Systematische Evaluierung verschiedener Datentransformationen für die Klassifizierung von Wald-, Offenland- und Latschen-Flächen in den Bayerischen Alpen

MASTERARBEIT

an der Universität für Bodenkultur Wien

Department für Raum, Landschaft und Infrastruktur (RaLI)

Institut für Vermessung, Fernerkundung und Landinformation (IVFL)

eingereicht von

Philipp Toscani

betreut von

Univ.Prof. Dr.rer.nat. Clement Atzberger

unter Mitbetreuung von

Markus Immitzer, MSc.

Since light travels faster than sound,

some people appear bright until you hear them speak.

[unknown]

Ich möchte mich bei allen bedanken, die bei der Entstehung dieser Masterarbeit beteiligt waren und mich während meines gesamten Studiums unterstützt haben. Besonderer Dank gilt:

- Meiner Mutter Johanna, die schon an mich geglaubt hat, bevor ich es selber getan habe.
- Meiner Frau Julia und unserer Luna, die immer ein offenes Ohr für mich haben, immer.
- Meinem Vater Thomas, der mehr für mich getan hat, als ihm vielleicht bewusst ist.
- Meinen Schwiegereltern Roswitha und Ernst, die mich in ihr Heim und die Familie aufgenommen haben und uns vieles ermöglicht haben.
- Meiner Großmutter Liese, die es schon immer gab und die seitdem für mich da ist.
- Meinem Bruder Clemens, Babsi und Emilian. Ohne Euch hätte ich vieles nicht erreicht.
- Meiner gesamten Familie, die mich immer dann unterstützt hat, wenn es erforderlich war.
- Meinen Freunden, die vielleicht nicht immer den richtigen Rat zur Verfügung hatten, aber es immerhin versucht haben.
- Clement Atzberger, für die fachliche Betreuung dieser Arbeit und die vielen Inputs.
- Markus Immitzer, der nicht nur die Aufgaben eines Mitbetreuers übernommen hat, sondern auch die eines Freundes.
- Allen MitarbeiterInnen des IVFL, die ein tolles Team sind und mir mit vielen Ratschlägen und freundlichen Worten zur Seite standen.

Verwendete Softwarepakete

• Definiens Developer 7.0 TM, Windows 7, 64bit

Abkürzung: Definiens

- ESRI© ArcMap[™], ArcGIS Desktop 9.3.1 ServicePack 2, Windows XP Abkürzung: ArcMap
- MATLAB® R2011b, Windows 7, 64bit

Abkürzung: MATLAB

• The R Project Version 2.15.1 (2012), Windows 7, 64bit und Linux, 64bit

Abkürzung: [R]

Kurzfassung

Die computergestützte Klassifizierung von Landbedeckungsarten großer Arbeitsgebiete ist eine gängige Fragestellung der Fernerkundung.

In Abhängigkeit der Aufgabenstellung und des vorhandenen Datenmaterials ist die Trennung von Klassen unterschiedlich genau möglich. Um die Klassifizierungsgenauigkeit zu erhöhen, können durch Datentransformationen wie beispielsweise Vegetationsindizes und Texturmaße zusätzliche Eingangsvariablen gewonnen werden.

Die Datengrundlage für diese Arbeit stellen digitale Orthofotos in den Bayerischen Alpen mit vier spektralen Kanälen (nahes Infrarot, Rot, Grün, Blau) in fünf Auflösungen (20 cm, 100 cm, 100 cm focal median, 200 cm, 500 cm) dar. Der Einfluss von spektraler und texturaler Information auf die Klassifizierungsgenauigkeit, die Auswirkungen von Variablenauswahl, Umfang und Größe der Trainingsobjekte sowie die Übertragbarkeit des Klassifikators auf andere Testgebiete werden getestet.

Die Klassifizierung erfolgte objektbasiert mittels Random Forest Klassifikator in sechs Klassen: Nadelholz, Laubholz, Latsche (*Pinus mugo*), Offenland Gras, Offenland Fels und Schatten. Objekte die mehr als zwei Klassen aufwiesen, wurden vom Test ausgeschlossen.

Die höchste Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes bei Verwendung der vier spektralen Kanäle nahes Infrarot, Rot, Grün und Blau beträgt 77.4 %, bei Nutzung aller erzeugten Variablen 85.5 % und durch Auswahl der nach MDA-Wichtigkeit 300 wichtigsten aller erzeugten Variablen 86.1 %.

Eine Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes von 84.2 % kann durch Variablenkombination aus spektraler Information und texturaler Information mit Graylevel Cooccurence Matrix Ansatz nach Haralick et al. sowie spektraler Information und texturaler Information aus der Diskrete Stationäre Wavelet Transformation erzielt werden.

Die höchsten Produzenten- und Nutzergenauigkeiten erzielen die Klassen Offenland Fels und Schatten, die geringsten Laubholz. Die häufigsten Fehlklassifizierungen entstehen zwischen den Klassen Nadelholz, Laubholz und Latsche.

Stichworte: Random Forest, Graylevel Co-occurence Matrix, Diskrete Stationäre Wavelet Transformation, Objektbasierte Klassifizierung, Grauwertverteilung im Objekt

Abstract

The computer-assisted landcover classification of large areas is a common task in remote sensing.

Depending from the individual question and the available inputdata, classes reach different levels of separability. For higher overallaccuracies of classification, additional features like vegetation indices or texture features can be produced through datatransformation.

The data set for this thesis are four chanel (near Infrared, red, green, blue) digital aerial images of the bavarian alps with in five resolutions (20 cm, 100 cm, 100 cm focal median, 200 cm, 500 cm). The influence of different aspects of spectral and textural features to the classificationresult, the impact of featureselection, amount and size of trainingsamples and the transferability of the classificator to bordering testsites are investigated.

For classification an object based approach using Random Forest classifier was chosen. Six classes were classified: coniferous trees, broad-leafed trees, mountain pine (*Pinus mugo*), grasland, rock and shadows. Objects containing more than two classes were left out of the systematic test.

The highest overallaccuracy of the independend testdata using the spectral information from all four channels near infrared, red, green and blue reached 77.4 %. Using all features a result of 85.5 %, through featureselection of the 300 most important of all features, rated by their MDA importance, 86.1 % was reached.

Using spectral features and texture features produced with the graylevel co-occurence matrix approach and the discrete stationary wavelet transform, overallaccuracies of 84.2 % of the independend testdataset were reached.

The highest Producer- and Useraccuracies were reached for the classes rock and shadow, the lowest for the class broad-leafed trees. Missclassification occured most frequently between the classes coniferous trees, borad-leafed trees and mountain pine.

Keywords: Random Forest, Graylevel co-occurence Matrix, discrete stationary wavelet transform, object based classification, grayvalue distribution in the object.

Inhaltsverzeichnis

1	Ein	Einleitung		
1.1 Ausga			gangssituation	1
1.2 Ziele der Arbeit			e der Arbeit	1
	1.3	Vorg	gehensweise	2
2	The	eoretis	che Grundlagen	3
	2.1	Bild	slassifizierung	3
	2.1.	1	Unüberwachte Klassifizierung	3
	2.1.	2	Überwachte Klassifizierung	4
	2.1.	3	Random Forest Klassifikator	4
	2.1.	4	Trainingsphase	6
	2.2	Eing	angsvariablen	6
	2.2.	1	Vegetationsindizes	6
	2.2.	2	Texturmaße	8
	2.2.	3	Grauwertverteilung im Objekt	13
	2.2.	4	Variablenauswahl und Transformation	14
3	Dat	engru	ndlage	15
4	Met	thodik	ζ	18
	4.1	Erze	ugung des Referenzdatensatzes	18
	4.1.	1	Segmentierung	18
	4.1.2		Referenzdatensatz	19
	4.1.	3	Trainingsdatensatz, Testdatensatz	21
	4.2	Bezu	ngsfläche der Variablenerzeugung	22
	4.2.	1	Bezugsfläche Objekt	23
	4.2.	2	Moving Window Ansatz	24
	4.3	Erste	ellung der Eingangsvariablen	26
	4.3.	1	Spektrale Information der Kanäle nahes Infrarot, Rot, Grün und Blau	27
	4.3.	2	Vegetationsindizes	28
	4.3.	3	Texturmaße	28
	4.3.	4	Grauwertverteilung im Objekt	32
	4.4	Syste	ematischer Test der Eingangsvariablen	32
	4.5	Such	e nach geeigneten Variablenkombinationen mittels Zufallsauswahl	33
	4.6	Ausv	virkung der Trainingsobjekte	33
	4.6.	1	Anzahl der Trainingsobjekte	34
	4.6.	2	Größe der Trainingsobjekte	34
	4.6.	3	Unterschied zwischen den Trainingsdatensätzen	34
	4.7	Anw	endbarkeit des trainierten Klassifikators auf angrenzende Testgebiete	34

5		Erg	gebnis	SSE			
	5.1	l	Refe	erenzklassifizierung			
5.1.1		1	Standardset				
5.1.2		2	Alle Eingangsvariablen				
	5.2	2	Syst	ematischer Test der Eingangsvariablen	40		
		5.2.	1	Gruppe Vegetationsindizes	40		
		5.2.	2	Gruppe Textur Graylevel Co-occurence Matrix nach Haralick mit	Moving		
		Win	ndow	basiertem Ansatz	43		
		5.2.	3	Gruppe Textur Graylevel Co-occurence Matrix nach Haralick mit objekt	oasierter		
		Ans	satz n	nit fixen GrayLimits	45		
		5.2.	4	Gruppe Textur Graylevel Co-occurence Matrix nach Haralick mit objekt	oasierter		
		Ans	satz n	nit dynamischen GrayLimits	47		
		5.2.	5	Gruppe Textur Diskrete Stationäre Wavelet Transformation	49		
		5.2.	6	Gruppe Grauwertverteilung im Objekt	51		
		5.2.7 Vergleich der Gruppen			52		
		5.2.	5.2.8 Klassifizierung mit allen Eingangsvariablen				
	5.2.9 5.2.10 5.2.11		5.2.9 Variablenauswahl anhand der MDA Wichtigkeit				
			10	Klassifizierungsergebnisse der Hauptklassen	58		
			11	Analyse der Klassenzuweisung der Objekte	60		
	5.3	3	Such	he nach geeigneten Variablenkombinationen mittels Zufallsauswahl	63		
	5.4	1	Aus	wirkung der Trainingsobjekte	67		
		5.4.	1	Anzahl der Trainingsobjekte	67		
		5.4.	2	Größe der Trainingsobjekte	68		
		5.4.	3	Unterschied zwischen den Trainingsdatensätzen	70		
	5.5	5	Anv	vendbarkeit des trainierten Klassifikators auf angrenzende Testgebiete	74		
6		Dis	kussi	on	77		
	6.1	l	Auf	lösung der Ausgangsbilder	77		
	6.2	2	Aus	wahl von Trainingsobjekten	77		
	6.3	3	Para	ameter der Texturmaße mit GLCM Ansatz nach Haralick	78		
	6.4	1	Unt	erschiede von Texturmaßen	83		
	6.5	5	Erke	enntnisse bezüglich Variablenauswahl	84		
7		Zus	samm	enfassung und Schlussfolgerungen	86		
8		Lite	eratur	verzeichnis			
9	9 AnhangI						

Tabellenverzeichnis

Parameter: A: (Haralick et al. 1973), B: (Metzler et al. 2002), C: (Baraldi & Parmiggiani 1995), D: (Cossu, 1988, zit. nach: Soh & Tsatsoulis 1999), E: (Soh & Tsatsoulis 1999), F: (Shaban & Dikshit 2001)10
Tabelle 2: Für den systematischen Test verwendete Wavelet Familien mit jeweils getestetem Wavelet sowie der Maßstabs- und Waveletfunktion des Wavelets (Wasilewski 2012). 12
Tabelle 3: Korrelationskoeffizient (R) der Kanäle nahes Infrarot, Rot, Grün und Blau des 100cm Bildes
Tabelle 4: Bezeichnung, Häufigkeit, Mittlere Größe (Median) und Standardabweichung der jeweiligen Klassen des Referenzdatensatzes
Tabelle 5: Anzahl von Objekten der jeweiligen Klasse im Trainings- bzw. Testdatensatz
Tabelle 6: Anzahl der zu berechnenden Fenster je Variable und Kanal
Tabelle 7: Am Boden erfasste Fläche in Abhängigkeit von Moving Window Größe und Bodenauflösung
Tabelle 8: Einteilung der für den Test erstellten Variablen in Gruppen, Untergruppen und Variablensets pro Auflösung mit Angabe der Anzahl von Variablen je Variablenset (N)26
Tabelle 9: 10 wichtigste Variablen nach MDA Wichtigkeit bei Klassifizierung mit allen Variablen aller Gruppen der jeweiligen Auflösung
Tabelle 10: Übersicht über das Klassifizierungsergebnis des unabhängigen Testdatensatzes mit den Variablen des Standardsets und allen Variablen des jeweiligen Eingangsbildes. Klassifizierungsgenauigkeit Trainingsdatensatz in Klammer
Tabelle 11: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes aller Variablen, 10 wichtigste Variablen nach MDA zuzüglich des Standardsets und 10 wichtigste Variablen nach MDG zuzüglich des Standardsets. Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Werte in [%]40
Tabelle 12: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes des besten Variablensets zuzüglich Standardset, aller Variablen der Gruppe zuzüglich Standardset, 10 wichtigste Variablen nach MDA zuzüglich Standardset und 10 wichtigste Variablen nach MDG zuzüglich Standardset. Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Werte in [%]. Vegetationsindex mit höchstem Ergebnis in zweiter Zeile

Tabelle 1: Die laut jeweiliger Studie relevanten Parameter der von (Haralick et al. 1973) vorgestellten Textur-

- Tabelle 17: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes des besten Variablensets der Untergruppe zuzüglich Standardset, aller Variablen der Untergruppe zuzüglich Standardset, 10 wichtigste Variablen der Untergruppe nach MDA zuzüglich Standardset und 10 wichtigste

- Tabelle 39: Variablen des höchsten Klassifizierungsergebnisses bei zufälliger Variablenauswahl aus allen Variablen aller Auflösungen ohne Moving Window (MW) Ansatz......III
- Tabelle 41: Konfusionsmatrizen ,Standardset⁶. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... SchattenX
- Tabelle 43: Konfusionsmatrizen ,Vegetationsindizes'. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... SchattenXII
- Tabelle 44: Konfusionsmatrizen ,Textur GLCM mit MW Ansatz⁴. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten......XIII
- Tabelle 45: Konfusionsmatrizen ,Textur GLCM objektbasiert, fixe GrayLimits'. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... SchattenXIV
- Tabelle 46: Konfusionsmatrizen ,Textur GLCM objektbasiert, dyn. GrayLimits⁶. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... SchattenXV
- Tabelle 47: Konfusionsmatrizen ,Textur DSWI^{*}. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... SchattenXVI
- Tabelle 48: Konfusionsmatrizen ,Datadistribution'. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... SchattenXVII

Abbildungsverzeichnis

Abbildung 1: Prinzip der GrayLevel Co-occurence Matrix für ein Bild mit vier Grauwertstufen. GLCM für horizontale Nachbarschaft erstellt
Abbildung 2: Beispielhafte Anwendung des 'dmey' Wavelets auf einen Ausschnitt des Untersuchungsgebietes in drei Durchgängen
Abbildung 3: Lage des Untersuchungsgebietes des Projektes "Erstellung einer Wald/Offenlandmaske aus digitalen Orthofotos" und der Testgebiete der Masterarbeit im deutschen Bundesland Bayern. Detailansicht der Lage der Testgebiete der Masterarbeit im bayerischen Teil des Karwendelgebirges
Abbildung 4: Übersicht über das für den Test verwendete Gebiet (Testgebiet A), bestehend aus zwei Orthofotos. Ausdehnung 2000×4000 m
Abbildung 5: Vergleich der fünf verwendeten Auflösungen (Falschfarbbilder mit Kanälen IR, R, G). Bildausschnitt fix
Abbildung 6: Größenverteilung aller 4549 Polygone mit Größen von 100 - 26849 m ²
Abbildung 7: Beispiele für Polygone der sieben Klassen
Abbildung 8: Referenzklassifizierung des Testgebietes A in 7 Klassen (a) und 5 Klassen (b)
Abbildung 9: Aufteilung der Objekte des Testgebietes A in einen unabhängigen Trainings- und Testdatensatz durch zufällige Auswahl. Löcher sind Objekte der Klasse "Sonstige" die vom systematischen Test ausgeschlossen wurden
Abbildung 10: Prinzip der objektbasierten Variablenerstellung. Direkt aus dem Eingangsbild erstellte Variablen (grüner Weg) und mittels Zwischenberechnung erstellte Variablen (blauer Weg)
Abbildung 11: Prinzip der Berechnung (z.B. Mittelwert) der Werte (z.B. Grauwerte des IR Kanales) zu einem Wert je Objekt. Zahl = Grauwert
Abbildung 12: a) Prinzip des Moving Window Ansatzes. b) Randpixelproblem beim Moving Window Ansatz. Zahl = Grauwert
Abbildung 13: Erstellung der Variablen der Gruppe Spektrale Information
Abbildung 14: Erstellung der Variablen der Gruppe Vegetationsindizes
Abbildung 15: Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit MW basiertem Ansatz
Abbildung 16: Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit objektbasiertem Ansatz und fixen GrayLimits
Abbildung 17: Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit objektbasiertem Ansatz und dynamischen GrayLimits
Abbildung 18: Erstellung der Variablen der Gruppe DSWT-basierte Texturmaße
Abbildung 19: Erstellung der Variablen der Gruppe Grauwertverteilung im Objekt (Datadistribution)
Abbildung 20: Übersicht über die Testgebiete B und C sowie deren Lage zu Testgebiet A. Größe der Testgebiete B und C jeweils 2000×2000 m
Abbildung 21: Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes in Testgebiet A der Variablensets zur Festlegung des Standarddatensets, getrennt nach den fünf Eingangsbildern
Abbildung 22: Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes in Testgebiet A aller Eingangsvariablen, getrennt nach den fünf Eingangsbildern
Abbildung 23: Korrelation der Vegetationsindizes NDVI und AVI bezogen auf Werte der Objekte (Mittelwert des VIs im Objekt) für das 20 cm Bild. Korrelationskoeffizient 0.794

- Abbildung 38: Verteilung der 100 wichtigsten Variablen der Zufallsauswahl aus allen Variablen aller Auflösungen ohne Moving Window Ansatz nach Gruppen. a) 5 Zufallsvariablen, b) 10 Zufallsvariablen, c) 15 Zufallsvariablen, d) 20 Zufallsvariablen DAT ... Datadistribution, S/VI ... Spektral und Vegetationsindizes, GLCM 2 ... GLCM Texturmaße Objekt mit dyn. GrayLimits, GLCM 3 ... GLCM Texturmaße Objekt mit fixen GrayLimits.

- Abbildung 41: Auswirkung der Anzahl von zufällig aus den 50 größten Objekten je Klasse gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes. Eingangsbild 20cm, Variablen des Standardsets, Boxplot von 1000 zufälligen Kombinationen von Trainingsobjekten....69
- Abbildung 42: Auswirkung der Anzahl von zufällig aus den 50 kleinsten Objekten je Klasse gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes. Eingangsbild 20cm, Variablen des Standardsets, Boxplot von 1000 zufälligen Kombinationen von Trainingsobjekten....69

- Abbildung 55: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 5 Variablen aus allen Variablen......V
- Abbildung 56: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 10 Variablen aus allen Variablen......VI
- Abbildung 57: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 15 Variablen aus allen Variablen......VI

Abbildung 59: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 5 Variablen aus allen Variablen ohne MW Ansatz......VII

Abbildung 62: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 20 Variablen aus allen Variablen ohne MW Ansatz

- Abbildung 63: Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes der Variablensets zuzüglich Standardset der Gruppe Vegetationsindizes, getrennt nach den fünf Eingangsbildern......XVIII
- Abbildung 64: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 3x3 Pixel, getrennt nach den fünf Eingangsbildern......XVIII
- Abbildung 65: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 7x7 Pixel, getrennt nach den fünf Eingangsbildern......XIX
- Abbildung 66: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 11x11 Pixel, getrennt nach den fünf Eingangsbildern......XIX
- Abbildung 67: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 21x21 Pixel, getrennt nach den fünf Eingangsbildern......XX
- Abbildung 68:Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 25x25 Pixel, getrennt nach den fünf Eingangsbildern......XX
- Abbildung 69: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 35x35 Pixel, getrennt nach den fünf Eingangsbildern......XXI
- Abbildung 70: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 51x51 Pixel, getrennt nach den fünf Eingangsbildern......XXI
- Abbildung 71: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 8 und GrayLimits [0 255], getrennt nach den fünf Eingangsbildern.....XXII
- Abbildung 72: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 16 und GrayLimits [0 255], getrennt nach den fünf Eingangsbildern.....XXII
- Abbildung 73: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 32 und GrayLimits [0 255], getrennt nach den fünf Eingangsbildern......XXIII
- Abbildung 74: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 64 und GrayLimits [0 255], getrennt nach den fünf Eingangsbildern......XXIII
- Abbildung 75: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 4 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern......XXIV
- Abbildung 76: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 5 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern......XXIV

- Abbildung 77: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 7 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern......XXV
- Abbildung 78: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 10 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern......XXV
- Abbildung 79: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 16 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern......XXVI

- Abbildung 83: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit diskreter stationärer Wavelet Transformation (DSWT) berechnet mit dem dmey Wavelet aus der Discrete Meyer Waveletfamilie, getrennt nach den fünf Eingangsbildern.....XXVIII
- Abbildung 84: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Grauwertverteilung im Objekt (Datadistribution), getrennt nach den fünf Eingangsbildern.....XXVIII
- Abbildung 85: Durch die jeweilige Variable für die Objekte des Testgebietes A ermittelten Werte der 10 wichtigsten Variablen nach MDA Wichtigkeit bei Klassifizierung mit allen Variablen des 20 cm Bildes als Karte dargestellt......XXIX
- Abbildung 86: Durch die jeweilige Variable für die Objekte des Testgebietes A auf dem 20 cm Bild ermittelten Werte von 12 unterschiedlichen Variablen.....XXX

1 Einleitung

1.1 Ausgangssituation

Die Möglichkeit, Landbedeckungsarten aus Luftbildern, Orthofotos und Satellitenbildern zu bestimmen, ist eine der Kernkompetenzen der Fernerkundung. Da die visuelle Klassifizierung großer Gebiete mit sehr hohem Zeitaufwand verbunden ist, wird versucht die Klassifizierung computergestützt durchzuführen und die manuelle Tätigkeit auf das Training des Klassifikationsverfahrens zu beschränken.

Den Ausgangspunkt für diese Arbeit stellt das Projekt "Erstellung einer Wald/Offenlandmaske aus digitalen Orthofotos" am Institut für Vermessung, Fernerkundung und Landinformation (IVFL) der Universität für Bodenkultur Wien (BOKU) mit dem Ziel, Waldflächen der Bayerischen Alpen in die Klassen Wald, Offenland und Latsche einzuteilen, dar. Die Ergebnisse dieser Wald/Offenlandmaske stehen als Eingangsdaten für viele Fragestellungen, wie Beispielsweise Untersuchungen im Rahmen von Natura 2000 Schutzmaßnahmen, zur Verfügung. Dieses Projekt wurde mit dem Softwarepaket Definiens Developer 7 umgesetzt. Zur objektbasierten Klassifizierung wurden vier spektrale Kanäle sowie Texturmaße nach dem Gray Level Co-occurence Matrix Ansatz von Haralick et al. (1973), welcher in Punkt 2.2.2.1 beschrieben wird, herangezogen.

Dabei stellte sich heraus, dass trotz verschiedener Eingangsparameter (z.B. verschiedene Layer und Parameter) und Klassifikation mittels Nearest Neighbour Verfahren als auch anhand von Membership Functions bei der Methodenentwicklung eine gewünschte Klassifizierungsgenauigkeit von größer 90 % nicht erreicht werden konnte. Dadurch war ein hoher Aufwand für die visuelle Nachbearbeitung erforderlich.

1.2 Ziele der Arbeit

Ausgehend von dem im vorigen Punkt beschriebenen Projekt, beschäftigt sich diese Arbeit mit dem Erstellen geeigneter Eingangsvariablen für die Klassifizierung der zur Verfügung gestellten Orthofotos.

Gesucht sind Eingangsvariablen, welche folgende drei Kriterien erfüllen: Verbesserung der Klassifizierungsgenauigkeit, schnelle Berechnung der Variablen und Auswirkung einzelner Variablen auf das Ergebnisse.

Die Verbesserung des Klassifizierungsergebnisses soll gleichzeitig auch die erforderliche Nachbearbeitungszeit für solche Fragestellungen reduzieren.

Die schnelle Berechnung von Variablen ist vor allem im Zusammenhang mit hochauflösenden Bildern ein wichtiger Punkt.

Im Zuge des systematischen Tests wird die Auswirkung einzelner Einstellungen bei der Gewinnung von Eingangsvariablen der jeweiligen Datentransformation auf das Klassifizierungsergebnis untersucht, um für zukünftige Fragestellungen über eine geeignete Vorgehensweise zu verfügen.

1.3 Vorgehensweise

Die Vorgehensweise dieser Arbeit lässt sich grob in fünf Schritten beschreiben:

- 1.) Segmentierung des Testgebietes
- 2.) Erstellen eines Referenzdatensatzes
- 3.) Erzeugung von Eingangsvariablen
- 4.) Überwachte Klassifizierung
- 5.) Evaluierung der Ergebnisse

Nach der Segmentierung des Testgebietes (vgl. Punkt 4.1.1) und dem Anlegen eines Referenzdatensatzes (vgl. Punkt 4.1.2) erfolgt die objektbasierte Erzeugung von Eingangsvariablen (vgl. Punkt 4.2). Die überwachte Klassifizierung erfolgt wie in Punkt 2.1.3 beschrieben mittels Random Forest (RF) Klassifikator. Dazu wird der RF Klassifikator anhand eines Trainingsdatensatzes trainiert und anhand eines unabhängigen Testdatensatzes evaluiert (vgl. Punkt 4.1.3).

2 Theoretische Grundlagen

2.1 Bildklassifizierung

(Lillesand et al. 2004, 550f) definiert die Aufgabe der Bildklassifizierung als die automatische Zuordnung eines Pixels zu einer Landbedeckungsklasse. Die numerischen Werte jedes Pixels der multispektralen Daten bildet dabei die Basis für die Kategorisierung.

Zusätzlich zu den spektralen Informationen können auch weitere Variablen mit einbezogen und unterschiedlich kombiniert werden.

Mustererkennung auf spektraler Basis klassifiziert jedes Pixel anhand der spektralen Information.

Mustererkennung auf räumlicher Basis berücksichtigt zusätzlich die Beziehung zu den benachbarten Pixel. Dabei werden Aspekte wie Textur, Distanz, Größe, Form und wiederholtes Auftreten erfasst, mit dem Ziel Informationen zu generieren, welche bei der visuellen Klassifizierung vom Bearbeiter erfasst werden. Die räumliche Mustererkennung ist viel rechenintensiver als spektrale Mustererkennung.

Mustererkennung auf Basis zeitlicher Veränderung nützt Änderungen der spektralen Information im Laufe der Zeit für die Zuweisung des Klasse. Für diese Arbeit scheidet diese Variante der Mustererkennung aus, da kein entsprechendes Bildmaterial zur Verfügung steht.

Mustererkennung auf der Basis richtungsabhängiger Information leitet aus der über das Bild gesehen stark variierende Aufnahmerichtung Information ab, welche zur Klassifizierung genutzt werden kann (Koukal & Atzberger 2012; Schlerf & Atzberger 2012).

Die Klassifizierung von hochauflösendem Bildmaterial ist bei pixelbasierten Ansätzen sehr rechenintensiv und kann bei manchen Klassifizierungsansätzen zu geringer Klassifizierungsgenauigkeit führen. Eine Alternative zur pixelbasierten Klassifizierung stellt die objektbasierte Klassifizierung (OBIA) dar. Bei dieser werden durch Segmentierung gleichartige Flächen zu Objekten zusammengefasst. Weitere Analysen der spektralen Information sowie mögliche Datentransformationen finden innerhalb der Objekte statt (Castilla & Hay 2008). Die Eignung des objektbasierten Ansatzes zur Klassifizierung von hochauflösendem Bildmaterial wurde schon in diversen Studien bestätigt (Yu et al. 2006; Castilla & Hay 2008; Mallinis et al. 2008).

2.1.1 Unüberwachte Klassifizierung

Ziel der unüberwachten Klassifizierung bzw. der Cluster-Analyse ist eine Zuordnung der einzelnen Pixel zu Klassen ähnlicher spektraler Eigenschaften. Da über die Bedeutung der Klassen nichts bekannt sein muss, werden auch keine Trainingsgebiete oder Referenzdaten benötigt (Albertz 2009, 158). Algorithmen dieser Familien untersuchen die spektrale Information eines Bildes und fassen sie zu spektral voneinander trennbaren Klassen. Dabei wird vorausgesetzt, dass die Werte innerhalb einer Klasse (Landbedeckungsart) näher zusammen liegen und sich von einer anderen Klasse deutlich abtrennen. Die so entstandenen Klassen müssen anschließend auf deren Information geprüft werden (Lillesand et al. 2004, 573f).

Häufig wird diese Art der Datenanalyse nicht als eigenes Verfahren angewandt, sondern als Vorbereitung einer überwachten Klassifizierung (Albertz 2009, 158).

2.1.2 Überwachte Klassifizierung

Die Zuordnung eines Pixels zu einer Klasse erfolgt bei der überwachten Klassifizierung auf Grund der Signatur von Trainingsgebieten. Dabei lässt sich der Ablauf der Klassifizierung in folgende Schritte aufteilen (Lillesand et al. 2004, 552ff; Richards 1993, 181f):

- 1. Trainingsschritt: Für die gewünschten Klassen werden Trainingsgebiete ausgewiesen. Daraus ergibt sich eine numerische Beschreibung der Klasse in diesem Bild.
- Klassifizierungsschritt: Jedem Pixel oder Objekt wird eine Klasse zugewiesen zu der es rechnerisch gehört. Bei manchen Klassifikatoren können Pixel nicht eindeutig einer Klasse zugewiesen werden und werden daher als unbekannt klassifiziert.
- 3. Ausgabeschritt: Je nach erforderlichem Ergebnis erfolgt die Ausgabe als Karte oder Tabelle

Für diese Arbeit wurde der Random Forest Klassifikator (Breiman 2001) gewählt.

2.1.3 Random Forest Klassifikator

Breiman (2001) entwickelte mit dem Random Forest (RF) Klassifikator ein nichtparametrische Klassifizierungsverfahren welches auf eine Vielzahl an Entscheidungsbäume aufbaut. RF wird zur Gruppe der Ensemble learning Klassifikatoren gezählt, welche durch die Kombination mehrerer Klassifikatoren die Erkennungsleistung steigern (Kroschel et al. 2011, 208). Dadurch stellt RF eine wesentliche Weiterentwicklung von traditionellen Entscheidungsbäumen dar (Rodriguez-Galiano et al. 2012b, 96).

