

Department für Ökosystem- und Landschaftsmanagement  
Lehrstuhl für Landnutzungsplanung und Naturschutz

## Objektorientierte Klassifikationsstrategien zur Erfassung der Landnutzung aus hochauflösenden Fernerkundungsdaten

Claudius Mott

Vollständiger Abdruck der von der Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt der Technischen Universität München zur Erlangung des akademischen Grades eines

Doktors der Naturwissenschaften (Dr.rer.nat.)

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr.rer.nat. Anton Fischer

Prüfer der Dissertation: 1. Univ.-Prof. Dr.oec.publ. Ulrich Ammer (em.)  
2. Univ.-Prof. Dr.agr., Dr.rer.nat.habil. Arnulf Melzer

Die Dissertation wurde am 20.07.2005 bei der Technischen Universität München eingereicht und durch die Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt am 07.11.2005 angenommen.



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>5</b>
1.1	Einführung in die Thematik	5
1.2	Ziele der Arbeit	7
<b>2</b>	<b>Stand der Forschung</b>	<b>8</b>
2.1	Allgemeine Einführung in das fernerkundliche Umfeld	8
2.2	Visuelle Interpretation und Bildwahrnehmung	10
2.3	Digitale Bildauswertung	12
2.3.1	Unüberwachte Klassifikation	14
2.3.2	Überwachte Klassifikation	14
2.4	Grenzen bildpunktbasierter Klassifikationsverfahren	15
2.5	Bedeutung des Pixel-Umfelds (Kontext)	17
2.6	Wissen und wissensbasierte Bildanalyse	18
2.6.1	<i>Data fusion</i> oder integrierte Wissensverarbeitung	19
2.6.2	Das Wissen des Experten	20
<b>3</b>	<b>Die objektorientierte Auswertung auf Basis von eCognition</b>	<b>22</b>
3.1	Einführung	22
3.2	Fragestellung	25
3.3	Eingangsdaten	26
3.4	Segmentierung	28
3.4.1	Segmentierung in eCognition	29
3.4.2	Segmentierung auf verschiedenen Maßstabsebenen	30
3.5	Wissensmodellierung	32
3.5.1	Objekteigenschaften	32
3.5.2	<i>Fuzzy logic</i>	34
3.5.3	Aufbau der Regelwerke	36
3.6	Klassifikation	37
3.7	Genauigkeitsanalyse	38
3.7.1	Referenzdaten	38
3.7.2	Konfusionsmatrix	39
3.8	Ergebnis	41
<b>4</b>	<b>Untersuchungsgebiet</b>	<b>42</b>
<b>5</b>	<b>Datengrundlagen</b>	<b>44</b>
5.1	IKONOS-Satellitendaten	44
5.1.1	Radiometrie der IKONOS-Aufnahmen	45
5.1.2	Georeferenzierung und Lagegenauigkeit der IKONOS-Aufnahmen	46
5.1.3	<i>Resampling</i>	48
5.2	Luftbilder	48
5.3	GIS-Daten	52
5.3.1	Seeuferkartierung (SUK) Bayern	52
5.3.2	Biotopkartierung Bayern	53
5.3.3	Nutzungskartierung der Osterseen	53
5.3.4	Geländekampagnen	53

<b>6</b>	<b>Fallstudien .....</b>	<b>54</b>
6.1	Analyse von hochauflösenden IKONOS-Satellitendaten .....	54
6.1.1	Fragestellung .....	54
6.1.2	Eingangsdaten .....	55
6.1.3	Segmentierung .....	55
6.1.4	Wissensmodellierung .....	57
6.1.5	Klassifikation .....	93
6.1.6	Genauigkeitsanalyse .....	95
6.2	Analyse von Luftbildern .....	99
6.2.1	Fragestellung .....	99
6.2.2	Segmentierung und Wissensmodellierung .....	99
6.2.3	Genauigkeitsanalyse .....	100
6.2.4	Multitemporale Analyse .....	103
6.3	Kombinierte Auswertung von GIS- und Fernerkundungsdaten .....	109
6.3.1	Fragestellung .....	109
6.3.2	Segmentierung und Wissensmodellierung .....	110
6.3.3	Ergebnisse .....	113
<b>7</b>	<b>Diskussion .....</b>	<b>114</b>
7.1	Vorverarbeitung .....	114
7.2	Klassifikationsstrategien .....	115
7.3	<i>Data-fusion</i> .....	121
7.4	Schlußfolgerungen für die Praxis .....	125
<b>8</b>	<b>Zusammenfassung .....</b>	<b>128</b>
<b>9</b>	<b>Literaturverzeichnis .....</b>	<b>131</b>

# 1 Einleitung

## 1.1 Einführung in die Thematik

Die Landschaft Europas hat sich in den vergangenen Jahrzehnten erheblich verändert. Arten und Lebensräume wurden durch die Ausdehnung von Siedlungsgebieten, Industrie und Verkehrsflächen dezimiert. Ganz allgemein werden die Änderungen in der Flächennutzung als wichtigster Aspekt bei der Beurteilung von Veränderungen ökologischer Systeme (VITOUSEK 1994) und der Biodiversität angesehen (CHAPIN et al. 2000). Neben dem Verlust an Lebens- und Rückzugsräumen für Fauna und Flora, gehen auch naturnahe Erholungsgebiete verloren oder werden in ihrem Wert eingeschränkt. Um das wertvolle Naturerbe zu schützen, wurden daher auf globaler, europäischer und landesweiter Ebene Richtlinien erlassen und Programme definiert (Wasserrahmenrichtlinie, Fauna-Flora-Habitat-Richtlinie, Agrarumweltmaßnahmen). Die Planungsbehörden der Länder haben die Aufgabe, diese Richtlinien und Naturschutzprogramme umzusetzen und die Landschaftsentwicklung zu überwachen. Dies führt zu einem steigenden Bedarf an großräumigen und detaillierten Grundlagenerhebungen bezüglich der Landnutzung und der Landschaftsstruktur (AMMER 2004). Vor diesem Hintergrund gewinnt der Einsatz der Fernerkundung immer mehr an Bedeutung.

Mit der Entwicklung ziviler Satellitensysteme haben sich Fernerkundungsmethoden seit den 1970er Jahren in vielen Bereichen durchgesetzt. So werden Satellitendaten beispielsweise in der Umweltüberwachung auf globaler (TOWNSHEND et al. 1991) oder regionaler Ebene eingesetzt (SCHNEIDER et al. 2000a). Auch die Schadenserfassung nach Naturkatastrophen wie Hochwasserereignissen (VAN DER SANDE 2001), Stürmen (KUNTZ und ZIMMERMANN 1993) oder Waldbränden (SIEGERT et al. 2001) ist ein wichtiger Einsatzbereich. Ferner werden Luftbilder und Daten von digitalen Kamerasystemen auch in der Forstwirtschaft (AMMER et al. 1983, HILDEBRANDT 1996), der Landwirtschaft (RINTELEN 2004) oder bei der Kartierung schützenswerter Biotope (LFU 2003) verwendet.

Dabei konnten Satellitenaufnahmen aufgrund ihrer technischen Begrenzungen bis vor wenigen Jahren die geforderte Detailtiefe für viele naturschutzfachliche Anwendungen nicht erfüllen. Nun liefern Satellitensensoren der jüngsten Generation hochauflösende Bilddaten mit einer Bildpunktgröße von 0,6 m bis 5 m und lassen damit präzisere Informationen erwarten. Mit jeder Verbesserung der Auflösung steigt aber auch die Komplexität des Informationsgehalts (SCHNEIDER und ZIMMERMANN 2004). So stoßen bei einer Bildpunktgröße von unter 5 m die herkömmlichen, bildpunktbasierten Klassifikationsmethoden an ihre Grenzen (SCHNEIDER und STEINWENDNER 1999, DE KOK 2001), denn die spektrale Varianz der Bildpunktwerte, die eine thematisch sinnvolle Klasse abbilden, nimmt mit steigender Auflösung deutlich zu (KENNEWEG et al. 1991).

Während auf der globalen bis regionalen Maßstabsebene mit automatisierten Auswerteverfahren für Fernerkundungsdaten sehr gute Ergebnisse erzielt werden (DEFRIES et al. 1995), ist auf der lokalen Maßstabsebene (1 : 5000 bis 1 : 10000), bei der planerische und naturschutzfachliche Maßnahmen umgesetzt werden, auch heute noch die Erfassung der Landbedeckung durch visuelle Interpretation von Luftbildern oder durch terrestrische Kartierung üblich. Diese Methoden sind jedoch personal- und damit kostenintensiv (ARZET 2004). Angesichts der immer knapper werdenden Finanzbudgets der Behörden ist daher anzustreben, diese aufwendigen Methoden zu reduzieren (AMMER 2004). Es gilt, die Auswertung hochauflösender Fernerkundungsdaten zu automatisieren, um daraus direkt verwertbare großmaßstäbliche Geoinformationsprodukte zu gewinnen. Ein geschulter Auswerter kann zwar in bestimmten Fällen präzisere Ergebnisse liefern als ein automatisches Klassifikationsverfahren,

doch ist das Ergebnis nicht reproduzierbar und immer abhängig von der Erfahrung des auswertenden Spezialisten (STRAND et al. 2002).

Im Gegensatz zum Computer ist der Interpret in der Lage, das Gesehene in einen größeren Zusammenhang zu stellen. Entscheidungen werden intuitiv und durch integrale Beurteilung des gesamten Bildinhalts getroffen (ROSENZWEIG 2001). Computer sind bisher nicht in der Lage, die kognitive Erfahrung eines Menschen beim Analyseprozeß miteinzubeziehen. Dafür sind rechnergestützte Verfahren reproduzierbar und mathematisch gesichert. Die Entwicklung von automatischen Auswertemethoden, welche die Entscheidungsprozesse eines Auswertespezialisten mit den reproduzierbaren Methoden eines Rechners kombinieren, ist daher ein wichtiger Schritt für eine operationelle Nutzung von Fernerkundungsmethoden (KARTIKEYAN et al. 1994, SOWMYA und TRINDER 2000).

Die Beschränkungen bildpunktbasierter Verfahren bei der Auswertung hochauflösender Fernerkundungsdaten haben objektorientierte Analysemethoden in den Mittelpunkt des Interesses gerückt. Bei der objektorientierten Bildanalyse werden Bildpunkte eines digitalen Datensatzes nicht mehr als unabhängige, diskrete Einheiten betrachtet. Vielmehr werden benachbarte, spektral ähnliche Bildpunkte zu Bildobjekten zusammengefaßt, deren Eigenschaften in einer Datenbank verwaltet werden. Zu diesen Eigenschaften zählen neben den spektralen Mittelwerten auch Form- und Texturparameter sowie Nachbarschaftsbeziehungen. Unter Zugriff auf die Objekt-Datenbank lassen sich, ähnlich einem Geographischen Informationssystem (GIS), räumliche Beziehungen und semantische Klassifikationsregelwerke formulieren. Der innovative Ansatz dieser Methode liegt in der Möglichkeit, eine Wissensbasis für die Auswertung aufzubauen und modellhaft Eigenschaften, Zusammenhänge und andere Zusatzinformationen für eine Landbedeckungsklasse zu beschreiben und damit einen Datensatz besser zu klassifizieren (SCHNEIDER et al. 2000b). Dabei werden das Wissen und die Erfahrung eines Interpreten in einer Rechnerumgebung nachmodelliert. Mit dem Programm eCognition ist der objektorientierte Klassifikationsansatz erstmals über eine Benutzeroberfläche verfügbar (BENZ et al. 2004) und gestattet dem Anwender eine transparente Handhabung dieses innovativen Klassifikationsansatzes.

## 1.2 Ziele der Arbeit

In der vorliegenden Arbeit soll erörtert werden, wie die objektorientierte Bildanalyse von hochauflösenden Fernerkundungsdaten umgesetzt werden kann. Mit den hier entwickelten Klassifikationsansätzen sollen reproduzierbare, großmaßstäbliche Landnutzungsinformationen für den angewandten Naturschutz abgeleitet werden. Vor diesem Hintergrund soll in einem ersten Schritt der Ablauf einer objektorientierten Klassifikation beleuchtet und strukturiert werden. Weiterhin stellt sich die Frage, welche Werkzeuge aus dem Methodenpool des verwendeten Klassifikationsansatzes besonders zielführend sind und wie sich Expertenwissen sowie die Erfahrungen eines Interpreten in einer Rechnerumgebung formalisieren lassen. Anhand **dreier Fallstudien** sollen die Anwendungsmöglichkeiten des Ansatzes bei der Landnutzungsklassifikation aus Satellitendaten bzw. Luftbildern, der multitemporalen Analyse und der kombinierten Auswertung von GIS- und Fernerkundungsdaten untersucht werden.

Die **erste Fallstudie** befaßt sich mit der Analyse zweier IKONOS-Datensätze vom Beginn und vom Ende der Vegetationsperiode. Dabei werden zunächst die notwendigen Vorverarbeitungsschritte für Satellitendaten behandelt. Für die Entwicklung einer Auswertestrategie werden sodann verschiedene Landnutzungsklassen untersucht, wobei besonderes Augenmerk auf die Wissensmodellierung, die Segmentierung und die erreichte Klassifikationsgenauigkeit gelegt wird. Um sich an einem allgemeingültigen Standard zu orientieren und eine zukünftige Nutzung der erarbeiteten Methoden zu erleichtern, wird für die Einteilung der Klassen die „Systematik der Biotoptypen und Nutzungskartierung“ des Bundesamts für Naturschutz verwendet (BFN 2002). In der **zweiten Fallstudie** wird auf die Fragestellung eingegangen, inwieweit es mit objektorientierten Analysemethoden möglich ist, die Landnutzung aus aktuellen Schwarz/Weiß-Luftbildern festzustellen und retrospektiv die Landschaftsentwicklung aus historischen Luftbildern zu erfassen. Die **dritte Fallstudie** befaßt sich mit der kombinierten Auswertung von GIS- und Fernerkundungsdaten. Dabei soll untersucht werden, wie sich GIS-Daten durch Satellitendaten aktualisieren lassen und inwiefern GIS-Daten als *a-priori* Information für den Analyseprozeß verwertbar sind.

Die vorliegende Arbeit entstand im Rahmen des Pilotprojekts AQUATIC<sup>1</sup> an der Technischen Universität München. AQUATIC war ein gemeinsames wissenschaftliches Vorhaben des Lehrstuhls für Landnutzungsplanung und Naturschutz unter Professor Ulrich Ammer und der Limnologischen Station Iffeldorf unter Professor Arnulf Melzer.

---

<sup>1</sup> AQUATIC - Einsatz hochauflösender Satellitendaten und moderner Bildanalysemethodik zur Erfassung aquatisch / limnologisch relevanter Parameter der oberbayerischen Seen. AQUATIC wurde gefördert durch das BMBF; Projektnummer: 50 EE 0040 & 50 EE 0041.

## 2 Stand der Forschung

### 2.1 Allgemeine Einführung in das fernerkundliche Umfeld

Die Analyse von Fernerkundungsdaten hat eine lange Geschichte. War anfangs das Luftbild die einzige Datengrundlage, so kamen mit dem Start ziviler Satellitensysteme in den 1970er Jahren neue Anwendungsbereiche hinzu. Die Wissenschaft der Fernerkundung hat zahlreiche Definitionen. Die deutsche Bezeichnung entspricht einer sinngemäßen Übersetzung des englischen Terminus „*remote sensing*“, der von Geographen des U.S. Office of Naval Research in den 1960er Jahren geprägt wurde (HILDEBRANDT 1996). Entsprechend der Definition des DEUTSCHEN INSTITUTS FÜR NORMUNG E.V. (1997) wird Fernerkundung nach DIN 18716/3 beschrieben als: „...*die Gesamtheit der Verfahren zur Gewinnung von Informationen über die Erdoberfläche durch Messung und Interpretation der von ihr ausgehenden (Energie-) Felder. Als Informationsträger dient dabei die von der Erde reflektierte oder emittierte elektromagnetische Strahlung*“.

Im Prinzip werden Messungen elektromagnetischer Strahlung vorgenommen, um Rückschlüsse auf die Eigenschaften der Meßobjekte zu ziehen, ohne selbst mit diesen in Kontakt zu treten. Der Vorgang des Messens selbst bedeutet, daß Eigenschaften von Objekten nach bestimmten Regeln abstrakt im Zahlenraum festgehalten werden. Bei einer fernerkundlichen Messung werden im allgemeinen Phänomene der Erdoberfläche, der Atmosphäre oder des elektromagnetischen Feldes der Erde erfaßt. Eine Aufnahme wird entweder aus der Luft oder aus dem Weltraum aufgezeichnet (HILDEBRANDT 1996). ALBERTZ (2001) präzisiert die Definition der Fernerkundung, indem er die bildhafte Wiedergabe der Erdoberfläche und der darauf befindlichen Objekte hervorhebt. Die verschiedenen Aufnahmeverfahren liefern unterschiedlichste Datentypen. Der Nutzer muß im Vorfeld klären, welche Information er benötigt und welcher Datentyp sich am besten dafür eignet. Im Folgenden wird ein kurzer Abriss über die verschiedenen Fernerkundungsdatentypen gegeben. Weiterführende Informationen sind in den gängigen Fernerkundungslehrbüchern enthalten (HILDEBRANDT 1996, SABINS 1997, ALBERTZ 2001).

HILDEBRANDT (1996) unterscheidet photographische, Radar- und elektro-optische Systeme, doch eine Unterteilung nach **aktiven** und **passiven Fernerkundungsverfahren**, wie sie ALBERTZ (2001) vorschlägt, scheint umfassender.

**Aktive Systeme** verfügen über eine eigene elektromagnetische Strahlungsquelle. Das sind z. B. Radarsysteme, die im Mikrowellenbereich (1 mm bis 1 m Wellenlänge) des elektromagnetischen Spektrums arbeiten. Diese Systeme senden einen Energiepuls aus und messen die Reflexion der Oberfläche. Radarbilder liefern ein intuitiv nicht sofort erfäßbares Abbild. Die Rückstreuung eines Radarsignals wird in erster Linie von der Oberflächenbeschaffenheit, der Feuchtigkeit und der Struktur eines Meßobjektes beeinflusst (SABINS 1997). Laserscanner, auch Laseraltimeter genannt, sind ebenfalls aktive Systeme, die einen Laserpuls in Richtung der Erde aussenden und anhand der Verzögerung bis die Rückantwort eintrifft, Schlüsse auf die Oberflächenhöhe zulassen. Wurden diese Systeme ursprünglich für topographische Kartierungen entwickelt (BLAIR et al. 1999), so werden die daraus gewonnenen Oberflächenmodelle heute auch für die Orthobildentzerrung genutzt (ALBERTZ 2001), um z. B. Bestandsparameter in der Forstwirtschaft abzuleiten (MALTAMOA et al. 2004) oder um Gebäudemäße für Stadtmodellierungen zu erhalten (HAALA und BRENNER 1999). Eine Sonderform der aktiven Systeme bildet das Sonar, weil hier nicht mit elektromagnetischer Strahlung gearbeitet wird. Vielmehr werden Schallwellen zur Unterwasserkartierung eingesetzt. Die daraus gewonnene

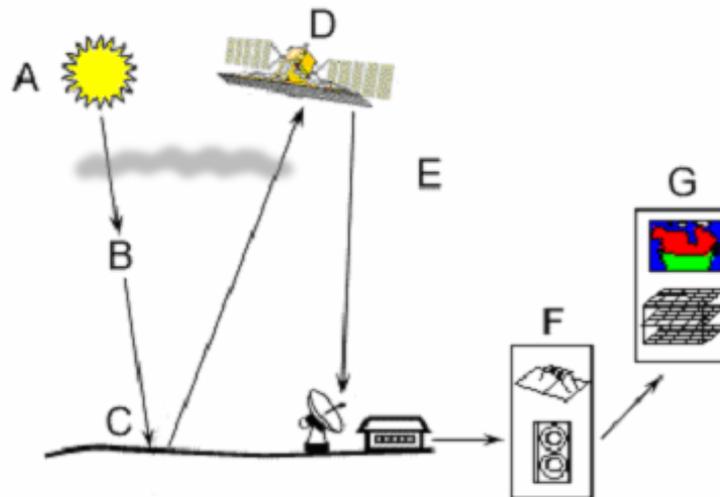
Information ist nicht bildhafter Natur, sondern gibt Auskunft über Aufbau und Struktur der gemessenen Objekte (ATALLAH und SMITH 2003).

