



Texturanalyse mittels diskreter Wavelet Transformation für die objektbasierte Klassifikation von Orthophotos

PHILIPP TOSCANI, MARKUS IMMITZER & CLEMENT ATZBERGER, Wien, Österreich

Keywords: texture, gray level co-occurrence matrices (GLCM), discrete stationary wavelet transformation (DSWT), random forest, land cover classification

Summary: *Wavelet-based texture measures for object-based classification of aerial images.* Object-based approaches permit the use of textural information in addition to the spectral signatures. However, it is not yet clear which textural features and which spatial resolution offer the highest information content. The aim of the research was to evaluate textural features based on discrete stationary wavelet transformation (DSWT) against metrics from gray level co-occurrence matrices (GLCM) within a typical land cover classification setting using 4-band UltraCam data with up to 20 cm ground resolution. The study clearly demonstrated the superiority of wavelet based approaches compared to classical GLCM-features both in terms of classification accuracy and necessary computer resources. The random forest (RF) based classification of three broad land cover classes (forest, open land and pinus mugo plus shadows) of the Bavarian Alps (Germany) using the coiflet-wavelet-family in addition to the spectral data gave for example an overall classification accuracy >90% with all individual class accuracies (user and producer accuracies) being >88%. Using the spectral data alone, the corresponding overall classification accuracy was 87%. The positive effect of the textural measures was particularly noticeable with the highest ground resolution. With decreasing resolution, the positive effect of the tested textures vanished and overall classification accuracies decreased. Both feature selection criteria offered by RF (mean decrease in accuracy and mean decrease in gini) permitted the identification of a small subset of features (~10) yielding similar or higher classification accuracies compared to the use of all textural features. This permits to significantly reduce the processing time for large scale applications.

Zusammenfassung: Bei der Klassifikation der Landbedeckung mittels objektbasierten Ansätzen bietet sich die Möglichkeit, die spektrale Information durch Textur beschreibende Parameter zu ergänzen. Dafür stehen verschiedenste Texturmaße zur Verfügung, welche zusätzlich auf unterschiedlicher räumlicher Auflösung berechnet werden können. In dieser Arbeit wurden auf Basis von diskreter stationärer Wavelet Transformation (DSWT) generierte Maße mit den weitverbreiteten Texturmaßen aus Gray Level Co-occurrence Matrizen (GLCM) verglichen. Für die Klassifikation der drei Landbedeckungsklassen Wald, Latsche und Offenland (+ Schatten) in den Bayerischen Alpen (Deutschland) wurden 4-Kanal-Orthophotos (UltraCam) mit 20 cm Bodenauflösung verwendet. Die DSWT-Maße zeigten deutliche Vorteile in Bezug auf Klassifikationsgenauigkeit und Rechenzeit. Bei der Klassifikation mittels Random Forest (RF) anhand spektraler Information und Kennwerten der Coiflet-Wavelet-Familie wurden Gesamtgenauigkeiten von über 90% erreicht. Dabei lagen alle klassenspezifischen Nutzer- und Produzentengenauigkeiten über 88%. Der positive Effekt der Texturmaße war bei der Klassifikation der Bilder mit der höchsten räumlichen Auflösung am deutlichsten und nahm mit abnehmender Auflösung bedeutend ab. Zusätzlich konnte gezeigt werden, dass sich die bei der Klassifikation mit RF ermittelten Wichtigkeitsmaße (Mean Decrease in Accuracy und Mean Decrease in Gini) für eine Variablenselektion eignen, wobei Mean Decrease in Accuracy Vorteile zeigte. Die Klassifikationsgenauigkeiten bei Verwendung der 10 wichtigsten Texturmaße lagen immer über den mit allen Variablen erzielten Werten. Die Variablenselektion verringert zusätzlich die Rechenzeiten, was vor allem bei großflächigen Anwendungen Vorteile bringt.

1 Einleitung

Objektbasierte Ansätze zeigen insbesondere bei der Klassifikation von räumlich sehr hochaufgelösten Fernerkundungsdaten Vorteile gegenüber pixelbasierten Verfahren (JÄHNE 2005, KAYITAKIRE et al. 2006, CASTILLA & HAY 2008, WASER et al. 2010, IMMITZER et al. 2012a). Das Zusammenfügen von ähnlichen und benachbarten Bildelementen zu Segmenten, welche realweltlichen Objekten entsprechen, ermöglicht neben der spektralen Information die Verwendung von zusätzlicher, das Objekt beschreibender Information für die Klassifikation (BLASCHKE & STROBL 2001, HAY et al. 2005, BLASCHKE 2010). Neben geometrischen Parametern wie Größe und Form kann vor allem die Oberflächenstruktur (Textur) bei der Klassifizierung von segmentierten Bildern einen wesentlichen Beitrag leisten (RENGERS & PRINZ 2009, VIEIRA et al. 2012). Das Ziel ist die Nachahmung bzw. mathematische Beschreibung der menschlichen Wahrnehmung eines Interpreten (ZHU & YANG 1998). Ein zusätzlicher Vorteil von objektbasierter Klassifikation ist der meist geringere Daten- und Rechenaufwand (JÄHNE 2005).

Etablierte Ansätze für die Beschreibung der Objekttextur basieren auf der statistischen Analyse der Grauwerte des Bildes. Ein guter Überblick zu Grundlagen, Modellen und Verwendung in der Landbedeckungsklassifikation findet sich in RENGERS & PRINZ (2009). Der in der Fernerkundung am weitesten verbreitete Ansatz stammt von HARALICK et al. (1973). Sie beschreiben 14 Texturmaße, welche mit Hilfe von Gray Level Co-occurrence Matrizen (GLCM) berechnet werden. Für die Berechnung der GLCM wird die Nachbarschaft eines Pixels in einer Aufnahmezelle betrachtet, gegebenenfalls in unterschiedlichen Distanzen, und die Zusammenhänge in verschiedenen, meist vier, Richtungen berechnet. Von diesen Messungen werden texturale Kennwerte abgeleitet. Der Informationsgehalt dieser Texturmaße ist abhängig vom spektralen Bereich, der Auflösung und der Charakteristik der zu erfassenden Objekte (Dimension, Form und räumliche Verteilung) und dem analysierten Bild (KAYITAKIRE et al. 2006). Verschiedene Studien zeigen, dass einige der 14 Texturparameter redundante Information lie-

fern (HARALICK et al. 1973, BARALDI & PARMIGIANI 1995, SOH & TSATSOU LIS 1999, SHABAN & DIKSHIT 2001, METZLER et al. 2002). Ein Nachteil der Texturmaße nach Haralick besteht darin, dass die Texturanalyse in nur einem Maßstab durchgeführt wird, weshalb der Größe der Auswahlzelle eine hohe Bedeutung zukommt (ZHU & YANG 1998, SHABAN & DIKSHIT 2001).

Methoden basierend auf der Wavelet Transformation arbeiten hingegen auf der Basis von multiresolution-Analysen. Die Bilder werden dabei einer Frequenzanalyse in mehreren Auflösungen unterzogen. Die Wavelet Transformation stammt aus dem Gebiet der Signalanalyse. Dabei wird versucht, durch Transformation eines Signales Information zu gewinnen, welche als Maß für die Textur genutzt werden kann. Bei der Analyse des Signales wird die Fenstergröße variabel gehalten und an die auftretende Frequenz angepasst (LOUIS et al. 1998, ZHU & YANG 1998, POLIKAR 1999). Dadurch können unterschiedliche Oberflächenbeschaffenheiten von feiner bis grober Textur unterschieden werden (GRAPS 1995). Der Vorteil der diskreten stationären Wavelet Transformation (DSWT) besteht darin, dass durch das Fehlen von Up- und Downsampling-Schritten die Abmessungen des Ausgabebildes jenen des Eingangsbildes entsprechen (NASON & SILVERMAN 1995). Jede Auflösungsstufe gibt vier Layer mit Ergebnissen zurück: A-Bild (Approximation), H-Bild (horizontale Details), V-Bild (vertikale Details) und D-Bild (diagonale Details) (LIVENS et al. 1997, BUSCH & BOLES 2002). Die verschiedenen Ergebnisse liegen pixelweise vor und können daher ohne weiteres auf Objektebene aggregiert werden.

Ziel dieser Studie ist die systematische Untersuchung des Potenzials verschiedener Texturmaße für die objektbasierte Klassifikation von 4-kanaligen Orthophotos im Hochgebirge. Dabei soll die etablierte Methode der Texturmaße nach Haralick mit der bisweilen weniger verwendeten DSWT-basierten Texturanalyse im Hinblick auf die Klassifikationsgenauigkeit untersucht werden. Zusätzlich soll der Einfluss der räumlichen Auflösung der Orthophotos auf die Klassifikationsgenauigkeit analysiert werden. Wert wird auf eine unabhängige Validierung der Klassifikationsergebnisse sowie auf die räumliche Übertrag-

barkeit der verwendeten Methoden gelegt. Für Fragen der praktischen Umsetzbarkeit wird auch die Rechenzeit mit betrachtet.