Für die Durchführung der RF Klassifikation wird aus dem Referenzdatensatz durch zufälliges Ziehen mit Zurücklegen (Bootstrapping) ein Trainingsdatensatz mit der Größe des Referenzdatensatzes generiert. In diesem Datensatz sind ca. 2/3 der Referenzdaten enthalten mit welchen der Entscheidungsbaum aufgestellt wird. Die nicht gezogenen Daten (out-of-bag, OOB) dienen als Validierungsdatensatz und werden mit dem erstellten Entscheidungsbaum klassifiziert. Damit jedes einzelne Objekt mehrmals im OOB-Datensatz enthalten ist und somit klassifiziert wird, wird dieser Vorgang oftmals wiederholt. Neben der Anzahl der Entscheidungsbäume (=Durchläufe) ist für die Erstellung einer RF Klassifikation nur noch die Anzahl an Variablen pro Entscheidungsknoten festzulegen. Zum Unterschied zu herkömmliche Entscheidungsbäume werden bei RF nicht alle Variablen sondern nur eine zufällige Auswahl an Variablen für die einzelnen Entscheidungen verwendet (Breiman 2001, 11). Dadurch kommt es zu einer Reduktion

der Korrelation zwischen den Entscheidungsbäumen (Hastie et al. 2009, 587), wobei eine nicht zu hohe Anzahl an Variablen verwendet werden soll (Rodriguez-Galiano et al. 2012b, 98). Der Standardwert für die Anzahl an Variablen wird aus der Wurzel aller verfügbaren Variablen berechnet. Nachdem alle Bäume erstellt wurden, weisen alle Objekte mehrere Klassifikationsergebnisse auf, von welchen der Modus (majority vote) verwendet und mit der tatsächlichen Klasse verglichen wird. Dadurch erhält man einen unverfälschten Schätzwert der Klassifizierungsgenauigkeit (Breiman 2001, 11). Für die Annäherung dieses Wertes an die tatsächliche Klassifikationsgenauigkeit ist eine relativ hohe Anzahl an Entscheidungsbäumen (>500) sinnvoll (Hastie et al. 2009, 592; Rodriguez-Galiano et al. 2012b, 96).

Zusätzlich zum Klassifikationsergebnis liefert RF auch Aussagen über die Wichtigkeit der einzelnen Variablen für die Klassifikation und ist so für die Variablenselektion geeignet. Die zwei gängigsten Maße sind "Mean decrease in Gini" (MDG) und "Mean decrease in accuracy" (MDA) (Immitzer et al. 2012; Rodriguez-Galiano et al. 2012a; Hastie et al. 2009, 593).

Für die Berechnung der MDA-Wichtigkeit einer Variable werden deren Werte in den OBB-Daten zufällig verändert. Alle anderen Variablen bleiben dabei unverändert. Anschließend erfolgt die erneute Klassifikation der OBB-Daten. Der Vergleich der dabei erzielten Klassifikationsgenauigkeit mit der ursprünglichen ergibt die Wichtigkeit der jeweiligen Variable. Dieser Vorgang wird für jede Variable wiederholt.

MDG errechnet sich aus dem Anstieg des Gini-Trennwertes (Trennmaß in den jeweiligen Entscheidungsknoten) hervorgerufen durch die jeweilige Variable. Die Werte der einzelnen Entscheidungsknoten werden dabei innerhalb des Baumes summiert und über alle Bäume normalisiert (Breiman 2002, 29).

Immitzer et al. (2012) zeigten, dass bei der Variablenauswahl die MDA-Wichtigkeit bessere Ergebnisse erzielte als die MDG-Wichtigkeit und somit zu bevorzugen ist.

Für die Verwendung von RF in dieser Arbeit sprechen folgende Vorteile dieses Klassifikators (Hastie et al. 2009; Rodriguez-Galiano et al. 2012a; Breiman 2001; Breiman 2002):

- Zuverlässiges Klassifikationsergebnis mit nur wenig Feinabstimmung.
- Klassen müssen nicht normalverteilt sein und können auch mehrgipfelig sein.
- Effizientes Arbeiten mit vieldimensionalen Datensätzen.
- Robustes Verhalten bei Reduktion der Trainingsdaten.
- Zuverlässige Klassifikation bei stark heterogenen Klassen
- Grundsätzlich keine Neigung zum Overfitting.

Trotz aller Vorteile des RF Klassifikators ist bei großer Anzahl an Variablen ohne Aussagekraft eine Verschlechterung des Ergebnisses zu erwarten (Hastie et al. 2009).

2.1.4 Trainingsphase

Lillesand et al. (2004, 562ff) beschreiben die Trainingsphase als schwierige Aufgabe, welche aber entscheidend für das Endergebnis ist. Das Ziel dieser Phase ist es einen Datensatz zu generieren, welcher die spektralen Muster eines Landbedeckungstypen repräsentiert. Um dies zu ermöglichen muss jede Klasse im Trainingsgebiet ausreichend oft vorhanden sein. Die Auswahl einer Trainingsfläche innerhalb des Trainingsgebietes kann entweder als Polygon erfolgen oder mittels Seed Pixel. Bei letzterer Variante wird ein Pixel (Trainingspunkt) in einer Trainingsfläche ausgewählt und spektral ähnliche Pixel ausgewiesen. Diese Trainingspunkte liefern die spektrale Information dieser einzelnen Trainingsfläche.

Unabhängig von der Auswahlmethode müssen in einer Trainingsfläche mindestens N+1 Trainingspunkte ausgewertet werden, wobei n die Anzahl der spektralen Bänder ist. In der Praxis haben sich aber 10N – 100N Trainingspunkte pro Trainingsfläche als sinnvoll erwiesen, um Varianz und Co-Varianz zu verbessern.

Bei der Auswahl der Trainingsflächen ist auf Verteilung über das gesamte Arbeitsgebiet zu achten. 20 Flächen zu 40 Pixel eignen sich besser zum Training als eine Fläche mit 800 Pixel.

Bei der Verfeinerung der Trainingsflächen für eine Klasse wird überprüft ob die Klassen spektral voneinander trennbar sind und ob jede Klasse ungefähr normalverteilt ist. Trainingsflächen, welche mehr als eine Klasse repräsentieren, müssen überarbeitet oder gelöscht werden.

Wenn zwei oder mehr Landbedeckungsarten an sich gleiche spektrale Signaturen aufweisen, können diese auch durch Optimierung der Trainingsdaten nicht spektral getrennt werden. Dazu müssen weitere Eingangsvariablen herangezogen werden.

2.2 Eingangsvariablen

2.2.1 Vegetationsindizes

In diesem Punkt werden alle Vegetationsindizes beschrieben, welche für diese Arbeit aufgrund des verfügbaren spektralen Datenmaterials umsetzbar sind.

Viele der verfügbaren Vegetationsindizes wurden in Zusammenhang mit dem Start der Landsat Satelliten ab dem Jahr 1972 entwickelt. Um aus den vielen Kanälen des Multispektralscanners einen Wert für Information über Vegetation zu berechnen, wurden diverse Ansätze entwickelt. Die meisten Formeln lassen sich dabei in zwei grundlegende Kategorien einteilen: Jene, die mit Verhältnissen arbeiten und jene, die mit Differenzen arbeiten um die spektrale Charakteristik von Vegetation und Boden zu ermitteln (Lautenschlager & Perry 1981, 77; Perry Jr. & Lautenschlager 1984, 179). Für diese Arbeit können jene Vegetationsindizes verwendet werden, welche auf die Landsat Kanäle 1 (Grün), 2 (rot) und 4 (Nahes Infrarot) aufbauen. Nach Untersuchungen von Lautenschlager & Perry (1981, 79) lassen sich die folgenden aufgelisteten Vegetationsindizes, die mit den Kanälen 2 und 4 arbeiten, in einer Klasse zusammenfassen.

2.2.1.1 Normalized Difference Vegetation Index (NDVI)

Der NDVI (Rouse et al. 1973a) gehört zu den Vegetationsindizes, welche geeignet sind, die Anwesenheit von grüner Vegetation darzustellen. Berechnet wird er aus sichtbarem Rot (R) und nahem Infrarot (NIR) Kanal mittels folgender Formel:

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

Formel 1

Bereiche mit Vegetation haben aufgrund der hohen Reflektion im Wellenlängenbereich des nahen Infrarot einen hohen NDVI Wert. Wolken, Wasser und Schnee haben einen negativen NDVI, Felsen und unbestellte Ackerflächen einen NDVI nahe Null. Es handelt sich um einen sehr robusten und häufig eingesetzten Vegetationsindex (Lillesand et al. 2004, 467f).

2.2.1.2 Ashburn Vegetation Index (AVI)

Der von Ashburn (1978, zit. nach: Perry Jr. & Lautenschlager 1984) entwickelte Vegetationsindex ist ein Maß für die grüne, wachsende Vegetation. In der ursprünglichen Form wird er mit folgender Formel berechnet:

$$AVI = 2 * Kanal4 - Kanal2$$

Formel 2

Der 6-bit tiefe Kanal 7 wird verdoppelt um ihn auf den gleichen Maßstab wie den 8-bit Kanal 5 zu bringen (Perry Jr. & Lautenschlager 1984, 173). Da bei dieser Arbeit alle 4 Kanäle über die gleiche Farbtiefe verfügen, errechnet sich der AVI wie folgt:

$$AVI = NIR - R$$

Formel 3

2.2.1.3 Transformed Vegetation Index (TVI)

Der TVI ist eine Transformation des NDVI die von Rouse et al. (1973b, 77) vorgeschlagen wurde. Zum NDVI wird 0,5 addiert, um negative Werte zu verhindern und daraus die Wurzel gezogen, um die Varianz zu stabilisieren.

$$TVI = \sqrt{NDVI + 0.5}$$

Formel 4

Nach Perry Jr. & Lautenschlager (1984, 171) beseitigt die Modifikation nicht alle negativen Werte, weshalb sie eine Modifikation des TVI vorschlagen:

$$TVI = \frac{NDVI + 0.5}{|NDVI + 0.5|} * \sqrt{|NDVI + 0.5|}$$

Formel 5

Für diese Arbeit wird der modifizierte TVI (vgl. Formel 5) verwendet.

2.2.1.4 Soil Adjusted Vegetation Index (SAVI)

Der von Huete (1988) entwickelte SAVI erweitert den NDVI um einen Korrekturfaktor L für den Boden.

$$SAVI = \frac{NIR - R}{NIR + R + L} * (1 + L)$$

Formel 6

Bei geringer Dichte der Vegetation ist das Reflektionsverhalten auch von der Bodenfarbe abhängig. Dieses kann mit dem Faktor L korrigiert werden. Nimmt L den Wert 0 an, ist der SAVI gleich dem NDVI (Bannari et al. 1995, 107). Huete (1988) gibt L=0,5 als optimalen Korrekturfaktor an.

2.2.2 Texturmaße

Oberflächenstrukturen (Textur) können bei der Segmentierung und Klassifizierung von Bildern einen wesentlichen Beitrag leisten. Um die Textur zu erfassen, werden die ein Pixel umgebenden Nachbarpixel mitbetrachtet. Die Wahl der richtigen Umgebung ist dabei für das Ergebnis relevant. Ist die Umgebung zu klein, werden nicht alle Eigenschaften der Textur erfasst, ist sie zu groß, werden viele Übergangsbereiche der Textur miterfasst. Durch die Wahl der Größe der Umgebung wird auch die Relevanz von Farbton zu Oberflächenstruktur verändert. Je kleiner die Umgebung ist, desto relevanter wird der Farbton und desto weniger relevant die Textur (Haberäcker 1989, 296; Haralick et al. 1979, 786).

2.2.2.1 Texturkennwerte nach Haralick et al.

Haralick et al. (1973, 610ff) beschreiben 14 Texturmaße, welche mit Hilfe von GrayLevel Co-occurence Matrizen (GLCM) berechnet werden.

Für die Berechnung der Co-occurence Matrix wird die 8er-Nachbarschaft eines Pixels in einer Aufnahmezelle betrachtet und die Zusammenhänge in vier Richtungen berechnet. Von diesen Messungen werden alle Textur Kennwerte abgeleitet. Der Mittelwert und der Streubereich der vier Matrizen stehen als Eingangsvariable zur Verfügung. Ein Beispiel für das Erstellen einer GLCM ist in Abbildung 1 zu sehen. Dabei wird die Nachbarschaft jedes Grauwertes im Bild in horizontaler Richtung untersucht. Jedes Auftreten einer Kombination wird gezählt und in der GLCM eingetragen.

	Bi	ld				GL	СМ	
					1	2	3	4
1	2	3	1	1	0	2	0	0
3	2	3	2	2	0	0	2	2
3	2	4	3	3	1	3	0	0
2	4	1	2	4	1	0	1	0

Abbildung 1: Prinzip der GrayLevel Co-occurence Matrix für ein Bild mit vier Grauwertstufen. GLCM für horizontale Nachbarschaft erstellt.

Der Grauwert 1 tritt im Bild in horizontaler Richtung nicht neben dem Grauwert 1 auf, daher steht in der GLCM die Zahl Null. Der Grauwert 2 tritt in horizontaler Richtung zweimal rechts vom Grauwert 1 auf.

Die Information über die Textur steckt in dem Verhältnis zwischen den Grauwerten des Bildes. Obwohl alle berechneten Kennzahlen Informationen über die Oberflächenstruktur des Bildes beinhalten, ist es nicht immer eindeutig welche davon welche Charakteristik beschreibt.

Mit zunehmender Größe der Aufnahmezelle wird die Genauigkeit immer größer, kann aber beim Überschreiten eines Limits wieder abnehmen. Als optimale Fenstergröße haben sich bei Versuchen von Shaban & Dikshit (2001, 591) 7x7 bzw. 9x9 Pixel herausgestellt.

Die 14 Texturmaße, welche (Haralick et al. 1979, 619) vorschlagen sind: (*f1*) Angular Second Moment, (*f2*) Contrast, (*f3*) Correlation, (*f4*) Variance, (*f5*) Inverse Difference Moment, (*f6*) Sum Average, (*f7*) Sum Variance, (*f8*) Sum Entropy, (*f9*) Entropy, (*f10*) Difference Variance, (*f11*) Difference Entropy, (*f12, f13*) Information Measures of Correlation, (*f14*) Maximal Correlation Coefficient.

Der Informationsgehalt dieser Texturmaße ist vom Typ des analysierten Bildes abhängig, sowie vom spektralen Bereich, der Auflösung und der Charakteristik der zu erfassenden Objekte (Dimension, Form und räumliche Verteilung) (Kayitakire et al. 2006, 392).

Viele Studien haben festgestellt, dass einige der von Haralick et al. vorgestellten Texturmaße redundante Information liefern. Die folgende Tabelle gibt einen Überblick über die relevanten Parameter zufolge der jeweiligen Studie: Tabelle 1: Die laut jeweiliger Studie relevanten Parameter der von Haralick et al. (1973) vorgestellten Textur-Parameter: A: (Haralick et al. 1973), B: (Metzler et al. 2002), C: (Baraldi & Parmiggiani 1995), D: (Cossu, 1988, zit. nach: Soh & Tsatsoulis 1999), E: (Soh & Tsatsoulis 1999), F: (Shaban & Dikshit 2001)

Parameter			Studie					
		Α	В	С	D	Е	F	
f1	Angular Second Moment	٠	٠	•	•	٠		
f2	Contrast	٠	٠	٠	٠	٠	•	
f3	Correlation	٠	٠	٠	٠	٠		
f4	Sum of Squares: Variance	٠	٠	٠	٠	٠	•	
f5	Inverse Difference Moment	•	٠	٠	٠	٠	•	
f6	Sum Average	٠						
f7	Sum Variance	٠						
f8	Sum Entropy	•						
f9	Entropy	•	٠	٠	٠	٠	•	
f10	Difference Variance	٠						
f11	Difference Entropy	٠						
f12	Information Measures	•	•					
f13	of Correlation	•	•					
f14	Maximal correlation coefficient	٠						

Eine Beschreibung der sechs am häufigsten aufgeführten Parameter folgt nach Baraldi & Parmiggiani (1995, 298ff):

(f1) Angular Second Moment (ASM): Dieser Parameter wird auch als Energie bezeichnet und ist ein Maß für die Homogenität des Bildes. Maximalwerte nahe 1 werden erreicht wenn das Bild entweder eine gleichmäßige oder eine periodische Grauwertverteilung aufweist.

(12) Contrast: Der Kontrast definiert sich als die Differenz des höchsten und des tiefsten Wertes benachbarter Pixel. Ein Bild mit geringem Kontrast muss nicht über eine sehr enge Grauwertverteilung verfügen. Der Kontrast ist stark mit der Ortsfrequenz korreliert.

(*f3*) Correlation: Die Korrelation ist ein Maß für lineare Abhängigkeiten von Grauwerten in einem Bild. Hohe Korrelationswerte nahe 1 implizieren ein lineares Verhältnis von Grauwerten. Korrelation ist mit Energie, Entropie und Kontrast nicht korreliert.

(f4) Variance: Die Varianz ist ein Maß für die Heterogenität und stark mit statistischen Werten wie Standardabweichung korreliert. Die Varianz steigt an, wenn Grauwerte vom Mittelwert abweichen. Die Varianz ist nicht vom Kontrast abhängig, benötigt aber mehr Rechenaufwand als der Kontrast.

(*f5*) Inverse Difference Moment (IDM): Dieser Parameter wird auch als Homogenität bezeichnet. Dabei wird die Homogenität ermittelt, indem geringen Grauwertunterschieden größere Werte zugeordnet werden als großen Unterschieden. Der IDM ist invertiert korreliert mit Kontrast und Energie.

(19) Entropy: Dieser Parameter beschreibt die Unordnung eines Bildes, und nimmt daher bei Bildern mit uneinheitlicher Textur sehr große Werte an. Konzeptuell ist der Entropie-Parameter sehr nahe mit dem Energie-Parameter (ASM) verwandt. Dabei hat die Energie den Vorteil der Normalisierung.

2.2.2.2 Spektrale Texturanalyse mittels Wavelet Transformation

Bei der Texturanalyse von Fernerkundungsaufnahmen kann man Verfahren, welche im Frequenzraum und im Ortsfrequenzraum arbeiten unterscheiden. Zu den Verfahren welche im Frequenzraum arbeiten, zählen zum Beispiel die Fourier-Transformation und die Diskrete-Kosinus-Transformation. Wird ein Verfahren im Frequenzraum dargestellt, sind die Frequenzen bekannt, die räumliche Information geht dabei aber verloren. Verfahren die im Ortsfrequenzraum arbeiten, weisen dieses Problem nicht auf, da sie den Ortsraum in Signalabschnitte unterteilen und dadurch Informationen über Frequenz und räumliche Lokalisation liefern. Zu diesen Verfahren gehören die Gabor-Transformation und die Wavelet-Transformation (Albertz 2009, 108f; Haberäcker 1989, 163ff).

Die Wavelet-Transformation stammt aus dem Gebiet der Signalanalyse und gehört zu den Verfahren mit Multiresolutionsansätzen. Dabei wird das Bild in verschiedenen Auflösungsstufen dargestellt und für jede Stufe unterschiedliche Frequenzen analysiert. Bei der Wavelet Transformation wird die Fenstergröße variabel gehalten. Bei hohen Frequenzen werden kleine, bei niedrigen Frequenzen große Fenster verwendet (Hupf 2004, 25).

Der Vorteil dieses Ansatzes besteht darin, dass ein Wavelet durch verschieben und skalieren an das jeweils vorliegende Signal und dessen Frequenz angepasst werden kann (Polikar 1999; Louis et al. 1998). Für die Anwendung bedeutet dies, dass sowohl kleine als auch große Strukturen erkannt werden können (Graps 1995, 50).

Da die kontinuierliche Wavelet-Transformation einerseits sehr rechenaufwändig und andererseits für digitale Bildsignale nicht anwendbar ist (Hupf 2004, 27), wird in dieser Arbeit mit der diskreten stationären Wavelet-Transformation gearbeitet, welche das Bild in verschiedenen Auflösungen analysiert. Der Vorteil der stationären Wavelet Transformation besteht für diese Arbeit darin, dass durch das Fehlen von Upund Downsampling-Schritten die Größe des Ausgabebildes jener des Eingangsbildes entspricht.

Bei einem Wavelet handelt es sich um eine mathematische Funktion, welche das gelieferte Signal – in diesem Fall ein Bild – in verschiedene Frequenzbereiche teilt und jeden Teil in einem zugeordneten Maßstab analysiert. Wavelet Familien unterscheiden sich hinsichtlich ihrer Form, Frequenzbereiche und Maßstäbe. Die meisten Wavelet Familien verfügen über Unterklassen mit unterschiedlichen Koeffizienten (Graps 1995). In dieser Arbeit werden jeweils ein Wavelet aus fünf verschiedenen Wavelet Familien getestet (vgl. Tabelle 2).

Familie	Biorthogonal	Coiflets	Daubechies	Discrete Meyer	Symlets sym2	
Wavelet	bior 1.1	coif1	db1	dmey		
Maßstabs- funktion	1 0.8 0.6 0.4 0.2 0 0 0.2 0.4 0.5 0.8		1 0.8 0.6 0.4 0.2 0 0 0 0.2 0.4 0.5 0.8	1 0.8 0.6 0.4 0.2 0 0 0.2 0 0 0.5 0.5 0.5 0.5 0.5 0.5 0.		
Wavelet- funktion ψ	1 0.75 0.5 0.25 0.25 0.25 0.25 0.25 0.25 0.25		0.75 0.5 0.26 0.25 0.5 0.25 0.25 0.25 0.25 0.25 0.25			

 Tabelle 2: Für den systematischen Test verwendete Wavelet Familien mit jeweils getestetem Wavelet sowie der Maßstabs- und Waveletfunktion des Wavelets (Wasilewski 2012).

Abbildung 2 zeigt die beispielhafte Anwendung des ,dmey' Wavelets aus der Familie Discrete Meyer auf einen Teil des Untersuchungsgebietes. Das Ausgangsbild (Abbildung 2a) wird in drei Durchgängen einer diskreten stationären Wavelet Transformation unterzogen (Abbildung 2b, c, d).



Abbildung 2: Beispielhafte Anwendung des ,dmey' Wavelets auf einen Ausschnitt des Untersuchungsgebietes in drei Durchgängen.

Jeder Durchgang liefert vier Bilder zurück. Das A-Bild (Approximation) im linken oberen Quadranten (Abbildung 2b, c, d) ist jeweils das skalierte Eingangsbild, welches das Eingangsbild für den nächsten Durchgang bildet. Das H-Bild (horizontale Filterung) im rechten oberen Quadranten (Abbildung 2b, c, d) zeigt das Filterergebnis des Wavelets in horizontaler Richtung, das D-Bild (diagonale Filterung) im rechten unteren Quadranten jeweils in diagonaler Richtung und das V-Bild (vertikale Filterung) im linken unteren Quadranten jeweils in vertikaler Richtung. Mit jedem Durchgang verändert sich die Information innerhalb der Bilder.

2.2.3 Grauwertverteilung im Objekt

Die Verteilung der Grauwerte innerhalb eines Objektes (Datadistribution) kann für die Klassifizierung relevante Informationen bereitstellen. Als Eingangsvariablen für jedes Objekt werden dabei die für die Grauwerte des Objektes geschätzten Parameter der unterstellten Verteilungsfunktion herangezogen. Bei dieser Arbeit wurden die geschätzten Parameter der folgenden Verteilungen untersucht.

2.2.3.1 Weibull Verteilung

Die Weibull Verteilung ist eine stetige Wahrscheinlichkeitsverteilung und gehört zur Klasse der Lebensdauerverteilungen, welche vor allem bei Modellierungen von Lebensdauern in der Zuverlässigkeitstheorie und in der Biologie/Medizin Anwendung finden. Die Parameter α und β , welche die Weibull Verteilung beschreiben, können mittels Maximum-Likelihood-Methode iterativ berechnet werden. (Hartung et al. 2009, 218ff)

2.2.3.2 Beta Verteilung

Bei der Beta Verteilung handelt es sich um eine stetige Wahrscheinlichkeitsverteilung, bei der die Werte im Intervall [0, 1] liegen. Die Parameter m und n welche die Form der Beta Verteilung beschreiben sind nicht negativ und werden mittels Maximum-Likelihood-Methode geschätzt. (Hazewinkel 1989, 380; MATLAB 2012a)

2.2.3.3 Generalized Extreme Value Verteilung

Die Kombination aus den Familien der Gumbel-, Fréchet- und Weibullverteilung in eine einzige Familie liefert die Gerneralized Extreme Value Verteilung (GEV).

Zur Beschreibung werden drei Parameter herangezogen, der Lageparameter μ , der Maßstabsparameter σ und der Formparameter ξ . Die Vereinigung der drei Familien vereinfacht die statistische Implementation (Coles 2004, 47f).

Die Parameter werden in MATLAB mittels Maximum-Likelihood-Methode geschätzt (MATLAB 2012b).

2.2.4 Variablenauswahl und Transformation

Der Aufwand für die Klassifizierung steigt mit der Anzahl der Eingangsvariablen an, die für die Beschreibung einer Klasse herangezogen werden. Dieser Anstieg kann je nach Klassifizierungsalgorithmus zum Beispiel linear oder quadratisch erfolgen (Richards 1993). Es ist daher auf jeden Fall erforderlich, nicht mehr Variablen als notwendig heranzuziehen und jene, die zur Abgrenzung der Klassen nicht beitragen, nicht zu berücksichtigen. Die zu entfernenden Variablen können durch Variablenauswahl bestimmt werden. Für die Auswahl der zu reduzierenden Variablen ist es notwendig, mathematisch die Wichtigkeit der einzelnen Variablen zu bestimmen. Dazu wird überprüft, wie sich die Trennbarkeit der Klassen verändert, wenn eine Eingangsvariable entfernt wird. Ändert sich die Trennbarkeit nicht, ist diese zu entfernen (Richards 1993, 245; Shaban & Dikshit 2001, 826). Der in dieser Arbeit verwendete RF Klassifikator liefert zwei Wichtigkeitsmaße für die Variablen, welche für die Variablenauswahl herangezogen werden können.

3 Datengrundlage

Die Datengrundlage für diese Arbeit stellt ein Satz digitaler Orthofotos dar, welcher von der Bayerischen Landesanstalt für Wald und Forstwirtschaft (LWF) zur Verfügung gestellt wurde. In Abbildung 3 ist die Lage des Testgebietes innerhalb Bayerns dargestellt.

Die im Projekt "Erstellung einer Wald/Offenlandmaske aus digitalen Orthofotos" bearbeiteten Flächen sind in grün dargestellt, die Lage des Testgebietes dieser Arbeit – östlich von Garmisch-Partenkirchen – ist in Detail A rot eingerahmt.

Es handelt sich um dasselbe Testgebiet, in welchem auch die Methodik für das oben genannte Projekt entwickelt wurde.



Abbildung 3: Lage des Untersuchungsgebietes des Projektes "Erstellung einer Wald/Offenlandmaske aus digitalen Orthofotos" und der Testgebiete der Masterarbeit im deutschen Bundesland Bayern. Detailansicht der Lage der Testgebiete der Masterarbeit im bayerischen Teil des Karwendelgebirges.

Die von der LWF gelieferten Orthofotos verfügen über vier Kanäle – Nahes Infrarot, Rot, Grün, Blau – und eine Bodenauflösung von 20 cm je Pixel.

Die für diese Arbeit verwendeten Orthofotos entstammen aus einem Flugtag (1. September 2009) und wurden mit dem Kameramodell Vexcel UltraCam X aufgenommen. Die beiden Orthofotos welche Testgebiet A bilden sind in Abbildung 4 dargestellt.



Abbildung 4: Übersicht über das für den Test verwendete Gebiet (Testgebiet A), bestehend aus zwei Orthofotos. Ausdehnung 2000×4000 m.

Das Orthofoto des Testgebietes wurde in drei weitere Bodenauflösungen – 100 cm, 200 cm, 500 cm – umgerechnet. Zusätzlich wurde auf das Bild mit 100 cm Bodenauflösung ein focal median Filter angewendet. Ein Ausschnitt der fünf so erzeugten Eingangsbilder ist in Abbildung 5 abgebildet.



Abbildung 5: Vergleich der fünf verwendeten Auflösungen (Falschfarbbilder mit Kanälen IR, R, G). Bildausschnitt fix.

Die Kanäle nahes Infrarot, Rot, Grün und Blau sind wie Tabelle 3 zeigt hoch bis sehr hoch korreliert.

Tabelle 3: Korrelationskoeffizient (R) der Kanäle nahes Infrarot, Rot, Grün und Blau des 100cm Bildes

	IR	R	G	В
IR	-	0.789	0.826	0.723
R	0.789	-	0.992	0.965
G	0.826	0.992	-	0.967
В	0.723	0.965	0.967	-

4 Methodik

4.1 Erzeugung des Referenzdatensatzes

Zur Evaluierung und Überprüfung der verschiedenen Klassifizierungsansätze wurde ein Referenzdatensatz erstellt, der das gesamte Untersuchungsgebiet umfasst. Dieser wurde durch visuelle Interpretation der Objekte, welche durch die Segmentierung erzeugt wurden, erstellt.

4.1.1 Segmentierung

Die Segmentierung des Testgebietes erfolgte computergestützt mit der Software Definiens. Als Eingangsbild dienten die Kanäle IR, R und G des vierkanaligen Bildes des Testgebietes mit einer Bodenauflösung von 1x1 m je Pixel. Die Segmentierung wurde vom Projekt "Erstellung einer Wald/Offenlandmaske aus digitalen Orthofotos" übernommen (Scaleparameter 40; Shape 0.3; Compactnes 0.5, Layergewichtung: IR 4, R 1, G 1).

Das Ergebnis waren 4681 Polygone mit einer Größe von 3 – 26849 m². Um die Polygone auch auf das Bildmaterial mit geringerer Bodenauflösung anwenden zu können, wurden in ArcMap Polygone mit einer Fläche < 100 m² eliminiert und dem benachbarten Objekt mit der größten Kantenlänge klassenunabhängig zugeordnet.

Durch die Eliminierung ergaben sich 4549 Polygone mit einer Größe von $100 - 26849 \text{ m}^2$. Die Größenverteilung der Polygone in Klassenweiten von je 1000 m^2 ist in Abbildung 6 dargestellt. Daraus ersichtlich ist, dass über 75 % der Polygone Flächen kleiner 2100 m^2 aufweisen.



Abbildung 6: Größenverteilung aller 4549 Polygone mit Größen von 100 - 26849 m².

4.1.2 Referenzdatensatz

Für den Test wurden die drei Hauptklassen in insgesamt sieben Klassen aufgeteilt, welche spektral besser voneinander zu trennen waren. Die Klasse Wald wurde in die Klassen Nadel- und Laubholz geteilt, Offenland in Offenland Gras und Offenland Fels, Schattenflächen wurden als eigene Fläche erfasst und Objekte mit Mischcharakter wurden in einer Klasse (Sonstige) erfasst und beim Test nicht berücksichtigt. Die Klassen können anschließend wieder zu den drei Hauptklassen plus Klasse Schatten aggregiert werden. Die Zuweisung der Schattenpolygone zu einer der drei Hauptklassen ist nicht eindeutig möglich, weshalb sie in dieser Arbeit nicht zugewiesen werden.

Die Klassifizierung der Polygone durch visuelle Interpretation erfolgte in ArcMap in insgesamt sieben Klassen, basierend auf dem Bild mit 1 m Bodenauflösung. Polygone, welche zwei Klassen aufwiesen, wurden der Klasse mit dem größeren Anteil zugeordnet. Polygone, die mehr als zwei Klassen aufwiesen, wurden der Klasse 6 (Sonstige) zugewiesen und beim systematischen Test nicht berücksichtigt (21 Stück). Der Klasse 7 (Schatten) wurden Polygone zugeordnet, welche nur aus beschatteter Fläche bestehen.

Klasse 1: Nadelholz: überwiegend mit Nadelhölzern bestockte Objekte; Klasse 2: Laubholz: überwiegend mit Laubhölzern bestockte Objekte; Klasse 3: Latsche: Bestockung mit Latsche (*Pinus mugo*); Klasse 4: Offenland – Gras: überwiegend unbestockte Flächen mit Vegetation; Klasse 5: Offenland – Fels: überwiegend unbestockte, vegetationslose Flächen; Klasse 6: Sonstige: Objekte welche mehr als zwei Klassen aufweisen; Klasse 7: Schatten: überwiegend beschattete Objekte;

Beispiele zu den sieben Klassen sind in Abbildung 7 dargestellt.



