

Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren

BARBARA KOCH, MARKUS JOCHUM, EVA IVITS & MATTHIAS DEES, Freiburg

Keywords: classification, pixel-based, object-based, remote sensing, forest

Zusammenfassung: Zur Klassifizierung von Landbedeckungsarten wird in zunehmendem Maße auf das objektbasierte Verfahren zurückgegriffen. Neben den durch den neuartigen Klassifizierungsansatz verbundenen Vorteilen, wie beispielsweise der Segmentierung kompakter Objekte, die dem menschlichen Wahrnehmungsvermögen entsprechen, hat diese Methode auch ihre Schwachstellen. Mit der Bildung homogener Objekte geht gleichzeitig auch eine Generalisierung einher. Mit der pixelbasierten Klassifizierung wird jedes einzelne Pixel nach spektralen Ähnlichkeiten untersucht und in Klassen sortiert, was in der Regel keine homogene Objektbildung zulässt, aber andererseits auch keine Generalisierung darstellt.

Die vorliegende Untersuchung beschreibt den Einsatz pixelbasierter Klassifizierungsalgorithmen zur Analyse von homogenen Objekten, welche aus der objektbasierten Klassifizierung hervorgegangen sind. Es werden dafür Wald-Objekte auf der Basis pixelbasierter Verfahren klassifiziert. Für eine Bewertung der pixelbasierten Klassifizierung werden die untersuchten Objekte visuell interpretiert und dieses Ergebnis der Klassifizierung gegenübergestellt.

Summary: *Pixel-based classification as comparison and as amendment of the object-based procedure.* Object-based methods are nowadays increasingly used for classification of land cover units. Beside the advantages of the new classification method, as for example segmentation of compact objects, which correspond to human perception, this method has also its weak points. By delineation of homogeneous objects also a generalisation of the objects is made at the same time. With the pixel-based classification each individual pixel is examined according to spectral similarities and sorted into classes, what usually permits no formation of homogeneous object, but on the other hand also no generalisation takes place.

This paper describes the application of pixel-based classification algorithms applied to homogeneous objects, which are derived from the object-based classification. For this the forest objects have been further classified by pixel-based algorithm. For the evaluation of the pixel-based classification the classified objects have been compared to visually interpreted objects.

1 Hintergrund

Hochauflösende Satellitendaten werden zunehmend eingesetzt, um Teile der Erdoberfläche aufzunehmen. Für die in der Regel automatische Klassifizierung der Satellitendaten stehen zwei Verfahren, das pixelbasierte und objektbasierte, zur Verfügung.

Bei den pixelbasierten Verfahren wird jedes einzelne Pixel analysiert und nach spektralen Ähnlichkeiten in Klassen sortiert. Bei den objektbasierten Verfahren wird von der Annahme ausgegangen, dass ein Pixel mit einer hohen Wahrscheinlichkeit die gleiche Klassenzugehörigkeit hat wie sein Nachbarpixel. Das heißt, der Bildraum wird zuerst in homogene Regionen, bestehend aus ähnlichen Pixel, segmentiert. Im Ergebnis entstehen im Bildraum sogenannte Objektprimitive, welche durch anschließende Klassifizierung über nutzer-definierte Regeln und Fuzzy zu homogenen Objekten klassifiziert werden (IVITS & KOCH, 2002). Gerade in jüngster Vergangenheit hat sich der Einsatz von objektbasierten Klassifizierungsverfahren für die Erfassung von Landbedeckungsklassen stark durchgesetzt, was darauf zurückzuführen ist, dass mit diesem Verfahren die Möglichkeit besteht, unter Einbeziehung von GIS-Datenbankinformation Objekte so abzugrenzen, dass sie dem Wahrnehmungsvermögen des Betrachters entsprechen.

Eine aktuelle Verwendung findet das objektbasierte Verfahren auch für Untersuchungen zur Biodiversität in dem von der EU geförderten Projekt *BIOASSESS* (EVK2-CT1999-00041). Hier wird das objektbasierte Verfahren als Instrument zur Aufnahme von Habitatstrukturen eingesetzt, welche die Grundlage für die Bewertung der Biodiversität sind. Die ersten Auswertungsergebnisse zeigten eine gute Übereinstimmung zwischen der automatischen Objektbegrenzung und der durch visuelle Interpretation abgegrenzten Objekte. Beim objektbasierten Klassifizierungsverfahren wurde auf das weitverbreitete eCognition Software Paket der Firma Definiens (eCognition User Guide, 2002) zurückgegriffen.

Trotz der in der Regel befriedigenden Klassifizierungsergebnisse auf der Basis objektbasierter Verfahren mit der Software eCognition gibt es auch Schwächen, die vor allem in der Segmentierung liegen. Diese erfolgt über die iterative Auswahl eines Scalefaktors. Es unterliegt also damit der subjektiven Wahrnehmung des Bearbeiters, was die Übertragbarkeit des Verfahrens einschränkt. Darüber hinaus erfolgt innerhalb der einmal im Rahmen der Seg-

mentierung gebildeten homogenen Objekte eine Generalisierung (KOCH & IVITS, 2002), die einerseits Vorteile hat, da sie der menschlichen Wahrnehmung entgegenkommt, aber gerade bei Biodiversitätsuntersuchungen wichtige Details innerhalb der Habitate (Objekte) nicht berücksichtigt, z.B. Lücken im Waldbestand, Mischungsverhältnisse im Mischbestand, Anteil offener Boden u.s.w. Pixelbasierte Verfahren haben den Nachteil, dass keine Objekte, wie sie der menschlichen Wahrnehmung entsprechen, abgegrenzt werden, andererseits aber jedes Pixel für den Nutzer aufgrund bestimmter statistischer Merkmale nachvollziehbar einer Klasse zugeordnet wird und damit der subjektive Einfluss des Bearbeiters sehr gering gehalten werden kann. Darüber hinaus unterbleibt jede Art von Generalisierung.