2 Daten und Methodik

2.1 Projekthintergrund

Bei der großflächigen Erfassung und Bewertung von FFH-Lebensraumtypen in den Natura 2000 Gebieten können fernerkundliche Analysen einen wesentlichen Beitrag leisten. Die Studie ist Teil einer Arbeit, in welcher Fernerkundungsdaten für diesen Zweck im bayerischen Alpenraum eingesetzt werden (BINNER & SEITZ 2009). Das Institut für Vermessung, Fernerkundung und Landinformation der Universität für Bodenkultur (BOKU) Wien wurde von der Bayerischen Landesanstalt für Wald und Forstwirtschaft (LWF) mit der Entwicklung und Umsetzung einer großflächigen Klassifikation der Natura 2000 Gebiete des bayerischen Alpenraumes beauftragt. Ziel war die Erfassung der Klassen Offenland, Wald und Latsche in den FFH- und SPA-Schutzgebieten des bayerischen Hochgebirges mit einer Gesamtfläche von 96.000 ha. Die drei Klassen resultieren aus der Tatsa-

che, dass die LWF nur für die Kartierung der Waldflächen zuständig ist. Daraus ergab sich die Notwendigkeit, die aktuelle Waldfläche von der Offenland- sowie Latschenfläche abzugrenzen. Einzusetzen waren vorrangig die digitalen Orthophotos des Bayerischen Landesamtes für Vermessung und Geoinformation (LVG) (IMMITZER et al. 2012c).

Die flächendeckende Kartierung wurde zwischenzeitlich erfolgreich abgeschlossen. Für kleine Teilbereiche wurden methodische Fragestellungen untersucht, die hier dargestellt werden.

2.2 Untersuchungsgebiet und Datengrundlage

Aus den Natura 2000-Gebieten des bayerischen Hochgebirges wurde für diese Studie das Teilgebiet Karwendel östlich von Garmisch-Partenkirchen ausgewählt (Abb. 1). Für die Klassifikation standen 4 Kanal Orthophotos (Blau, Grün, Rot, Infrarot) mit einer Bodenauflösung von 20 cm zur Verfügung. Die Bilder wurden am 1. September 2009 mit einer UltraCamX aufgenommen. Für die Untersuchung wurden 3 Orthophotokacheln mit jeweils 4 km² Fläche verwendet. Die wesent-

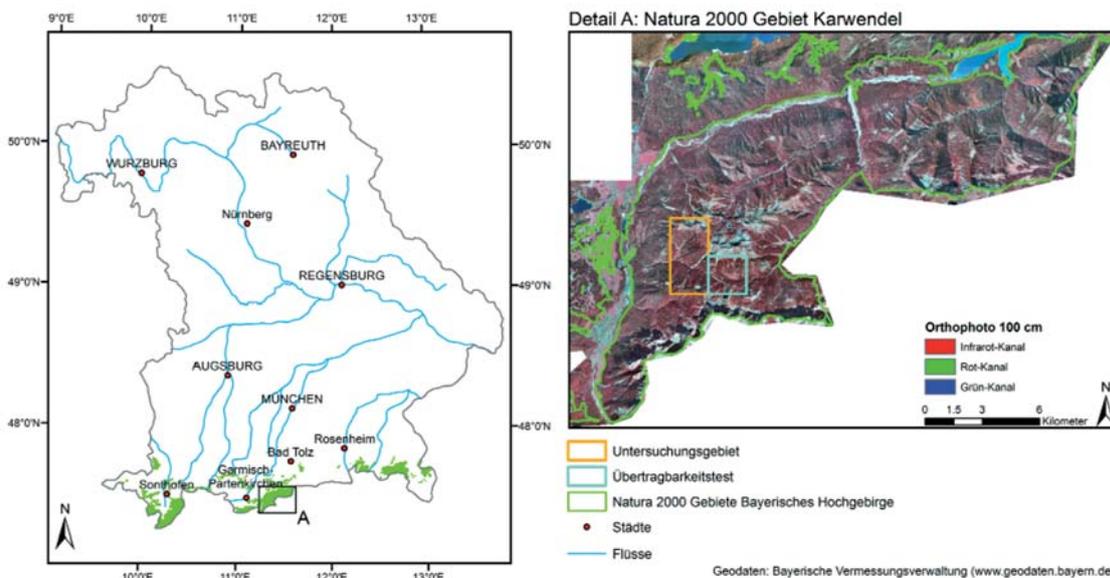


Abb. 1: Lage der Natura 2000 Gebiete des Bayerischen Hochgebirges (Untersuchungsgebiet des Projekts „Wald-Latsche-Offenland Abgrenzung“) und Detailausschnitt des Natura 2000 Gebietes Karwendel mit den verwendeten Orthophotokacheln.

lichen Analysen wurden auf 2 Kacheln durchgeführt, welche in Abb. 1 rechts orange markiert sind. Eine weitere Kachel (hellblau dargestellt) wurde lediglich für die Untersuchung der Übertragbarkeit herangezogen.

2.3 Segmentierung und visuelle Klassifikation

Die Segmentierung des Testgebietes erfolgte mit der Software Definiens unter Verwendung der Kanäle Grün, Rot und Infrarot. Die Ursprungsdaten wurden zu diesem Zweck auf 100 cm Bodenauflösung degradiert. Die für die multiresolution-Segmentierung (BAATZ & SCHÄPE 2000) geeigneten Parameter wurden wie für derartige Fragestellungen üblich (DRÄGUT et al. 2010) mittels Trial-and-Error Herangehensweise ermittelt. Die Qualität der Segmentierung wurde durch visuelle Kontrolle der Segmente bewertet. Dabei wurde vor allem auf die Klassenreinheit der einzelnen Segmente geachtet. Zusätzlich sollte die Übertragbarkeit der Segmentierungseinstellung auf Orthophotokacheln anderer Befliegungstage gewährleistet bzw. mit geringem Adaptionaufwand möglich sein. Mit folgenden Parametern wurde ein den Anforderungen entsprechendes Ergebnis erzielt: Scale =

40, Shape = 0,3 und Compactness = 0,5. Die drei zur Segmentierung verwendeten Kanäle wurden wie folgt gewichtet: Infrarot = 4, Rot = 1 und Grün = 1.

Die Segmentierung ergab 4.681 Polygone mit einer Größe von $3 \text{ m}^2 - 26.849 \text{ m}^2$. Die am Ausgangsbild mit 100 cm Bodenauflösung generierten Polygone wurden auch für die Analysen mit höherer und mit niedrigerer Auflösung verwendet. Um die Übertragbarkeit sicherzustellen, wurden Polygone mit einer Fläche $< 100 \text{ m}^2$ eliminiert und dem benachbarten Objekt mit der längsten gemeinsamen Grenze klassenunabhängig zugeordnet. Durch die Eliminierung ergaben sich 4.549 Polygone mit einer Größe von $100 \text{ m}^2 - 26.849 \text{ m}^2$.

Anschließend wurden alle Polygone visuell einer der sechs Klassen Nadelwald, Laubwald, Latsche, Offenland Gras, Offenland Fels bzw. Schatten zugeordnet. In Abb. 2 sind für die einzelnen Klassen Beispielpolygone dargestellt. Dieser Datensatz stellt die Referenzinformation dar, mit der die Klassifikation durchgeführt und validiert wurde. Für zusammenfassende Analysen wurden die Klassen Nadel- und Laubwald zur Klasse Wald und die Klassen Offenland Gras bzw. Offenland Fels zu Offenland entsprechend den Projektanforderungen (Kapitel 2.1) zusammengefasst.

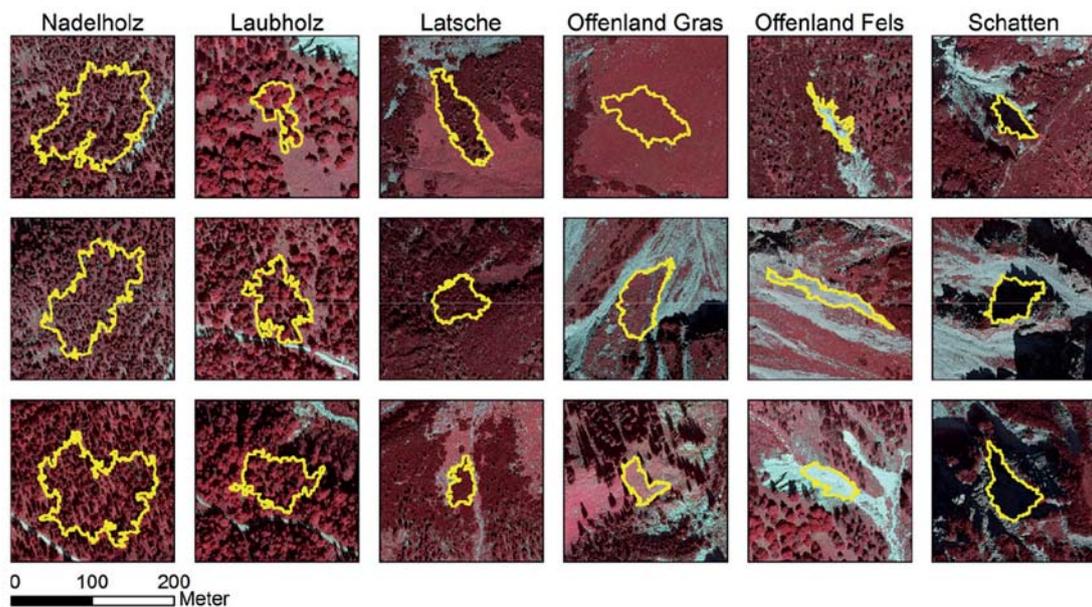


Abb. 2: Beispielpolygone der 6 untersuchten Klassen (CIR Darstellung aus den Kanälen Infrarot, Rot und Grün).

Tab. 1: Aufteilung der Objekte auf die 6 Klassen und deren objekt- bzw. flächenbezogene Anteile sowie der Mittelwert und Median der Objektgrößen je Klasse des gesamten Testgebietes.