Abbildung 7: Beispiele für Polygone der sieben Klassen.

Die Anzahl von Objekten je Klasse sowie deren mittlere Größe und Standardabweichung der Größe in m² sind in Tabelle 4 zusammengefasst.

Tabelle 4: Bezeichnung, Häufigkeit, Mittlere Größe (Median) und Standardabweichung der jeweiligen Klassen des Referenzdatensatzes.

Klasse	Bezeichnung	Anzahl	Mittlere Größe m ²	STD m ²
1	Nadelholz	1215	1422	2510
2	Laubholz	577	1374	1603
3	Latsche	794	1453	1262
4	Offenland, überwiegend Gras	1060	1301	963
5	Offenland, überwiegend Fels	513	1137	998
6	Sonstige	21	1704	1851
7	Schatten	369	1151	776
		4549		

Das Ergebnis der Referenzklassifizierung für die sieben Klassen ist in Abbildung 8 dargestellt. Rot dargestellt sind die Objekte der Klasse Sonstige, die für den systematischen Test nicht berücksichtigt wurden.



Abbildung 8: Referenzklassifizierung des Testgebietes A in 7 Klassen (a) und 5 Klassen (b).
4.1.3 Trainingsdatensatz, Testdatensatz

Das komplette Set von 4528 Polygonen (Klassen 1, 2, 3, 4, 5 und 7 ohne Klasse 6) wurde in zwei voneinander unabhängige Datensätze geteilt. Dabei wurden circa 50 % der Polygone, stratifiziert nach der Klasse, zufällig dem Trainingsdatensatz und die restlichen Polygone dem Testdatensatz zugewiesen. Die Anzahl von Objekten je Klasse im Trainings- und Testdatensatz sind in Tabelle 5 zu finden. Die Größenverteilungen waren mehr oder weniger identisch (nicht gezeigt).

Klasse	Sse Bezeichnung I Nadelholz 2 Laubholz 3 Latsche 4 Offenland, überwiegend Gras	Datensatz				
		Training	Test			
1	Nadelholz	607	608			
2	Laubholz	288	289			
3	Latsche	397	397			
4	Offenland, überwiegend Gras	530	530			
5	Offenland, überwiegend Fels und Schotter	256	257			
7	Schatten	184	185			
		2262	2266			

Tabelle 5: Anzahl von Objekten der jeweiligen Klasse im Trainings- bzw. Testdatensatz

Die Aufteilung der Objekte in ein unabhängiges Trainings- und Testgebiet ist in Abbildung 9 dargestellt.



Abbildung 9: Aufteilung der Objekte des Testgebietes A in einen unabhängigen Trainings- und Testdatensatz durch zufällige Auswahl. Löcher sind Objekte der Klasse "Sonstige" die vom systematischen Test ausgeschlossen wurden.

4.2 Bezugsfläche der Variablenerzeugung

Die Klassifikation erfolgte immer objekt-basiert. Objektbasierte Ansätze sind pixelbasierten Ansätzen wenn möglich vorzuziehen, da der zu bewältigende Daten- und Rechenaufwand sehr viel geringer ist (Jähne 2005, 567). Zudem können texturale Größen etc. gut mit in die Klassifizierung eingebaut werden (Vieira et al. 2012).

Zur Generierung der objekt-bezogenen Klassifizierungsvariablen wurden zwei Verfahren verwendet (vgl. Abbildung 10). Im ersten Fall wurden lediglich die einzelnen Pixel innerhalb eines Segmentes zur Merkmalsgenerierung herangezogen (z.B. mittlerer Grauwert im IR). Im zweiten Fall wurde in einem Zwischenschritt zunächst Information über die Nachbarschaft eines Pixels innerhalb einer quadratischen Bezugsfläche errechnet, welche immer um ein Pixel weiter verschoben wurde (Moving Window Ansatz). Dem zentralen Pixel wird dabei ein neuer Wert zugewiesen, der beispielsweise die Textur in der untersuchten Nachbarschaft beschreibt. Nach erfolgter Moving Window Berechnung wurden dann die

neuen Merkmale wie im ersten Ansatz objekt-weise aggregiert. Alle Variablen wurden in MATLAB berechnet.



Abbildung 10: Prinzip der objektbasierten Variablenerstellung. Direkt aus dem Eingangsbild erstellte Variablen (grüner Weg) und mittels Zwischenberechnung erstellte Variablen (blauer Weg).

4.2.1 Bezugsfläche Objekt

Bei diesem Ansatz wurde die geometrische Form der bei der Segmentierung erstellten Objekte als Bezugsfläche für die zu berechnende Variable verwendet. Das Resultat der Berechnung (z.B. mittlerer Grauwert im IR) wurde dem entsprechenden Objekt zugeordnet (vgl. Abbildung 11).

Die Anzahl der Berechnungen je Variable ist beim objektbasierten Ansatz nur von der Anzahl der Objekte, nicht aber von der Bodenauflösung des Eingangsbildes abhängig. Mit steigender Bodenauflösung steigt die Information je Objekt und somit die Rechendauer an.

146	11	237	112	62	73	241	172	195	247
220	200	120	213	162	28	230	11	242	19
52	248	216	169	210	231	123	55	247	153
46	141	122	168	61	135	159	98	20	237
137	29	62	178	218	130	155	229	207	124
254	187	150	97	207	97	196	227	169	221
186	177	231	186	158	98	151	223	239	11
212	134	242	131	175	166	164	149	208	224
20	205	77	169	18	180	37	42	175	244
37	99	62	69	24	189	213	6	8	180

Abbildung 11: Prinzip der Berechnung (z.B. Mittelwert) der Werte (z.B. Grauwerte des IR Kanales) zu einem Wert je Objekt. Zahl = Grauwert.

4.2.2 Moving Window Ansatz

Beim Moving Window Ansatz wurde die Nachbarschaft eines zentralen Pixels innerhalb eines definierten quadratischen Fensters (z.B. 7x7 Pixel Größe) analysiert und der errechnete Wert dem zentralen Pixel zugeordnet. Dieses quadratische Fenster wurde immer um ein Pixel verschoben, sodass als Endergebnis eine neue Ebene mit den gleichen Abmaßen des Ausgangsbildes entstand. Die Vorgehensweise ist in Abbildung 12a schematisch dargestellt.

a)	146	11	237	112	62	73	241	172	195	247
	220	200	120	213	162	28	230	11	242	19
	52	248	216	169	210	231	123	55	247	153
	46	141	122	168	61	135	159	98	20	237
	137	29	62	178	218	130	155	229	207	124
	254	187	150	97	207	97	196	227	169	221
	186	177	231	186	158	98	151	223	239	11
	212	134	242	131	175	166	164	149	208	224
	20	205	77	169	18	180	37	42	175	244
	37	99	62	69	24	189	213	6	8	180

b)	0	0	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	0	0	0
	125	100	254	184	48	208	238	0	0	0
	26	244	98	73	130	235	206	0	0	0
	225	26	152	34	163	161	135	0	0	0
	169	177	213	226	157	168	68	0	0	0
	123	87	178	194	129	59	52	0	0	0
	193	27	9	14	12	169	225	0	0	0
	254	53	195	86	23	74	89	0	0	0

Abbildung 12: a) Prinzip des Moving Window Ansatzes. b) Randpixelproblem beim Moving Window Ansatz. Zahl = Grauwert.

Beim Moving Window (MW) Ansatz galt es zwei Probleme zu lösen, das der Randpixel und das der Rechenleistung.

Wird ein MW zur Berechnung der Pixel am Rand des Bildes verwendet, so wird das quadratische Fenster über den Bildrand hinaus verschoben. Abbildung 12b) stellt dieses Problem schematisch dar.

Für diese Arbeit wurde das Ausgangsbild um einen Rand mit der Breite (*BreiteMovingWindow – 1*)/2 um den Wert 0 auf allen Seiten erweitert. Dadurch ließen sich alle Berechnungen innerhalb des Fensters durchführen, welche mit fehlenden Werten nicht möglich gewesen wären.

Das zweite Problem betraf die Rechenintensität des MW Ansatzes. Für jedes Pixel im Bild wurde pro gesuchter Variable eine Berechnung durchgeführt. Die Anzahl der Berechnungen (vgl. Tabelle 6) und dadurch auch die Rechendauer steigt mit dem Quadrat der Auflösung und der Größe des Fensters an.

Tabelle 6: Anzahl der zu berechnenden Fenster je Variable und Kanal

Bodenauflösung	Anzahl Berechnungen						
500 cm	0,32 × 10 ⁶						
200 cm	2 × 10 ⁶						
100 cm	8 × 10 ⁶						
20 cm	200 × 10 ⁶						

Die Qualität der Beschreibung von heterogenen bzw. homogenen Bereichen im Bild ist von der am Boden erfassten Fläche abhängig. Heterogene Bereiche werden zuverlässiger von kleinen Flächen beschrieben, homogene von größeren Flächen (Rodriguez-Galiano et al. 2012b, 96). Da die am Boden erfasste Fläche von der Größe des Fenster und der Bodenauflösung abhängig ist, wurden unterschiedlich große MWs berechnet. Die durch das MW am Boden erfasste Fläche ist in Tabelle 7 für die unterschiedlichen Bodenauflösungen zusammengefasst.

Tabelle 7: Am Boden erfasste Fläche in Abhängigkeit von Moving Window Grö	öße und Bodenauflösung
---	------------------------

Moving	Bodenauflösung									
Window	500 cm	500 cm 200 cm		20 cm						
3×3	15×15 m	6×6 m	3×3 m	0,6×0,6 m						
7×7	35×35 m	14×14 m	7×7 m	1,4×1,4 m						
11×11	55×55 m	22×22 m	11×11 m	2,2×2,2 m						
21×21	105×105 m	42×42 m	21×21 m	4,2×4,2 m						
25×25	125×125 m	50×50 m	25×25 m	5×5 m						
35×35	175×175 m	70×70 m	35×35 m	7×7 m						
51×51	255×255 m	102×102 m	51×51 m	10,2×10,2 m						

Von den mittels MW Ansatz berechneten Informationen wurden durch Verschneidung mit der Segmentierung Mittelwert, Median und Standardabweichung als Eingangsvariable pro Objekt berechnet.

4.3 Erstellung der Eingangsvariablen

Die erstellten Eingangsvariablen wurden in sieben Gruppen eingeteilt: Spektrale Information, Vegetationsindizes, GLCM-basierte Texturmaße nach Haralick mit objektbasiertem Ansatz und fixen GrayLimits, GLCM-basierte Texturmaße nach Haralick mit objektbasiertem Ansatz und dynamischen GrayLimits, DSWT-basierte Texturmaße und Grauwertverteilung im Objekt. Die Gruppen wurden teilweise zusätzlich in Untergruppen aufgegliedert. Daraus wurden Variablensets zusammengestellt (Beispielsweise Mittelwert der Spektralen Kanäle), welche die kleinste betrachtete Untersuchungseinheit des systematischen Tests darstellen. Zur Veranschaulichung ist diese Vorgehensweise in Tabelle 8 abgebildet.

Tabelle 8: Einteilung der für den Test erstellten Variablen in Gruppen, Untergruppen und Variablensets pro Auflösung mit Angabe der Anzahl von Variablen je Variablenset (N).

Gruppe	Untergruppe	Variablensets
Spektrale Information		 Mittelwert Kanäle IR/R/G/B (N = 4) Mittelwert und Standardabweichung Kanäle IR/R/G/B (N = 8) Mittelwert, Median und Standardabweichung Kanäle IR/R/G/B (N = 12) Mittelwert Kanäle R/G/B (N = 3) Mittelwert und Standardabweichung Kanäle R/G/B (N = 6) Mittelwert, Median und Standardabweichung Kanäle R/G/B (N = 9) Mittelwert Kanäle IR/R/G (N = 3) Mittelwert und Standardabweichung Kanäle IR/R/G (N = 6) Mittelwert, Median und Standardabweichung Kanäle IR/R/G (N = 9) Mittelwert Kanäle IR/R/B (N = 3) Mittelwert Kanäle IR/R/B (N = 3) Mittelwert und Standardabweichung Kanäle IR/R/B (N = 6) Mittelwert, Median und Standardabweichung Kanäle IR/R/B (N = 9) Mittelwert Kanäle IR/G/B (N = 3) Mittelwert und Standardabweichung Kanäle IR/R/B (N = 9) Mittelwert Kanäle IR/G/B (N = 3)
Vegetationsindizes	 NDVI AVI TVI SAVI 	 Alle Variablen der Gruppe (N = 12) Mittelwert, Median und Standardabweichung je Untergruppe (N = 3) 10 wichtigste Variablen der Gruppe nach MDA Wichtigkeit (N = 10) 10 wichtigste Variablen der Gruppe nach MDG Wichtigkeit (N = 10)
GLCM-basierte Texturmaße nach Haralick mit MW- basiertem Ansatz	 MW Größe 3×3 Pixel MW Größe 7×7 Pixel MW Größe 11×11 Pixel MW Größe 21×21 Pixel MW Größe 25×25 Pixel MW Größe 35×35 Pixel MW Größe 51×51 Pixel NumLevels 16, GrayLimits [0 255] 	 Alle Variablen je Untergruppe (N = 96) Texturparameter Contrast aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 24) Texturparameter Correlation aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 24) Texturparameter Energy aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 24) Texturparameter Homogeneity aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 24) Alle 4 Texturparameter des IR Kanales je Untergruppe (N = 24) Alle 4 Texturparameter des R Kanales je Untergruppe (N = 24) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 24) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 24) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 24) I0 wichtigste Variablen je Untergruppe nach MDA Wichtigkeit (N = 10) 10 wichtigste Variablen je Untergruppe nach MDG Wichtigkeit (N = 10)
GLCM-basierte Texturmaße nach Haralick mit objekt- basiertem Ansatz und fixen GrayLimits	NumLevels 8 NumLevels 16 NumLevels 32 NumLevels 64 GrayLimits [0 255]	 Alle Variablen je Untergruppe (N = 48) Texturparameter Contrast aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 12) Texturparameter Correlation aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 12) Texturparameter Energy aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 12) Texturparameter Homogeneity aller 4 Kanäle (IR/R/G/B) je

		 Untergruppe (N = 12) Alle 4 Texturparameter des IR Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des R Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des G Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) 10 wichtigste Variablen je Untergruppe nach MDA Wichtigkeit (N = 10) 10 wichtigste Variablen je Untergruppe nach MDG Wichtigkeit (N = 10)
GLCM-basierte Texturmaße nach Haralick mit objekt- basiertem Ansatz und dynamischen GrayLimits	NumLevels 4 NumLevels 5 NumLevels 7 NumLevels 10 NumLevels 16 GrayLimits dynamisch	 Alle Variablen je Untergruppe (N = 48) Texturparameter Contrast aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 12) Texturparameter Correlation aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 12) Texturparameter Energy aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 12) Texturparameter Homogeneity aller 4 Kanäle (IR/R/G/B) je Untergruppe (N = 12) Alle 4 Texturparameter des IR Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des R Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) Alle 4 Texturparameter des B Kanales je Untergruppe (N = 12) 10 wichtigste Variablen je Untergruppe nach MDA Wichtigkeit (N = 10) 10 wichtigste Variablen je Untergruppe nach MDG Wichtigkeit (N = 10)
DSWT-basierte Texturmaße	 bior 1.1 Wavelet coif 1 Wavelet db 1 Wavelet dmey Wavelet sym 2 Wavelet 	 Alle Variablen je Untergruppe (N = 192 [20 cm, 100 cm, 100 cm fm], N = 96 [200 cm, 500 cm]) Alle Texturvariablen des IR Kanales je Untergruppe (N = 48 [20 cm, 100 cm, 100 cm fm], N = 24 [200 cm, 500 cm]) Alle Texturvariablen des R Kanales je Untergruppe (N = 48 [20 cm, 100 cm, 100 cm fm], N = 24 [200 cm, 500 cm]) Alle Texturvariablen des G Kanales je Untergruppe (N = 48 [20 cm, 100 cm, 100 cm fm], N = 24 [200 cm, 500 cm]) Alle Texturvariablen des G Kanales je Untergruppe (N = 48 [20 cm, 100 cm, 100 cm fm], N = 24 [200 cm, 500 cm]) Alle Texturvariablen des B Kanales je Untergruppe (N = 48 [20 cm, 100 cm, 100 cm fm], N = 24 [200 cm, 500 cm]) Alle Texturvariablen je Untergruppe nach MDA Wichtigkeit (N = 10) 10 wichtigste Variablen je Untergruppe nach MDG Wichtigkeit (N = 10)
Grauwertverteilung im Objekt	BetaverteilungWeibullverteilungGEV Verteilung	 Alle Variablen der Gruppe (N = 56) Alle Variablen Betaverteilung der 4 spektralen Kanäle und 4 Vegetationsindizes (N = 16) Alle Variablen Betaverteilung der 4 spektralen Kanäle (N = 8) Alle Variablen Weibullverteilung der 4 spektralen Kanäle und 4 Vegetationsindizes (N = 16) Alle Variablen Weibullverteilung der 4 spektralen Kanäle (N = 8) Alle Variablen GEV Verteilung der 4 spektralen Kanäle (N = 8) Alle Variablen GEV Verteilung der 4 spektralen Kanäle (N = 12) Alle Variablen GEV Verteilung der 4 spektralen Kanäle (N = 12) 10 wichtigste Variablen der Gruppe nach MDA Wichtigkeit (N = 10) 10 wichtigste Variablen Der Gruppe nach MDG Wichtigkeit (N = 10)

4.3.1 Spektrale Information der Kanäle nahes Infrarot, Rot, Grün und Blau

Für die vier spektralen Kanäle nahes Infrarot (IR), Rot (R), Grün (G) und Blau (B) wurden objektbasiert der Mittelwert, der Median sowie die Standardabweichung berechnet. Die Erstellung der Variablen der Gruppe Spektrale Information ist schematisch in Abbildung 13 dargestellt.



Abbildung 13: Erstellung der Variablen der Gruppe Spektrale Information.

4.3.2 Vegetationsindizes

Die Vegetationsindizes NDVI, AVI, TVI und SAVI wurden entsprechend den Formeln im Kapitel 2.2.1 berechnet.

Der NDVI (Formel 1) und TVI (Formel 5) liefern mathematisch keinen Wert, wenn die Grauwerte der Kanäle IR und R Null sind. Um Mittelwert, Median und Standardabweichung der Objekte sicher berechnen zu können, wurden diese Werte bei der Berechnung nicht berücksichtigt.

Die Erstellung der Variablen der Gruppe Vegetationsindizes ist schematisch in Abbildung 14 dargestellt.



Abbildung 14: Erstellung der Variablen der Gruppe Vegetationsindizes.

4.3.3 Texturmaße

4.3.3.1 GrayLevel Co-occurence Matrix Ansatz nach Haralick et al.

Die Erstellung einer Grauwertmatrix nach dem Ansatz von Haralick et al. (1973) ist mit der Funktion *graycomatrix* in MATLAB implementiert. Texturmaße wurden für die einzelnen Spektralkanäle getrennt berechnet.

Das Ergebnis kann dabei über folgende Parameter gesteuert werden:

• Offset: steuert die Richtung und Lag-Distanz, in welchen die Nachbarschaftsverhältnisse analysiert werden.

- Symmetric: steuert, ob beim Analysieren der Nachbarschaftsverhältnisse ein Wertepaar in beide Richtungen gezählt wird. Ist der Parameter auf "true" gesetzt, so wird 1,2 und 2,1 jeweils einmal gezählt, wenn das Vorkommen von 2 als Nachbar von 1 analysiert wird.
- NumLevels (NL): gibt die Anzahl der Klassen an, in welche die Grauwerte geteilt werden.
- GrayLimits (GL): gibt den Wertebereich für die im Bild auftretenden Grauwerte an.

Die Berechnung der GLCM erfolgte auf den vier spektralen Kanälen nahes Infrarot, Rot, Grün und Blau. Der Parameter Offset wurde so gewählt, dass die Richtungen 0°, 45°, 90° und 135° mit einer Lag-Distanz von 1 berechnet werden. Symmetric wurde auf ,true' gesetzt. Mit der Funktion *graycoprops* wurden aus der im vorherigen Schritt erstellten Grauwertmatrix die Mittel- und Maximalwerte der Parameter ,Contrast', ,Correlation', ,Energy' und ,Homogeneity' berechnet.

GRUPPE MOVING WINDOW BASIERTER ANSATZ

Bei den Berechnungen der Texturparameter mittels Moving Window Ansatzes wurden die Parameter GrayLimits mit [0 255] und NumLevels mit 16 festgesetzt.

Für die mittels Moving Window Ansatz ermittelten Texturparameter wurden für jedes Objekt Mittelwert, Median und Standardabweichung des Mittel- und Maximalwertes berechnet.

Die Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit MW basiertem Ansatz ist schematisch in Abbildung 15 dargestellt.



Abbildung 15: Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit MW basiertem Ansatz.

GRUPPE OBJEKTBASIERTER ANSATZ MIT FIXEN GRAYLIMITS

Bei dieser Gruppe wurden die GrayLimits mit [0 255] fixiert und NumLevels von 8, 16, 32 und 64 berechnet. Für die so ermittelten Texturparameter wurde für jedes Objekt der Mittel-, Maximalwert und die Standardabweichung der vier Richtungen des jeweiligen Parameters berechnet. Die Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit objektbasiertem Ansatz und fixen GrayLimits ist schematisch in Abbildung 16 dargestellt.



Abbildung 16: Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit objektbasiertem Ansatz und fixen GrayLimits.

GRUPPE OBJEKTBASIERTER ANSATZ MIT DYNAMISCHEN GRAYLIMITS

Bei dieser Gruppe wurden die GrayLimits dynamisch an die minimal und maximal im Objekt auftretenden Grauwerte angepasst und NumLevels von 4, 5, 7, 10 und 16 kalkuliert. Für die so ermittelten Texturparameter wurde für jedes Objekt der Mittel-, Maximalwert und die Standardabweichung der vier Richtungen des jeweiligen Parameters berechnet. Die Erstellung der Variablen der Gruppe GLCMbasierte Texturmaße nach Haralick mit objektbasiertem Ansatz und dynamischen GrayLimits ist schematisch in Abbildung 17 dargestellt.



Abbildung 17: Erstellung der Variablen der Gruppe GLCM-basierte Texturmaße nach Haralick mit objektbasiertem Ansatz und dynamischen GrayLimits.

4.3.3.2 Diskrete Stationäre Wavelet Transformation

Über die in der MATLAB Wavelet-Toolbox enthaltene Funktion *swt2()* wurden die vier Kanäle IR, R, G und B der Eingangsbilder einer diskreten stationären Wavelet Transformation (DSWT) unterzogen.

Je nach Bilddimension war eine unterschiedlich hohe Anzahl an Transformationsdurchgängen möglich. Für die Bodenauflösungen von 500 cm und 200 cm wurden zwei Durchgänge gewählt, für 100 cm und 20 cm vier Durchgänge. Von den für jeden Kanal und jede Auflösung entstehenden Bildern wurde jeweils für jedes Objekt Mittelwert, Median und Standardabweichung berechnet.

Die Erstellung der Variablen der Gruppe DSWT-basierte Texturmaße ist schematisch in Abbildung 18 dargestellt.



Abbildung 18: Erstellung der Variablen der Gruppe DSWT-basierte Texturmaße.

4.3.4 Grauwertverteilung im Objekt

Die Verteilung der Grauwerte innerhalb eines Objektes (Datadistribution) wurde durch die Parameterschätzung der jeweiligen –fit Funktionen in MATLAB untersucht.

Dabei wurde für die Weibullverteilung die Funktion *wblfit()*, Betaverteilung die Funktion *betafit()* und die Generalized Extreme Values Verteilung die Funktion *gevfit()* verwendet.

Die drei Funktionen wurden auf die vier spektralen Kanäle nahes Infrarot, Rot, Blau und Grün sowie die Vegetationsindizes NDVI, AVI, TVI und SAVI angewandt. Die von der Funktion gelieferten Parameter wurden als Eingangsvariablen für das jeweilige Objekt abgespeichert. Die Erstellung der Variablen der Gruppe DSWT-basierte Texturmaße ist schematisch in Abbildung 19 dargestellt.



Abbildung 19: Erstellung der Variablen der Gruppe Grauwertverteilung im Objekt (Datadistribution).

4.4 Systematischer Test der Eingangsvariablen

Der systematische Test der Eingangsvariablen wurde mittels Random Forest (RF) Klassifizierung für die fünf Auflösungen separat durchgeführt.

Die Klassifizierung erfolgte mittels Softwarepaket [R] mit dem Package randomForest 4.6.6 (Liaw & Wiener 2002) auf dem Großrechner NONA der Universität für Bodenkultur Wien.

Im ersten Schritt des systematischen Tests wurden die Variablensets der Gruppe Spektrale Information auf deren Klassifikationsgenauigkeit getestet. Jenes Variablenset, welches das höchste Klassifizierungsergebnis bei geringster Variablenanzahl erzielte, wurde als Standardset ausgewiesen.

Im zweiten Schritt wurden alle Variablensets der jeweiligen Untergruppen und Gruppen zuzüglich des Standardsets getestet. Als Ergebnis aus der jeweiligen Klassifizierung wurde die Vorhersage des Trainingsdatensatzes, unabhängigen des Testdatensatzes sowie die Variablenwichtigkeit ,MeanDecreaseGini' ,MeanDecreaseAccuracy' gespeichert. Beurteilung und Die der Klassifizierungsgenauigkeit eines Variablensets erfolgte immer anhand des Ergebnisses des unabhängigen Testdatensatzes.

In einem weiteren Schritt wurde zur Evaluierung für jede Klassifizierung eine Konfusionsmatrix für die Vorhersage des Trainingsdatensatzes und des Testdatensatzes erstellt, sowie die Gesamtgenauigkeit, Kappa, Nutzer- und Produzentengenauigkeit berechnet (Congalton & Green 1999).

4.5 Suche nach geeigneten Variablenkombinationen mittels Zufallsauswahl

Für die Suche nach geeigneten Kombinationen aus zufällig gezogenen Eingangsvariablen wurden die fünf separaten Datensätze der unterschiedlichen Eingangsbilder zu einem Datensatz kombiniert.

Ein Datensatz mit allen Variablen aller Eingangsbilder wurde erzeugt, welcher 9 750 Variablen je Objekt umfasste sowie ein zweiter Datensatz mit allen Variablen außer den mittels Moving Window Ansatz erzeugten, mit 6 400 Variablen je Objekt.

Der zweite Datensatz umfasst somit jene Variablen, die mit geringer Rechenzeit erstellt werden können, da sie ohne den Moving Window Ansatz auskommen.

Für die zufällige Auswahl von Variablen wurden in MATLAB mit dem Befehl *randperm()* jeweils 500 000 zufällige Kombinationen von 5, 10, 15 und 20 Variablen erstellt.

Die Klassifizierung dieser zufällig gezogenen Variablenkombinationen erfolgte analog zum systematischen Test mit dem Softwarepaket [R] und dem Package randomForest 4.6.6 (Liaw & Wiener 2002) auf dem Großrechner NONA der Universität für Bodenkultur Wien.

Als Ergebnis der jeweiligen Klassifizierung wurde die Gesamtgenauigkeit des Trainings- und Testdatensatzes, die klassifizierten Variablen und deren Wichtigkeiten MDG und MDA gespeichert. Der Test- und Trainingsdatensatz sind bei diesem Test im Gegensatz zum restlichen Test vertauscht.

Für die Bestimmung der wichtigsten Variablen, wurden von beiden Datensätzen die 100 Variablenkombinationen bestehend aus 5, 10, 15 und 10 Variablen mit dem besten Klassifizierungsergebnis auf die darin auftretenden Variablen untersucht. Für jedes Auftreten der jeweiligen Variable wurden drei Werte gespeichert: Summe des Auftretens der Variable, Summe MDG Wichtigkeit normalisiert und Summe MDA Wichtigkeit normalisiert.

Mit den 50 und 100 wichtigsten Variablen, gereiht nach der summierten MDA Wichtigkeit wurde der Testdatensatz klassifiziert.

4.6 Auswirkung der Trainingsobjekte

Wie bereits in Punkt 0 angeführt wurde, ist die Auswahl geeigneter Trainingsobjekte für die erreichbare Klassifizierungsgenauigkeit essentiell. Um den Einfluss auf die Klassifizierungsgenauigkeit zu testen, wurden die im folgenden beschriebenen Tests mit dem Softwarepaket [R] und dem Package randomForest 4.6.6 (Liaw & Wiener 2002) auf dem Großrechner NONA der Universität für Bodenkultur Wien durchgeführt.

4.6.1 Anzahl der Trainingsobjekte

Da mit steigender Anzahl von Trainingsobjekten auch der Zeitbedarf für die Trainingsphase ansteigt, wurde für den vorhandenen Datensatz untersucht, wie sich die Anzahl der zum Training herangezogenen Objekte auf die Klassifizierungsgenauigkeit auswirkt.

Es wurden je 1000 Trainingsdatensätze, bestehend aus 5, 10 , 20 , 30, 50, 100, 150 und 180 Trainingsobjekten je Klasse in MATLAB mit dem Befehl *randperm()* zufällig gezogen und in [R] klassifiziert.

4.6.2 Größe der Trainingsobjekte

Die Frage nach der optimalen Größe der Trainingsobjekte steht in engem Zusammenhang mit der Anzahl der Trainingsobjekte.

Für diesen Test wurden die 50 größten und 50 kleinsten Objekte jeder Klasse herausgesucht und aus diesen je 1000 Trainingsdatensätze zu 5, 10, 20, 30 und 50 Objekten je Klasse zufällig in MATLAB mit dem Befehl *randperm()* gezogen und in [R] klassifiziert.

4.6.3 Unterschied zwischen den Trainingsdatensätzen

Da zufällig gezogene Trainingsdatensätze beim Klassifizieren des Testdatensatzes unterschiedlich hohe Klassifizierungsgenauigkeiten liefern, wurde versucht anhand von Trainingsdatensätzen bestehend aus je 10 Objekten je Klasse Gründe für die Unterschiede zu finden.

Dazu wurden in MATLAB mit dem Befehl *randperm()* zufällig 1×10⁶ Datensätze generiert und in [R] klassifiziert.

Die Objekte des höchsten und niedrigsten Ergebnisses wurden visuell dargestellt und die Verteilung der Daten des Trainingsdatensatzes im Vergleich zum Testdatensatz der 10 besten und der 10 schlechtesten Ergebnisse verglichen.

Für den Modus der 10 besten und der 10 schlechtesten Ergebnisse wurde eine Konfusionsmatrix erstellt.

4.7 Anwendbarkeit des trainierten Klassifikators auf angrenzende Testgebiete

Um die Übertragbarkeit des mit dem Trainingsdatensatz trainierten RF Klassifikators auf unabhängigen Datensätzen der gleichen Befliegung zu testen, wurden zwei weitere Orthofotokacheln ausgewählt, die als Testgebiet B und Testgebiet C bezeichnet wurden. Wie in Abbildung 20 zu sehen ist, schließt das Testgebiet B nördlich an das für die bisherige Arbeit verwendete Testgebiet A an und Testgebiet C östlich.



Abbildung 20: Übersicht über die Testgebiete B und C sowie deren Lage zu Testgebiet A. Größe der Testgebiete B und C jeweils 2000×2000 m.

