
Universität Salzburg, Zentrum für Geoinformatik; Nationalpark Bayerischer Wald

AUTOMATISIERTE ERFASSUNG VON WALDSTRUKTUREN IM NATIONALPARK BAYERISCHER WALD MIT OBJEKTBASIERTER BILDANALYSE

Antonia Osberger

Zusammenfassung: Bei der Erforschung von Naturwäldern bildet die wissenschaftliche Beobachtung der Waldlebensgemeinschaft einen zentralen Aufgabenschwerpunkt. Basierend auf diesem wird in der vorliegenden Studie der Frage nachgegangen, in wie weit mit der Methodik der objektbasierten Bildanalyse ein Algorithmus zur (semi-)automatisierten fortschreibenden Erfassung von Waldstrukturen und Waldentwicklungsphasen möglich ist. Der Ansatz wird anhand multispektraler digitaler Luftbilddaten im Nationalpark Bayerischer Wald erprobt. Die Klassenmodellierung beruht auf wissensbasierten Regelwerken, wodurch ein gewisses Maß an Nachvollziehbarkeit gewährleistet wird. Die Definition der Regeln erfolgt sowohl durch Crisp wie Fuzzy Sets. Die Ergebnisse sind mit Gütemaßen von 61 % und 74 % vielversprechend. Schwachstellen in der Klassifikation treten vorwiegend in Bereichen auf, in denen das Vorhandensein von vitaler Bodenvegetation fälschlicherweise zu einer Ausweisung von Flächen mit Verjüngung und vitalem Baumbestand führt.

Schlüsselwörter: Zustandsbeschreibung von Waldlebensgemeinschaften, objektbasierte Bildanalyse, Klassenmodellierung mit Fuzzy- und Crisp-Regeln

// AUTOMATED EXTRACTION OF FOREST STRUCTURES IN THE BAVARIAN FOREST NATIONAL PARK WITH OBJECT-BASED IMAGE ANALYSIS

// Abstract: The most important planning unit for forest management is the forest stand. In this paper an object-based image analysis methodology was used for the development of an algorithm for semi-automated continuous detailed mapping of forest stands in the Bavarian Forest National Park. The object-based mapping is based on digital aerial photographs. The methodology consists of image segmentation and classification through an interlinked concept. Image segmentation decreased the level of detail and reduced image complexity whereas class modeling was based on a rule-based production system where expert knowledge can be implemented. The rules were defined by both crisp and fuzzy sets. Latter permits more adequate modeling of natural areas taking into account the vagueness of complex systems with continuously varying patterns. The results with accuracy of 61 % and 74 % are promising and encourage further investments. Limitations arose in areas where vital vegetation on the ground cause mistakenly regions with greening and vital tree population.

Keywords: Forest stand delineation, object-based image analysis, class modeling with fuzzy and crisp rules

Anschrift der Autorin

Bakk. rer. nat, MSc. Antonia Osberger
Paris-Lodron-Universität Salzburg
Zentrum für Geoinformatik (Z_GIS)
Hellbrunnerstraße 34
A-5020 Salzburg
E: antonia.osberger@sbg.ac.at

1. EINFÜHRUNG UND MOTIVATION

1.1 WALDÖKOSYSTEME

Die Wälder dieser Erde spielen eine grundlegende Rolle für die Zukunft der Menschheit, da sie einen gewichtigen ökologischen und gesellschaftlichen Beitrag leisten. Waldökosysteme dienen als Filter gegen schädigende klimarelevante Umwelteinflüsse. In ihrem Biomassebestand sind in etwa 283 Milliarden Tonnen Kohlendioxid gespeichert. Überdies fungieren sie als Rohstofflieferanten, Wasserspeicher und Erholungsort für den Menschen, bieten Lebensraum für eine Vielzahl von Tier- und Pflanzenarten und regulieren das lokale und globale Klima. Folglich zählt heute der Erhalt einer ungestörten natürlichen Walddynamik zu den wichtigsten Naturschutzziele (FAO 2007; Louman et al. 2009). Die Funktionsfähigkeit der Biosphäre wird jedoch nur mehr durch die bislang noch relativ wenigen ungenutzten, nicht durch den Menschen beeinträchtigten Ökosysteme gewährleistet. Diese verbliebenen natürlichen bzw. naturnahen Ökosysteme gilt es durch weitläufige Schutzgebiete vor menschlichen Einflüssen und Eingriffen zu bewahren und zu sichern. Solche großräumigen Zonen, die ganz der Eigendynamik der Natur überlassen bleiben, bilden jedoch bislang die Ausnahme (Succow, Jeschke 2008).

Eine dieser Ausnahmen stellt der Nationalpark Bayerischer Wald (NPBW) in der Bundesrepublik Deutschland dar. Im Nationalparkgebiet verzichtet man seit den 1970er Jahren auf jegliche Art regulierender forstlicher Eingriffe. Indem die Waldgesellschaft ihrer natürlichen Dynamik überlassen wird, entwickelt sie sich wieder zu einem Naturwald. Ein zentraler Schwerpunkt liegt in der wissenschaftlichen Beobachtung dieser Waldlandschaft und den damit in engem Zusammenhang stehenden natürlichen Entwicklungen. Von großer Wichtigkeit ist die jährliche Dokumentation der im Zuge des Borkenkäferbefalls ablaufenden Prozesse und Strukturveränderungen in ihrer räumlichen Verteilung. Beim bisherigen Verfahren der visuellen Interpretation erfolgt die Definierung der Kalamitätsflächen mit dem ERDAS *Stereo Analyst*. Diese Vorgehensweise stellt bereits eine Vereinfachung zu der bis ins Jahr 2000 angewandten Methode der visuellen-manuellen Auswertung der Originalluftbilder unter dem Stereoskop dar. Nichtsdestotrotz steigt der Bedarf an (semi-)automatisierten Bildverarbeitungsstrategien, um Veränderungsdetektionen

sowie Monitoring- und Managementaufgaben und die Bewertung von Schadensereignissen strukturiert, kostengünstig, effizient und in geringen Zeitabständen bewältigen zu können. Dieser Beitrag stellt als Ergänzung den Ansatz der objektbasierten Bildanalyse (*objectbased image analysis*, OBIA) vor, der eine operationelle und (semi-)automatisierte flächenmäßige Erfassung von Totholzflächen sowie die Filterung von Merkmalen zur Waldstruktur mit Hilfe eines adäquaten Algorithmus erleichtert.

1.2 UNTERSUCHUNGSGEBIET

Der NPBW, der als Untersuchungsgebiet für die vorliegende Studie fungiert, ist der älteste und größte Nationalpark in der Bundesrepublik Deutschland. Das Schutzgebiet befindet sich im Südosten Deutschlands im mittleren Teil des Inneren Bayerischen Waldes entlang der Grenze zur Tschechischen Republik.

