



Eignung von WorldView-2 Satellitenbildern für die Baumartenklassifizierung unter besonderer Berücksichtigung der vier neuen Spektralkanäle

MARKUS IMMITZER, CLEMENT ATZBERGER & TATJANA KOUKAL, Wien, Österreich

Keywords: tree species, classification, temperate forest, WorldView-2, linear discriminant analysis

Summary: *Suitability of WorldView-2 data for tree species classification with special emphasis on the four new spectral bands.* There is an increasing demand for information on tree species composition and spatial distribution. Detailed tree species maps are essential for addressing different ecological problems. Moreover, they are important in modern forest management as close to nature forest management is becoming more and more common. This study examines the potential of 8-band WorldView-2 data with 2 m ground sample distance (GSD) for identifying 10 tree species in a mid-European forest. We delineated well-illuminated tree crowns manually and did a supervised classification using linear discriminant analysis (LDA) implemented in a bootstrapping environment (1465 observations, 500 bootstrap samples). The overall accuracy for the 10 tree species was around 84 % (8 bands) with class-specific producer's accuracies ranging between 54 % (*Carpinus betulus*) and 96 % (*Fagus sylvatica*). In general, the accuracy was higher for the 5 deciduous tree species (89 %) than for the 5 coniferous tree species (79 %). The classification accuracies decreased significantly, if only the 4 conventional bands Blue, Green, Red, and Near Infrared 1 were used (78 % overall accuracy). However, when the classification focused only on the 4 main tree species in the investigation area, i.e. *Picea abies*, *Pinus sylvestris*, *Fagus sylvatica*, *Quercus robur*, the 4 conventional bands were sufficient to achieve high classification accuracies (95 % overall accuracy). Adding the 4 new bands (Coastal, Yellow, Red Edge, Near Infrared 2) to the input feature set did not further improve the overall classification accuracy for these 4 main tree species. Hence, the positive impact of the additional 4 new bands resulted from strongly increased classification accuracies of the 6 secondary tree species. Green and Near Infrared 1 (conventional bands) as well as the bands Red Edge and Near Infrared 2 (new bands) contributed most to class separability (according to Wilks' Lambda).

Zusammenfassung: Informationen über die Baumartenzusammensetzung und -verteilung werden vermehrt nachgefragt. Detaillierte Baumartenkarten sind beispielsweise bei vielen ökologischen Fragestellungen unverzichtbar, stellen aber auch in der forstlichen Praxis aufgrund der mehr und mehr praktizierten naturnahen Waldbewirtschaftung eine wichtige Datengrundlage dar. In dieser Studie wird das Potenzial der 8-Band WorldView-2 Daten mit einer Bodenauflösung von 2 m für die Unterscheidung von 10 Baumarten in einem mitteleuropäischen Testgebiet untersucht. Dazu wurden gut beleuchtete Teile von Baumkronen manuell abgegrenzt und mit Hilfe der Linearen Diskriminanzanalyse (LDA) klassifiziert. Durch Bootstrapping (1465 Referenzflächen, 500 Wiederholungen) wurde für die 10 Baumarten eine Gesamtgenauigkeit von 84 % ermittelt (8 Kanäle). Die Ergebnisse variierten von Baumart zu Baumart zum Teil beträchtlich (Produzentengenauigkeit bei Hainbuche 54 % und bei Buche 96 %). Generell lag die Klassifikationsgenauigkeit bei den 5 Laubbaumarten höher (89 %) als bei den 5 Nadelbaumarten (79 %). Die Klassifikationsgenauigkeiten nahmen deutlich ab, wenn nur die 4 konventionellen Spektralkanäle Blue, Green, Red und Near Infrared 1 verwendet wurden (78 % Gesamtgenauigkeit). Wurden jedoch lediglich die 4 Hauptbaumarten kartiert (Fichte, Kiefer, Buche und Eiche), konnte bereits mit den 4 konventionellen Kanälen eine hohe Gesamtgenauigkeit erzielt werden (95 %). Für die 4 Hauptbaumarten konnte durch die zusätzliche Verwendung der 4 neuen Kanäle (Coastal, Yellow, Red Edge, Near Infrared 2) keine Steigerung der Klassifikationsgenauigkeit erzielt werden. Der positive Einfluss der 4 zusätzlichen Kanäle ist dagegen bei den 6 Nebenbaumarten stark ausgeprägt. Die Untersuchung der Trennkraft der einzelnen Kanäle ergab, dass von den 4 konventionellen Kanälen Green und Near Infrared 1 am meisten zur Trennung der Klassen beitragen und von den 4 neuen Kanälen Red Edge und Near Infrared 2 (Wilks' Lambda).

1 Einleitung

Die Identifikation und Kartierung von Baumarten stellt eine Aufgabe dar, die sowohl forstwirtschaftlich als auch ökologisch von großer Relevanz ist. Die Baumartenzusammensetzung sowie die räumliche Verteilung verschiedener Baumarten sind beispielsweise wesentliche Eingangsparameter bei Habitatmodellierungen zur Beschreibung der Artenbiodiversität und für Monitoringzwecke. Aber auch in der forstlichen Planung sind baumartenbezogene Aussagen unverzichtbar (WULDER et al. 2004, McDERMID et al. 2009). Gerade die zunehmende naturnahe Bewirtschaftung erhöht den Aufwand der Baumartenerkennung, da großflächige Monokulturen in strukturierte, gemischte Bestände mit kleinflächigen Nutzungen übergeführt werden. Die traditionellen, rein terrestrischen Methoden der Datenerfassung wie Stichprobeninventur und Taxation liefern lediglich punktuelle Informationen. Diese können zwar auf die Fläche hochgerechnet werden, ermöglichen aber keine detaillierte flächenhafte Darstellung. Dies ist besonders bei baumartenreichen Wäldern oftmals unzureichend.

Der Einsatz von Fernerkundungsmethoden kann einen wesentlichen Beitrag zur Beseitigung von forstlichen Informationsdefiziten leisten (HILDEBRANDT 1996, OLSSON et al. 2008, FALKOWSKI et al. 2009). So können bei der visuellen Stereointerpretation von Farbinfrarot-Luftbildern, u.a. durch die charakteristische Farbe, Kronenform und -struktur, Baumarten generell sehr gut erfasst werden (ALBERTZ 2009). Eine großflächige Anwendung scheitert dabei aber meist an der zeitaufwändigen Bearbeitung und den damit verbundenen hohen Kosten. Die automatisierte Baumartenkartierung stellt daher einen aktuellen Forschungsschwerpunkt der forstlichen Fernerkundung dar (BROSINGER 2010, BUCK et al. 2010). Dabei weisen die zur Verfügung stehenden Sensoren systemspezifische Vor- und Nachteile auf: Digitale Orthophotos bieten zwar eine hohe räumliche Auflösung bei geringen Erstellungskosten, sind jedoch auf die Spektralkanäle Blau, Grün, Rot und Nahes Infrarot beschränkt. Die über das Bild gesehen stark variierende Aufnahme- und die daraus ableitbare Information über

das richtungsabhängige Reflexionsverhalten kann zwar prinzipiell in einer Klassifizierung genutzt werden (HEIKKINEN et al. 2011, KOUKAL & ATZBERGER 2012). Da diese direktionalen Effekte im Zuge der Bildauswertung üblicherweise jedoch nicht berücksichtigt werden, stellen sie in den meisten Anwendungen eher eine Fehlerquelle dar. Satellitengestützt stehen sowohl multi- als auch hyperspektrale Sensoren zur Verfügung, jedoch bei meist geringerer räumlicher Auflösung als bei Luftbilddaten. Die geringe räumliche Auflösung verhindert eine einzelbaumweise Erfassung und die resultierenden Mischpixel erschweren eine korrekte Identifizierung der Baumarten (SCHLERF et al. 2003). Dem hohen spektralen Informationsgehalt von Hyperspektraldaten steht die meist eher geringe Verfügbarkeit bei hohen Kosten gegenüber.

Mit WorldView-2 steht seit 2010 ein satellitengestützter Sensor zur Verfügung, der durch die hohe räumliche Auflösung sowie durch 4 neue Spektralkanäle ein hohes Potenzial für die Untersuchung von Vegetation aufweist (siehe Kapitel 2). Erste Ergebnisse über die Verwendung dieser Daten zur Ermittlung forstlicher Strukturparameter wurden bereits veröffentlicht (HUANG & CAO 2011, OZDEMIR & KARNIELI 2011). In einer Überblicksstudie bewerteten MARCHISIO et al. (2010) die Steigerung der Klassifikationsgenauigkeit durch die erstmals verfügbaren Kanäle (Coastal, Yellow, Red Edge und Near Infrared 2) gegenüber traditionellen 4-Kanal-Bildern von Sensoren mit vergleichbarer räumlicher Auflösung. Die Klassifikationsergebnisse konnten um 5 bis 20 % erhöht werden. Auch COLLIN & PLANES (2011) erzielten durch die 4 zusätzlichen Kanäle eine Steigerung der Klassifikationsgenauigkeiten. Weitere Arbeiten mit WorldView-2 Daten wurden im Zuge der von DigitalGlobe ausgeschriebenen „8-Band Challenge“ publiziert. Darunter finden sich auch einige Studien, die sich mit dem Themenkomplex der „Baumartenerkennung“ beschäftigten: CHEN (2011) konnte bei der Baumartenidentifizierung auf Hawaii mit WorldView-2 Bildern deutlich höhere Genauigkeiten erzielen als mit IKONOS Daten. HAMDAN (2010) erreichte bei der Klassifikation von 10 tropischen Baumarten in Malaysia sehr gute Ergebnisse. SRIDHARAN (2011) klassifizierte

urbane Wälder in Texas auf mehreren Detaillierungsstufen bis hinunter aufs Artenniveau und erreichte nur geringfügig geringere Klassifikationsgenauigkeiten als mit AISA Hyperspektraldaten.