In beiden Gebieten sind die sechs trainierten Klassen ausreichend vorhanden und es gibt mit Ausnahme einer kleinen Wasserfläche in Testgebiet C keine neuen Klassen. Für die beiden Testgebiete wurde eine bestehende Segmentierung übernommen, welche aus der Bearbeitung des Projektgebietes stammt. Das bestehende Klassifizierungsergebnis konnte nicht als Referenz herangezogen werden, da dieses nur in den drei Klassen "Wald", "Offenland" und "Latsche" vorlag. Um die Evaluierung vollflächig durchführen zu können, wurden die Objekte der Testgebiete visuell klassifiziert. Die Evaluierung erfolgte in Form einer Konfusionsmatrix für das Klassifizierungsergebnisses der Testgebiete A, B und C.

Die Eingangsbilder standen wieder mit 20 cm, 100 cm, 200 cm und 500 cm Bodenauflösung zur Verfügung und das 100 cm Bild mit angewendetem ,focal median' Filter.

In MATLAB wurden alle Variablen wie für den systematischen Test berechnet, auf die mittels Moving Window Ansatz berechneten Texturparameter wurde aus Gründen der Rechenzeit verzichtet.

Um die Anwendbarkeit des trainierten Klassifikators auf die Testgebiete B und C zu testen, wurde dieser mit zehn verschiedenen Variablenkombinationen getestet.

- Die erste Kombination entsprach den 300 besten Variablen nach MDA Wichtigkeit der Klassifizierung mit allen Variablen aller Auflösungen (vgl. Abbildung 30 auf Seite 57).
- Die zweite Kombination umfasste die Variablen des besten Klassifizierungsergebnisses der einzelnen Gruppen. Dabei wurde mit dem Standardset (12 spektrale Variablen) und 10 Texturvariablen des DSWT Ansatzes mit Coif 1 Wavelet des 20 cm Bildes klassifiziert (vgl. Tabelle 24 auf Seite 53). Die 10 verwendeten Texturmaße der Diskreten Stationären Wavelet Transformation (DSWT) sind in Anhang B (Tabelle 38) aufgelistet.

- Die 3. bis 6. Kombination enthielt die Variablen des höchsten Klassifizierungsergebnisses mit 5, 10, 15, 20 aller Variablen ohne Moving Window Ansatz. Die verwendeten Variablen sind in Anhang B (Tabelle 39) aufgelistet.
- Die 7. Bis 10. Kombination umfasste die 50 wichtigsten Variablen laut Ergebnis der Zufallskombinationen mit 5, 10, 15, 20 Variablen ohne Moving Window Ansatz.

Die Klassifizierung erfolgte mittels Softwarepaket [R] mit dem Package randomForest 4.6.6 (Liaw & Wiener 2002).

5 Ergebnisse

Die Ergebnisse in diesem Kapitel beziehen sich wenn nicht anders erwähnt auf das Klassifizierungsergebnis des unabhängigen Testdatensatzes des Testgebietes A. Kapitel 5.5 zeigt die Klassifizierungsergebnisse der angrenzenden Testgebiete B und C.

5.1 Referenzklassifizierung

5.1.1 Standardset

Bei der Suche nach einem geeigneten Standardset, aus der Gruppe Spektrale Information, welches die spektrale Grundinformation für den weiteren systematischen Test darstellt, haben sich zwei Kombinationen deutlich von den anderen getesteten hervorgehoben. Das beste Ergebnis auf dem Testdatensatz lieferte die Kombination Mittelwert, Median und Standardabweichung aller vier Kanäle welches als Standardset jeder Auflösung gewählt wurde. Die Kombination derselben Werte für die Kanäle IR, R und B liefert ein ähnlich hohes Ergebnis (Abbildung 21).



Abbildung 21: Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes in Testgebiet A der Variablensets zur Festlegung des Standarddatensets, getrennt nach den fünf Eingangsbildern.

Im Vergleich der fünf Eingangsbilder zeigen die Bilder mit niedriger Bodenauflösung tendenziell schlechtere Klassifizierungsergebnisse. Durch die Anwendung des focal median Filters auf das Bild mit 100 cm Bodenauflösung (100 cm fm) kann eine ähnlich hohe und teilweise gering höhere Klassifizierungsgenauigkeit erzielt werden als bei dem höchst auflösenden Bild mit 20 cm Bodenauflösung.

5.1.2 Alle Eingangsvariablen

Die jeweiligen Klassifizierungsergebnisse des unabhängigen Standardsets aller Eingangsvariablen je Auflösung sowie die Auswahl der 10 wichtigsten Variablen nach MDA/MDG Wichtigkeit zuzüglich Standardset zeigt Abbildung 22. Die 10 wichtigsten Variablen aller Variablen je Auflösung zeigt Tabelle 9, die des 20 cm Bildes nach MDA Wichtigkeit sind in Form von Karten in Abbildung 85 (Anhang F) dargestellt. Die 10 wichtigsten Variablen zeigen, dass bei den hoch aufgelösten Bildern die Texturvariablen nach Haralick et. al mit MW Ansatz eine große Wichtigkeit haben (sechs der 10 wichtigsten Variablen). Die Variablen welche aus den Vegetationsindizes berechnet wurden, sowie deren Grauwertverteilung im Objekt gehören bei allen Auflösungen zu den wichtigsten 10 Variablen nach MDA Wichtigkeit. Beim 200 cm Bild sind unter den 10 wichtigsten Variablen keine Texturvariablen zu finden, beim 500 cm Bild sind Texturvariablen des DSWT Ansatzes enthalten (vgl. Tabelle 9).

Tabelle 9: 10 wichtigste Variablen nach MDA Wichtigkeit bei Klassifizierung mit allen Variablen aller Gruppen der jeweiligen Auflösung.

	Eingangsbild												
Nr.	20cm	100cm	100cm fm	200cm	500cm								
1	AVI Weibull a	median of mean Correlation MW 7x7px NL 16 IR	mean of mean Correlation MW 3x3px NL 16 IR	AVI mean Objekt	AVI median Objekt								
2	median of mean Correlation MW 25x25px NL 16 IR	mean of mean Correlation MW 3x3px NL 16 IR	AVI mean Objekt	AVI Weibull a	SAVI median Objekt								
3	AVI mean Objekt	mean of max Correlation MW 7x7px NL 16 IR	AVI GEV mu	SAVI GEV mu	AVI mean Objekt								
4	median of max Correlation MW 25x25px NL 16 IR	median of max Correlation MW 7x7px NL 16 IR	NDVI GEV mu	SAVI median Objekt	NDVI GEV mu								
5	AVI median Objekt	AVI mean Objekt	TVI median Objekt	NDVI median Objekt	AVI Weibull a								
6	std of max Contrast MW 51x51px NL 16 B	median of mean Correlation MW 3x3px NL 16 IR	AVI median Objekt	TVI median Objekt	AVI GEV mu								
7	TVI median Objekt	mean of mean Correlation MW 7x7px NL 16 IR	SAVI GEV mu	NDVI GEV mu	NDVI median Objekt								
8	median of mean Correlation MW 35x35px NL 16 IR	AVI Weibull a	SAVI median Objekt	AVI GEV mu	TVI median Objekt								
9	std of max Contrast MW 35x35px NL 16 IR	AVI GEV mu	TVI GEV mu	AVI median Objekt	DSWT Sym2 median A1 R								
10	median of max Correlation MW 35x35px NL 16 IR	AVI median Objekt	AVI Weibull a	SAVI mean Objekt	DSWT Sym2 mean A1 R								



Abbildung 22: Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes in Testgebiet A aller Eingangsvariablen, getrennt nach den fünf Eingangsbildern.

Die maximale Klassifizierungsgenauigkeit mit allen verfügbaren Eingangsvariablen je Auflösung liegt bei 85.5% (20 cm Bild). Das stellt eine Verbesserung von 8.1 % Punkte im Vergleich zum Standarddatenset dar.

Ein Überblick über die Klassifizierungsergebnisse des Standardsets und aller Variablen je Eingangsbild und die Verbesserung des Ergebnisses liefert Tabelle 10. Die größte Verbesserung des Ergebnisses kann beim 100 cm Bild erzielt werden, die geringste Verbesserung beim 100 cm focal median Bild.

Tabelle 10: Übersicht über das Klassifizierungsergebnis des unabhängigen Testdatensatzes mit den Variablen des Standardsets und allen Variablen des jeweiligen Eingangsbildes. Klassifzierungsgenauigkeit Trainingsdatensatz in *Klammer*.

	Eingangsbild												
	20cm	100cm	100cm fm	200cm	500cm								
Standardset	77.4 (77.2)%	76.6 (76.6)%	77.8 (77.5)%	76.8 (77.1)%	73.6 (<i>75.6)</i> %								
Alle Variablen	85.5 (84.4)%	85.1 <i>(85.1)</i> %	83.7 <i>(</i> 83.6)%	83.2 <i>(82.4)</i> %	80.0 (78.7)%								
Verbesserung	8.1%	8.5%	5.9%	6.4%	6.4%								

Die Klassifizierung mit den 10 wichtigsten Variablen MDA/MDG zuzüglich des Standardsets liefert bei allen Eingangsbildern ein schlechteres Ergebnis als bei Verwendung aller Variablen (Tabelle 11). Die Klassifizierung mit den 10 wichtigsten Variablen nach MDA/MDG zuzüglich des Standardsets erreicht bei der Variablenauswahl nach MDA 83.7 % und MDG 82.8 % Genauigkeit (20 cm Bild).

Tabelle 11: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes aller Variablen, 10 wichtigste Variablen nach MDA zuzüglich des Standardsets und 10 wichtigste Variablen nach MDG zuzüglich des Standardsets. Bestes Ergebnis pro Eingangsbild ist **fett** geschrieben. Werte in [%].



5.2 Systematischer Test der Eingangsvariablen

5.2.1 Gruppe Vegetationsindizes

Die jeweiligen Klassifizierungsgenauigkeiten des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der Gruppe Vegetationsindizes zeigt Abbildung 63 (Anhang E). Die vier getesteten Vegetationsindizes liefern geringe Unterschiede in der Klassifizierungsgenauigkeit, der AVI liefert bis auf bei der 200 cm Auflösung tendenziell das niedrigste Ergebnis.

Der zusammenfassende Vergleich des Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der Gruppe Vegetationsindizes in Tabelle 12 zeigt, dass das Klassifizierungsergebnis durch Verwendung aller Variablen nur beim 200 cm Bild gesteigert werden kann. Die Klassifizierung mit den 10 wichtigsten Variablen MDA/MDG zuzüglich des Standardsets führt zu keiner Verbesserung der Klassifizierungsgenauigkeit. Die Klassifizierung mit den Daten des 100 cm focal median Bildes liefert das beste Ergebnis, 0.4 % Punkte besser als das Ergebnis des 20cm Bildes.

Tabelle 12: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes des besten Variablensets zuzüglich Standardset, aller Variablen der Gruppe zuzüglich Standardset, 10 wichtigste Variablen nach MDA zuzüglich Standardset und 10 wichtigste Variablen nach MDG zuzüglich Standardset. Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Werte in [%]. Vegetationsindex mit höchstem Ergebnis in zweiter Zeile

Eingangsbild

	20cm 100cm					100cm fm			200cm				500cm							
	enset	riablen ıppe	ıtigste	ıtigste	enset	riablen Ippe	ntigste	ntigste	enset	riablen ıppe	ntigste	ıtigste	enset	riablen ıppe	ntigste	ıtigste	enset	riablen ıppe	ntigste	ıtigste
Variablen	Bestes Variabl	Alle Va der Gru	10 wich MDA	10 wich MDG	Bestes Variabl	Alle Va der Gru	10 wich MDA	10 wich MDG	Bestes Variabl	Alle Va der Gru	10 wich MDA	10 wich MDG	Bestes Variabl	Alle Va der Gru	10 wich MDA	10 wich MDG	Bestes Variabl	Alle Va der Gru	10 wich MDA	10 wich MDG
VI	79.7 SAVI	79.1	79.4	79.3	78.9 NDVI	78.3	78.1	78.2	80.1 NDVI	79.6	79.4	79.3	77.9 SAVI	78.7	78.7	78.6	75.0 TVI	74.8	75.2	75.2

Die Korrelation bezogen auf Pixel und Objekte (Mittelwert des VIs im Objekt) der vier getesteten Vegetationsindizes NDVI, AVI, TVI und SAVI ist getrennt nach den Auflösungen in Tabelle 13 abgebildet. Die Korrelation zwischen den VIs ist bezogen auf die Werte des Objektes gleich oder höher als pixelbezogen. Die VIs NDVI, TVI und SAVI liefern bei allen Auflösungen fast idente Information. Die Korrelation zwischen AVI und den anderen Vegetationsindizes ist mit Korrelationswerten größer 0.662 am geringsten, aber immer noch als hoch zu beurteilen. Die Korrelation des NDVI mit dem AVI bezogen auf die Werte der Objekte ist für das 20 cm Bild in Abbildung 23 dargestellt.

Tabelle 13: Korrelationsmatrizen der Vegetationsindizes NDVI, AVI, TVI und SAVI bezogen auf Pixel undObjekte (Mittelwert des VIs im Objekt), getrennt nach Auflösungen.

		Korrelation Pixel								
		NDVI	AVI	TVI	SAVI					
20 cm	NDVI	-	0.663	0.995	1.000					
	AVI	0.663	-	0.681	0.666					
	TVI	0.995	0.681	-	0.995					
	SAVI	1.000	0.666	0.995	-					

		Korrelation Pixel								
		NDVI	AVI	TVI	SAVI					
۶	NDVI	-	0.663	0.995	1.000					
100 cr	AVI	0.663	-	0.681	0.666					
	TVI	0.995	0681	-	0.996					
	SAVI	1.000	0.666	0.996	-					

	Korrelation Objekte								
	NDVI	AVI	TVI	SAVI					
NDVI	-	0.794	0.998	0.999					
AVI	0.794	-	0.804	0.796					
TVI	0.998	0.804	-	0.998					
SAVI	0.999	0.796	0.998	-					

	Korrelation Objekte								
	NDVI	AVI	τvi	SAVI					
NDVI	-	0.764	0.998	0.999					
AVI	0.764	-	0.776	0.766					
TVI	0.998	0.776	-	0.998					
SAVI	0.999	0.766	0.998	-					

		Korrelation Pixel								
		NDVI	AVI	TVI	SAVI					
Ę,	NDVI	-	0.680	0.997	1.000					
100 cm	AVI	0.680	-	0.698	0.683					
	TVI	0.997	0.698	-	0.997					
	SAVI	1.000	0683	0.997	-					

NDVI

_

0.662

0.995

1.000

NDVI

AVI

TVI

SAVI

200 cm

Korrelation Pixel

TVI

0.995

0.680

-

0.995

SAVI

1.000

0.665

0.995

_

AVI

0.662

_

0.680

0.665

Korrelation Objekte

	NDVI	AVI	TVI	SAVI
NDVI	-	0.760	0.998	0.999
AVI	0.760	-	0.774	0.763
TVI	0.998	0.774	-	0.998
SAVI	0.999	0.763	0.998	-

Korrelation Objekte

	NDVI	AVI	TVI	SAVI
NDVI	-	0.795	0.998	0.999
AVI	0.795	-	0.805	0.797
τvi	0.998	0.805	-	0.998
SAVI	0.999	0.797	0.998	-

			Korrelati	ion Pixe	I
		NDVI	AVI	τvi	SAVI
F	NDVI	-	0.662	0.995	1.000
00 CU	AVI	0.662	-	0.681	0.665
ũ	TVI	0.995	0.681	-	0.995
	SAVI	1.000	0.665	0.995	-

Korrelation Objekte

	NDVI	AVI	TVI	SAVI
NDVI	-	0.841	0.998	0.999
AVI	0.841	-	0.847	0.842
TVI	0.998	0.847	-	0.998
SAVI	0.999	0.842	0.998	-



Abbildung 23: Korrelation der Vegetationsindizes NDVI und AVI bezogen auf Werte der Objekte (Mittelwert des VIs im Objekt) für das 20 cm Bild. Korrelationskoeffizient 0.794.

5.2.2 Gruppe Textur Graylevel Co-occurence Matrix nach Haralick mit Moving Window basiertem Ansatz

Eine Zusammenfassung des besten Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets jeder Moving Window Größe befindet sich in Tabelle 14. Die höchste Klassifizierungsgenauigkeit liefert dabei das 20cm Eingangsbild bei einer Moving Window Größe von 51x51 Pixel unter Verwendung der vier Parameter Contrast, Correlation, Homogeneity und Energy auf dem Blaukanal zuzüglich des Standardsets mit 84.2 %. Das beste erzielte Ergebnis liegt somit 1.3 % Punkte unter dem besten Klassifizierungsergebnis mit allen Variablen. Die MW Größe hat mit Ausnahme des 20 cm Bildes eine geringe Auswirkung auf die Klassifizierungsgenauigkeit.

Mit geringer Bodenauflösung des Eingangsbildes sinkt die erzielte Gesamtgenauigkeit.

Tabelle 14: Zusammenfassung der besten Klassifizierungsergebnisse des unabhängigen Testdatensatzes der Variablensets zuzüglich Standardset jeder Moving Window Größe (MW). Bestes Ergebnis pro Eingangsbild ist **fett** geschrieben. Klassifzierungsgenauigkeit Trainingsdatensatz in *Klammer*. Variablenset in zweiter Zeile, 4 Parameter = Contrast, Correlation, Energy und Homogeneity.

	Eingangsbild									
MW	20cm	100cm	100cm fm	200cm	500cm					
3×3	81.5 <i>(80.4)</i> % Contr. IR/R/G/B	81.1 (80.3)% Corr. IR/R/G/B	80.3 (79.7)% Contr. IR/R/G/B	79.3 (77.5)% Contr. IR/R/G/B	74.2 <i>(</i> 73.2 <i>)</i> % 4 Parameter IR					
7×7	81.7 <i>(</i> 80.9)% Contr. IR/R/G/B	80.8 <i>(80.1)</i> % 4 Parameter IR	80.8 <i>(79.0)%</i> Contr. IR/R/G/B	79.4 <i>(</i> 78.6)% 4 Parameter IR	75.9 <i>(74.9)</i> % 4 Parameter IR					
11×11	81.6 <i>(80.2)</i> % Contr. IR/R/G/B	81.0 <i>(80.9)</i> % 4 Parameter IR	80.4 <i>(79.4)</i> % 4 Parameter IR	80.0 <i>(78.6)</i> % 4 Parameter IR	75.9 <i>(76.1)</i> % 4 Parameter IR					
21×21	82.7 <i>(81.0)</i> % 4 Parameter IR	80.4 <i>(80.3)</i> % 4 Parameter IR	80.7 <i>(79.9)</i> % 4 Parameter IR	79.6 (77.9)% Contr. IR/R/G/B	76.3 <i>(76.0)</i> % 4 Parameter IR					
25×25	82.6 <i>(80.4)</i> % 4 Parameter IR	80.5 <i>(79.7)</i> % 4 Parameter IR	80.4 <i>(80.2)</i> % 4 Parameter IR	79.2 <i>(79.0)</i> % 4 Parameter IR	76.8 <i>(75.8)</i> % 4 Parameter IR					
35×35	82.7 <i>(81.2)</i> % 4 Parameter IR	80.8 <i>(79.9)</i> % 4 Parameter IR	80.5 <i>(80.3)</i> % 4 Parameter IR	80.0 <i>(78.2)</i> % 4 Parameter IR	76.9 (76.1)% 4 Parameter IR					
51×51	84.2 (81.7)% 4 Parameter B	80.1 <i>(79.6)</i> % 4 Parameter IR	81.4 <i>(80.0)</i> % 4 Parameter IR	80.1 (78.5)% 4 Parameter IR	76.4 (76.8)% Contr. IR/R/G/B					

Auffallend ist, dass alle Eingangsbilder, mit Ausnahme des 100cm Bildes, unabhängig von ihrer Bodenauflösung die besten Klassifizierungsgenauigkeiten bei großen Moving Window Größen erreichen. Der spektrale Kanal nahes Infrarot (IR) ist mit Ausnahme des höchsten Klassifizierungsergebnisses des 20 cm Bildes auch immer beteiligt.

Die für das höchste Klassifizierungsergebnis jeder Auflösung beteiligten Variablen und deren normalisierte MDA Wichtigkeit ist in Abbildung 24 dargestellt. Das Standardset und die Parameter Contrast und Correlation haben dabei eine höhere Wichtigkeit als die Parameter Energy und Homogeneity. Mit abnehmender Bodenauflösung geht die Wichtigkeit der Texturparameter in Vergleich zur spektralen Information des Standardsets zurück.



Abbildung 24: Normalisierte MDA Wichtigkeit der Eingangsvariablen des jeweiligen Variablensets je Auflösung, getrennt nach Standardset und den vier Haralick Parametern Contrast, Correlation, Energy und Homogeneity.

Der zusammenfassende Vergleich des Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der Gruppe Textur GLCM Ansatz nach Haralick mit MW basiertem Ansatz in Tabelle 15 zeigt, dass mit Ausnahme des 20 cm Bildes das Klassifizierungsergebnis durch Verwendung aller Variablen gesteigert werden kann. Die Klassifizierung mit den 10 wichtigsten Variablen MDA/MDG zuzüglich Standardset führt in einzelnen Fällen zu einer Verbesserung des Ergebnisses.

Tabelle 15: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes des besten Variablensets der Untergruppe zuzüglich Standardset, aller Variablen der Untergruppe zuzüglich Standardset, 10 wichtigste Variablen der Untergruppe nach MDA zuzüglich Standardset und 10 wichtigste Variablen der Untergruppe nach MDG zuzüglich Standardset. Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Werte in [%].

Eingangsbild

20cm					100	100cm			100cm fm			200cm			500cm					
MW	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG
3×3	81.5	81.5	81.3	81.1	81.1	81.4	80.2	80.1	80.3	79.9	79.8	79.5	79.3	78.9	78.9	78.8	74.2	73.6	75.4	74.9
7×7	81.7	82.0	81.8	81.7	80.8	80.5	80.5	81.1	80.8	79.9	79.3	80.7	79.4	79.9	79.8	79.9	75.9	75.9	75.9	75.9
11×11	81.6	81.9	81.3	81.6	81.0	81.9	81.1	81.5	80.4	81.0	80.1	79.8	80.0	80.0	80.5	80.1	75.9	76.3	75.8	75.6
21×21	82.7	82.1	81.6	81.7	80.4	81.9	81.0	80.8	80.7	81.5	80.8	80.8	79.6	81.0	79.3	79.4	76.3	77.2	76.4	76.4
25×25	82.6	81.7	81.5	81.1	80.5	81.6	80.9	80.5	80.4	81.3	80.1	80.3	79.2	80.4	79.5	79.6	76.8	77.4	75.9	76.1
35×35	82.7	82.2	81.6	81.9	80.8	81.4	80.8	80.5	80.5	81.8	80.6	80.6	80.0	81.0	79.5	79.4	76.9	77.3	76.3	76.2
51×51	84.2	83.1	81.2	81.6	80.1	80.9	80.7	80.2	81.4	82.0	80.6	80.6	80.1	81.1	80.3	79.8	76.4	77.1	75.3	76.5

Abbildung 64 bis Abbildung 70 (Anhang E) zeigen die Klassifizierungsergebnisse des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der jeweiligen Untergruppe der Gruppe Textur GLCM Ansatz nach Haralick et al. mit Moving Window basiertem Ansatz.

5.2.3 Gruppe Textur Graylevel Co-occurence Matrix nach Haralick mit objektbasierter Ansatz mit fixen GrayLimits

Die Auswirkung unterschiedlicher NumLevels auf die Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes durch unterschiedliche Variablensets bei fixen GrayLimits von [0 255] zeigt Tabelle 16.

Die höchste Klassifizierungsgenauigkeit liefert dabei das 20cm Eingangsbild bei einem NumLevel von 32 unter Verwendung des Parameters Homogeneity auf allen vier Kanälen mit 80.8 %. Das beste erzielte Ergebnis liegt somit 4.7 % Punkte unter dem besten Klassifizierungsergebnis mit allen Variablen des 20 cm Bildes. Mit abnehmender Bodenauflösung des Eingangsbildes sinkt die erzielbare Klassifizierungsgenauigkeit. Der Texturparameter Energy liefert häufig das beste Klassifizierungsergebnis.

 Tabelle
 16:
 Zusammenfassung der besten Klassifizierungsergebnisse des unabhängigen Testdatensatzes der

 Variablensets zuzüglich Standardset jedes NumLevels (NL). Bestes Ergebnis pro Eingangsbild ist fett geschrieben.
 Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Klassifzierungsgenauigkeit Trainingsdatensatz in *Klammer*.

 Variablenset in zweiter Zeile, 4 Parameter = Contrast, Correlation, Energy und Homogeneity.

			Eingangsbild		
NL	20cm	100cm	100cm fm	200cm	500cm
8	80.8 (79.0)%	78.0 (77.2)%	78.8 (77.2)%	78.1 (76.9)%	73.6 (75.2)%
	Energy IR/R/G/B	Homog IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B	4 Parameter G
16	80.5 (79.2)%	78.2 (77.3)%	79.4 (77.8)%	78.6 (76.3)%	73.4 <i>(74.8)</i> %
	Energy IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B
32	80.8 (79.8)%	78.4 (77.8)%	80.2 (78.9)%	77.8 (76.6)%	73.5 <i>(74.4)</i> %
	Homog IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B	4 Parameter G
64	80.8 (79.9)%	79.1 (77.5)%	79.8 (78.6)%	78.1 (77.1)%	73.4 <i>(74.2)</i> %
	Energy IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B	Energy IR/R/G/B	4 Parameter G

Die normalisierte Wichtigkeit der 24 Eingangsvariablen des Variablensets mit höchster Klassifzierungsgenauigkeit für das beste Klassifizierungsergebnis je Auflösung, getrennt nach Standardset und den vier Texturparametern ist in Abbildung 25 dargestellt. Daraus ist die hohe Wichtigkeit der spektralen Information des Standardsets und die mit abnehmender Bodenauflösung sinkende Wichtigkeit der Texturparameter ersichtlich.



Abbildung 25: Normalisierte MDA Wichtigkeit der Eingangsvariablen des jeweiligen Variablensets je Auflösung, getrennt nach Standardset und den vier Haralick Parametern Contrast, Correlation, Energy und Homogeneity.

Der zusammenfassende Vergleich des Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der Gruppe Textur GLCM Ansatz nach Haralick mit objektbasiertem Ansatz mit fixen GrayLimits in Tabelle 17 zeigt, dass das Klassifizierungsergebnis durch Verwendung aller Variablen nicht gesteigert werden kann. Die Klassifizierung mit den 10 wichtigsten Variablen MDA/MDG zuzüglich Standardset liefert bei den Bildern mit geringer Bodenauflösung (200 cm, 500 cm) ein besseres Ergebnis als unter Verwendung aller Variablen der Gruppe.

Tabelle 17: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes des besten Variablensets der Untergruppe zuzüglich Standardset, aller Variablen der Untergruppe zuzüglich Standardset, 10 wichtigste Variablen der Untergruppe nach MDA zuzüglich Standardset und 10 wichtigste Variablen der Untergruppe nach MDG zuzüglich Standardset. Bestes Ergebnis pro Eingangsbild ist **fett** geschrieben. Werte in [%].

									E	Eingan	gsbild	t								
	20cm 100cm								100cm fm					200	cm			500	cm	
NL	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG
8	80.8	80.4	78.7	78.9	78.0	77.9	77.9	77.8	78.8	76.3	76.7	77.1	78.1	74.8	75.7	75.9	73.6	70.9	72.7	72.3
16	80.5	80.2	79.1	79.3	78.2	77.4	77.2	76.8	79.4	77.3	77.8	77.7	78.6	75.0	75.6	75.6	73.4	71.6	72.8	72.9
32	80.8	80.0	80.2	80.1	78.4	77.8	77.7	77.1	80.2	78.2	78.5	78.4	77.8	75.2	75.5	75.7	73.5	72.8	73.4	73.9
64	80.8	80.4	80.3	80.2	79.1	77.6	77.5	77.3	79.8	78.4	78.4	78.2	78.1	75.9	76.4	76.6	73.4	71.9	72.7	72.9

Abbildung 71 bis Abbildung 74 (Anhang E) zeigen die Klassifizierungsergebnisse des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der jeweiligen Untergruppe der Gruppe Textur GLCM Ansatz nach Haralick et al. mit objektbasiertem Ansatz mit fixen GrayLimits.

5.2.4 Gruppe Textur Graylevel Co-occurence Matrix nach Haralick mit objektbasierter Ansatz mit dynamischen GrayLimits

Die Auswirkung unterschiedlicher NumLevels auf die Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes durch unterschiedliche Variablensets bei dynamischen GrayLimits zeigt Tabelle 18.

Die höchste Klassifizierungsgenauigkeit liefert dabei das 20cm Eingangsbild bei einem NumLevel von 16 unter Verwendung der Parameter Contrast, Correlation, Energy und Homogeneity des Infrarotkanales zuzüglich Standardset mit 80.0 %. Das beste erzielte Ergebnis liegt somit 5.5 % Punkte unter dem besten Klassifizierungsergebnis mit allen Variablen des 20 cm Bildes. Insgesamt liefert dieser Ansatz schlechtere Klassifizierungsgenauigkeiten als der Ansatz mit fixen GrayLimits. Die NumLevels haben kaum Einfluss auf die Klassifizierungsgenauigkeit.

 Tabelle
 18:
 Zusammenfassung der besten Klassifizierungsergebnisse des unabhängigen Testdatensatzes der

 Variablensets zuzüglich Standardset jedes NumLevels (NL). Bestes Ergebnis pro Eingangsbild ist fett geschrieben.
 Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Klassifzierungsgenauigkeit Trainingsdatensatz in *Klammer*.

 Variablenset in zweiter Zeile, 4 Parameter = Contrast, Correlation, Energy und Homogeneity.

	Eingangsbild													
NL	20cm	100cm	100cm fm	200cm	500cm									
 4	79.7 <i>(78.9)</i> % Energy IR/R/G/B	76.9 <i>(75.7)</i> % 4 Parameter G	77.7 <i>(77.4)</i> % Energy IR/R/G/B	77.9 <i>(76.3)</i> % Energy IR/R/G/B	73.7 (74.4)% Energy IR/R/G/B									
 5	79.8 (78.4)% Energy IR/R/G/B	77.1 <i>(76.1)</i> % 4 Parameter IR	78.6 <i>(77.0)</i> % Energy IR/R/G/B	77.9 (75.6)% Energy IR/R/G/B	73.4 (73.8)% 4 Parameter B									
7	79.7 <i>(80.1)</i> % 4 Parameter R	77.5 <i>(76.6)</i> % 4 Parameter IR	78.7 (77.8)% Energy IR/R/G/B	77.3 (76.6)% Energy IR/R/G/B	73.5 <i>(73.5)</i> % 4 Parameter G									
 10	79.7 <i>(81.0)</i> % 4 Parameter G	77.2 (76.9)% Corr. IR/R/G/B	78.4 <i>(77.5)</i> % Energy IR/R/G/B	78.5 (77.0)% Energy IR/R/G/B	73.5 <i>(73.5)</i> % 4 Parameter G									
 16	80.0 <i>(80.8)</i> % 4 Parameter IR	77.5 (77.7)% 4 Parameter IR	78.5 (77.7)% Energy IR/R/G/B	78.1 <i>(76.9)</i> % Energy IR/R/G/B	73.6 <i>(</i> 73.7)% 4 Parameter G									

Die normalisierte Wichtigkeit der 24 Eingangsvariablen des Variablensets mit höchster Klassifzierungsgenauigkeit je Auflösung, die in Abbildung 26 dargestellt ist, lässt erkennen, dass die wichtigsten Variablen für die Klassifizierung mit Ausnahme des 20 cm und 100 cm Bildes aus dem Standardset kommen. Mit abnehmender Bodenauflösung wird die Wichtigkeit der Texturparameter geringer.