Auf der Basis der genannten Vor- und Nachteile der unterschiedlichen Klassifizierungsverfahren stellt sich die Frage, inwieweit eine Kombination der Ansätze zu einer Optimierung der Klassifizierung von Wäldern führen kann.

2 Zielsetzung

Die Arbeit hatte daher zwei Zielsetzungen, einmal sollte die objektbasierte Klassifizierung, unter Nutzung der eCognition Software mit den auf der Basis der in ERDAS IMAGINE verfügbaren pixelbasierten Klassifizierungsalgorithmen (ERDAS FIELD GUIDE, 2001) verglichen werden, andererseits sollte geprüft werden, inwieweit es sinnvoll ist, das pixelbasierte Verfahren an das objektbasierte zu koppeln, um die homogenen Objekte einer weitergehenden Klassifizierung auf dem pixelbasierten Wege zu unterziehen.

Im Rahmen des Projektes *BIOASSESS* wurden bereits Testgebiete in der Schweiz mit dem objektbasierten Verfahren unter Anwendung der Software eCognition Version 3.1 klassifiziert. Unter den im Rahmen von *BIOASSESS* klassifizierten Landbedeckungsarten wurden in dieser Arbeit ausschließlich die Objekte, die Wald repräsentieren, mit dem pixelbasierten Verfahren verglichen und weiterklassifiziert. Es wurden für die Untersuchungen zwei Testgebiete in der Schweiz genutzt. Diese eigneten sich für die Untersuchung besonders gut, da die wenigsten Bestände kompakte Reinbestände sind, so dass bei einer objektbasierten Klassifizierung die Objekte sehr stark generalisiert werden.

3 Methodik

3.1 Bildverarbeitung

Die gegebenen Daten der Satellitensysteme IRS 1D Pan (5,6m) und Landsat ETM (30m) wurden einer topographischen Normalisierung unterzogen und anschließend mit der von STEINNOCHER (1999) entwickelten Adaptive Image Fusion Methode (AIF) fusioniert. Aus dem Bildprodukt (AIF) wurden im Folgenden weitere sekundäre oder künstliche Kanäle errechnet, wie Tasseled Cap, NDVI, Hauptkomponente und drei unterschiedliche Ratiokanäle (Abb. 1). Darüber hinaus stand auch ein digitales Höhenmodell (DHM) des Untersuchungsgebiets zur Verfügung.




Abb. 1: Informationsebenen erstellt aus Landsat ETM und IRS 1-D Daten als Basis für die Klassifizierungen

3.2 *Verwendete Klassifizierungsalgorithmen*

3.2.1 *Objektbasierte Klassifizierung mit eCognition*

Die fusionierten Landsat ETM und IRS 1D Bilder wurden unter Nutzung der „Fractal Net Evolution Approach“ (FNEA) mit der Software eCognition (BAATZ & SCHÄPE, 1999) in aufeinander folgenden Ebenen segmentiert. Der FNEA verwendet eine Segmentationstechnik im objektorientierten Rahmen. Das Ziel ist es, benachbarte Pixel mit ähnlichen Grauwerten zu Objekten zu gruppieren, wobei der zugrunde liegende Optimierungsalgorithmus Pixel aufgrund von Homogenitätskriterien in Objekte zusammenfasst. Die Homogenität wurde sowohl nach spektralen als auch nach räumlichen Eigenschaften bestimmt. Die Segmentierung fand in hierarchischen Ebenen statt, wobei zwischen den verschiedenen Ebenen und deren Objekten ein semantisches Netz gebildet wird. Die Objekte der verschiedenen Ebenen wurden unter Nutzung der „Fuzzy-Logik“ Theorie nach nutzerdefinierten Regeln in Klassen zusammengefasst. Dies gestattete die Entwicklung eines hierarchischen Klassifikationssystems, wobei die Objekte in immer feinere Klassen eingeordnet wurden.

In dieser Studie wurden sechs hierarchische Stufen nach dem CORINE System klassifiziert. Auf der einfachsten Stufe wurden Wald, sonstige Vegetation und mehrere Nichtvegetationsklassen mit Hilfe von Multispektral-, Textur- und Höheninformation als Klassen gebildet. Auf weiteren Ebenen wurde der Wald bis zu einer Flächengröße von 1 ha in Nadel-, Laub-, Mischwald und offene Waldflächen differenziert. Bei Flächen unter 1 ha wurde der Wald zwar als Fläche erfasst, aber nicht mehr weiter differenziert. Im Rahmen der Segmentierung konnten auf der Basis der genannten Datensätze Waldflächen ab einer Größe von 250-300 m² abgegrenzt werden. Für landschafts-ökologische Auswertungen, bei denen Objekteigenschaften wie Fläche, Umfang und Nachbarschaftsbeziehungen eine entscheidende Rolle spielen, erwies sich die objektorientierte Methode als ein stabiles Verfahren zur Objektdefinierung (IVITS et al., 2002).