**Passive Fernerkundungsverfahren** messen elektromagnetische Strahlung, die von der Erdoberfläche emittiert wird. Bei emittierter Energie handelt es sich um thermale oder niederfrequente Mikrowellenstrahlung. Die natürliche Oberflächenstrahlung wird hier von sogenannten Radiometern punktuell oder flächig aufgenommen (HILDEBRANDT 1996).

Für die Messung der reflektierten Sonnenstrahlung gibt es zahlreiche Systeme. Bei **photographischen Systemen** werden analoge Abbildungen der Erdoberfläche auf Filmmaterial hergestellt. Hier kann sowohl das sichtbare Lichtspektrum als auch der Infrarotbereich genutzt werden. Analoge Luftbilder werden seit Jahren bei der Forstinventur (BUCK 2001, NAESSET und BJERKNES 2001), bei landschaftsplanerischen Fragestellungen (HORNFECK 2000) oder bei der Stadtkartierung (SEGL et al. 2003) verwendet. Sie dienen auch zur Unterstützung bei der bayernweiten Biotopkartierung (LFU 2003) und wurden z. B. für die Seeuferkartierung des Starnberger Sees erfolgreich eingesetzt (MELZER et al. 2001). Aktuell kommen Luftbilder im Rahmen des Kulturlandschaftsprogramms für die Ermittlung und Kontrolle von Fördermitteln zum Einsatz (AMMER 2004).

Meist werden Reihenaufnahmen mit senkrechter Aufnahmerichtung und einem bestimmten Überdeckungsgrad durchgeführt. Eine Überdeckung der Aufnahmen ist Voraussetzung für eine stereoskopische bzw. photogrammetrische Auswertung. Bei einer stereoskopischen Auswertung wird der räumliche Eindruck genutzt, um bei der Interpretation z. B. die Landnutzung genauer zu differenzieren. Im Zuge der zunehmenden elektronischen Datenverarbeitung erfolgte ein Übergang von der reinen stereoskopischen Auswertung (analoge Photogrammetrie) zur analytischen und in jüngster Zeit auch zur digitalen Photogrammetrie. Mit diesen Verfahren ist es möglich, Objekthöhen- und Höhendifferenzen einzumessen und entsprechende Oberflächen- und Geländemodelle digital herzustellen. Solche Oberflächenmodelle dienen oft als Grundlage für die Orthobildentzerrung. Dabei wird ein Luftbild differentiell von der Zentralperspektive auf eine orthogonale Projektion gebracht (KONECNY 1984). Analytische und digitale photogrammetrische Methoden sind in zunehmendem Maße integrale Bestandteile von Softwareapplikationen zur Geodatenprozessierung (z. B. PCI Geomatica oder Erdas Imagine) und liefern Informationsgrundlagen für Geographische Informationssysteme und Datenbanken. Bei regionalen bis globalen Fragestellungen wird das klassische Luftbild zunehmend durch digitale Aufnahmesysteme abgelöst (SCHNEIDER und ZIMMERMANN 2004). Dieser Trend setzt sich bis hin zur lokalen Maßstabsebene fort.

Bei **digitalen Aufnahmesystemen** wird die Erdoberfläche durch einen elektro-optischen Sensor erfaßt. In Abbildung 1 sind die grundsätzlichen Schritte eines Meßvorgangs durch einen Satellitensensor dargestellt.



**Abb. 1:** Prozeß eines fernerkundlichen Meßvorgangs. Das Sonnenlicht (A) dringt durch die Atmosphäre (B) und wird von der Erdoberfläche reflektiert (C). Das vom Satellitensensor (D) empfangene Rückstreusignal wird zur Bodenstation gesendet (E), weiterverarbeitet (F) und steht für Anwendungen (G) zur Verfügung (Abb. aus CCRS (2001), verändert).

Bei der elektro-optischen Fernerkundung wird das von der Erdoberfläche reflektierte Sonnenlicht (Abb. 1 (A, D)) gemessen und digital aufgezeichnet. Die solare Einstrahlung an der Erdoberfläche entspricht dem Anteil, der ungehindert durch die Atmosphäre dringt (Abb. 1 (B)). Komplexe Absorptions- und Streuvorgänge innerhalb der Atmosphäre spielen hier eine Rolle. Für das sichtbare Licht (0,3 nm bis 0,7 nm) ist die Atmosphäre weitgehend durchlässig. Trifft elektromagnetische Strahlung auf Materie (Abb. 1 (C)), so wird ein Teil davon reflektiert, ein Teil transmittiert und ein Teil absorbiert (wobei die Absorption gegebenenfalls die Emission von Strahlung anderer Wellenlänge anregt (Lumineszenz)). Diese Vorgänge sind abhängig von der Wellenlänge des eintreffenden Lichts und den spezifischen Eigenschaften des reflektierenden Materials. Die unterschiedliche Interaktion verschiedener Materialien mit dem Wellenspektrum bildet die Grundlage fernerkundlicher Wissenschaft. Die Grundannahme ist, daß Objekte einer Klasse bei gleichen Beleuchtungs- und Aufnahmebedingungen ähnliche Reflexionseigenschaften besitzen (SABINS 1997). Die spezifische Reflexion in Abhängigkeit von der Wellenlänge wird als **spektrale Signatur** bezeichnet. Der von der Bodenbedeckung reflektierte Teil des Sonnenlichts wird vom Sensor aufgezeichnet (Abb. 1 (D)). Die Meßwerte werden digital erfaßt und zu einer Bodenstation gesendet (Abb. 1 (E)). Dort werden die Rohdaten prozessiert und für weitere Analysen vorbereitet (Abb. 1 (F)). Für das Endprodukt, z. B. eine thematische Karte (Abb. 1 (G)), müssen die Daten entsprechend ausgewertet werden.

## 2.2 Visuelle Interpretation und Bildwahrnehmung

Fernerkundungsdaten sind meist Grundlage für die Anfertigung thematischer Karten. Sie sind in verschiedenen räumlichen, zeitlichen, spektralen und radiometrischen Auflösungen verfügbar. Ziel ist es, thematische Information aus diesen Datensätzen zu extrahieren. Diese Information wird in Landbedeckungs-/Landnutzungsklassen aufgeschlüsselt. Die Auswertung selbst erfolgt entweder digital mit statistischen Methoden durch einen Computer oder visuell durch einen Interpreten.

Die **visuelle Auswertung** von Luftbildern und Satellitendaten wird seit Jahrzehnten operationell durchgeführt. Durch Wissen und Erfahrung kann der Mensch Muster, Farbverläufe und Texturen deuten und zu einer Gesamtaussage verbinden. ALBERTZ (2001) nennt verschiedene Bildinhalte, die wichtig sein können, um eine Landbedeckungsklasse in einem Fernerkundungsdatensatz zu erkennen. Neben dem Farbton, der Form und der Größe einer Fläche, können auch die Textur oder Helligkeitsunterschiede zu einer benachbarten Fläche zu einer Unterscheidung beitragen.

Anders als bei einem Computer, wo Zusammenhänge im Zahlenraum eindeutig und ohne Interpretationsspielraum dargestellt werden, ist die Entscheidungsfindung eines Menschen subjektiv. Viele verschiedene Kriterien haben Einfluß und wenn versucht wird, diese Kriterien in Worte zu fassen bzw. ihnen eine Gewichtung zu geben, so kann die formulierte Beschreibung mehrdeutig sein oder anders interpretiert werden (BALTSAVIAS 2004).

Typisch für die visuelle Wahrnehmung ist, daß verschiedene Elemente eines Bildes unbewußt hervorgehoben und als reale Gegenstände wahrgenommen werden, während andere als unstrukturierter Hintergrund erscheinen. Die für eine spezifische Fragestellung relevanten Bildanteile werden von irrelevanten unterschieden (JAIN et al. 2000). Das menschliche Wahrnehmungssystem ist offenbar in der Lage, sich auf die informationstragenden Signale zu konzentrieren. ALBERTZ (1997) nennt solche stabilen Merkmale *Invarianten der visuellen Wahrnehmung*. So ist ein Baum im Gelände (nahezu) unabhängig von der Tageszeit und Lichtintensität immer als Baum erkennbar. Invariant sind hier vor allem die Konturen und Formen, d.h. wie sich der Baum gegen den Hintergrund abzeichnet: die visuellen Reize sind nicht willkürlich verteilt, sondern ergeben eine Struktur, die wir, teils unbewußt, mit unseren Erfahrungen und unserem Wissen abgleichen. „Passen“ die Reize ins Bild, so folgt die entsprechende Assoziation.

Aufgrund seiner Wahrnehmungsfähigkeit liefert der Mensch also qualitativ hochwertige Interpretationen. Er eignet sich allerdings wegen des hohen Aufwands nur mäßig dafür, große Datenmengen zu klassifizieren. Desweiteren ist das menschliche Urteilsvermögen eine kritische Komponente der Datenanalyse und immer abhängig von der Erfahrung des Interpreten (STRAND et al. 2002). Verschiedene Interpreten können zu unterschiedlichen Ergebnissen kommen. Deshalb ist diese Methode nicht vollständig objektiv und reproduzierbar (EHLERS et al. 2003). Nicht zuletzt aus diesen Gründen bestand eine der Herausforderungen der fernerkundlichen Analyse seit jeher in der Automatisierung des Interpretationsprozesses mit Hilfe eines Rechners. Die bisher verfügbaren automatischen Klassifikationsverfahren reichen im allgemeinen jedoch nicht an die Auswertequalität eines Menschen heran (COPPIN et al. 2004). Hinzu kommt die steigende Komplexität der abgebildeten Landschaftsstrukturen, die mit verbesserter räumlicher Sensorauflösung einher geht (FUNG und CHAN 1994). Da für Anwendungen auf Planungsebene räumlich sehr hochaufgelöste Daten notwendig sind (SCHNEIDER und ZIMMERMANN 2004), reichen die herkömmlichen, auf Bildpunktebene arbeitenden Auswertelgorithmen nicht mehr aus (DE KOK et al. 1999, SCHNEIDER und STEINWENDNER 1999). Um diese Methoden zu verbessern, gilt es zu verstehen, auf welche Weise ein Mensch einen Bilddatensatz wahrnimmt (JAIN et al. 2000, SCHNEIDER et al. 2000b).

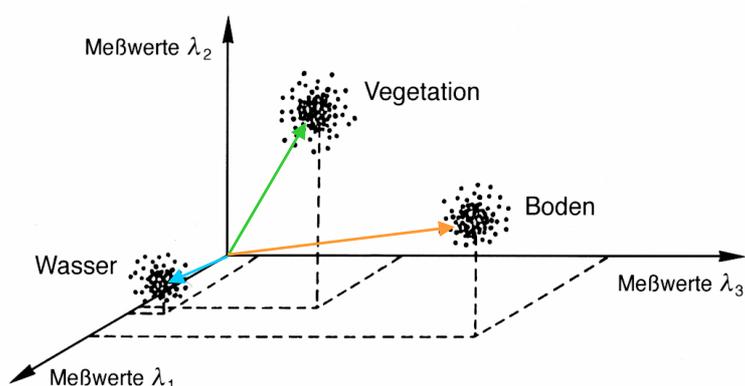
Zusammenfassend läßt sich feststellen, daß ein Mensch nicht unvoreingenommen an einen Bilddatensatz herangeht. Neben seinen wahrnehmungspsychologischen Werkzeugen verfügt er über verschiedene Arten von Vorinformation und Wissen. Dieses Wissen zu formalisieren, es in einer Rechnerumgebung umzusetzen und es nachvollziehbar zu strukturieren, sind die entscheidenden Schritte für die Automatisierung der Auswertung. Bislang sind diese Ansätze in der traditionellen Bildauswertung nicht verwirklicht.

## 2.3 Digitale Bildauswertung

Bei der digitalen Bildauswertung werden thematische Informationen automatisch durch einen Rechner aus einem Fernerkundungsdatensatz extrahiert. Dabei werden mathematisch-statistische Techniken angewendet, um eine symbolische Beschreibung der abgebildeten Landschaft zu erhalten (LILLESAND und KIEFER 2000). Ein Bilddatensatz stellt eine  $x \cdot y$  große Anordnung multivariater Bildpunkte dar (SWAIN et al. 1980). Der Bildpunkt oder Pixel ist dabei die elementare Analyseeinheit in der Fernerkundung (FISHER 1997), wobei sich seine Position durch eine  $x$ - und eine  $y$ -Koordinate exakt definiert. Er hat einen bestimmten Grauwert, der abstrakt die Reflexionseigenschaften des ihm entsprechenden Gebiets innerhalb eines bestimmten Spektralbereichs repräsentiert. Nach HILDEBRANDT (1996) ist davon auszugehen, daß unterschiedliche Landbedeckungstypen aufgrund ihrer physikalischen, chemischen und morphologischen Eigenschaften spezifische Wechselwirkungen mit elektromagnetischer Strahlung eingehen. Diese lassen sich in einer eindeutigen Reflexionsantwort beschreiben.

Traditionelle fernerkundliche Klassifikationsverfahren gehen von den Eigenschaften einzelner Bildpunkte aus. Mit verschiedensten mathematisch-statistischen Methoden wird die Merkmalsausprägung eines Bildpunktes bewertet und entsprechend einer Klasse zugewiesen. Einzelne Bildpunkte werden im klassischen Ansatz als voneinander unabhängige Elemente betrachtet (WOODCOCK und STRAHLER 1987). Ausgangspunkt der Klassifikation ist der **Merkmalsraum** (Abb. 2), dessen Dimension durch die Zahl seiner Merkmale bestimmt wird. JÄHNE (2002) versteht den Klassifikationsvorgang als Analyse der Strukturen im Merkmalsraum. Als Merkmale werden die numerischen Eigenschaften eines Bildpunktes herangezogen. Die Zuordnung eines Bildpunktes basiert auf diesen Merkmalen, die aus verschiedenen Quellen stammen können. Bei einer reinen spektralen Klassifikation entsprechen die Merkmale den Grauwerten der Bildpunkte aus den verschiedenen Spektralkanälen eines Systems. In diesem Fall besteht das Ergebnis der Klassifikation in Spektralklassen, da die Ermittlung der Klassen ausschließlich anhand der spektralen Merkmale erfolgt (RICHARDS und JIA 1999).

Werden die Reflexionswerte in einem dreidimensionalen Merkmalsraum betrachtet, so ergeben sich im Idealfall Punkteverteilungen, die geometrisch voneinander trennbar sind (Abb. 2).



**Abb. 2:** Der Merkmalsraum. Die Abbildung zeigt schematisiert eine mögliche Verteilung dreier Klassen in einem dreidimensionalen Merkmalsraum. Die Meßwerte  $\lambda_1$ ,  $\lambda_2$ ,  $\lambda_3$  entsprechen zum Beispiel Spektralkanälen. In Farbe sind beispielhaft drei Merkmalsvektoren dargestellt (Abb. aus ALBERTZ (2001), verändert).

Jeder Bildpunkt kann durch einen **Merkmalsvektor** beschrieben werden (Abb. 2). Dieser Vektor charakterisiert durch seine Länge und seine Winkel zu den Achsen des Merkmalsraums eindeutig die

Position eines Bildpunktes im Merkmalsraum. Dabei fallen die Meßpunkte einer Klasse nicht auf denselben Punkt, sondern sind in einer Punktwolke verteilt. Dies hat viele Ursachen, wie etwa die natürliche Varianz der Bodenbedeckung, atmosphärische Einflüsse oder das Rauschen des Aufnahmesystems. Auf die Instabilität des Fernerkundungssignals wird ausführlich in Kapitel 3.5.1 eingegangen.

Generell sind **parametrische** und **nicht-parametrische Klassifikationsverfahren** zu unterscheiden. Bei parametrischen Verfahren wird davon ausgegangen, daß die Klassen im Merkmalsraum eine bestimmte Verteilungsfunktion aufweisen, also einer mathematisch ermittelbaren Häufigkeitsverteilung entsprechen. Die Klassifikation basiert auf statistischen Kenngrößen, die diese Häufigkeitsverteilung beschreiben. Das sind unter anderem Mittelwert, Varianz, Kovarianz, sowie Minimum und Maximum der Referenzflächen im Merkmalsraum. Diese bilden die rechnerische Grundlage für die zu ermittelnden Klassen.

Neben den Spektralkanälen können auch weitere digitale Informationsebenen zum Merkmalsraum hinzugefügt und zur Klassifikation genutzt werden. Beispiel hierfür sind gerechnete Textur-Kanäle (SIEGERT und HOFFMANN 2000), Höhenmodelle (NAESSET und BJERKNES 2001) oder Kartenwerke (BALTSAVIAS und HAHN 2000).

Viel Forschungsarbeit wurde auch bei der Berechnung und Anwendung von **Vegetationsindizes** geleistet (DEFRIES et al. 1995, RAHMAN et al. 2003). Sie basieren durchweg auf der arithmetischen Kombination von Spektralkanälen. In dieser Arbeit wurde der NDVI (*Normalized Difference Vegetation Index*) verwendet (Kap. 6.1). Es gilt als der Klassiker unter den Vegetationsindizes und verknüpft die Reflexion aus dem nahen Infrarot-Bereich (NIR) und dem roten Spektralbereich. Mit dem NDVI läßt sich lebende Vegetation von unbewachsenen oder mit abgestorbener Vegetation bedeckten Flächen unterscheiden (HILDEBRANDT 1996). Zudem gibt dieser Index Hinweise auf Biomasse und Vitalität der Pflanzendecke (SCHNEIDER et al. 2000b). Der NDVI berechnet sich nach Formel 1.