Klasse	Objekte	Anteil Objekte	Fläche (m ²)	Anteil Fläche	Mittelwert der Objektgröße (m ²)	Median der Objektgröße (m ²)
Nadelholz	1.166	0,26	2.752.042	0,34	2.360,2	1.508
Laubholz	490	0,11	954.202	0,12	1.947,4	1.412
Latsche	772	0,17	1.388.250	0,17	1.798,3	1.470
Offenland Gras	1.109	0,24	1.657.608	0,21	1.494,7	1.275
Offenland Fels	544	0,12	701.066	0,09	1.288,7	1.148
Schatten	468	0,10	546.832	0,07	1.168,4	1.125
Summe	4.549		8.000.000		1.758,6	1.322

Die Aufteilung der Objekte auf die einzelnen Klassen zeigt Tab. 1. Die Klassen Nadelholz und Offenland Gras weisen die höchsten Anteile auf, sowohl bezogen auf die Objektanzahl als auch auf die bedeckte Fläche. Die durchschnittliche Objektgröße ist bei den beiden Waldklassen (Nadelholz und Laubholz) am größten. Die Objekte der Klassen Offenland Fels und Schatten sind durchschnittlich am kleinsten.

Die Orthophotokachel für den Test der Übertragbarkeit wurde mit denselben Einstellungen segmentiert und ebenfalls visuell klassifiziert.

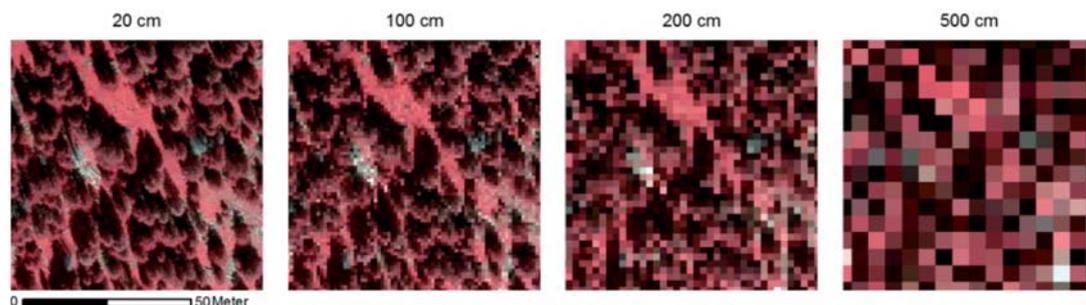
2.4 Erstellung der Eingangsvariablen

Für die Verringerung der Rechenzeiten und zur Erleichterung der Datenmanipulation bietet sich für sehr großräumige Analysen die Verringerung der räumlichen Auflösung der verwendeten Daten an (SCHLERF et al. 2003). Aus diesem Grund wurden aus den Aus-

gangsdaten (20 cm Bodenauflösung), Bilder mit 100 cm, 200 cm und 500 cm berechnet (Abb. 3). Alle Eingangsvariablen wurden für die 4 Auflösungen berechnet und für die Klassifikation parallel untersucht.

Die zur Klassifizierung verwendeten Variablen können vier Gruppen zugeordnet werden (Abb. 4). Beim ersten Verfahren „*Spektrale Information*“ wurden die Grauwerte der einzelnen Pixel innerhalb eines Segmentes zur Merkmalsgewinnung herangezogen, z. B. mittlerer Grauwert des IR-Kanals.

Beim zweiten Verfahren „*Texturmaße, Bezugsfläche Segment*“ wurde aus den einzelnen Pixeln der Segmente eine Grauwertmatrix (GLCM) erstellt, aus welcher dann die objektbasierten Texturparameter, z. B. *Energy*, ermittelt wurden. Beim dritten Verfahren „*Texturmaße, Moving Window*“ wurde in einer Zwischenberechnung zunächst die Information über die Nachbarschaft eines Pixels innerhalb einer quadratischen Bezugsfläche gesammelt, daraus eine GLCM erstellt und dann die Texturparameter, z. B. *Energy*, dem zen-

**Abb. 3:** Detailausschnitt in den verwendeten Auflösungen.

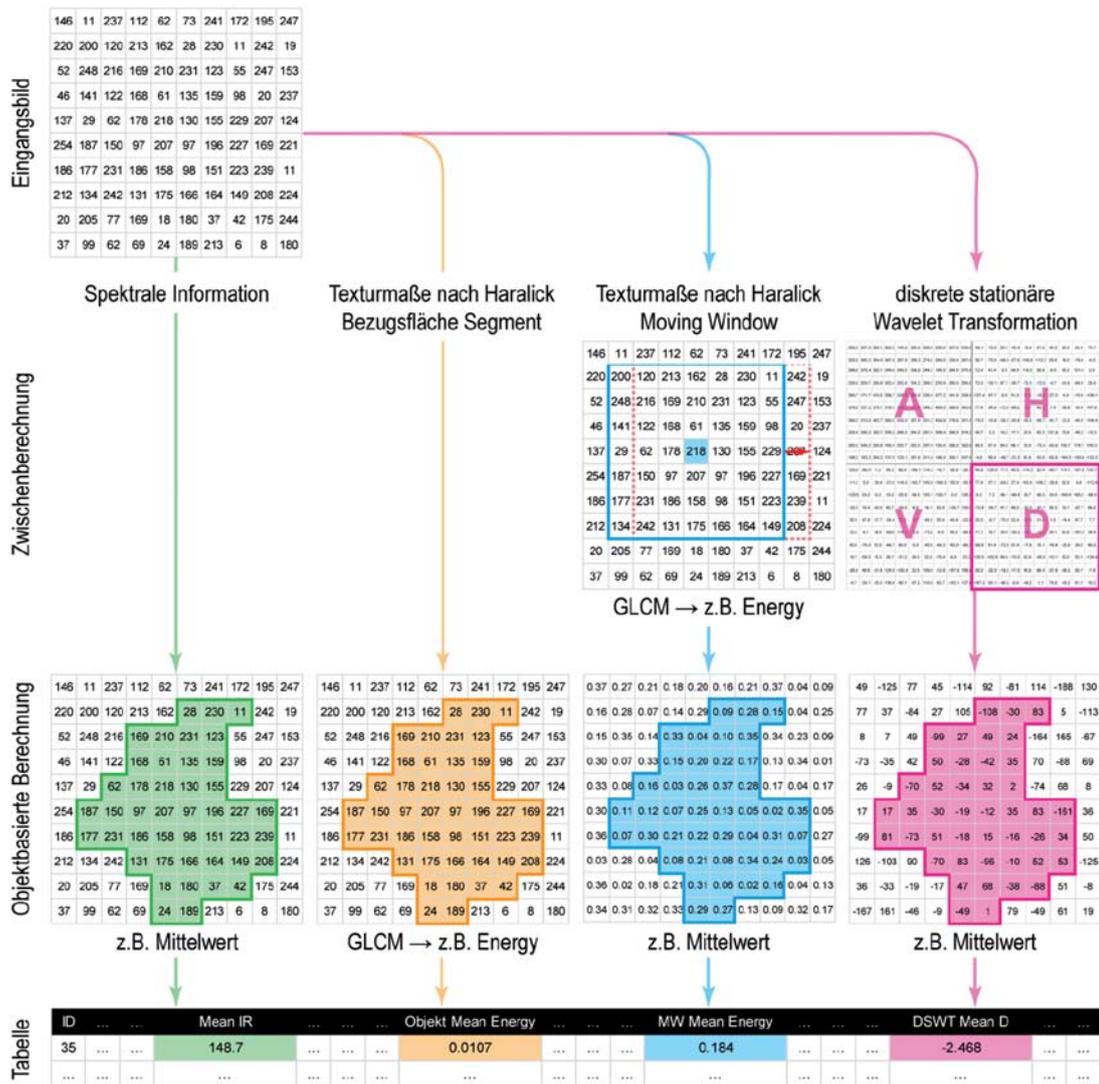


Abb. 4: Ablaufschema für die Berechnung der objektbezogenen Variablen (GLCM = Gray-level co-occurrence matrix).

tralen Pixel zugewiesen. Nach Verschiebung der Bezugsfläche um ein Pixel (Moving Window) wurde die Berechnung für das nächste zentrale Pixel vorgenommen. Dadurch wurde ein neuer Layer mit den Abmessungen des Eingangsbildes generiert. Dessen Merkmale wurden im nächsten Schritt wieder objektweise aggregiert, z. B. Mittelwert. Beim vierten Verfahren wurde das Eingangsbild in einer Zwischenberechnung einer „diskreten stationären Wavelet Transformation“ unterzogen. Diese liefert pro Transformationsdurchgang vier Layer mit den Abmessungen des Ein-

gangsbildes, welche im nächsten Schritt wieder objektbasiert ausgewertet wurden, z. B. Mittelwert.

2.4.1 Haralick, Bezugsfläche Segment (Haralick Segment)

Die Berechnung der GLCM für die einzelnen Objekte erfolgte in MATLAB (2011) getrennt für die vier Spektralkanäle mit folgenden Einstellungen: Lag-Distanz 1, Richtungen 0°, 45°, 90° und 135°, NumLevels (NL) 16, GrayLimits 0 – 255, Symmetric true. Aus den

vier GLCM je Spektralkanal wurden Mittelwert, Maximalwert und Standardabweichung der Texturparameter *Contrast*, *Correlation*, *Energy* und *Homogeneity* für jedes Objekt berechnet ($4 \text{ Kanäle} \times 4 \text{ Texturmaße} \times 3 \text{ Statistische Kennwerte im Objekt} = 48 \text{ Variablen pro räumlicher Auflösung}$).