Abbildung 26: Normalisierte MDA Wichtigkeit der Eingangsvariablen des jeweiligen Variablensets je Auflösung, getrennt nach Standardset und den vier Haralick Parametern Contrast, Correlation, Energy und Homogeneity.

Der zusammenfassende Vergleich des Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der Gruppe Textur GLCM Ansatz nach Haralick mit objektbasiertem Ansatz mit fixen GrayLimits in Tabelle 19 zeigt, dass das Klassifizierungsergebnis durch Verwendung aller Variablen nicht gesteigert werden kann. Die Klassifizierung mit den 10 wichtigsten Variablen MDA/MDG zuzüglich Standardset liefert bei allen Bildern ein besseres Ergebnis als bei Verwendung aller Variablen.

Tabelle 19: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes des besten Variablensets der Untergruppe zuzüglich Standardset, aller Variablen der Untergruppe zuzüglich Standardset, 10 wichtigste Variablen der Untergruppe nach MDA zuzüglich Standardset und 10 wichtigste Variablen der Untergruppe nach MDG zuzüglich Standardset. Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Werte in [%].

	Eingangsbild																			
	20cm 100cm								100cm fm				200cm				500cm			
NL	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG
4	79.7	79.2	78.9	79.5	76.9	75.0	76.8	76.9	77.7	75.2	77.0	77.2	77.9	73.9	76.6	76.9	73.7	71.7	73.1	72.9
5	79.8	78.8	78.2	78.4	77.1	74.8	77.4	77.1	78.6	76.0	78.0	77.8	77.9	74.7	76.2	76.3	73.4	71.6	73.1	72.8
7	79.7	79.4	79.7	80.1	77.5	76.4	77.4	77.2	78.7	76.3	78.4	78.2	77.3	74.5	76.2	76.2	73.5	71.4	73.3	73.0
10	79.7	79.3	80.0	80.2	77.2	75.9	77.1	77.3	78.4	75.7	77.8	78.0	78.5	75.5	76.4	76.3	73.5	71.8	73.4	73.3
16	80.0	79.7	80.4	80.5	77.5	76.9	78.3	77.3	78.5	76.3	78.2	78.6	78.1	75.1	76.3	76.1	73.6	71.4	72.9	72.7

Abbildung 75 bis Abbildung 79 (Anhang E) zeigen die Klassifizierungsergebnisse des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der jeweiligen Untergruppe der Gruppe Textur GLCM Ansatz nach Haralick et al. mit objektbasiertem Ansatz mit dynamischen GrayLimits.

5.2.5 Gruppe Textur Diskrete Stationäre Wavelet Transformation

Eine Zusammenfassung des besten Klassifizierungsergebnisses jedes Wavelets aus fünf verschiedenen Waveletfamilien befindet sich in Tabelle 20.

Die höchste Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes liefert dabei das 20cm Eingangsbild mit dem dmey Wavelet aus der Discrete Meyer Familie auf dem Infrarotkanal angewendet zuzüglich Standardset mit 83.1 %. Das beste erzielte Ergebnis liegt somit 2.5 % Punkte unter dem besten Klassifizierungsergebnis mit allen Variablen des 20 cm Bildes. Mit sinkender Bodenauflösung des Eingangsbildes sinkt die erzielte Genauigkeit. Aus den Ergebnissen ist ersichtlich, dass das Arbeiten mit hohen Bodenauflösungen erforderlich ist.

Tabelle 20: Zusammenfassung der besten Klassifizierungsergebnisse des unabhängigen Testdatensatzes der Variablensets zuzüglich Standardset jedes Wavelets (WL). Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Klassifizierungsgenauigkeit Trainingsdatensatz in *Klammer*. Spektraler Kanal auf dem das höchste Ergebnis berechnet wurde in zweiter Zeile.

			Eingangsbild		
WL	20cm	100cm	100cm fm	200cm	500cm
bior 1.1	82.5 <i>(</i> 82.2)%	80.7 <i>(80.5)</i> %	80.2 <i>(81.0)</i> %	80.8 <i>(80.3)</i> %	74.5 <i>(75.1)</i> %
	Nahes Infrarot	Nahes Infrarot	Nahes Infrarot	Nahes Infrarot	Blau
coif 1	82.7 <i>(82.5)</i> %	81.2 <i>(</i> 82.2)%	80.5 <i>(81.7)</i> %	80.2 <i>(79.8)</i> %	74.4 (75.9)%
	Blau	Blau	Blau	Nahes Infrarot	Nahes Infrarot
db 1	82.3 <i>(82.2)</i> %	80.7 <i>(80.9)</i> %	80.2 <i>(80.8)</i> %	80.8 (80.1)%	74.6 (75.3)%
	Nahes Infrarot	Nahes Infrarot	Nahes Infrarot	Nahes Infrarot	Nahes Infrarot
dmey	83.1 (82.4)%	80.9 <i>(81.4)</i> %	79.9 <i>(81.2)</i> %	79.9 <i>(79.2)</i> %	74.2 (75.1)%
	Nahes Infrarot	Blau	Nahes Infrarot	Blau	Nahes Infrarot
sym 2	82.4 (83.3)%	81.3 <i>(81.3)</i> %	80.5 <i>(80.8)</i> %	80.8 <i>(79.6)</i> %	74.4 (75.1)%
	Nahes Infrarot	Nahes Infrarot	Blau	Nahes Infrarot	Nahes Infrarot

Die normalisierte Wichtigkeit der Eingangsvariablen des Variablensets mit höchster Klassifzierungsgenauigkeit je Auflösung (Abbildung 27), lässt erkennen, dass die wichtigsten Variablen für die Klassifizierung aus allen verfügbaren Variablen kommen. Die Wichtigkeit des H Bildes ist etwas geringer als jene der anderen Bilder.



Abbildung 27: Normalisierte MDA Wichtigkeit der Eingangsvariablen je Auflösung des Variablensets mit höchstem Klassifizierungsergebnis, getrennt nach Standardset und den vier Ergebnisbildern der diskreten stationären Wavelettransformation des besten Klassifizierungsergebnisses je Eingangsbild. A Bild: Approximation, D Bild: diagonale Filterung, H Bild: horizontale Filterung, V Bild: vertikale Filterung.

Der zusammenfassende Vergleich des Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der Gruppe Textur mit DSWT Ansatz in Tabelle 21 zeigt, dass

das Klassifizierungsergebnis durch Verwendung aller Variablen teilweise gesteigert werden kann. Die Klassifizierung mit den 10 wichtigsten Variablen MDA/MDG zuzüglich Standardset führt in den meisten Fällen zu einer Verbesserung des Ergebnisses. Die höchste Klassifizierungsgenauigkeit dieser Gruppe wird durch die Auswahl der 10 wichtigsten Variablen anhand der MDG Wichtigkeit der ,coif 1^c Wavelets auf dem 20 cm Bild zuzüglich Standardset mit 84.2 % erreicht. Das erzielte Ergebnis entspricht dem höchsten Klassifizierungsergebnis welches mit dem GLCM Ansatz nach Haralick erzielt wurde und ist 1.3 % Punkte geringer als das Ergebnis bei Klassifizierung mit allen Variablen des 20 cm Bildes.

Tabelle 21: Zusammenfassung des Klassifizierungsergebnisses des unabhängigen Testdatensatzes des besten Variablensets der Untergruppe zuzüglich Standardset, aller Variablen der Untergruppe zuzüglich Standardset, 10 wichtigste Variablen der Untergruppe nach MDA zuzüglich Standardset und 10 wichtigste Variablen der Untergruppe nach MDG zuzüglich Standardset. Bestes Ergebnis pro Eingangsbild ist **fett** geschrieben. Werte in [%].

	Eingangsbild																					
	20cm 100cm										100cm fm				200cm				500cm			
WL	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG		
bior 1.1	82.5	83.1	83.5	82.3	80.7	80.8	80.2	79.5	80.2	80.3	80.3	80.6	80.8	80.1	79.3	79.5	74.5	74.2	74.1	74.5		
coif 1	82.7	82.8	84.1	84.2	81.2	81.7	81.0	80.7	80.5	80.5	80.7	81.5	80.2	79.9	79.9	80.7	74.4	74.8	73.8	74.1		
db 1	82.3	83.0	83.4	82.1	80.7	80.8	80.3	79.6	80.2	80.4	80.4	80.8	80.8	80.1	79.2	79.9	74.6	74.1	74.7	74.5		
dmey	83.1	83.3	83.8	82.6	80.9	80.5	81.4	81.3	79.9	79.7	80.8	80.8	79.9	79.3	78.9	79.6	74.2	74.7	74.3	74.4		
sym 2	82.4	82.9	83.7	83.8	81.3	81.0	80.6	79.8	80.5	80.6	81.5	81.2	80.8	79.9	79.7	79.5	74.4	74.1	74.8	74.9		

Abbildung 80 bis Abbildung 83 (Anhang E) zeigen die Klassifizierungsergebnisse des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der jeweiligen Untergruppe der Gruppe Textur mit DSWT Ansatz.

5.2.6 Gruppe Grauwertverteilung im Objekt

Eine Zusammenfassung des höchsten Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets der Gruppe Grauwertverteilung im Objekt (Datadistribution) zuzüglich Standardset zeigt

Tabelle 22. Bei allen Eingangsbildern wird das höchste Klassifizierungsergebnis unter Verwendung der GEV Verteilung auf den vier spektralen Kanälen IR/R/G/B und vier Vegetationsindizes NDVI, AVI, TVI und SAVI erzielt. Das höchste Klassifizierungsergebnis erzielt das 20cm Bild mit 80.9 %. Das entspricht 4.6 % Punkte weniger als das Ergebnis mit allen Variablen des 20 cm Bildes. Der Einfluss der räumlichen Auflösung ist mit Ausnahme des 500 cm Bildes sehr gering.

Tabelle 22: Zusammenfassung der besten Klassifizierungsergebnisse des unabhängigen Testdatensatzes der Variablensets zuzüglich Standardset jedes Wavelets (WL). Bestes Ergebnis pro Eingangsbild ist **fett** geschrieben. Klassifizierungsgenauigkeit Trainingsdatensatz in *Klammer*. Variablen der Schätzwerte für Verteilung von vier Kanälen IR/R/G/B (4K) und vier Vegetationsindizes NDVI/AVI/TVI/SAVI (4VI).

	Eingangsbild												
	20cm	100cm	100cm fm	200cm	500cm								
Ergebnis	80.9 <i>(81.1)</i> %	79.9 <i>(79.0)</i> %	80.8 <i>(80.6)</i> %	80.4 <i>(79.6)</i> %	75.7 (76.5)%								
Verteilung	GEV 4K+4VI	GEV 4K+4VI	GEV 4K+4VI	GEV 4K+4VI	GEV 4K+4VI								

Der zusammenfassende Vergleich des Klassifizierungsergebnisses des unabhängigen Testdatensatzes der Variablensets zuzüglich des Standardsets der Gruppe Textur mit DSWT Ansatz in Tabelle 23 zeigt, dass mit Ausnahme des 20 cm und 200 cm Bildes das Klassifizierungsergebnis durch Verwendung aller Variablen gesteigert werden kann. Die Auswahl der 10 wichtigsten Variablen MDA/MDG zuzüglich Standardset bewirkt bei allen Eingangsbildern eine Verschlechterung des Klassifizierungsergebnisses.

Tabelle 23: Zusammenfassung des Klassifizierungsergebnisses der besten einzelnen Variablengruppe, aller Variablen, 10 wichtigste Variablen nach MDA und 10 wichtigste Variablen nach MDG. Bestes Ergebnis pro Eingangsbild ist fett geschrieben. Werte in [%]. Verteilungsfunktion mit höchstem Ergebnis in zweiter Zeile.

Eingangsbild

									•	•									
20cm				100cm				100cm fm			200cm				500cm				
Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG	Bestes Variablenset	Alle Variablen der Untergruppe	10 wichtigste MDA	10 wichtigste MDG
80.9	81.7	79.0	77.4	79.9	80.2	77.9	77.4	80.8	81.2	79.3	78.8	80.4	80.1	77.8	77.7	75.7	76.6	74.7	75.1

Bei allen Verteilungsfunktionen ist das Klassifizierungsergebnis höher, wenn zu den Variablen der vier Spektralen Kanäle IR/R/G/B jene der vier Vegetationsindizes NDVI/AVI/TVI/SAVI hinzugefügt werden (vgl. Abbildung 84, Anhang E). Die GEV Verteilung liefert bei allen Eingangsbildern die höchste Klassifizierungsgenauigkeit, das 500 cm Bild liefert eine deutlich geringere Genauigkeit als die anderen vier Eingangsbilder.

5.2.7 Vergleich der Gruppen

Eine Zusammenfassung der höchsten Klassifizierungsgenauigkeiten jeder getesteten Gruppe mit den jeweiligen Parametern, sowie die Anzahl an Variablen die für die Klassifizierung verwendet wird findet sich in Tabelle 24.

Tabelle 24: Zusammenfassung der besten Klassifizierungsergebnisse jeder Gruppe. Bestes Ergebnis pro Eingangsbild ist **fett** geschrieben. Anzahl Variablen in *Klammer*, Variablenset mit Parametern in zweiter Zeile. 4 Parameter = Contrast, Correlation, Energy und Homogeneity; MW = Moving Window mit Größenangabe in Pixel; NL = NumLevels; 4K = IR/R/G/B; 4VI = NDVI, AVI, TVI, SAVI;

			Eingangsbild		
Gruppe	20cm	100cm	100cm fm	200cm	500cm
Standardset	77.4% (12)	76.6% <i>(12)</i>	77.8% (12)	76.8% (12)	73.6% (12)
Alle Variablen aller Gruppen	85.5% (2144)	85.1% <i>(2144)</i>	83.7% (2144)	83.2% (1664)	80.0% (1664)
Vegetations- indizes	79.7% <i>(15)</i> SAVI	78.9% <i>(15)</i> NDVI	80.1% <i>(15)</i> NDVI	78.7% <i>(22)</i> 10 wichtigste MDA	75.2% <i>(22)</i> 10 wichtigste MDA
Textur GLCM Moving Window fixe GrayLimits	84.2% <i>(36)</i> 4 Parameter B, NL 16, MW 51x51	81.9% <i>(108)</i> Alle Variablen der Gruppe, NL 16, MW 11x11	82.0% <i>(108)</i> Alle Variablen der Gruppe, NL 16, MW 51x51	81.1% <i>(108)</i> Alle Variablen der Gruppe, NL 16, MW 51x51	77.4% (108) Alle Variablen der Gruppe, NL 16, MW 25x25
Textur GLCM Objekt, fixe GrayLimits	80.8% (24) Homog. IR/R/G/B NL 32	79.1% <i>(24)</i> Energy IR/R/G/B NL 64	80.2% <i>(24)</i> Energy IR/R/G/B NL 32	78.6% <i>(24)</i> Energy IR/R/G/B NL 16	73.9% <i>(22)</i> 10 wichtigste MDG NL 32
Textur GLCM Objekt, dyn. GrayLimits	80.5% <i>(22)</i> 10 wichtigste MDG NL 16	78.3% <i>(22)</i> 10 wichtigste MDA NL 16	78.7% <i>(24)</i> Energy IR/R/G/B NL 7	78.5% <i>(24)</i> Energy IR/R/G/B NL 10	73.7% <i>(24)</i> Energy IR/R/G/B NL 4
Textur DSWT	84.2% (22) 10 wichtigste MDG coif 1	81.4% <i>(22)</i> 10 wichtigste MDA dmey	81.5% <i>(22)</i> 10 wichtigste MDG coif 1	80.8% <i>(36)</i> IR Kanal db 1	74.9% <i>(22)</i> 10 wichtigste MDG sym 2
Grauwertverteilung im Objekt	80.9% <i>(36)</i> GEV 4K + 4VI	79.9% <i>(36)</i> GEV 4K + 4VI	80.8% <i>(36)</i> GEV 4K + 4VI	80.4% <i>(36)</i> GEV 4K + 4VI	75.7% <i>(36)</i> GEV 4K + 4VI

Der Vergleich der verschiedenen Gruppen (Abbildung 28) zeigt, dass die Klassifizierung mit dem Standardset zuzüglich Texturinformation nach dem GLCM Ansatz nach Haralick et al. bei allen Eingangsbildern das jeweils höchste Ergebnis liefert. Das zweite höchste Klassifizierungsergebnis liefert die Gruppe Texturinformation mittels diskreter stationärer Wavelet Transformation (DSWT).



Abbildung 28: Zusammenfassung der besten Klassifizierungsergebnisse je Gruppe des systematischen Tests, getrennt nach den fünf Auflösungen.

Das höchste Klassifizierungsergebnis von 84.2 % wird auf dem 20 cm Bild, sowohl durch den GLCM Ansatzes nach Haralick et al. erreicht, als auch durch den DSWT Ansatz. Aufgrund des hohen Rechenaufwandes und der damit verbundenen Rechenzeiten des Moving Window Ansatzes ist die Texturinformation des DSWT Ansatzes vorzuziehen. Bezüglich der maximal erzielbaren Klassifizierungsgenauigkeit zeigt sich, dass das Bild mit 500 cm Bodenauflösung deutlich schlechtere Ergebnisse liefert, als die anderen getesteten Auflösungen. Die Anwendung des focal median Filters auf das 100 cm Bild bewirkt bei einzelnen Variablengruppen eine Erhöhung der Klassifizierungsgenauigkeit, bezüglich des maximal erzielten Ergebnisses der Gruppen kann aber keine Verbesserung beobachtet werden. Bei der Klassifizierung mit allen Variablen je Auflösung ist das Ergebnis ohne focal median Filter sogar um 1.4 % Punkte besser als mit Filter.

Bei jenen Gruppen, wo das höchste Ergebnis durch Klassifizierung mit den 10 wichtigsten Variablen MDA/MDG zuzüglich Standardset erzielt wird, ist davon auszugehen, dass in den Variablen dieser Gruppe viele mit geringer oder keiner Aussagekraft vorhanden sind. Das Vorhandensein solcher Variablen beeinflusst das Klassifizierungsergebnis negativ.

Die Konfusionsmatrizen der höchsten Klassifizierungsergebnisse je Gruppe befinden sich in Anhang D, eine grafische Darstellung des Klassifizierungsergebnisses mit allen Variablen des 20 cm Bildes in Abbildung 29.



Abbildung 29: Klassifizierungsergebnis mit allen Variablen des 20cm Bildes. Schraffierte Bereiche unterscheiden sich von Referenzklassifizierung. Klassifizierung mit 6 Klassen in Bild a) und 4 Klassen in Bild b).

5.2.8 Klassifizierung mit allen Eingangsvariablen

Das Klassifizierungsergebnis mit allen Eingangsvariablen aller Auflösungen ist in Form einer Konfusionsmatrix in Tabelle 25 dargestellt, die Konfusionsmatrix für die Klassifizierung mit allen Eingangsvariablen aller Auflösungen ohne die mittels Moving Window Ansatz ermittelten Texturparameter in Tabelle 26. Durch Verwendung aller Variablen kann eine Klassifizierungsgenauigkeit von 85.6 % erzielt werden. Das Ergebnis für die Variablen ohne Moving Window Ansatz, die deutlich weniger rechenintensiv sind, ist mit 84.5 % geringfügig niedriger. Im Vergleich zu den besten

Klassifizierungsergebnissen aus einer Auflösung (vgl. Tabelle 24), welches bei 84.2% liegt, ist das Klassifizierungsergebnis aller Variablen aller Auflösungen als gering höher zu betrachten. Die höchste Nutzergenauigkeit wird bei beiden Varianten bei der Klasse Latsche erzielt, die geringste bei der Klasse Nadelholz (NH). Die Trennung zwischen den Klassen Nadelholz und Laubholz (LH) ist am meisten fehlerbehaftet.

Werden die sechs Klassen in die drei Hauptklassen (Wald, Latsche und Offenland) und Klasse Schatten zusammengefasst, ergibt sich eine Klassifizierungsgenauigkeit des Testdatensatzes von 91.5 % mit allen Variablen aller Auflösungen und 90.4 % mit allen Variablen aller Auflösungen ohne MW Ansatz.

Tabelle 25: Konfusionsmatrix der Klassifizierung des unabhängigen Testdatensatzes mit allen Variablen aller Auflösungen. P Acc = Produzentengenauigkeit, U Acc = Nutzergenauigkeit. NH ... Nadelholz, LH ... Laubholz, OL ... Offenland

	NH	LH	Latsche	OL Gras	OL Fels	Schatten		U Acc.
NH	537	79	16	32	1	18	683	0.786
LH	24	194	0	6	1	2	227	0.855
Latsche	9	1	353	12	0	3	378	0.934
OL Gras	25	12	20	457	10	2	526	0.869
OL Fels	0	0	5	22	240	2	269	0.892
Schatten	13	3	3	1	5	158	183	0.863
_	608	289	397	530	257	185	2 266	
P Acc.	0.883	0.671	0.889	0.862	0.934	0.854		0.856
Карра	0.820							

Tabelle 26: Konfusionsmatrix der Klassifizierung des unabhängigen Testdatensatzes mit allen Variablen aller Auflösungen ohne die mittels Moving Window Ansatz ermittelten Texturparameter. P Acc = Produzentengenauigkeit, U Acc = Nutzergenauigkeit. NH ... Nadelholz, LH ... Laubholz, OL ... Offenland

	NH	LH	Latsche	OL Gras	OL Fels	Schatten		U Acc.
NH	532	79	32	34	1	21	699	0.761
LH	26	192	2	6	0	1	227	0.846
Latsche	11	1	336	12	1	2	363	0.926
OL Gras	26	14	19	457	9	2	527	0.867
OL Fels	0	0	5	20	240	2	267	0.899
Schatten	13	3	3	1	6	157	183	0.858
_	608	289	397	530	257	185	2 266	
P Acc.	0.875	0.664	0.846	0.862	0.934	0.849		0.845
Kappa	0.806							

5.2.9 Variablenauswahl anhand der MDA Wichtigkeit

Da die meisten Variablen Datensatz hoch korreliert sind, wurde die Klassifizierung mit einem Teil der nach MDA Wichtigkeit gereihten Variablen des Datensatzes mit allen Variablen aller Auflösungen ohne MW Ansatz durchgeführt. Das Klassifizierungsergebnis des Testdatensatzes zeigt Abbildung 30.
Mit den 300 besten Variablen (vgl. Abbildung 30) wird eine Klassifizierungsgenauigkeit von 86.1% erreicht und liegt somit höher als die Klassifizierungsgenauigkeit aller Variablen aller Eingangsbilder.



Abbildung 30: Klassifizierungsgenauigkeit des Testdatensatzes bei Training mit den n-wichtigsten Variablen nach MDA des Klassifizierungsergebnisses aller Variablen aller Auflösungen ohne Texturparameter des Moving Window Ansatzes.

Der Rückgang der Klassifizierungsgenauigkeit des Testdatensatzes bei steigender Variablenanzahl – hier im Bereich zwischen 300 und 1500 Variablen – weist auf das Auftreten des Hughes Phänomens hin (Richards 1993, 364). Durch die hohe Anzahl an Variablen stehen nicht genug Trainingsobjekte je Variable zur Verfügung, was einen Rückgang der Klassifikationsgenauigkeit bewirkt. Die Klassifikationsgenauigkeit des Trainingsdatensatzes stabilisiert sich ab einer Variablenanzahl von 300 Variablen.

Der Vergleich der nach MDA Wichtigkeit 300 wichtigsten Variablen bezüglich ihrer Gruppenzugehörigkeit zeigt, dass sowohl bei der Klassifizierung mit allen Variablen aller Eingangsbilder als auch bei der Klassifizierung mit allen Variablen aller Eingangsbilder ohne Moving Window (MW) Ansatz die Verhältnisse zwischen der Information der Datadistribution, Spektral und Vegetationsindizes sowie Textur gleich bleibt (Abbildung 31). Innerhalb der Texturinformation liefern bei Vorhandensein der mittels MW Ansatz gerechneten Variablen diese rund 35 % der Variablen. Abbildung 32 zeigt die Gruppenzugehörigkeit aller Variablen aller Auflösungen. Daraus ist zu erkennen, dass die Gruppen mit texturaler Information beim Datensatz mit allen Variablen aller Auflösungen 96 % der Variablen ausmachen (Abbildung 32b) und beim Datensatz mit allen Variablen aller Auflösungen ohne MW Ansatz 94 % (Abbildung 32a).



Abbildung 31: Gruppenzugehörigkeit der 300 wichtigsten Variablen nach MDA Wichtigkeit für die Klassifizierung mit allen Variablen aller Auflösungen ohne Moving Window Ansatz (a) und allen Variablen aller Auflösungen (b).



Abbildung 32: Gruppenzugehörigkeit aller Variablen aller Auflösungen ohne Moving Window Ansatz (a) und allen Variablen aller Auflösungen (b).

5.2.10 Klassifizierungsergebnisse der Hauptklassen

Um die drei Hauptklassen (Wald, Latsche, Offenland) spektral besser trennen zu können, wurden die Objekte in sieben Klassen klassifiziert wobei Objekte der Klasse Sonstige vom Test ausgeschlossen wurden.

Die Klassen Nadel- und Laubholz können zur Klasse Wald, Offenland Gras und Offenland Fels zur Klasse Offenland aggregiert werden. Die Klasse Schatten kann nicht eindeutig einer der drei Hauptklassen zugewiesen werden, weshalb diese Klasse zusätzlich ausgewiesen wird. Für die besten Klassifizierungsergebnisse des systematischen Tests sind die Ergebnisse für die sechs Klassen und die Klassen in Tabelle 27 dargestellt. Die im Projekt aggregierten vier "Erstellung einer Wald/Offenlandmaske aus digitalen Orthofotos" geforderte Klassifizierungsgenauigkeit von größer 90 % wird wie in Tabelle 27 zu sehen ist mehrfach erreicht. Die Einbeziehung von texturaler Information ist erforderlich um die gewünschte Genauigkeit zu erzielen. Das Klassifizierungsergebnis der Hauptklassen liegt um 6 – 7 % Punkte über dem Ergebnis mit sechs Klassen.

Tabelle 27: Ergebnis der besten Klassifizierungsergebnisse au	us dem systematischen Test in 6 Klassen und 4 Klassen
(3 Hauptklassen + Schatten).	

Gruppe	6 Klassen	4 Klassen
Standardset	77.4 %	84.6 %
Alle Variablen aller Gruppen	85.5 %	91.2 %
Vegetationsindizes	79.7 %	86.4 %
Textur GLCM Moving Window fixe GrayLimits	84.2 %	91.4 %
Textur GLCM Objekt, fixe GrayLimits	80.8 %	87.6 %
Textur GLCM Objekt, dyn. GrayLimits	80.5 %	87.8 %
Textur DSWT	84.2 %	90.2 %
Grauwertverteilung im Objekt	80.9 %	87.2 %
Alle Variablen aller Auflösungen	85.6 %	91.5 %
Alle Variablen aller Auflösungen ohne MW Ansatz	84.5 %	90.4 %
300 wichtigste Variablen MDA aller Variablen aller Auflösungen ohne MW Ansatz	86.1 %	91.9 %

Das höchste erzielte Klassifizierungsergebnis des systematischen Tests wird auf sechs Klassen und vier Klassen bezogen mit den 300 wichtigsten Variablen MDA aller Variablen aller Auflösungen ohne MW Ansatz erzielt. Die graphische Darstellung (vgl. Abbildung 33) zeigt, dass viele Fehlklassifizierungen zwischen den Klassen Nadel- und Laubholz vorhanden sind, welche beide der Hauptklasse Wald angehören.



Abbildung 33: Klassifizierungsergebnis mit den 300 wichtigsten Variablen nach MDA Wichtigkeit aller Variablen aller Auflösungen ohne MW Ansatz. Schraffierte Bereiche unterscheiden sich von Referenzklassifizierung. Klassifizierung mit 6 Klassen in Bild a) und 4 Klassen in Bild b).

5.2.11 Analyse der Klassenzuweisung der Objekte

Die Klassifizierungsergebnisse des systematischen Tests zeigen, dass bei Verwendung verschiedener Variablenkombinationen zur Klassifizierung des Testdatensatzes, maximal 86.1 % der Objekte (rund 1950 Objekte) die selbe Klasse wie im Referenzdatensatz zugewiesen wird. Um zu überprüfen, ob immer die selben Objekte richtig und falsch klassifiziert werden, wurde die Klassenzuweisung der Objekte des Trainingsdatensatzes und des Testdatensatzes von allen Klassifizierungsergebnissen des systematischen Tests, die eine gleich hohe oder höhere Klassifizierungsgenauigkeit wie das Standardset aufweisen, analysiert. Das Ergebnis dieser Analyse ist in Abbildung 34 dargestellt und zeigt, dass rund 25 % der Objekte des Trainings- und Testdatensatzes immer richtig und circa 1 % der Objekte nie richtig klassifiziert werden. Aus diesem Ergebnis ist ersichtlich, dass 75 % der Objekte des Datensatzes bei unterschiedlich trainiertem RF Klassifikator unterschiedlichen Klassen zugewiesen werden.



Abbildung 34: Analyse der Übereinstimmung der Klassenzuweisung durch den RF Klassifikator aller Objekte des Trainings- und Testdatensatzes bei allen Klassifizierungsergebnissen des systematischen Tests welche Klassifizierungsgenauigkeiten gleich oder höher jener des Standardsets erzielen.

Die Räumliche Verteilung der Objekte, welche durch den RF Klassifikator immer die gleiche und nie die gleiche Klasse wie der Referenzdatensatz erhalten ist in Abbildung 35 dargestellt. Die immer richtig klassifizierten Objekte bilden dabei größere, zusammenhängende Flächen. Die immer falsch klassifizierten Objekte sind über das gesamte Testgebiet A verteilt, ein Zusammenhang der Objekte ist nicht zu erkennen. Im Zentrum des Testgebietes A sind kaum immer richtig klassifizierte Objekte zu finden. Der Vergleich mit der Referenzklassifizierung (Abbildung 8, Seite 20) zeigt, dass in diesem Bereich vermehrt die Klassen Laubholz und Nadelholz auftreten.

Vergleicht man die Klassenzugehörigkeit der immer richtig klassifizierten Objekte mit jener der Grundgesamtheit (Abbildung 36a), zeigt sich, dass die Klassen Laubholz und Nadelholz seltener immer richtig klassifiziert werden, als dies aus der Grundgesamtheit zu erwarten wäre. Die Klassen Offenland Gras, Offenland Fels und Schatten werden hingegen öfter immer richtig klassifiziert als zu erwarten wäre. Eine Auswertung bezüglich der Größenklassen in Abbildung 36b zeigt, dass die kleinsten Objekte (100 – 1099 m²) seltener und die Größenklasse 1100 – 2099 m² häufiger immer richtig klassifiziert wird als es aus der Grundgesamtheit zu erwarten wäre.

Die immer falsch klassifizierten Objekte stammen wie Abbildung 36a zeigt vermehrt aus der Klasse den Klassen Offenland Gras und Schatten. Die Klasse Nadelholz wird am wenigsten oft immer falsch klassifizierten Objekte stammen vermehrt aus der kleinsten Größenklasse (Abbildung 36b).



Abbildung 35: Räumliche Verteilung der Objekte, die immer und nie durch den RF Klassifikator die gleiche Klasse wie die Referenzklassifizierung zugewiesen bekommen haben.



Abbildung 36: Verhältnis der immer richtig und immer falsch klassifizierten Objekte bezogen auf die Klassenzugehörigkeit (a) und Objektgröße (b) im Vergleich zur Grundgesamtheit der Objekte.