**Formel 1:** NDVI. Der Vegetationsindex errechnet sich aus der Differenz aus nahem Infrarot-Band (Kanal 4 bei IKONOS) und dem Rot-Band (Kanal 3 bei IKONOS), geteilt durch die Summe aus dem nahen Infrarot-Band und dem Rot-Band.

$$NDVI = \frac{(NIR_{(4)} - Rot_{(3)})}{(NIR_{(4)} + Rot_{(3)})}$$

Auch zeitliche Aspekte können in die Klassifikation miteinbezogen werden. Bei diesen Ansätzen wird von einer multitemporalen Analyse gesprochen. Der Merkmalsraum setzt sich hier nicht nur aus den Daten eines Aufnahmezeitpunkts zusammen. Vielmehr werden Daten analysiert, die von verschiedenen Aufnahmezeitpunkten stammen. Jeder Bildpunkt enthält also die spektralen Merkmale unterschiedlicher Zeitpunkte. Dieser Ansatz kann in zwei Kategorien eingeteilt werden, der **multitemporale** (1) und der **multisaisonale** (2) Ansatz:

1. **Multitemporal:** um Veränderungen festzustellen. der Vergleich neuer und älterer Daten eignet sich sehr gut, um Veränderungen der Landbedeckung zu dokumentieren (COPPIN et al. 2004) und daraus zukünftige Entwicklungstendenzen abzuleiten (MOTT et al. 2004a).
2. **Multisaisonal:** um Klassen genauer zu differenzieren, also um die thematische Auflösung zu erhöhen. Vegetation verändert ihr phänologisches Erscheinungsbild im Lauf der Vegetationsperiode und besitzt deshalb verschiedene Reflexionseigenschaften, je nachdem ob die

Rückstrahlung am Anfang (z. B. im laublosen Zustand) oder auf dem Höhepunkt der Vegetationsentwicklung gemessen wird.

Die Erweiterung des Merkmalsraums um die zeitliche Komponente liefert also zusätzliche Unterscheidungskriterien, um Klassen genauer zu differenzieren und Veränderungen festzuhalten. Allerdings wurden diese Auswerteverfahren nach COPPIN (2004) bisher meist auf Bildpunktebene durchgeführt. Grundsätzlich lassen sich bildpunkt-basierte Klassifikationsverfahren in zwei Gruppen einteilen: **unüberwachte** und **überwachte Klassifikation**.

### 2.3.1 Unüberwachte Klassifikation

Bei der unüberwachten Klassifikation, auch Clusteranalyse genannt, wird der Merkmalsraum ohne Vorwissen auf spektrale Ähnlichkeit untersucht. Eine genaue Kenntnis der gesuchten Klassen ist nicht notwendig und es werden **keine Trainingsgebiete** verwendet, die als Referenz für den Algorithmus dienen. Jeder Bildpunkt wird der Klasse zugewiesen, zu welcher er die größte spektrale Ähnlichkeit aufweist (JÄHNE 2002). Die thematische Bedeutung dieser Klassen muß während des Klassifizierungsvorgangs nicht bekannt sein. BRUZZONE und PRIETO (2000) schlagen die unüberwachte Vorgehensweise vor, wenn keine genauen Felddaten vorliegen, um Trainingsgebiete auszuweisen. Der Vorteil dieser Herangehensweise kann auch darin bestehen, Klassen zu finden, von deren Existenz der Bearbeiter nichts weiß. Voraussetzung ist nur, daß sich die gesuchten Klassen statistisch im Merkmalsraum voneinander trennen lassen. JÄHNE (2002) stuft die unüberwachte Methode als objektiver ein, verglichen mit dem überwachten Ansatz, weil die subjektive Auswahl der Trainingsgebiete durch einen Bearbeiter entfällt. Die am häufigsten verwendeten unüberwachten Auswertelgorithmen sind der ISODATA-, der *k*-means- und der *Quick-Partitioning*-Algorithmus (BALL und HALL 1967, LEICA GEOSYSTEMS 2002a).

### 2.3.2 Überwachte Klassifikation

Die überwachte Klassifikation faßt Methoden zusammen, bei welchen der Analyst vor dem eigentlichen Rechenschritt **Trainingsgebiete** für jede gesuchte Klasse definiert. Die Anzahl und der Typ der gesuchten Klassen werden vor der Klassifikation festgelegt. HILDEBRANDT (1996) betont, daß die Variabilität der Erscheinungsformen der Landbedeckung und die sich daraus ergebende Varianz der Spektralwerte durch die Trainingsgebiete erfaßt werden sollten. Seitens des Bearbeiters ist also eine genaue Kenntnis über die Lage und Art der Trainingsgebiete in einem Untersuchungsgebiet notwendig. Die Qualität der Klassifikation steht und fällt mit der Qualität der Wahl der Trainingsgebiete. Diese Auswahl stellt dementsprechend einen sehr sensiblen Schritt dar (BÄHR und VÖGTLE 1998). Was häufig unerwähnt bleibt, ist die subjektive Komponente, welche durch die Wahl der Trainingsgebiete in eine Klassifikation einfließt. Ähnlich einem visuellen Interpretieren sucht der Bearbeiter aufgrund seines Vorwissens bzw. seiner Feldkenntnis passende Gebiete aus.

Die Merkmale der Trainingsgebiete sind die Entscheidungsgrundlage des Klassifikationsalgorithmus. Für jede Klasse werden mit mathematisch-statistischen Methoden aus dem Merkmalsraum ähnliche Bildpunkte ermittelt. Die bekanntesten überwachten Auswertelgorithmen sind der *BOX*-Klassifikator, der *Maximum-Likelihood*-Klassifikator und der *Minimum-Distance*-Klassifikator (SCHNEIDER et al. 2000b). Zahlreiche Arbeiten bestätigen gute Ergebnisse dieser Verfahren bei mittel bis niedrig aufgelösten Fernerkundungsdaten (DEFRIES et al. 1995). Das *Spectral-Angle-Mapper*-Verfahren, das vor allem bei hyperspektralen Daten verwendet wird (CROSTA et al. 1998), nutzt die numerischen

Eigenschaften eines Merkmalsvektors als Maß für die Berechnung der Klassenzugehörigkeit. Die Verfahren der überwachten und unüberwachten Klassifikation werden seit Jahrzehnten angewandt, weiterentwickelt und sind eingehend beschrieben (LILLESAND und KIEFER 2000, JÄHNE 2002).

Wenngleich bildpunktbasierter statistische Klassifikatoren in vielen Bereichen gute Ergebnisse liefern, ist dieser Ansatz für bestimmte Anwendungen oder Datentypen ungeeignet. Verschiedene Probleme, die mit der Natur des fernerkundlichen Prozesses und der abgebildeten Bodeninformation zusammenhängen, lassen sich nur unzureichend bearbeiten. Wie bereits erwähnt, stoßen die traditionellen Methoden vor allen Dingen bei der Klassifikation hochauflösender Fernerkundungsdaten an ihre Grenzen.

## 2.4 Grenzen bildpunktbasierter Klassifikationsverfahren

Fortschritte in der Sensortechnologie führen zur Entwicklung von geometrisch, radiometrisch und spektral immer höher auflösenden Fernerkundungsdaten. Mit dem Start der Satellitensysteme IKONOS (1999) und QuickBird (2002) ist die Technik in Auflösungsbereiche von unter einem Meter vorgedrungen. Bislang war eine solche Auflösung nur Luftbildern, oder flugzeuggetragenen elektrooptischen Sensoren vorbehalten. Die verbesserte Auflösung bringt aber auch Erschwernisse mit sich. Laut ZADEH (1973) nimmt die Genauigkeit der Aussagen über ein System ab, wenn seine Komplexität zunimmt. SCHNEIDER und ZIMMERMANN (2004) übertragen diese Erkenntnis direkt auf die technologische Entwicklung der Sensoren und folgern daraus, daß bei der automatischen Auswertung verstärkt Schwierigkeiten auftreten.

EHLERS et al. (2003) betrachten einen Datensatz als hochauflösend, wenn einzelne, real existierende Objekte sich aus mehreren Bildpunkten zusammensetzen. Dementsprechend bedeutet niedrigauflösend, daß sich das Signal eines Bildpunktes aus verschiedenen realen Objekten zusammensetzt. Was als reales Objekt gilt, ist abhängig vom Betrachtungsmaßstab und der Fragestellung (WOODCOCK und STRAHLER 1987). In einem einzigen Landsat-TM-Bildpunkt (30 m \* 30 m), der ein Siedlungsgebiet abbildet, kann beispielsweise die Reflexion eines Hausdachs, einer Straße und eines Vorgartens enthalten sein. In einer hochauflösenden IKONOS-Aufnahme (1 m \* 1 m) wird die gleiche Fläche mit 900 Bildpunkten erfaßt: Vorgärten, Straßen und Hausdächer sind hier räumlich aufgelöst. Die Klasse „Siedlungsgebiet“ enthält also im IKONOS-Datensatz eine Vielzahl verschiedener Reflexionssignale. Zahlreiche Studien belegen, daß Klassifikationsalgorithmen, die ausschließlich auf der statistischen Auswertung unabhängiger Bildpunkte beruhen, Schwierigkeiten haben, hochauflösende Bilddaten komplexer Landschaften zu klassifizieren (GURNEY und TOWNSHEND 1983).

Insbesondere mittel und grob auflösende Daten enthalten **Mischpixel**. Das sind Bildpunkte, die zu mehr als einer Klasse gehören, also Reflexionsanteile von verschiedenen Klassen enthalten. Mischpixel treten immer dann auf, wenn sich die Grenzbereiche der gesuchten Klassen innerhalb eines Bildpunktes überlappen (WOODCOCK und STRAHLER 1987). Die natürlichen Übergänge einer Landbedeckung sind oft nicht scharf, was besonders bei der klein strukturierten Landschaft Europas zu zahlreichen Mischpixeln führt (SCHNEIDER et al. 2000b). Bei der Verwendung „harter“ Klassifikatoren wird jeder Bildpunkt exakt einer Klasse zugewiesen (FOODY 2000). Es gilt die Annahme, daß jeder Pixel in einem Datensatz das reine Signal nur eines Landbedeckungstyps repräsentiert (MELGANI et al. 2000) und die räumliche Ausprägung dieser Landbedeckung exakt durch einen Bildpunkt dargestellt werden kann (FISHER 1997). Daß natürliche Landbedeckung meist von Übergängen und Verläufen geprägt ist, wird hier völlig außer acht gelassen. Mischpixel stellen in

diesem Zusammenhang ein Problem bei der Bewertung der Klassifikationsgenauigkeit dar. Manche der festgestellten Fehler könnten sich als richtig herausstellen, wie umgekehrt einige der richtig klassifizierten Pixel teilweise falsch sein könnten. Bei einer Genauigkeitsanalyse wird dieser Aspekt meist nicht beachtet (FOODY 2002). Das Entmischen von Bildpunkten ist daher Gegenstand zahlreicher Arbeiten. Bei solchen Verfahren wird versucht, in komplexen Modellierungsprozessen Informationen über die Zusammensetzung der Bodenbedeckungstypen innerhalb eines Bildpunktes zu gewinnen (GROSS und SCHOTT 1998, FOODY 2000).

Im theoretischen Idealfall fallen Pixel einer Landnutzungs- oder Landbedeckungsklasse im Merkmalsraum aufeinander (KARTIKEYAN et al. 1994). In der Praxis ist dies allerdings selten so eindeutig der Fall, denn jede natürliche Bodenbedeckung variiert in ihrem Erscheinungsbild. Bildpunkte einer Klasse sind oft über den gesamten Merkmalsraum verteilt, was in der spektralen Varianz im Merkmalsraum zum Ausdruck kommt. Diese spektrale Varianz hängt ab von der Sensorauflösung und von der Komplexität der Landbedeckung (FUNG und CHAN 1994). Je höher die Sensorauflösung und je komplexer die Landbedeckung, desto mehr Einzelsignale einer Landbedeckungsklasse werden erfaßt und desto höher ist die spektrale Varianz dieser Klasse (KENNEWEG et al. 1991). Da die meisten konventionellen Klassifikationsmethoden rein auf statistischen Kenngrößen einzelner Bildpunkte beruhen, spielt in diesem Zusammenhang die Varianz der Bildpunkte eine wichtige Rolle. Stark gestreute Klassen überlappen im Merkmalsraum. In diesen Fällen ist eine Klassifikation allein anhand statistischer Klassifikationsmethoden nur ungenau möglich.

KARTIKEYAN et al. (1994) gliedern die Varianz einer Klasse in zwei Kategorien, in **klassenabhängige** und **klassenunabhängige Varianz**:

- Die **klassenabhängige Varianz** ist bedingt durch die Heterogenität natürlicher Bodenbedeckung. Die Verteilung und Dichte der Einzelobjekte auf der Erdoberfläche spielen hier die entscheidende Rolle. So können Bäume in einem Wald beispielsweise unterschiedlich dicht stehen oder eine unterschiedliche Artenzusammensetzung aufweisen, was jeweils zu einer anderen Signatur führt.
- Die **klassenunabhängige Varianz** ist bedingt durch externe Einflüsse, wie Sensorrauschen, atmosphärische Interferenzen oder verschiedene Aufnahmecharakteristika von Sensoren.

Technisch gesehen bedeutet eine Verbesserung der Auflösung, daß eine geringere Menge des reflektierten Lichtes pro Bildpunkt aufgenommen werden kann. Die endliche Menge an Photonen, die von einem Objekt reflektiert wird, muß also in immer kleineren „Portionen“ erfaßt werden. Bei einer Verbesserung der Auflösung von 30 m \* 30 m (z. B. Landsat-TM) auf 1 m \* 1 m (z. B. IKONOS) kann der Sensor theoretisch nur noch 0,11 % (1 / 900) der Energie empfangen. Bislang sind lediglich Silizium-Sensoren empfindlich genug, um bei diesen relativ schwachen Reflexionen noch ein passables Verhältnis von Signal zu Rauschen zu erhalten. Allerdings sind diese Sensoren technisch auf Messungen im sichtbaren bis nahen Infrarot-Bereich begrenzt. Zusätzlich muß die Bandbreite der Spektralkanäle relativ groß gewählt werden. Dies führt zu einer vergleichsweise geringen spektralen Detailtiefe. Sehr hochauflösende, weltraumgestützte Systeme wie IKONOS oder QuickBird beschränken sich daher auf den sichtbaren bis nahen Infrarotbereich. Das bedeutet, daß Auswertansätze sich nicht allein auf den spektralen Informationsgehalt verlassen dürfen, um den vollen Informationsgehalt dieser Daten auszuschöpfen. Dies gilt noch viel mehr für Schwarz/Weiß-Luftbilder, in denen nur eine einzige Grauwertebene vorliegt. Um das Informationspotential hochauflösender Fernerkundungsdaten auszuschöpfen, muß deshalb das Umfeld eines Pixels (Kontext) mitbetrachtet werden.

## 2.5 Bedeutung des Pixel-Umfelds (Kontext)

Wenn die Bildpunktgröße kleiner ist als die Größe der beobachteten Objekte, dann nimmt die räumliche Autokorrelation zu (WOODCOCK und STRAHLER 1987). Es steigt die Wahrscheinlichkeit, daß ein Nachbapixel zur selben Klasse gehört, wie das betrachtete Pixel. Das bedeutet, daß die Bezugnahme auf das räumliche Umfeld eines Bildpunktes - oder seinen Kontext - wichtig ist (GURNEY und TOWNSHEND 1983, EHLERS et al. 2003).

Viele Landnutzungsklassen können durch Beachtung ihres räumlichen Umfeldes besser beschrieben werden. ATKINSON und LEWIS (2000) stellen in diesem Zusammenhang fest, daß die traditionellen Klassifikationsverfahren meist die potentiell sehr aufschlußreichen räumlichen Zusammenhänge benachbarter Bildpunkte ignorieren.

GURNEY und TOWNSHEND (1983) unterscheiden zwei Ansätze, um Kontextinformationen zu extrahieren:

1. Der direkte **texturelle Ansatz** bezieht sich auf die Grauwertvariationen einer endlichen Gruppe von Pixeln in der Nachbarschaft oder in der Nähe eines Bildpunktes.
2. Der **kontextuelle Ansatz** beschreibt die semantischen Beziehungen einzelner Bildpunkte zueinander, die innerhalb eines Datensatzes existieren.

zu 1) **Textureller Ansatz**: die einfachste Methode, um den räumlichen Kontext bei einer Klassifikation miteinzubeziehen, ist die Berechnung künstlicher Textur-Kanäle, welche dann bei der Klassifikation zum Merkmalsraum hinzugefügt werden. Unter Textur ist die Strukturierung einer Fläche zu verstehen, die sich aus ihren Material- und Oberflächeneigenschaften ergibt. Textur an sich kann als räumliches Muster von Grauwerten in einem Datensatz verstanden werden (RYHERD und WOODCOCK 1996). Diese räumlichen Muster sind in der Regel in der natürlichen Ausprägung einzelner Klassen vorhanden (TILTON et al. 1982).

Ein Texturkanal wird üblicherweise über ein Filterfenster definierter Größe berechnet. Dieser Filter bewegt sich über den gesamten Datensatz und weist jeweils dem Bildpunkt in der Mitte des Fensters einen Wert zu, welcher sich aus der Zusammensetzung der Grauwerte innerhalb des Fensters errechnet (GUINDON 1997). Im einzelnen gibt es zahlreiche Methoden dafür, auf welche Art und Weise ein Textur-Wert berechnet werden kann. Eine ausführliche Übersicht zu verschiedenen Texturarten geben HARALICK et al. (1973). Jeder neu gerechnete Textur-Kanal wird dem Merkmalsraum zugefügt und gibt so Auskunft über die Umgebung eines Bildpunkts, abhängig von der Größe des Filterfensters. Diese einfache Methode der Integration von räumlicher Umgebungsinformation hat sich in zahlreichen Arbeiten als erfolgreich erwiesen (SIEGERT und HOFFMANN 2000). HARALICK und JOO (1986) geben allerdings zu bedenken, daß sich die Auflösung eines Datensatzes durch die Textur-Filterung verringert und deshalb Strukturen nicht mehr so fein aufgelöst werden können. WOODCOCK und STRAHLER (1987) empfehlen die Nutzung von Textur bei der Klassifikation sehr stark gestreuter Klassen wie Siedlungsgebiete oder Waldbestände.

zu 2.) **Kontextueller Ansatz**: die Klassifikation eines Bildpunkts wird hier unter Bezugnahme auf andere Bildpunkte innerhalb des Datensatzes durchgeführt. Klassen werden über ihre räumlichen Beziehungen beschrieben, die in syntaktischen Regeln formuliert werden (TILTON et al. 1982). Nicht nur die spektrale Ausprägung eines Bildpunktes wird hier betrachtet, sondern auch die gefundenen Klassen in seiner Nachbarschaft (SWAIN et al. 1980). TILTON et al. (1982) halten fest, daß bestimmte Landbedeckungsklassen in bestimmten Zusammenhängen häufiger bzw. seltener vorkommen als in

anderen. Die Klassifikation eines Bildpunktes kann theoretisch in Abhängigkeit jedes anderen Bildpunktes durchgeführt werden. Durch einen solchen Ansatz lassen sich nicht nur Fehlklassifikationen vermeiden, sondern auch neue Klassen ableiten, indem Spektralklassen zusätzlich nach ihrem Kontext unterteilt werden (GURNEY und TOWNSHEND 1983). Dieser Vorgang ist der menschlichen Bildwahrnehmung sehr ähnlich. So läßt sich beispielsweise ein Siedlungsgebiet als Mosaik verschiedener Elemente beschreiben. Die Einzelelemente Häuser, Straßen, Rasen, Autos und Bäume sind Inhalt der Klasse Siedlungsgebiet. Diese Vorgehensweise entspricht im eigentlichen Sinne der Integration von Wissen und Erfahrung in den Klassifikationsprozeß.