2.4.2 Haralick, Moving Window (Haralick MW)

Für die Berechnung der GLCM wurden die gleichen Einstellungen wie bei der Bezugsfläche Segment verwendet. Die GLCM wurde jedoch nicht für die einzelnen Segmente, sondern in quadratischen Moving Windows (MW) erstellt. In Anlehnung an die Arbeiten von SHABAN & DIKSHIT (2001) und RODRIGUEZ-GALIANO et al. (2012a) wurden MW-Größen von 35×35 und 51×51 Pixel verwendet. Aus den vier GLCM je Spektralkanal wurden der Mittel- und Maximalwert der Texturparameter *Contrast*, *Correlation*, *Energy* und *Homogeneity* berechnet und dem zentralen Pixel des MW zugewiesen. Im nächsten Rechenschritt wurden die Mittelwerte, Maximalwerte und die Standardabweichung der Texturparameter direkt im Objekt berechnet ($4 \text{ Kanäle} \times [4 \text{ Texturmaße} \times 2 \text{ Statistische Kennwerte}] \times 3 \text{ Statistische Kennwerte im Objekt} = 96 \text{ Variablen pro räumlicher Auflösung}$).

2.4.3 Diskrete Stationäre Wavelet Transformation (DSWT)

Die Eingangsbilder wurden getrennt nach den einzelnen Spektralkanälen in MATLAB (2011) einer diskreten stationären Wavelet Transformation (DSWT) unterzogen. Dabei wurde aus folgenden fünf Wavelet-Familien je ein Wavelet (Bezeichnungen in Klammer) getestet: *Biorthogonale Wavelets (bior1.1)*, *Coiflets (coif1)*, *Daubechies Wavelets (db1)*, *Discrete Meyer (dmey)* und *Symlets (sym2)*. Wavelet-Familien unterscheiden sich hinsichtlich ihrer Form, dem Frequenzbereich und ihrer Maßstäbe (GRAPS 1995). In Abhängigkeit der Bilddimensionen war eine unterschiedlich hohe Anzahl von Transformationsdurchgängen möglich. Für die Bodenauflösungen 500 cm und 200 cm wurden zwei Durchgänge, für 100 cm und 20 cm vier Durchgänge

gewählt. Für jeden Spektralkanal und jeden Transformationsdurchgang entstehen vier Ergebnisbilder: Approximation (A), horizontale Details (H), vertikale Details (V), diagonale Details (D). Das A-Bild des Durchganges i dient dabei als Eingangsbild für den Durchgang $i+1$. Von jedem Ergebnisbild wurde für jedes Objekt Mittelwert, Maximalwert und Standardabweichung berechnet ($4 \text{ Kanäle} \times 4 \text{ Durchgänge} \times 4 \text{ Ergebnisbilder} \times 3 \text{ Statistische Kennwerte im Objekt} = 192 \text{ Variablen pro räumlicher Auflösung bei } 20 \text{ cm und } 100 \text{ cm}$; $4 \text{ Kanäle} \times 2 \text{ Durchgänge} \times 4 \text{ Ergebnisbilder} \times 3 \text{ Statistische Kennwerte im Objekt} = 96 \text{ Variablen bei } 200 \text{ cm und } 500 \text{ cm}$).

2.5 Klassifikation und Variablenselektion mittels Random Forest

Für die Klassifikation wurde der von BREIMAN (2001) entwickelte Random Forest Klassifikator (RF) verwendet. RF ist ein nicht parametrisches Verfahren, welches zuverlässige Klassifikationsergebnisse bei geringer Feinabstimmung liefert (LIAW & WIENER 2002). Das Verfahren wird zur Gruppe der Ensemble learning Klassifikatoren gezählt. Dabei wird durch die Kombination mehrerer Klassifikatoren die Erkennungsleistung gesteigert (WASKE & BRAUN 2009, KROSCHER et al. 2011). RF stellt somit eine wesentliche Weiterentwicklung von traditionellen Entscheidungsbäumen dar (RODRIGUEZ-GALIANO et al. 2012b).

Die Vorteile dieses Verfahrens sind (BREIMAN 2001, 2002, WASKE & BRAUN 2009, HASTIE et al. 2009, RODRIGUEZ-GALIANO et al. 2012a):

- die Klassen müssen nicht normalverteilt und können auch multimodal sein,
- hochdimensionale und redundante Datensätze können effizient verarbeitet werden,
- robustes Verhalten bei der Reduktion der Trainingsdaten,
- neigt nicht zum Overfitting,
- auch bei stark heterogenen Klassen sind zuverlässige Ergebnisse zu erwarten.

Für die Durchführung der RF Klassifikation wird aus dem Referenzdatensatz durch zufälliges Ziehen mit Zurücklegen (Bootstrapping) ein Trainingsdatensatz mit der Größe des Re-

ferenzdatensatzes generiert. In diesem Datensatz sind ca. 2/3 der Referenzdaten enthalten, mit welchen ein Entscheidungsbaum erstellt wird. Die nicht gezogenen Daten (out-of-bag, OOB) dienen als unabhängiger Validierungsdatsatz 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 (Anzahl an Entscheidungsbäumen). Neben der Anzahl der Entscheidungsbäume ist für die Erstellung einer RF Klassifikation auch noch die Anzahl an Variablen pro Entscheidungsknoten festzulegen. Im Unterschied zu herkömmlichen Entscheidungsbäumen werden bei RF nicht alle Variablen verwendet, sondern nur eine zufällige Auswahl (BREIMAN 2001). Dadurch kommt es zu einer Reduktion der Korrelation zwischen den Entscheidungsbäumen (HASTIE et al. 2009). Der Standardwert für die Anzahl an Variablen wird aus der Wurzel aller verfügbaren Variablen berechnet (LIAW & WIENER 2002). Nachdem alle Bäume erstellt wurden, weisen alle Objekte mehrere Klassifikationsergebnisse auf. Aus diesen wird letztendlich der Modus (majority vote) dem jeweiligen Objekt zugeordnet. Durch den Vergleich mit der tatsächlichen Klasse erhält man einen unverfälschten Schätzwert der Klassifizierungsgenauigkeit. Für die Annäherung dieses Wertes an die tatsächliche Klassifizierungsgenauigkeit ist eine relativ hohe Anzahl an Entscheidungsbäumen (> 500) sinnvoll (BREIMAN 2001, HASTIE et al. 2009).

Da Variablen ohne Aussagekraft zu einer Verschlechterung des Ergebnisses führen können (HASTIE et al. 2009), ist in bestimmten Fällen eine Variablenselektion sinnvoll. Dazu bieten sich die von RF gelieferten Aussagen über die Wichtigkeit der einzelnen Variablen für die Klassifikation an. Die zwei gängigsten Maße sind „Mean decrease in Gini“ (MDG) und „Mean decrease in accuracy“ (MDA). Für die Berechnung der MDA-Wichtigkeit einer Variablen werden deren Werte in den OOB-Daten zufällig verändert. Alle anderen Variablen bleiben dabei unverändert. Anschließend erfolgt die erneute Klassifikation der OOB-Daten. Der Vergleich der dabei erzielten Klassifizierungsgenauigkeit mit der ursprünglichen Genauigkeit ergibt die Wichtigkeit der jewei-

ligen Variablen. 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).

2.6 Testablauf

Für die Klassifikation wurde der Datensatz entsprechend der Objektanzahl der einzelnen Klassen in zwei gleichgroße Teildatensätze geteilt. Anschließend wurden mit einem Teil die RF-Modelle erstellt, inklusive der Ermittlung der OOB Fehler und MDA/MDG Wichtigkeiten. Dabei wurden die spektrale Information alleine (12 Variablen), sowie kombiniert mit den 3 Gruppen der Texturmaße verwendet. Anschließend wurde mit den erstellten Modellen der zweite Teil des Datensatzes als unabhängiger Validierungsdatsatz klassifiziert. Damit stehen neben dem OOB-Fehler des Trainingsdatensatzes auch Fehlermaße aus dem unabhängigen Validierungsdatsatz zur Verfügung.

Zusätzlich zur Klassifikation mit allen Variablen erfolgte auch eine Klassifikation mit einem durch Variablenselektion reduzierten Datensatz, d. h. mit den 10 wichtigsten Texturvariablen nach MDA bzw. MDG. Die Texturvariablen wurden immer zusätzlich zu den 12 Variablen aus den Spektralkanälen verwendet. Dieser Vorgang, von der Aufteilung des Datensatzes bis zur Klassifikation, wurde 100-mal wiederholt. Aus den Ergebnissen der einzelnen Wiederholungen wurden Mittelwert und Standardabweichung der Gesamtgenauigkeiten berechnet. Die Unterschiede der einzelnen Verfahren wurden mittels ANOVA analysiert.

Für die Erstellung der flächendeckenden Kartendarstellung wurde das Majority Vote der 100 Klassifizierungswiederholungen verwendet. Diese Werte wurden auch für die Erstellung der Konfusionsmatrizen herangezogen.

Die Berechnungen der Texturmaße erfolgte mit der Image Processing bzw. der Wave-

let Toolbox in MATLAB 7.13.0 (MATLAB 2011). Für die Klassifikation und die Analysen der Ergebnisse wurde das Statistikprogramm R 2.15.0 (R DEVELOPMENT CORE TEAM 2012) mit dem Zusatzpaket randomForest in der Version 4.6 (LIAW & WIENER 2002) verwendet.

3 Ergebnisse

3.1 Bedeutung der spektralen Information und der Texturvariablen

Die Ergebnisse zeigen eine deutliche Verbesserung des Klassifikationsergebnisses, wenn zusätzlich zur spektralen Information Texturvariablen verwendet werden (Abb. 5). Der orange Balken stellt dabei die Gesamtgenauigkeit unter alleiniger Verwendung der spektralen Information dar (Orthophoto mit 100 cm Bodenauflösung). Alle getesteten Texturmaßgruppen konnten eine höchst signifikante Verbesserung der Klassifikationsgenauigkeit bewirken (ANOVA post-hoc Tukey's HSD-text $p < 0.01$).

