die Entscheidung erforderlich, welche der

beiden Regressionsgeraden verwendet wird. Diese Entscheidung, die Stratifizierung der Pixel, erfolgt bei dieser Methode durch die Maximum-Likelihood-Methode, welche auf die Mahalanobis-Distanz basiert, welche ein Entfernungsmaß zwischen Punkten in einem mehrdimensionalen Vektorraum ist. Im Gegensatz zur euklidischen Distanz wird bei diesem Distanzmaß auch die Kovarianz  $\Sigma$  berücksichtigt. Die Mahalanobis-Distanz zwischen den Vektoren  $X_i$  und  $Y_j$  berechnet sich durch

$$d(X_i, Y_j) = \sqrt{(X_i - Y_j)^T \Sigma^{-1} (X_i - Y_j)}. \quad (33)$$

Während die Grauwertvektoren  $X_i$  den zu stratifizierenden Pixel entsprechen, beziehen sich die Grauwertvektoren  $Y_j$  auf die von den Trainingsgebieten repräsentierten Straten. Die Trainingsgebiete bilden folgende Straten:

- Bestände mit einem Beschirmungsgrad  $< 65\%$
- Bestände mit einem Beschirmungsgrad  $\geq 65\%$

Nach der Zuweisung der Trainingsgebiete zu den Straten werden mit der Maximum-Likelihood Klassifizierung auch die Pixel des Satellitenbildes einem Stratum zugewiesen. In einem nächsten Schritt werden die Referenzdaten für die Berechnung der Koeffizienten  $\beta_0$  und  $\beta_1$  verwendet, wobei für jedes Stratum ein Koeffizientenpaar ermittelt wird. Dazu verwendet man den Schlussgrad als Zielvariable und das nahe Infrarot des zu klassifizierenden Satellitenbildes als Kovariable. Wie in der Regressionsanalyse bereits beschrieben wurde, ist der NIR Kanal der einzige, der den Überschirmungsgrad von lockeren und dichten Beständen ausreichend beschreibt. Schlussendlich erfolgt die Berechnung der Beschirmung, abhängig vom Stratum des Pixels, mit einem der Koeffizientenpaare und dem NIR Kanal des Satellitenbildes mit der Regressionsgleichung. Bevor diese Klassifizierung in einer Karte dargestellt werden kann, müssen unbestockte Flächen und unrealistische Beschirmungen ( $<0\%$  und  $>100\%$ ) berichtigt werden.



#### 8.4 Zwei lineare Regressionen mit vorhergehender Stratifizierung durch die Logistische Regression

Diese Methode verwendet ebenfalls zwei lineare Regressionen für die Bestimmung des Überschirmungsgrades, was wiederum eine vorhergehende Stratifizierung der Pixel im Satellitenbild erfordert. Hier erfolgt die Stratifizierung mit der logistischen Regression, welche in Kapitel 4.1.2 bereits beschrieben wurde. Bei dieser Stratifizierung sind zwei Arbeitsschritte erforderlich:

1. Schätzung der Regressionskoeffizienten aus den Referenzdaten (Trainingsgebieten)
2. Berechnung der Straten mit den geschätzten Koeffizienten und den Grauwerten des Satellitenbildes

Für die Schätzung der Regressionskoeffizienten werden Kovariablen und Zielvariablen benötigt, welche von den Trainingsgebieten stammen. Als Zielvariable wird die Stratenzugehörigkeit und als Kovariable werden die Kanäle des zu klassifizierenden Satellitenbildes verwendet. Bei der Zielvariablen ist zu beachten, dass die Stratennummer in binärer Form gegeben sein muss. Somit erhalten lockere Bestände das Stratum 0 und dichte Bestände das Stratum 1. Für die anschließende Stratifizierung des Satellitenbildes werden die Kanäle und die berechneten Koeffizienten verwendet, um die Wahrscheinlichkeiten der Stratenzugehörigkeit zu erhalten, welche noch binarisiert werden müssen.

Die Bestimmung des Überschirmungsgrades auf der Basis der beiden Regressionsgeraden verläuft entsprechend der vorigen Methode. Mit den Referenzdaten (Beschirmung und NIR) werden die Koeffizientenpaare ermittelt, mit denen darauf in Kombination mit dem NIR des Satellitenbildes, abhängig vom Stratum des Pixels, der Überschirmungsgrad berechnet wird. Abbildung 24 verdeutlicht den Ablauf dieser Methode. Was in dieser Abbildung jedoch nicht ersichtlich ist, ist die notwendige Nachbearbeitung des Klassifizierungsergebnisses. Wie auch bei den anderen Methoden, müssen unbestockte Flächen und unrealistische Beschirmungen ( $<0\%$  und  $>100\%$ ) berichtigt werden.



## 8 Vergleich der vier Klassifizierungsmethoden




Abbildung 25: Spektrale Verteilung der Straten in der IRS P6 Szene vom 17.07.06

Die Zugehörigkeit der Trainingsgebiete zu den beiden Straten in Abbildung 25 ist durch die Farben Rot und Blau dargestellt. Weiters ist der schematische Verlauf der Grauwerte in Abhängigkeit des Schlussgrades durch die schwarzen Pfeile angedeutet. Diese Form der Darstellung wurde gewählt, da durch die alternative Hinzunahme der einzelnen Überschirmungsgrade die Übersicht verloren ginge. Wie zu erkennen ist, sind die Trainingsgebiete nahe dieser beiden Geraden angeordnet. Obwohl ein paar Gebiete des ersten Stratum, Bestände mit einer Beschirmung  $< 65\%$ , im Scattergram innerhalb des Grauwertbereiches des zweiten Stratum liegen, ist generell eine Unterscheidung der Trainingsgebiete möglich. Bei den Gebieten, die sich mit dem anderen Stratum vermischen, handelt es sich vor allem um Waldflächen mit Beschirmungsgraden um die 60% bis 70%.

Um die zwei Stratifizierungsmethoden objektiv vergleichen zu können, wird die im Kapitel 4.3 beschriebene Leave-One-Out-Kreuzvalidierung verwendet. Dabei werden von den  $n$  Trainingsgebieten,  $n - 1$  Gebiete für die Berechnung der benötigten Modellparameter genutzt. Mit diesen Parametern und dem Modell wird dann das komplementäre Trainingsgebiet klassifiziert. Da die Klassifizierungsergebnisse Straten entsprechen, ist deren Darstellung in einer Kontingenztabelle praktikabel. Bei einer Kontingenztabelle ist die relative Häufigkeit des Auftretens für alle möglichen Kombinationen von ermittelter Klasse und tatsächlicher Klasse, eingetragen. Aus der Kontingenztabelle ist die Gesamtgenauigkeit (Overall Accuracy) ableitbar, die dem Prozentwert der richtig zugewiesenen Klassen entspricht.