Die in dieser Arbeit angewandte objektorientierte Methode nutzt sowohl die Möglichkeiten des **texturellen** als auch des **kontextuellen** Ansatzes. Die **Textur** wird hier allerdings nicht über ein Filterfenster gerechnet, sondern aus den Grauwertvariationen innerhalb eines Bildobjektes abgeleitet. Verschiedenste Texturtypen sind im Rahmen des objektorientierten Ansatzes mit eCognition einsetzbar. Die Berücksichtigung des **Kontextes** wird bei der vorliegenden Studie über topologische Beziehungen eines Bildobjektes zu anderen Klassen implementiert. Das Wissen des Experten über das Vorkommen einer Klasse in bestimmten Zusammenhängen kann mit der objektorientierten Methode effizient modelliert werden. Dieser Ansatz kann damit als wissensbasierte Auswertemethode eingeordnet werden und bietet somit eine Möglichkeit, der Komplexität im Umgang mit hochauflösenden Daten angemessen Rechnung zu tragen. Zu Recht steht daher die Entwicklung wissensbasierter Bildauswertemethoden im Vordergrund aktueller Forschung.

## 2.6 Wissen und wissensbasierte Bildanalyse

Bildinterpretation ist mehr, als nur die Grauwerte eines Bildpunktes auszuwerten. ARGIALAS und HARLOW (1990) fordern für automatisierte Klassifikationsverfahren die Identifizierung von räumlichen Mustern, sowie die Bezugnahme auf Wissen und Erfahrung. Diese Erkenntnis hat zur Entwicklung wissensbasierter Bildanalysemethoden geführt. Dabei ist Wissen definiert als „*Inbegriff von rationalen Kenntnissen*“, die sich durch Beobachtung, Erfahrung und Aneignung von Wissensstoff bilden (BROCKHAUS 1985). Wissensbasierte Systeme integrieren verschiedenste Formen des Wissens in den Auswerteprozeß. JAIN et al. (2000) nennen neben der Fernerkundung verschiedene Bereiche, wie Biologie, Medizin oder Industrie, in welchen diese Verfahren der Bildanalyse erfolgreich genutzt werden.

Grundsätzlich muß zwischen existierendem „Wissen“ in Form von digitalen Daten (**1. Fall**) und dem Wissen eines Bearbeiters oder Experten (**2. Fall**) unterschieden werden. Digitale Daten sind in diesem Zusammenhang Datensätze mit räumlichem Bezug und thematischer Information. Dies können z. B. Landnutzungskarten im Vektorformat oder digitale Geländemodelle im Rasterformat sein. Klassischerweise wird dieser Datentyp in GIS-Systemen verwaltet.

Im **ersten Fall** kommen synergistische Effekte durch die kombinierte Auswertung von Fernerkundungsdaten und bereits bestehenden digitalen Daten zustande. Diese Vorgehensweise wird mit dem englischen Begriff *data fusion* bezeichnet, was soviel wie eine „integrierte Wissensverarbeitung“ unterschiedlicher Informationsquellen bedeutet.

Im **zweiten Fall** geht es um die Modellierung menschlichen Wissens innerhalb eines Bildauswertesystems, wie es im Forschungsgebiet der „Künstlichen Intelligenz“ eingesetzt wird. Das **Wissen eines Experten** wird bei diesem Ansatz in einer Rechnerumgebung abgebildet.

## 2.6.1 *Data fusion* oder integrierte Wissensverarbeitung

Die integrierte Auswertung von Fernerkundungs- und GIS-Daten ist bereits seit einigen Jahren ein intensiver Gegenstand der Forschung. EHLERS fordert schon 1989 ein Zusammenwachsen der GIS- und Fernerkundungsgemeinden. Nach BALTSAVIAS und HAHN (2000) läßt sich das Zusammenspiel von GIS-Daten und Bildverarbeitungsmethoden der Fernerkundung in drei Bereiche gliedern:

1. **GIS-Daten, die als *a-priori* Information genutzt werden, um einen Bildszene oder einen Suchraum einzuschränken.** HUTCHINSON (1982) beschreibt diesen Ansatz als Stratifizierung. Thematische Information wird verwendet, um irrelevante Bereiche auszumaskieren und nur in Bereichen zu klassifizieren, in welchen die gesuchten Klassen potentiell auftreten können. ANDRESEN et al. (2004) verwendeten beispielsweise bestehende Biotopgrenzen, um gezielt innerhalb ökologisch sensibler Bereiche zu klassifizieren und Feuchtvegetation hochgenau zu detektieren.
2. **Bildprozessierungsmethoden, die auf GIS-Daten angewendet werden.** Dies gilt insbesondere für Raster-GIS-Daten. So kann z. B. die Berechnung der Hangneigung aus einem digitalen Geländemodell erfolgen, wie dies BUCK (2001) beschrieben hat.
3. **Integrierte Auswertung von GIS- und Fernerkundungsdaten.** In diesem Fall werden die GIS- und Fernerkundungsdaten in direkten Zusammenhang gestellt und gemeinsam ausgewertet. Die GIS-Daten wirken hier als unterstützendes Element der Bildverarbeitung.

Für BALTSAVIAS und HAHN (2000) stellt diese dritte Möglichkeit die interessanteste dar. Es geht dabei um die verknüpfte Auswertung von Daten, die aus unterschiedlichen Quellen stammen. Das Ziel dabei ist, Informationen in besserer Qualität zu erhalten, als dies bei isolierter Betrachtung der einzelnen Quellen möglich ist.

Besondere Bedeutung gewinnt die Integration von GIS-Daten bei fernerkundlichen Auswertungen für die Aktualisierung von Landnutzungsdaten bzw. für die Feststellung von Veränderungen (SMITS und ANNONI 1999). Hier ergibt sich auch ein wirtschaftlich interessantes Einsatzfeld, da ein großer Bedarf an aktuellen Landnutzungsdaten für behördliche Datenbestände herrscht (ARZET 2004). Geltende administrative Einheiten (z. B. Grenzen von Fauna-Flora-Habitat-Gebieten oder Naturschutzgebieten) können auf diese Weise direkt bei der Analyse miteinfließen, überprüft und aktualisiert werden. Verschiedenste Rahmen und Ansätze wurden für diesen Zweck entwickelt (DE KOK et al. 1999, BUCK 2001, EHLERS et al. 2003).

Da „Landkarten“ von Untersuchungsgebieten oft schon existieren, sollten sie auch bei der Auswertung von Fernerkundungsdaten genutzt werden (TON et al. 1991). In der Praxis bereitet allerdings die Umsetzung oft Schwierigkeiten (BOLSTAD und LILLESAND 1992). Die kombinierte Auswertung wird dadurch erschwert, daß in einer GIS-Umgebung digitale Karten als Vektordaten verwaltet werden, die sich weniger gut für eine Fusion mit Rasterdaten eignen (BENZ et al. 2004). Moderne Bildanalyseapplikationen wie eCognition von der Definiens (BAATZ et al. 2002) oder der *Expert Classifier* von ERDAS Imagine (LEICA GEOSYSTEMS 2002a) erlauben jedoch die Integration von vektorialen GIS-Daten bei der Analyse von Fernerkundungsdaten.

Vielfach werden auch die gegebenen Möglichkeiten nicht ausreichend ausgeschöpft (BALTSAVIAS und HAHN 2000). Häufig ist der Entstehungsprozeß von Geodaten nicht ausreichend dokumentiert. Das bedeutet, daß sowohl Aussagen über die geometrische als auch über die thematische Genauigkeit fehlen. TRODD (1995) bemerkt, daß für 84 Klassifikationen in 25 veröffentlichten Studien in nur 60 %

der Fälle eine Konfusionstabelle angegeben war und bei 8 % Genauigkeitsangaben vollständig fehlten. Denkbar ist auch, daß die Daten zu einer anderen Fragestellung erfaßt wurden und eine andere thematische Gewichtung vorliegt. Sofern externe Daten fehlerhaft sind, muß sich der Bearbeiter bewußt sein, daß sein Ergebnis den Fehler weiterführt. Wie EHLERS et al. (1991) feststellen, ist auch das Daten-Format manchmal nicht verlustfrei übertragbar und kann zu Inkonsistenzen führen. Ausführliche Angaben darüber, wie ein Datensatz gewonnen wurde und welche Rahmenbedingungen für eine Studie galten (Information über Fragestellung, Dokumentation der Prozesse und mögliche Schwierigkeiten), sind notwendig, um eine reibungslosere Integration von GIS- und Fernerkundung zu ermöglichen. Im Rahmen dieser Arbeit wurde eine Fallstudie durchgeführt, bei welcher GIS- und Fernerkundungsdaten integriert ausgewertet wurden. Die Ergebnisse dieser Teilstudie sind in Kapitel 6.3 beschrieben.

Während es sich bei thematischen GIS-Daten um digitale Informationen handelt, welche bereits in einer dem Rechner verständlichen Form vorliegen, ist die Integration und Modellierung menschlichen Wissens eine wesentlich komplexere Aufgabe.

## 2.6.2 Das Wissen des Experten

Bei der visuellen Interpretation von Bilddaten wird der Betrachter von einer Vielzahl von intrinsischen und extrinsischen Eindrücken geleitet. Sein Wissen und seine Erfahrung steuern diesen Vorgang. Während die visuelle Wahrnehmung in Kapitel 2.2 behandelt wurde, soll hier auf das Wissen eingegangen werden, welches letztendlich zu einer Entscheidung führt.

Das Wissen eines Menschen läßt sich in verschiedene Bereiche gliedern. STREIT (1999) unterscheidet im wesentlichen zwei Arten:

1. **Theoretisches Wissen:** Wissen in Form von Fakten, Zahlen, Gesetzmäßigkeiten und Verfahrensregeln. Es wird bewußt und gezielt erworben und ist relativ leicht formalisierbar.
2. **Praktisches Wissen:** vages Wissen, das sich auf Erfahrungswerte stützt und auf Erkenntnisse, die sich zum Lösen eines Problems bereits bewährt haben. Diese Art von Wissen in Regeln zu fassen ist deutlich schwieriger.

Die zwei Wissenskategorien gehen in der Praxis häufig ineinander über und lassen sich nur schwer voneinander trennen, denn der Mensch beurteilt eine Situation intuitiv nach seinem theoretischen und praktischen Wissensschatz.

Neben dem Wissen des Experten sind manche Beziehungen und Eigenschaften durch den „gesunden“ Menschenverstand erfaßbar, also durch **Alltagswissen**. So stellt zum Beispiel die Annahme, daß in unmittelbarer Nähe eines Hauses mit hoher Wahrscheinlichkeit auch ein Weg oder eine Straße liegt, Alltagswissen dar. Diese Art von Wissen ist Teil der täglichen Wahrnehmung unserer Umwelt. Es wird im allgemeinen unbewußt erworben und läßt sich nur schwer formalisieren. Es fällt auch Experten manchmal schwer, genau zu erläutern, welches Merkmal ausschlaggebend für die Entscheidungsfindung war und wie die einzelnen Merkmale zueinander gewichtet wurden (BINAGHI et al. 1997). Selbst wenn sich diese Gewichtung in Worten formulieren läßt, ist dies auf einem Rechner, der allein mit Zahlen und genau beschriebenen Zusammenhängen arbeitet, nur schwer nachzuvollziehen. Obschon das *fuzzy logic*-Konzept hilft, Informationen „weicher“ zu verknüpfen, ist das Problem der Entscheidungsfindung nicht gelöst.

**Expertenwissen** geht wesentlich weiter als das Alltagswissen. Ein Förster weiß, daß die Baumart Fichte kühle und luftfeuchte Lagen mit mindestens 600 mm Niederschlag bevorzugt oder daß in unmittelbarer Nähe von offenen Moorflächen die Wahrscheinlichkeit des Vorkommens von Moorbirken oder Spirken hoch ist. Ein Fernerkundungsexperte weiß, daß eine Feuchtwiese aufgrund der ständigen Vernässung des Bodens eine relativ niedrige Reflexion im nahen Infrarot aufweist. Ein Landwirt kennt den phänologischen Kalender seiner Region. Er weiß genau, zu welchem Zeitpunkt und auf welchem Bodentyp eine bestimmte Ackerfrucht angebaut werden kann. Welche spektralen Reflexionseigenschaften die Ackerfrüchte wiederum aufweisen, liegt im Wissensspektrum des Fernerkundungsexperten. Diese Beispiele sollen die Vielfältigkeit der verschiedenen Arten von Fachwissen verdeutlichen und die Schwierigkeiten herausstellen, die damit verbunden sind, dieses Wissen zu sammeln und zu integrieren. FERRIER und WADGE (1997) beschreiben den Prozeß des Wissenserwerbs als Flaschenhals und Hauptschwierigkeit beim Aufbau eines wissensbasierten Auswertesystems. BALSAVIAS (2004) dagegen sieht in der „Verschwommenheit“ des menschlichen Wissens und seiner entsprechenden Repräsentation in einer Rechnerumgebung eine der ungelösten Schlüsselfragen.

Der in dieser Arbeit untersuchte objektorientierte Ansatz ist als wissensbasierte Analyse- und Bewertungsmethode zu betrachten. In der verwendeten Software eCognition kann die Beschreibung einer Klasse und die Modellierung von Wissen in Form von übersichtlichen Produktionsregeln<sup>1</sup> formuliert werden. Diese Produktionsregeln können die spektralen Eigenschaften einer Klasse beschreiben, auf digitale Zusatzinformation aus GIS-Daten (Kap. 2.6.1) zurückgreifen und auch kontextuelle und topologische Zusammenhänge der Bildobjekte zueinander (Kap. 3.5) definieren.

---

<sup>1</sup> Wissensrepräsentation in **Produktions-Systemen** (*production systems*): Solche Systeme setzen sich aus einer Wissensbasis und einem Regelwerk zusammen. In der Wissensbasis werden Attribute abgelegt, die einzelne Bildobjekte charakterisieren. Das Regelwerk beschreibt, wie diese Attribute zu interpretieren sind. Die Regelwerke (oder Produktions-Regeln) sind aus WENN-DANN Beziehungen aufgebaut. Das bedeutet WENN eine Prämisse gilt, DANN folgt eine entsprechende Konklusion. WENN ein Bereich länglich UND homogen ist, DANN gehört er zu der Klasse „Straße“. Die generelle Funktionsweise kann durch den „*match-select-act*“-Ablauf beschrieben werden (frei übersetzt: Entsprechung-Auswahl-Ausführung). Das System findet in der ersten Phase alle Regeln, die den Eigenschaften eines Objektes **entsprechen**. Anschließend wird die zutreffendste Regel **ausgewählt** und **ausgeführt**.

## 3 Die objektorientierte Auswertung auf Basis von eCognition

ECognition ist die erste kommerziell verfügbare Bildanalysesoftware, die objektorientierte Verarbeitungsmethoden speziell für Fernerkundungsdaten anbietet. Mit dieser Software wurde in der vorliegenden Studie gearbeitet.

Dabei gliedert sich der gewählte Untersuchungsansatz in zwei Teile:

1. Die Entwicklung eines **objektorientierten Auswertekonzepts** und die Darstellung der einzelnen Teilschritte, sowie
2. die Überprüfung und Anwendung des entwickelten Konzepts auf **drei verschiedene Fallstudien**, mit dem Ziel methodische Besonderheiten herauszuarbeiten und darzustellen.

Dabei erscheint es zweckmäßig, die Herleitung des objektorientierten Auswertekonzepts für hochauflösende Fernerkundungsdaten im Anschluß an die Darstellung des Wissensstands (Kap. 2) zu behandeln. Erst danach wird das Untersuchungsgebiet dargestellt (Kap. 4), dessen Kenntnis notwendig ist, um die Fallstudien (Kap. 6) nachvollziehen zu können.

### 3.1 Einführung

**Objektorientierung** ist im eigentlichen Sinne ein Konzept aus der Softwareentwicklung. Sachverhalte und Erscheinungen werden nicht mehr auf ihre Einzelheiten begrenzt, sondern als eingegliedertes Ganzes betrachtet, bei dem die einzelnen Komponenten miteinander verbunden sind und Abhängigkeiten zwischen ihnen bestehen (OESTEREICH 2001).

Wie bereits dargelegt, bedeutet Objektorientierung in der Fernerkundung, daß nicht einzelne Pixel in ihrer spezifischen spektralen Ausprägung betrachtet werden, sondern vielmehr Gruppen benachbarter Pixel, sogenannte Segmente oder Bildobjekte. Diese **Bildobjekte** werden durch eine Segmentierung der Fernerkundungsdaten gebildet. Bei hochauflösenden Daten gilt die Annahme, daß benachbarte Bildpunkte eine hohe Wahrscheinlichkeit haben, zur selben Landbedeckungsklasse zu gehören. TOBLER (1970) hat die räumliche Autokorrelation benachbarter Pixel in seinem „*first law of geography*“ formuliert: „*Everything is related to everything, but near things are more related than distant things*“. Analog dazu stellt BARTEL (2000) fest, daß bei räumlicher Koinzidenz stets ein inhaltlicher Zusammenhang nahe liegt.

Erste objektorientierte Bildanalyseverfahren wurden bereits in den 1970er Jahren entwickelt. KETTIG und LANDGREBE (1976) faßten benachbarte, spektral ähnliche Bildpunkte zu homogenen Bildobjekten zusammen und erreichten bei deren Klassifikation eine höhere Genauigkeit als mit bildpunktbasierter Methoden.

Das große Interesse, das in jüngster Zeit dem objektorientierten Ansatz entgegen gebracht wird, ist im wesentlichen vom technologischen Fortschritt bestimmt: die hohe Auflösung der neuen Satellitendaten erfordert anspruchsvolle Auswertemethoden. Bevor das Produkt eCognition auf den Markt kam, waren objektorientierte Methoden ausschließlich Spezialisten mit fortgeschrittenen Programmierkenntnissen vorbehalten. Die graphische Benutzeroberfläche macht diesen Ansatz nun einer breiten Anwendergemeinde zugänglich.

Der objektorientierte Klassifikationsansatz mit eCognition ist im Prinzip eine **Kombination verschiedener Bildanalysemethoden**. Im Arbeitsablauf verschwimmen die Grenzen oft zwischen der einen oder anderen Methode, die sich dementsprechend schwer voneinander trennen lassen. Durch die Kombination dieser verschiedenen Methoden lassen sich viele Synergien erzielen und zahlreiche Probleme lösen. Die folgende Tabelle 1 gibt einen Überblick über die einzelnen Ansätze, und zeigt auf welche Fortschritte mit diesen Methoden erzielt werden können. Darüber hinaus wird jeweils darauf verwiesen, in welchen Kapiteln dieser Arbeit, das entsprechende Thema aufgegriffen wird.