Der Einsatz von WorldView-2 für forstliche Fragestellungen ist auf Grund der hohen räumlichen Auflösung von 0,5 m (panchromatisch) bzw. 2 m (multispektral), der zusätzlichen 4 Kanäle und der raschen Verfügbarkeit der Daten eine interessante Alternative zu Orthophotos. Für mitteleuropäische Wälder sind derzeit jedoch noch kaum Untersuchungen publiziert. In dieser Studie werden daher die forstlichen Einsatzmöglichkeiten von WorldView-2 Daten im Bereich der Baumartenerkennung in einem mitteleuropäischen Waldgebiet untersucht. Folgende Fragen stehen im Mittelpunkt: (1) Welche Baumarten können auf Grund der spektralen Information aus WorldView-2 Daten unterschieden werden, (2) welchen Mehrwert haben die 4 neuen Kanäle im Vergleich zur alleinigen Verwendung der 4 konventionellen Kanäle, und (3) welche der insgesamt 8 Kanäle tragen am meisten zur Baumartenunterscheidung bei?

Für die Beantwortung dieser Fragen werden die Reflexionswerte in den multispektralen Kanälen mit 2 m Pixelgröße von manuell abgegrenzten, beleuchteten Kronenteilen verwendet. Zur Baumartenklassifikation und Bestimmung der spektralen Trennkraft wurde die Lineare Diskriminanzanalyse (LDA) verwendet.

2 Daten und Methodik

2.1 Untersuchungsgebiet

Das Untersuchungsgebiet befindet sich im Osten Österreichs (Burgenland, Bezirk Oberpullendorf) und ist durch hügelige Landschaft geprägt. Mit Seehöhen von 290 bis 670 m über NN liegt es in der submontanen bis tiefmontanen Höhenstufe des forstlichen Wuchsgebiets 5.2 „Bucklige Welt“. Der Jahresniederschlag liegt, mit einem sommerlichen Maximum, zwischen 700 und 1100 mm. Die Grundgesteine sind vor allem basenarme Silikate, Gneis und Quarzphyllit. Die potentielle natürliche Waldgesellschaft reicht vom Eichen -

Hainbuchenwald über sauren Weiß-Kiefern - Eichenwald bis hin zum Tannen - Buchenwald mit Beimischungen von Eichen, Edelkastanie und Weiß-Kiefer (KILIAN et al. 1994).

Das Untersuchungsgebiet umfasst eine Fläche von knapp 3000 ha, auf welchen die beiden Nadelhölzer Gemeine Fichte (*Picea abies*, (L.) Karst.) und Weiß-Kiefer (*Pinus sylvestris*, L.) gemeinsam mit den beiden Laubhölzern Rot-Buche (*Fagus sylvatica*, L.) und Stiel-Eiche (*Quercus robur*, L.) die Hauptbaumarten darstellen. Weiters kommen die Baumarten Weiß-Tanne (*Abies alba*, Mill.), Europäische Lärche (*Larix decidua*, Mill.), Douglasie (*Pseudotsuga menziesii*, (Mirb.) Franco), Scheinzypresse (*Chamaecyparis lawsoniana* (A.Murr.) Parl.), Riesen-Tanne (*Abies grandis*, Lindl), Gelb-Kiefer (*Pinus ponderosa*, Douglas ex P. et C.Laws), sowie Gemeine Esche (*Fraxinus excelsior*, L.), Hainbuche (*Carpinus betulus*, L.), Zerleiche (*Quercus cerris*, L.), Weiß-Birke (*Betula pendula*, Roth), Schwarz-Erle (*Alnus glutinosa*, L.), Wal-Nuss (*Juglans regia*, L.), Robinie (*Robinia pseudoacacia*, L.), Edelkastanie (*Castanea sativa*, Mill.), Vogel-Kirsche (*Prunus avium*, L.), Linden- (*Tilia* sp.), Ahorn- (*Acer* sp.), Ulmen- (*Ulmus* sp.) und Pappel-Arten (*Populus* sp.) vor.

2.2 WorldView-2 Daten

Der WorldView-2 Satellit liefert seit Anfang 2010 räumlich hochauflösende Daten

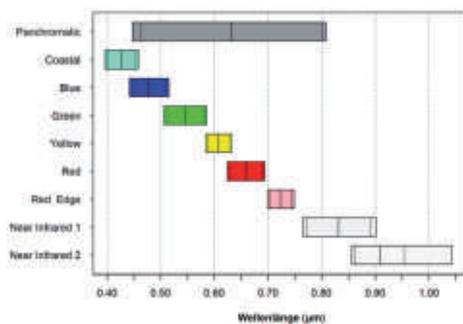


Abb. 1: Lage und Bandbreite der 8 Farbkkanäle und des panchromatischen Kanals des WorldView-2 Sensors sowie Bandbreite (gestrichelt) und mittlere Wellenlänge (durchgezogen) bei 50 % der maximalen Sensitivität (UPDIKE & COMP 2010).

in 8 Spektralkanälen (Abb. 1). Bei senkrechter Aufnahmerichtung beträgt die Bodenauf­lösung des panchromatischen Kanals 50 cm und die der multispektralen Kanäle 200 cm. Zusätzlich zu den 4 üblichen Kanälen Blue, Green, Red und Near Infrared 1 stehen 4 weitere Kanäle, Coastal, Yellow, Red Edge und Near Infrared 2, zur Verfügung, für welche vom Anbieter ein großes Potenzial für vegetationskundliche Fragestellungen postuliert wird (DIGITALGLOBE 2009).

Die verwendete WorldView-2 Szene wurde am 10. Juli 2010 aufgenommen und deckt eine Fläche von 7500 ha ab (Scandirection: forward, Mean Satellite Elevation: 77,8°, Mean Satellite Azimuth: 76,6°, Mean Off Nadir View Angle: 11°).

Zur radiometrischen und atmosphärischen Korrektur der Aufnahme wurden zunächst die Pixelgrauwerte in „at-sensor“ Strahldichten umgerechnet (UPDIKE & COMP 2010). Anschließend wurde das Bild mit Hilfe des ENVI-Moduls (ENVI 4.8) FLAASH atmosphärisch korrigiert. Die Einstellungen wurden dabei iterativ durch Plausibilitätsprüfung der resultierenden Reflexionswerte eruiert. Für das Pansharpning wurde der speziell für WorldView-2 Daten entwickelte und in ERDAS Imagine 2010 verfügbare HCS-Algorithmus (Hyperspherical Colour Space Algorithmus) angewendet, welcher die Einbeziehung aller 8 Kanäle ermöglicht (PADWICK et al. 2010). Die Georektifizierung wurde mittels ERDAS (Control Points) unter Verwendung eines Digitalen Geländemodells (5 m × 5 m Raster) vorgenommen. Die Passpunktkoordinaten stammten aus einem Farbinfrarot-Orthophoto (Aufnahmejahr 2007, Pixelgröße 0,5 m). Die erreichte mittlere Lagegenauigkeit (RMSE) lag im 2 m Bild bei 0,70 Pixel (x: 0,50, y: 0,47).

2.3 Auswahl von Referenzflächen

Zur Auswahl von Referenzflächen wurde eine digitale Bestandeskarte herangezogen. Diese enthält verschiedenste Bestandesattribute, die im Zuge der Forsteinrichtung durch Taxation und Stichprobeninventur erhoben wurden. Die Taxation dient der bestandesweisen Zustandserhebung. Dabei werden in den einzelnen Beständen durch Winkelzählproben die Baumartenanteile und Vorräte ermittelt. Auf Grund der üblichen Mindestgröße von 0,5 ha können aber durchaus auch, bezüglich Aufbau, Struktur und Baumarten, uneinheitliche Waldteile in Beständen zusammengefasst sein. Dadurch ist eine direkte Umlegung der Taxationsdaten auf die gesamte Bestandesfläche nicht ohne Weiteres möglich.

Ausgehend von den angegebenen Baumartenanteilen wurden möglichst reine Bestände sowie Bestände mit eindeutig identifizierbaren Baumarten ausgewählt. Durch visuelle Interpretation wurden die Taxationsangaben auf Plausibilität überprüft und anschließend Beispielbäume ausgewählt. Dabei wurde auf eine gute Verteilung der ausgewählten Bestände über das Untersuchungsgebiet und die Erfassung verschiedener Altersklassen geachtet. Um Beschattungs- und Beleuchtungseinflüsse zu minimieren, wurden nur die gut beleuchteten Baumkronen(-teile) verwendet (CLARK et al. 2005, LECKIE et al. 2005b, GREENBERG et al. 2006).