Für die Signatur des Satellitenbildes vom 17.07.06 wurden für die Stratifizierung alle möglichen Kombinationen von Grauwertkanälen getestet. Das beste Ergebnis ergab sich

## 8 Vergleich der vier Klassifizierungsmethoden

bei der Maximum-Likelihood Klassifizierung bei der Verwendung des MIR Kanals mit einer Gesamtgenauigkeit von 88%. Mit der logistischen Regression konnten bei Verwendung des grünen und des mittleren infraroten Kanals hingegen 90% der Gebiete richtig klassifiziert werden. Die Konfusionsmatrizen der beiden Ergebnisse sind in Tabelle 8 ersichtlich.


Tabelle 8: Ergebnisse der Kreuzvalidierung bei der Stratifizierung

Referenz	Logistische Regression		Maximum-Likelihood-Methode	
	Stratum 1	Stratum 2	Stratum 1	Stratum 2
Stratum 1	48,9%	7,6%	47,8%	8,7%
Stratum 2	2,2%	41,3%	3,3%	40,2%


Verwendet man bei der Stratifizierung mit der logistischen Regression nur den MIR Kanal als Kovariable, erhält man eine Gesamtgenauigkeit von 88%, genau wie bei der Stratifizierung durch die Maximum-Likelihood. Während eine Hinzunahme des grünen Kanals zum MIR Kanal eine Verbesserung der Genauigkeit bei der logistischen Regression bewirkt, verschlechtert sich das Ergebnis der Mahalanobis-Distanz Stratifizierung gering und es wird nur noch eine Genauigkeit von 87% erreicht. Nutzt man bei der logistischen Regression den grünen, den NIR und den MIR Kanal erhält man 90% Gesamtgenauigkeit, was der maximal erreichten Genauigkeit entspricht, die ebenfalls mit zwei Kovariablen, dem grünen und dem MIR Kanal, erreicht wurde. Betrachtet man die statistischen Kennwerte der logistischen Regression, fällt jedoch auf, dass beim Modell mit den drei Kanälen eine Multikollinearität auftritt, die bei einem Variationsinflationfaktor von 12,44 bereits über der Grenze 10 liegt. Das Akaikes Informationskriterium (Formel: 20) und das McFadden's  $R^2$  (Formel: 21) bestätigen die Ergebnisse der Kreuzvalidierung. Bei der logistischen Regression mit dem MIR Kanal erhält man ein Akaikes Informationskriterium (AIC) von 58,1 und ein McFadden's  $R^2$  von 0,58, nach der Hinzunahme des grünen Kanals ein AIC von 56,25 und ein  $R^2$  von 0,61. Zur Wiederholung sei hier erwähnt, dass je kleiner das AIC und je größer das McFadden's  $R^2$  desto besser ist die Anpassung durch die Regression. An den Kennwerten ist somit ersichtlich, dass sich die Anpassung verbessert hat. Nimmt man jedoch das Modell mit drei Kanälen als Kovariablen, bekommt man für das AIC 58,0 und für das  $R^2$  0,61. Während das Bestimmtheitsmaß gleich bleibt, vergrößert sich das AIC, was eine Verschlechterung anzeigt. Diese Ergebnisse sind durch die vorher angesprochene Multikollinearität bedingt.

Abbildung 26 zeigt zwei Scattergramme, in denen abermals die spektrale Verteilung der beiden Straten zu sehen ist. Die in den Scattergrammen enthaltenen Ellipse und Linie kennzeichnen die Abgrenzung zwischen den beiden Clustern, durch den jeweiligen

## 8 Vergleich der vier Klassifizierungsmethoden



(a) Maximum-Likelihood Klassifizierung



(b) Logistische Regression

Abbildung 26: Spektrale Verteilung der Straten und die Abgrenzung durch Klassifizierung (MIR-GRÜN)

Algorithmus. Optisch ist hier kein Unterschied bei der Qualität der Klassifizierungen zu erkennen. Da die Differentierung der zwei Straten mit dem grünen und dem MIR Kanal gut funktioniert, werden die Stratifizierungen durch die beiden Methoden in Folge mit diesen beiden Kanälen durchgeführt.

### 8.6 Evaluierung der Klassifizierungsmethoden

Da die vier Klassifizierungsmethoden keinen vergleichbaren Kennwert aufweisen, der deren Qualität beschreibt, wurde für deren Evaluierung die Leave-One-Out-Kreuzvalidierung herangezogen. Dabei wurden je Methode  $n$  Modelle erstellt und damit  $n$  unabhängige Beschirmungen ermittelt. Mit den berechneten Überschirmungsgraden und den Referenzbeschirmungen erfolgte die Bestimmung des Root Mean Square Errors (RMSE). Die Kreuzvalidierung wurde für alle Methoden für die drei in Kapitel 5 beschriebenen Satellitenbilder durchgeführt. Die Einstellungen der Methoden wurden, bis auf die der Stratifizierungen der Hybrid- und der Regressionsmethode, nicht verändert. Während für das erste IRS Bild der grüne und der MIR Kanal für die Stratifizierung verwendet wurden, musste bei den weiteren Bildern zusätzlich der NIR Kanal in das Modell aufgenommen werden.

#### 8.6.1 IRS-P6 Satellitenbild vom 17.07.06

Für die Trainingsgebiete und Signatur des Satellitenbildes vom 17.07.06 ergibt die Kreuzvalidierung einen RMSE von 11,8%, sowohl für die lineare Regression als auch für die Methode der  $k$ -Nächsten-Nachbarn. Die beiden komplexeren Methoden liefern die Streu-

## 8 Vergleich der vier Klassifizierungsmethoden

ungswerte von 10,7% und 9,9%, wobei das genauere Ergebnis durch die Regressionsmethode ermittelt wurde, welche die logistische Regression zur Stratifizierung der Grauwerte verwendet.