Geologisch betrachtet zählt der Bayerische Wald zum Böhmerwald, ein von Südosten nach Nordwesten ziehendes Mittel-

gebirge. Dementsprechend überwiegen im Schutzgebiet die charakteristischen Waldgesellschaften höherer Mittelgebirge, die eine zonale Gliederung nach Höhenstufen aufweisen. Hierbei handelt es sich im Wesentlichen um drei bedeutende Waldtypen – die Aufichtenwälder in den Tallagen, die Bergmischwälder in den Hanglagen und die Bergfichtenwälder in den Hochlagen (Bibelriether 1979).

1.3 DATENGRUNDLAGE

Zur Dokumentation der Waldentwicklung im NPBW werden seit 1988 jährlich flächendeckend Luftbildbefliegungen durchgeführt, mit deren Hilfe sich langfristige und großflächige Veränderungen der Waldstruktur relativ einfach verfolgen und aufzeigen lassen. Als Grundlage für die Studie dienen die mittels des ZEISS Digitalen Mapping Kamerasystems (*Digital Mapping Camera*, DMC), welche von der Firma Z/Hmaging entwickelt wurde, aufgenommenen digitalen Luftbilder. Für die Auswertung standen Farbinfrarotbilder aus einer

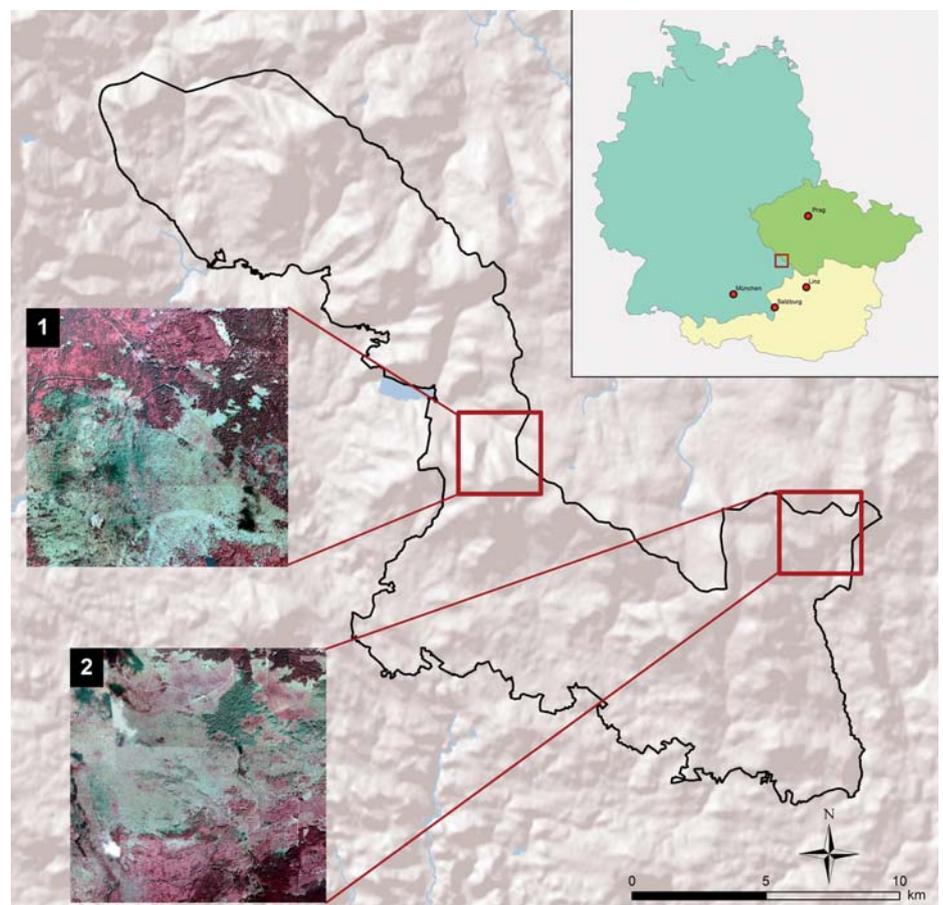


Abbildung 1: Lageübersicht über die verwendeten Luftbildszenen im NPBW. **Szene 1:** entstammt dem Testgebiet, an dem die Entwicklung des Regelsatzes und die Klassenmodellierung zur Waldstruktur Erfassung vollzogen und im Anschluss auf die Gesamtszene übertragen wurde. **Szene 2:** Evaluierung der Übertragbarkeit des Algorithmus.

Befliegung vom 3. September 2004 mit einer Bodenauflösung von 20 bis 23 cm zur Verfügung, die neben den zwei optischen Kanälen rot und grün auch den Spektralbereich des nahen Infrarots (0,7–0,9 µm) enthielten. Im Bereich des kurzwelligen sichtbaren Lichtes wurde auf das blaue Spektrum verzichtet.

Für die Entwicklung des Algorithmus zur Ausweisung einzelner Waldstrukturklassen mit Definiens Cognition Network Language (CNL) und für die Modellierung von Klassifikationsabläufen wurde ein Testgebiet (Luftbildszene I entnommen) gewählt, in dem die Problematik der unterschiedlich ausgeprägten Totholzflächen hinsichtlich der Dichte des abgestorbenen Baumbestandes, die Vermischung von stehendem Totholz mit bzw. ohne Feinreisig und mit liegendem Totholz, der variierende Grad der bodennahen Vegetationsbedeckung und diverse Waldbestände deutlich ersichtlich sind. Um die Übertragbarkeit des erstellten Algorithmus zu evaluieren, wurde dieser auf zwei Gesamtszenen (zu je 9,61 km²)

angewandt. Eine Übersicht über die entsprechende Lage der verwendeten Luftbildszenen im Untersuchungsgebiet ist in Abbildung 1 dargestellt.

2. WALDSTRUKTURERFASSUNG IM BAYERISCHEN WALD

2.1 INTERPRETATIONSSCHLÜSSEL ZUR WALDSTRUKTURBESCHREIBUNG

Die Waldstruktur beschreibt die Verteilung der Baumeigenschaften innerhalb einer Waldgesellschaft und bezieht sich im Speziellen auf die Baumartenverteilung und die Baumdimension (Gadow 2003). Jeder Ur- bzw. Naturwald, unabhängig von seinen Struktur- und Entwicklungseigenschaften, durchläuft einen zyklischen Regenerationsprozess, der sich oftmals in Abständen von mehreren Jahrhunderten vollzieht. Ein Entwicklungszyklus gliedert sich in verschiedene Abschnitte mit jeweils spezifischen Strukturverhältnissen, den so genannten Entwicklungsphasen (Leibundgut 1959; Fischer 1995).