**Tab. 1:** Überblick der verwendeten Methoden.

<b>Methode</b>	<b>Fortschritt</b>	<b>Kapitel</b>
<b>1. Segmentierung</b>	<b>Spektrale Varianz</b> im Merkmalsraum wird reduziert	Kap. 2.4, Kap. 2.5, Kap. 3.4
<b>2. Bildobjektdatenbank</b>	Erweiterung des Merkmalraums, z. B. mit <b>Textur-</b> oder <b>Formattributen</b>	Kap. 3.5.1
<b>3. Topologie, Kontext</b>	<b>kontextuelle</b> und <b>multiskalare</b> Aspekte können angesprochen werden	Kap. 2.5, Kap. 3.4.2
<b>4. fuzzy-Regelwerke</b>	Formulierung von „ <b>unscharfem</b> “ <b>Expertenwissen</b>	Kap. 2.6, Kap. 3.5.2
<b>5. data-fusion</b>	<b>Stratifikation</b> durch Integration von externer thematischer Information, <b>integrierte Auswertung</b>	Kap. 2.6.1

Die **Segmentierung** dient dazu, Bildobjekte zu generieren und damit die **spektrale Varianz** im Merkmalsraum zu reduzieren. Die Eigenschaften der Objekte werden in einer **Bildobjektdatenbank** verwaltet. In dieser Bildobjektdatenbank werden neben den Spektralattributen weitere Attribute wie **Textur** oder **Form** eines Objektes abgelegt. Diese Eigenschaften gehören zu den ausschlaggebenden Identifikationskriterien für einen Interpreten. Durch die **topologische Verknüpfung** der Bildobjekte, sowohl über die eigene Ebene als auch zu über- oder untergeordneten Skalenebenen, lassen sich komplexe Beziehungen der Landbedeckungsklassen modellieren. Das Wissen über den **Kontext** einer Landbedeckungsklasse und ihre **multiskalaren** Zusammenhänge läßt sich dadurch nutzen. Expertenwissen wird durch die Modellierung von **fuzzy-Regelwerken** formalisiert. Durch den **fuzzy-**Aspekt kann auch **unscharfes Expertenwissen** bei der Klassifikation verwendet werden. Unterschiedliche Datenquellen können integriert ausgewertet werden (**data-fusion**). Die Hinzunahme thematischer Informationen kann die Klassifikation unterstützen, weil hierdurch der Suchraum für eine Klasse eingengt wird. Die **integrierte Auswertung** vereinfacht es auch, bestehende Kartierungen zu aktualisieren. Daneben können Fernerkundungsdaten verschiedener Auflösung fusioniert werden.

### Konzept einer objektorientierten Analyse

Wie bereits erwähnt, wurde ein Konzept entwickelt, das dem Anwender den Einstieg in die objektorientierte Analyse erleichtert. In Abbildung 3 ist diese Vorgehensweise, welche die einzelnen methodischen Schritte zusammenfügt, als Ablaufschema dargestellt.

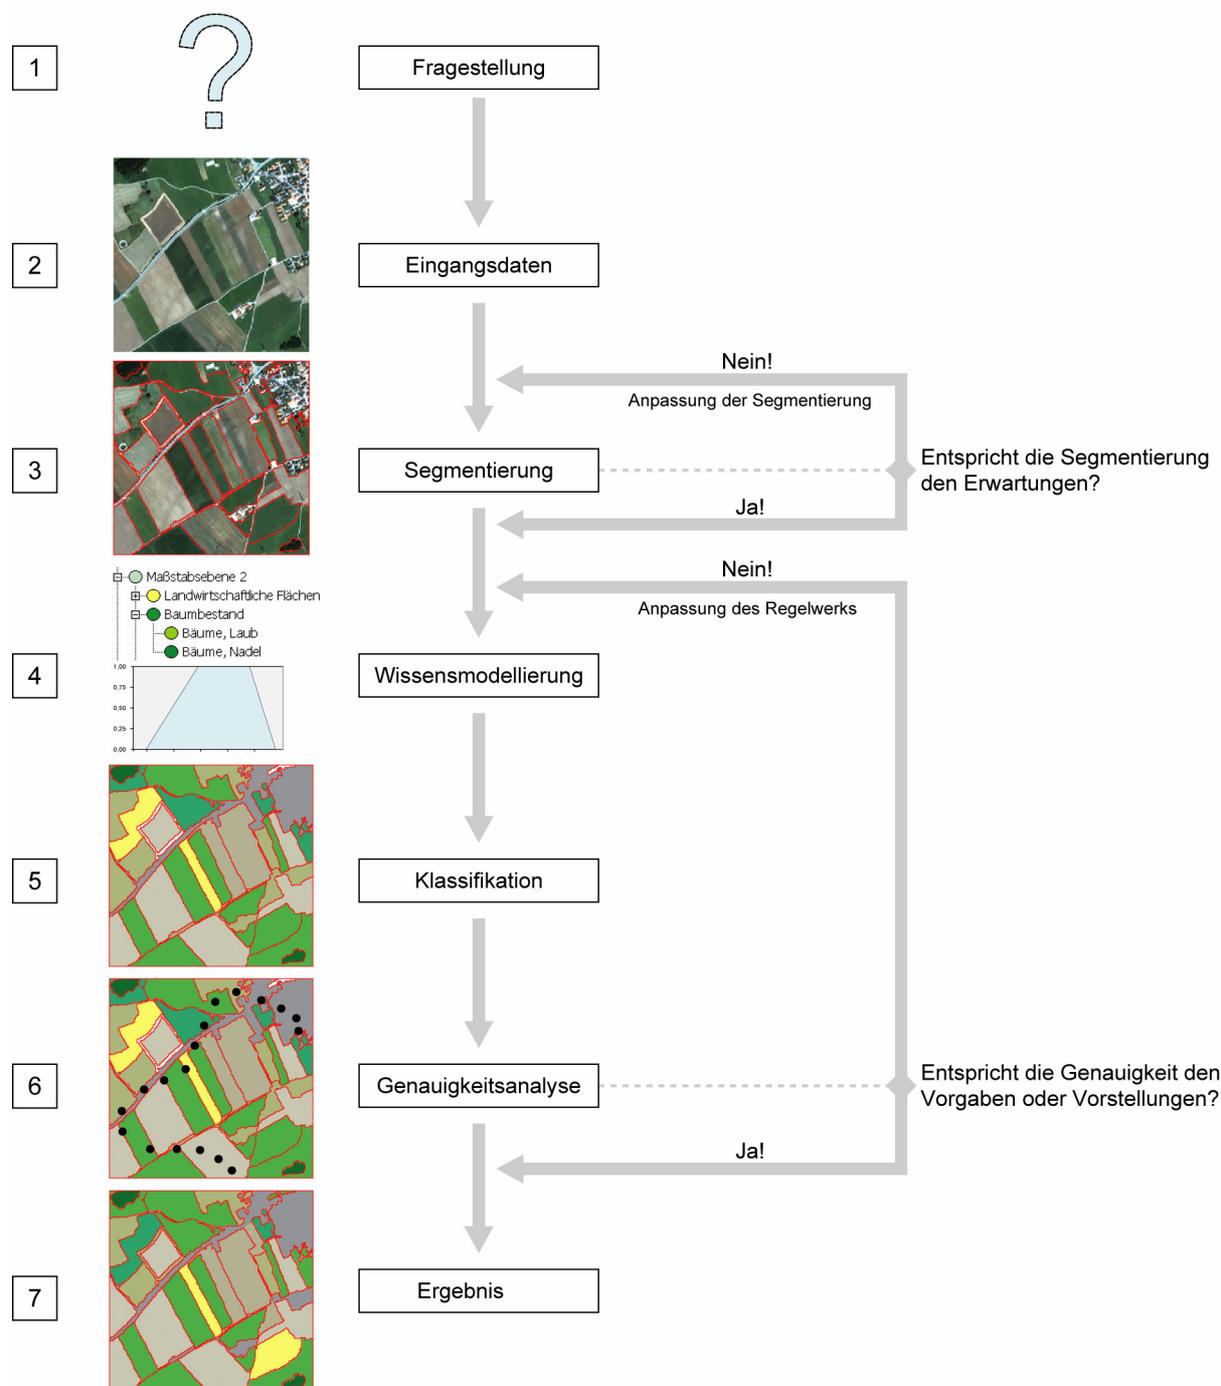


Abb. 3: Ablaufschema einer objektorientierten Analyse.

## 3.2 Fragestellung

### 1. Schritt

Der erste Schritt einer Bildanalyse ist grundsätzlich die Auseinandersetzung mit der **Fragestellung** eines Projekts. Welche Information erwartet sich der Bearbeiter oder Auftraggeber von der fernerkundlichen Analyse. Eine eindeutige und klar abgegrenzte Zieldefinition ist eine unbedingte Voraussetzung, vor allem wenn wirtschaftliche Aspekte eine Rolle spielen.

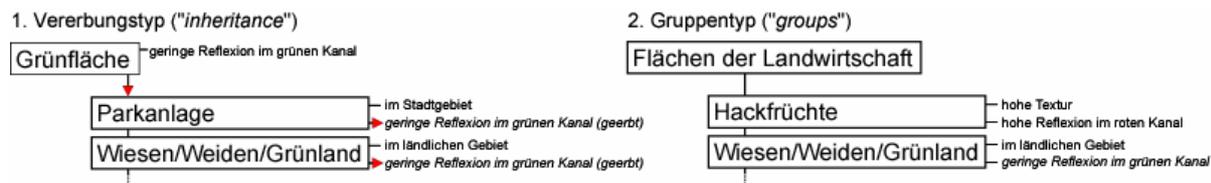
Die allgemeine Charakterisierung des **Untersuchungsgebiets** im Blick auf seine geographischen, geomorphologischen und geobotanischen Eigenheiten ist notwendig, um die erwartete Landbedeckung einzugrenzen. Im Prinzip beginnt hier die Wissensakquisition für das gesamte Vorhaben. Man macht sich Gedanken über das Untersuchungsgebiet und seine Landschaftsstruktur und fängt an, sich die Frage zu stellen, wie sich die Zielinformation am besten extrahieren läßt.

CONGALTON (1991) sieht den logischen Aufbau eines **Klassenschemas** unter Berücksichtigung der räumlichen und spektralen Auflösung der Daten, sowie der Zielsetzung der Untersuchung als unbedingte Voraussetzung für ein erfolgreiches Analyseprojekt. Im Optimalfall ist das Schema hierarchisch gestaltet, also vom Allgemeinen zum Speziellen aufgebaut. Der Nutzer hat so die Möglichkeit, abhängig von seinen Anforderungen an den thematischen Inhalt, Klassen zusammenzufassen oder weiter aufzulösen. Diese hierarchische Stufung entspricht auch am ehesten der Art, wie Menschen die Landbedeckung einteilen und wahrnehmen (TON et al. 1991). Dabei kann die Einteilung sowohl auf die räumliche Ausdehnung (Laubwald ► Laubbaum) oder auf die thematische Tiefe (Laubwälder ► Sommergrüne Laubwälder ► Buche-Eiche-Laubmischwälder) bezogen sein. Oft wird erst im Lauf einer Untersuchung deutlich, welche der Landbedeckungsklassen sich nicht unterscheiden lassen oder welche Klassen zusätzlich gebildet werden müssen. Besonders bei Forschungsvorhaben sollte das Klassenschema flexibel behandelt werden, wenn nicht von Anfang an klar ist, welche Informationen aus einem neuen Datentyp extrahierbar sind. Andererseits ist eine grobe Vorstellung über Zielklassen notwendig, damit recherchiert werden kann, welche Informationsgrundlage für welche Klasse geeignet ist.

In eCognition gibt es die Möglichkeit, über eine graphische Benutzerführung ein hierarchisch gestaffeltes Klassenschema aufzubauen. Dabei handelt es sich jedoch um weit mehr als ein visualisiertes Klassenschema: In dieser sogenannten **Klassenhierarchie** werden auch die Klassenbeschreibungen oder Regelwerke verwaltet. Über die Klassenhierarchie werden für jede Klasse Regelwerke aus kombinierten *fuzzy*-Zugehörigkeitsregeln aufgebaut (Kap. 3.5.2). Eine Klasse ist in diesem Kontext definiert als Gruppe von Objekten, welche den Regelwerken oder Beschreibungen einer Klasse entsprechen. Die hierarchischen Zusammenhänge der Objektklassen werden in zwei Hierarchie-Typen unterschieden:

1. **Vererbungstyp** („*inheritance*“). Hier werden Klassenbeschreibungen von der Vaterklasse auf die Sohnklasse vererbt, d.h. die Zugehörigkeitsregeln der Vaterklasse gelten auch für die Sohnklasse. Die Vererbung gründet sich auf gemeinsame physikalische und morphologische Eigenschaften, die sich in einem ähnlichen Reflexionsverhalten und somit auch in den Objektattributen widerspiegeln.
2. **Gruppentyp** („*groups*“). Hier werden Klassen thematisch in einer Hierarchie gegliedert.

Die Abbildung 4 enthält ein Beispiel für jeden Hierarchie-Typ, das anschließend erläutert wird.



**Abb. 4:** Übersicht zur Klassenhierarchie.

zu 1.) **Vererbungstyp:** die Vaterklasse „Grünfläche“ hat als Eigenschaft geringe Reflexionswerte im grünen Kanal. Diese Eigenschaft wird den Sohnklassen „Parkanlage“ und „Wiesen/Weiden/Grünland“ vererbt, die ebenfalls geringe Reflexion im grünen Kanal aufweisen (tatsächlich sind die Spektraleigenschaften beider Sohnklassen dieselben, denn beide Flächentypen sind mit Gräsern bewachsen!). Die Sohnklassen lassen sich aber entsprechend ihres räumlichen Kontextes weiter untergliedern: Parkanlagen existieren meist im Stadtgebiet, Wiesen/Weiden/Grünland sind meist im ländlichen Gebiet zu finden. Die Vaterklasse hat lediglich die Spektraleigenschaften weitergegeben, der räumliche Kontext ist für die Sohnklassen separat definiert. In diesem Beispiel wird die Landbedeckungsklasse „Grünfläche“ in die Landnutzungsklassen „Parkanlage“ und „Wiesen/Weiden/Grünland“ gegliedert.

zu 2.) **Gruppentyp:** hier werden Klassen zusammengefaßt, die thematisch zusammengehören - unabhängig von ihren Klassenbeschreibungen. Die Vaterklasse „Flächen der Landwirtschaft“ gliedert sich in verschiedene Sohnklassen, die nicht unbedingt gemeinsame Klassenbeschreibungen aufweisen. Thematisch sind sie allerdings gemeinsam einzuordnen. Bei klassenbezogenen Attributen wird die Bezugnahme nach unten vererbt, z. B. *benachbart zu* „Flächen der Landwirtschaft“ umfaßt *benachbart zu* „Hackfrüchte“ und *benachbart zu* „Wiesen/Weiden/Grünland“.

Unter Verwendung der Klassenhierarchie lassen sich hochkomplexe hierarchische und thematische Zusammenhänge der Landklassen modellieren.

### 3.3 Eingangsdaten

#### 2. Schritt

Als nächstes muß geklärt werden, welche **Daten** für ein Projekt bereits **verfügbar** sind. Die Frage, welche **Daten zusätzlich** erworben werden, ist von verschiedenen Faktoren abhängig. Jeder Sensor hat spezifische Abbildungseigenschaften, die in Abhängigkeit von der Aufgabenstellung mehr oder weniger sinnvoll sein können. Bei Fernerkundungsdaten ist es in erster Linie eine Frage nach der spektralen und räumlichen Auflösung, welcher Datentyp für eine Untersuchung verwendet wird.

Die **räumliche Auflösung** eines Sensors setzt sich aus der Kombination von Flughöhe und dem momentanen Gesichtsfeld des Sensors (IFOV, *instantaneous field of view*) zusammen (ALBERTZ 2001). Dieser Parameter wird in der Fernerkundung häufig mißverstanden und falsch interpretiert (JOSEPH 2000). Die Erfahrung zeigt, daß z. B. mit Landsat-TM auch Strukturen erfaßt werden können, die kleiner als 30 m (entspricht der Bodenauflösung von Landsat-TM) sind, vorausgesetzt der Kontrast zur Umgebung ist entsprechend groß. Die räumliche Auflösung sollte im Optimalfall so gewählt werden, daß die gewünschte Information mit der geringsten Datenmenge erfaßt werden kann (ATKINSON und CURRAN 1997), denn jede Erhöhung der Auflösung bringt eine sprunghafte Zunahme in der Datenmenge mit sich. Bei gleicher Datentiefe geht eine Veränderung der Auflösung von 30 m auf 1 m, mit einer Erhöhung der Datenmenge um den beträchtlichen Faktor 900 einher. Dieser Aspekt ist trotz der immer leistungsfähigeren Computersysteme zu bedenken.

Oft wird die Entscheidung, welche Auflösung sich am besten für eine Fragestellung eignet, vom Bearbeiter intuitiv getroffen (STEIN et al. 1998) oder es wird eine verfügbare Datengrundlage verwendet (ATKINSON und CURRAN 1997). Jedoch gibt es keine räumliche Auflösung, die sämtliche geographischen Einheiten eines Untersuchungsgebietes erfassen und unterscheiden kann (MARCEAU und HAY 1999). Die Beschaffungskosten der Daten und mögliche Folgekosten, die sich aus dem Verarbeitungsaufwand ergeben, spielen ebenfalls eine wichtige Rolle. Ferner ist die weitere Verwertbarkeit der Daten für andere Vorhaben zu prüfen. Bei Forschungsvorhaben ist sicherlich auch die Frage des innovativen Charakters der Fragestellung im Kontext mit dem Datentyp zu sehen.

Die benötigte **spektrale Auflösung** eines Sensors muß in Zusammenhang mit der Fragestellung geklärt werden. Mit Hyperspektraldaten lassen sich zum Beispiel sehr differenzierte Informationen und zahlreiche physiologische Parameter der Pflanzendecke ableiten (BLACKBURN 1998). Solche hochwertigen Systeme sind allerdings mit ihren eigenen Fehlern und Ungenauigkeiten behaftet und für viele Anwendungen beim Erwerb zu teuer.

SCHNEIDER und ZIMMERMANN (2004) stellen eine „Checkliste Sensor“ mit den wichtigsten Entscheidungskriterien für die Auswahl eines adäquaten Systems bei einer konkreten Fragestellung vor. Dabei weisen sie ausdrücklich auf die zeitliche Komponente hin. Gemeint ist damit die mögliche Wiederholungsfrequenz eines Systems, was besonders bei Monitoringaufgaben von Bedeutung ist. Bei flugzeuggetragenen Systemen ist dies meist eine Kostenfrage, wohingegen Satellitensysteme einen festgelegten Wiederholungszyklus haben. Der Vorteil satellitengestützter Fernerkundung liegt sicherlich auch darin, daß keine besondere Flugplanung durchgeführt werden muß und die Bilddaten vergleichsweise unkompliziert und schnell verfügbar sind. Neuere hochauflösende Systeme wie IKONOS oder Quickbird-2 verfügen über die Möglichkeit, den Sensor zu schwenken und gewährleisten so eine häufigere Aufnahmegelegenheit, als durch die orbitale Flugbahn vorgegeben. Die Möglichkeit, eine wolkenfreie Aufnahme zu erfassen, erhöht sich dadurch erheblich.

Die **Vorverarbeitung** der Eingangsdaten ist oft ein sehr zeitaufwendiger Schritt und sollte bereits bei der Beschaffung oder Sichtung der Eingangsdaten abgeschätzt werden. Meist werden die Eingangsdaten vor der eigentlichen Analyse georeferenziert, also in ein geographisches Koordinatensystem übertragen. Dieser Schritt ist für eine spätere Weiterverwaltung in einem Geographischen Informationssystem notwendig, auch um einen Bezug zu einem eventuell vorhandenen Geodatenbestand herzustellen. Werden verschiedene Fernerkundungs- und thematische GIS-Datensätze kombiniert bearbeitet, so ist eine genaue Referenzierung der einzelnen Datensätze aufeinander eine unerläßliche Voraussetzung (COPPIN 2004).