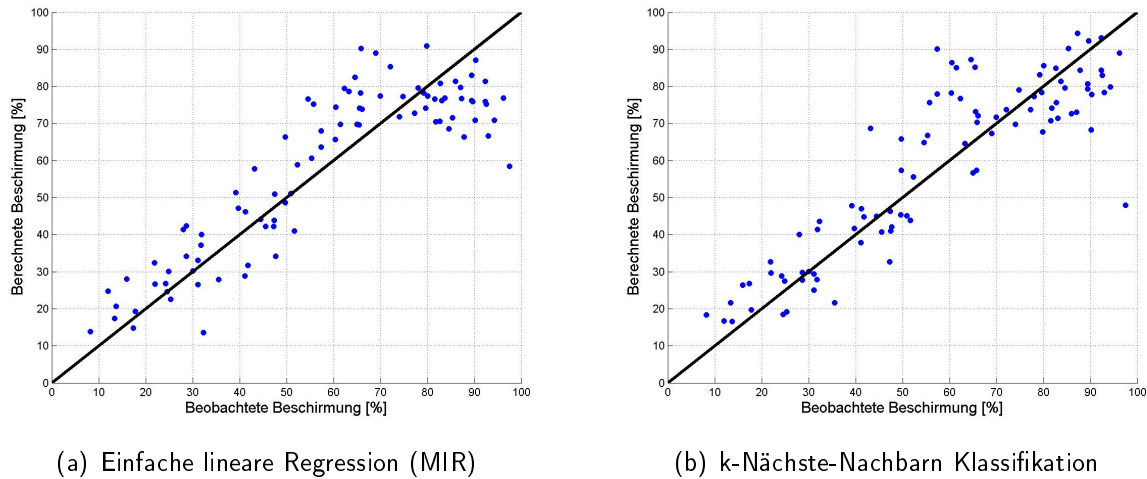



Abbildung 27: Vergleich der Kreuzvalidierung der Methoden 1 und 2 (Satellitenbild vom 17.07.06)


Abbildung 27 zeigt in den Graphiken die Ergebnisse der Kreuzvalidierung der ersten beiden Methoden. Bei den Scattergrammen ist auf der X-Achse der beobachtete Beschirmungsgrad, der Wert der Referenzdaten, aufgetragen und auf der Y-Achse der mit den unterschiedlichen Methoden ermittelte Schlussgrad. Das erste Scattergramm, welches die Resultate der Methode der linearen Regression beschreibt, zeigt die bereits diskutierten großen Abweichungen der beobachteten zu den ermittelten Beschirmungen im oberen Bereich. Bei der Methode der k-nächsten Nachbarn sind die Abweichungen eher im Bereich von 60% zu erkennen, wo die Schlussgrade zu hoch geschätzt werden. Dieser Umstand ergibt sich aus der Tatsache, dass sich Bestände mit einer Beschirmung von 60% im spektralen Merkmalsraum mit den höher beschirmten Beständen vermischen, welche zahlenmäßig dominieren.

In Abbildung 28 sind die Scattergramme der beiden Methoden dargestellt, welche den Schlussgrad nach einer vorhergehenden Stratifizierung über eine aus zwei möglichen Regressionen bestimmen. Der Unterschied beider Methoden ist wie bereits beschrieben die Stratifizierung, die entweder durch die Berechnung der Mahalanobis-Distanz oder durch eine logistische Regression erfolgt. Nicht nur aus dem RMSE, sondern auch optisch ist zu erkennen, dass die vierte Methode bessere Ergebnisse liefert als die dritte. Beim Verfahren mit der Maximum-Likelihood Stratifizierung wird eine größere Anzahl von hoch beschirmten Beständen unterschätzt. Diese Erscheinung resultiert aus der Tatsache, dass die zu klassifizierenden Pixel bei der Stratifizierung falsch zugeordnet werden und die

## 8 Vergleich der vier Klassifizierungsmethoden



(a) Zwei lineare Regressionen nach Stratifizierung durch die Maximum-Likelihood-Methode



(b) Zwei lineare Regressionen nach Stratifizierung durch die logistische Regression


Abbildung 28: Vergleich der Kreuzvalidierung der Methoden 3 und 4 (Satellitenbild vom 17.07.06)

falsche Regressionsgerade verwendet wird, um den Schlussgrad zu ermitteln. Abgesehen von den Ausreißern, die ihre Ursache in der Stratifizierung haben, liefern die Hybrid- und die Regressionsmethode bessere Berechnungen für den Überschirmungsgrad als die beiden anderen Methoden.


### 8.6.2 IRS-P6 Satellitenbild vom 23.06.05

Das Ergebnis der Kreuzvalidierung zur Verifizierung der IRS-Daten liefert für die ersten beiden Verfahren den RMSE von 12,0%, was nur gering ungenauer ist als die Ergebnisse, die mit den IRS-Daten vom 17.07.06 erzielt wurden. Auch Hybrid- und Regressionsmethode liefern ungenauere Ergebnisse und es werden nur noch RMSE von 16,0% und 11,9% erreicht. Wiederum wird das beste Ergebnis durch die Regressionsmethode erzielt. Eine Hinzunahme eines weiteren Kanals für die Stratifizierung bringt keine entsprechende Verbesserung bei der Hybridmethode, hingegen ergibt sich bei der Kreuzvalidierung der Regressionsmethode ein RMSE von 10,9%.

## 8 Vergleich der vier Klassifizierungsmethoden




(a) Einfache lineare Regression (MIR)




(b) k-Nächste-Nachbarn Klassifikation

Abbildung 29: Vergleich der Kreuzvalidierung der Methoden 1 und 2 (Satellitenbild vom 23.06.05)

Das Scattergramm 29(a) der Kreuzvalidierung der linearen Regression zeigt keine nennenswerten Unterschiede zu dem von 27(a). Obwohl die entsprechenden Scattergramme der Methode der  $k$  Nächsten Nachbarn (kNN) sehr verschieden wirken, ist eine ähnliche Systematik der Klassifizierung zu erkennen. Ebenfalls wird der Bereich des Schlussgrades um die 60% überschätzt, wobei dieser Bereich diesmal größer ist. Darüberhinaus ist eine deutliche Unterschätzung der hohen Überschirmungsgrade zu erkennen. Diese systematischen Erscheinungen lassen sich durch die spektrale Vermischung der Trainingsgebiete erklären.



(a) Zwei lineare Regressionen nach Stratifizierung durch die Maximum-Likelihood-Methode



(b) Zwei lineare Regressionen nach Stratifizierung durch die logistische Regression

Abbildung 30: Vergleich der Kreuzvalidierung der Methoden 3 und 4 (Satellitenbild vom 23.06.05)

Die Hybrid- und die Regressionsmethode, deren Kreuzvalidierungen in Abbildung 30 dargestellt sind, weisen hier höhere Abweichungen auf als im Bild vom 17.07.06. Bei beiden



Methoden zeigen sich größere Differenzen bei dichteren Beständen ab einem Schlussgrad von 50%. Die Verantwortung liegt dabei bei der Stratifizierung, die manche Gebiete falsch zuweist, wodurch der Schlussgrad mit der falschen Regressionsgleichung bestimmt wird. Im Vergleich zueinander sind wiederum größere Abweichungen bei der Methode mit der Maximum-Likelihood-Methode zu erkennen.