Im NPBW werden regelmäßig insgesamt acht Waldentwicklungsstadien (Abb. 2) ausgewiesen (NPBW 2003):

- 1 Jugendstadium (JS)
- 2 Wachstumsstadium (WS)
- 3 Reifungsstadium (RS)
- 4 Zerfallsstadium (ZS)
- 5 Verjüngungsstadium (VS)
- 6 Plenterstadium (PS)
- 7 Mortalstadium (MS)
- 8 Unbestockt (U).

2.2 BILDBASIERTE STRUKTURERFASSUNG

Bei einer bildbasierten Strukturbeschreibung, wie es im Rahmen dieser Untersuchung durchgeführt wurde, standen Farbe und Textur als zentrale Indikatoren im Mittelpunkt der Analyse. Da Geoobjekte in verschiedenen Wellenlängenbereichen ein typisches Reflexionsverhalten aufweisen, wird versucht über die verschiedenen spektralen Werte die entsprechenden Waldstrukturen zu filtern und adäquat zu beschreiben. Für die Analyse ist das Spektrum des nahen Infrarots von entscheidender Bedeutung, da sich mittels der Farbinfrarotbilder Aussagen über die Vitalität der Vegetation ableiten lassen, eine bessere Baumartenunterscheidung ermöglicht und die Differenzierung zwischen lebenden und abgestorbenen Pflanzenmaterialien begünstigt wird.

Die Textur bezeichnet den Grad der Grauwertveränderung von Oberflächen bzw. Objekten im Detail und trägt zu deren Erkennung und Abgrenzung bei. Dies erfolgt konkret durch die Anordnung und Verteilung von Komponenten unterschiedlicher Grauwerte, die durch spezifische Reflexionsintensitäten verursacht werden. Meist geschieht dies durch Erscheinungen, die zu klein sind, um als Einzelobjekte dargestellt zu werden, wie die Blätter eines Baumes. Texturparameter werden unter anderem eingesetzt, um verschiedene Baumarten voneinander abzugrenzen. Hierbei macht man sich zunutze, dass arttypische Kronenstrukturen auftreten, die einerseits eine Differenzierung in Laub- und Nadelgehölze erlauben, aber auch als Merkmal zur Erkennung von Vitalitätszuständen und Schadsymptomen in Waldbeständen dienen. Eine detaillierte Beschreibung von Texturmerkmalen, die sich zur Klassifizierung von Waldstrukturen eignen, wird bei Hildebrandt (1996) bereitgestellt. Komplexere Texturparameter zur

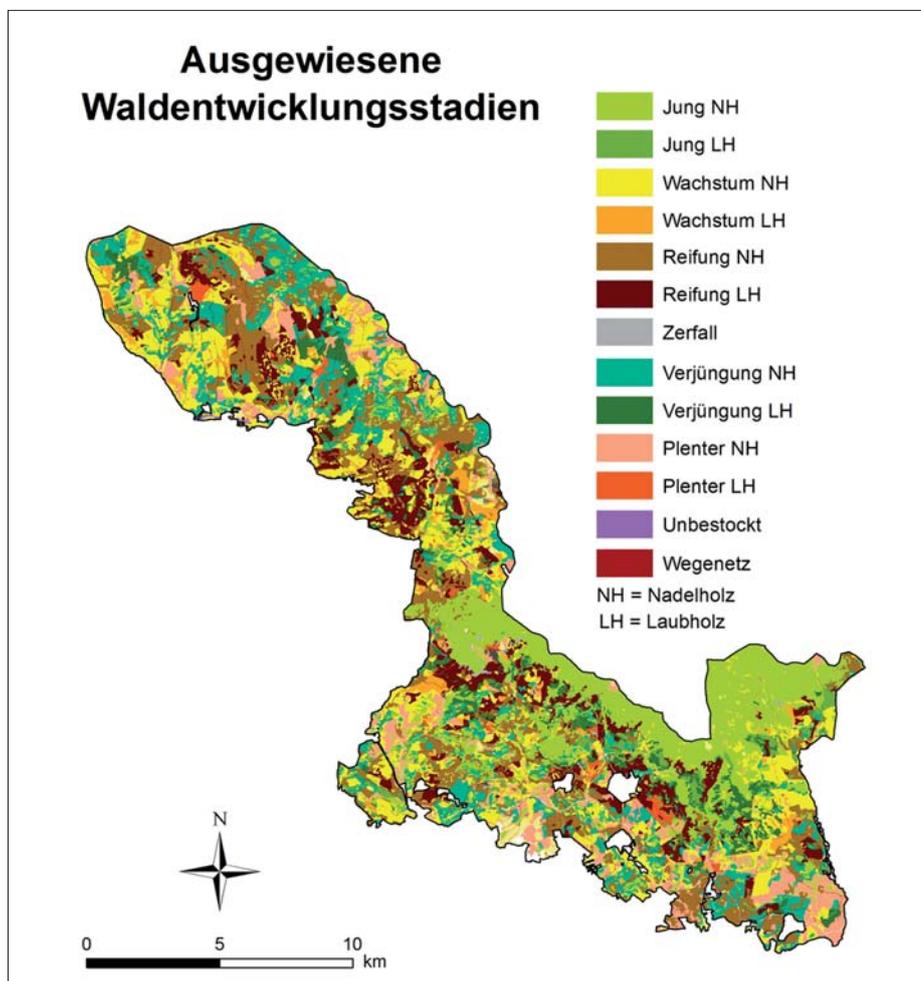


Abbildung 2: Waldstruktur mit ausgewiesenen Entwicklungsstadien im NPBW

Ableitung der wichtigsten Variablen zur Charakterisierung von Nadelholzbeständen – Alter, Baumhöhe, Kronenumfang und Bestandesdichte – unter Heranziehung der von Haralick et al. (1973) vorgeschlagenen Grauwertematrix (*grey level co-occurrence matrix*, GLCM) werden bei Kayitakire et al. (2006) erläutert und auf deren Potentiale überprüft.

3. ANSATZ DER OBJEKTBASIERTEN BILDANALYSE

3.1 MULTISKALARE SEGMENTIERUNG

Die durch den Fortschritt in der Fernerkundung verbesserten räumlichen (bis zu 0,5m) und zeitlichen Auflösungen mit einem exponentiell zunehmenden Detailgrad an Bilddaten rechtfertigen das sich neu abzeichnende Paradigma OBIA im Bereich der Bildanalyse und -auswertung.

Methodisch betrachtet liegen die Bestrebungen von OBIA darin begründet, die ehemals eindeutig dem GIS-Bereich zugeschriebenen Techniken, im Speziellen räumliche Analysekonzepte, mit Fernerkundungsanwendungen zu kombinieren bzw. zu verbinden. Der sogenannte Brückenschlag zwischen diesen beiden Domänen entsteht über Polygone, wie klassifizierte Bildobjekte, die Geoobjekte darstellen. Der Ansatz setzt sich aus zwei in Wechselbeziehung stehenden methodischen Komponenten zusammen, die darauf abzielen, relevante räumliche Einheiten zu charakterisieren und zu klassifizieren. Zum einen handelt es sich um die **Segmentierung** zur Generierung repräsentativer Bildregionen und zum anderen um die **Klassenmodellierung** anhand von Regelwerken, welche die Einbindung von Expertenwissen vorsehen und ein bestimmtes Maß an Nachvollziehbarkeit gewährleisten (Benz et al. 2004; Lang 2008).