Der Trainings- und Testdatensatz weisen zusammen 47 Objekte auf, welche immer falsch klassifiziert werden. Das heißt diesen Objekten wird nie die Klasse des Referenzdatensatzes zugewiesen. Die Analyse dieser 47 Objekte ergibt, dass davon 12 Objekten im Referenzdatensatz eine falsche Klasse zugewiesen wurde, 26 Objekten keine eindeutige Klasse zugewiesen werden kann (Objekt mit Mischklassen) und 9 Objekte vom RF Klassifikator nicht richtig klassifiziert werden.

5.3 Suche nach geeigneten Variablenkombinationen mittels Zufallsauswahl

Eine Zusammenfassung der höchsten erzielten Klassifizierungsgenauigkeit mit einer zufällig gezogenen Variablenkombination ist in Tabelle 28 zu finden. Die Variablenkombinationen sind in Anhang B (Tabelle 39 und Tabelle 40) angeführt. Der Trainings- und Testdatensatz bei diesem Test sind im Vergleich zu den anderen Tests dieser Arbeit vertauscht.

Die besten Ergebnisse sind bei den Kombinationen mit 15 und 20 Variablen zu finden, wobei die zufälligen Variablenkombinationen aus allen Variablen aller Gruppen eine um 0.5 % bis 1.0 % Punkte höhere Klassifizierungsgenauigkeit erzielen.

Auf Grund der hohen Anzahl von möglichen Variablenkombinationen ist es nicht möglich alle dieser zu testen. Daher wurde eine große Anzahl zufällig gezogener Variablenkombinationen (vgl. Tabelle 28) klassifiziert. Bei den besten Variablenkombinationen handelt es sich also um die beste gefundene Kombination und nicht die beste mögliche Kombination. Die beste Kombination mit 20 Variablen mit und ohne MW Ansatz liefert eine gleich hohe Klassifizierungsgenauigkeit wie die Klassifizierung mit allen Variablen aller Eingangsbilder mit und ohne MW Ansatz.

Tabelle 28: Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes (Test) und Trainingsdatensatzes (Training) durch die beste gefundene Variablenkombination je Variablenanzahl sowie die Anzahl der getesteten zufälligen Variablenkombinationen (Anzahl) getrennt nach dem Datensatz mit allen Variablen aller Auflösungen und allen Variablen aller Auflösungen ohne MW Ansatz. Auswahlkriterium für die beste Variablenkombination ist die höchste Klassifizierungsgenauigkeit am unabhängigen Testdatensatz.

	Alle Variablen aller Auflösungen			Alle Variablen aller Auflösungen ohne MW			
Variablen	Test	Training	Anzahl	Test	Training	Anzahl	
5	0.821	0.809	171 033	0.804	0.793	160 124	
10	0.839	0.824	123 134	0.828	0.829	109 740	
15	0.846	0.820	135 333	0.841	0.826	122 804	
20	0.853	0.848	155 949	0.847	0.832	145 039	

Die Klassifizierungsergebnisse mit den 50 und 100 wichtigsten Variablen aus den 100 besten Kombinationen von 5, 10, 15 und 20 Variablen sind in Tabelle 29 zusammengefasst. Die Ergebnisse weisen nur geringe Unterschiede der Klassifizierungsergebnisse zwischen den verschiedenen Sets aus Variablen auf. Auch bei diesem Test sind die Ergebnisse bei Verwendung der Variablen mit den Texturparametern des MW Ansatzes um 0.5 % bis 1.5 % Punkte höher als ohne.

Tabelle 29: Klassifizierungsgenauigkeit des Testdatensatzes (Test) und des Trainingsdatensatzes (Training) durch die 50 und 100 wichtigsten Variablen der Variablenkombination. Bewertung der Wichtigkeit erfolgt anhand der Summe der gewichteten MDA Wichtigkeit der jeweiligen Variablen aus dem Klassifizierungsergebnis mit N zufällig gezogenen Variablen.

	Alle Vari Auflö	ablen aller sungen	Alle Variablen aller Auflösungen ohne MW	
Variablen	Test	Training	Test	Training
50 wichtigste aus Kombinationen von 5 Variablen	0.844	0.835	0.824	0.822
100 wichtigste aus Kombinationen von 5 Variablen	0.842	0.837	0.834	0.825
50 wichtigste aus Kombinationen von 10 Variablen	0.840	0.834	0.835	0.826
100 wichtigste aus Kombinationen von 10 Variablen	0.848	0.835	0.835	0.828
50 wichtigste aus Kombinationen von 15 Variablen	0.849	0.837	0.835	0.825
100 wichtigste aus Kombinationen von 15 Variablen	0.855	0.843	0.842	0.835
50 wichtigste aus Kombinationen von 20 Variablen	0.841	0.830	0.834	0.834
100 wichtigste aus Kombinationen von 20 Variablen	0.852	0.840	0.840	0.836

Der Vergleich der 100 wichtigsten Variablen aus den 100 besten Klassifizierungsergebnissen je Variablenanzahl mit den 100 wichtigsten Variablen nach MDA und MDG Wichtigkeit der Klassifizierung mit allen Variablen zeigt Übereinstimmungen von 26 - 53% wie in Tabelle 30 zu sehen ist. Die Übereinstimmung bei allen Variablen ist deutlich höher als bei allen Variablen ohne MW Ansatz.

Tabelle 30: Übereinstimmung der 100 wichtigsten Variablen der Zufallsauswahl mit den 100 wichtigsten Variablen nach MDG und MDA bei Klassifizierung mit allen Variablen und allen Variablen ohne Moving Window (MW) Ansatz.

	Alle Varial Grup	blen der pe	Variablen ohne MW		
Variablen	MDG	MDA	MDG	MDA	
5	0.44	0.46	0.27	0.26	
10	0.53	0.56	0.32	0.31	
15	0.52	0.52	0.31	0.29	
20	0.53	0.50	0.28	0.26	

Die Übereinstimmung von mindestens 26 und maximal 53 Variablen innerhalb der wichtigsten 100 Variablen erklärt die ähnlich hohen Klassifizierungsergebnisse wie bei Klassifizierung mit den 100 besten Variablen aller Variablen.

Die Aufteilung der 100 wichtigsten Variablen nach den getesteten Gruppen ist in Abbildung 37 für Alle Variablen der Gruppe und in Abbildung 38 für Alle Variablen der Gruppe ohne MW Ansatz dargestellt.

Die vier Gruppen der Texturparameter nehmen dabei einen Variablenanteil von 56 % bis 67 % der Variablen ein. Der Großteil der Texturvariablen stammt dabei aus den Gruppen der Diskreten Stationären Wavelet Transformation (DSWT) und der GLCM Parameter aus dem MW Ansatz. Die 50 wichtigsten Variablen je Anzahl von Variablenkombinationen sind in Anhang C angeführt.



Abbildung 37: Verteilung der 100 wichtigsten Variablen der Zufallsauswahl aus allen Variablen aller Auflösungen nach Gruppen. a) 5 Zufallsvariablen, b) 10 Zufallsvariablen, c) 15 Zufallsvariablen, d) 20 Zufallsvariablen DAT ... Datadistribution, S/VI ... Spektral und Vegetationsindizes, GLCM 1 ... GLCM Texturmaße mit MW Ansatz, GLCM 3 ... GLCM Texturmaße Objekt mit fixen GrayLimits.



Abbildung 38: Verteilung der 100 wichtigsten Variablen der Zufallsauswahl aus allen Variablen aller Auflösungenohne Moving Window Ansatz nach Gruppen. a) 5 Zufallsvariablen, b) 10 Zufallsvariablen, c) 15 Zufallsvariablen, d)20 ZufallsvariablenDAT ... Datadistribution, S/VI ... Spektral und Vegetationsindizes, GLCM 2 ... GLCMTexturmaße Objekt mit dyn. GrayLimits, GLCM 3 ... GLCM Texturmaße Objekt mit fixen GrayLimits.

5.4 Auswirkung der Trainingsobjekte

5.4.1 Anzahl der Trainingsobjekte

Die Auswirkung der Anzahl von Trainingsobjekten auf die Klassifizierungsgenauigkeit ist für die unterschiedlichen Eingangsbilder in Form von Boxplots in Abbildung 39 für das 20 cm Bild für die Variablen des Standardsets dargestellt. Die Boxplots der anderen Eingangsbilder befinden sich in Anhang A (Abbildung 47 bis Abbildung 54).

Die Trainingsobjekte wurden zufällig aus allen Objekten je Klasse gezogen, die Eingangsvariablen entsprechen jenen des Standardsets (Mittelwert, Median und Standardabweichung der Kanäle IR/R/G/B). Die Ergebnisse zeigen, dass die Klassifizierungsgenauigkeit im Bereich größer 100 Objekte pro Klasse mit zunehmender Objektanzahl nicht mehr stark zunimmt. Die Streuung innerhalb der getesteten Datensätze nimmt mit steigender Objektanzahl ab.



Abbildung 39: Auswirkung der Anzahl von zufällig gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes. Eingangsbild 20cm, Variablen des Standardsets, Boxplot von je 1000 zufälligen Kombinationen von Trainingsobjekten.

Der Vergleich der Mediane der Klassifizierungsergebnisse in Abbildung 40 zeigt, dass die Eingangsbilder mit geringerer Bodenauflösung unabhängig von der Anzahl von Trainingsobjekten je Klasse eine schlechtere Klassifizierungsgenauigkeit liefern als jene mit höherer Bodenauflösung.

Die Bilder 20 cm und 100 cm focal median liefern beinahe idente Ergebnisse, weshalb in Abbildung 40 die Linie des 20 cm Bildes nicht zu sehen ist.



Abbildung 40: Vergleich der Mediane der Klassifizierungsergebnisse des unabhängigen Testdatensatzes mit den Variablen des Standardsets von 1000 zufälligen Kombinationen von Trainingsobjekten in Abhängigkeit der Anzahl gezogener Objekte je Klasse.

5.4.2 Größe der Trainingsobjekte

Die Auswirkung der Anzahl und die Größe von Trainingsobjekten auf die Klassifizierungsgenauigkeit ist für das 20 cm Eingangsbild für die Variablen des Standardsets in Form von Boxplots in Abbildung 41 und Abbildung 42 dargestellt.

Erfolgt das Training nur mit großen Objekten (Abbildung 41), ist der Median der Klassifizierungsgenauigkeit deutlich höher als beim Training mit den kleinsten Objekten (Abbildung 42). Dieser Effekt ist umso größer, je weniger Objekte je Klasse zum Training herangezogen werden. Der Boxplot der Klassifizierung mit 50 Objekten der 50 größten und 50 kleinsten Objekte zeigt die geringe Schwankung des Klassifizierungsergebnisses des RF Klassifikators.

Bezüglich der maximal erzielten Klassifizierungsgenauigkeiten ist der Unterschied zwischen den beiden Testszenarien geringer.

Das Training mit den größten Objekten (Abbildung 41) liefert kein besseres Klassifizierungsergebnis, als jenes durch zufällige Auswahl aus allen Objekten (Abbildung 39).



Abbildung 41: Auswirkung der Anzahl von zufällig aus den 50 größten Objekten je Klasse gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes. Eingangsbild 20cm, Variablen des Standardsets, Boxplot von 1000 zufälligen Kombinationen von Trainingsobjekten.



Abbildung 42: Auswirkung der Anzahl von zufällig aus den 50 kleinsten Objekten je Klasse gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes. Eingangsbild 20cm, Variablen des Standardsets, Boxplot von 1000 zufälligen Kombinationen von Trainingsobjekten.

Der Vergleich der Mediane der Klassifizierungsergebnisse bei Training mit den kleinsten und größten Objekten ist in Abbildung 43 dargestellt. Daraus ersichtlich ist, dass das Training mit den kleinsten Objekten bei allen Eingangsbildern eine deutlich niedrigere Klassifizierungsgenauigkeit liefert als jenes mit den größten Objekten.



Abbildung 43: Vergleich der Mediane der Klassifizierungsergebnisse des unabhängigen Testdatensatzes mit den Variablen des Standardsets von 1000 zufällig aus den 50 kleinsten/größten Objekten je Klasse gezogenen Kombinationen von Trainingsobjekten in Abhängigkeit der gezogenen Anzahl Objekte je Klasse.

5.4.3 Unterschied zwischen den Trainingsdatensätzen

Für diesen Test wurden 1×10⁶ zufällig gezogene Datensätze aus den Objekten des 20 cm Bildes mit den Variablen des Standardsets gebildet. Da in Standardwerken häufig 10 Objekte als minimale Anzahl Trainingsobjekte je Klasse zu finden ist und diese Anzahl von Objekten auch visuell gut verglichen werden kann, wurden die zufällig gezogenen Datensätze mit 10 Objekten je Klasse erstellt. Mit diesen Datensätzen wurde der RF Klassifikator trainiert und der unabhängige Testdatensatz klassifiziert. Von den 1×10⁶ Trainingsdatensätzen wurde eine Konfusionsmatrix für den Modus der 10 besten und 10 schlechtesten Ergebnisse erstellt, welche in Tabelle 31 und Tabelle 32 dargestellt sind. Die 10 höchsten Klassifizierungsergebnisse erreichen eine Klassifizierungsgenauigkeit von 72.6 %, welche somit 4.8 % Punkte unter dem Ergebnis des Standardsets mit allen Trainingsobjekten liegt. Die Klassen Offenland Fels (OL Fels) und Schatten erzielen eine deutlich höhere Produzentengenauigkeit als die anderen Klassen.

Die geringste Nutzer- und Produzentengenauigkeit weist die Klasse Laubholz (LH) auf welche oft mit der Klasse Nadelholz (NH) fehlklassifiziert wird.

Tabelle 31: Konfusionsmatrix des Modus für die 10 höchsten Klassifizierungsergebnisse des Testdatensatzes aus
1×106 Trainingsdatensätzen bestehend aus je 10 Objekten je Klasse. P Acc = Produzentengenauigkeit, U Acc =
Nutzergenauigkeit. NH Nadelholz, LH Laubholz, OL Offenland

	NH	LH	Latsche	OL Gras	OL Fels	Schatten		U Acc.
NH	400	75	71	36	2	15	599	0.668
LH	70	175	9	18	0	3	275	0.636
Latsche	32	6	284	43	3	4	372	0.763
OL Gras	52	19	14	386	8	1	480	0.804
OL Fels	3	5	13	46	239	2	308	0.776
Schatten	51	9	6	1	5	160	232	0.690
_	608	289	397	530	257	185	2266	
P Acc.	0.658	0.606	0.715	0.728	0.930	0.865		0.726
Kappa	0.662							

Die niedrigsten 10 Ergebnisse erreichen eine Klassifizierungsgenauigkeit von 48.1 %, diese liegt 29.3 % Punkte unter dem Ergebnis des Standardsets mit allen Trainingsobjekten.

Die höchsten Produzentengenauigkeiten weisen die Klassen Schatten und Offenland Fels auf. Die geringste Produzentengenauigkeit weist die Klasse Nadelholz (NH) mit 14.0 % auf.

Tabelle 32: Konfusionsmatrix des Modus für die 10 niedrigsten Klassifizierungsergebnisse des Testdatensatzes aus 1×10^6 Trainingsdatensätzen bestehend aus je 10 Objekten je Klasse. P Acc = Produzentengenauigkeit, U Acc =Nutzergenauigkeit. NH ... Nadelholz, LH ... Laubholz, OL ... Offenland

	NH	LH	Latsche	OL Gras	OL Fels	Schatten		U Acc.
NH	85	37	30	30	0	4	186	0.457
LH	257	187	143	18	0	4	609	0.307
Latsche	81	19	164	56	18	4	342	0.480
OL Gras	89	23	40	259	9	1	421	0.615
OL Fels	6	5	6	166	225	1	409	0.550
Schatten	90	18	14	1	5	171	299	0.572
_	608	289	397	530	257	185	2266	
P Acc.	0.140	0.647	0.413	0.489	0.875	0.924		0.481
Kappa	0.385							

Der Modus der Ränge der Variablenwichtigkeit nach MDA der zur Klassifizierung verwendeten Variablen sind in Tabelle 33 für die 10 höchsten und 10 niedrigsten Klassifizierungsgenauigkeiten zusammengefasst. Die Ränge der Variablen verschieben sich zwischen den beiden Ergebnissen gering, nur die Variable "B std Objekt" verändert ihren Rang zwischen dem höchsten und niedrigsten Ergebnis deutlich.

Modus 10 höch: Klassifizierungsgenat	ste iigkeiten Rang	Modus 10 niedrigste Klassifizierungsgenauigkeiten Rang		
IR median Objekt	1	IR median Objekt	1	
IR mean Objekt	2	B std Objekt	3	
IR std Objekt	3	R mean Objekt	3	
R mean Objekt	5	IR mean Objekt	4	
R median Objekt	5	B median Objekt	4	
B median Objekt	7	B mean Objekt	5	
G mean Objekt	7	R median Objekt	6	
B mean Objekt	8	G median Objekt	7	
G median Objekt	9	IR std Objekt	7	
B std Objekt	11	G mean Objekt	8	
G std Objekt	11	R std Objekt	10	
R std Objekt	12	G std Objekt	11	

Tabelle 33: Modus des Ranges der Variablen nach MDA Wichtigkeit der 10 höchsten/niedrigstenKlassifizierungsergebnisse. IR ... Infrarotkanal, R ... Rotkanal, G ... Grünkanal, B ... Blaukanal

Für die Variablen ,IR median Objekt' und ,R mean Objekt' sind in Abbildung 44 die Werteverteilung der Klassen des Testdatensatzes in Form eines Boxplots und die Werte der 10 besten und 10 schlechtesten Trainingsdatensätze als Punkte dargestellt.



Abbildung 44: Boxplot der Werteverteilung je Klasse im Testdatensatz und Werte der 10 besten Trainingsdatensätze (grün) und 10 schlechtesten Trainingsdatensätze (rot). a) 'IR median Objekt', b) 'R mean Objekt'

Für die Klasse Nadelholz (NH), welche eine große Differenz zwischen der Produzentengenauigkeit des höchsten und niedrigsten Klassifizierungsergebnisses aufweist, ist bei beiden Variablen ein Unterschied zwischen den besten Trainingsdaten (grün) und den schlechtesten (rot) zu erkennen. Für die Klasse Laubholz (LH) ist die Streuung der besten Trainingsdaten höher und die Produzentengenauigkeit niedriger als bei den schlechtesten Trainingsdaten. Die stärkere Streuung der Trainingsdaten kann ein Teil der Erklärung der Unterschiede zwischen den Trainingsdatensätzen sein.

Die 10 Objekte, die je Klasse und Trainingsdatensatz herangezogen wurden, sind für die Klasse Nadelholz (NH) für das höchste Klassifizierungsergebnis in Abbildung 45 und für das niedrigste Ergebnis in Abbildung 46 im gleichen Maßstab abgebildet.

Visuell unterscheiden sich die 10 Objekte der beiden Datensätze kaum voneinander. In beiden Fällen sind große und kleine, kompakte und weitläufige und stärker beschattete und wenig beschattete Objekte vorhanden.



Abbildung 45: Darstellung der 10 Objekte der Klasse Nadelholz (NH) des Trainingsdatensatzes mit dem besten Klassifizierungsergebnis. Alle Objekte im gleichen Maßstab.



Abbildung 46: Darstellung der 10 Objekte der Klasse Nadelholz (NH) des Trainingsdatensatzes mit dem niedrigsten Klassifizierungsergebnis. Alle Objekte im gleichen Maßstab.

5.5 Anwendbarkeit des trainierten Klassifikators auf angrenzende Testgebiete

Die Ergebnisse der Klassifizierung der Testgebiete B und C mit dem in Testgebiet A trainierten RF Klassifikators sind in Form von Konfusionsmatrizen in Tabelle 34 zusammengefasst.

Die erreichten Klassifizierungsgenauigkeiten liegen bei den Variablenkombinationen Standardset plus 10 beste Variablen DSWT Coif1 MDG und den 300 wichtigsten Variablen nach MDG Wichtigkeit aller Variablen ohne MW Ansatz in beiden Testgebieten höher als beim Testdatensatz. Das Ergebnis bei Training mit den 10 wichtigsten Texturvariablen des DSWT Ansatzes mit Coif 1 Wavelet liefert in beiden Testgebieten das höchste Ergebnis. Das Klassifizierungsergebnis für diese Variablenkombination ist als Konfusionsmatrix für die beiden Testgebiete in Tabelle 35 und

Tabelle 36 dargestellt.

Für die höhere Klassifizierungsgenauigkeit in den Testgebieten B und C als in Testgebiet A sind zwei Erklärungen zu finden.

Erstens gibt es in den Testgebieten viele Mischobjekte, also solche die mehr als eine Klasse aufweisen. Die Zuordnung dieser in der Referenzklassifizierung kann stärker dem Klassifizierungsergebnis der RF Klassifizierung entsprechen als im Testgebiet A, da Testgebiet A vor Beginn des systematischen Tests visuell klassifiziert wurde und Testgebiet B und C nach Abschluss.

Zweitens wurde für die Testgebiete B und C die Segmentierung aus dem Projekt "Erstellung einer Wald/Offenlandmaske aus digitalen Orthofotos" verwendet, welche nicht exakt der Segmentierung des Testgebietes A entspricht. Die Segmentierung in Testgebiet A wurde nicht auf Grund der Größe überarbeitet.

Tabelle 34: Klassifizierungsgenauigkeit von 10 verschiedenen Variablenkombinationen der Testgebiete A, B und C, sowie der Out of Bag Klassifizierungsfehler (OOB) des Trainingsdatensatzes.

		Testgebiet			
Variablenauswahl	OOB	Α	В	С	
Standardset + 10 beste DSWT Coif1 MDG	0.824	0.842	0.893	0.900	
300 beste MDA aller Variablen ohne MW	0.838	0.840	0.828	0.842	
Höchstes Ergebnis 5 Variablen Zufallsauswahl	0.808	0.810	0.812	0.750	
Höchstes Ergebnis 10 Variablen Zufallsauswahl	0.833	0.820	0.791	0.774	
Höchstes Ergebnis 15 Variablen Zufallsauswahl	0.824	0.840	0.842	0.828	
Höchstes Ergebnis 20 Variablen Zufallsauswahl	0.837	0.846	0.827	0.828	
Beste 50 Variablen laut Zufallsauswahl aus 5 Variablen	0.826	0.826	0.790	0.821	
Beste 50 Variablen laut Zufallsauswahl aus 10 Variablen	0.828	0.834	0.833	0.840	
Beste 50 Variablen laut Zufallsauswahl aus 15 Variablen	0.826	0.836	0.804	0.842	
Beste 50 Variablen laut Zufallsauswahl aus 20 Variablen	0.831	0.833	0.818	0.831	

Die beste Kombination aus fünf Variablen, schafft im Testgebiet A eine Klassifizierungsgenauigkeit von 81.0 %. Die Übertragbarkeit auf Testgebiet B mit 81.2 % ist sehr gut, auf Testgebiet C mit 75.0 % gut möglich. Die Übertragbarkeit der Kombination aus 10 Variablen ist zufriedenstellend, die mit 15 und 20 Variablen sehr zufriedenstellend. Die besten 50 Variablen laut der Zufallsauswahl aus 5, 10, 15 und 20 Variablen ermöglichen alle sehr hohe Klassifizierungsgenauigkeiten.

Die Konfusionsmatrizen für das Klassifizierungsergebnis des Testgebietes B (Tabelle 35) und Testgebiet C (Tabelle 36) mit den Variablen des Standardsets und den 10 wichtigsten Texturvariablen (MDG) des DSWT Ansatzes mit Coif 1 Wavelet zuzüglich Standardset zeigen für alle Klassen hohe Produzentengenauigkeiten von über 83 %. Die Nutzergenauigkeiten liegen mit Ausnahme der Klasse Laubholz (LH) über 85 %. Bei der Klasse LH kommt es häufig zu Fehlklassifikationen mit der Klasse Nadelholz (NH). Gründe dafür können Objekte Laub- und Nadelholzanteil sein, die nicht eindeutig einer der beiden Klassen zugewiesen werden können. Die geringsten Fehlklassifikationen treten bei den Klassen Schatten und Offenland Fels auf.

Tabelle 35: Konfusionsmatrix des Klassifizierungsergebnisses des Testgebietes B mit dem Standardset und den 10 wichtigsten Texturvariablen nach MDG des DSWT Ansatzes mit Coif 1 Wavelet. P Acc = Produzentengenauigkeit, U Acc = Nutzergenauigkeit. NH ... Nadelholz, LH ... Laubholz, OL ... Offenland

	NH	LH	Latsche	OL Gras	OL Fels	Schatten		U Acc.
NH	814	1	7	16	1	1	840	0.969
LH	102	138	3	19	2	1	265	0.521
Latsche	21	4	384	11	4	0	424	0.906
OL Gras	29	3	10	276	4	0	322	0.857
OL Fels	1	0	0	0	346	0	347	0.997
Schatten	6	0	0	1	7	172	186	0.925
	973	146	404	323	364	174	2384	
P Acc.	0.837	0.945	0.950	0.854	0.951	0.989		0.893
Kappa	0.862							

Tabelle 36: Konfusionsmatrix des Klassifizierungsergebnisses des Testgebietes C mit dem Standardset und den 10 wichtigsten Texturvariablen nach MDG des DSWT Ansatzes mit Coif 1 Wavelet. P Acc = Produzentengenauigkeit, U Acc = Nutzergenauigkeit. NH ... Nadelholz, LH ... Laubholz, OL ... Offenland

	NH	LH	Latsche	OL Gras	OL Fels	Schatten		U Acc.
NH	597	2	2	18	0	2	621	0.961
LH	110	153	10	53	0	0	326	0.469
Latsche	12	3	597	16	1	0	629	0.949
OL Gras	0	0	3	486	6	0	495	0.982
OL Fels	0	0	0	2	257	0	259	0.992
Schatten	0	0	0	0	1	88	89	0.989
_	719	158	612	575	265	90	2419	
P Acc.	0.830	0.968	0.975	0.845	0.970	0.978		0.900
Kappa	0.873							

Die Anwendbarkeit des trainierten Klassifikators auf angrenzende Testgebiete funktioniert bei geeigneter Variablenauswahl den erzielten Ergebnissen zufolge sehr gut.

6 Diskussion

6.1 Auflösung der Ausgangsbilder

Die Arbeit mit hochauflösenden Orthofotos ermöglicht eine sehr detaillierte Klassifizierung. Wie beispielsweise von Castilla & Hay (2008) hingewiesen wird, ist bei hochauflösenden Bildern eine objektbasierte Klassifizierung einer pixelbasierten vorzuziehen. Aus diesem Grund wurde in dieser Arbeit mit einem objektbasiertem Ansatz gearbeitet.

Je nach Aufgabenstellung der Klassifizierung kann es von Vorteil sein manche Klassen anhand von Bildern mit geringerer Bodenauflösung zu bestimmen. Die Ausscheidung eines Parkplatzes kann zum Beispiel bei einem Bild mit einer Bodenauflösung von 10×10 m exakter erfolgen, als bei Bildern mit 0.2×0.2 m, welche jedes abgestellte Fahrzeug mit mehreren Pixeln erfassen (Castilla & Hay 2008, 107).

In dieser Arbeit wurde versucht, den Einfluss der Bodenauflösung auf das Klassifizierungsergebnis zu untersuchen, indem alle Variablen separat für eine Bodenauflösung von 20 cm, 100 cm, 200 cm und 500 cm erstellt wurden. Die Ergebnisse zeigen deutlich, dass das Klassifizierungsergebnis des 500 cm Bildes immer das Schlechteste, jene des 20 cm Bildes fast immer das Beste ist. Die Anwendung des focal median Filters auf das 100 cm Bild bewirkt bei einigen Variablenkombinationen ein ähnlich hohes oder geringfügig besseres Klassifizierungsergebnis als jenes mit dem 20 cm Bild. Die höchste Klassifizierungsgenauigkeit eines einzelnen Eingangsbildes wird mit dem 20 cm Bild erreicht.

Keine der Klassen wurde von einem Bild mit geringer Bodenauflösung genauer klassifiziert als bei hoher. Gründe dafür können ein geringer Unterschied der Klassen sein, wie das bei LH, NH und Latsche der Fall ist, und die Segmentierung, welche auf dem Bild mit 1×1 m Bodenauflösung erstellt wurde und für die anderen Auflösungen skaliert wurde. Eine Segmentierung auf dem Bild mit geringster Bodenauflösung könnte zu anderer Form und Größe der Segmente führen.

Die Ergebnisse dieser Arbeit legen die Klassifizierung mit dem Bildmaterial mit der höchsten Bodenauflösung von 20 cm nahe. Die Klassifizierung mit Bildern mit 100 cm Bodenauflösung führt zu einem Verlust der Klassifizierungsgenauigkeit von rund 2.5 % Punkten, verkürzt aber die Rechendauer erheblich.

6.2 Auswahl von Trainingsobjekten

Die Auswahl geeigneter Trainingsobjekte hat entscheidenden Einfluss auf das Klassifizierungsergebnis (Lillesand et al. 2004, 562ff).

Ein Teil dieser Arbeit beschäftigt sich mit dem Unterschied zwischen Trainingsdatensätzen, welche hohe Klassifizierungsgenauigkeiten des Testdatensatzes erzeugen und jenen, die niedrige Genauigkeiten erzielen. Die visuelle Unterscheidbarkeit geeigneter und ungeeigneter Objekte, ist wie in Abbildung 45 (Seite 73) und Abbildung 46 (Seite 73) dargestellt, oft nicht eindeutig, der Unterschied im Klassifizierungsergebnis ist aber deutlich (vgl. Tabelle 31 und Tabelle 32 Seite 71). Gründe für die

unterschiedlichen Klassifizierungsergebnisse konnten nicht gefunden werden. Der Vergleich der Werteverteilung je Klasse im Testdatensatz und der Werteverteilung der Trainingsobjekte in Abbildung 44 (Seite 72) zeigt, dass die Objekte welche bei einer Klasse stärker streuen bei diesen Klassen geringer Produzenten- und Nutzergenauigkeiten erzielen als jene die weniger stark streuen. Das könnte ein Teil der Erklärung der unterschiedlichen Klassifizierungsgenauigkeiten sein.

Ein zweiter Einflussfaktor auf die erzielbare Klassifizierungsgenauigkeit ist die Anzahl Trainingsobjekte je Klasse. In Standardwerken wie Lillesand et al. (2004, 562ff) findet sich häufig der Richtwert von 10 – 100 Trainingsobjekten je Klasse. Die Ergebnisse dieser Arbeit legen eine Anzahl von größer 100 Trainingsobjekten je Klasse nahe. Die Ergebnisse der Arbeit von Foody (2009) zeigen, dass eine hohe Anzahl an Trainingsobjekten das Klassifizierungsergebnis deutlich verbessert, zu viele Trainingsobjekte das Ergebnis aber auch verschlechtern können.

Weiters wurde festgestellt, dass wenige gut geeignete Objekte eine höhere Klassifizierungsgenauigkeit erzielen können, als viele durchschnittliche Objekte. Ähnliches wurde auch in der Arbeit von Vuolo & Atzberger (2012) bei der Verwendung von SVM berichtet. Wie in Abbildung 39 (Seite 67) zu sehen ist, liefern die besten Datensätze mit 30 Objekten je Klasse eine gleich hohe Klassifizierungsgenauigkeit des Testdatensatzes wie der Durchschnitt mit 100 Objekten je Klasse.