### 8.6.3 SPOT 4 Satellitenbild vom 12.09.06

Auch für das Spot 4 Satellitenbild vom 12.09.06 wurde eine Kreuzvalidierung für die verschiedenen Methoden gerechnet. Die suboptimale Sonnenelevation von  $46^\circ$  ließ erwarten, dass die Werte im Vergleich zu den anderen Szenen durchgehend schlechter sind. Der RMSE der linearen Regression entsprach 15,6% und die des kNN Verfahrens 14,4%. Die Hybridmethode und die Regressionsmethode die jeweils die drei Kanäle (grün, NIR und MIR) zur Stratifizierung nutzten, lieferten die RMSE von 13,7% und 14,0%.

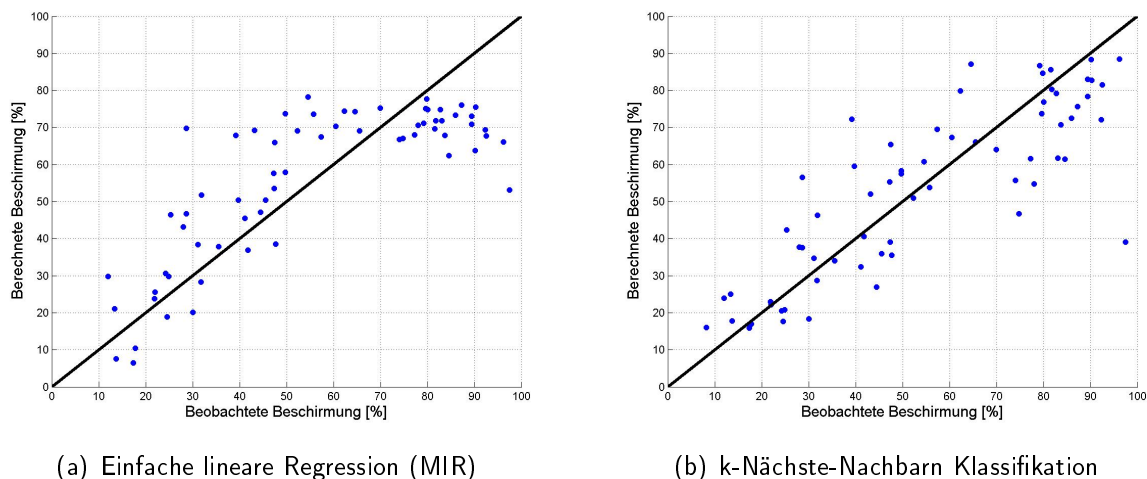
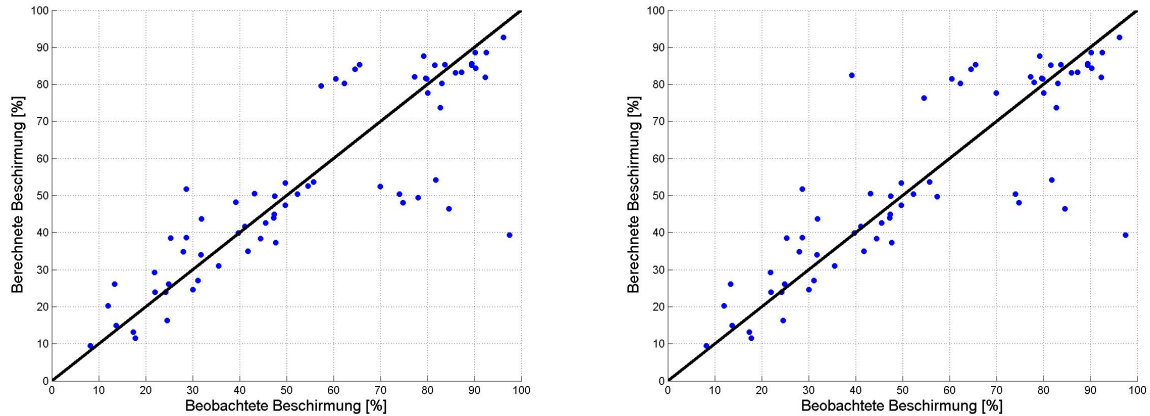


Abbildung 31: Vergleich der Kreuzvalidierung der Methoden 1 und 2 (Satellitenbild vom 12.09.06)

Die in Abbildung 31 ersichtlichen Scattergramme zeigen die Resultate der Kreuzvalidierung der ersten beiden Methoden. Bei der linearen Regression ist auch bei diesem Bild das dafür typische Resultat zu erkennen. Die charakteristische Überschätzung mittel bestockter Flächen und die Unterschätzung dichter Bestände ist bei diesem Bild am stärksten ausgeprägt. Das Scattergramm des Verfahrens der  $k$  nächsten Nachbarn zeigt unter diesen Umständen keine ersichtlichen systematischen Abweichungen, jedoch ist die Streuung der einzelnen Resultate verhältnismäßig groß.

Wie auch bei den anderen Satellitenszenen sind bei der Hybrid- und der Regressionsmethode die durch die Stratifizierung verursachten Abweichungen zu erkennen. Abgesehen von diesen Ausreißern sind die Ergebnisse jedoch besser als die der beiden anderen

## 8 Vergleich der vier Klassifizierungsmethoden



(a) Zwei lineare Regressionen nach Stratifizierung durch die Maximum-Likelihood-Methode

(b) Zwei lineare Regressionen nach Stratifizierung durch die logistische Regression

Abbildung 32: Vergleich der Kreuzvalidierung der Methoden 3 und 4 (Satellitenbild vom 12.09.06)

Methoden. Beim Vergleich der beiden Verfahren untereinander sind keine großen Unterschiede zu erkennen.


### 8.7 Anwendung der Methoden auf verschiedene Bestandestypen

Von den Trainingsgebieten wurden bisher für die Bestimmung der Modelle der Methoden und deren Evaluation nur Nadelbestände mit den Alterklassen Baumholz bis Altholz verwendet. Da es für die weiteren Bestandestypen (Misch- und Laubwald) an Trainingsgebieten mangelt, werden diese nicht für eine separate Modellierung herangezogen. Um dennoch zu testen, ob die Methoden für andere Bestandestypen geeignet sind, werden deren Trainingsgebiete in den bestehenden Modellen aufgenommen und evaluiert.