Die Auswahl der Beispielkronen erfolgte auf Basis des Bildes mit 0,5 m Pixelgröße (pansharpned) auf Grund der Taxationsdaten ohne visuelle Vorinterpretation (Abb. 2). Gut beleuchtete Kronenbereiche, die möglichst sicher einer Baumart zuzuordnen waren, wurden anschließend im Bild mit 2 m Pixelgröße

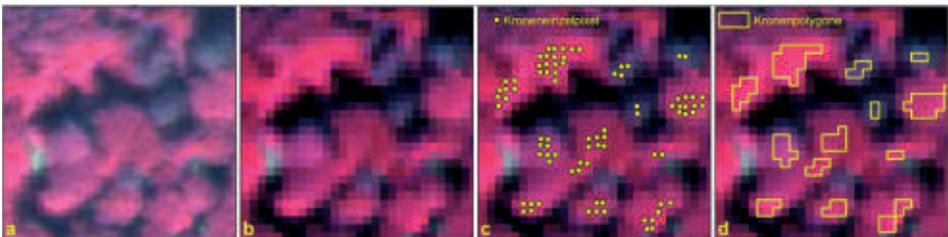


Abb. 2: Auswahl beleuchteter Baumkronen(-teile) als Referenzflächen: Baumkronen a) im Bild mit 0,5 m Pixelgröße, b) im Bild mit 2 m Pixelgröße, c) Auswahl der Kronenpixel durch Punktsetzung, d) Referenzpolygone entsprechend den pixelweise ausgewählten Kronenteilen.

aufgesucht und durch pixelweises Setzen von Punkten (Shapefile) markiert. Den Punkten wurden die wesentlichen Attribute wie Baumart und Alter aus den Forsteinrichtungsdaten zugeordnet. Punkte in benachbarten Rasterzellen wurden anschließend zu Polygonen zusammengefügt und in eine Vektordatei (Polygon-Shapefile) konvertiert. Dieser Datensatz wurde schließlich für das Auslesen der Spektralinformationen aus dem WorldView-2 Bild herangezogen. Für jede Referenzfläche wurden die Mittelwerte pro Kanal ausgelesen.

Neben den 4 Hauptbaumarten Gemeine Fichte, Weiß-Kiefer, Rot-Buche und Stiel-Eiche konnten auch Bestände mit den Baumarten Europäische Lärche, Douglasie, Scheinzypresse, Hainbuche, Weiß-Birke und Schwarz-Erle eindeutig identifiziert werden. Diese 6 Nebenbaumarten wurden ebenfalls in die Analysen aufgenommen. Weitere Baumarten konnten nicht berücksichtigt werden, da nicht genügend Individuen eindeutig identifiziert werden konnten.

Für die 10 untersuchten Baumarten sind in Tab. 1 Angaben über die Anzahl der Referenzflächen und Flächenanteile aufgeführt. Insgesamt wurden 1465 Referenzflächen generiert. Die unterschiedlichen Anteile spiegeln ungefähr die relativen Flächenverhältnisse vor Ort wider.

2.4 Spektrale Trennbarkeit und Klassifikation der Baumarten

Für die Auswertung wurden die spektralen Mittelwerte der einzelnen Referenzpolygone verwendet. Die Analyse und Visualisierung der Daten erfolgte mit dem Statistikprogramm R 2.14.1 (R DEVELOPMENT CORE TEAM 2011) mit den Zusatzpaketen MASS (VENABLES & RIPLEY 2002) und scatterplot3d (LIGGES & MÄCHLER 2003). Die Baumartenklassifizierung erfolgte mit Hilfe der Linearen Diskriminanzanalyse (LDA). Die LDA ist ein strukturprüfendes Verfahren, welches die Abhängigkeit der Gruppenzugehörigkeit (nominal skaliert) von den metrisch skalierten Merkmalsvariablen prüft. Dabei werden durch Linearkombinationen der Merkmalsvariablen sogenannte Diskriminanzfunktionen erstellt. Deren Eigenwerte beschreiben den Anteil der durch diese Funktionen erklärten Varianz. Die Trennkraft der einzelnen Kanäle wurde sowohl univariat (ANOVA, Wilks' Lambda) als auch multivariat (standardisierte mittlere Diskriminanzkoeffizienten) beurteilt (BACKHAUS et al. 2008).

Die Klassifikationsgenauigkeiten wurden durch Bootstrapping (EFRON & TIBSHIRANI 1993) ermittelt. Dabei wird durch das zufällige Ziehen mit Zurücklegen ein Trainingsdatensatz der Größe der Stichprobe gewonnen. Jene Beispieldaten, die nicht im Trainingsdatensatz enthalten sind (ca. 36,8 % der Daten), verbleiben als unabhängiger Testdatensatz.

Tab. 1: Verteilung der Referenzflächen auf die 10 untersuchten Baumarten (getrennt in Nadel- und Laubholz und gereiht nach der forstlichen Bedeutung).

Baumart	Wissenschaftliche Bezeichnung	Abkürzung	Anzahl Pixel	Anzahl Referenzflächen	Anteil (%)
Gemeine Fichte	<i>Picea abies</i>	Fi	1084	226	15,4
Weiß-Kiefer	<i>Pinus sylvestris</i>	Ki	807	235	16,0
Europäische Lärche	<i>Larix decidua</i>	Lä	472	122	8,3
Douglasie	<i>Pseudotsuga menziesii</i>	Dgl	677	178	12,1
Scheinzypresse	<i>Chamaecyparis lawsoniana</i>	SZy	166	42	2,9
Rot-Buche	<i>Fagus sylvatica</i>	Bu	1519	247	16,9
Stiel-Eiche	<i>Quercus robur</i>	Ei	1770	152	10,4
Hainbuche	<i>Carpinus betulus</i>	HBu	445	81	5,5
Weiß-Birke	<i>Betula pendula</i>	Bi	397	86	5,9
Schwarz-Erle	<i>Alnus glutinosa</i>	SEr	387	96	6,6
		Summe	7724	1465	100,0

Die Anzahl der Bootstrap-Stichproben betrug in unserer Studie 500, wobei die zufällige Referenzflächenauswahl entsprechend der jeweiligen Anzahl an Referenzflächen pro Klasse stratifiziert erfolgte.

Die Analyse der Klassifikationsergebnisse der einzelnen Baumarten erfolgte durch die Erstellung von Klassifikationsmatrizen (CONGALTON & GREEN 1999). Im Zuge der 500 Bootstrap-Stichproben wurde jede Referenzfläche mehrmals klassifiziert. Für die Klassifikationsmatrizen wurde für jede Referenzfläche die am häufigsten klassifizierte Klasse (Modalwert) verwendet. Der Vergleich von Ergebnissen unterschiedlicher Methoden bzw. Datengrundlagen erfolgte über den Mittelwert der Gesamtgenauigkeiten aus den einzelnen Bootstrap-Wiederholungen.

2.5 Flächige Anwendung auf Testfläche

Für die flächige Anwendung der Klassifizierung wurde im Untersuchungsgebiet eine Testfläche mit großer Baumartenvielfalt ausgewählt. Innerhalb dieser Testfläche wurden alle Baumkronen abgegrenzt, wobei die Abgrenzung wie bei den Referenzflächen erfolgte (Abb. 2). Zur Plausibilitätsprüfung der Klassifizierungsergebnisse standen Taxationsdaten zur Verfügung. Obwohl die Taxati-

on keine absolut zuverlässige Referenzinformation für die gesamte Fläche im Sinne einer Vollaufnahme darstellt, kann diese Information dennoch für eine näherungsweise Beurteilung der Klassifikationsergebnisse verwendet werden.

3 Ergebnisse

3.1 Spektrale Signaturen

In Abb. 3 sind die gemittelten Spektralsignaturen über alle Referenzpolygone einer Baumart dargestellt. Der Vergleich der spektralen Signaturen zeigt wie erwartet bei den Laubhölzern deutlich höhere Reflexionswerte im nahen Infrarot als bei den Nadelhölzern, wobei die Rot-Buche, gefolgt von der Hainbuche, die höchsten Werte aufweist. Zwischen Stiel-Eiche, Weiß-Birke und Schwarz-Erle sind im nahen Infrarot nur geringe Unterschiede erkennbar. Bei den Nadelhölzern zeigt die Scheinzypresse die höchsten Reflexionswerte im nahen Infrarot. Mit abnehmenden Reflexionsgraden folgen Douglasie, Europäische Lärche, Weiß-Kiefer und Gemeine Fichte. Der Detailausschnitt für den Wellenlängenbereich des sichtbaren Lichts zeigt, dass die Unterschiede zwischen den Baumarten in den Kanälen Green und Yellow am größten sind. Eine eindeutige Differenzierung zwischen Laub-

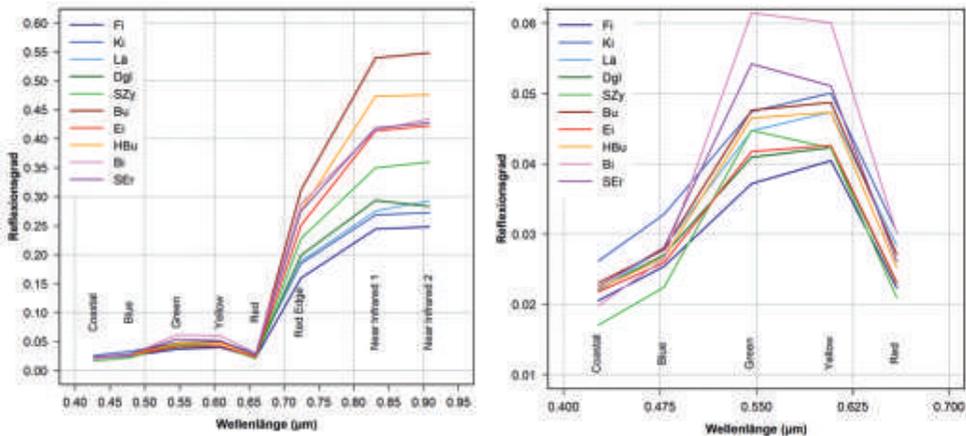


Abb. 3: Mittlere spektrale Signaturen der 10 untersuchten Baumarten über alle Referenzpolygone, links: gesamter Wellenlängenbereich, rechts: Detailansicht im Bereich des sichtbaren Lichts.