3.2.2 *Pixelbasierte Klassifizierung mit ERDAS IMAGINE Software*

Für die pixelbasierte Klassifizierung wurde auf den selben Datensatz wie für die objektorientierte Klassifizierung zurückgegriffen. Es wurden zunächst die pixelbasierten Klassifizierungsalgorithmen Maximum Likelihood, Minimum Distance und Box-Classifer (ERDAS FIELD GUIDE, 2001) im Rahmen einer überwachten Klassifizierung getestet. Darüber hinaus wurde der verfügbare Expert Classifier zur hierarchischen Klassifizierung genutzt. Im Gegensatz zu den ersten drei genannten Klassifizierungsalgorithmen, auf die hier nicht näher eingegangen wird, da sie in der einschlägigen Literatur vielfach beschrieben sind, erfolgt bei der hierarchischen Klassifizierung die Zuordnung der Pixel zu Klassen durch eine Aneinanderreihung von Einzelentscheidungen.

Mit dem Modul Expert Classifier von ERDAS in der Version 8.5 ist es möglich, das Prinzip der hierarchischen Klassifizierung umzusetzen. Ein Element des Expert Classifiers ist der Knowledge Engineer, ein graphischer Editor, der es ermöglicht, einen wissensbasierten Entscheidungsbaum anzufertigen. Durch den Begriff „wissensbasiert“ kommt zum Ausdruck, dass zusätzliche Kenntnisse über das Untersuchungsgebiet in den Klassifizierungsprozess mit eingebunden werden können. In der vorliegenden Arbeit wurde weitgehend Wissen in Form von spektralen Informationen der Landbedeckungsarten verarbeitet.

Bestandteile eines Entscheidungsbaumes im Expert Classifier sind Hypothesen, Regeln und Variablen. Als Hypothesen werden die Ausgabeklassen einer Klassifizierung bezeichnet. Jede Hypothese (Klasse) wird von mindestens einer Regel definiert, welche wiederum eine oder mehrere Bedingungen bzw. Variablen enthält. Eine Verknüpfung dieser Elemente erlaubt die Erstellung eines hierarchischen Entscheidungsbaumes. Ein Pixel des zugrunde liegenden Satellitenbildes wird nur einer definierten Klasse zugewiesen, wenn es die Bedingungen der entsprechenden Regeln und Variablen erfüllt. Entscheidend für die Konstruktion eines Entscheidungsbaumes ist daher die Definition der Regeln und Variablen. Über die Variablen lassen sich neben den Satellitenbilddaten auch alle Arten sekundärer Bildparameter wie NDVI, Ratiokanäle, Tasseled Cap, etc., sowie Hangneigung, Exposition, Höhenmodelle und Vektordaten in das Regelwerk einbinden. Der Vorteil der hierarchischen Klassifizierung liegt in einer sehr flexiblen Anwendung, da für jeden Entscheidungsschritt die günstigste Kanalkombination für die Bestimmung der Trennwerte gewählt werden kann (ALBERTZ, 1991).

Im Knowledge Engineer werden diese Trennkriterien über die Variablen definiert, wobei ein Kanal sowie ein bestimmter Schwellenwert festgelegt werden muss. Aus dem zur Verfügung stehenden Datenmaterial musste nun für jeden Entscheidungsschritt herausgefunden werden, welche Kanalkombination am besten geeignet ist und mit welchen Trennwerten letztlich eine möglichst genaue Trennung zweier Klassen vorgenommen werden kann. Für diesen Zweck wurden über typische Trainingsgebiete der gesuchten Klassen spektrale Signaturen entnommen und einer

Signaturanalyse unterzogen. Somit konnten die Kanäle identifiziert werden, die eine gute Trennung der gesuchten Klassen zulassen (JOCHUM, 2002).

Die Erstellung des Entscheidungsbaumes ist ein iterativer Prozess, bei dem an jeder Entscheidungsstufe zusätzlich geprüft werden muss, welche Klasse zur Trennung von den restlichen Klassen geeignet ist. Eine Klasse eignet sich zur Trennung, wenn sie sich bezüglich charakteristischer spektraler oder sonstiger Merkmale zumindest in einer Informationsebene von anderen Klassen unterscheidet.

3.2.3 Trennkriterien für die Klassifizierung mit dem Expert Classifier

Da die Klassifizierung sich ausschließlich auf die Waldflächen beschränkte, wurde zunächst, wie beschrieben, eine Wald-Nichtwaldklassifizierung durchgeführt. Hierzu wurden für den Expert Classifier die auf der Basis von Trennbarkeitsanalysen in Tabelle 1 und 2 gelisteten Informationsebenen mit den angegebenen Trennwerten ermittelt.

Tab. 1: Trennkriterien der Klasse Wald Testgebiet 1

Klasse	Kanal	Trennwert
Wald	IRS 1-D	≤ 47
	Hauptkomponente	≤ 83
	AIF Band 4	≤ 150

Tab. 2: Trennkriterien der Klasse Wald für Testgebiet 2

Klasse	Kanal	Trennwert
Wald	IRS 1-D	≤ 45
	Hauptkomponente	≤ 89
	AIF Band 4	≤ 139

Für die Klassen Nadelwald, Mischwald, Laubwald und offener Wald wurde der Entscheidungsbaum weitergeführt und die in Tabelle 3 und 4 angegebenen Informationsebenen und Werte genutzt.