#### 8.7.1 Anwendung der Methoden auf Nadelwälder in den Altersklassen von Jungwuchs bis Stangenholz

Um die Eignung der Methoden für Nadelwälder in den Altersklassen von Jungwuchs bis Stangenholz zu prüfen, wird die Signatur der Satellitenszene vom 17.07.06 verwendet. Bei gleicher Einstellung der Methoden wie in 8.6.1 erhalten wir bei der Kreuzvalidierung für die lineare Regression ein RMSE von 16,6% und bei der kNN Methode ein RMSE von 26,4%. Die Kreuzvalidierung der Hybridmethode ergibt einen RMSE von 22,5% und die Regressionsmethode einen RMSE von 20,1%. Die lineare Regression weist das beste Ergebnis auf und die kNN Methode das schlechteste. Wegen der geringen Anzahl der Referenzgebiete (20), ist der RMSE jedoch nicht wirklich aussagekräftig.

## 8 Vergleich der vier Klassifizierungsmethoden




(a) Einfache lineare Regression (MIR)




(b) k-Nächste-Nachbarn Klassifikation

Abbildung 33: Anwendung der Methoden 1 und 2 auf Nadelwälder unterschiedlicher Altersklassen

In den Scattergrammen von Abbildung 33 sind die beobachteten gegen die berechneten Überschirmungsgrade aufgetragen. Die Färbung der Punkte repräsentiert die Zugehörigkeit zu den zwei Altersklassengruppen: während die blauen Punkte Nadelholz in den Altersklassen von Baumholz bis Altholz darstellen, werden die Trainingsgebiete der Altersklassen von Jungwuchs bis Stangenholz durch die roten Punkte gekennzeichnet. Beim ersten Scattergramm ist zu erkennen, dass die einfache lineare Regression den Beschirmungsgrad von jungen Beständen genauso wie ältere dichte Wälder unterschätzt. Die Abweichungen zum tatsächlichen Überschirmungsgrad sind jedoch geringer als bei den älteren Beständen. Auch die kNN Methode unterschätzt einen Teil der Schlussgrade, jedoch sind hier die Differenzen deutlich größer als bei der linearen Regression.



(a) Zwei lineare Regressionen nach Stratifizierung durch die Maximum-Likelihood-Methode




(b) Zwei lineare Regressionen nach Stratifizierung durch die logistische Regression

Abbildung 34: Anwendung der Methoden 3 und 4 auf Nadelwälder unterschiedlicher Altersklassen


In Abbildung 34 sind die Klassifizierungsergebnisse der beiden komplexeren Methoden dargestellt. Obwohl beide Methoden einen sehr großen RMSE aufweisen, sind die Schätzungen der Schlussgrade sehr gut. Lediglich zwei bzw. ein Ausreißer, welche durch eine fehlerhafte Stratifizierung entstanden sind, trüben das Ergebnis. Diese Ausreißer sind auch der Grund für den sehr hohen RMSE.

### 8.7.2 Anwendung der Methoden auf Misch- und Laubwälder

Um die Anwendbarkeit der Methoden auf Misch- und Laubwälder zu testen, wurden ebenfalls Kreuzvalidierungen durchgeführt. Wie zuvor wurde die Signatur des Satellitenbildes vom 17.07.06 verwendet. Wegen der geringen Anzahl von Referenzgebieten ist der RMSE auch hier nicht wirklich aussagekräftig. Davon abgesehen, zeigen die hohen Werte (alle >50%), dass keine der Methoden in dieser Form für die Bestimmung der Beschirmung gemischter Wälder geeignet ist.



(a) Einfache lineare Regression (MIR)

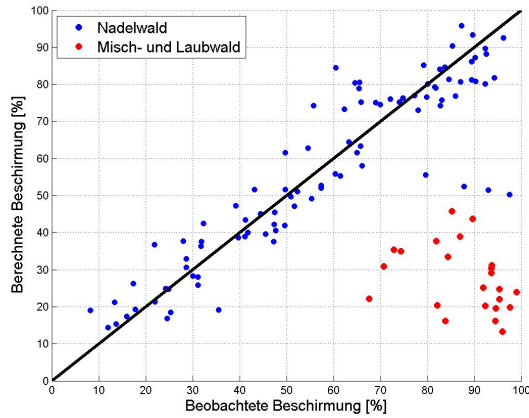


(b) k-Nächste-Nachbarn Klassifikation


Abbildung 35: Anwendung der Methoden 1 und 2 auf Misch- und Laubwälder

In den Scattergrammen von Abbildung 35 sind die beobachteten gegen die berechneten Schlussgrade der Trainingsgebiete aufgetragen und in zwei Gruppen geteilt, die durch die Farben blau und rot gekennzeichnet sind. Es ist deutlich zu erkennen, dass die lineare Regression ebenso wie die kNN Methode den Schlussgrad von Misch- und Laubbeständen deutlich unterschätzt. Was bereits bei den RMSE zu erkennen war, wird auch bei der Gegenüberstellung der berechneten gegen den aufgenommenen Beschirmungen deutlich, keine der beiden Methoden liefert ein brauchbares Ergebnis für den Schlussgrad von Misch- und Laubwäldern.

## 8 Vergleich der vier Klassifizierungsmethoden



(a) Zwei lineare Regressionen nach Stratifizierung durch die Maximum-Likelihood-Methode



(b) Zwei lineare Regressionen nach Stratifizierung durch die logistische Regression

Abbildung 36: Anwendung der Methoden 3 und 4 auf Misch- und Laubwälder

Die Ergebnisse der Kreuzvalidierung der Hybrid- und der Regressionsmethode sind in Abbildung 36 dargestellt. Wenn man die beiden Ergebnisse vergleicht, erkennt man, dass die Misch- und Laubbestände gleich klassifiziert wurden, und beide Methoden den Schlussgrad deutlich unterschätzen. Aufgrund der Signatur der Misch- und Laubbestände werden diese zum Stratum des gering beschirmten Nadelholzes gerechnet und der Schlussgrad mit dieser Regression bestimmt. Das Fazit ist, dass für die Bestimmung des Schlussgrades von Misch- und Laubwäldern die Trainingsgebiete von Nadelbeständen nicht nutzbar sind. Um mit den komplexen Methoden eine brauchbare Schätzung für den Beschirmungsgrad von Misch- und Laubbeständen zu erhalten, müssen geeignete Trainingsgebiete vorhanden sein und das Modell muss um ein oder mehrere Straten erweitert werden.