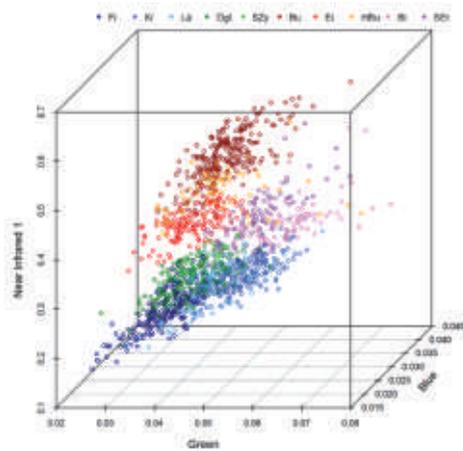


Abb. 4: Verteilung der Referenzflächen der untersuchten Baumarten in den Kanälen Blue, Green und Near Infrared 1.

und Nadelbäumen ist hier jedoch nicht möglich. Die Ergebnisse entsprechen typischen Signaturen für Laub- und Nadelbäume, wie sie auch in der Literatur beschrieben werden (KADRO 1981, HOSGOOD et al. 1994, JONES et al. 2010).

In Abb.4 sind die Reflexionswerte aller Referenzflächen in den Kanälen Blue, Green und Near Infrared 1 dargestellt. Dies erlaubt einerseits Rückschlüsse auf die Trennbarkeit der Baumarten und zeigt andererseits auch die Streuungen innerhalb der Baumarten sowie die baumartenspezifischen Korrelationen zwischen den 3 Spektralkanälen. Während die Trennung in Nadel- und Laubbäume anhand dieses Streudiagramms noch relativ gut möglich ist, überlagern sich die Punktwolken der einzelnen Baumarten innerhalb dieser zwei Gruppen teilweise sehr stark.

3.2 Lineare Diskriminanzanalyse (LDA)

Für die LDA wurden alle 8 Kanäle verwendet, da laut univariater ANOVA alle Spektralkanäle die 10 Baumarten höchst signifikant (F-Test, $P < 0,01$) trennen. Die erstellten 8 Diskriminanzfunktionen wurden ebenfalls auf ihre Trennkraft untersucht. Dabei wurde festgestellt, dass alle Funktionen einen signifikan-

ten Beitrag zur Trennung liefern (Chi²-Test, $P < 0,05$). Auch wenn die höchste Trennkraft bei der Verwendung aller Funktionen erzielt wurde, nahmen die Eigenwerte der einzelnen Funktionen von der ersten zur achten Diskriminanzfunktion stark ab. So trug die erste Funktion bereits 75,6 % der Varianz; die zweite trug 14,0 %, die dritte 6,6 % und die vierte 2,7 % zur Erklärung der Varianz bei. Die Anteile der anderen 4 Funktionen lagen unter 1 %.

Zur Veranschaulichung der Trennkraft der ersten 4 Diskriminanzfunktionen sind in Abb.5 Streudiagramme von jeweils 2 Funktionen sowie die dazugehörigen univariaten Dichteverteilungen dargestellt, welche für jede Baumart die Streuung in der jeweiligen Funktion zeigen. Die Abbildung macht ersichtlich, dass durch die Kombination der ersten beiden Funktionen bereits eine deutliche Trennung der Nadel- von den Laubbäumen erzielt wird. Aber auch innerhalb der Laubbäume sind die einzelnen Baumarten als gut trennbare Gruppen erkennbar, wobei sich Schwarz-Erle und Weiß-Birke von den anderen 3 Baumarten deutlicher absetzen. Die Kombinationen der ersten mit der dritten und in geringerem Maße auch mit der vierten Diskriminanzfunktion separieren dann auch die Arten innerhalb der Gruppe der Nadelbäume besser.

3.3 Klassifikationsergebnisse

Das durch Bootstrapping ermittelte Klassifikationsergebnis bei Verwendung aller 8 Kanäle ist in Form einer Klassifikationsmatrix in Tab.2 dargestellt. Über alle 10 Baumarten konnten 83,7 % der 1465 Referenzflächen richtig klassifiziert werden (Kappa: 0,814). Die Trennung zwischen Nadel- und Laubbäumen erfolgte zu 99,1 % richtig. Innerhalb der Nadelbäume sind 79,3 % der Referenzflächen richtig klassifiziert. Die häufigsten Fehlklassifikationen finden sich zwischen Douglasien und Fichten (16,3 %) und zwischen Lärchen und Kiefern (16,4 %) bzw. Fichten (15,8 %). Mit 64,8 % weist die Lärche die geringste Produzentengenauigkeit der Nadelbäume auf, während die Kiefer mit 87,2 % die höchste Produzentengenauigkeit zeigt.

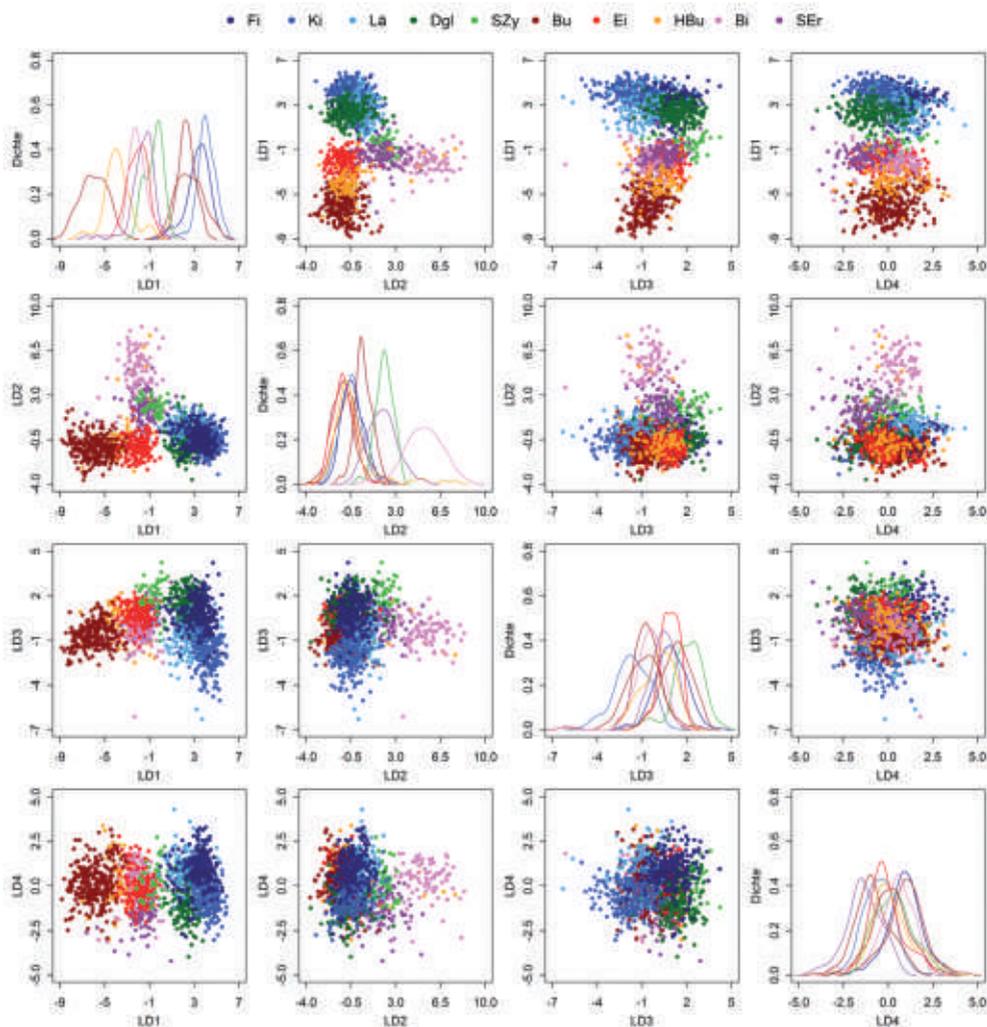


Abb. 5: Streudiagramme der ersten 4 Diskriminanzfunktionen (LD1 bis LD4) zur Visualisierung der Trennkraft der einzelnen Funktionen sowie die zugehörigen Dichtefunktionen für die 10 Baumarten.

Die 662 Referenzflächen der Laubbaumarten werden zu 89,0 % richtig klassifiziert. Die häufigsten Fehlklassifikationen bei Laubbäumen sind bei Hainbuche zu beobachten. Das beste Klassifikationsergebnis zeigt die Buche, die mit 96,0 % die höchste Produzenten- und mit 91,9 % gemeinsam mit Birke (92,0 %) auch die höchste Nutzergenauigkeit aller Baumarten aufweist.