Die Anzahl der Trainingsobjekte muss auch in Abstimmung mit der Anzahl von Eingangsvariablen erfolgen. Sind im Verhältnis zu den Variablen zu wenig Objekte vorhanden, tritt ein Rückgang der Klassifizierungsgenauigkeit ein, welcher als Hughes Phänomen bezeichnet wird (Richards 1993, 364). Das Auftreten dieses Effektes ist für den vorliegenden Datensatz in Abbildung 30 (Seite 57) erkennbar.

Da die Trainingsphase zeitaufwändig und dadurch kostenintensiv ist, sollte der Grundsatz so viele Objekte wie notwendig, so wenig Objekte wie möglich eingehalten werden. Rodriguez-Galiano et al. (2012b) kommen zu dem Ergebnis, dass die Anzahl von Trainingsobjekten bei homogenen Klassen geringer gehalten werden kann und in heterogenen Klassen erhöht werden soll.

Da die Trainingsobjekte möglichst repräsentativ für das zu klassifizierende Gebiet sein sollen, ist auch auf eine Durchmischung der Objektgrößen zu achten.

6.3 Parameter der Texturmaße mit GLCM Ansatz nach Haralick

Der Vergleich der Klassifizierungsergebnisse mit den vier Texturmaßen Contrast, Correlation, Energy und Homogeneity nach dem Graylevel Co-occurence Ansatz nach Haralick et al. zeigt, dass die drei Ansätze – Moving Window (MW), Objekt mit fixen GrayLimits und Objekt mit dynamischen GrayLimits – unterschiedliche Klassifizierungsergebnisse ermöglichen.

Dabei erreicht der MW basierte Ansatz bei allen Eingangsbildern die besten Klassifizierungsergebnisse aller Ansätze. Ein Nachteil dieses Ansatzes ist der extrem hohe Rechenaufwand (vgl. Tabelle 37, Seite 83) vor allem bei hochaufgelösten Daten (20 cm). Die Auswirkung verschiedener Parameter bei der Erstellung der GLCM auf die Texturparameter wurde schon in einigen Studien wie zum Beispiel von Kayitakire et al. (2006) untersucht. Als wichtigster Einflussfaktor auf die Texturparameter wird dabei die Größe des Moving Windows (MW) genannt.

Auch für diese Arbeit wurde der Einfluss der MW Größe auf die vier getesteten Texturmaße untersucht. Die Darstellung der Mittelwerte aller Objekte je Klasse für das 20 cm Eingangsbild findet sich in Abbildung 47, jene für das 500 cm Bild in Abbildung 48. Diese Abbildungen zeigen, dass die MW Größe einen deutlichen Einfluss auf die Mittelwerte der einzelnen Klassen hat. Die Werte des Parameters Correlation nehmen beim 20 cm Bild bei steigender MW Größe zu, scheinen sich aber einem Maximalwert anzunähern. Beim 500 cm Bild erreicht dieser Parameter im Bereich des 7x7 bis 11x11 Moving Windows sein Minimum und steigt dann wieder an.



Abbildung 47: Einfluss der Moving Window Größe auf die Variable 'mean of max Contrast', 'mean of max Correlation', 'mean of max Energy', 'mean of max Homogeneity' des 20cm Eingangsbildes. Darstellung getrennt nach Mittelwerten aller Objekte je Klasse.

Die Werte des Parameters Homogeneity sinken mit steigender MW Größe, die Mittelwerte liegen aber beim 500 cm Bild deutlich näher zusammen als beim 20 cm Bild. Diese Beobachtung stimmt auch mit der geringen MDA Importance des Texturparameters Homogeneity in Abbildung 24 (Seite 44) überein.

Der Parameter Contrast reagiert beim 20cm Bild geringer auf die Änderung der MW Größe, als beim 500 cm Bild.



Abbildung 48: Einfluss der Moving Window Größe auf die Variable 'mean of max Contrast', 'mean of max Correlation', 'mean of max Energy', 'mean of max Homogeneity' des 500cm Eingangsbildes. Darstellung getrennt nach Mittelwerten aller Objekte je Klasse.

Die Beobachtung von Kayitakire et al. (2006, 397), dass die MW Größe keinen Einfluss auf die Werte der Correlation Parameters haben kann für die vorliegenden Daten nicht bestätigt werden.

Die Größe des MWs hat einen starken Einfluss auf die Klassifizierungsgenauigkeit. Shaban & Dikshit (2001, 591) kommen zu dem Ergebnis, dass ein größeres MW zu höherer Klassifizierungsgenauigkeit führt, es aber eine maximale Größe gibt ab der sie wieder sinkt. Bei einer Studie von Rodriguez-Galiano et al. (2012a) erwies sich eine MW Größe von 31×31 Pixel als optimal. Die Ergebnisse dieser beiden

Arbeiten stimmen weitestgehend mit den Beobachtungen dieser Arbeit überein. Beim Vergleich von MW Größen unterschiedlicher Studien ist zu beachten, dass je nach vorliegender Bodenauflösung der Eingangsdaten unterschiedlich große Flächen am Boden aufgenommen werden.

Für die beiden objektbasierten Ansätze wurde die Anzahl der NumLevels variiert und bei einem Test die GrayLimits mit [0 255] fixiert und beim anderen Test die GrayLimits dynamisch an die im Bild auftretenden Grauwerte angepasst.

Der Einfluss der Graylimits (GL) auf die Werte der Texturparameter ist für den objektbasierten Ansatz mit dynamischen GL ist in Abbildung 49 für das 20cm Bild und in Abbildung 50 für das 500cm Bild dargestellt.



Abbildung 49: Einfluss der NumLevels (NL) auf die Variable 'mean Contrast', 'mean Correlation', 'mean Energy', 'mean Homogeneity' des 20cm Eingangsbildes. Darstellung getrennt nach Mittelwerten aller Objekte je Klasse.

Die Werte des Parameters Contrast steigen, die der Parameter Energy und Homogeneity sinken bei steigenden NumLevels (Abbildung 49). Die Auswirkung auf den Parameter Correlation ist für die beiden Eingangsbilder unterschiedlich.



Abbildung 50: Einfluss der NumLevels (NL) auf die Variable 'mean Contrast', 'mean Correlation', 'mean Energy', 'mean Homogeneity' des 500cm Eingangsbildes. Darstellung getrennt nach Mittelwerten aller Objekte je Klasse.

Auch bei der Gruppe Textur mit objektbasiertem Ansatz ist erkennbar, dass die Mittelwerte beim Bild mit hoher Bodenauflösung weiter auseinander liegen als bei dem Bild mit niedriger Bodenauflösung.

In dieser Arbeit wurden vier der 14 von Haralick et al. (1973) vorgestellten Texturmaße auf fünf verschiedene räumliche Auflösungen angewendet. Wie auch schon in anderen Arbeiten (z.B. Kayitakire et al. (2006)) festgestellt wurde, ist die Aussagekraft einzelner Parameter von Rahmenbedingungen wie Bodenauflösung, Spektralen Kanälen und der Charakteristik der zu erfassenden Objekte abhängig. So erzielt zum Beispiel der Texturparameter Correlation (IR/R/G/B) plus Standardset beim 20 cm Bild 79.5 % und beim 500 cm Bild 73.0 % Klassifizierungsgenauigkeit.

Baraldi & Parmiggiani (1995) haben festgestellt, dass die wichtigsten Texturparameter Correlation und Energy sind. Die Ergebnisse dieser Arbeit bestätigen die Wichtigkeit dieser beiden Texturparameter, zeigen aber auch das Potential der anderen Beiden.

6.4 Unterschiede von Texturmaßen

Für das Erstellen von Texturinformation gibt es sehr viele Ansätze. Gängige Ansätze sind der Graylevel Co-occurence Matrix (GLCM) Ansatz nach Haralick et al., Fourier Transformation, Diskrete Kosinus Transformation, Gabor Transformation und Wavelet Transformation (Haralick et al. 1979; Hupf 2004; Randen & Husøy 1999).

In dieser Arbeit wurde der sehr gängige GLCM Ansatz in zwei objektbasierten und einer Moving Window (MW) basierten Variante und der Ansatz der Diskreten Stationären Wavelete Transformation (DSWT) gewählt um Texturinformationen des Untersuchungsgebietes zu erhalten.

Dabei haben der Ansatz GLCM MW Ansatz und der DSWT Ansatz die besten Klassifizierungsergebnisse geliefert. Gründe dafür, dass der GLCM Ansatz bei Berechnung der Texturparameter beim MW Ansatz bessere Ergebnisse liefert als beim objektbasierten könnten Form und Größe der Segmente und die gewählten Texturparameter sein. Da die Texturmaße des GLCM Ansatzes innerhalb des quadratischen MWs bessere Ergebnisse liefern als innerhalb eines Objektes, könnten blockförmige Segmente bessere Ergebnisse liefern als weitläufige. Den Ergebnissen dieser Arbeit zu folge liefern die auf den höchst auflösenden Bildern gerechneten Texturparameter die höchste Klassifizierungsgenauigkeit.

Der Vergleich des besten Ergebnisses des MW basierten GLCM Ansatzes mit dem besten Ergebnis des DSWT Ansatzes zeigt, dass für dieses Untersuchungsgebiet kein Unterschied hinsichtlich der Klassifikationsgenauigkeit zu beobachten ist. Für die Texturvariablen des DSWT Ansatzes ist eine Variablenauswahl anhand der MDA oder MDG Wichtigkeit erforderlich, da bei den zahlreichen Variablen welche der Ansatz liefert, viele ohne Trennkraft sind. Die Klassifizierung mit den 10 wichtigsten Variablen nach MDG plus dem Standardset erhöht beim "Coif1" Wavelet die Klassifizierungsgenauigkeit des 20 cm Bildes um 1.5 % Punkte (vgl. Tabelle 21 Seite 51).

Eine Entscheidungshilfe bei der Auswahl des Ansatzes der Texturparameter kann durch den Vergleich der erforderlichen Rechenzeiten in MATLAB gegeben werden.

Tabelle 37: Erforderliche Rechenzeiten des verwendeten MATLAB Codes für die Berechnung der Texturparameter eines Orthofotos mit 2000×2000 m bei 20cm Bodenauflösung.

Ansatz	Rechenzeit [h]
GLCM MW	360
GLCM Objekt fixe GL	3
GLCM Objekt dyn. GL	3
DSWT	16

Der Vorteil des DSWT Ansatzes gegenüber dem GLCM MW Ansatz liegt bei deutlich kürzeren Rechenzeiten, beide Ansätze sind bei der Berechnung in MATLAB sehr arbeitsspeicherintensiv.

Die Wahl des geeigneten Ansatzes für die Berechnung von Texturmaßen ist wie in der Arbeit von Randen & Husøy (1999, 309) gezeigt wird, für die jeweilige Fragestellung unterschiedlich. Jeder Ansatz kann für die vorhandenen Eingangsbilder sehr gut passen oder auch nicht.

Unter Berücksichtigung der Ergebnisse dieser Arbeit hinsichtlich erzielbarer Klassifikationsgenauigkeiten und des dafür erforderlichen Zeitbedarfes bei der Erstellung der texturbeschreibenden Variablen, ist die Verwendung des DSWT Ansatzes mit Variablenauswahl durch MDA oder MDG Wichtigkeit anzuraten.

6.5 Erkenntnisse bezüglich Variablenauswahl

Die Eignung von Variablen zur Trennung von Klassen ist in erster Linie von den zu trennenden Klassen und den verfügbaren Eingangsdaten abhängig. Sind die Klassen spektral stark unterschiedlich (z.B. Wald und Fels), ist die Trennung anhand von spektraler Information und Vegetationsindizes ohne Probleme möglich. Unterscheiden sich die Klassen in den verfügbaren Eingangsdaten nicht deutlich (z.B. Nadelholz, Laubholz und Latsche), kann durch Datentransformation der Eingangsdaten (z.B. Texturmaße) versucht werden, die Trennbarkeit durch zusätzliche Variablen zu erhöhen.

Die Auswertung der Variablenzusammensetzung der (wichtigsten) Variablen nach Gruppen, zeigt bei den Tests mit zufällig gezogenen Variablenkombinationen und bei Klassifikation mit allen Variablen aller Auflösungen ein einheitliches Ergebnis. Die drei Gruppen der Texturvariablen nehmen einen Anteil zwischen 56 % und 72 % ein. Von dem verbleibenden Anteil nimmt die Gruppe Spektrale Information und Vegetationsindizes 50 % bis 70 % ein, die restlichen Variablen werden aus der Gruppe Datadistribution aufgefüllt.

Bei allen klassifizierten Variablenkombinationen des systematischen Tests wurde die Klassifizierungsgenauigkeit des Testdatensatzes und des Trainingsdatensatzes ermittelt. Die Klassifizierungsgenauigkeiten korrelieren dabei sehr hoch ($\mathbf{R} = 0.917$), weshalb die OOB Genauigkeit als geeignetes Maß für die Beurteilung von Variablenkombinationen herangezogen werden kann. Voraussetzung dafür ist eine entsprechend hohe Anzahl von Trainingsobjekten, 100 Objekte pro Klasse haben sich als empfehlenswert herausgestellt. Beim systematischen Test der Variablenkombinationen lag die Klassifikationsgenauigkeit des Trainingsdatensatzes tendenziell um 1-3 % Punkte unter der des Testdatensatzes.

Bei hoher Anzahl von Eingangsvariablen hat die Auswahl von weniger Variablen hoher Wichtigkeit teilweise zu einer deutlichen Verbesserung der Klassifizierungsgenauigkeit geführt. Im Vergleich der beiden dafür herangezogenen Wichtigkeitsmaße "MeanDecreaseGini" (MDG) und "MeanDecreaseAccuracy" (MDA) hat sich gezeigt, dass MDA bei sehr vielen Eingangsvariablen eine bessere Variablenreihung ermöglicht als MDG. Dieses Ergebnis deckt sich mit den Erkenntnissen der Arbeit von Immitzer et al. (2012).

Der Random Forest Klassifikator (RF), wie er in dieser Arbeit verwendet wurde, ist in der Lage, mit beliebig vielen Variablen und Objekten zu arbeiten. Trotzdem kann durch Verwendung von wenig gut geeigneten Variablen das Klassifizierungsergebnis verbessert werden, wie in Abbildung 30 (Seite 57) zu sehen ist. Der Grund dafür ist das Hughes Phänomen, welches auch als "Fluch der Dimensionalität" bezeichnet wird. Aus diesem Grund weisen auch Rodriguez-Galiano et al. (2012a) auf die Notwendigkeit der Variablenauswahl hin, wenn wie bei dieser Arbeit mit Texturmaßen gearbeitet wird, die durch die hohe Anzahl von möglichen Variablen einen hochdimensionalen Raum erzeugen. Beim RF Klassifikator kann ein zusätzliches Problem auftreten, da der RF Klassifikator bei jedem Entscheidungsknoten eine zufällige Auswahl von Variablen trifft, kann bei Vorhandensein vieler Variablen ohne Aussagekraft das Klassifikationsergebnis verschlechtert werden (Hastie et al. 2009).

Ein anderer Ansatz der Variablenauswahl wurde in dieser Arbeit durch Klassifzierung des Testdatensatzes mit zufälligen Variablenkombinationen demonstriert. Eine Kombination von nur fünf Variablen war ausreichend um eine Klassifizierungsgenauigkeit von über 80 % zu erreichen welche auch auf angrenzende Testgebiete übertragen werden konnte.

Die Ergebnisse dieser Arbeit legen für die Variablenauswahl einen Variablenumfang von 15 bis 50 Variablen nahe, die aus den wichtigsten Variablen nach MDA oder MDG Wichtigkeit bei Klassifizierung mit allen Variablen bestimmt werden. Ein Verhältnis von spektraler zu texturaler Information von 2:3 hat sich als vorteilhaft erwiesen, der Anteil spektraler Information sollte aber nicht unterschritten werden.

7 Zusammenfassung und Schlussfolgerungen

In dieser Arbeit wurden durch verschiedene Datentransformationen viele Eingangsvariablen für die Klassifizierung gewonnen, die grob in die drei Gruppen spektrale Information und Vegetationsindizes, Datadistribution und Texturmaße eingeteilt werden können.

Unter den getesteten Variablenkombinationen stach die Klassifizierungsgenauigkeit weniger Kombinationen positiv hervor. Die Gruppe der Texturmaße mit GLCM Ansatz nach Haralick et al., die in einem Moving Window berechnet wurden, sowie die Gruppe der Texturinformation durch Diskrete Stationäre Wavelet Transformation lieferten die höchsten Klassifizierungsgenauigkeiten der getesteten Gruppen.

Durch die Auswahl von Variablen anhand derer Wichtigkeit nach "MeanDecreaseGini" (MDG) und "MeanDecreaseAccuracy" (MDA) konnte das Klassifizierungsergebnis durch Reduktion der herangezogenen Variablen erhöht werden.

Durch die zufällige Kombination von Variablen wurde versucht, die wichtigsten Variablen aus allen verfügbaren Variablen zu ermitteln. Auch bei diesen Tests stellte sich heraus, dass 15 bis 50 Variablen vollkommen ausreichen um hohe Klassifizierungsergebnisse mit guter Übertragbarkeit auf benachbarte Testgebiete zu ermöglichen. Sogar eine sehr geringe Variablenanzahl von 5 bis 10 Variablen reicht aus um ein Klassifizierungsergebnis von rund 80 % zu erzielen, welches auch auf angrenzende Testgebiete übertragen werden kann.

Das geeignete Verhältnis zwischen spektraler Information, Vegetationsindizes und Datadistribution Variablen zu den Texturvariablen war in mehreren Tests 2:3.

Die Anzahl erforderlicher Trainingsobjekte für eine ausreichend hohe Klassifizierungsgenauigkeit ist in Zusammenhang mit der Anzahl der verwendeten Variablen, der Fragestellung und dem verwendeten Klassifikator zu wählen. Die Anzahl von Trainingsobjekten sollte an die jeweilige Klasse angepasst werden.

Auf den Erkenntnissen dieser Arbeit aufbauend, sind für zukünftige Untersuchungen die folgenden Bereiche von Interesse:

Für die Bearbeitung hochauflösender Daten ist ein objektbasierter Ansatz sinnvoll. Die Qualität der Klassifizierung steht und fällt bei einem solchen Ansatz mit der Qualität der Segmentierung. Weisen Objekte durch die Segmentierung mehr als eine der zu klassifizierenden Klassen auf ist eine eindeutige Zuweisung nicht möglich. Es ist davon auszugehen, dass in der Verbesserung der Segmentierung hohe Potentiale für die Verbesserung der Klassifizierungsgenauigkeit stecken.

Die Ergebnisse dieser Arbeit zeigen das hohe Potential der Diskreten Stationären Wavelet Transformation (DSWT) für diese Aufgabenstellung. Darauf aufbauend sollten weitere Untersuchungen mit der Wavelet Transformation erfolgen. In der Arbeit wurde ein Wavelet je Waveletfamilie getestet, welche alle unterschiedlich gute Ergebnisse geliefert haben. Die erzielbare Klassifizierungsgenauigkeit anderer als der getesteten Wavelets gilt es abzuklären.

Für diese Arbeit wurde der DSWT Ansatz gewählt, da er rechnerisch gut umsetzbar ist und die Zuordnung der Frequenzinformation zu den Objekten eindeutig. Eine objektbasierte Durchführung der Wavelet Transformation konnte nicht umgesetzt werden, könnte aber für weiterführende Untersuchungen erfolgversprechend sein. Dabei könnten die Grauwerte eines Objektes ähnlich einer Frequenz in der Signalverarbeitung eindimensional ausgewertet werden.

Die Klassifizierung der Variablenkombinationen bei dieser Arbeit erfolgte mittels Random Forest (RF) Klassifikator. Ziel war es, Variablenkombinationen zu finden, welche das Testgebiet mit möglichst hoher Genauigkeit klassifizieren und diese Klassifikationsgenauigkeit auch in zwei weiteren Testgebieten ermöglichen.

Ein alternativer Ansatz wäre, Variablenkombinationen zu suchen, welche einzelne Klassen mit möglichst hoher Produzenten- und Nutzergenauigkeit klassifizieren. Ist eine solche Variablenkombination für eine Klasse gefunden, können die damit klassifizierten Objekte aus dem Datensatz herausgenommen werden. Die verbleibenden Objekte können mit der besten Variablenkombination für die nächste Klasse klassifiziert werden. Eine solche stufenweise Klassifizierung könnte nicht nur mit unterschiedlichen Variablenkombinationen, sondern auch mit unterschiedlichen Klassifikatoren erfolgen.

Das Arbeiten mit hochauflösenden Daten wird in Zukunft bei immer mehr Fragestellungen Anwendung finden. Orthofotos mit 20 cm Bodenauflösung sind längst Stand der Technik. Unbemannte Luftfahrzeuge (UAVs) liefern für kleinräumige Fragestellungen Bodenauflösungen im Subdezimeter Bereich (Laliberte & Rango 2009). Die Verarbeitung dieser großen Datenmengen wird in Zukunft den Einsatz von objektbasierten Klassifizierungsansätzen unumgänglich machen. Da Texturinformation für viele Klassifizierungsaufgaben erhebliche Vorteile liefert, sollte der Fokus bei zukünftigen Untersuchungen vermehrt im Bereich von objektbasierter Texturinformation liegen.

8 Literaturverzeichnis

- Albertz, J. 2009. Einführung in die Fernerkundung : Grundlagen der Interpretation von Luft- und Satellitenbildern. Darmstadt: Wiss. Buchges.
- Bannari, A., Morin, D., Bonn, F., & Huete, A.R. 1995. A review of vegetation indices. Remote Sensing Reviews 13(1-2): S.95–120.
- Baraldi, A., & Parmiggiani, F. 1995. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. IEEE Transactions on Geoscience and Remote Sensing 33(2): S.293–304.
- Breiman, L. 2001. Random forests. Machine learning 45(1): S.5-32.
- Breiman, L. 2002. Manual on Setting Up, Using, and Understanding Random Forests V3.1. Available at: http://oz.berkeley.edu/users/breiman/Using_random_forests_V3.1.pdf.
- Castilla, G., & Hay, G. 2008. Îmage objects and geographic objects. In: Blaschke T., Lang S., Hay G. (Hg.): ObjectBased Image Analysis: S.92–110.
- Coles, S. 2004. An introduction to statistical modeling of extreme values. London [u.a.]: Springer.
- Congalton, R., & Green, K. 1999. Assessing the accuracy of remotely sensed data principles and practices. Boca Raton: Lewis.
- Foody, G.M. 2009. Sample size determination for image classification accuracy assessment and comparison. International Journal of Remote Sensing 30(20): S.5273–5291.
- Graps, A. 1995. An introduction to wavelets. IEEE Computational Science Engineering 2(2): S.50 -61.
- Haberäcker, P. 1989. Digitale Bildverarbeitung : Grundlagen und Anwendungen 3. überarbeitete Aufl. München u.a: Hanser.
- Haralick, R.M., Shanmugam, K., & Dinstein, I. 1973. Textural Features for Image Classification. IEEE Transactions on Systems, Man and Cybernetics 3(6): S.610–621.
- Haralick, R.M., Shanmugam, K., & Dinstein, I. 1979. Statistical and structural approaches to texture. Proceedings of the IEEE 67(5): S.786– 804.
- Hartung, J., Elpelt, B., & Klösener, K.-H. 2009. Statistik Lehr- und Handbuch der angewandten Statistik 15. Aufl. München: Oldenbourg.
- Hastie, T., Friedman, J., & Tibshirani, R. 2009. The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition 2. Aufl. Greenwood Publishing Group.
- Hazewinkel, M. 1989. Encyclopaedia of mathematics: an updatedand annotated translation of the Soviet "Mathematical encyclopaedia": vol. 4 Fibonacci Method - H. Dordrecht; Boston; London: Kluwer Academic Publishers.
- Huete, A.R. 1988. A soil-adjusted vegetation index (SAVI). Remote Sensing of Environment 25(3): S.295-309.
- Hupf, K. 2004. Spektral-basierte Ähnlichkeitssuche auf Texturen, Diplomarbeit.
- Immitzer, M., Atzberger, C., & Koukal, T. 2012. Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. Remote Sensing 4(9): S.2661–2693.
- Jähne, B. 2005. Digitale Bildverarbeitung : mit 155 Ubungsaufgaben und CD-ROM. Berlin; Heidelberg; New York: Springer.
- Kayitakire, F., Hamel, C., & Defourny, P. 2006. Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. Remote Sensing of Environment 102(3-4): S.390–401.
- Koukal, T., & Atzberger, C. 2012. Potential of Multi-Angular Data Derived From a Digital Aerial Frame Camera for Forest Classification. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 5(1): S.30 – 43.

- Kroschel, K., Rigoll, G., & Schuller, B. 2011. Statistische Informationstechnik : Signal und Mustererkennung, Parameter- und Signalschätzung. Berlin; Heidelberg [u.a.]: Springer Berlin.
- Laliberte, A.S., & Rango, A. 2009. Texture and Scale in Object-Based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery. IEEE Transactions on Geoscience and Remote Sensing 47(3): S.761 –770.
- Lautenschlager, L., & Perry, C. 1981. Comparison of Vegetation Indices Based on Satellite Acquired Spectral Data. Proceedings, Survey Research Methods Section of American Statistical Association, Washington, DC.
- Liaw, A., & Wiener, M. 2002. Classification and Regression by randomForest. R News 2(3): S.18-22.
- Lillesand, T.M., Kiefer, R.W., & Chipman, J.W. 2004. Remote sensing and image interpretation. New York: Wiley.
- Louis, A.K., Maass, P., & Rieder, A. 1998. Wavelets : Theorie und Anwendungen. Stuttgart: Teubner.
- Mallinis, G., Koutsias, N., Tsakiri-Strati, M., & Karteris, M. 2008. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. ISPRS Journal of Photogrammetry and Remote Sensing 63(2): S.237–250.
- MATLAB. 2012a. R2012a Documentation, Beta parameter estimates. Available at: http://www.mathworks.de/help/toolbox/stats/betafit.html [Zugegriffen Juli 31, 2012].
- MATLAB. 2012b. R2012a Documentation, Generalized extreme value parameter estimates. Available at: http://www.mathworks.de/help/toolbox/stats/gevfit.html [Zugegriffen September 3, 2012].
- Metzler, V., Palm, C., Lehmann, T., & Aach, T. 2002. Texture classification of gray-level images by multiscale cross co-occurrence matrices. In 549–552. IEEE Comput. Soc
- Perry Jr., C.R., & Lautenschlager, L.F. 1984. Functional equivalence of spectral vegetation indices. Remote Sensing of Environment 14(1–3): S.169–182.
- Polikar, R. 1999. The Wavelet Tutorial. Available at: http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html.
- Randen, T., & Husøy, J. 1999. Filtering for Texture Classification: A Comparative Study. IEEE Transactions on Pattern Analysis and Machine Intelligence 21(4): S.291 310.
- Richards, J.A. 1993. Remote sensing digital image analysis : an introduction. Berlin: Springer-Verlag.
- Rodriguez-Galiano, V.F., Chica-Olmo, M., Abarca-Hernandez, F., Atkinson, P.M., & Jeganathan, C. 2012a. Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. Remote Sensing of Environment 121: S.93–107.
- Rodriguez-Galiano, V.F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J.P. 2012b. An assessment of the effectiveness of a random forest classifier for land-cover classification. ISPRS Journal of Photogrammetry and Remote Sensing 67: S.93–104.
- Rouse, J., Haas, R., Schell, J., & Deering, D. 1973a. Monitoring vegetation systems in the Great Plains with ERTS. In Proceedings of the Third ERTS Symposium, 309–317. Washington DC
- Rouse, J.W., Haas, R.H., Schell, J.A., & Deering, D.W. 1973b. Monitoring the vernal Advancement an Retrogradation (Green Wave Effect) of natural vegetation. Texas, USA: Remote Sensing Center, College Station Texas.
- Schlerf, M., & Atzberger, C. 2012. Vegetation Structure Retrieval in Beech and Spruce Forests Using Spectrodirectional Satellite Data. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 5(1): S.8–17.
- Shaban, M.A., & Dikshit, O. 2001. Improvement of classification in urban areas by the use of textural features: The case study of Lucknow city, Uttar Pradesh. International Journal of Remote Sensing 22(4): S.565–593.
- Soh, L.-K., & Tsatsoulis, C. 1999. Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. IEEE Transactions on Geoscience and Remote Sensing 37(2): S.780–795.
- Vieira, M.A., Formaggio, A.R., Rennó, C.D., Atzberger, C., Aguiar, D.A., & Mello, M.P. 2012. Object Based Image Analysis and Data Mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. Remote Sensing of Environment 123(0): S.553–562.

- Vuolo, F., & Atzberger, C. 2012. Exploiting the Classification Performance of Support Vector Machines with Multi-Temporal Moderate-Resolution Imaging Spectroradiometer (MODIS) Data in Areas of Agreement and Disagreement of Existing Land Cover Products. Remote Sensing 4(10): S.3143–3167.
- Wasilewski, F. 2012. Wavelet Properties Browser. Available at: http://wavelets.pybytes.com/ [Zugegriffen September 25, 2012].
- Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., & Schirokauer, D. 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. Photogrammetric Engineering and Remote Sensing 72(7): S.799.

9 Anhang

ANHANG A



Abbildung 51: Auswirkung der Anzahl von zufällig gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des Testdatensatzes. Eingangsbild 100cm, Boxplot von je 1000 zufälligen Kombinationen von Trainingsobjekten.



Abbildung 52: Auswirkung der Anzahl von zufällig gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des Testdatensatzes. Eingangsbild 100cm fm, Boxplot von je 1000 zufälligen Kombinationen von Trainingsobjekten.



Abbildung 53: Auswirkung der Anzahl von zufällig gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des Testdatensatzes. Eingangsbild 200cm, Boxplot von je 1000 zufälligen Kombinationen von Trainingsobjekten.



Abbildung 54: Auswirkung der Anzahl von zufällig gezogenen Trainingsobjekten auf die Klassifizierungsgenauigkeit des Testdatensatzes. Eingangsbild 500cm, Boxplot von 1000 zufälligen Kombinationen von Trainingsobjekten.
ANHANG B

Variablenkombinationen für den Test der Anwendbarkeit des trainierten Klassifikators auf benachbarte Testgebiete.

Tabelle 38: 10 wichtigste Texturmaße nach MDG Wichtigkeit der Diskreten Stationären Wavelet Transformation (DSWT) mit coif1 Wavelet des 20cm Bildes. V ... Vertikale Filterung, D ... Diagonale Filterung, A ... Approximation; 1,3,4 ... Auflösung, IR/R/G/B ... Spektraler Eingangskanal

1 DSWT coif1 std V4 B	6 DSWT coif1 median D1 R
2 DSWT coif1 std V4 IR	7 DSWT coif1 median A3 R
3 DSWT coif1 std D1 B	8 DSWT coif1 median A4 G
4 DSWT coif1 std D1 IR	9 DSWT coif1 median A4 B
5 DSWT coif1 median A4 R	10 DSWT coif1 median A4 IR

Tabelle 39: Variablen des höchsten Klassifizierungsergebnisses bei zufälliger Variablenauswahl aus allen Variablen aller Auflösungen ohne Moving Window (MW) Ansatz.