Die Bildsegmentierung (*image segmentation*) ist eine räumliche Regionalisierungstechnik zur Aggregation des Detailgehaltes in vielschichtigen, auf unterschiedlichen Maßstabsebenen befindlichen Repräsentationen in einzelne, möglichst kontinuierliche homogene Regionen. Dabei vollzieht sich gleichzeitig eine sowohl räumliche als auch semantische Strukturierung des Bildinhaltes auf unterschiedlichen Maßstabsebenen (Benz et al. 2004; Lang, Blaschke 2007).

Dieser Beitrag bezieht sich gemäß Lang und Blaschke (2007) in seiner methodischen Umsetzung auf die skalenadaptive Herangehensweise, bei der es zur Ausbildung eines streng hierarchischen Systems von Bildobjekten kommt. Um die erzeugte Hierarchie für alle Bildobjekte zu gewährleisten, folgen die Objektgrenzen eines zu erzeugenden Levels immer jenen Abgrenzungen von Objekten der darunter befindlichen Segmentierungsebene. Demgemäß werden einmal gezogene Grenzen beibehalten, wodurch auf keine maßstabsspezifische

Generalisierung zurückgegriffen wird. Diese Form der maßstabsabhängigen Segmentierung bietet die Möglichkeit, die hierarchischen Objektbeziehungen direkt in die Klassenmodellierung einzubeziehen, da jedes einzelne Bildobjekt sowohl auf seiner eigenen Skalenebene seine nachbarschaftlichen sowie auch seine vertikalen Beziehungen durch Ober- und Unterobjekte eindeutig kennt.

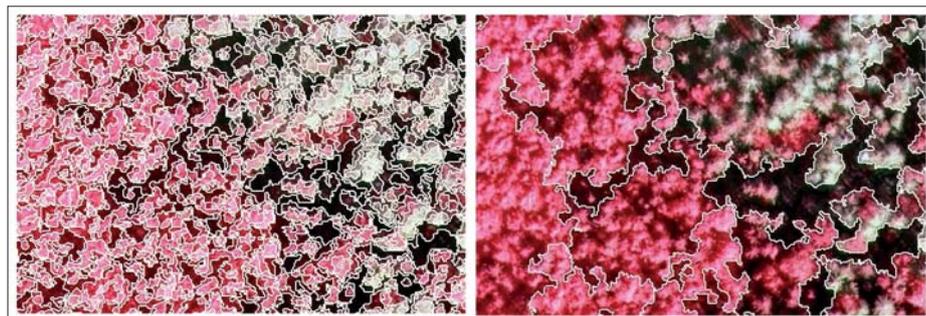


Abbildung 3: Beispiel für verschiedene Maßstabsebenen: links: Level 1; rechts: Level 2

Nach dieser Strategie folgender Segmentierungsalgorithmus ist in der Bildanalyse-Software Definiens implementiert, ein *bottom-up region-merging* Verfahren, genannt *Multiresolution Segmentation*. Hierbei wird von einem Einzelpixel als dem kleinsten eigenständigen Bildobjekt an einer beliebigen Stelle des Bildes ausgegangen. Eine detaillierte Beschreibung dieses Segmentierungsalgorithmus wird von Baatz und Schöpe (2000) bereitgestellt.

Das Untersuchungsgebiet wurde anhand der Multiresolution Segmentation auf zwei Maßstabsebenen segmentiert (Abb. 3). Die Erstsegmentierung auf Level 1 dient zur Abgrenzung von Einzelbäumen bzw. kleineren Baumgruppen sowohl im Bereich der vitalen Vegetation als auch im Totholz und zum anderen der Ausweisung von

3.2 KLASSENMODELLIERUNG

Bei der regionsbasierten Bildanalyse fließen zur Modellierung komplexer, strukturell definierter Zielklassen neben dem spektralen Verhalten (Mittelwerte, Standardabweichung usw.) der Objekte auch Textureigenschaften (räumliche Textur, Textur aus Standardabweichung der Unterobjekte), geometrische Eigenschaften hinsichtlich Länge, Größe, Anzahl der Kanten, Form etc., kontextuelle Attribute, Objekthöhe (im Falle der Integration von LiDAR Daten, *light detection and ranging*; vgl. Zimble et al. 2003) wie auch topologische Beziehungen in Form von Nachbarschaften, Unter- und Oberobjekte etc. ein, wobei sich der Merkmalsraum zu einer virtuell unbegrenzten Ausdehnung erweitert.

Gekoppelt mit einem regelbasierten System kann auf Expertenwissen in Form von Regelwerken zur Beschreibung der Klassen zurückgegriffen werden. Dies trägt maßgeblich zur Erhöhung der Kontrolle und der Nachvollziehbarkeit des Ansatzes bei und gewährleistet eine vermehrte Transparenz. Durch die Berücksichtigung der raumstrukturellen und nachbarschaftsbezogenen Merkmale können kritische Klassen deutlich besser unterschieden werden bzw. deren

Differenzierung erst möglich machen. Ein weiterer Vorteil besteht in der relativ hohen Korrelation von realweltlichen Objekten mit den erzeugten Bildobjekten. In diesen genannten Punkten liegt der entscheidende Unterschied bzw. die Limitierung von herkömmlichen pixel-basierten Multispektralklassifikationen, die lediglich spektrale Ähnlichkeiten unabhängig von ihrer räumlichen Dimension und von kontextbezogener Information berücksichtigen (Benz et al. 2004; Lang 2008).

In der wissensbasierten Bildanalyse zieht man zur Interpretation und Klassifikation von Fernerkundungsdaten unter anderem Ansätze von *soft classifiers* heran. Für diese Studie erwiesen sich Fuzzy-Klassifikationssysteme als geeignet. Diese tragen dem Umstand Rechnung, dass in der Natur keine präzisen Grenzziehungen möglich sind. Man findet insbesondere in naturbelassenen oder naturnahen Ökosystemen Übergangsbereiche vor und selten scharfe, deutlich nachvollziehbare Grenzen. Sie berücksichtigen Unsicherheiten bei Sensormessungen, vage Klassenbeschreibungen und vermischte Klassen aufgrund limitierter Auflösung (Benz et al. 2004).

function) ausgedrückt. Die Zugehörigkeitsfunktion in einem Crisp Set stützt sich auf die Boolesche Logik. Zur Wahl stehen zwei Möglichkeiten – {Ja, Nein} bzw. {0 (falsch), 1 (wahr)}. Demzufolge wird ein Element eines Crisp Sets immer nur einer einzigen Gruppe mit dem Zugehörigkeitsgrad 1 zugewiesen (Abb. 4a). Im Gegensatz dazu erlaubt die Fuzzy-Logik-Theorie einen graduellen Übergang vom Zustand der Zugehörigkeit zur Nicht-Zugehörigkeit. Das Konzept an sich beruht auf einer partiellen Zugehörigkeit, welche die Aussagen der Booleschen Logik insofern relativiert, indem sie diese durch das Intervall von 0 (keine Zugehörigkeit) bis 1 (volle Zugehörigkeit) [0, ..., 1] ersetzt. Alle Werte innerhalb dieser Spanne stellen einen entsprechenden Übergang zwischen *falsch* und *wahr* dar (Abb. 4b). Eine Fuzzy-Klassifikation verlangt ein komplettes Fuzzy-System, welches aus den drei Hauptkomponenten (1) *Fuzzification*, (2) *Inference* und (3) *Defuzzification* besteht (Brandt, Mather 2001; Zadeh 1965).