Tab. 3: Trennkriterien Testgebiet 1

Klasse	Kanal	Trennwert
Nadelwald	AIF Band 4	≤ 92
	Tasseled Cap 1	≤ 63
Offener Wald	Ratio AIF 5/4	≥ 67
	DHM	≥ 1200
Laubwald	Tasseled Cap 1	≥ 75
Mischwald	Tasseled Cap 1	< 75

Tab. 4: Trennkriterien Testgebiet 2

Klasse	Kanal	Trennwert
Offener Wald	Ratio AIF 5/4	≥ 70
Nadelwald	Tasseled Cap	≤ 48
	AIF Band 4	< 87
Laubwald	Tasseled Cap 1	> 60
Mischwald	Tasseled Cap 1	≤ 60

3.3 Visuelle Interpretation zur Verifizierung der Ergebnisse

Für den Vergleich der objektbasierten Klassifizierung mit der pixelbasierten Klassifizierung wurde in der vorliegenden Arbeit die thematische Genauigkeit der Waldmaske sowie die Genauigkeit der Klassen Nadelwald, Mischwald, Laubwald und offener Wald für jedes Testgebiet überprüft. Die Verifizierung der produzierten Klassifizierungen erfolgte durch einen Vergleich mit geographischen Referenzdaten, die aus gut interpretierbarem Bildmaterial einer Aufnahme des hochauflösenden Satelliten QuickBird (2,5m) entnommen wurden. Dabei wurden für die Waldmaske 100 Stichprobenpunkte und für die Bestandesklassifizierung 230 Stichprobenpunkte vom Computer zufällig über das Bild verteilt, ausgewählt und anschließend den visuell interpretierten Klassen zugewiesen. Die Gegenüberstellung der referenzierten mit den klassifizierten Punkten in einer Kontingenztabelle ermöglichte die Herleitung der Gesamtgenauigkeit.

Für die Verifizierung der pixelbasierten Klassifizierungsgenauigkeit innerhalb einzelner Objekte wurden QuickBird (2,5m Nadir) und CIR-Luftbilder im Maßstab 1:10.000 interpretiert. Zur differenzierten Bewertung einzelner pixelbasiert klassifizierter Objekte wurden 75 Objekte, die sich in beiden Testgebieten befinden durch eine systematische Stichprobe selektiert. Diese Objekte wurden anschließend in einem GIS (ArcView) auf der Grundlage einer Aufnahme des Satelliten QuickBird visuell interpretiert. Dafür wurden die von eCognition segmentierten Objektkollektive für Nadelwald, Mischwald, Laubwald und offener Wald als Vektordatei in ArcView exportiert und als Layer über das orthorektifizierte QuickBird Bild gelegt. Für jedes einzelne Objekt wurden nun innerhalb der gegebenen Objektgrenzen erkennbare Bestandestypen digitalisiert. Hierbei wurden neben den Klassen Nadelwald, Mischwald, Laubwald und offener Wald auch zusätzlich Nicht-Waldflächen ausgeschieden. Für die Bewertung der pixelbasierten Klassifizierung wurden anschließend alle 75 ausgewählten und pixelweise klassifizierten Objekte den entsprechenden visuell interpretierten Objekten gegenübergestellt. Die Daten der Objekte aus der pixelbasierten Klassifizierung und der visuellen Interpretation in ArcView ermöglichten einen statistischen Vergleich der Klassenanteile in Hektar bzw. Quadratmeter, ohne Beurteilung der Lagerichtigkeit. Um darüber hinaus auch Aussagen über die Lagerichtigkeit der pixelweisen Klassifizierung machen zu können, wurde ein visueller Vergleich der interpretierten Objekte mit den pixelweise klassifizierten durchgeführt. Im Rahmen dieser visuellen Bewertung wurden 3 Kategorien gebildet:

Kategorie 1: Nahezu vollständige Übereinstimmung

Kategorie 2: Übereinstimmung in Teilbereichen

Kategorie 3: Geringe Übereinstimmung

Trotz dieser recht subjektiven Bewertung kann bei dieser Vorgehensweise ein Eindruck zum lagerichtigen Informationsgewinn durch ergänzende pixelweise Klassifizierung der Objekte gewonnen werden.

4 Ergebnisse

4.1 Ergebnis der vergleichenden Klassifizierung von objektbasierten und pixelbasierten Verfahren

Die Ergebnisse für die klassifizierte Waldmaske und die Klassifizierung der Waldtypen (Nadelwald, Mischwald, Laubwald und offener Wald) sind im Folgenden dargestellt.

Für die Waldmaske sind nur die Genauigkeiten der pixelbasierten hierarchischen Klassifizierung im Vergleich zur objektbasierten dargestellt, da die anderen pixelbasierten Klassifizierungsalgorithmen in ihrer Genauigkeit deutlich hinter dem hierarchischen Klassifizierungsansatz zurückblieben.