Die Steigerung der Genauigkeit ist bei Verwendung der im Objekt generierten Texturmaße nach Haralick am geringsten und bei den mittels DSWT erstellten Maßen am höchsten. Zwischen den getesteten Wavelets sind nur geringe Unterschiede feststellbar, wobei die Ergebnisse, die mit DSWT *coif1*, *dmey* und *sym2* erzielt wurden, die höchsten Genauigkeiten zeigten.

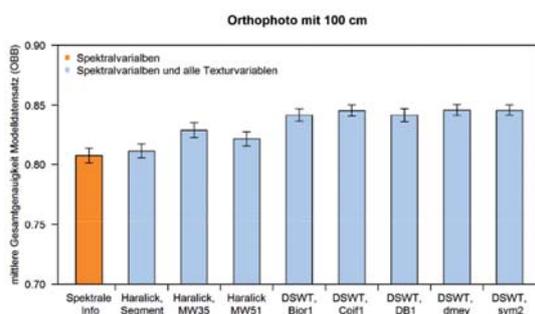


Abb. 5: Klassifikationsgenauigkeit (OOB) für 6 Klassen unter alleiniger Verwendung der spektralen Information (orange) und bei zusätzlicher Verwendung von Texturmaßen (Orthophoto mit 100 cm Auflösung).

3.2 Vergleich unterschiedlicher Auflösungen

Mit abnehmender Bodenauflösung der Eingangsdaten ist generell eine Verschlechterung der Klassifikationsgenauigkeit erkennbar. Der Einfluss hängt jedoch stark von den verwendeten Klassifikationsmerkmalen ab. Verwendet man beispielsweise für die Unterscheidung der 6 Klassen nur die spektrale Information, sind zwischen 100 cm und 200 cm keine Genauigkeitsunterschiede erkennbar. Das Ergebnis mit 20 cm liegt über, jenes mit 500 cm deutlich darunter. Wesentlich deutlicher sind die Unterschiede, wenn für die Klassifikation zusätzliche Texturmaße verwendet werden. Während am Orthophoto mit 20 cm Auflösung Ergebnisse um 85% erzielbar sind, liegen die Gesamtgenauigkeiten beim Orthophoto mit 500 cm Auflösung um 10 Prozentpunkte darunter. Bei der Bewertung macht es keinen Unterschied, ob die OOB Fehler aus dem Trainingsdatensatz betrachtet werden oder die Ergebnisse aus dem unabhängigen Validierungsdatensatz (Abb. 6).

Zwischen den drei getesteten Gruppen von Texturmaßen schneidet bis 200 cm die DSWT (*coif1*) immer am besten ab. Die schlechtesten Ergebnisse liefern die im Objekt berechneten Haralick Texturmaße. Die mittels Moving Window berechneten Haralick Texturmaße nehmen eine Mittelstellung ein. Ab 200 cm Bodenauflösung können die direkt im Objekt berechneten Haralick Texturmaße nicht mehr zu einer Steigerung der Klassifikationsgenauigkeit beitragen. Am Orthophoto mit 500 cm Auflösung bringen die mittels Moving Window berechneten Texturmaße nach Haralick die besten Ergebnisse. Sie sind die einzigen, die bei dieser Auflösung noch einen nennenswerten Beitrag zur Verbesserung des Klassifikationsergebnisses liefern können. Allerdings sind die bei dieser groben Auflösung erzielten Genauigkeiten wesentlich schlechter als beispielsweise jene mit den 20 cm Daten.

3.3 Variablenselektion

In Abb. 7 sind die mittleren Gesamtgenauigkeiten aus 100 Berechnungen bei Verwendung unterschiedlich vieler „wichtigsten Va-

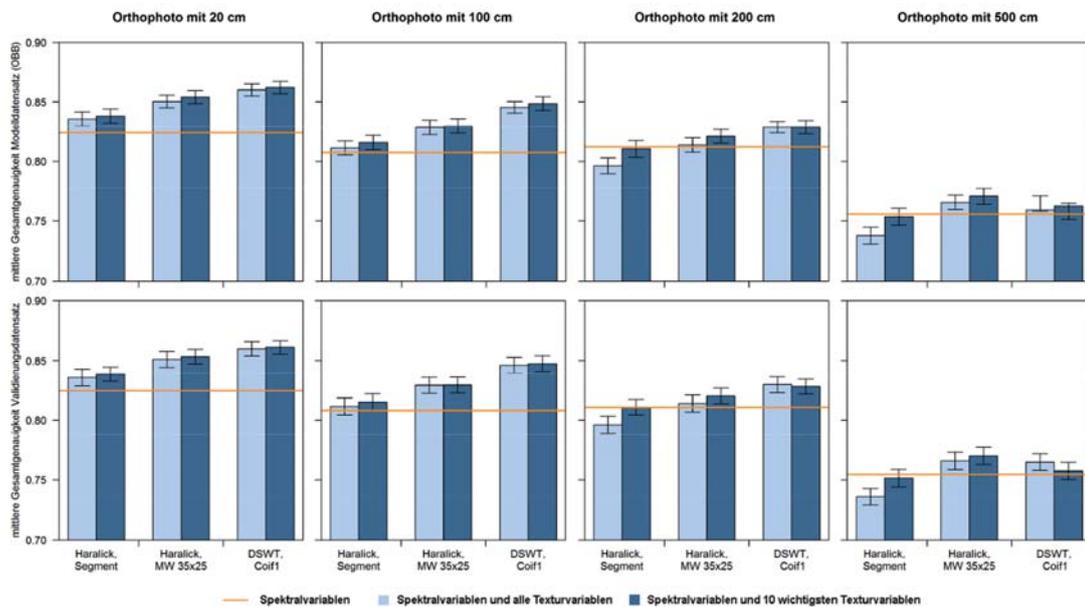


Abb. 6: Mittlere Gesamtgenauigkeit und Standardabweichung aus 100 Wiederholungen bei Verwendung aller bzw. der nach MDA 10 wichtigsten Texturvariablen für die unterschiedlichen Orthophotoauflösungen, obere Reihe: OOB-Genauigkeiten des Modellansatzes, untere Reihe: Gesamtgenauigkeit des unabhängigen Validierungsdatensatzes.

riablen“ nach MDA bzw. MDG des DSWT coif1 dargestellt. Vergleicht man diese Ergebnisse (Punktreihen) mit dem Ergebnis bei Verwendung aller coif1 Texturvariablen zeigt sich, dass durch gezielte Auswahl an Variablen höhere Klassifikationsgenauigkeiten erreicht werden können. Die Variablenselektion anhand der MDA-Wichtigkeit liefert bereits mit den 6 wichtigsten Variablen ein besseres Ergebnis. Die Ergebnisse auf Basis von

MDG liegen allgemein unter jenen auf Basis von MDA. Daher sind die 11 wichtigsten Variablen nach MDG notwendig, um die Klassifikationsgenauigkeit unter Verwendung aller Variablen zu erreichen. Aus diesem Grund sind in Abb. 6 neben den mit allen Variablen erzielten Ergebnissen (in hellblau) auch jene bei Verwendung der 10 wichtigsten Variablen nach MDA dargestellt (in dunkelblau).

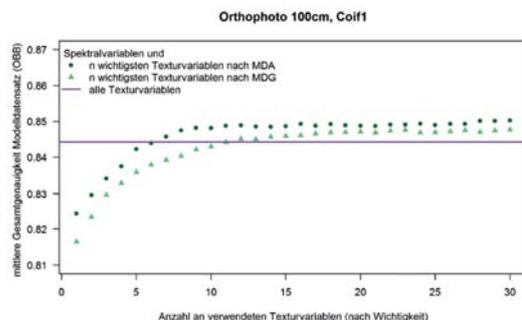


Abb. 7: Klassifikationsgenauigkeit (Mittelwerte aus 100 Wiederholungen) mit unterschiedlicher Anzahl (1-30) an nach MDA bzw. MDG wichtigsten Variablen im Vergleich zum Ergebnis mit allen Variablen (Orthophoto mit 100 cm Auflösung, Variablen: DSWT coif1).

3.4 Detaildarstellung des besten Klassifikationsergebnisses

Die Klassifikationsmatrizen basierend auf den Majority Votes aus den 100 Wiederholungen der Klassifikation mit und ohne den 10 wichtigsten Texturmaßen der DSWT coif1 zeigen, dass alle Klassen mit hohen Genauigkeiten klassifiziert wurden. Die geringsten Nutzer- und Produzentengenauigkeiten finden sich bei der Klasse Laubholz (LH), wobei die meisten Verwechslungen mit der zweiten Waldklasse Nadelholz (NH) zu beobachten sind. Die Latschenflächen wurden am zahlreichsten mit Nadelholz bzw. mit Offenland Gras verwechselt. Die Schattenobjekte wurden am häufigs-

Tab. 2: Klassifikationsmatrix aus dem Majority Vote der 100 Wiederholungen für 6 Klassen bei Verwendung der spektralen Information und den nach MDA 10 wichtigsten DSWT coif1 Variablen aus dem 100 cm Orthophoto (in Klammern die Werte bei Klassifikation nur mit spektraler Information). NH = Nadelholz, LH = Laubholz, OL = Offenland, NG = Nutzergenauigkeit, PG = Produktionsgenauigkeit.