Werden für die Analysen nur die 4 konventionellen Kanäle verwendet, zeigt sich über

beinahe alle Baumarten eine deutliche Verschlechterung der Produzenten- und Nutzergenauigkeiten (Tab. 3). Unverändert bleiben dagegen die sehr geringen Fehlklassifikationen zwischen Nadel- und Laubbäumen (<1 %). Der Anstieg der Fehlerraten beschränkt sich somit auf die bereits erläuterten Verwechslungen innerhalb der Nadel- bzw. Laubhölzer. Am deutlichsten zeigt sich die Verschlechterung bei Hainbuche: konnten mit 8 Kanälen noch 44 von den 81 Referenzflächen richtig

Tab. 2: Klassifikationsmatrix für die Klassifikation mit 8 Kanälen (Modalwerte aus 500 Bootstrap-Wiederholungen, PG = Produzentengenauigkeit, NG = Nutzergenauigkeit).

	Referenz											Σ	NG
	Fi	Ki	Lä	Dgl	SZy	Bu	Ei	HBu	Bi	SEr			
Klassifiziert als	Fi	183	17	19	29	0	0	0	0	0	0	248	0,738
	Ki	12	205	20	8	0	0	0	0	0	0	245	0,837
	Lä	13	11	79	5	2	0	0	0	0	0	110	0,718
	Dgl	17	2	3	136	0	0	0	0	0	1	159	0,855
	SZy	0	0	0	0	34	0	0	0	1	3	38	0,895
	Bu	0	0	0	0	0	237	0	18	1	2	258	0,919
	Ei	1	0	1	0	0	1	144	10	0	4	161	0,894
	HBu	0	0	0	0	0	9	4	44	1	0	58	0,759
	Bi	0	0	0	0	0	0	0	5	80	2	87	0,920
	SEr	0	0	0	0	6	0	4	4	3	84	101	0,832
	Σ	226	235	122	178	42	247	152	81	86	96	1465	
PG	0,810	0,872	0,648	0,764	0,810	0,960	0,947	0,543	0,930	0,875		0,837	

Tab. 3: Klassifikationsmatrix für die Klassifikation mit den 4 konventionellen Kanälen Blue, Green, Red, NearInfrared1 (Modalwerte aus 500 Bootstrap-Wiederholungen, PG=Produzentengenauigkeit, NG=Nutzergenauigkeit).

	Referenz											Σ	NG
	Fi	Ki	Lä	Dgl	SZy	Bu	Ei	HBu	Bi	SEr			
Klassifiziert als	Fi	167	12	19	33	0	0	0	0	0	0	231	0,723
	Ki	12	205	22	10	0	0	0	0	0	0	249	0,823
	Lä	10	14	72	11	1	0	0	1	0	0	109	0,661
	Dgl	36	4	8	120	0	0	0	0	0	0	168	0,714
	SZy	1	0	0	3	37	0	0	0	1	4	46	0,804
	Bu	0	0	0	0	0	228	0	32	0	2	262	0,870
	Ei	0	0	1	0	0	1	143	18	0	3	166	0,861
	HBu	0	0	0	0	0	18	6	21	1	0	46	0,457
	Bi	0	0	0	0	0	0	0	5	75	6	86	0,872
	SEr	0	0	0	1	4	0	3	4	9	81	102	0,794
	Σ	226	235	122	178	42	247	152	81	86	96	1465	
PG	0,739	0,872	0,590	0,674	0,881	0,923	0,941	0,259	0,872	0,844		0,784	

klassifiziert werden, waren es mit 4 Kanälen nur noch 21. Auch bei Fichte ist ein deutlicher Anstieg der fälschlich als Douglasien klassifizierten Referenzflächen zu beobachten (36 Fälle bei 4 Kanälen gegenüber 17 bei 8 Kanälen).

Eine Zusammenfassung aller Ergebnisse ist in Tab. 4 dargestellt. Die Genauigkeitsmaße aus den oben angeführten Klassifikationsmatrizen werden ergänzt durch die Klassifikationsergebnisse für die Trennung der 4 Hauptbaumarten Gemeine Fichte, Weiß-Kiefer, Rot-Buche und Stiel-Eiche (im Vergleich zu den insgesamt 10 Baumarten). Außerdem werden die Mittelwerte (MW) der Gesamtgenauigkeiten und deren Standardabweichungen (SD) aus den 500 Bootstrap-Wiederholungen aufgelistet.

Werden statt der 8 verfügbaren nur die 4 konventionellen Kanäle für die Klassifikation verwendet, verschlechtert sich das Klassifikationsergebnis deutlich. Bei Betrachtung der mittleren Gesamtgenauigkeiten der 500 Einzelklassifikationen ist eine signifikante Abnahme von 83,0 % auf 78,2 % (T-Test, $t=-54,05$, $df=998$, $P<0,01$) feststellbar. Beschränkt sich die Klassifikation hingegen auf die 4 Hauptbaumarten, zeigen die 4 zusätzlichen Kanäle keine Verbesserung. So liegt im Untersuchungsgebiet die mittlere Gesamtgenauigkeit bei der Unterscheidung der 4 Hauptbaumarten Fichte, Kiefer, Buche und Eiche bei Verwendung von 4 Kanälen mit 94,8 % sogar geringfügig über den 94,5 % bei Verwendung von 8 Kanälen (T-Test, $t=4,91$, $df=998$, $P<0,01$).

Tab. 4: Übersicht der Klassifikationsergebnisse für die 10 Baumarten (Fi, Ki, Lä, Dgl, SZy, Bu, Ei, HBU, Bi, SEr) bzw. 4 Baumarten (Fi, Ki, Bu, Ei) mit 8 bzw. 4 Kanälen (beste Klassifikationsergebnisse jeweils in Fettschrift; Mittelwerte, Standardabweichungen und Modalwerte aus 500 Bootstrap-Wiederholungen).

Bewertungskriterium	10 Baumarten		4 Baumarten	
	8 Kanäle	4 Kanäle	8 Kanäle	4 Kanäle
Mittelwert der Gesamtgenauigkeiten	0,830	0,782	0,945	0,948
Standardabweichung der Gesamtgenauigkeiten	0,013	0,015	0,011	0,011
Gesamtgenauigkeit aus Modalwerten (Klassifikationsmatrix)	0,837	0,784	0,945	0,950
Kappa aus Modalwerten (Klassifikationsmatrix)	0,814	0,754	0,926	0,933

Die in Tab. 4 aufgeführten Mittelwerte der Gesamtgenauigkeiten und deren Standardabweichungen aus den 500 Bootstrap-Wiederholungen berücksichtigen die Streuung (unterschiedliche Klassifikationen) innerhalb der Referenzflächen und liegen erwartungsgemäß etwas unter den Werten aus den Klassifikationsmatrizen, die aus den Modalwerten pro Referenzfläche erstellt wurden. Die Unterschiede zwischen den beiden Gesamtgenauigkeitsmaßen fallen aber über alle Modelle nur sehr gering aus und bescheinigen den Modellen damit eine hohe Robustheit gegenüber den verwendeten Trainingsdaten.

Schwarz-Erle, Hainbuche, Rot-Buche und einzelne Europäische Lärchen vor, während im Süden Weiß-Kiefer und Gemeine Fichte dominieren. Das Klassifizierungsergebnis (10 Baumarten, 8 Kanäle) stimmt mit dieser Beschreibung weitgehend überein. Die Vergesellschaftung von Stiel-Eiche mit Hainbuche ist plausibel (Eichen-Hainbuchenwald), jedoch erscheint der Anteil der Hainbuche etwas höher als es die Taxationsdaten erwarten lassen. Die Baumart Douglasie wird in der Bestandesbeschreibung nicht erwähnt. Bei den klassifizierten Douglasien handelt es sich daher vermutlich um Fehlklassifikationen.

3.4 Klassifikation einer Testfläche

In dem Bestandesteil, der als Testfläche ausgewählt wurde, kommen laut Taxation im nördlichen Teil die Baumarten Stiel-Eiche,

3.5 Trennkraft der einzelnen Spektralkanäle

Im Zuge der LDA wurden zwei Kennwerte berechnet, die Aufschluss über die Trennkraft

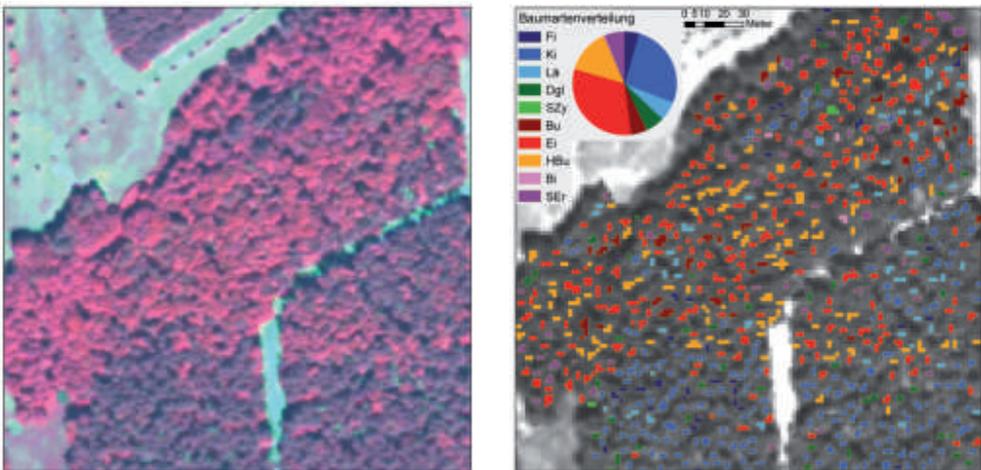


Abb. 6: Klassifizierung der Kronenpolygone der Testfläche: links: Bestand in CIR-Darstellung (Pixelgröße 0,5 m), rechts: mittels LDA klassifizierte Kronenpolygone.