Tab. 5: Gesamtgenauigkeit der klassifizierten Waldmaske (pixelbasiert, objektbasiert) für die Testgebiete 1 und 2

Waldmaske	Gesamtgenauigkeit
Testgebiet 1 pixelbasiert	92 %
Testgebiet 1 objektbasiert	89 %
Testgebiet 2 pixelbasiert	94 %
Testgebiet 2 objektbasiert	92 %

Der Vergleich des objektbasierten Verfahrens mit dem pixelbasierten hierarchischen Verfahren schloss auch eine Überprüfung der absoluten Waldfläche mit ein. Wie aus den Abbildungen 4 und 5 deutlich wird, wurde mit beiden Verfahren sowohl im Testgebiet 1 als auch 2 in etwa die gleiche Waldfläche erfasst. Die pixelbasierte Klassifizierung lieferte dabei in beiden Fällen mit 1117,4 ha (Testgebiet 1) und 905,1 ha (Testgebiet 2) eine etwas größere Waldfläche als die objektbasierte Variante mit 1026,5 ha (Testgebiet 1) und 878,3 ha (Testgebiet 2).

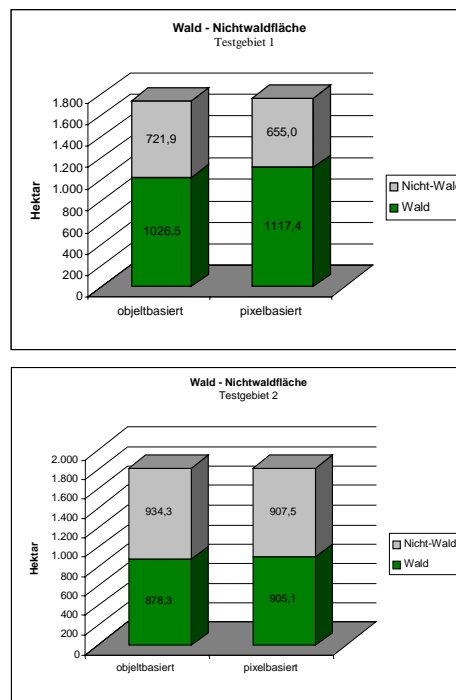


Abb. 2: Vergleich der Wald- und Nichtwaldfläche von pixelbasierter und objektbasierter Klassifizierung für das Testgebiet 1 und 2

In Tabelle 6 wird deutlich, dass das objektbasierte Verfahren bei der Klassifizierung der Waldtypen den pixelbasierten Verfahren überlegen ist. Wiederum konnte bei den pixelbasierten Verfahren mit dem hierarchischen Klassifizierungsansatz das beste Ergebnis erzielt werden

Tab. 6: Gesamtgenauigkeit der Klassifizierungen in Nadelwald, Mischwald, Laubwald und offener Wald

	Klassifizierungs- Verfahren	Gesamt- genauigkeit
Testgebiet 1	Hierarchisch	78 %
	Maximum Likelihood	66 %
	Minimum Distance	73 %
	Box-Klassifikator	67 %
	Objektbasiert	92 %
Testgebiet 2	Hierarchisch	76 %
	Maximum Likelihood	60 %
	Minimum Distance	61 %
	Box-Klassifikator	63 %
	Objektbasiert	82 %

Ein Vergleich der Bestandesanteile aus der objektbasierten Waldtypenklassifizierung mit den verschiedenen pixelbasierten Verfahren (hierarchisch, Maximum Likelihood, Minimum Distance, Box-Klassifikator) (Abb. 3) macht deutlich, dass die Anteile Nadelwald, Mischwald, Laubwald und offener Wald unter den pixelbasierten Verfahren erhebliche Abweichungen zeigen. Hierbei zeigt wiederum der hierarchische Ansatz bei der pixelbasierten Klassifizierung die größte Übereinstimmung mit dem objektbasierten Verfahren.




Abb. 3: Bestandesanteile nach verwendeten Klassifizierungsverfahren für das Testgebiet 1 und 2

5 Ergebnis der pixelbasierten Klassifizierung innerhalb einzelner segmentierter Objekte

Wie in Abbildung 4 zu erkennen ist, werden durch die objektbasierte Klassifizierung die Objekte, trotz der im Vergleich zu QuickBird (2.5 m Nadir) nur mäßigen räumlichen Auflösung der Eingangsdaten (fusionierte Landsat ETM (30 m) und IRS 1D (5.6 m)), in der Form der Außengrenzen recht gut erfasst. Nichtsdestotrotz sind Abweichungen an der Außengrenze erkennbar, die einerseits auf die im Vergleich zu QuickBird geringeren Auflösung zurückzuführen sind, andererseits aber auch auf den objektbasierten Ansatz. Dies gilt auch für die Innenflächen der Objekte, die in diesem Beispiel zwar vorwiegend aus Laubwaldanteilen bestehen, aber auch offene Bereiche und Einmischungen von anderen Baumgruppen aufweisen, die so von dem objektbasierten Ansatz nicht erfasst werden können. Eine Überprüfung der auf der Basis von eCognition durchgeführten Objektklassifizierung zeigte im Vergleich zur visuellen Interpretation, dass bei 23 Objekten die jeweilige zugewiesene Klasse mit weniger als 50 % an der Gesamtfläche vertreten ist.