		Referenz						Σ	NG
		NH	LH	Latsche	OL Gras	OL Fels	Schatten		
Klassifiziert als	NH	1001 (953)	134 (126)	36 (130)	40 (42)	5 (1)	67 (67)	1283 (1319)	0,780 (0,723)
	LH	54 (61)	333 (309)	2 (6)	18 (18)	0 (0)	11 (12)	418 (406)	0,797 (0,761)
	Latsche	38 (61)	1 (15)	682 (590)	44 (45)	1 (2)	7 (4)	773 (717)	0,882 (0,823)
	OL Gras	42 (59)	17 (24)	41 (33)	985 (985)	22 (20)	0 (0)	1107 (1121)	0,890 (0,879)
	OL Fels	0 (0)	0 (0)	4 (5)	22 (19)	510 (515)	3 (5)	539 (544)	0,946 (0,947)
	Schatten	31 (32)	5 (16)	7 (8)	0 (0)	6 (6)	380 (380)	429 (442)	0,886 (0,860)
	Σ	1166 (1166)	490 (490)	772 (772)	1109 (1109)	544 (544)	468 (468)	4549 (4549)	
PG	0,858 (0,817)	0,680 (0,631)	0,883 (0,764)	0,888 (0,888)	0,938 (0,947)	0,812 (0,812)		0,855 (0,820)	

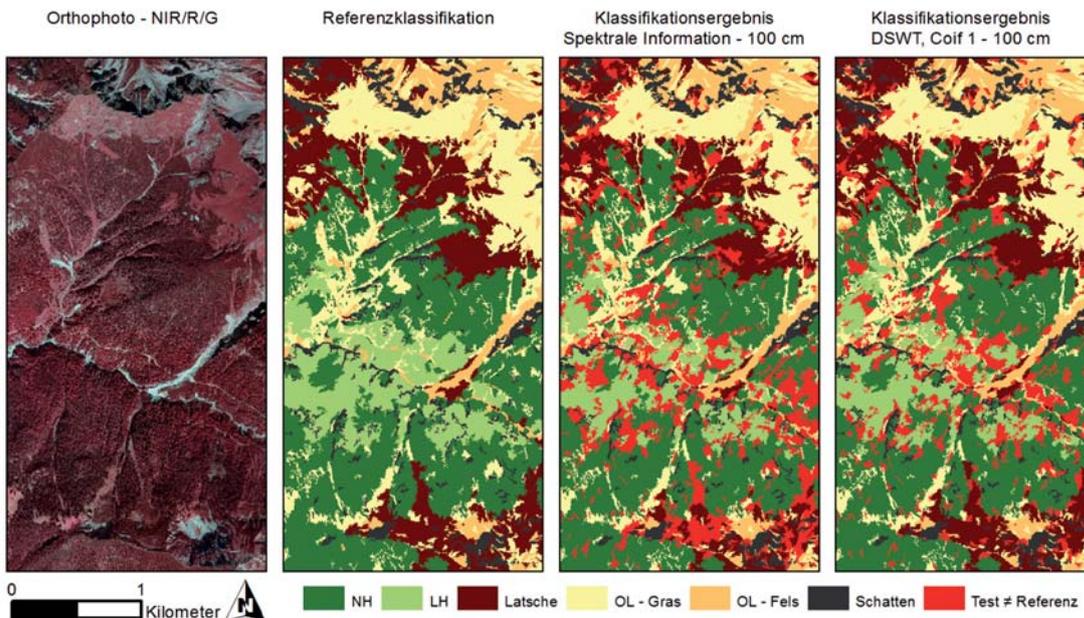


Abb. 8: Orthophoto, Referenzklassifikation und Klassifikationsergebnisse Spektraler Information bzw. Spektraler Information + DSWT coif1 (Mittelwerte aus 100 Wiederholungen) des Untersuchungsgebietes für 6 Klassen bei Verwendung des 100 cm Orthophotos.

ten fälschlich als Nadelholz klassifiziert. Im Vergleich zum Klassifikationsergebnis ohne Texturinformation ist eine Verbesserung der Klassifikationsgenauigkeit vor allem bei der Klasse Latsche und im geringeren Ausmaß bei den beiden Waldklassen (NH und LH) erkennbar.

In der Kartendarstellung in Abb. 8 sind diese beiden Klassifikationsergebnisse (mit/ohne coif1) der Referenzklassifikation gegenübergestellt. Abweichungen zwischen den Klassifikationsergebnissen und der Referenzklassifizierung sind in Rot dargestellt. Insbesondere im Norden und im südlichen Bereich des Bil-

Tab. 3: Klassifikationsmatrix aus dem Majority vote der 100 Wiederholungen für 3 Klassen (+ Schatten) bei Verwendung der spektralen Information und den nach MDA 10 wichtigsten DSWT coif1 Variablen aus dem 100 cm Orthophoto (in Klammern die Werte bei Klassifikation nur mit spektraler Information).

		Referenz					Σ	NG
		Wald	Latsche	Offenland	Schatten			
Klassifiziert als	Wald	1522 (1449)	38 (136)	63 (61)	78 (79)	1701 (1725)	0,895 (0,840)	
	Latsche	39 (76)	682 (590)	45 (47)	7 (4)	773 (717)	0,882 (0,823)	
	Offenland	59 (83)	45 (38)	1539 (1539)	3 (5)	1646 (1665)	0,935 (0,924)	
	Schatten	36 (48)	7 (8)	6 (6)	380 (380)	429 (442)	0,886 (0,860)	
	Σ	1656 (1656)	772 (772)	1653 (1653)	468 (468)	4549 (4549)		
PG		0,919 (0,875)	0,883 (0,764)	0,931 (0,931)	0,812 (0,812)		0,906 (0,870)	

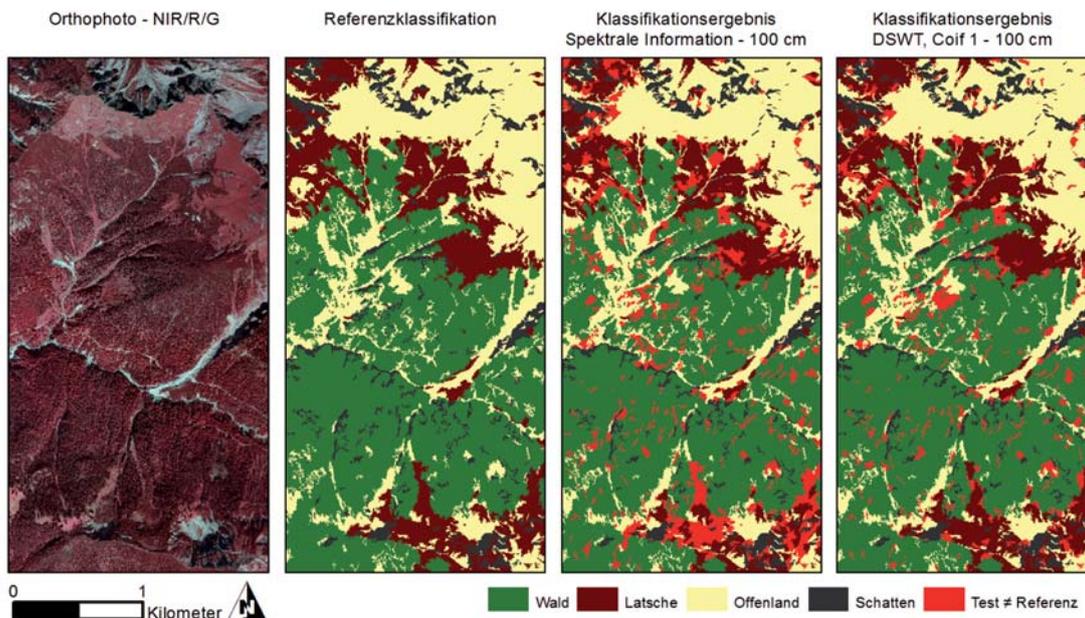


Abb. 9: Orthophoto, Referenzklassifikation und Klassifikationsergebnisse Spektraler Information bzw. Spektraler Information + DSWT coif1 (Mittelwerte aus 100 Wiederholungen) des Untersuchungsgebietes für 3 Klassen (plus Schatten) bei Verwendung des 100 cm Orthophotos.

des ist die deutliche Verbesserung der Klassifikation der Latschenflächen erkennbar, wenn die *coif1* Texturinformation zur Klassifikation mitverwendet wurde.

Die Untersuchung des Einflusses der Polygongröße auf das Klassifikationsergebnis zeigt, dass sich die Größenverteilung der falschklassifizierten Polygone nur geringfügig von den restlichen Polygonen unterscheidet. Lediglich bei den Klassen Nadelholz und Schatten konnte ein signifikanter Einfluss der Objektgröße festgestellt werden. Bei diesen beiden Klassen ist der Median der falsch klassifizierten Polygone deutlich geringer als im gesamten Datensatz. Das bedeutet, dass für diese beiden Klassen die größeren Polygone tendenziell besser klassifiziert wurden.

Die Aggregation der Ergebnisse auf die im ursprünglichen Projekt geforderten 3 Klassen (+ Schatten) verbessert die Gesamtklassifikationsgenauigkeit ohne Texturvariablen von 82,0% auf 87,0% und mit *coif1* Texturvariablen von 85,5% auf 90,6%. Mit Texturvariablen liegen alle Nutzer- und Produzentengenauigkeiten der drei Klassen Wald, Latsche und Offenland über 88% (Tab. 3).

Die Kartendarstellung in Abb. 9 zeigt den Vergleich der Klassifikationsergebnisse mit und ohne Texturvariablen (*coif1*) für die 3 ursprünglich geforderten Klassen und der zusätzlichen Schattenklasse.

Um die Übertragbarkeit der RF Modelle auf andere Gebiete zu untersuchen, wurde eine benachbarte Orthophotokachel (Abb. 1) ohne weitere Anpassungen klassifiziert. Es wurde eine mittlere Gesamtgenauigkeit von 83,2% bei 100 cm und 85,3% bei 20 cm Auflösung erzielt.