Bei einer Crisp-Klassifizierung wird beispielsweise ein Bildsegment entweder der Klasse Nadelwald oder der Klasse

Die entsprechende Erstellung des Regelsatzes wurde innerhalb eines Prozessbaumes durchgeführt, der die Dokumentation jeglicher Ablaufschritte und Einstellungen, deren Bewertung und Anpassung während des gesamten Entwicklungsgangs ermöglicht. Solch eine Verfahrensweise garantiert eine relativ einfache und

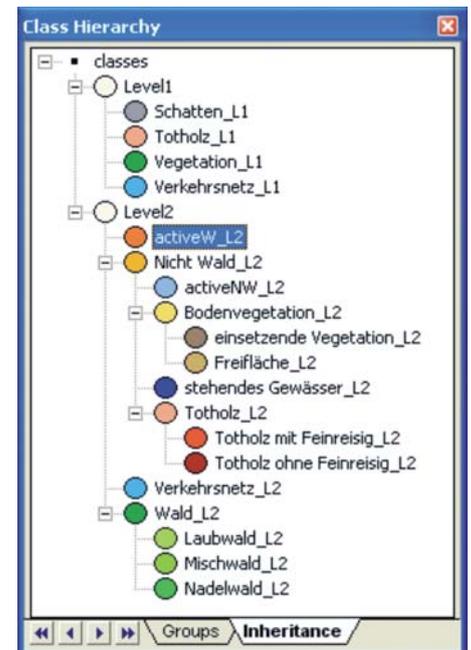


Abbildung 5: Regelbasierte Klassenmodellierung (Level 1 und Level 2)

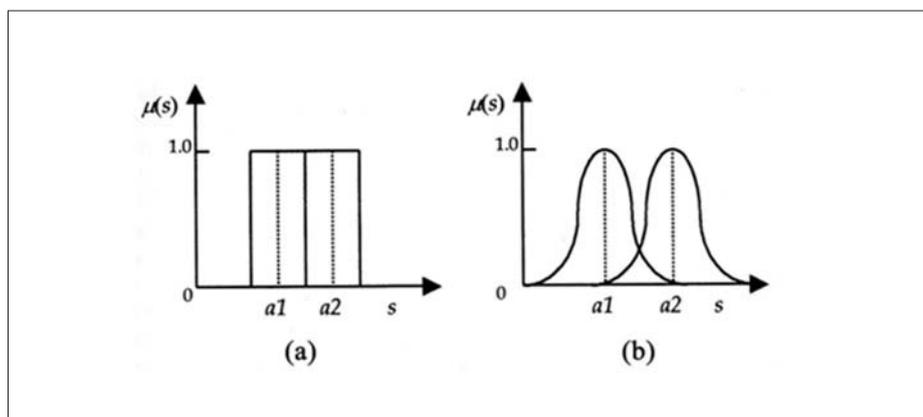


Abbildung 4: (a) Crisp Set: Zugehörigkeit von Cluster a1 oder a2 ist entweder 0 oder 1 (b) Fuzzy Set: Möglichkeit eines Überlappungsbereiches zwischen zwei Clustern (Brandt, Mather 2001)

Die Fuzzy-Logik-Theorie nähert sich unserer vielschichtigen realen Welt besser an als das vereinfachte Boolesche System, da es in adäquaterer Art und Weise menschliche Entscheidungs- und Beweisführung modelliert und linguistische Regelungsprinzipien inkludiert (ebd.). Der Unterschied zwischen Crisp und Fuzzy Sets wird mittels des Zugehörigkeitsgrads zu einer Zugehörigkeitsfunktion (*membership*

Laubwald zugeordnet, je nachdem welcher Zugehörigkeitsgrad der höchste ist. Hingegen ist bei einer Fuzzy-Klassifikation für ein und dasselbe Bildobjekt eine Zuweisung von 0,78 für Laubwald und 0,22 für Nadelwald nach dem Prinzip der partiellen Zugehörigkeit durchaus zulässig. In solchen Fällen sollte grundsätzlich darauf geachtet werden, dass eine Komplementarität auf 1 gegeben sein muss.

stabile Übertragbarkeit auf verschiedene Bildausschnitte. Die Klassenmodellierung wurde nach der in Abbildung 5 dargestellten Klassenhierarchie durch die Ausweisung von Eltern- und Kinderklassen erzeugt. Sie bildet den eigentlichen Rahmen für die Durchführung der Klassifikation, da in ihr alle Klassen organisiert nach einer hierarchischen Struktur zusammengefasst sind. Die jeweiligen Merkmalsbeschreibungen der Elternklassen werden auf die Kinderklassen übertragen. Die Klassifizierung wurde auf der zweiten Segmentierungsebene durchgeführt. Die einzelnen Klassen wurden mehrheitlich über fuzzyfizierte Regelsätze unter Verwendung von Zugehörigkeitsfunktionen definiert. Zur Modellierung von Objekten, die im Zuge der Fuzzifizierung keine entsprechende Klassenzuweisung erhielten, zur Eliminierung von Fehlerklassifikationen und für komplexere Abfragealgorithmen wurde auf scharfe Regeln in Form fester Schwellwertesetzungen zurückgegriffen.