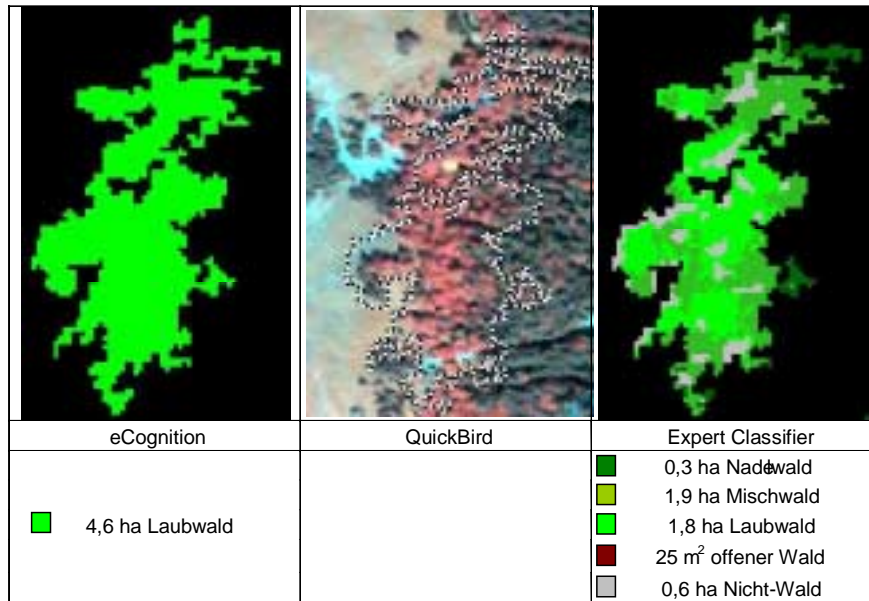


Abb. 4: Laubwaldobjekt aus dem objektbasierten Verfahren im Vergleich zu QuickBird und der pixelbasierten Klassifizierung

Von diesen 23 Objekten entfallen allein 9 auf die Objektklasse offener Wald. Mit Hilfe der nicht generalisierten, pixelweisen Klassifizierung, wie im rechten Bildteil dargestellt, kann dagegen bei gleicher Auflösung der Eingangsdaten eine differenziertere Wiedergabe der Objektränder und in jedem Fall des Gesamtobjektes erreicht werden. Obwohl also mit dem pixelbasierten Ansatz grundsätzlich eine differenziertere Wiedergabe der Flächenzusammensetzung innerhalb der Objekte erreicht wurde, zeigte die Auswertung der insgesamt 75 Objekte, dass bei 46 Flächen deutliche Abweichungen zwischen pixelbasierter Klassifizierung und Interpretation bestehen, bei 20 Objekten die interpretierten Flächenanteile gut durch die pixelbasierte Klassifizierung beschrieben werden und bei 9 eine nahezu vollständige Übereinstimmung vorliegt (Abb. 5 und Abb. 6). Unter den 9 Objekten der Kategorie 1 befanden sich 4 Objekte, die keine zusätzlich klassifizierten Bestandeselemente aufweisen, da es sich um Reinbestände handelt.