## 9 Ergebnisse der Klassifizierung

Für die Klassifizierung des Satellitenbildes vom 17.07.06 wurde die Methode der zwei linearen Regressionen verwendet, welche eine vorhergehende Stratifizierung durch die logistische Regression voraussetzt. Obwohl diese Methode nur brauchbare Schätzungen für Nadelbestände liefert, wurden auch Laub bzw. Mischwälder damit klassifiziert. Die Nicht-Waldflächen, die aus einer Waldkarte entnommen wurden, wurden ausmaskiert, um nur für den Wald Werte für den Beschirmungsgrad zu erhalten.

Für die Maskierung von Wald und Nicht-Wald wurde eine fernerkundungsbasierte Waldkarte verwendet, die vom Joanneum Research im Rahmen des von der ESA finanzierten Projektes GSE Forest Monitoring erstellt wurde. GSE Forest Monitoring ist ein internationales Projekt der ESA (European Space Agency) im Rahmen von Global Monitoring for Environment and Security (GMES) zur Entwicklung von globalen Monitoringsystemen. Diese Waldkarte basiert auf der international anerkannten Walddefinition der Food and Agriculture Organization (FAO) der vereinten Nationen. Diese Definition von 2004 besagt, dass Bestände eine Mindestgröße von 0,5 ha aufweisen müssen, um als Wald zu gelten, auch eine Mindestbreite von 20 m und eine Beschirmung von über 10% sind Voraussetzung. Diese Waldkarte mit der geometrischen Auflösung von 12,5 m ist mit einer Genauigkeit von über 95% besser als vergleichbare Karten (Gallaun, 2008[7]).

Nach der Klassifizierung des Satellitenbildes und der Ausmaskierung der unbestockten Flächen war weiters eine Berichtigung unrealistischer Schlussgrade notwendig. Da die Regressionsmethode auch Überschirmungsgrade von  $<0\%$  und  $>100\%$  liefert, mussten diese Werte detektiert und korrigiert werden. Ausschnitte dieser berichtigten Klassifikation werden in Folge dargestellt. Dabei sind die ursprünglich kontinuierlichen Überschirmungsgrade zu 10% Schritten zusammengefasst.

In Abbildung 37(a) ist ein nordexponierter Waldteil in einem CIR Luftbild dargestellt. Das weiße Polygon zeigt ein Referenzgebiet mit einer Beschirmung von 39%. Dieses Gebiet ist außerdem in der Klassifizierung des Satellitenbildes eingezeichnet. Die zur Interpretation nötige Legende, welche die einzelnen Farben den Schlussgradbereichen gegenüberstellt, steht neben der Beschirmungskarte. Die in der Karte vorkommende schwarze Farbe illustriert unbestockte Flächen. Innerhalb des Referenzgebietes wurden die meisten Pixel der Klasse 40 - 50% zugewiesen und ein Teil repräsentiert die Klasse mit dem Schlussgrad von 30 - 40%. Mittelt und vergleicht man die Werte der Klassifizierung mit dem beobachteten Beschirmungsgrad, ist die gute Übereinstimmung der

## 9 Ergebnisse der Klassifizierung




Abbildung 37: Waldbestand mit 39% Beschirmung

Referenzfläche zur Klassifizierung zu erkennen. Weiters ist im Luftbild eine Abnahme des Beschirmungsgrades in südlichöstlicher Richtung ersichtlich. Diese Erscheinung ist auch in der Karte durch den Farbverlauf von Orange bis Dunkelrot zu sehen.




Abbildung 38: Waldbestand mit 32% Beschirmung

In Abbildung 38 ist ein südexponierter Fichtenbestand mit einem Schlussgrad von 32% und dessen Klassifizierung dargestellt. Bei der Interpretation der Farbwerte der Karte ist zu erkennen, dass der Beschirmungsgrad des Referenzgebietes überschätzt wird, was die Mittelung der einzelnen Pixelergebnisse bestätigt. Weiters sind im Luftbild und in der Klassifizierung Variationen des Schlussgrades zu sehen. Auffichtungen wie die im Norden oder die im Südosten sind im Bild und in der Karte ersichtlich.