User \ Referenc...	Laubwald_L2	Nadelwald_L2	Mischwald_L2	Totholz mit Feinre...	Totholz ohne Fei...	Freifläche_L2	Verjüngung_L2	Sum
Confusion Matrix								
Laubwald_L2	13	5	3	0	0	0	1	22
Nadelwald_L2	1	54	2	4	3	0	2	66
Mischwald_L2	1	4	5	0	0	0	0	10
Totholz mit Feinrei...	0	0	1	15	5	4	0	25
Totholz ohne Feinre...	0	2	0	0	15	0	2	19
Freifläche_L2	0	0	1	1	1	11	0	13
Verjüngung_L2	1	2	0	14	18	4	16	55
unclassified	0	1	0	0	0	0	0	1
Sum	16	68	11	34	42	19	21	
Accuracy								
Producer	0.8125000	0.7941176	0.4545455	0.4411765	0.3571429	0.579	0.762	
User	0.591	0.8181818	0.5	0.6	0.7894737	0.8461538	0.291	
Holden	0.6842105	0.806	0.4761905	0.5084746	0.4918033	0.6875000	0.421	
Short	0.52	0.675	0.3125000	0.341	0.326	0.5238095	0.2666667	
KIA Per Class	0.7906746	0.7004057	0.4274084	0.366	0.2935268	0.5513025	0.678	
Totals								
Overall Accuracy	0.6113744							
KIA	0.5262452							

Abbildung 6: Konfusionsmatrix der Luftbildszene I

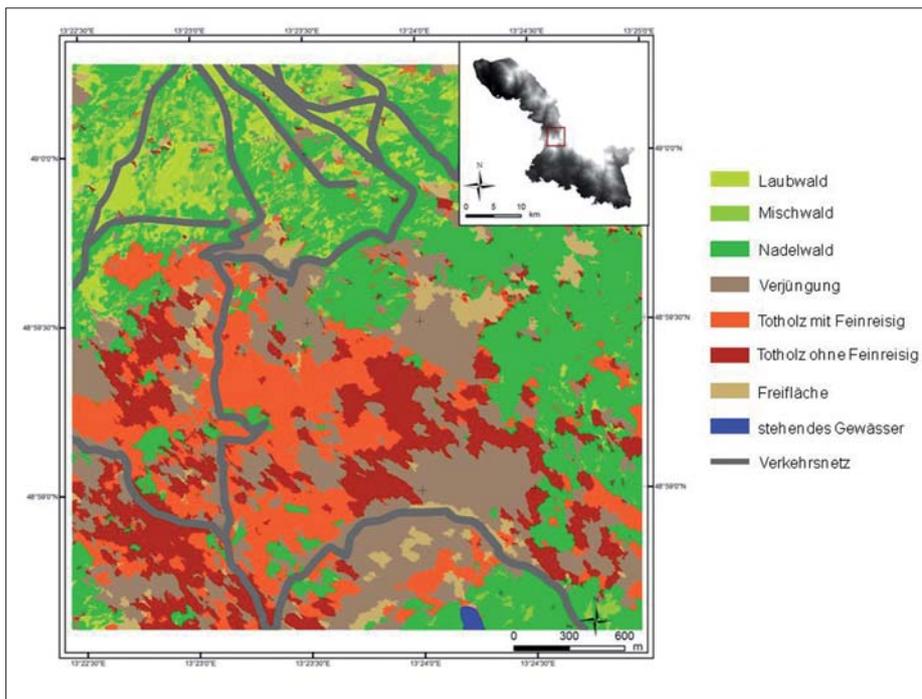


Abbildung 7: Ergebnisse für die Waldstrukturklassifikation der Luftbildszene 1

4. ERGEBNISSE EINZELNER WALDSTRUKTURKLASSEN

Die Genauigkeitsabschätzung der Ergebnisse wurde in Definiens Developer 7 auf Level 2 durchgeführt. Da keine adäquaten Referenzdaten zur Verfügung standen, wurden 211 zufällig generierte Punkte je Luftbildszene in ArcGIS Desktop 9.3.1 über das Tool *Create Random Points* erzeugt, wobei für jede Klasse 30 Punkte eingerechnet wurden. Der Bearbeiter wies durch eine visuelle Interpretation den jeweiligen Stichprobenpunkten eine entsprechende Klasse zu. Die Klassen stehendes Gewässer und Verkehrsnetz wurden in die Evaluierung nicht mit einbezogen, da deren Klassifizierung ausschließlich mittels thematischer Layerinformationen erfolgte. Die Genauigkeitsabschätzung für Luftbildszene I ergab eine Genauigkeit von 61 % und jene

für Szene II eine von 74 %. Eine detaillierte Darstellung der erzielten Genauigkeiten für die einzelnen Klassen der Luftbildszene I liefert die Fehlermatrix in Abbildung 6. Grundsätzlich kann angemerkt werden, dass die Ergebnisse der Waldstrukturklassifikation (Abb. 7) mit den vorhandenen Mitteln zufriedenstellend sind und zur Weiterentwicklung des Algorithmus anregen.

Anhand eines Beispiels soll nun die Vorgehensweise bei der Klassenmodellierung mit den entsprechenden Zugehörigkeitsfunktionen näher erläutert werden. Zur Differenzierung grober Einheiten wurde eine Waldmaske erstellt. Zu diesem Zweck fand eine Unterteilung des Testgebietes in bewaldete (Klasse Wald) und nicht bewaldete (Klasse Nichtwald) Flächen statt. Zur Klasse Nichtwald zählen in dieser Studie

einerseits Freiflächen mit aufkommender Verjüngung und jene mit einsetzender Bodenvegetation und andererseits Kalamitätsflächen, die stehendes (mit oder ohne Feinreisig) oder liegendes Totholz beinhalten. Die Trennung von Bodenvegetation und Kalamitätsflächen erfolgt durch Fuzzy Sets unter Berücksichtigung der Spektralwerte im Infrarotkanal, dem minimalen Pixelwert (Wert des Pixels mit dem geringsten Intensitätswert des Bildobjektes) im grünen Kanal und durch die Ausweisung der Beziehung zu den klassifizierten Unterobjekten Schatten auf Level 1 anhand des Merkmals *Relative area of sub objects*. Hierbei wird Schatten die Funktion eines Indikators zugeschrieben. Dies resultiert aus der Überlegung, dass auf Level 2 Objekte mit einem hohen flächenmäßigen Anteil an Schatten und einem relativ geringen Anteil an Vegetation zu Totholz gezählt werden können. Objekte, die nach der Fuzzy-Klassifizierung in der Oberklasse Nichtwald verblieben sind, wurden der temporären Klasse *activeNW* zugeschrieben, um diese ohne Auswirkungen auf bereits klassifizierte Segmente ansprechen zu können. Diese Hilfsklasse wurde während der Klassenmodellierung häufig auch an anderen Stellen eingesetzt, um gewisse Bedingungen nur auf Teilbereiche zu übertragen. Über die Verwendung der Beziehung zu den Unterobjekten über das Merkmal *Rel. area of sub objects* erfolgte eine vollständige Klassifikation.

Die entsprechende Heuristik zur Ableitung von Kalamitätsflächen wird auszugsweise in Abbildung 8 mit den dafür definierten Zugehörigkeitsfunktionen illustriert. Zur genaueren Erläuterung der Funktionen wird exemplarisch der Spektralwert im Infrarotkanal (*Mean nir*, Formel 1) herausgegriffen.