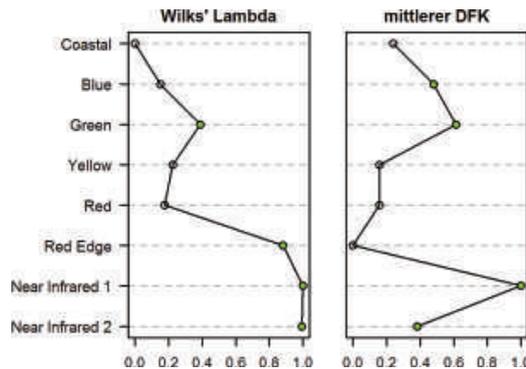


Abb. 7: Normalisierte Wichtigkeiten (0 = geringste, 1 = höchste Wichtigkeit) der einzelnen Kanäle für die Klassifizierung der 10 Baumarten. Die jeweils 4 wichtigsten sind grün hervorgehoben.

der einzelnen Spektralkanäle liefern (Abb. 7). Die Wilks'-Lambda-Werte der univariaten ANOVA geben an, wie gut die einzelnen Kanäle die 10 Baumarten trennen können. Mit den geringsten Wilks'-Lambda-Werten trennen die Kanäle Near Infrared 1 und 2, bzw. auch der Red Edge Kanal univariat deutlich besser als die Kanäle im Wellenlängenbereich des sichtbaren Lichts. Bewertet man die Trennkraft auf Basis der standardisierten und gemittelten Diskriminanzkoeffizienten aus der LDA, ergibt sich folgende Reihung: Near Infrared 1, Green, Blue und Near Infrared 2. Interessanterweise befinden sich damit 2 Kanäle aus dem Wellenlängenbereich des sichtbaren Lichts unter den 3 wichtigsten Kanälen. Für den direkten Vergleich der einzelnen Maße wurden die Kenngrößen auf den Wertebereich von 0 (geringste Wichtigkeit) bis 1 (höchste Wichtigkeit) normalisiert. Die Ergebnisse in Abb. 7 zeigen eine gute Übereinstimmung zwischen den Reihungen anhand der beiden Wichtigkeitsmaße.

Die Kanäle Near Infrared 1, Near Infrared 2 und Green sind bei beiden Wichtigkeitsmaßen unter den 4 wichtigsten Kanälen. Bei den Mittleren Diskriminanzkoeffizienten fallen Red Edge und Near Infrared 2 jedoch verglichen mit der Reihung nach den Wilks' Lambda Werten stark gegenüber dem Kanal Near Infrared 1 ab. Dies ist vermutlich durch hohe Korrelationen zwischen den genannten Kanälen zu erklären. Von den 4 neuen Kanälen (Coastal, Yellow, Red Edge und Near Infrared 2) sind laut Wilks' Lambda nur 2 unter den 4 wichtigsten Kanälen (Red Edge und Near

Infrared 2); unter Verwendung des Mittleren Diskriminanzkoeffizienten ist es nur der Near Infrared 2 Kanal.

4 Diskussion

Die verwendeten WorldView-2 Satellitendaten zeigten eine gute Eignung für die Trennung der untersuchten Baumarten im Testgebiet. Bei der Klassifikation der 4 Hauptbaumarten (Fi, Ki, Bu, Ei) zeigten bereits die 4 konventionellen Kanäle (Blau, Grün, Rot und Near Infrared 1) sehr gute Ergebnisse, welche durch die Mitverwendung der 4 neuen Kanäle (Coastal, Yellow, Red Edge und Near Infrared 2) nicht mehr verbessert wurden. Bezüglich der 6 Nebenbaumarten konnten die zusätzlichen Kanäle jedoch eine deutliche Verbesserung des Klassifikationsergebnisses bewirken. So konnte die Gesamtgenauigkeit der Klassifikation der 10 untersuchten Baumarten von 78 % (4 Kanäle) auf 84 % (8 Kanäle) gesteigert werden. Die geringen Genauigkeitsunterschiede bei Verwendung von 4 gegenüber 8 Kanälen bei der Analyse weniger (Haupt-) Baumarten decken sich mit den Ergebnissen der Studie von CHEN (2011). Dieser erzielte bei der Klassifikation zweier Baumarten mit verschiedenen Klassifikationsalgorithmen (u.a. LDA) mit 4 Kanälen immer annähernd die gleichen Ergebnisse wie mit 8 Kanälen.

Die Detailergebnisse zeigten, dass die Unterscheidung zwischen Nadel- und Laubbäumen zu 99 % richtig erfolgte. Die erzielten Nutzergenauigkeiten der einzelnen Baumarten

ten lagen zwischen 71 % und 92 %, die Produzentengenauigkeiten zwischen 54 % und 96 %, wobei die geringsten Werte bei Hainbuche bzw. Lärche festgestellt wurden. Gerade bei diesen Baumarten ist vermutlich ein Teil der Fehlklassifikationen auf Fehler in den Referenzdaten (falsche Baumartenzuordnung) zurückzuführen: Beide Baumarten bilden im Untersuchungsgebiet keine Reinbestände, vielmehr handelt es sich um begleitende (Hainbuche) oder einzeln eingesprengte (Lärche) Baumarten. Dadurch kann es bei der Referenzdatengewinnung zu fehlerhaften Zuordnungen gekommen sein. Die Tatsache, dass einzelne Baumarten bei sonst sehr ausgeglichenem Klassifikationsergebnis deutlich geringere Genauigkeiten erzielen, ist bei nahezu allen Studien, die eine größere Anzahl an Arten untersuchen, zu beobachten (CARLEER & WOLFF 2004, VOSS & SUGUMARAN 2008, WASER et al. 2010, 2011, JONES et al. 2010, HAMDAN 2010).

Hervorzuheben sind auch die generell geringeren Klassifikationsgenauigkeiten bei den Nadelbaumarten im Vergleich zu den Laubbaumarten. Neben den geringeren spektralen Unterschieden zwischen den Nadelbäumen könnte die höhere Fehlerrate teilweise auch durch die Kronenform begründet sein: Durch die für Nadelbäume typische, schmale Kronenform sind bei Bilddaten mit 2 m Pixelgröße nur wenige Pixel gut beleuchtet und baumartenrein. Dadurch fielen bei der Referenzdatengewinnung deutlich weniger Pixel pro Beispielkronen an, wodurch einzelne Mischpixel einen größeren Einfluss auf den Mittelwert des Referenzpolygons ausüben. Durch die geringe Nadel- und Kronentransmissivität sind Schatteneffekte zudem stärker ausgeprägt als bei Laubbäumen (SCHLERF & ATZBERGER 2012).

Ähnlichen Studien in temperierten Wäldern zeigten bei Verwendung von Sensoren unterschiedlicher spektraler und räumlicher Auflösung Gesamtgenauigkeiten zwischen 45 % und 96 %. Die besten Werte wurden in der Regel erzielt, wenn nur wenige Baumarten, wie z.B. 3 Arten bei HEIKKINEN et al. (2011), untersucht oder zusätzliche Eingangsdaten, wie z.B. LiDAR bei HOLMGREN et al. (2008), verwendet wurden. In der vorliegenden Studie konnten die 4 Hauptbaumarten Gemeine Fichte, Weiß-Kiefer, Rot-Buche und

Stiel-Eiche mit einer Gesamtgenauigkeit von 95 % klassifiziert werden, unabhängig davon ob nur die 4 konventionellen oder alle 8 Kanäle zum Einsatz kamen. Dieses Ergebnis liegt über vergleichbaren Studien, in denen ebenfalls 4 bis 5 Baumarten rein spektral klassifiziert wurden. Auch bei der Klassifikation der 10 Baumarten liegen die erzielten Gesamtgenauigkeiten mit 84 % im Spitzenfeld der Ergebnisse vergleichbarer Studien (CARLEER & WOLFF 2004, WASER et al. 2010, JONES et al. 2010). Die Gründe dafür liegen vermutlich einerseits in den spektralen und geometrischen Eigenschaften der verwendeten WorldView-2 Daten und andererseits in der Klassifizierung ausschließlich gut beleuchteter Kronenteile. Durch diese Vorgangsweise kann der Einfluss von Beleuchtungsunterschieden auf das Klassifikationsergebnis deutlich reduziert werden.