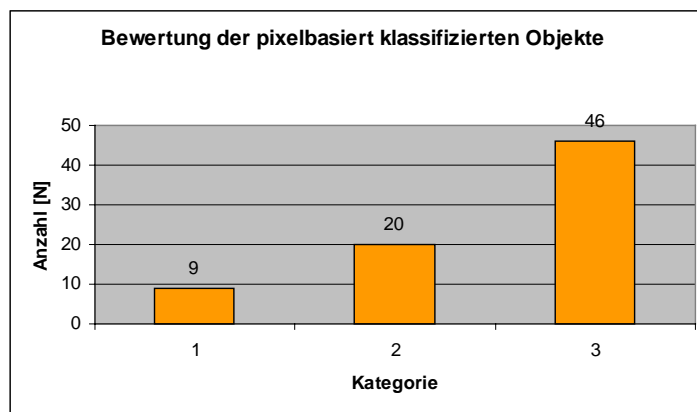


Abb. 5: Bewertung aller 75 Objekte, die pixelbasiert klassifiziert wurden

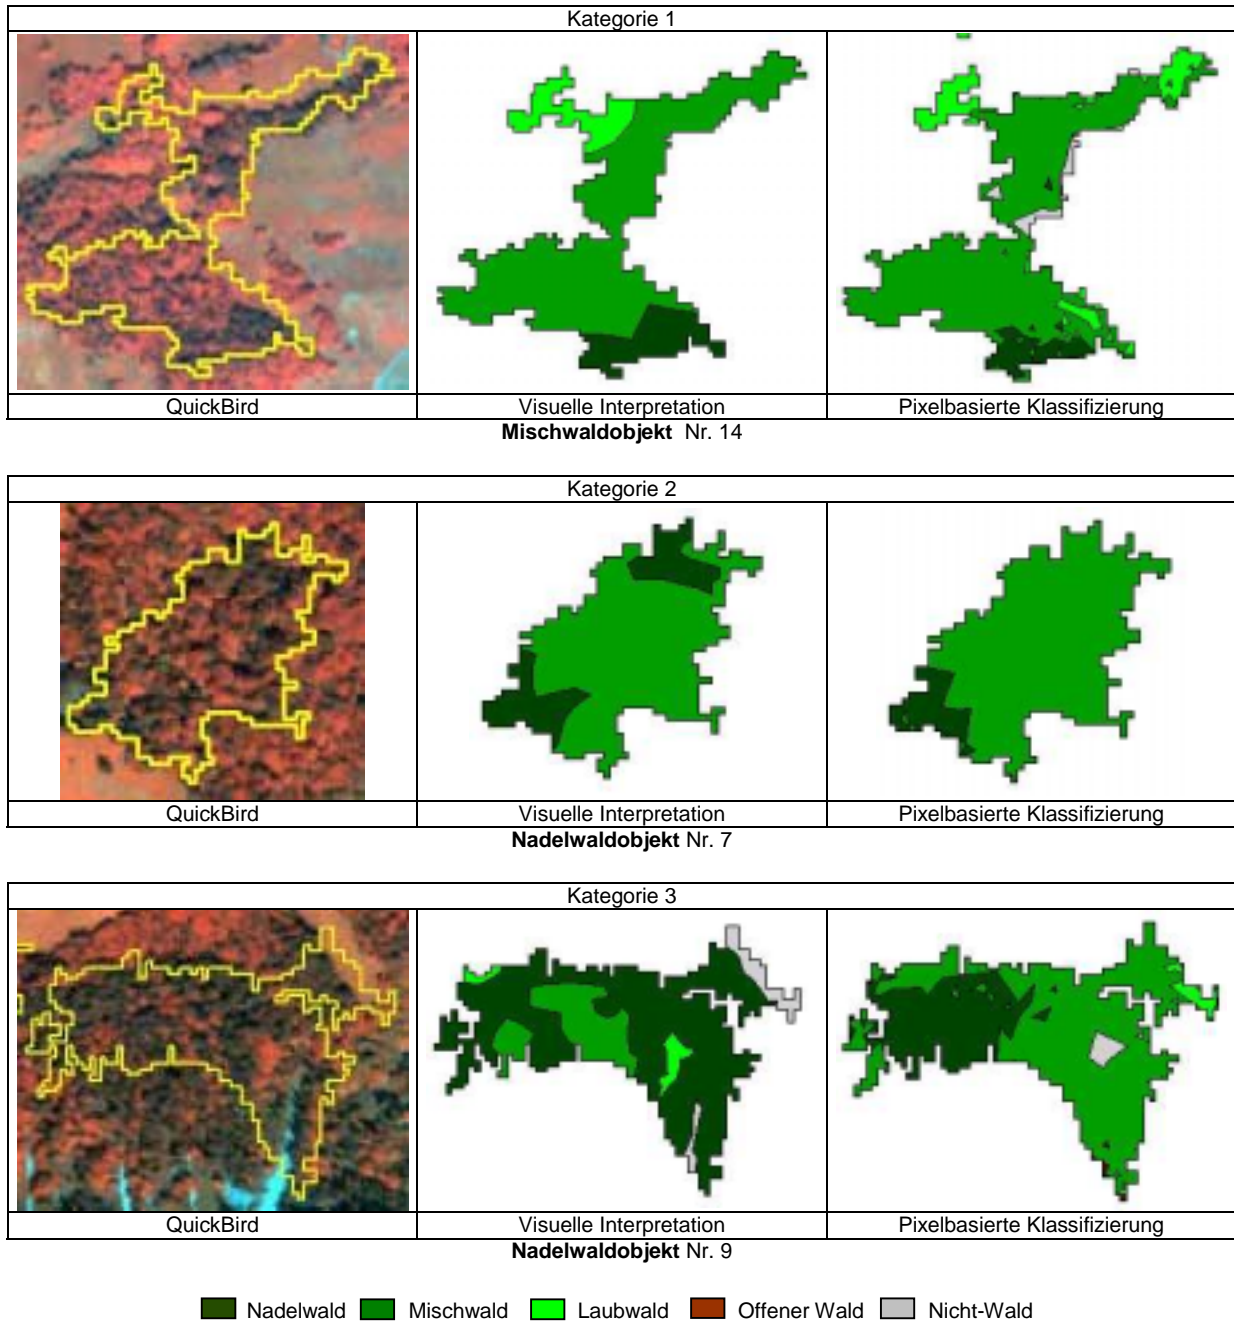


Abb. 6: Beispiele für die verschiedenen Bewertungskategorien

Ein Blick auf die Bewertung der einzelnen objektkollektive macht deutlich, dass vor allem die Nadelwaldobjekte und die Objekte offener Wald gut über den pixelweisen Ansatz klassifiziert wurden. Bei letzteren konnten vor allem Flächen, die nicht dem Wald angehören sehr gut erfasst werden. Die Mischwaldobjekte und Laubwaldobjekte zeigten den geringsten Deckungsgrad im Vergleich zur visuellen Interpretation (Tab. 7). Insbesondere die schlechte Übereinstimmung für die Kategorie Mischwald ist jedoch auch auf Interpretationsprobleme zurückzuführen, da fließende Übergänge in die Reinbestandsform keine eindeutige und wiederholbare Abgrenzung erlauben.