Im vorliegenden Beispiel erhalten alle jene Objekte, die im Infrarotkanal einen durchschnittlichen Spektralwert kleiner als 3150 aufweisen, einen Fuzzy-Wert von 1 zugeschrieben, was einer vollständigen Zugehörigkeit entspricht. Jene Segmente mit Werten größer als 3190 finden in der Kategorie Kalamität keine Beachtung. Die abfallende Funktion im Wertebereich von 3150 bis 3190 stellt den abnehmenden Grad an Zugehörigkeit zwischen 0 und 1 zur Kalamitätsfläche dar (Abb. 8).

Grundsätzlich treten Schwachstellen in der Klassifikation vorwiegend in Bereichen

auf, an denen das Vorhandensein von vitaler Bodenvegetation zu einer Ausweisung von unbefallenen Flächen führt. Durch die Einbindung von Höheninformation, wie dies bei Laserscanner gestützten Aufnahmen der Fall ist, würde die Erkennung der jeweiligen Baumhöhe die Unter-

auch detaillierte Rückschlüsse auf die einzelnen Waldentwicklungsphasen zu, da Daten zu charakteristischen Variablen von Beständen wie Alter, Kronenumfang und Bestandesdichte leichter erfasst werden könnten. Aussagen über die natürliche Regeneration in geschlossenen Waldbeständen hätten

Ergebnisse könnten in solchen Bereichen ebenfalls durch die Einbeziehung von Laserscannerdaten erzielt werden.

Die Unterscheidung zwischen Nadel- und Laubwald war zufriedenstellend. Für die Nadelwaldbestände wurden jedoch deutlich höhere Genauigkeiten erzielt. Da die Luftbildbefliegung im Spätsommer durchgeführt wurde, ergeben sich aufgrund der tiefer stehenden Sonne häufig Schatten. Dies führt in den einzelnen Szenen zu beachtlichen Helligkeits-, Farb- und Kontrastunterschieden, die eine Übertragbarkeit des Regelwerkes auf unterschiedliche Ausschnitte maßgeblich erschweren. Laubwald wies somit oftmals dieselben Helligkeitswerte wie Frei- oder Verjüngungsflächen auf. Um diese Abweichungen zu umgehen, wurde versucht, mit Ratios und Vegetationsindizes zu arbeiten. Eine bessere bzw. exaktere Differenzierung wäre mit Luftbildern zu einem Aufnahmezeitpunkt im Frühling gegeben. Durch die Kombination von multitemporalen Daten könnte mit ziemlicher Sicherheit die Klassifikationsgüte erhöht werden.

Einschränkungen ergaben sich bei der Abgrenzung von stehendem Totholz ohne Feinreisig gemeinsam mit liegendem Totholz, da diese Zielklasse aus spektral stark kontrastierenden Objekten aufgebaut ist. Der gewählte Segmentierungsalgorithmus beruht jedoch auf einem Homogenitätskriterium.

Limitierungen bestanden auch aufgrund der mangelhaften Qualität des zugrunde liegenden Bildmaterials. Aufnahmen von den Jahren 2007 und 2008 zeigen durch verbesserte Verfahrenstechniken bereits einen höheren Detailgrad und eine deutliche Verminderung des Verkippungseffektes. Eine Kombination von LiDAR (*Light detection and ranging*) und multispektralen Daten wäre wünschenswert, um detaillierte Aussagen zu den einzelnen Waldentwicklungsphasen treffen zu können und entsprechende Kenngrößen zu ermitteln.

5. FAZIT UND AUSBLICK

Die vorgestellte Methode der objektbasierten Bildanalyse erleichtert eine operationelle und (semi-)automatisierte flächenmäßige Erfassung von Totholzflächen sowie die Filterung von Merkmalen zur Waldstruktur im Vergleich zur bisherigen visuellen Interpretation mit dem ERDAS Stereo Analyst. Die Herausforderung liegt

Mean nir: Mathematisch betrachtet wird der Mittelwert eines Layers $\bar{c}_k(P_v)$ von jenen Layer-Werten $c_k(x, y)$ aller Pixel $\#P_v$ berechnet, die ein Segment bilden.

Formel:

$$\bar{c}_k(v) := \bar{c}_k(P_v) = \frac{1}{\#P_v} \sum_{(x,y) \in P_v} c_k(x, y)$$

Parameter:

P_v : Set an Pixel eines Segmentes v

$P_v := \{(x, y) : (x, y) \in v\}$

$\#P_v$: Gesamtsumme an Pixel innerhalb P_v

$c_k(x, y)$: Layer-Wert des Pixels (x, y)

c_k^{min} : dunkelst möglicher Intensitätswert des Layers k

c_k^{max} : hellst möglicher Intensitätswert des Layers k

\bar{c}_k : durchschnittliche Intensität des Layers k

(Definiens AG 2007)

Formel 1

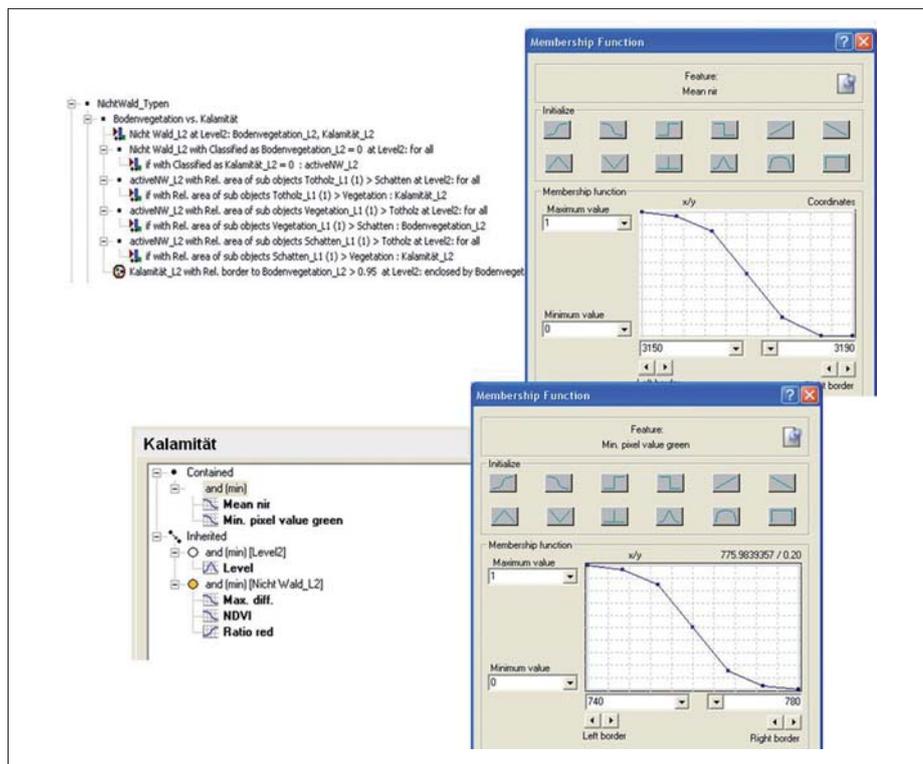


Abbildung 8: Heuristik zur Ableitung der Klasse Kalamität mit den entsprechenden Zugehörigkeitsfunktionen (Auszug aus dem Prozessbaum Bodenvegetation vs. Kalamität)