Die Abgrenzung der beleuchteten Kronenteile erfolgte manuell. Für die großflächige Umsetzung der Baumartenkartierung ist es notwendig, diesen Arbeitsschritt zu automatisieren. Dies wurde bereits in mehreren Studien z.B. durch die Kombination von Spektraldaten mit 3D-Informationen erfolgreich bewerkstelligt (z.B. VOSS & SUGUMARAN 2008, HOLMGREN et al. 2008, DALPONTE et al. 2008, STRAUB et al. 2010, JONES et al. 2010, WASER et al. 2011), wobei die Spektraldaten in erster Linie der Artunterscheidung dienen. Die 3D-Informationen z.B. in Form von Digitalen Oberflächenmodellen wurden hingegen vor allem für die Abgrenzung einzelner Baumindividuen verwendet. Für diese Zwecke sind LiDAR-Daten gut nutzbar (z.B. HEINZEL et al. 2008, HOLMGREN et al. 2008, STRAUB et al. 2010, WASER et al. 2011). Selbstverständlich können geeignete Oberflächenmodelle auch aus dem Bildmaterial selbst erstellt werden (z.B. HIRSCHMUGL et al. 2007). Bei der Verwendung von LiDAR Daten könnten diese neben den Spektralkanälen auch als Eingangsdaten für die Klassifikation dienen und zu einer weiteren Verbesserung des Ergebnisses führen (VOSS & SUGUMARAN 2008, HOLMGREN et al. 2008, JONES et al. 2010).

Andere Ansätze beschränken sich auf nur eine Datenquelle und verwenden verschiedene Segmentierungsalgorithmen zur Einzelbaumabgrenzung. Diese reichen von vorgefertigten Verfahren z.B. mit Definiens (SRIDHARAN

2011), über weiterentwickelte Watershed Segmentation Ansätze (z.B. KANDA et al. 2004, WANG et al. 2004) bis hin zu speziell entwickelten Verfahren (z.B. BRANDTBERG 1999, ATZBERGER & SCHLERF 2002, CULVENOR 2002, ERIKSON 2003, LECKIE et al. 2005a). Ein ausführlicher Überblick über die unterschiedlichen Verfahren findet sich unter anderem in CULVENOR (2003) und WOLF & HEIPKE (2007). Alle Studien verwenden hochauflösende Bilddaten, vorzugsweise Luftbilder. Mit dem panchromatischen Kanal mit einer Auflösung von 0,5 m sollten auch WorldView-2 Daten für derartige Verfahren geeignet sein.

5 Schlussfolgerungen und Ausblick

Im Vergleich zu Luftbildern bieten WorldView-2 Daten aufgrund der höheren spektralen Auflösung bei gleichzeitig geringeren Blickrichtungseffekten deutliche Vorteile. Nachteilig sind die geringere Flexibilität bezüglich des Aufnahmezeitpunkts und die geringere räumliche Auflösung. Gegenüber anderen satellitengestützten Sensoren, wie z.B. QuickBird, kann WorldView-2 vor allem durch die höhere spektrale und räumliche Auflösung punkten.

Da der Erwerb aller 8 anstelle der 4 konventionellen Kanäle zu einer Verdoppelung der Datenkosten führt, ist für jede konkrete Anwendung eine Kosten-/Nutzenanalyse sinnvoll. Wie in dieser Studie gezeigt werden konnte, reichen bei Klassifikationsaufgaben mit wenigen Zielklassen die konventionellen Kanäle aus, während sich die 4 neuen Kanäle (Coastal, Yellow, Red Edge und Near Infrared 2) bei komplexeren Fragestellungen als vorteilhaft erwiesen haben.

Der vorgestellte Ansatz beschränkt sich auf die Analyse der beleuchteten Kronenteile, welche manuell abgegrenzt wurden. Ziel unserer weiteren Forschungsarbeit ist die automatisierte, großflächige Umsetzung der Methode. Soweit möglich soll dabei die Einzelbaumabgrenzung rein auf Basis des WorldView-2 Bildes ohne Zuhilfenahme zusätzlicher Daten, wie z.B. LiDAR Daten, erfolgen, um im Sinne einer praxistauglichen Anwen-

dung den Datenaufwand möglichst gering zu halten.

Neben der großflächigen Anwendung ist eine Ausweitung der Analyse in Bezug auf weitere Baumarten und die Berücksichtigung des Baumalters geplant. Im Zuge dessen werden für alle relevanten Baumarten Referenzdaten vor Ort erhoben. Damit können Unsicherheiten, wie sie im Zusammenhang mit Taxationsdaten speziell bei sehr heterogenen, gemischten Beständen auftreten, in den weiteren Untersuchungen vermieden werden. Auch ein direkter Vergleich der Klassifikation für das gleiche Untersuchungsgebiet mit einem weiteren Sensor, vorzugsweise mit Luftbildern, ist geplant.

In der vorliegenden Studie wurden lediglich LDA-basierte Klassifikationsergebnisse vorgestellt. Nicht gezeigt wurden parallel dazu durchgeführte Untersuchungen mit Hilfe des Algorithmus Random Forests (BREIMAN 2001), welche in jeder Hinsicht sehr ähnliche Ergebnisse ergaben. Dies betrifft sowohl den möglichen Informationsgewinn durch die Verwendung der zusätzlichen WorldView-2 Kanäle als auch die Analyse der spektralen Trennkraft der einzelnen Kanäle.

Im spektralen Merkmalsraum abgeleitete Texturmerkmale (ATZBERGER 2003) wurden in der vorliegenden Studie nicht untersucht, könnten aber Genauigkeitssteigerungen bewirken. Ebenso wäre die Optimierung der Klassifikation durch die Verwendung eines späteren Aufnahmezeitpunktes innerhalb der Vegetationsperiode oder eines multi-saisonalen Datensatzes desselben Sensors denkbar (HILL et al. 2010).

Danksagung

Die Arbeiten wurden zum Teil durch den FFG Innovationscheck finanziert. Die Autoren bedanken sich bei GÜNTHER BRONNER und BERNHARD PFANDL von der Fa. Umweltdata GmbH für die Bereitstellung der WorldView-2 Szene und der Referenzdaten. MATTEO MATTIUZZI danken wir für die Unterstützung bei der Umsetzung der Analysen mit dem Softwarepaket R. Schließlich bedanken wir uns bei den anonymen Gutachtern für ihre wertvollen Anregungen zum Manuskript.

Referenzen

- ALBERTZ, J., 2009: Einführung in die Fernerkundung: Grundlagen der Interpretation von Luft- und Satellitenbildern. – 4. aktualisierte Auflage, 254 S., Wissenschaftliche Buchgesellschaft, Darmstadt.
- ATZBERGER, C. & SCHLERF, M., 2002: Automatisierte Bestimmung der Bestockungsdichte in Nadelwäldern aus räumlich hochauflösenden Orthofluftbildern. – PFG **2002** (3): 171–180.
- ATZBERGER, C., 2003: Möglichkeiten und Grenzen der fernerkundlichen Bestimmung biophysikalischer Vegetationsparameter mittels physikalisch basierter Reflexionsmodelle. – PFG **2003** (3): 51–61.
- BACKHAUS, K., ERICHSOHN, B., PLINKE, W. & WEIBER, R., 2008: Multivariate Analysemethoden - Eine anwendungsorientierte Einführung. – 12th ed., 575 S., Springer, Berlin.
- BRANDTBERG, T., 1999: Automatic individual tree based analysis of high spatial resolution aerial images on naturally regenerated boreal forests. – Canadian Journal of Forest Research **29** (10): 1464–1478.
- BREIMAN, L., 2001: Random forests. – Machine learning **45** (1): 5–32.
- BROSINGER, F., 2010: Erwartungen der Forstverwaltung an die Fernerkundung. Der gepixelte Wald – forstliche Fernerkundung vor dem Hintergrund aktueller Entwicklungen in Umwelt und Technik. – Fachtagung am Zentrum Wald-Forst-Holz in Freising-Weißenstephan 2008, Frank, München.
- BUCK, G., SEITZ, R. & TROYCKE, A., 2010: Fernerkundung an der Bayerischen Landesanstalt für Wald und Forstwirtschaft (LWF) – Umsetzung von Forschungsergebnissen in die forstliche Praxis. – PFG **2010** (4): 295–303.
- CARLEER, A. & WOLFF, E., 2004: Exploitation of Very High Resolution Satellite Data for Tree Species Identification. – Photogrammetric Engineering and Remote Sensing **70** (1): 135–140.
- CHEN, Q., 2011: Comparison of Worldview-2 and IKONOS-2 imagery for identifying tree species in the habitat of an endangered bird species in Hawaii. 8-Band Research Challenge, DigitalGlobe, <http://dgl.us.neolane.net/res/img/f3e-1241921965c60aeae869dd949bb48.pdf> (8.3.2011).
- CLARK, M.L., ROBERTS, D.A. & CLARK, D.B., 2005: Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. – Remote Sensing of Environment **96** (3–4): 375–398.
- COLLIN, A. & PLANES, S., 2011: What is the value added of 4 bands within the submetric remote sensing of tropical coastscape? QuickBird-2 vs WorldView-2. – IEEE International Geoscience and Remote Sensing Symposium (IGARSS): 2165–2168, Vancouver, BC, Canada.
- CONGALTON, R. & GREEN, K., 1999: Assessing the accuracy of remotely sensed data principles and practices. – 137 S., Lewis, Boca Raton.
- CULVENOR, D.S., 2002: TIDA: An algorithm for the delineation of tree crowns in high spatial resolution remotely sensed imagery. – Computers and Geosciences **28** (1): 33–44.
- CULVENOR, D.S., 2003: Extracting individual tree information: a survey of techniques for high spatial resolution imagery. Remote Sensing of Forest Environments: Concepts and Case Studies. – 1st ed., 255–277, Kluwer Academic Publishers, Boston, Dordrecht, London.
- DALPONTE, M., BRUZZONE, L. & GIANELLE, D., 2008: Fusion of Hyperspectral and LIDAR Remote Sensing Data for Classification of Complex Forest Areas. – IEEE Transactions on Geoscience and Remote Sensing **46**: 1416–1427.
- DIGITALGLOBE, 2009: White Paper – The Benefits of the 8 Spectral Bands of WorldView-2, http://worldview2.digitalglobe.com/docs/WorldView-2_8-Band_Applications_Whitepaper.pdf (12.5.2011).
- EFRON, B. & TIBSHIRANI, R., 1993: An Introduction to the Bootstrap. – Chapman and Hall, New York.
- ERIKSON, M., 2003: Segmentation of individual tree crowns in colour aerial photographs using region growing supported by fuzzy rules. – Canadian Journal of Forest Research **33** (8): 1557–1563.
- FALKOWSKI, M.J., WULDER, M.A., WHITE, J.C. & GILLIS, M.D., 2009: Supporting large-area, sample-based forest inventories with very high spatial resolution satellite imagery. – Progress in Physical Geography **33** (3): 403–423.
- GREENBERG, J.A., DOBROWSKI, S.Z., RAMIREZ, C.M., TULL, J.L. & USTIN, S.L., 2006: A bottom-up approach to vegetation mapping of the Lake Tahoe Basin using hyperspatial image analysis. – Photogrammetric Engineering and Remote Sensing **72** (5): 581–589.
- HAMDAN, O., 2010: Commercial Timber Tree Species Identification Using Multispectral WorldView-2 Data. 8-Band Research Challenge, DigitalGlobe, <http://dgl.us.neolane.net/res/img/e809c430f196bad7ffd19e3ed53bdac2.pdf> (8.3.2011).
- HEIKKINEN, V., KORPELA, I., TOKOLA, T., HONKAVAARA, E. & PARKKINEN, J., 2011: An SVM Classification of Tree Species Radiometric Signatures Based on the Leica ADS40 Sensor. – IEEE Transactions on Geoscience and Remote Sensing **49** (11): 4539–4551.