Um Reproduzierbarkeit und Objektivität bei Fernerkundungsanalysen sicherzustellen, fordern SCHNEIDER und ZIMMERMANN (2004) die „Normalisierung“ von Fernerkundungsdaten in der Vorverarbeitungsphase. Unter „Normalisierung“ ist eine Übertragung der vom Sensor erfaßten relativen Signale in physikalische Meßwerte zu verstehen. Dabei gilt es, sensorspezifische Einflüsse (z. B. mangelhafte Sensorkalibrierung, Aufnahmefehler), Beleuchtungs- und Beobachtungswinkelabhängige Einflüsse und vor allem atmosphärische und topographische Auswirkungen auf das empfangene Signal herauszurechnen. Auf die „Instabilität“ einer spektralen Signatur und ihre Ursachen wird in Kapitel 3.4.1 noch einmal eingegangen.

Zur Analyse der integrierten Datenauswertung wurden in der vorliegenden Arbeit **GIS-Daten** in ein eCognition-Projekt als sogenannte thematische Ebenen eingelesen. Die inhaltlichen Attribute der GIS-Daten lassen sich zur Klassenmodellierung heranziehen. Wie in Kap 2.6.1 erwähnt, können GIS-Daten

verwendet werden, um den Suchraum für eine Klasse einzuschränken. Es lassen sich auch gegebene Geometrien einfach übernehmen (z. B. Straßenzüge). Diese Geometrien können bei der Segmentierung mit eCognition berücksichtigt werden.

## 3.4 Segmentierung

### 3. Schritt

Durch eine **Segmentierung** der Eingangsdaten werden Bildobjekte gebildet, die dann Gegenstand der weiteren Betrachtung sind. Eine Voraussetzung für eine sinnvolle Segmentierung ist, daß die gesuchten Klassen durch mehr als einen Bildpunkt repräsentiert sind. HARALICK und SHAPIRO (1985) definierten folgende Qualitätsmerkmale einer Segmentierung:

1. Bildobjekte (oder Segmente) sollen homogen in Eigenschaften wie Farbwert oder Textur sein.
2. Benachbarte Segmente sollen sich deutlich voneinander abgrenzen.
3. Die Segmentgrenzen sollen nicht zu sehr verzweigt sein.

Bei der Segmentierung einer Fernerkundungsaufnahme werden diese Merkmale in ihrer Gesamtheit im Normalfall nicht erfüllt. Bedingt durch die Inhomogenität natürlicher Bodenbedeckung ergeben sich oft fraktale Segmentgrenzen oder Löcher innerhalb eines Objektes (RAHMAN et al. 2003). Laut DE KOK (2001) verstärkt sich dieser Effekt mit höherer geometrischer Datenauflösung.

Der Segmentierungsvorgang wird oft mit einer unüberwachten Klassifikation verglichen (HARALICK und SHAPIRO 1985, SCHNEIDER und STEINWENDNER 1999). Entscheidender Unterschied ist jedoch, daß die Gruppierung nicht wie bei der unüberwachten Klassifikation einzig im spektralen Merkmalsraum stattfindet. Vielmehr wird auch die räumliche Komponente berücksichtigt, so daß nur Gruppen benachbarter Bildpunkte zu Segmenten zusammengefaßt werden. Das bedeutet allerdings auch, daß die Reflexionsantwort über ein Segment gemittelt wird und das Spektralsignal nicht mehr den ursprünglichen Informationsgehalt aufweist.

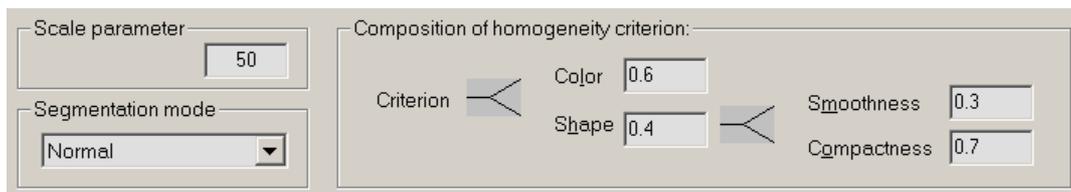
Zahlreiche Segmentierungsalgorithmen mit unterschiedlichen Vor- und Nachteilen wurden in den letzten Jahrzehnten entwickelt (TON et al. 1991). HARALICK und SHAPIRO (1985) geben in ihrer Übersichtspublikation eine breit gefächerte Zusammenfassung zu den Grundlagen verschiedener Segmentierungsansätze. Viele dieser Algorithmen beruhen allein auf der Grauwertstatistik eines Datensatzes. Solche sogenannten „**bottom-up**“-Ansätze segmentieren wissensfrei, rein auf der Bildstatistik basierend, den gesamten Datensatz und geben sogenannte Objektprimitive aus. Objektprimitive sind Segmente ohne thematische Zuweisung. Es ist dann die Aufgabe des Bearbeiters, diesen Objektprimitiven über einen Klassifikationsvorgang eine Bedeutung zu geben. GUIDON (1997) dagegen fordert die Entwicklung von Systemen, die wissensbasiert Bildsegmente extrahieren: als Vorgabe muß gelten, die Segmentierung konkret an die thematischen Bildinhalte anzupassen, wie es bei sogenannten „**top-down**“-Ansätzen der Fall ist. Hier sind die gesuchten Objektklassen vor der Segmentierung bekannt und entsprechende Parameter fließen in den Segmentierungsalgorithmus ein, um gesuchte Bildobjekte gezielt zu extrahieren. Solche Vorgehensweisen werden, wie von GUIDON (1997) beschrieben, häufig bei einer systematischen Objekterkennung in Luftbildern verwendet.

Der in dieser Arbeit verwendete Segmentierungsalgorithmus ist als „**top-down**“-Ansatz zu sehen, denn der Bearbeiter hat die Möglichkeit, abhängig von den gesuchten Klassen, verschiedene Segmentierungsparameter einzustellen.

### 3.4.1 Segmentierung in eCognition

Die Grundlagen des hier verwendeten Segmentierungsalgorithmus werden ausführlich in der entsprechenden Patentschrift EP 0 858 051 a2 vom 12.8.1998 beschrieben (BAATZ et al. 1998). Es handelt sich um ein Verfahren, bei dem ein digitales Bild beliebiger Dimension (d.h. mit beliebig vielen Kanälen) in unterschiedlichen Skalen segmentiert werden kann. Das Verfahren ermöglicht zudem, Daten unterschiedlicher Auflösung kombiniert zu segmentieren oder Polygongrenzen aus zugefügten GIS-Daten zu übernehmen (wobei für die Klassifikation dann auf deren fachliche Attributierung zurückgegriffen werden kann).

Der Segmentierungsalgorithmus entspricht einer Art iterativen „*region-merging*“-Prozedur. Anfangs bildet jeder Bildpunkt ein individuelles Segment. Schrittweise werden benachbarte Segmente paarweise zusammengefaßt. Die **Heterogenität** des neuen Nachbarobjektpaares wird geprüft. Über einen abstrakten *Scale*-Parameter kann der Schwellenwert für die maximal erlaubte Heterogenität eines neu gebildeten Objektpaares vom Benutzer eingestellt werden. Diese Heterogenität errechnet sich aus den Spektralwerten der Daten (*Color*) und der Form (*Shape*) des neu gebildeten Segmentes. Es wird das Objektpaar fusioniert, welches die geringste Heterogenität aufweist. Falls der Schwellenwert überschritten wird, findet keine Fusion statt. Auf diese Weise durchläuft der Segmentierungsalgorithmus schrittweise den Datenraum, bis keine benachbarten Segmente mehr fusioniert werden. Die Abbildung 5 zeigt den Einstellungsdialog von eCognition für die Farb- und Formparameter, die bei einer Segmentierung gelten.



**Abb. 5:** Ausschnitt aus dem Segmentierungs-Dialog, bei dem der Bearbeiter verschiedene Segmentierungseinstellungen vornehmen kann.

Um aussagekräftige Bildobjekte bei einer Segmentierung zu erhalten, kann der Bearbeiter, abhängig vom Betrachtungsmaßstab und dem Datentyp, einen passenden **Scale-Parameter** wählen. Dieser Wert bestimmt, wie oben beschrieben, die maximal erlaubte Heterogenität eines Segmentes und steht somit in direktem Zusammenhang mit der Größe der resultierenden Segmente. Der Farbparameter *Color* bestimmt die Gewichtung der Datenkanäle bei der Segmentierung. Der Formparameter *Shape* dagegen hat Einfluß auf die räumliche Ausprägung eines Segments. Dieser Parameter ist weiter unterteilt in *Smoothness* und *Compactness*. Während *Smoothness* den Grad der fraktalen Ausstreckung eines Segmentes beeinflusst, bestimmt *Compactness* die Ähnlichkeit zum „optimalen Körper“ - einem Quadrat. *Color/Shape* und *Smoothness/Compactness* stehen in reziproker Beziehung zueinander.

Um die Tauglichkeit und die Einstellungsparameter für eine Segmentierung bei einer konkreten Fragestellung abzuschätzen, schlägt MATSUYAMA (1987) **Versuch-und-Irrtum-Experimente** vor. Solche Experimente wurden auch im Rahmen dieser Arbeit durchgeführt. Die Beurteilung, ob eine Segmentierung „optimal“ oder zumindest geeignet ist, folgt nach rein subjektiven Kriterien. Der Bearbeiter testet verschiedene Einstellungsparameter und begutachtet das Ergebnis entsprechend der „Treffergenauigkeit“ der gesuchten Zielklassen. Die Segmentierung ist bei gleichen Einstellungen reproduzierbar, die Auswahl der geeigneten Parameter jedoch ist abhängig vom Bearbeiter. Damit fehlt, wie auch GUIDON (1997) bemerkt, ein standardisiertes Bewertungsverfahren für die Qualität

einer Segmentierung. Wünschenswert ist die Bildung von Segmenten, die sich mit existierenden physikalischen Einheiten auf der Erdoberfläche decken, da sowohl eine zu große Zerstückelung als auch eine zu starke Generalisierung ein Problem darstellen können (GUINDON 1997). Wenn die Objektprimitive die räumliche Ausprägung einer Landbedeckungseinheit „treffen“, dann sind auch Form-Eigenschaften wie Fläche oder Länge eines Segmentes für die Beschreibung der Klasse sinnvoll einsetzbar (BENZ et al. 2004).

Obschon der in dieser Arbeit verwendete automatische Segmentierungsalgorithmus sehr ausgefeilt ist, kann nicht erwartet werden, daß alle Ansprüche einer Fragestellung von einer Segmentierung erfüllt werden. DAS und BHANU (1998) schreiben, daß eine „100 % richtige“ Segmentierung für komplexe reale Bilddaten kaum erreicht werden kann. Dennoch besteht nach SCHNEIDER (2000) einer der großen Vorteile einer Segmentierung gegenüber der visuellen Interpretation darin, daß die Objektabgrenzung nicht mehr visuell am Bildschirm erfolgt, sondern durch einen automatisierten Prozeß am Computer abläuft. Somit ist dieser Vorgang reproduzierbar und objektiv.

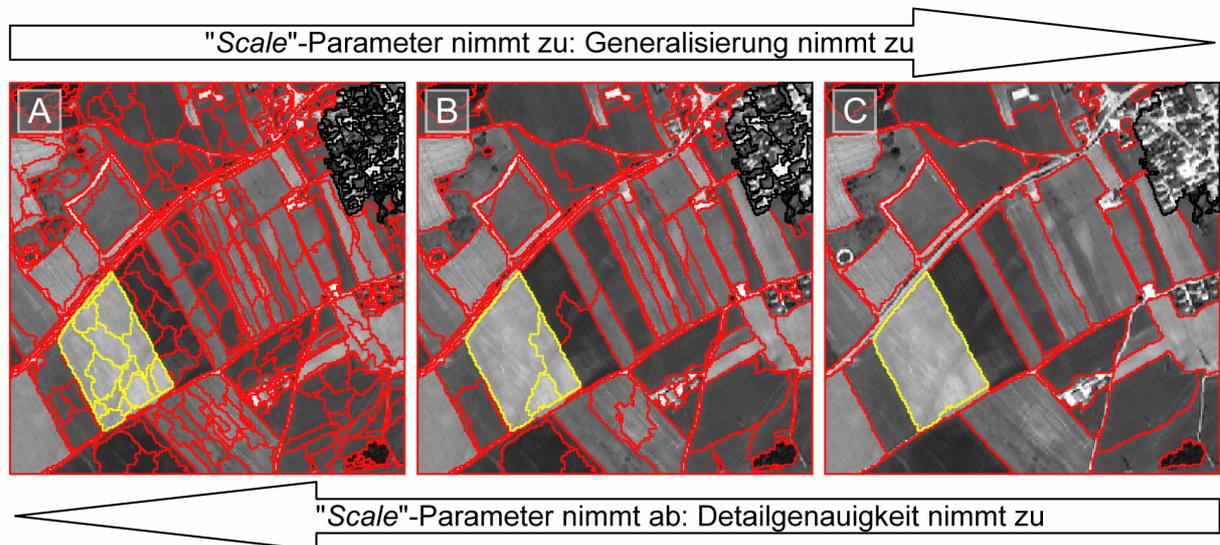
### 3.4.2 Segmentierung auf verschiedenen Maßstabsebenen

In der klassischen Kartographie bezeichnet **Maßstab** das Verhältnis zwischen der abgebildeten Größe (z. B. Streckenlänge) auf einer Karte, einem Plan oder einem Modell und der entsprechenden Größe in der Wirklichkeit. WOODCOCK und STRAHLER (1987) weisen jedoch daraufhin, daß in der Fernerkundung der Maßstab einer Untersuchung meist direkt von der Sensorauflösung abgeleitet wird. Während die Sensorauflösung durch die Bildpunktgröße in einem Datensatz ausgedrückt wird, beschreiben BAATZ et al. (2002) den Maßstab in Zusammenhang mit der objektorientierten Analyse auf eine andere Weise. Hier wird der Maßstab dadurch bestimmt, ob eine Landschaftsstruktur bei einer Segmentierung durch viele Bildobjekte, ein einziges Bildobjekt oder gar nicht repräsentiert ist. Da der Begriff Maßstab in diesem Kontext leicht mißverstanden werden kann, wird im folgenden dafür der Begriff **Skalenebene** verwendet.

Eine Landschaft wird durch eine Reihe von informationstragenden Skalenebenen repräsentiert (BURNETT und BLASCHKE 2003). HAY et al. (2003) betonen deshalb, daß es für eine fernerkundliche Analyse nicht eine einzige, sondern viele geeignete Skalenebenen gibt. Bei einer Landschaftsanalyse sollte die Wahl der Betrachtungsskalen demnach von der räumlichen Ausprägung der gesuchten Landbedeckungstypen abhängig gemacht werden.

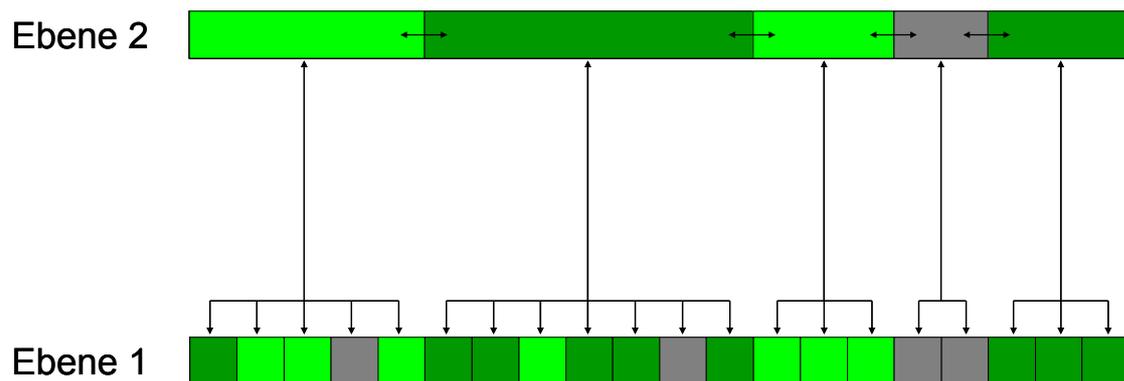
Wird beispielsweise ein Mischwald aus 1000 m Entfernung mit bloßem Auge betrachtet, so ist hauptsächlich der Landbedeckungstyp Wald und seine räumliche Ausdehnung zu erkennen. Aus 100 m Entfernung lassen sich Laub- und Nadelbäume unterscheiden. Bei 25 m sind verschiedene Baumarten differenzierbar. Kommt der Beobachter noch näher, lassen sich weitere Differenzierungen wie z. B. Blattform, Vergilbungen oder Nadelverlust erkennen. Es können jedoch keine strukturellen Aussagen mehr über den Wald als Ganzes gemacht werden. Je nach Fragestellung sind verschiedene hierarchisch gegliederte Stufen der Abstraktion notwendig. BURNETT und BLASCHKE (2003) fordern deshalb, Auswertemethoden zu nutzen, welche die komplexen Skalenzusammenhänge einer Landschaft innerhalb eines Datensatzes verwertbar machen. Die Grenzen dieser Skalenebenen sind fließend. In der vorliegenden Arbeit werden diese Skalenzusammenhänge mit Hilfe der verschieden aufgelösten und miteinander vernetzten Objektebenen (oder Skalenebenen) untersucht. Die multiskalaren Beziehungen zwischen den Ebenen lassen sich bei der Auswertung eines Datensatzes nutzen. In Abbildung 6 ist ein Beispiel für eine Segmentierung auf verschiedenen Skalenebenen dargestellt. Jede Segmentierung hat ihren eigenen Informationsgehalt. So lassen sich bei der feinsten

Segmentierung (Abb. 6 (A)) Inhomogenitäten auf den Äckern detektieren (gelbe Umrandung) und das Siedlungsgebiet (schwarze Umrandung) ist in seine Bestandteile aufgelöst (Bäume, Straßen, Häuser und Grünflächen). Mit zunehmender Segmentgröße werden die Landschaftselemente zusammengefaßt und zunehmend generalisiert (Abb. 6 (A) nach (C)).



**Abb. 6:** Verschiedene Segmentierungen. Die Daten wurden mit ansteigendem *Scale*-Parameter segmentiert (von (A) nach (C)). Die Detailgenauigkeit nimmt von (C) nach (A) zu, während der Grad der Generalisierung sich in umgekehrter Richtung bewegt (von (A) nach (C)). Jeder Segmentierungsmaßstab hat seinen spezifischen Grad der Abstraktion. Ein Acker (gelbe Umrandung) und ein Siedlungsgebiet (schwarze Umrandung) sind jeweils verschieden differenziert.

Auf diese Weise läßt sich eine hierarchische Bildobjektstruktur mit eCognition aufbauen und Bildobjektebenen mit verschiedenen großen Segmentausprägungen können erstellt werden. Die Segmentebenen sind sowohl vertikal als auch horizontal miteinander vernetzt, d.h. jedes Segment „kennt“ seine Nachbar-, Über- und Unterobjekte (Abb. 7). Diese Information ist in der Objektdatenbank verfügbar.