4 Diskussion

Durch die Einbeziehung von texturbeschreibenden Variablen bei der Klassifikation konnte in dieser Arbeit die Klassifikationsgenauigkeit signifikant gesteigert werden. Diese Erkenntnis deckt sich mit zahlreichen Studien zur Klassifikation der Landbedeckung (RYHERD & WOODCOCK 1996, WULDER et al. 1998, FRANKLIN et al. 2000, LALIBERTE & RANGO 2009, RODRIGUEZ-GALIANO et al. 2012a). Da-

bei ergaben alle drei getesteten Texturansätze zum Teil deutlich verbesserte Klassifikationsergebnisse. Die höchste Steigerung der Klassifikationsgenauigkeit erzielte in unserer Studie der Ansatz „*diskrete stationäre Wavelet Transformation*“ (im Mittel eine um 3,3 Prozentpunkte verbesserte Klassifikationsgenauigkeit am 100 cm Orthophoto), gefolgt vom Ansatz „*Texturmaße nach Haralick, Moving Window*“ (mittlere Steigerung: 2,2 Prozentpunkte). Die geringste Genauigkeitssteigerung brachte der Ansatz „*Texturparameter nach Haralick, Bezugsfläche Segment*“ (1,0 Prozentpunkte am 100 cm Orthophoto). Vor allem für die Unterscheidung von spektral sehr ähnlichen Klassen erwiesen sich die getesteten Texturmaße als vorteilhaft. Im konkreten Fall sind dies vor allem die Klassen Nadelholz und Latsche. Objekte dieser beiden Klassen würde auch ein Bildinterpret nur anhand der für Latschen eindeutigen Textur (Abb. 2) unterscheiden. Damit wird auch deutlich, wie wichtig es ist, bei der Arbeit mit hochauflösenden Sensoren auf objektbasierte Ansätze zurückzugreifen (JÄHNE 2005, KAYITAKIRE et al. 2006, CASTILLA & HAY 2008). Im Vergleich zu pixelbasierten Verfahren ermöglichen objektbasierte Ansätze auf eine einfache Art und Weise die Berechnung zusätzlicher, das Objekt beschreibender Information wie z. B. Textur.

Die positiven Erfahrungen in dieser Arbeit mit wavelet-basierten Texturmaßen bezüglich Klassifikationsgenauigkeit und Rechenzeitaufwand sind besonders herauszuheben. Sie bestätigen frühere Arbeiten von ZHU & YANG (1998), VAN COILLIE et al. (2011), SINGH et al. (2012). Insbesondere stellt die diskrete stationäre Wavelet Transformation unseres Erachtens eine interessante Alternative zu den gängigen Texturparametern nach Haralick dar. Das Potential der Frequenzanalyse durch Wavelet Transformation wird schon seit längerem in vielen Bereichen wie beispielsweise der Computer Vision für bildgebende Verfahren in der Medizin und Datenkompression in der Bildverarbeitung genutzt (GRAPS 1995, LOUIS et al. 1998). Eine verbreitete Anwendung in der Fernerkundung blieb aber bisweilen noch aus, wahrscheinlich auch, weil solche Verfahren noch nicht in gängigen Softwareprodukten implementiert sind.

LIVENS et al. (1997) zeigten, dass die einzelnen Wavelets nur geringe Unterschiede in den Klassifikationsergebnissen bewirken. Dieses Erkenntnis deckt sich mit den Ergebnissen dieser Arbeit. Die fünf aus unterschiedlichen Wavelet-Familien stammenden Wavelets zeigten ebenfalls nur geringe Unterschiede in der Klassifikationsgenauigkeit. Wesentlich wichtiger als die verwendete Wavelet-Familie, war die räumliche Auflösung der Daten. Generell konnten die besten Ergebnisse bei der höchsten Auflösung erzielt werden. Dies wurde auch bereits durch andere Arbeiten bestätigt (SCHLERF et al. 2003).

Neben den Klassifikationsergebnissen stellt der Aufwand der Datengewinnung einen wesentlichen Aspekt für die Bewertung der Anwendbarkeit dar. Bezüglich der erforderlichen Rechenzeit unterscheiden sich die drei getesteten Ansätze deutlich voneinander. Die Berechnung der Parameter „Haralick, Bezugsfläche Segment“ erfolgte am schnellsten. Aber auch die Berechnungen der DSWT-Parameter war deutlich weniger zeitintensiv als die Haralick Parameter mittels Moving Window. Die Rechenzeiten der drei getesteten Ansätze verhielten sich dabei ca. im Verhältnis 1:2:80 (Haralick Segment, DSWT, Haralick MW). Noch rechenzeitkritischer ist die Auflösung des analysierten Bildes. Hier steigt die Rechenzeit mit dem Quadrat des Auflösungsfaktors (RANDEN & HUSØY 1999, LILLESAND et al. 2004). Die Berechnung der Texturparameter auf dem 20 cm Bild benötigt daher rund 25-mal so lange wie jene auf dem 100 cm Bild.

Für großflächige Anwendungen ist daher eine Anpassung der Auflösung zu erwägen. Die dabei zu erwartende Verschlechterung der Klassifikationsgenauigkeit wurde auch bei dieser Untersuchung bestätigt. Die Verringerung der Auflösung der analysierten Orthophotos von 20 cm auf 100 cm und weiter auf 200 cm bewirkte eine Verschlechterung der mittleren Klassifikationsgenauigkeit von 82,3% auf 80,7% bei alleiniger Verwendung der spektralen Information. Zwischen 100 cm (80,7%) und 200 cm (81,2%) ist hingegen keine Verschlechterung feststellbar. Werden aber die Texturvariablen in der Klassifikation mitverwendet, sind die Vorteile der besseren Auflösung deutlicher. Die durch die Hinzunahme der DSWT coif1 Variablen gesteigerten

Klassifikationsgenauigkeiten lagen dabei bei 86,2% am 20 cm, bei 84,9% am 100 cm und bei 82,9% am 200 cm Bild.

Die Vergleiche der einzelnen Klassifikationen erfolgte in dieser Arbeit in erster Linie auf der im Random Forest (RF) Modell berechneten OOB Genauigkeit. Zusätzlich wurden die einzelnen Modelle aber auch auf einen unabhängigen Datensatz angewendet und dadurch validiert. Dabei konnte bestätigt werden, dass Random Forest durch das interne Bootstrapping bereits eine ausreichende unabhängige Testgröße liefert. Die Modellgenauigkeit, also die OOB-Klassifikationsgenauigkeit, lieferte dabei idente Genauigkeiten im Vergleich zum Validierungsdatensatz.

Die beiden gängigen Wichtigkeitsmaße Mean Decrease in Accuracy (MDA) und Mean Decrease in Gini (MDG) aus der RF Klassifikation eignen sich in der vorliegenden Arbeit gut für die Variablenselektion. So konnte mit beiden Maßen die Variablenzahl verringert und gleichzeitig die Klassifikationsgenauigkeit gesteigert werden. Auch wenn Random Forest prinzipiell mit einer großen Anzahl an Variablen umgehen kann, können zu viele Variable mit geringer Trennkraft das Klassifikationsergebnis verschlechtern (HASTIE et al. 2009). Eine Variablenselektion vermindert darüber hinaus den Zeitaufwand für die Berechnung der Klassifikationsmerkmale. Die Auswahl anhand MDA lieferte in unserer Studie das bessere Ergebnis und ermöglichte bereits mit den 10 wichtigsten Variablen bessere Ergebnisse als mit allen Texturvariablen. Somit sind für die Variablenselektion sowohl die MDA- als auch die MDG-Wichtigkeit geeignet, wobei in der Regel die MDA-Wichtigkeit zu bevorzugen ist, was auch die Ergebnisse anderer Studien bestätigt (CHAN & PAELINCKX 2008, NICODEMUS 2011, STUMPF & KERLE 2011, IMMITZER et al. 2012b).

5 Schlussfolgerungen und Ausblick

Durch das Hinzufügen von texturbeschreibenden Parametern in die objektbasierte Klassifikation von hochauflösenden Orthophotos ist eine deutliche Verbesserung der Klassifikationsgenauigkeit möglich. Mit den aus der

diskreten stationären Wavelet Transformation (DSWT) abgeleiteten Texturmaßen stehen interessante Alternativen zu den etablierten GLCM-Texturmaßen nach Haralick zur Verfügung. Die getesteten DSWT Texturmaße konnten dabei bezüglich Klassifikationsgenauigkeit aber auch in punkto geringerer Rechenzeit gegenüber den Haralick-Texturmaßen überzeugen. Diese Vorteile sind vor allem bei sehr hoher räumlicher Auflösung wesentlich. In dieser Studie konnten die besten Ergebnisse mit der höchsten Auflösung des Bildmaterials erzielt werden. Die Texturmaße zeigten bei den Orthophotos mit 20 cm bzw. 100 cm ihr Verbesserungspotenzial am deutlichsten.

Rechenzeitbetrachtungen sind insbesondere für großflächige Anwendungen von Bedeutung. So steigt der Rechenaufwand für die Berechnung der Texturvariablen im Quadrat zur Auflösung. Für großflächige Anwendungen sind daher Orthophotos mit 100 cm Auflösung trotz der etwas geringeren Klassifikationsgenauigkeiten gegenüber den höher auflösenden Daten oft zu bevorzugen.

Alle fünf getesteten Wavelets lieferten ähnlich gute Ergebnisse, wobei keine der fünf getesteten Wavelet-Familien besonders positiv hervorstach. Aus diesem Grund sind noch weitere Tests geplant, wobei auch noch nicht verwendete Wavelet-Familien einbezogen werden. Neben den Variablen und dem Klassifikationsverfahren wird vor allem den Objekten selbst ein wesentlicher Einfluss auf die Klassifikation zugeschrieben. Je homogener die Objekte bezüglich Größe und Form sind, desto aussagekräftiger werden auch die Texturmaße sein. Daher werden weitere Aktivitäten für die Optimierung der Segmentierung unternommen.