- HEINZEL, J.N., WEINACKER, H. & KOCH, B., 2008: Full automatic detection of tree species based on delineated single tree crowns – a data fusion approach for airborne laser scanning data and aerial photographs. – *SilviLaser 8th international conference on LiDAR applications in forest assessment and inventory*: 76–85, Edinburgh UK.
- HILDEBRANDT, G., 1996: Fernerkundung und Luftbildmessung für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie. – 1. Aufl., 676 S., Herbert Wichmann Verlag.
- HILL, R.A., WILSON, A.K., GEORGE, M. & HINSLEY, S.A., 2010: Mapping tree species in temperate deciduous woodland using time-series multi-spectral data. – *Applied Vegetation Science* **13**: 86–99.
- HIRSCHMUGL, M., OFNER, M., RAGGAM, J. & SCHARDT, M., 2007: Single tree detection in very high resolution remote sensing data. – *Remote Sensing of Environment* **110**: 533–544.
- HOLMGREN, J., PERSSON, Å. & SÖDERMAN, U., 2008: Species identification of individual trees by combining high resolution LiDAR data with multi-spectral images. – *International Journal of Remote Sensing* **29** (5): 1537–1552.
- HOSGOOD, B., JACQUEMOUD, S., ANDREOLI, G., VERDEBOUT, J., PEDRINI, G. & SCHMUCK, G., 1994: Leaf Optical Properties EXperiment 93 (LOPEX93). – European Commission, Joint Research Centre, Institute for Remote Sensing Applications, Report EUR **16095 EN**: 11.
- HUANG, H. & CAO, B., 2011: Experiment on extracting forest canopy height from Worldview-2. – *IEEE Fuzzy Systems and Knowledge Discovery (FSKD)*: 2614–2617, Shanghai.
- JONES, T.G., COOPS, N.C. & SHARMA, T., 2010: Assessing the utility of airborne hyperspectral and LiDAR data for species distribution mapping in the coastal Pacific Northwest, Canada. – *Remote Sensing of Environment* **114** (12): 2841–2852.
- KADRO, A., 1981: Untersuchung der spektralen Reflexionseigenschaften verschiedener Vegetationsbestände. – Dissertation, Universität Freiburg.
- KANDA, F., KUBO, M. & MURAMOTO, K., 2004: Watershed segmentation and classification of tree species using high resolution forest imagery. – *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*: 3822–3825.
- KILIAN, W., MÜLLER, F. & STARLINGER, F., 1994: Die forstlichen Wuchsgebiete Österreichs – Eine Naturraumgliederung nach waldökologischen Gesichtspunkten. – BFW, Wien.
- 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): 30–43.
- LECKIE, D.G., GOUGEON, F.A., TINIS, S., NELSON, T., BURNETT, C.N. & PARADINE, D., 2005a: Automated tree recognition in old growth conifer stands with high resolution digital imagery. – *Remote Sensing of Environment* **94** (3): 311–326.
- LECKIE, D.G., TINIS, S., NELSON, T., BURNETT, C., GOUGEON, F.A., CLONEY, E. & PARADINE, D., 2005b: Issues in species classification of trees in old growth conifer stands. – *Canadian Journal of Remote Sensing* **31** (2): 175–190.
- LIGGES, U. & MÄCHLER, M., 2003: Scatterplot3d – an R package for Visualizing Multivariate Data. – *Journal of Statistical Software* **8** (11): 1–20.
- MARCHISIO, G., PACIFICI, F. & PADWICK, C., 2010: On the relative predictive value of the new spectral bands in the WorldView-2 sensor. – *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*: 2723–2726, Honolulu, Hawaii, USA.
- MCDERMID, G.J., HALL, R.J., SANCHEZ-AZOFEIFA, G.A., FRANKLIN, S.E., STENHOUSE, G.B., KOBLIUK, T. & LEDREW, E.F., 2009: Remote sensing and forest inventory for wildlife habitat assessment. – *Forest Ecology and Management* **257** (11): 2262–2269.
- OLSSON, H., SCHNEIDER, W. & KOUKAL, T., 2008: Preface: 3D Remote Sensing in Forestry. – *International Journal of Remote Sensing* **29** (5): 1239–1242.
- OZDEMIR, I. & KARNIELI, A., 2011: Predicting forest structural parameters using the image texture derived from WorldView-2 multispectral imagery in a dryland forest, Israel. – *International Journal of Applied Earth Observation and Geoinformation* **13** (5): 701–710.
- PADWICK, C., DESKEVICH, M., PACIFICI, F. & SMALLWOOD, S., 2010: WorldView-2 Pan-Sharpener. – ASPRS 2010.
- R DEVELOPMENT CORE TEAM, 2011: R: A Language and Environment for Statistical Computing. – R Foundation for Statistical Computing, Vienna.
- 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.
- 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): 8–17.
- SRIDHARAN, H., 2011: Multi-Level comparison of WorldView-2 8-Band and AISA Hyperspectral imageries for urban forest classification. 8-Band Research Challenge. – DigitalGlobe, <http://dgl>.

- us.neolane.net/res/img/019954e1ad60acaed6b05b88e7319030.pdf (23.11.2011).
- STRAUB, C., WEINACKER, H. & KOCH, B., 2010: A comparison of different methods for forest resource estimation using information from airborne laser scanning and CIR orthophotos. – *European Journal of Forest Research* **129** (6): 1069–1080.
- UPDIKE, T. & COMP, C., 2010: Radiometric Use of WorldView-2 Imagery. – DigitalGlobe, Longmont, http://www.digitalglobe.com/downloads/Radiometric_Use_of_WorldView-2_Imagery.pdf (7.5.2012).
- VENABLES, W.N. & RIPLEY, B.D., 2002: *Modern applied statistics with S.* – 4th ed., 495 S., Springer, New York.
- VOSS, M. & SUGUMARAN, R., 2008: Seasonal effect on tree species classification in an urban environment using hyperspectral data, LiDAR, and an object-oriented approach. – *Sensors* **8** (5): 3020–3036.
- WANG, L., GONG, P. & BIGING, G.S., 2004: Individual Tree-Crown Delineation and Treetop Detection in High-Spatial-Resolution Aerial Imagery. – *Photogrammetric Engineering and Remote Sensing* **70** (3): 351–357.
- 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.
- WASER, L.T., GINZLER, C., KUECHLER, M., BALTSAVIAS, E. & HURNI, L., 2011: Semi-automatic classification of tree species in different forest ecosystems by spectral and geometric variables derived from Airborne Digital Sensor (ADS40) and RC30 data. – *Remote Sensing of Environment* **115** (1): 76–85.
- WOLF, B.-M. & HEIPKE, C., 2007: Automatic extraction and delineation of single trees from remote sensing data. – *Machine Vision and Applications* **18** (5): 317–330.
- WULDER, M.A., HALL, R.J., COOPS, N.C. & FRANKLIN, S.E., 2004: High spatial resolution remotely sensed data for ecosystem characterization. – *BioScience* **54** (6): 511–521.

Adressen der Autoren:

MARKUS IMMITZER MSc., Univ. Prof. Dr. CLEMENT ATZBERGER & Dr. TATJANA KOUKAL, Universität für Bodenkultur, Institut für Vermessung, Fernerkundung und Landinformation, Peter-Jordan-Straße 82, A-1190 Wien, Tel.: +43-1-47654-5100, Fax: -5142, e-mail: vorname.nachname@boku.ac.at

Manuskript eingereicht: April 2012
Angenommen: Mai 2012