**Abb. 7:** Schematische Darstellung topologischer Verknüpfungen. Die Segmente auf Ebene 2 „kennen“ die Zusammensetzung ihrer untergeordneten Segmente auf Ebene 1 und können so thematisch kategorisiert werden. Diese Verknüpfung verläuft in beide Richtungen. Auch „kennt“ jedes Bildobjekt seine Nachbarobjekte (nur auf Ebene 2 dargestellt). Durch diese topologischen Verknüpfungen lassen sich kontextuelle Zusammenhänge modellieren (aus MOTT et al. (2002a), verändert).

BENZ et al. (2004) betonen, daß ein topologisches **Bildobjektnetzwerk**, wie es auch mit eCognition aufgebaut werden kann, einen großen Vorteil bietet: es erlaubt eine effektive Nutzung verschiedener Arten von kontextuellen Beziehungen zwischen Objektklassen für die Klassenbeschreibung. Kontext-

beziehungen lassen sich sowohl zwischen den Ebenen, als auch auf derselben Ebene formulieren. Eine Streuobstwiese besteht beispielsweise in den Unterobjekten aus einem Teil Wiese und einem Teil Obstbäumen. Genauso sind Waldlichtungen immer in unmittelbarer Nachbarschaft zu Waldflächen. Diese topologischen Zusammenhänge zwischen den Bildobjekten werden in der internen Bildobjektdatenbank verwaltet. Entsprechend können solche kontextuellen Beziehungen in den Klassenregelwerken modelliert werden. FUNG und CHAN (1994) bemerken, daß viele Klassen nur aufgrund ihres Aufbaus und des räumlichen Kontextes zu erkennen sind. Bereits STRAHLER und WOODCOCK (1986) formulierten die Beschreibung eines Bildes durch verschachtelte Modelle. Bei diesem Ansatz wird die Information einer Objektskalenebene genutzt, um die Klassen einer Ebene mit kleinerer Objektskala (und größeren Segmenten) zu beschreiben. Die größeren Segmente stellen dabei eine Zusammenballung der kleineren Segmente dar (BURNETT und BLASCHKE 2003).

## 3.5 Wissensmodellierung

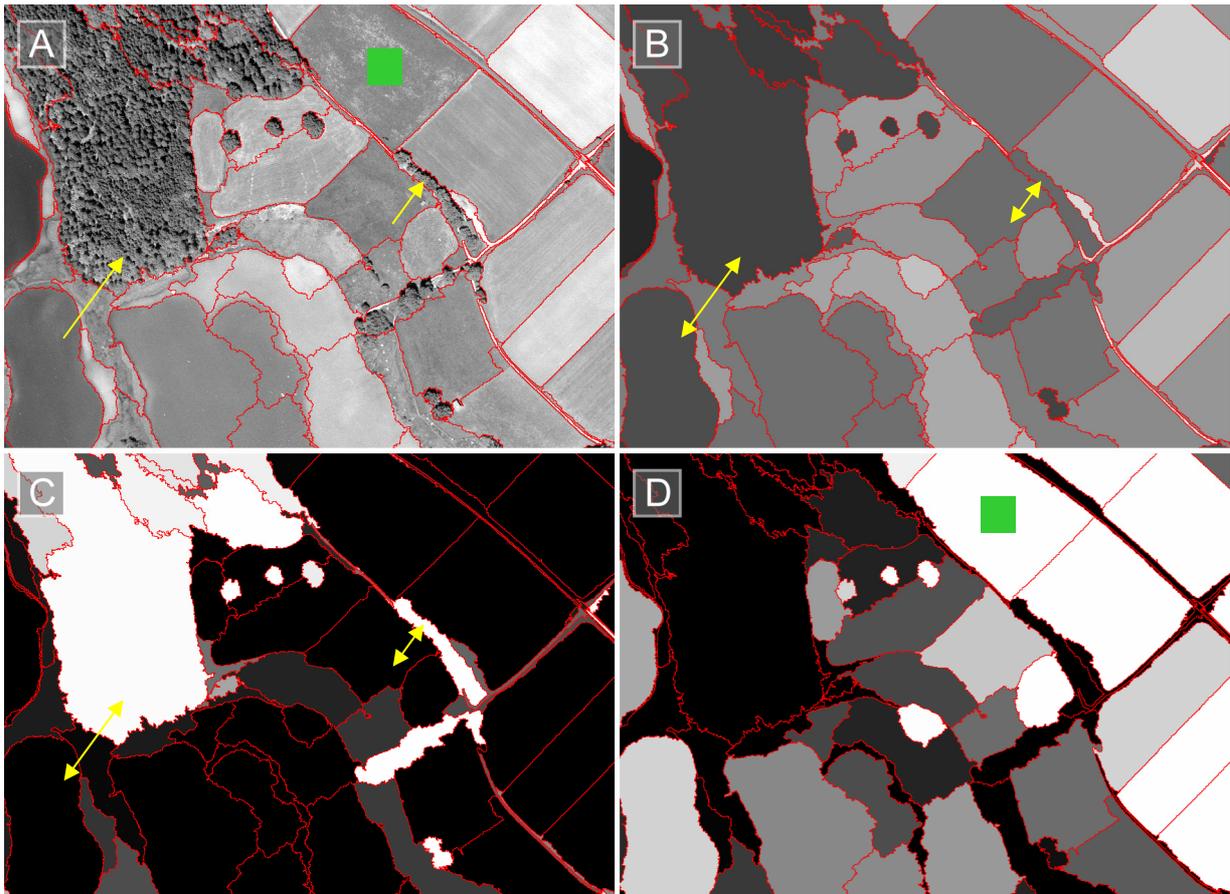
### 4. Schritt

Die Betrachtung von Bildobjekten anstatt von Bildpunkten ist nur ein Aspekt, der durch die objektorientierte Analyseverfahren möglich wurde. Weitere wesentliche Gesichtspunkte sind das rechnergestützte Bildverstehen und die wissensbasierte Bildauswertung. Der menschliche Wahrnehmungsprozeß soll nachmodelliert und das Wissen über die Charakteristika einer Bodenbedeckungsklasse genutzt werden. Dieses Wissen wird **über Regelwerke formalisiert**, welche die Eigenschaften der Bildobjekte für die Zugehörigkeit zu einer Klasse beschreiben. Die Formulierung von Klassifikationsregelwerken entspricht im eigentlichen Sinne einer komplexen Datenbankabfrage (MOTT et al. 2002a). Für SCHNEIDER et al. (2000) stellen insbesondere die Nutzung der Objektdatenbank einen entscheidenden Schritt in Richtung des computergestützten Bildverstehens dar. Die Fernerkundungsgemeinde hat durch die Objektdatenbank Zugriff auf Analysewerkzeuge, die bisher nur in Geographischen Informationssystemen existierten. Damit stehen dem Nutzer zwei beliebig kombinierbare Methodenpools zur Verfügung: zum einen Datenbankwerkzeuge und topologische Beziehungen aus dem GIS-Methodenpool, zum anderen Bildanalysewerkzeuge aus dem Fernerkundungsmethodenpool. In der Objektdatenbank sind somit Objekteigenschaften enthalten, die sich aus Routinen beider Methodenpools ableiten lassen.

### 3.5.1 Objekteigenschaften

Liegen bei einer bildpunktbasierter Klassifikation nur die spektralen Kanäle und eventuell zusätzlich gerechnete Kanäle (z. B. Textur, Vegetationsindizes) vor, so hat der Bearbeiter bei der objektorientierten Klassifikation Zugriff auf eine große Zahl von Objektattributen.

In Abbildung 8 sind exemplarisch drei Objekteigenschaften dargestellt. Deutlich zu sehen ist, daß sich Baumbestände (Abb. 8 (A), gelbe Pfeile) allein anhand der Grauwerte nicht eindeutig unterscheiden lassen (Abb. 8 (B)). Wasserflächen und Weiden (Abb. 8 (B), gelbe Pfeile) haben ähnliche Grauwerte wie Baumbestände. Das Objektattribut Standardabweichung (Abb. 8 (C)) eignet sich dagegen sehr gut, um Baumbestände von anderen Landbedeckungstypen zu differenzieren. Der helle Grauton der Baumbestände steht für eine hohe Standardabweichung im Vergleich zu anderen Bodenbedeckungen (Abb. 8 (C), gelbe Pfeile). Die Objekteigenschaft *Compactness* (Abb. 8 (D)) ist ein Formparameter. Vor allem die landwirtschaftlichen Nutzflächen (Abb. 8 (A, D), grünes Quadrat) nehmen hier einen hohen Wert ein.



**Abb. 8:** Übersicht zu verschiedenen Objekteigenschaften. Ausschnitt aus einem Luftbild der südlichen Osterseen (A), Bildobjektgrenzen in rot, mittlerer Grauwert pro Bildobjekt (B), Standardabweichung pro Bildobjekt (C), Formattribut *Compactness* pro Bildobjekt (D). Objektattributwerte sind in Graustufen abgebildet, wobei ein niedriger Wert dunkel und ein hoher Wert hell dargestellt wird. Gelbe Pfeile: Gehölze (↔ Wasserfläche), grünes Quadrat: Ackerfläche.

Die Objekteigenschaften lassen sich generell in „**instabile**“ und „**stabile**“ **Attribute** einteilen (MOTT et al. 2002b, MOTT et al. 2004b). Als „instabil“ gelten Eigenschaften eines Bildobjekts, die auf den spektralen Werten beruhen. Als Beispiel hierfür seien die spektralen Objektmittelwerte oder die Standardabweichung pro Segment erwähnt.

Die **Instabilität** einer Signatur hat verschiedene Ursachen:

1. **Sensorspezifische Einflüsse:** jeder Sensor hat spezifische Abbildungseigenschaften, sowohl räumlich als auch spektral. Oft ist auch die Kalibrierung der Daten unsicher.
2. **Atmosphärische Einflüsse:** wird mit Datensätzen unterschiedlicher Aufnahmezeitpunkte gearbeitet, so ist der atmosphärische Einfluß auf die Signatur verschieden stark ausgeprägt. Dies resultiert in unterschiedlichen Spektralmeßwerten einer Klasse.
3. **Topographische Einflüsse:** deutliche Geländemorphologie hat Einfluß auf die Reflexionsantwort. So hat ein Landoberflächentyp auf der sonnenabgewandten Seite eines Hangs andere Spektralmeßwerte als auf der sonnenzugewandten Seite.
4. **Blickwinkelabhängige Einflüsse:** abhängig vom Blickwinkel des Sensors im Verhältnis zum Sonnenstand ist die Reflexion verschieden. Dieser Effekt wird Anisotropie genannt, und stellt einen Schwerpunkt aktueller Forschung dar (SCHNEIDER et al. 2004).

5. **Temporale Einflüsse:** bei unterschiedlichen Aufnahmezeitpunkten spielt die jeweilige Vegetationsperiode eine entscheidende Rolle. Abhängig davon, zu welchem Zeitpunkt im Jahr eine Aufnahme gemacht wird, haben Landbedeckungsklassen unterschiedliche Erscheinungsformen.

„**Stabile**“ **Eigenschaften** entsprechen „Kontext“-Beziehungen. Sie beschreiben die Zusammenhänge zwischen einzelnen Bildobjekten. Diese werden in der Literatur häufig als räumliche Beziehungen adressiert. Durch Hinzunahme solcher Beziehungen lassen sich Klassen unterscheiden, die spektral nicht voneinander trennbar sind (GURNEY und TOWNSHEND 1983). Dies gilt für Landnutzungsklassen, die durch ihren räumlichen Kontext beschreibbar sind. So ist eine Grünfläche in einem Stadtgebiet mit großer Wahrscheinlichkeit ein Park oder ein Sportplatz, während dasselbe Spektralsignal in einer ländlichen Gegend beispielsweise für eine Wiese oder Weide spricht.

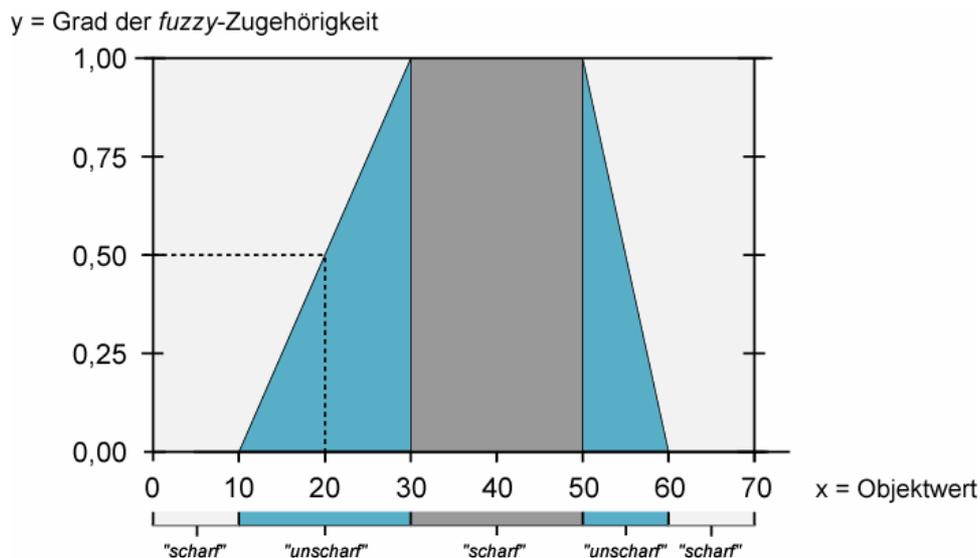
Aus obiger Beschreibung ergibt sich, daß „instabile“ Eigenschaften für jeden Datentyp und Aufnahmezeitpunkt angepaßt werden müssen, während die „stabilen“, also die kontextuellen Beziehungen, übernommen werden können. Die Trennung in kontextuelle und von der Datengrundlage abhängige Parameter erleichtert eine Übertragbarkeit der Regelwerke (MOTT et al. 2002b).

### 3.5.2 *Fuzzy logic*

Das in eCognition verwendete Klassifikationskonzept stützt sich auf die **fuzzy logic-Theorie**. Der Begriff *fuzzy* kann mit unscharf oder verschwommen übersetzt werden und wurde erstmals von ZADEH (1965) geprägt. In der *fuzzy logic*-Theorie werden Beobachtungen nicht als absolut betrachtet. Der Merkmalsraum von *fuzzy logic* liegt zwischen „unwahr“ (0) und „wahr“ (1), wobei auch ein „unscharfer“ Übergang von „unwahr“ (0) bis „wahr“ (1) beschrieben werden kann. Das bedeutet, daß Zwischenwerte möglich sind. Eine Aussage kann also zum Teil „wahr“ sein.

Da auch Landbedeckungsformen meist fließend ineinander übergehen, ist das *fuzzy*-Modell gut geeignet, um diese Verhältnisse auf der Erdoberfläche wiederzugeben. MOLENAAR und CHENG (2000) bestätigen dies, indem sie nachwiesen, daß die Beschreibung sowohl natürlicher Abgrenzungen als auch der Überlappungsbereiche zwischen mehreren Klassen mit „unscharfen“ Grenzen besser möglich ist. Oft ist auch nur die begriffliche Bezeichnung einer Klasse „unscharf“ oder besser vage. So lautet beispielsweise die Definition der CORINE Klasse 2.3.1 „Weide“, daß sie hauptsächlich zu Weidezwecken genutzt werden darf und von Gramineae dominiert ist. Die Fragen, wie „hauptsächlich“ und „dominiert“ definiert werden und wo die Grenzen zu ziehen sind, bleiben offen. Dies ist zweifelsohne ein vager Entscheidungsprozeß. Die kognitive Feststellung eines Interpreten läßt sich mit verknüpften *fuzzy*-Zugehörigkeitsregeln gut nachmodellieren. Dies gilt vor allem, wenn die Entscheidungskriterien nicht exakt bestimmbar sind - aufgrund sehr heterogener Daten, unsicheren Informationsebenen oder bei komplex verknüpften Beurteilungsfaktoren (BINAGHI et al. 1997). Eine Baumkrone hat zum Beispiel nicht immer denselben Durchmesser und ein Acker ist nicht immer rechteckig. Doch gibt es für beide Objekte jeweils Toleranzbereiche, die dem menschlichen Experten aufgrund von Erfahrung bewußt sind und die sich in *fuzzy*-Regelwerken formalisieren lassen. Genauso kann die Instabilität der Eingangsdaten (Kap 3.4.1) mit dem „unscharfen“ Ansatz besser angesprochen werden. Anders als bei einem Computer, wo Zusammenhänge im Zahlenraum eindeutig und ohne Interpretationsspielraum dargestellt werden, ist die Entscheidungsfindung eines Menschen als diffus einzuordnen. Viele verschiedene Kriterien haben ihren Einfluß und wenn versucht wird, diese Kriterien in Worten zu fassen oder ihnen eine Gewichtung zu geben, so kann die formulierte Beschreibung mehrdeutig sein oder verschieden interpretiert werden (BALTSAVIAS 2004).

Die Modellierung der Zugehörigkeit zu einer Klasse erfolgt über die Definition von **fuzzy-Zugehörigkeitsfunktionen** für jeweils eine Objekteigenschaft. Diese Zugehörigkeitsfunktionen entsprechen den Produktionsregeln und sind die Grundbausteine der Wissensmodellierung. Die Höhe der Kurve definiert den Grad an *fuzzy*-Zugehörigkeit eines Bildobjekts bei einer bestimmten Objekteigenschaft. Es wird also das Verhältnis zwischen den Objektattributwerten und der entsprechenden Zugehörigkeit zu einer Klasse beschrieben. Die Zugehörigkeitsfunktionen sind in der WENN-DANN Form zu lesen: *WENN Objektwert ist x, DANN fuzzy-Zugehörigkeit ist y*. Zum besseren Verständnis ist in Abbildung 9 der Aufbau einer Zugehörigkeitskurve schematisiert dargestellt.



**Abb. 9:** Darstellung einer *fuzzy*-Zugehörigkeitskurve. Der Objektwert  $x$  wird gegen den Grad der *fuzzy*-Zugehörigkeit  $y$  aufgetragen. Die „scharfen“ Bereiche legen eine eindeutige Zugehörigkeit fest: keine Zugehörigkeit ( $x = 0$  bis  $10$ ;  $x = 60$  bis  $70$ ) und totale Zugehörigkeit ( $x = 30$  bis  $50$ ). Der blaue Teil der Kurve ( $x = 10$  bis  $30$ ;  $x = 50$  bis  $60$ ) ist der „unscharfe“ Übergangsbereich zwischen totaler Zugehörigkeit ( $y = 1$ ) und keine Zugehörigkeit ( $y = 0$ ) (Abb. aus BENZ (2004), verändert).