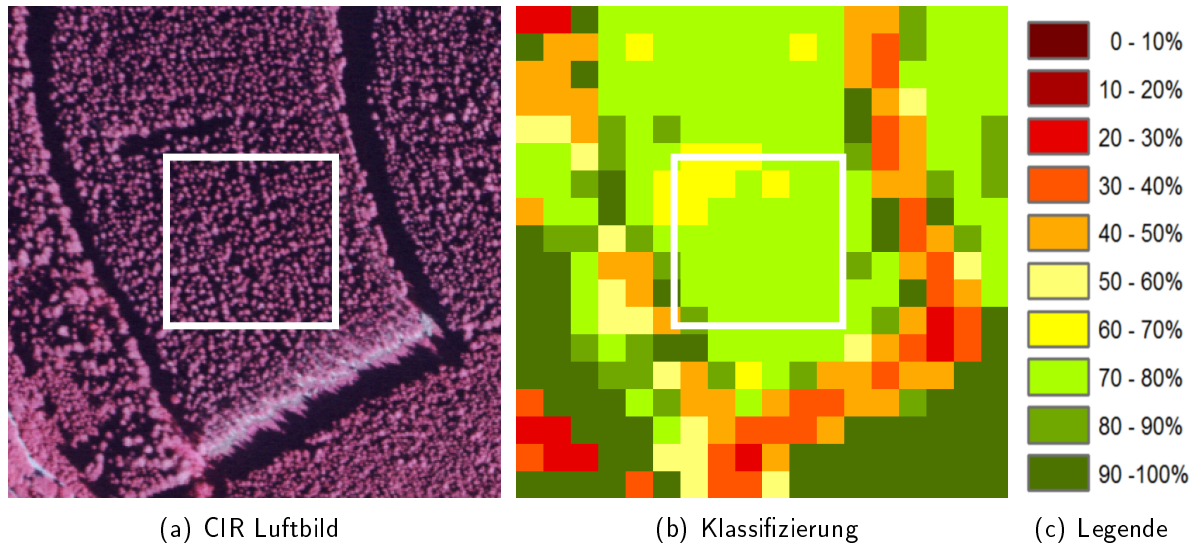


Abbildung 39: Waldbestand mit 66% Beschirmung

In Abbildung 39 ist ein homogener Fichtenbestand mit einer Beschirmung von 66% dargestellt. Die großflächig gleichmäßige Verteilung der Baumkronen ist auch in der Karte anhand der einseitig grünen Färbung zu erkennen. Da diese Farbe die Klasse mit dem Beschirmungsgrad zwischen 70-80% darstellt, ist zu erkennen, dass die tatsächliche Beschirmung geringfügig überschätzt wird. Östlich der Forststraße, die im Luftbild wegen des Schattens nur erahnbar ist, befindet sich ein Bestand mit ähnlichen Bestandesparametern, der auch in der Klassifizierung ähnliche Beschirmungsgrade liefert. Die Forststraße ist ebenso wie die Kahlschlagfläche in der Karte durch einen reduzierten Schlussgrad zu erkennen. Aufgrund der geringen Auflösung des Satellitenbildes und der Beschattung durch die Bäume enthält kein Pixel einen Überschirmungsgrad von Null. Ein Bestand, der sich in der Altersklasse von Stangenholz befindet, ist im südlichsten Bereich des Luftbildes zu sehen. Dieser sehr dichte Bestand ist auch in der Karte richtigerweise mit einem sehr hohen Beschirmungsgrad ausgewiesen.

Die Darstellungen in Abbildung 40 zeigen einen jungen Fichtenbestand im Luftbild und die Klassifizierung des Überschirmungsgrades aus dem Satellitenbild. Obwohl für die Klassifizierung des Satellitenbildes vom 17.07.06 nur Trainingsgebiete aus den Altersklassen Baumholz und Altholz verwendet wurden, wird der Beschirmungsgrad von 89% des jungen Bestandes sehr gut angenähert. Auch außerhalb des Referenzgebietes scheint die Karte plausibel. So weisen die Kahlschlagflächen im Westen und Süden des Referenzgebietes Überschirmungsgrade nahe Null auf, was in der Karte durch die roten Flächen ausgedrückt wird. Auch die älteren Bestände, die offensichtlich einen geringeren



## 9 Ergebnisse der Klassifizierung




Abbildung 40: Waldbestand mit 89% Beschirmung

Überschirmungsgrad als das Referenzgebiet aufweisen, sind in der Karte durch ihren geringeren Schlussgrad zu erkennen.




Abbildung 41: Waldbestand mit 67% Beschirmung

Das Luftbild in 41(a) zeigt einen Laubbestand, der zu einem geringen Teil mit Nadelbäumen durchmischt ist. Die nebenstehende Klassifizierung des Satellitenbildes weist gegenüber dem beobachteten Überschirmungsgrad eine große Abweichungen auf. Diese Erscheinung ist auch bei den anderen Laub bzw. Mischbeständen im klassifizierten Bild ersichtlich. Wie bereits im vorigen Kapitel festgestellt wurde, ist die Regressionsmethode in dieser Form ungeeignet den Überschirmungsgrad von Laub- und Mischbeständen zu

bestimmen.

Die Ausschnitte verdeutlichen die in Kapitel 8 getätigten Feststellungen. Die Regressionsmethode liefert bei geeignetem Datenmaterial sehr gute Schätzungen für die Beschirmung von jungen und alten Nadelbeständen. Für die Bestimmung des Überschirmungsgrades von Misch- und Laubbeständen ist diese Methode in dieser Form ungeeignet. Der Grund dafür ist, dass die Reflexion in Abhängigkeit von der Baumartenzusammensetzung ebenfalls stark variiert. Die größten spektralen Unterschiede zwischen Laub- und Nadelbeständen treten in der Vegetationsperiode im nahen Infrarot auf, jenem Kanal, mit dem hier der Überschirmungsgrad bestimmt wird. Diese multiplen Abhängigkeiten der Reflexion von den Bestandesparametern, können von dieser Methode nicht verarbeitet werden. Um auch für Misch- und Laubbestände eine wirklichkeitsnahe Beschirmung zu erhalten, müssten mehrere Modifikationen bei der Regressionsmethode durchgeführt werden.

## 10 Zusammenfassung und Ausblick

In dieser Arbeit wurde die Ableitung des Überschirmungsgrades aus hochauflösenden Satellitenbildern betrachtet. Für die Methode, die dazu verwendet werden sollte, bestand die Bedingung, dass die resultierende Beschirmung einem kontinuierlichen Wert entsprechen muss. Ausgehend von diesen Rahmenbedingungen wurden vier geeignete Methoden aufgezeigt und miteinander verglichen, die aufgrund von wissenschaftlichen Arbeiten, Signatur- und Regressionsanalyse gewählt wurden.

Diese Arbeit führte unter Anderem zum Schluss, dass für die genaue Ermittlung des Überschirmungsgrades von Nadelbeständen im Satellitenbild die einfache und die multiple lineare Regression unzureichend sind. Besonders bei dichten Beständen versagen die linearen Regressionen, da sie den Schlussgrad deutlich unterschätzen. Ähnlich große Abweichungen liefert die kNN Methode, wobei sich hier bei mittel beschirmten Beständen die größeren Unterschiede zu den beobachteten Schlussgraden zeigen. Das beste Ergebnis liefert die Regressionsmethode, bei der der Schlussgrad mit einer von zwei Regressionen erst nach einer Stratifizierung durch die logistische Regression bestimmt wird. Diese Erkenntnisse lassen sich durch den Verlauf der Reflexion in Abhängigkeit des Überschirmungsgrades erklären. Anfänglich sinken die Reflexionswerte mit steigendem Schlussgrad, ab einer gewissen Beschirmung ist ein erneuter Anstieg der Grauwerte zu erkennen. Die Ursache für diesen spezifischen Reflexionsverlauf ist der Schattenwurf der Baumkronen, die einerseits den Boden und andererseits auch Kronenteile verdunkeln. Während der Anteil des Kronenschattens mit zunehmendem Überschirmungsgrad linear steigt, entspricht der Verlauf des Anteils des Bodenschattens einer Funktion mit einem Maximum. Das Maximum und die Form der Funktion werden von der Sonnenelevation, der Exposition und der Hangneigung bestimmt. Der Reflexionsverlauf ist im nahen Infrarot am deutlichsten zu erkennen und bietet sich auch für die Erstellung der beiden Regressionsgeraden an. Die Tatsache, dass die Grauwerte der Kanäle im Verlauf unterschiedlich stark abfallen und ansteigen, ermöglicht die Unterscheidung zwischen den Straten der gering und hoch beschirmten Bestände, wozu sich die Methode der logistischen Regression anbietet.