Tab. 7: Anzahl der Objekte nach Objektkollektiven und Kategorie

Objektkollektiv	Kategorie			Ø Kategorie
	1	2	3	
Nadelwaldobjekte	4	9	12	2,32
Mischwaldobjekte	3	-	17	2,7
Laubwaldobjekte	1	4	12	2,6
Objekte offener Wald	1	7	5	2,3
Summe	9	20	46	

Eine genauere Betrachtung der Fehlklassifizierungen zeigt darüber hinaus, dass diese vorwiegend auf die unterschiedliche Auflösung der Datenebenen zurückzuführen sind, d.h. die wesentlich geringere Auflösung der Landsat ETM Daten im Vergleich zu QuickBird führte dazu, dass in QuickBird interpretierte Teilflächen auf der Landsat Datenebene nur als Mischpixel erfasst wurden. Diese Mischpixel wurden dann bei der Klassifizierung aufgrund der gemischten spektralen Rückstrahlung vielfach einer anderen als der interpretierten Klasse zugeordnet. Dies war insbesondere dann der Fall, wenn Pixel über wenig reflektierenden Nadelwaldteilen durch umliegenden stark reflektierenden Laubwald oder Grünlandanteile beeinflusst waren. Des Weiteren wird deutlich, dass trotz topographischer Normalisierung bei steilem Gelände der Einfluss unterschiedlicher Beleuchtung nicht völlig zurückgedrängt werden kann. So wurden nadelwalddominierte Flächen, die zwar Laubwaldanteil aufwiesen, aber weniger als 30%, und somit nach Definition als Nadelwald hätten klassifiziert werden sollen, in sonnenexponierten Lagen eher der Klasse Mischwald als Nadelwald zugeordnet.

5 Zusammenfassung und Schlussfolgerung

Die Untersuchungen zeigten, dass der objektspezifische Klassifizierungsansatz sich gut eignet, um Waldobjekte zu segmentieren. Obwohl für die Klassifizierung von Waldobjekten der objektspezifische Ansatz dem pixelbasierten Verfahren überlegen ist, haben die Untersuchungen auch gezeigt, dass die einzelnen Objekte stark generalisiert werden. Der gleiche Objekttyp kann in seiner Ausprägung sehr unterschiedlich sein, so hat z.B. der Objekttyp Laubwald zwar immer einen dominierenden Anteil an Laubbäumen, aber die Höhe des Anteils und die Beimischung anderer Bestandestypen kann sehr verschieden sein. Mit dem pixelbasierten Ansatz können solche unterschiedlichen Ausprägungen dargestellt werden. Insgesamt scheint eine Kombination des objektspezifischen Ansatzes mit dem pixelbasierten hierarchischen Ansatz vielversprechend, um die Klassifizierung zu verbessern, denn es können einerseits Objekte ausgewiesen werden, die an die Datengrundlage und die Bedürfnisse des Nutzers (z.B. keine Flächen unter 0.5 ha) angepasst sind, andererseits aber auch differenziertere Informationen über das Objekt erfasst werden.

6 Danksagung

Die Autoren danken der Eidgenössischen Forschungsanstalt für Wald und Schnee (WSL) in der Schweiz für die Bereitstellung des digitalen Höhenmodells.

7 Literatur

- ALBERTZ, J., 1991: Grundlagen der Interpretation von Luft- und Satellitenbildern – Eine Einführung in die Fernerkundung. Darmstadt: Wiss. Buchges., 204 S.
- BAATZ, M., SCHÄPE A., 1999: Object-Oriented and Multi-Scale Image Analysis in Semantic Networks. Proc. Of the 2nd International Symposium on Operationalization of Remote Sensing. August 16th-20th, 1999. Enschede. ITC.
- eCognition User Guide, 2002, <http://www.definiens-imaging.com>.
- ERDAS FIELD GUIDE 2001, 5. Auflage ERDAS IMAGINE® inc., Atlanta.
- IVITS, E., ADLER, P., KOCH, B., 2002: Optimierung der Erfassung der Biodiversität auf der Basis von Satelliten- und Luftbildern: ein Europäisches Landschaftskonzept.- Tagungsbeitrag zur 3. Jahrestagung der IALE-Region Deutschland: Bewertung und Entwicklung der Landschaft, 26.- 28. September 2002, Dresden
- IVITS, E.; KOCH, B., 2002: Object-Oriented Remote Sensing Tools for Biodiversity Assessment: a European Approach. - In Proceedings of the 22nd EARSeL Symposium, Prag, Czech Republik, 4-6 Juni 2002, Millpress Science Publishers, Rotterdam, Niederlande
- JOCHUM, M., 2002: Pixelbasierte Klassifizierung für landschaftsökologische Auswertungen zur Erfassung der Biodiversität in Europa – Ein Vergleich mit dem objektbasierten Verfahren, Diplomarbeit an der Fakultät für Forst- und Umweltwissenschaften der Albert Ludwigs-Universität, Freiburg im Breisgau
- KOCH, B., IVITS, E., 2002: What can Remote Sensing provide for Biodiversity Assessment - BioAssess an project example. Presented at ForestSAT Symposium Heriot Watt University, Edinburgh, August 5th-9th of August 2002

STEINNOCHER, K., 1999: Adaptive Image Fusion of Multisource Raster Data Applying Filter Techniques. International Archives of Photogrammetry and Remote Sensing, Vol. **32**, Part 7-4-3 W6.

Anschrift der Autoren:

Prof. Dr. BARBARA KOCH

e-mail: barbara.koch@felis.uni-freiburg.de

Dipl.-Forstwirt MARKUS JOCHUM

e-mail: markus.jochum@felis.uni-freiburg.de

M.Sc. EVA IVITS

e-mail: eva.ivits@felis.uni-freiburg.de

Dr. MATTHIAS DEES

e-mail: dees@ruf.uni-freiburg.de

Albert-Ludwigs-Universität, Freiburg

Abt. Fernerkundung und Landschaftsinformationssysteme, Tennenbacher Straße 4,

D-79106 Freiburg, Tel.: (49)-761-203 3694 Fax:(49)-761-203 3701