5 Variablen ohne MW
100cc fm AVI median Objekt
20cc DSWT bior1 1 std V4 B
20cc NDVI beta a
20cc DSWT coif1 median V1 G
100 cc fm DSWT coif1 median A2 R
20 Variablen ohne MW
100cc G gev sigma
100cc B median Objekt
100cc fm DSWT sym2 median V1 B
100cc DSWT coif1 std D2 G
100cc DSWT db1 std H2 G
20cc R Correlation max Obj dyn GL NL 16
200cc DSWT bior1 1 std V1 B
100cc G Correlation min Obj NL 16
200cc B Correlation min Obj NL 32
100cc DSWT coif1 median A1 B
200cc DSWT db1 std A1 R
100cc fm G gev sigma
100cc fm DSWT db1 std A3 R
500cc B Energy std Obj dyn GL NL 16
20cc DSWT coif1 std D1 B
20cc DSWT sym2 median D2 R
200cc G Contrast std Obj NL 64
100cc DSWT sym2 std D2 IR
100cc TVI median Objekt
100cc fm DSWT dmey mean H1 G

10 Variablen ohne MW
100cc B Contrast mean Obj NL 16
20cc DSWT dmey std D1 B
100cc TVI beta a
100cc DSWT sym2 median D2 B
100cc fm SAVI median Objekt
100cc DSWT sym2 median H3 R
100cc fm DSWT dmey mean V3 B
20cc R beta B
100cc fm DSWT db1 std H2 IR
100cc fm DSWT db1 median A1 R
15 Variablen ohne MW
100cc fm DSWT sym2 std A1 B
500cc DSWT coif1 median D2 B
100cc DSWT sym2 median H2 B
100cc fm AVI median Objekt
100cc fm DSWT bior1 1 std A3 R
20cc DSWT dmey std V4 IR
20cc DSWT db1 median A3 G
100cc DSWT bior1 1 mean A2 G
100cc fm DSWT bior1 1 mean A2 IR
500cc DSWT dmey mean H1 IR
100cc G Contrast std Obj dyn GL NL 4
500cc DSWT sym2 std V1 G
20cc G Contrast mean Obj NL 32
20cc DSWT coif1 std D1 IR
100cc fm R Homogeneity max Obj dyn GL NL 16

Tabelle 40: Variablen des höchsten Klassifizierungsergebnisses bei zufälliger Variablenauswahl aus allen Variablen aller Auflösungen.

5 Variablen
20cc median of mean Correlation MW 51x51px NL 16 IR
100cc fm DSWT bior1 1 mean A2 IR
100cc b Correlation mean Obj dyn GL NL 4
100cc SAVI mean Objekt
500cc TVI weibull b
20 Variablen
100cc TVI median Objekt
20cc median of mean Correlation MW 21x21px NL 16 IR
500cc mean of mean Contrast MW 21x21px NL 16 G
20cc DSWT bior1 1 median V4 G
100cc DSWT sym2 std H3 R
100cc DSWT dmey std V1 B
100cc b Energy mean Obj NL 32
500cc median of max Contrast MW 25x25px NL 16 B
200cc std of max Correlation MW 3x3px NL 16 R
20cc median of mean Contrast MW 3x3px NL 16 R
20cc DSWT dmey std V4 IR
100cc std of max Contrast MW 7x7px NL 16 B
100cc mean of max Correlation MW 11x11px NL 16 IR
20cc DSWT db1 std A1 G

100cc DSWT dmey std A3 IR 200cc g Energy mean Obj NL 64

100cc fm DSWT bior1 1 median A2 B

200cc b Homogeneity mean Obj dyn GL NL 4

100cc fm DSWT db1 std A4 B

100cc b Energy mean Obj dyn GL NL 10

10 Variablen

200cc DSWT sym2 std V2 IR
100cc r Contrast mean Obj NL 32
20cc DSWT bior1 1 mean D3 G
100cc fm median of mean Homogeneity MW 7x7px NL 16 IR
20cc median of max Correlation MW 35x35px NL 16 IR
20cc median of max Homogeneity MW 3x3px NL 16 R
100cc median of max Correlation MW 25x25px NL 16 R
100cc TVI median Objekt
100cc IR gev mu
20cc DSWT svm2 std V1 IR

15 Variablen

20cc mean of max Correlation MW 25x25px NL 16 IR
20cc median of mean Correlation MW 11x11px NL 16 R
500cc std of mean Energy MW 3x3px NL 16 B
20cc DSWT sym2 median A2 B
200cc DSWT dmey mean V1 G
20cc mean of mean Homogeneity MW 21x21px NL 16 R
500cc mean of mean Contrast MW 21x21px NL 16 G
500cc median of mean Energy MW 7x7px NL 16 IR
100cc fm DSWT coif1 std A3 G
100cc fm mean of mean Contrast MW 11x11px NL 16 IR
500cc r Homogeneity max Obj dyn GL NL 4
100cc fm DSWT sym2 std H3 R
20cc g Energy mean Obj dyn GL NL 5
100cc DSWT dmey std A2 R

100cc fm NDVI median Objekt

ANHANG C

Zufällige Variablenauswahl aus allen Variablen:



Abbildung 55: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 5 Variablen aus allen Variablen.

Legende für alle Abbildungen in Anhang C: VAR IMP ... Anzahl des Auftretens, MDG ... summierte, normalisierte MDG Wichtigkeit, MDA IMP ... summierte, normalisierte MDA Wichtigkeit



Abbildung 56: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 10 Variablen aus allen Variablen.



Abbildung 57: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 15 Variablen aus allen Variablen.



Abbildung 58: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 20 Variablen aus allen Variablen.

Variablenauswahl aus allen Variablen ohne Moving Window (MW) Ansatz:



Abbildung 59: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 5 Variablen aus allen Variablen ohne MW Ansatz.



Abbildung 60: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 10 Variablen aus allen Variablen ohne MW Ansatz.







Abbildung 62: 50 wichtigste Variablen der 100 höchsten Klassifizierungsgenauigkeiten der Zufallsauswahl von 20 Variablen aus allen Variablen ohne MW Ansatz

ANHANG D

Tabelle 41: Konfusionsmatrizen "Standardset". Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten

Standardset IR/R/G/B - 20cm											
	1	2	3	4	5	7		U Acc.			
1	459	69	65	41	0	22	656	0.700			
2	52	190	4	14	0	1	261	0.728			
3	33	10	293	23	2	0	361	0.812			
4	40	10	24	429	22	2	527	0.814			
5	0	1	6	21	226	3	257	0.879			
7	24	9	5	2	7	157	204	0.770			
-	608	289	397	530	257	185	2266				

P Acc. 0.755 0.657 0.738 0.809 0.879 0.849 0.774 Kappa 0.719

	Standardset IR/R/G/B - 100cm fm											
	1	2	3	4	5	7		U Acc.				
1	459	72	58	45	0	24	658	0.698				
2	46	187	2	12	0	1	248	0.754				
3	37	9	306	21	1	2	376	0.814				
4	45	12	20	430	22	2	531	0.810				
5	0	0	6	20	228	3	257	0.887				
7	21	9	5	2	6	153	196	0.781				
	608	289	397	530	257	185	2266					

P Acc. 0.755 0.647 0.771 0.811 0.887 0.827 0.778 Kappa 0.724

Standardset IR/R/G/B - 500cm

	1	2	3	4	5	7		U Acc.
1	471	96	56	45	1	28	697	0.676
2	45	164	1	12	0	3	225	0.729
3	35	7	283	37	3	7	372	0.761
4	41	14	41	402	33	5	536	0.750
5	2	4	9	31	216	11	273	0.791
7	14	4	7	3	4	131	163	0.804
-	608	289	397	530	257	185	2266	

P Acc. 0.775 0.567 0.713 0.758 0.840 0.708 0.736 Kappa 0.670

Standardset IR/R/G/B - 100cm

	1	2	3	4	5	7		U Acc.
1	447	75	77	39	0	21	659	0.678
2	48	177	6	10	0	2	243	0.728
3	43	13	284	23	1	1	365	0.778
4	46	13	22	437	17	2	537	0.814
5	0	0	5	20	234	2	261	0.897
7	24	11	3	1	5	157	201	0.781
-	608	289	397	530	257	185	2266	

P Acc. 0.735 0.612 0.715 0.825 0.911 0.849 0.766 *Kappa 0.709*

Standardset IR/R/G/B - 200cm										
	1	2	3	4	5	7		U Acc.		
1	461	76	60	49	0	24	670	0.688		
2	46	178	4	8	0	3	239	0.745		
3	38	13	296	21	3	3	374	0.791		
4	40	13	26	428	19	2	528	0.811		
5	0	2	6	22	230	5	265	0.868		
7	23	7	5	2	5	148	190	0.779		
	608	289	397	530	257	185	2266			
P Acc.	0.758	0.616	0.746	0.808	0.895	0.800		0.768		
Kappa	0.712									

Tabelle 42: Konfusionsmatrizen "Alle Variablen der Gruppe". Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten

Alle Variablen der Gruppe - 20cm									
	1	2	3	4	5	7		U Acc.	
1	519	63	16	30	2	19	649	0.800	
2	38	209	1	10	0	3	261	0.801	
3	8	0	352	10	0	2	372	0.946	
4	25	13	21	460	9	3	531	0.866	
5	0	0	5	19	241	1	266	0.906	
7	18	4	2	1	5	157	187	0.840	
	608	289	397	530	257	185	2266		
P Acc.	0.854	0.723	0.887	0.868	0.938	0.849		0.855	

Kappa 0.820

Alle Variablen der Gruppe - 100cm U Acc. 0.786 0.837 0.912 0.868 0.897 0.855 P Acc. 0.865 0.657 0.889 0.858 0.953 0.859 0.851

Kappa 0.814

Alle Variablen der	Gruppe - 100cm fm
--------------------	-------------------

	1	2	3	4	5	7		U Acc.
1	531	84	32	27	1	20	695	0.764
2	23	185	3	8	0	1	220	0.841
3	13	2	328	15	1	3	362	0.906
4	28	12	26	458	12	2	538	0.851
5	0	0	5	21	237	2	265	0.894
7	13	6	3	1	6	157	186	0.844
	608	289	397	530	257	185	2266	

P Acc. 0.873 0.640 0.826 0.864 0.922 0.849 0.837 Kappa 0.796

Alle Variablen der Gruppe - 500cm

	1	2	3	4	5	7		U Acc.
1	516	68	25	41	1	19	670	0.770
2	32	194	0	6	1	4	237	0.819
3	17	3	316	23	2	8	369	0.856
4	36	18	46	424	28	7	559	0.758
5	0	2	5	33	222	7	269	0.825
7	7	4	5	3	3	140	162	0.864
	608	289	397	530	257	185	2266	

P Acc. 0.849 0.671 0.796 0.800 0.864 0.757 0.800 *Kappa 0.750*

Alle Variablen	der Gruppe - 200cm	
----------------	--------------------	--

	1	2	3	4	5	7		U Acc.
1	527	79	34	36	1	19	696	0.757
2	25	185	1	8	0	0	219	0.845
3	12	5	331	17	1	3	369	0.897
4	34	14	24	442	7	3	524	0.844
5	0	1	5	25	243	3	277	0.877
7	10	5	2	2	5	157	181	0.867
	608	289	397	530	257	185	2266	
P Acc.	0.867	0.640	0.834	0.834	0.946	0.849		0.832

Kappa 0.790

Tabelle 43: Konfusionsmatrizen ,Vegetationsindizes⁴. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten

	Spektral SAVI - 20cm											
	1	2	3	4	5	7		U Acc.				
1	471	66	60	34	0	21	652	0.722				
2	53	197	4	13	0	1	268	0.735				
3	28	8	301	17	2	0	356	0.846				
4	38	11	22	440	9	2	522	0.843				
5	0	0	5	24	239	3	271	0.882				
7	18	7	5	2	7	158	197	0.802				
-	608	289	397	530	257	185	2266					

P Acc. 0.775 0.682 0.758 0.830 0.930 0.854 0.797 Kappa 0.748

Spektral NDVI - 100cm fm

	1	2	3	4	5	7		U Acc.
1	474	61	63	35	0	22	655	0.724
2	39	200	3	15	0	1	258	0.775
3	33	8	304	15	1	1	362	0.840
4	40	12	17	441	10	2	522	0.845
5	0	0	6	22	241	3	272	0.886
7	22	8	4	2	5	156	197	0.792
	608	289	397	530	257	185	2266	

P Acc. 0.780 0.692 0.766 0.832 0.938 0.843 0.801 Kappa 0.753

Spektral Alle 10 wichtigste MDA - 500cm

	1	2	3	4	5	7		U Acc.
1	479	81	56	50	1	21	688	0.696
2	53	180	4	15	0	4	256	0.703
3	28	9	287	25	5	7	361	0.795
4	37	15	33	399	26	5	515	0.775
5	1	2	6	39	222	11	281	0.790
7	10	2	11	2	3	137	165	0.830
	608	289	397	530	257	185	2266	

P Acc. 0.788 0.623 0.723 0.753 0.864 0.741 0.752 Kappa 0.691

	Spektral NDVI - 100cm													
1 2 3 4 5 7 L														
1	459	62	74	33	0	22	650	0.706						
2	43	193	3	10	0	2	251	0.769						
3	39	12	290	16	1	0	358	0.810						
4	44	14	21	448	10	2	539	0.831						
5	0	0	5	22	241	3	271	0.889						
7	23	8	4	1	5	156	197	0.792						
	608	289	397	530	257	185	2266							
Acc.	0.755	0.668	0.730	0.845	0.938	0.843		0.789						

P Acc.	0.755	0.668	0.730	0.845	0.938	0.843	0.789
Kappa	0.737						

Spektral Alle 10 wichtigste MDA - 200cm

	1	2	3	4	5	7		U Acc.
1	456	62	60	33	0	21	632	0.722
2	59	194	6	12	0	2	273	0.711
3	28	10	297	17	2	2	356	0.834
4	46	14	24	440	10	2	536	0.821
5	0	2	5	24	241	3	275	0.876
7	19	7	5	4	4	155	194	0.799
	608	289	397	530	257	185	2266	
Acc.	0.750	0.671	0.748	0.830	0.938	0.838		0.787
	0 700							

Kappa 0.736

Ρ

Tabelle 44: Konfusionsmatrizen ,Textur GLCM mit MW Ansatz'. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten

	Textur MW 51x51 NL 16 B - 20cm													
	1 2 3 4 5 7 U Acc.													
1	514	72	16	22	3	25	652	0.788						
2	48	201	0	10	0	4	263	0.764						
3	7	0	354	15	0	3	379	0.934						
4	23	12	16	457	19	2	529	0.864						
5	0	0	6	24	232	2	264	0.879						
7	16	4	5	2	3	149	179	0.832						
	608	289	397	530	257	185	2266							

P Acc. 0.845 0.696 0.892 0.862 0.903 0.805 0.842 Kappa 0.803

Textur MW 51x51 NL 16 IR/R/G/B - 100cm fm

	1	2	3	4	5	7		U Acc.
1	529	75	27	28	0	15	674	0.785
2	28	192	5	7	1	8	241	0.797
3	13	4	332	28	4	5	386	0.860
4	27	14	23	439	34	2	539	0.814
5	1	0	7	20	213	3	244	0.873
7	10	4	3	8	5	152	182	0.835
_	608	289	397	530	257	185	2266	

0.820 P Acc. 0.870 0.664 0.836 0.828 0.829 0.822 Kappa 0.775

Textur MW 25x25 NL 16 IR/R/G/B - 500cm

	1	2	3	4	5	7		U Acc.
1	502	79	34	44	1	15	675	0.744
2	39	183	3	6	1	9	241	0.759
3	25	3	297	23	2	8	358	0.830
4	36	18	43	418	30	8	553	0.756
5	2	4	12	36	218	10	282	0.773
7	4	2	8	3	5	135	157	0.860
	608	289	397	530	257	185	2266	

P Acc. 0.826 0.633 0.748 0.789 0.848 0.730 0.774 Kappa 0.718

Textur MW 11x11 NL 16 IR/R/G/B - 100cm

	1	2	3	4	5	7		U Acc.
1	510	99	18	31	1	14	673	0.758
2	33	170	2	6	0	4	215	0.791
3	16	4	346	15	0	3	384	0.901
4	29	10	21	438	19	2	519	0.844
5	0	2	7	38	232	2	281	0.826
7	20	4	3	2	5	160	194	0.825
	608	289	397	530	257	185	2266	

P Acc. 0.839 0.588 0.872 0.826 0.903 0.865 0.819 Kappa 0.775

Textur MW 51x51 NL 16 IR/R/G/B - 200cm

	1	2	3	4	5	7		U Acc.
1	509	75	33	35	1	15	668	0.762
2	38	192	6	6	1	5	248	0.774
3	19	3	321	18	1	3	365	0.879
4	30	12	23	435	23	4	527	0.825
5	2	3	8	34	226	3	276	0.819
7	10	4	6	2	5	155	182	0.852
	608	289	397	530	257	185	2266	
P Acc.	0.837	0.664	0.809	0.821	0.879	0.838		0.811
Kappa	0.765							

Tabelle 45: Konfusionsmatrizen ,Textur GLCM objektbasiert, fixe GrayLimits'. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten

٦	Textur Objekt NL 32 Homogeneity IR/R/G/B - 20cm											
	1	2	3	4	5	7		U Acc.				
1	489	68	45	37	0	22	661	0.740				
2	37	198	2	10	0	2	249	0.795				
3	19	1	320	14	0	3	357	0.896				
4	38	12	21	438	20	2	531	0.825				
5	1	1	6	29	231	0	268	0.862				
7	24	9	3	2	6	156	200	0.780				
-	608	289	397	530	257	185	2266					

P Acc. 0.804 0.685 0.806 0.826 0.899 0.843 0.808 Kappa 0.762

Textur Objekt NL 32 Energy IR/R/G/B - 100cm fm

	1	2	3	4	5	7		U Acc.
1	497	80	42	40	1	20	680	0.731
2	26	182	2	7	0	0	217	0.839
3	24	4	322	24	3	5	382	0.843
4	42	13	21	426	15	1	518	0.822
5	0	2	6	30	233	2	273	0.853
7	19	8	4	3	5	157	196	0.801
	608	289	397	530	257	185	2266	

P Acc. 0.817 0.630 0.811 0.804 0.907 0.849 0.802 Kappa 0.753

Textur Objekt NL 32 IR/R/G/B, 10 wichtigste MDG - 500cm

	1	2	3	4	5	7		U Acc.
1	479	102	51	40	3	30	705	0.679
2	36	155	0	15	0	2	208	0.745
3	29	5	292	37	0	6	369	0.791
4	51	18	39	407	38	4	557	0.731
5	2	5	12	28	211	12	270	0.781
7	11	4	3	3	5	131	157	0.834
	608	289	397	530	257	185	2266	

P Acc. 0.788 0.536 0.736 0.768 0.821 0.708 0.739 *Kappa 0.674*

Textur Objekt NL 64 Energy IR/R/G/B - 100cm

	1	2	3	4	5	7		U Acc.
1	481	78	58	41	0	20	678	0.709
2	36	176	5	8	0	1	226	0.779
3	24	8	303	15	1	1	352	0.861
4	42	17	20	439	17	2	537	0.818
5	0	3	6	25	234	2	270	0.867
7	25	7	5	2	5	159	203	0.783
	608	289	397	530	257	185	2266	
P Acc.	0.791	0.609	0.763	0.828	0.911	0.859		0.791

Kappa 0.740

Textur Objekt NL 16 Energy IR/R/G/B

	1	2	3	4	5	7		U Acc.
1	484	78	50	48	0	25	685	0.707
2	32	172	3	5	0	1	213	0.808
3	29	8	311	21	2	1	372	0.836
4	43	21	23	428	17	3	535	0.800
5	0	2	6	26	232	2	268	0.866
7	20	8	4	2	6	153	193	0.793
	608	289	397	530	257	185	2266	
P Acc.	0.796	0.595	0.783	0.808	0.903	0.827		0.786
Kappa	0.733							

Tabelle 46: Konfusionsmatrizen ,Textur GLCM objektbasiert, dyn. GrayLimits'. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten

Textur Objekt dyn. GrayLimits NL 16, 10 wichtigste MDG - 20cm

	1	2	3	4	5	7		U Acc.
1	481	79	43	44	0	17	664	0.724
2	47	185	1	7	0	1	241	0.768
3	22	5	325	15	0	5	372	0.874
4	34	14	19	439	16	2	524	0.838
5	0	0	5	24	235	2	266	0.883
7	24	6	4	1	6	158	199	0.794
-	608	289	397	530	257	185	2266	

P Acc. 0.791 0.640 0.819 0.828 0.914 0.854 0.805 Kappa 0.757

Textur Objekt dyn. GrayLimits NL 7 Energy IR/R/G/B - 100cm fm

	1	2	3	4	5	7		U Acc.
1	489	98	45	36	2	21	691	0.708
2	32	155	2	9	0	2	200	0.775
3	21	8	319	25	2	3	378	0.844
4	44	18	21	434	16	1	534	0.813
5	0	1	5	24	230	1	261	0.881
7	22	9	5	2	7	157	202	0.777
-	608	289	397	530	257	185	2266	

P Acc. 0.804 0.536 0.804 0.819 0.895 0.849 0.787 Kappa 0.735

Textur Objekt dyn. GrayLimits NL 4 Energy IR/R/G/B - 500cm

	1	2	3	4	5	7		U Acc.
1	478	107	56	46	2	22	711	0.672
2	35	147	1	10	0	3	196	0.750
3	26	7	281	33	1	4	352	0.798
4	52	17	41	411	38	3	562	0.731
5	2	5	12	29	213	12	273	0.780
7	15	6	6	1	3	141	172	0.820
-	608	289	397	530	257	185	2266	

P Acc. 0.786 0.509 0.708 0.775 0.829 0.762 0.737

Kappa 0.672

Textur Objekt dyn. GrayLimits NL 16, 10 wichtigste MDA -100cm

	1	2	3	4	5	7		U Acc.
1	487	90	57	33	1	21	689	0.707
2	34	165	4	10	0	2	215	0.767
3	31	13	308	27	3	6	388	0.794
4	35	14	17	438	22	2	528	0.830
5	0	0	5	21	223	1	250	0.892
7	21	7	6	1	8	153	196	0.781
	608	289	397	530	257	185	2266	

P Acc. 0.801 0.571 0.776 0.826 0.868 0.827 0.783 Kappa 0.729

Textur Objekt dyn. GrayLimits NL 10 Energy IR/R/G/B - 200cm

	1	2	3	4	5	7		U Acc.
1	484	90	57	46	0	19	696	0.695
2	39	165	3	7	0	0	214	0.771
3	23	12	309	20	1	5	370	0.835
4	40	13	20	432	17	2	524	0.824
5	0	1	5	23	234	4	267	0.876
7	22	8	3	2	5	155	195	0.795
	608	289	397	530	257	185	2266	
P Acc.	0.796	0.571	0.778	0.815	0.911	0.838		0.785

Kappa 0.732

Tabelle 47: Konfusionsmatrizen , Textur DSWT'. Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras,

5 ... Offenland Fels, 7 ... Schatten

Textur DSWT Coif 1 IR/R/G/B 10 wichtigste MDG - 20cm

	1	2	3	4	5	7		U Acc.
1	503	53	24	26	2	18	626	0.804
2	47	218	3	10	0	3	281	0.776
3	10	3	340	19	0	1	373	0.912
4	29	10	22	454	15	2	532	0.853
5	0	1	5	19	235	2	262	0.897
7	19	4	3	2	5	159	192	0.828
	608	289	397	530	257	185	2266	

P Acc. 0.827 0.754 0.856 0.857 0.914 0.859 0.842 Kappa 0.805

Textur DSWT Coif 1 IR/R/G/B 10 wichtigste MDG - 100cm fm

U Acc. 663 0.751 0.789 0.856 0.833 0.909 0.812 185 2266

P Acc. 0.819 0.661 0.839 0.838 0.895 0.816 0.815 *Kappa 0.770*

Textur DSWT sym2 IR/R/G/B - 500cm

	1	2	3	4	5	7		U Acc.
1	470	99	53	41	1	23	687	0.684
2	52	167	4	12	0	1	236	0.708
3	33	6	281	29	3	8	360	0.781
4	43	12	44	416	30	3	548	0.759
5	0	2	9	29	219	5	264	0.830
7	10	3	6	3	4	145	171	0.848
-	608	289	397	530	257	185	2266	

P Acc. 0.773 0.578 0.708 0.785 0.852 0.784 0.749 Kappa 0.687

Textur DSWT dmey IR/R/G/B 10 wichtigste MDA - 100cm

	1	2	3	4	5	7		U Acc.
1	511	86	32	33	2	23	687	0.744
2	33	179	3	13	0	0	228	0.785
3	21	5	328	22	0	3	379	0.865
4	22	15	25	438	18	2	520	0.842
5	0	0	5	23	233	2	263	0.886
7	21	4	4	1	4	155	189	0.820
-	608	289	397	530	257	185	2266	

P Acc. 0.840 0.619 0.826 0.826 0.907 0.838 0.814 *Kappa 0.768*

Textur DSWT db 1 IR - 200cm

	1	2	3	4	5	7		U Acc.
1	510	85	34	35	1	18	683	0.747
2	30	177	3	16	0	3	229	0.773
3	18	5	330	27	3	1	384	0.859
4	36	16	20	430	19	3	524	0.821
5	0	2	6	21	229	4	262	0.874
7	14	4	4	1	5	156	184	0.848
	608	289	397	530	257	185	2266	
P Acc.	0.839	0.612	0.831	0.811	0.891	0.843		0.808
Kappa	0.761							

Tabelle 48: Konfusionsmatrizen "Datadistribution". Klassen: 1 ... Nadelholz, 2 ... Laubholz, 3 ... Latsche, 4 ... Offenland Gras, 5 ... Offenland Fels, 7 ... Schatten

	1	2	3	4	5	7		U Acc.
1	489	66	55	39	0	19	668	0.732
2	48	195	3	14	0	0	260	0.750
3	13	7	313	19	1	2	355	0.882
4	41	13	17	437	10	2	520	0.840
5	0	0	4	19	241	3	267	0.903
7	17	8	5	2	5	159	196	0.811
	608	289	397	530	257	185	2266	

P Acc. 0.804 0.675 0.788 0.825 0.938 0.859 0.809 *Kappa* 0.763

Datadistribution GEV IR/R/G/B/NDVI/AVI/TVI/SAVI - 100cm fm

	1	2	3	4	5	7		U Acc.
1	484	70	51	35	0	22	662	0.731
2	46	194	3	15	0	2	260	0.746
3	19	5	315	12	1	1	353	0.892
4	39	11	17	444	12	2	525	0.846
5	0	1	5	22	239	3	270	0.885
7	20	8	6	2	5	155	196	0.791
_	608	289	397	530	257	185	2266	

P Acc. 0.796 0.671 0.793 0.838 0.930 0.838 0.808 *Kappa 0.762*

Datadistribution GEV IR/R/G/B/NDVI/AVI/TVI/SAVI - 500cm

	1	2	3	4	5	7		U Acc.
1	494	86	58	50	3	22	713	0.693
2	47	176	5	18	1	4	251	0.701
3	14	6	287	23	2	3	335	0.857
4	42	15	35	401	27	7	527	0.761
5	1	2	4	38	220	11	276	0.797
7	10	4	8	0	4	138	164	0.841
	608	289	397	530	257	185	2266	

P Acc. 0.813 0.609 0.723 0.757 0.856 0.746 0.757 Kappa 0.697

Datadistribution GEV IR/R/G/B/NDVI/AVI/TVI/SAVI - 100cm

	1	2	3	4	5	7		U Acc.
1	465	62	60	38	0	20	645	0.721
2	47	193	5	8	0	1	254	0.760
3	26	10	304	13	1	1	355	0.856
4	47	16	19	447	9	2	540	0.828
5	0	0	4	22	242	2	270	0.896
7	23	8	5	2	5	159	202	0.787
	608	289	397	530	257	185	2266	
P Acc.	0.765	0.668	0.766	0.843	0.942	0.859		0.799

Kappa 0.750

Datadistribution GEV IR/R/G/B/NDVI/AVI/TVI/SAVI - 200cm

	1	2	3	4	5	7		U Acc.
1	485	60	49	38	0	24	656	0.739
2	48	195	7	14	0	2	266	0.733
3	22	9	313	13	2	1	360	0.869
4	37	15	19	434	9	3	517	0.839
5	0	0	5	28	242	3	278	0.871
7	16	10	4	3	4	152	189	0.804
	608	289	397	530	257	185	2266	
P Acc.	0.798	0.675	0.788	0.819	0.942	0.822		0.804

Kappa 0.756

ANHANG E



Klassifizierungsergebnis der Gruppen und Untergruppen des systematischen Tests.

Abbildung 63: Klassifizierungsgenauigkeit des unabhängigen Testdatensatzes der Variablensets zuzüglich Standardset der Gruppe Vegetationsindizes, getrennt nach den fünf Eingangsbildern.



Abbildung 64: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 3x3 Pixel, getrennt nach den fünf Eingangsbildern.



Klassifizierungsgenauigkeit 0.65 0.6 0.55 — 200cm 0.5 Alle Variablen Textur MW 11x11 NL 16 Standardset IR/R/G/B Alle Variablen Textur MW 11x11 NL 16 R Fextur MW 11x11 NL 16 G Fextur MW 11x11 NL 16 B Textur MW 11x11 NL 16 10 wichtigste MDG Textur MW 11x11 NL 16 Contrast IR/R/G/B Textur MW 11x11 NL 16 Correlation IR/R/G/B Textur MW 11x11 NL 16 Energy IR/R/G/B Textur MW 11x11 NL 16 Homogeneity IR/R/G/B Textur MW 11x11 NL 16 IR Textur MW 11x11 NL 16 10 wichtigste MDA

0.9

0.85

0.8

0.75

0.7

Abbildung 65: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 7x7 Pixel, getrennt nach den fünf Eingangsbildern.

Abbildung 66: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 11x11 Pixel, getrennt nach den fünf Eingangsbildern.

- 20cm

100cm - 100cm fm

500cm

Abbildung 68:Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 25x25 Pixel, getrennt nach den fünf Eingangsbildern.

Abbildung 69: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 35x35 Pixel, getrennt nach den fünf Eingangsbildern.

Abbildung 70: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., berechnet in einem Moving Window der Größe 51x51 Pixel, getrennt nach den fünf Eingangsbildern.

Abbildung 72: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 16 und GrayLimits [0 255], getrennt nach den fünf Eingangsbildern.

Abbildung 74: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 64 und GrayLimits [0 255], getrennt nach den fünf Eingangsbildern.

Abbildung 76: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 5 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern.

Abbildung 77: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 7 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern.

Abbildung 78: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 10 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern.

Abbildung 79: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit Gray Level Co-occurence Matrix Ansatz nach Haralick et al., Objektbasiert mit NumLevels 16 und dynamischen GrayLimits, getrennt nach den fünf Eingangsbildern.

Abbildung 80: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit diskreter stationärer Wavelet Transformation (DSWT) berechnet mit dem bior 1.1 Wavelet aus der Biorthogonal Waveletfamilie, getrennt nach den fünf Eingangsbildern.

Abbildung 82: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit diskreter stationärer Wavelet Transformation (DSWT) berechnet mit dem db 1 Wavelet aus der Daubechies Waveletfamilie, getrennt nach den fünf Eingangsbildern.

Abbildung 83: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Textur mit diskreter stationärer Wavelet Transformation (DSWT) berechnet mit dem dmey Wavelet aus der Discrete Meyer Waveletfamilie, getrennt nach den fünf Eingangsbildern.

Abbildung 84: Klassifizierungsgenauigkeit der Variablensets zuzüglich Standardset der Gruppe Grauwertverteilung im Objekt (Datadistribution), getrennt nach den fünf Eingangsbildern.

ANHANG F

Abbildung 85: Durch die jeweilige Variable für die Objekte des Testgebietes A ermittelten Werte der 10 wichtigsten Variablen nach MDA Wichtigkeit bei Klassifizierung mit allen Variablen des 20 cm Bildes als Karte dargestellt.

Abbildung 86: Durch die jeweilige Variable für die Objekte des Testgebietes A auf dem 20 cm Bild ermittelten Werte von 12 unterschiedlichen Variablen.

Anhang XXX