Die Reflexion von Wald wird von mehreren Bestandesmerkmalen bestimmt, darunter sind die Baumartenzusammensetzung und das Bestandesalter von größtem Interesse. Die verschiedensten Kombinationen dieser Bestandesmerkmale können zu ähnlichen bzw. gleichen Reflexionswerten führen. Die Anwendung der Methoden auf andere Bestandesformen zeigte, dass auch Schlussgrade von Nadelwäldern in den Altersklassen bis

Stangenholz ausreichend genau klassifiziert werden. Die allgemein höhere Reflexion von jüngeren Beständen wirkt sich allerdings durch eine Überschätzung der Beschirmung aus. Da jedoch nach dem Jungwuchs, beginnend mit der Dickung, junge Bestände grundsätzlich ein dichtes Kronendach aufweisen, ist diese Überschätzung zu vernachlässigen. Die Baumartenzusammensetzung - im Besonderen die Mischung zwischen Laub- und Nadelbäumen - ist dagegen problematisch für die Bestimmung des Schlussgrades. Wie die Untersuchungen ergeben haben, sind die Reflexionen von gleich beschirmten Laub- und Nadelbeständen so verschieden, dass eine gemeinsame Klassifizierung mit Nadelholz unmöglich ist. Dieses Problem könnte man umgehen, indem man ein oder mehrere Straten für Laubholz einführt, anstatt der logistischen Regression eine multinomiale Regression für die Stratifizierung verwendet, und schlussendlich für jedes Stratum eine eigene lineare Regression für den Beschirmungsgrad bestimmt.

Abschließend ist anzumerken, dass eine simultane oder quasi simultane Bestimmung der Bestandesparameter Baumartenzusammensetzung, Bestandesalter und Überschirmungsgrad notwendig ist, da sie sich in der Reflexion gegenseitig überlagern. Die Verwendung der Regressionsanalyse für die Bestimmung der Bestandesparameter aus Satellitenbildern ist zweckmäßig, da sich die Bestandesparameter linear oder teilweise linear in der Reflexion erkennbar zeigen. Eine Kombination von Stratifizierung durch multinomiale Regression und folgender Klassifizierung der einzelnen Bestandesparameter durch mehrere einfache oder multiple lineare Regressionen wäre möglich, die Performance dieser Methode müsste jedoch noch untersucht werden.

## Literatur

- [1] BACKHAUS, KLAUS, BERND ERICHSON, WULFF PLINKE und ROLF WEIBER: *Multivariate Analysemethoden - Eine anwendungsorientierte Einführung*. Springer, 1996.
- [2] BUHK, RAINER: *Modellbasierte Schätzung von Kronendeckungsgrad und -transparenz aus Landsat TM5 Fernerkundungsdaten unter Berücksichtigung reliefbedingter Beleuchtungseffekte*. Doktorarbeit, Forstwissenschaftlichen Fakultät der Albert-Ludwigs-Universität, 2000.
- [3] CARREIRAS, JOAO M.B., JOSE M.C. PAREIRA und JOAO S. PAREIRA: *Estimation of tree canopy cover in evergreen oak woodlands using remote sensing*. *forest Ecology and Management*, 223:45–53, 2006.
- [4] EFRON, BRADLEY und GAIL GONG: *A Leisurely Look at the Bootstrap, the Jack-knife, and Cross-Validation*. *The American Statistician*, 37:36–48, 1983.
- [5] FORSTGESETZ, (BGBL. NR. 440/1975 I.D.G.F.): *Bundesgesetz, mit dem das Forstwesen geregelt wird*.
- [6] FRANCO-LOPEZ, HECTOR, ALAN R. EK und MARVIN E. BAUER: *Estimation and mapping of forest stand density, volume, and cover type using the k-nearest neighbors method*. *Remote Sensing of Environment*, 77:251–274, 2001.
- [7] GALLAUN, HEINZ, STEPHANIE LINSER, MARTIN HÖLZL und MATHIAS SCHARDT: *Digitale Waldkarte von Österreich*. *Forstzeitung - Österreichischer Agrarverlag*, Wien, 119 (11)(11):8–10, November 2008.
- [8] GALLAUN, HEINZ, MATHIAS SCHARDT und STEFANIE LINSER: *Remote Sensing Based Forest Map of Austria and Derived Environmental Indicators*. In: *Forestsat 2007 Montpellier, France*, Seite 5, 2007.
- [9] HILDEBRANDT, GERD: *Fernerkundung und Luftbildmessung*. Wichmann, 1996.
- [10] HÄRDLE, WOLFGANG: *Regression*. Springer, 2007.
- [11] IVITS, EVA, ALISTAIR LAMB, FILIP LANGAR, SCOTT HEMPHILL und BARBARA KOCH: *Orthogonal transformation of segmented spot5 images: Seasonal and geographical dependence of the tasseled cap parameters*. *Photogrammetric Engineering & Remote Sensing*, 74(11):1351–1364, 2008.

- [12] KANE, VAN R., ALAN R. GILLESPIE, ROBERT MCGAUGHEY, JAMES A. LUTZ, KEVIN CEDER und JERRY F. FRANKLIN: *Interpretation and topographic compensation of conifer canopy self-shadowing*. Remote Sensing of Environment, 112:3820–3832, 2008.
- [13] KAUTH, R. J. und G. S. THOMAS: *The Tasselled Cap - A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT*. Proceedings of the Symposium on Machine Processing of Remotely Sensed Data, 1976.
- [14] MINNAERT, M.: *The reciprocity principle in lunar photometry*. Astrophysical Journal, 93:403 – 410, 1941.
- [15] ROSEMA, A., W. VERHOEF, H. NOORBERGEN und J.J. BORGESIU: *A new forest light interaction model in support of forest monitoring*. Remote Sensing of Environment, 42:23–41, 1992.
- [16] RUPERT, MÜLLER, THOMAS KRAUSS, MANFRED LEHNER, PETER REINARTZ, JÖRGEN FORSGREN, GÖTE RÖNNBÄCK und ÅKE KARLSSON: *IMAGE2006 European Coverage, Methodology and Results*, 05 2009.
- [17] SACHS, LOTHAR: *Angewandte Statistik*. Springer, 2006.
- [18] SCHARDT, MATHIAS: *Beobachtung von Waldschäden im niedersächsischen Harz mit Methoden der Fernerkundung und Aufbau eines Waldinformationssystems*, 1997. TU Berlin, (Habil. Schr.).