scheidung zwischen Bodenvegetation, Verjüngung und vitalem Baumbestand deutlich unterstützen bzw. begünstigen. Folglich wären exakte Angaben zur räumlichen Verteilung des Jungwuchses möglich und ließen

eventuell über Parameter zur Rauheit von Oberflächen getroffen werden können. Die Luftbilder lassen jedoch aufgrund des starken Schattenwurfs in kleineren Waldlücken nur Vermutungen zu. Bessere

insbesondere in der Entwicklung eines adäquaten Algorithmus, dessen Übertragbarkeit auf alle das Nationalparkgebiet betreffenden Orthofotos mit geringfügigen bis keinen Anpassungen gewährleistet. Dies setzt eingangs eine dementsprechend zeitintensive Entwicklung voraus, bietet aber im Anschluss den Vorteil, dass die entsprechenden Regelwerke jährlich für neuere Auswertungen und Analysen herangezogen werden können. Folglich werden im Zuge (semi-)automatisierter Klassifikationsmethoden im Vergleich zur visuellen Interpretation objektivere Resultate im Sinne einer erhöhten

Reproduzierbarkeit, Transparenz und Übertragbarkeit generiert, die ebenfalls eine bessere Quantifizierung der Ergebnisse erlauben. Durch den Wegfall der subjektiven Komponente des Luftbildinterpretieren ist eine größere Vergleichbarkeit von Analysen in einem Landschaftsausschnitt über Zeitreihen hinweg durchführbar. Hingegen kann dies bei einem menschlichen Interpretieren weitgehend ausgeschlossen werden, da ein und derselbe Interpret nicht zwei Mal in der Lage ist, eine visuelle Interpretation vollständig identisch zu wiederholen. Dies lässt jedoch keinesfalls den Rückschluss zu, dass die im

Zug der objektbasierten Bildanalyse erzielten Ergebnisse höhere Genauigkeiten erzielen. Vielmehr wird ein hoher Grad an Nachvollziehbarkeit und die bereits eingangs erläuterten Vorzüge gewährleistet.

ANMERKUNG

Dieser wissenschaftliche Fachbeitrag ist aus der Masterarbeit von Antonia Osberger am Zentrum für Geoinformatik der Universität Salzburg (Dr. Stefan Lang, Dr. Dirk Tiede) in Kombination mit dem Nationalpark Bayerischer Wald (Dr. Heinrich Rall, Dr. Marco Heurich) entstanden. ◀

Literatur

- Baatz, M.; Schäpe, A. (2000): Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation. In: Strobl, J., Blaschke, T.; Griesebner, G. (Hrsg.): *Angewandte Geographische Informationsverarbeitung XII*. Wichmann Verlag, Heidelberg, S. 24–29.
- Benz, U. C.; Hofmann, P.; Willhauck, G.; Lingenfelder, I.; Heynen, M. (2004): Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 58, S. 239–258.
- Bibelriether, H. (1979): *Nationalpark Bayerischer Wald*. Kilda-Verlag, Münster.
- Blaschke, T.; Strobl, J. (2001): What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. In: *GIS 6*, S. 12–17.
- Blaschke, T.; Burnett, C.; Pekkarinen, A. (2004): New contextual approach using image segmentation for object-based classification. In: de Mer, F.; de Jong, S. (Hrsg.): *Contextual Methods in Image Processing of Remotely Sensed Data*. Kluwer Academic Publishers, Dordrecht, S. 211–236.
- Brandt, T.; Mather, P. (2001): *Classification methods for remotely sensed data*. New York.
- Burnett, C.; Blaschke, T. (2003): A multi-scale segmentation / object relationship modelling methodology for landscape analysis. In: *Ecological Modelling* 168/3, S. 233–249.
- Definiens AG (2007): *Definiens Developer 7 Reference Book*. München.
- FAO (2007): *State of the World's Forests 2007*. Rome.
- Fischer, A. (1995): *Forstliche Vegetationskunde*. Berlin, Wien.
- Gadow, K. (2003): *Waldstruktur und Wachstum*. Universitätsverlag Göttingen.
- Haralick, R. M.; Shanmugan K.; Dinstein I. (1973): Texture features for image classification. In: *IEEE Transactions on Systems, Man and Cybernetics*, 3/6, S. 610–621.
- Hildebrandt, G. (1996): *Fernerkundung und Luftbildmessung für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie*. Heidelberg.
- Kayitakire, F.; Hamel C.; Defourny P. (2006): Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. In: *Remote Sensing of Environment* 102, S. 390–401.
- Lang, S. (2008): Object-based image analysis for remote sensing applications: Modeling reality – dealing with complexity. In: Blaschke, T., Lang, S.; Hay, G. J. (Hrsg.): *Object-Based Image Analysis – Spatial concepts for knowledge-driven remote sensing applications*. Springer Verlag, Berlin, S. 3–27.
- Lang, S.; Blaschke, T. (2007): *Landschaftsanalyse mit GIS*. Eugen Ulmer, Stuttgart.
- Leibundgut, H. (1959): Über Zweck und Methodik der Struktur- und Zuwachsanalyse von Urwäldern. In: *Schweiz. Zeitschrift für Forstwesen*, 110/3, S. 111–124.
- Louman, B.; Fischlin, A.; Glück, P.; Innes, J.; Lucier, A.; Parrotta, J.; Santoso, H.; Thompson, I.; Wreford, A. (2009): Forest ecosystem services: a cornerstone for human well-being. In: Seppälä, R.; Buck, A.; Katila, P. (Hrsg.): *Adaptation of forests and people to climate change. A global assessment report*. International Union of Forest Research Organizations (IUFRO), Prepared by the Global Forest Expert Panel on Adaptation of Forests to Climate Change, Helsinki, S. 15–27.
- Nationalpark Bayerischer Wald (NPBW) (2003): *Durchführungshinweise zum Waldbegegang 2003 im Nationalpark Bayerischer Wald*. Grafenau.
- Succow, M.; Jeschke, L. (2008): *Mensch und Natur im 21. Jahrhundert – 13 Thesen*. Greifswald. (online: http://www.succow-stiftung.de/stift_thesen.html, Zugriff 06/2009).
- Zadeh, L. A. (1965): Fuzzy Sets. In: *Information and Control* 8, S. 338–353.
- Zimble, D.; Evans, D.; Carlson, G.; Parker, R.; Grado, S.; Gerard, P. (2003): Characterizing vertical forest structure using small-footprint airborne LiDAR. In: *Remote Sensing of Environment* 87, S. 171–182.