6 Danksagung

Die Arbeit wurde im Rahmen eines Projektes zwischen der Bayerischen Landesanstalt für Wald und Forstwirtschaft (LWF) und dem Institut für Vermessung, Fernerkundung und Landinformation (IVFL) der Universität für Bodenkultur Wien (BOKU) erstellt. Wir möchten uns bei Rudolf Seitz und Anna Kanold (LWF) für die bereitgestellten Daten

bedanken. Unser Dank geht auch an Tatjana Koukal, Reinfried Mansberger und Matteo Mattiuzzi für die gewährte technische und methodische Unterstützung.

Referenzen

- BAATZ, M. & SCHÄPE, A., 2000: Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. – STROBL, J., BLASCHKE, T. & GRIESEBNER, G. (Hrsg.): *Angewandte Geographische Informationsverarbeitung XII*: 12–23, Wichmann-Verlag, Heidelberg.
- 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): 293–304.
- BINNER, S. & SEITZ, R., 2009: Mit Fernerkundung und GIS zuverlässig und kostensparend FFH-Gebiete erfassen und bewerten. – *LWF aktuell* **69**: 17–19.
- BLASCHKE, T., 2010: Object based image analysis for remote sensing. – *ISPRS Journal of Photogrammetry and Remote Sensing* **65**: 2–16.
- BLASCHKE, T. & STROBL, J., 2001: What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. – *GIS – Zeitschrift für Geoinformationssysteme* **6** (14): 12–17.
- BREIMAN, L., 2001: Random forests. – *Machine learning* **45** (1): 5–32.
- BREIMAN, L., 2002: *Manual on Setting Up, Using, and Understanding Random Forests V3.1.* – http://oz.berkeley.edu/users/breiman/Using_random_forests_V3.1.pdf (3.5.2012).
- BUSCH, A. & BOLES, W., 2002: *Texture Classification Using Multiple Wavelet Analysis.* – *DICTA2002: Digital Image Computing Techniques and Applications*, Melbourne, Australia.
- CASTILLA, G. & HAY, G., 2008: Image objects and geographic objects. – BLASCHKE, T., LANG, S. & HAY, G. (Hrsg.): *Object Based Image Analysis*: 92–110.
- CHAN, J.C.-W. & PAELINCKX, D., 2008: Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. – *Remote Sensing of Environment* **112** (6): 2999–3011.
- VAN COILLIE, F.M.B., VERBEKE, L.P.C. & DE WULF, R.R., 2011: Wavelet-based texture measures for semicontinuous stand density estimation from very high resolution optical imagery. – *Journal of Applied Remote Sensing* **5** (1).

- DRĂGUT, L., TIEDE, D. & LEVICK, S.R., 2010: ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. – *International Journal of Geographical Information Science* **24** (6): 859–871.
- FRANKLIN, S.E., HALL, R.J., MOSKAL, L.M., MAUDIE, A.J. & LAVIGNE, M.B., 2000: Incorporating texture into classification of forest species composition from airborne multispectral images. – *International Journal of Remote Sensing* **21** (1): 61–79.
- GRAPS, A., 1995: An introduction to wavelets. – *IEEE Computational Science Engineering* **2** (2): 50–61.
- HARALICK, R.M., SHANMUGAM, K. & DINSTEN, I., 1973: Textural Features for Image Classification. – *IEEE Transactions on Systems, Man and Cybernetics* **3** (6): 610–621.
- HASTIE, T., TIBSHIRANI, R. & FRIEDMAN, J., 2009: *The elements of statistical learning: Data mining, inference, and prediction*. – 2. Auflage, 768 S., Springer, New York.
- HAY, G.J., CASTILLA, G., WULDER, M.A. & RUIZ, J.R., 2005: An automated object-based approach for the multiscale image segmentation of forest scenes. – *International Journal of Applied Earth Observation and Geoinformation* **7** (4): 339–359.
- IMMITZER, M., ATZBERGER, C. & KOUKAL, T., 2012a: Eignung von WorldView-2 Satellitenbildern für die Baumartenklassifizierung unter besonderer Berücksichtigung der vier neuen Spektralkanäle. – *PFG* **2012** (5): 573–588.
- IMMITZER, M., ATZBERGER, C. & KOUKAL, T., 2012b: Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. – *Remote Sensing* **4** (9): 2661–2693.
- IMMITZER, M., KOUKAL, T., KANOLD, A., SEITZ, R., MANSBERGER, R. & ATZBERGER, C., 2012c: Abgrenzung der Natura 2000 Waldflächen – Klassifikation von Wald, Offenland und Latschenfeldern im bayerischen Hochgebirge unter Verwendung digitaler Luftbild- und Laserscannerdaten. – *LWF aktuell* **88**: 49–51.
- JÄHNE, B., 2005: *Digitale Bildverarbeitung*. – Springer-Verlag Berlin, Heidelberg, New York.
- 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): 390–401.
- KROSCHEL, K., RIGOLL, G. & SCHULLER, B., 2011: *Statistische Informationstechnik: Signal - und Mustererkennung, Parameter- und Signalschätzung*. – Springer-Verlag Berlin, Heidelberg.
- LABERTE, 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): 761–770.
- LIAW, A. & WIENER, M., 2002: Classification and Regression by randomForest. – *R News* **2** (3): 18–22.
- LILLESAND, T.M., KIEFER, R.W. & CHIPMAN, J.W., 2004: *Remote sensing and image interpretation*. – Wiley, New York.
- LIVENS, S., SCHEUNDERS, P., VAN DE WOUWER, G. & VAN DYCK, D., 1997: Wavelets for texture analysis, an overview. – *Sixth International Conference on Image Processing and Its Applications 1997*: 581–585.
- LOUIS, A.K., MAASS, P. & RIEDER, A., 1998: *Wavelets: Theorie und Anwendungen*. – Teubner, Stuttgart.
- MATLAB, 2011: Version 7.13.0 (R2011b). – The MathWorks Inc., Natick, Ma, USA.
- METZLER, V., PALM, C., LEHMANN, T. & AACH, T., 2002: Texture classification of gray-level images by multiscale cross co-occurrence matrices. – *IEEE Computer Society*: 549–552.
- NASON, G.P. & SILVERMAN, B.W., 1995: The stationary wavelet transform and some statistical applications. – *Lecture Notes in Statistics*: 281–281.
- NICODEMUS, K.K., 2011: Letter to the editor: on the stability and ranking of predictors from random forest variable importance measures. – *Briefings in bioinformatics* **12** (4): 369–373.
- POLIKAR, R., 1999: The Wavelet Tutorial. – <http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html> (27.9.2012).
- R DEVELOPMENT CORE TEAM, 2012: *R: A language and environment for statistical computing*. – R Foundation for Statistical Computing, Vienna, Austria.
- RANDEN, T. & HUSØY, J., 1999: Filtering for Texture Classification: A Comparative Study. – *IEEE Transactions on Pattern Analysis and Machine Intelligence* **21** (4): 291–310.
- RENGERS, N. & PRINZ, T., 2009: JAVA-based Texture Analysis Employing Neighborhood Gray-Tone Difference Matrix (NGTDM) for Optimization of Land Use Classifications in High Resolution Remote Sensing Data. – *PFG* **2009** (5): 455–467.
- 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**: 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**: 93–104.
- RYHERD, S. & WOODCOCK, C., 1996: Combining spectral and texture data in the segmentation of remotely sensed images. – *Photogrammetric Engineering and Remote Sensing* **62** (2): 181–194.
- SCHLERF, M., HILL, J., BÄRISCH, S. & ATZBERGER, C., 2003: Einfluss der spektralen und räumlichen Auflösung von Fernerkundungsdaten bei der Nadelwaldklassifikation. – *PFG* **2003** (1): 25–34.
- 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): 565–593.
- SINGH, A., DUTTA, R., STEIN, A. & BHAGAT, R.M., 2012: A wavelet-based approach for monitoring plantation crops (tea: *Camellia sinensis*) in North East India. – *International Journal of Remote Sensing* **33** (16): 4982–5008.
- SOH, L.-K. & TSATSIOULIS, C., 1999: Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. – *IEEE Transactions on Geoscience and Remote Sensing* **37** (2): 780–795.
- STUMPF, A. & KERLE, N., 2011: Object-oriented mapping of landslides using Random Forests. – *Remote Sensing of Environment* **115**: 2564–2577.
- 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**: 553–562.
- WASER, L.T., KLONUS, S., EHLERS, M., KÜCHLER, M. & JUNG, A., 2010: Potential of digital sensors for land cover and tree species classifications – A case study in the framework of the DGPF-project. – *PFG* **2010** (2): 141–156.
- WASKE, B. & BRAUN, M., 2009: Classifier ensembles for land cover mapping using multitemporal SAR imagery. – *ISPRS Journal of Photogrammetry and Remote Sensing* **64** (5): 450–457.
- WULDER, M.A., LEDREW, E.F., FRANKLIN, S.E. & LAVIGNE, M.B., 1998: Aerial Image Texture Information in the Estimation of Northern Deciduous and Mixed Wood Forest Leaf Area Index (LAI). – *Remote Sensing of Environment* **64** (1): 64–76.
- ZHU, C. & YANG, X., 1998: Study of remote sensing image texture analysis and classification using wavelet. – *International Journal of Remote Sensing* **19** (16): 3197–3203.

Adresse der Autoren:

PHILIPP TOSCANI, MARKUS IMMITZER & Dr. CLEMENT ATZBERGER, Universität für Bodenkultur, Institut für Vermessung, Fernerkundung und Landinformation, Peter-Jordan-Straße 82, A-1190 Wien, Tel: +43-1-47654-5100, Fax: +43-1-47654-5142, e-mail: {philipp.toscani}{markus.immitzer}{clement.atzberger}@boku.ac.at

Manuskript eingereicht: November 2012

Angenommen: Januar 2013