Im Beispiel aus Abbildung 9 liegt der Wertebereich der Objekteigenschaft ( $x$ -Achse) zwischen 0 und 70. Bei Werten von 0 bis 10 bzw. 60 bis 70 wird „keine Zugehörigkeit“ ausgegeben ( $y$ -Achse: Grad der Zugehörigkeit), während Objektwerte zwischen 30 und 50 für die volle Zugehörigkeit stehen. Diese Wertebereiche sind eindeutig bzw. „scharf“ festgelegt. Die *fuzzy*-Bereiche, bei welchen eine teilweise Zugehörigkeit vorliegt, sind bei Objektwerten zwischen 10 bis 30 bzw. 50 bis 60 anzutreffen. Bei einem Objektwert von 20 (gestrichelte Linie) beträgt die *fuzzy*-Zugehörigkeit beispielsweise 0,5. Das bedeutet, daß das Bildobjekt zur Hälfte das Kriterium dieser Kurve erfüllt. Je höher der *fuzzy*-Wert, desto sicherer ist die Zugehörigkeit des Bildobjekts. Je niedriger der *fuzzy*-Wert, um so vager oder „unschärfer“ ist die Zugehörigkeit. Die Anpassung des Kurvenverlaufs kann vom Bearbeiter durchgeführt werden und richtet sich interaktiv nach den Häufigkeitsverteilungen von ausgesuchten Referenzobjekten. Eine detaillierte Beschreibung dieses Vorgangs findet sich im nächsten Kapitel 3.4.3.

Eine Klasse wird meist über kombinierte Zugehörigkeitsfunktionen für verschiedene Objektattribute beschrieben. Die Verknüpfung der Zugehörigkeitsfunktionen erfolgt über **logische Grundoperatoren** (Komplement (NOT), Vereinigung (OR) bzw. Schnittmenge (UND)). Bei der Bewertung einer Klassenzugehörigkeit werden nur *fuzzy*-Werte in Beziehung zueinander gesetzt, d.h. es werden verschieden dimensionierte Objekteigenschaften in denselben Merkmalsraum projiziert. So können völlig unterschiedliche Attribute wie Spektralwert oder Formindizes unabhängig von ihrer

ursprünglichen Dimension direkt über *fuzzy*-Werte zwischen 0 und 1 miteinander verglichen werden. Die Normalverteilungsprämisse, die bei den meisten statistischen Klassifikationsverfahren gilt, entfällt hier.

Ein Bildobjekt kann Zugehörigkeiten zu verschiedenen Klassen aufweisen. Je größer der Unterschied zwischen dem höchsten und dem zweithöchsten *fuzzy*-Zugehörigkeitswert ist, desto stabiler ist eine Zuweisung. Gleiche oder ähnliche Zugehörigkeitswerte zu verschiedenen Klassen deuten auf eine unsichere Klassifikation hin (BENZ et al. 2004).

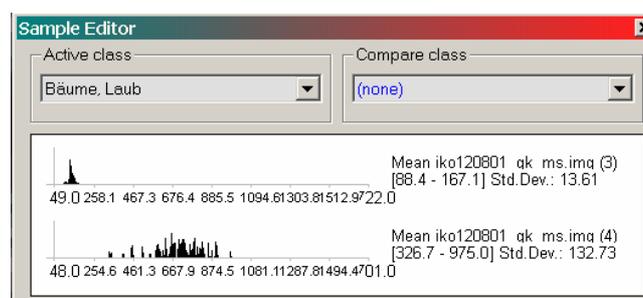
### 3.5.3 Aufbau der Regelwerke

Um Mißdeutungen zu vermeiden, seien hier kurz zwei Begriffe erläutert: ein **Klassenregelwerk** entspricht der Definition einer Klasse durch verknüpfte Zugehörigkeitsfunktionen. Ein **Klassifikationsregelwerk** hingegen stellt die Gesamtheit aller Klassenregelwerke dar.

Um eine komplexe Objektklasse zu charakterisieren, ist meist die **Verknüpfung verschiedener beschreibender Attribute** notwendig (MATSUYAMA 1987). Im Prinzip geht es um das Sammeln von Indizien, die für oder gegen eine Klassenzuweisung sprechen. Die Zahl der verwendeten Zugehörigkeitsfunktionen sollte dabei möglichst gering und eindeutig sein. Es gilt die Devise: „So einfach wie möglich, so komplex wie nötig“ (DE KOK 2001). Die Erstellung eines Klassenregelwerks entspricht einer Gratwanderung zwischen Flexibilität und thematischer Genauigkeit. Je detaillierter eine Landbedeckungsklasse im Klassenregelwerk beschrieben wird, um so größer ist auch die Treffsicherheit des Regelwerks für ein spezielles Untersuchungsgebiet und den entsprechenden Fernerkundungsdaten. Dabei nimmt jedoch die Flexibilität ab, d.h. das Klassenregelwerk wird anfällig für die Instabilität der Reflexionswerte und damit verringert sich die Übertragbarkeit auf andere Aufnahmeszenen. Sind die Modellannahmen allerdings zu stark vereinfacht, kann dies, wie BALSAVIAS und HAHN (2000) bemerken, eine potentielle Fehlerquelle darstellen.

Durch die immense Fülle an Objektattributen und Verknüpfungsmöglichkeiten hat der Bearbeiter die „**Qual der Wahl**“ (DE KOK 2001). Er muß eine transparente und auch nachvollziehbare Auswahlstrategie entwickeln, der zugrunde liegt, welche Objekteigenschaften für eine Klassenbeschreibung „sinnvoll“ sind und wie diese miteinander zu verknüpfen sind. Neben Expertenwissen, Literatur und den Werkzeugen aus eCognition können aus einer statistischen Analyse der Objekteigenschaften weitere wertvolle Hinweise für den Aufbau der Klassenregelwerke gewonnen werden.

Zuerst müssen Referenzsegmente für jede Klasse gewählt werden. Über das Dialogfenster *Sample-Editor* (Abb. 10) hat der Bearbeiter in eCognition dann eine Übersicht über die Verteilung der Werte der Referenzsegmente in den verschiedenen Objekteigenschaften.



**Abb. 10:** *Sample-Editor* aus eCognition. Gezeigt wird die Verteilung der Werte der Referenzobjekte der Klasse „Bäume, Laub“ in den IKONOS-Kanälen drei (rot) und vier (NIR).

Hat der Bearbeiter eine Auswahl an charakteristischen Objektattributen für eine Klasse getroffen, kann die Form der *fuzzy*-Zugehörigkeitskurve für jedes der Objektattribute modelliert werden. Die Häufigkeitsverteilung der Referenzgebiete innerhalb einer Objekteigenschaft ist das ausschlaggebende Kriterium dafür, wie eine Zugehörigkeitskurve verläuft. Die Kurvenmodellierung selbst wird manuell vom Bearbeiter durchgeführt. Dieser Vorgang ist ein relativ subjektiver Prozeß, zumal der „*Sample-Editor*“ vergleichsweise unübersichtlich ist und dem Bearbeiter nur wenig Auskunft über die Verteilungsstatistiken der Referenzsegmente gibt. Wie schon erwähnt, besteht der innovative Aspekt der objektorientierten Analyse in der Ablage der Objektattribute in einer Datenbank. Die Untersuchung der Objektdatenbank durch ein Statistikprogramm liegt also nahe und wurde im Rahmen dieser Arbeit durchgeführt. Nicht zuletzt sprechen die diesbezüglich beschränkten Analyse- und Darstellungsmöglichkeiten der Software eCognition dafür, weitere Statistikprogramme einzusetzen.

Die Untersuchung der Verteilungsstatistiken ist einer Signaturanalyse bei konventionellen Verfahren nicht unähnlich. Die Objektdatenbankdatei aus eCognition läßt sich im dBase-Format (\*.dbf) ausgeben und in das **Statistikprogramm SPSS** (Version 11.0) einlesen. Das dBase-Format ist ein relationales Datenbankformat, das von den meisten Statistik- und Tabellenkalkulationsprogrammen importiert werden kann. Dementsprechend lassen sich verschiedene Analysen mit dem Programm SPSS durchführen. Zielvorgabe ist es, zu erfahren, welche Objektattribute einzelne Klassen charakterisieren und wie sich Objekteigenschaften über einen multisaisonalen Zeitraum verhalten.

Der gesamte objektorientierte Prozeß ist ein **iterativer Arbeitsablauf**: Nach dem Aufbau der Regelwerke werden diese angewendet, d.h. es folgt eine Klassifikation der Bildobjekte. Diese Klassifikation entspricht anfangs oft nicht den Erwartungen und „fällt bei der Genauigkeitsanalyse durch“. Aus diesem Grunde wird interaktiv untersucht, wo die Fehlerquellen zu finden sind. Nach einer Anpassung der Regelwerke erfolgt ein neuer Klassifikationsdurchlauf und unter Umständen eine erneute Anpassung der Regelwerke. Dieser Vorgang wird so lange wiederholt, bis das Ergebnis den Erwartungen und Genauigkeitsvorstellungen entspricht.

## 3.6 Klassifikation

### 5. Schritt

Der eigentliche Klassifikationsvorgang ist ein überschaubarer Schritt. Die Klassenbeschreibungen können wahlweise mit oder ohne klassenbezogene Objekteigenschaften angewendet werden. Klassenbezogene Objekteigenschaften sind Kontext-Beziehungen zwischen den Klassen und werden durch das Bildobjektnetzwerk ermöglicht (Kap. 3.4.2). Abhängig von der Anzahl der klassenbezogenen Attribute in einem Klassifikationsregelwerk und der Größe eines Untersuchungsgebiets kann sich ein Klassifikationsdurchgang über mehrere Stunden hinziehen.

Das Ergebnis nach dem Arbeitsschritt „Klassifikation“ ist eine digitale thematische Karte. Diese kann mitsamt ihren Objekteigenschaften als **ArcView-Shape-Datei** exportiert werden und in einem GIS weiterverarbeitet werden. Das ArcView-Shape-Datenformat ist allgemein gebräuchlich.

## 3.7 Genauigkeitsanalyse

### 6. Schritt

Jede Karte stellt eine Vereinfachung der tatsächlichen Verhältnisse dar und enthält Ungenauigkeiten bzw. Fehler. Die qualitative Bewertung ist Thema zahlreicher Studien und wichtiger Bestandteil der meisten fernerkundlichen Analysen (FOODY 2002). Hierbei ist das Ziel herauszufinden, wie nah das Ergebnis an der Realität liegt (SMITS et al. 1999), d.h. wie gut die tatsächliche Bodenbedeckung wiedergegeben wird. Wird von Klassifikationsqualität gesprochen, so stellt man die Genauigkeit in einen größeren Zusammenhang, indem sie mit definierten Zielsetzungen und konkreten Anforderungen verglichen wird. Dabei haben verschiedene Nutzer unterschiedliche Anforderungen an die **Genauigkeitsanalyse**. Manchen genügt eine allgemeine Aussage, andere wollen etwas über einen klassenspezifischen Fehler erfahren und wieder anderen reicht eine Fehlflächenabschätzung. CONGALTON (1991) gibt einen „geschichtlichen“ Überblick über die Art, wie Genauigkeitsanalysen durchgeführt werden. Anfangs wurden Karten als gut bewertet, wenn das Ergebnis „gut“ aussah. Doch nur „gutes“ Aussehen ist ein hochgradig subjektiver Eindruck und abhängig von den Kenntnissen des Betrachters über das betreffende Gebiet. Für ein objektiveres Bild wird in jedem Fall eine Vergleichsgrundlage in Form von Referenzdaten benötigt.

#### 3.7.1 Referenzdaten

Im Normalfall wird eine Reihe von **Referenzflächen** ausgewählt und mit dem Klassifikationsergebnis verglichen. Die Bodenbedeckung dieser Flächen ist bekannt und wird als „wahr“ angesehen. Die Auswahl der Referenzflächen sollte unabhängig von den Trainingsgebieten sein, die genutzt wurden, um den Klassifikationsalgorithmus zu eichen. Oft werden für die Genauigkeitsanalyse existierende Landnutzungskarten als Referenz herangezogen. Dabei sollte beachtet werden, daß solche Karten häufig nicht aktuell sind oder daß deren Genauigkeit nicht bekannt ist. Auch wird in vielen Fällen ein anderes Klassenschema verwendet, so daß ein direkter Vergleich nicht möglich ist. Dies kann eine potentielle Fehlerquelle sein. Eine gute geometrische Übereinstimmung, d.h. eine korrekte Registrierung der Referenzdaten und des Klassifikationsergebnisses, ist Bedingung für eine aussagekräftige Genauigkeitsanalyse (FOODY 2002). Luftbilder oder höher aufgelöste Daten gelten gemeinhin als gute Vergleichsgrundlage (CONGALTON 1991). Es wird davon ausgegangen, daß die Interpretation der höher aufgelösten Daten zu 100 % korrekt ist (was nur eingeschränkt zutrifft). Das Ergebnis der Genauigkeitsanalyse trägt den Fehler der Referenzdaten in sich.

Vielfach werden Felddaten genutzt, um die Qualität einer Klassifikation zu bestimmen. Das Sammeln von Felddaten und die entsprechende Integration in ein Klassenschema ist im Prinzip auch eine Art Klassifikationsprozeß, der ebenso fehlerhaft sein kann. Eine Kenntnis der Methoden, mit der die Felddaten erfaßt wurden, sowie genaue Definitionen der Klassen sind daher notwendig, um die Tauglichkeit der Referenzdaten abzuschätzen. Genauso wichtig ist die räumliche und inhaltliche Detailtiefe, mit der die Felddaten erfaßt wurden. SMITS et al. (1999) weisen in diesem Zusammenhang darauf hin, daß Feldkampagnen oft teuer sind und dementsprechend gut geplant sein müssen. Für jede Klasse sollten genug Felddaten gesammelt werden, um bei der späteren Genauigkeitsanalyse abgesicherte Ergebnisse erzielen zu können.

Für die Genauigkeitsanalyse der IKONOS-Klassifikation werden in dieser Arbeit pro Klasse zwischen 10 und 59 Referenzobjekte gewählt, die eine durchschnittliche Fläche von 300 m<sup>2</sup> (Einzelbäume) bis 6000 m<sup>2</sup> (Grünland) pro Objekt aufwiesen. Die Auswahl der Referenzobjekte stützt sich auf

terrestrische Kampagnen und sehr hochaufgelöste Luftbilder. Die Klassifikation von Luftbildern wird einer gut dokumentierten visuellen Interpretation desselben Bildmaterials gegenübergestellt. In jedem Fall werden die Referenzdaten mit dem Klassifikationsergebnis verglichen und auf statistischem Weg die Genauigkeit der Klassifikation über eine Konfusionsmatrix ermittelt.

### 3.7.2 Konfusionsmatrix

Um die Genauigkeit der Klassifikation zu beschreiben und Informationen über die Art des Fehlers zu erhalten, gilt die **Konfusionsmatrix** als das effektivste Werkzeug (SMITS et al. 1999, FOODY 2002). Sie wurde deshalb auch für diese Arbeit herangezogen. Eine Konfusionsmatrix ist eine Tabelle, bei der klassenweise die Ergebnisse der Klassifikation den Referenzdaten gegenüber gestellt werden (Abb. 11a). Die Spalten entsprechen normalerweise den Referenzdaten, während die Zeilen das Klassifikationsergebnis wiedergeben (LILLESAND und KIEFER 2000). Verwechslungen innerhalb einer Klasse sind sofort ersichtlich. Je nach Blickwinkel werden zwei Genauigkeiten unterschieden: Die Produzentengenauigkeit gibt an, wie „gut“ eine Klasse gefunden wurde und ergibt sich aus dem Quotienten zwischen der richtig klassifizierten Fläche und den Referenzflächen. Die Benutzergenauigkeit gibt an, welcher Teil der insgesamt gefundenen Fläche tatsächlich dieser Klasse in den Referenzdaten entspricht. Sie berechnet sich aus dem Quotienten der richtig klassifizierten Fläche und der gesamten klassifizierten Fläche. In diesem Zusammenhang wird auch von Einschluß- und Ausschlußfehler gesprochen.

Klassifikation	Referenz					Genauigkeit (%)	
	Klasse 1	Klasse 2	...	Klasse N	Gesamt $\sum$	Benutzer	Produzent
Klasse 1	$p_{11}$	$p_{12}$	...	$p_{1N}$	$p_{1+}$	$\frac{p_{11}}{p_{1+}}$	$\frac{p_{11}}{p_{+1}}$
Klasse 2	$p_{21}$	$p_{22}$	...	$p_{2N}$	$p_{2+}$	$\frac{p_{22}}{p_{2+}}$	$\frac{p_{22}}{p_{+2}}$
...	...	...	...	...	...	...	...
Klasse N	$p_{N1}$	$p_{N2}$	...	$p_{NN}$	$p_{N+}$	$\frac{p_{NN}}{p_{N+}}$	$\frac{p_{NN}}{p_{+N}}$
Gesamt $\sum$	$p_{+1}$	$p_{+2}$	...	$p_{+N}$	$p_{++}$	Gesamtgen.: $\frac{\sum_{k=1}^N p_{kk}}{p_{++}}$	

**Abb. 11a:** Schema einer Konfusionsmatrix, inklusive der Angaben über Benutzer-, Produzenten- und Gesamtgenauigkeit (nach SMITS et al. 1999 und FOODY 2002).

Es gibt noch keinen Konsens darüber, welche Methode die Klassifikationsgenauigkeit am besten beschreibt (FOODY 2002). Weit verbreitet sind die KAPPA-Statistiken, die auf der Konfusionsmatrix basieren. Der **KAPPA-Index** ist ein Maß dafür, welcher Anteil der Klassenübereinstimmung mit der Referenz tatsächlich richtig ist und welcher Anteil rein zufällig getroffen wurde (CONGALTON 1991). Auch im Rahmen der vorliegenden Arbeit wurde der KAPPA-Index bei der Genauigkeitsanalyse berechnet. Sein Wertebereich liegt zwischen 0 und 1, wobei 0 bedeutet, daß die Übereinstimmung rein zufällig ist und bei einem Wert von 1 die Genauigkeit als zu hundert Prozent richtig angesehen werden kann. Ein KAPPA-Index der kleiner als 0,4 ist, deutet eine schlechte Klassifikationsgenauigkeit an, wohingegen Werte größer 0,75 als sehr gutes Ergebnis angesehen werden (DE LANGE 2002). SMITS et

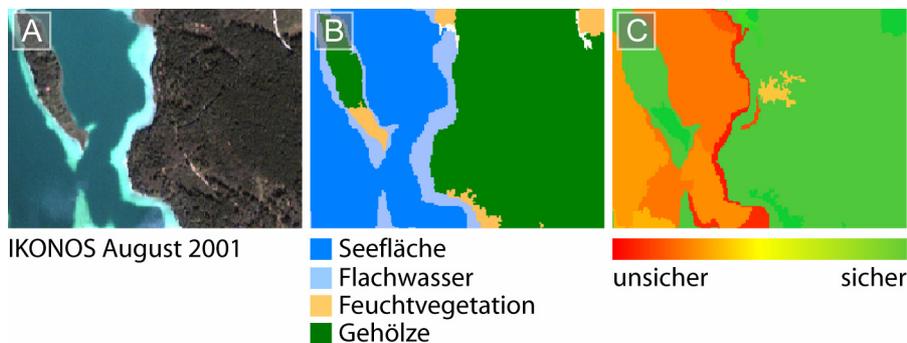
al. (1999) fordern eine Standardisierung bei der Angabe der Klassifikationsgenauigkeit. So sollte die Konfusionsmatrix inklusive der entsprechenden KAPPA-Statistiken bei keiner Studie fehlen.

**Formel 2:** KAPPA-Index.

$$\kappa = \frac{\text{gefundene Genauigkeit} - \text{zufällige Übereinstimmung}}{1 - \text{zufällige Übereinstimmung}}$$

Für weiterführende Informationen zur Berechnung des KAPPA-Indexes wird auf CONGALTON (1991) und DE LANGE (2002) verwiesen.

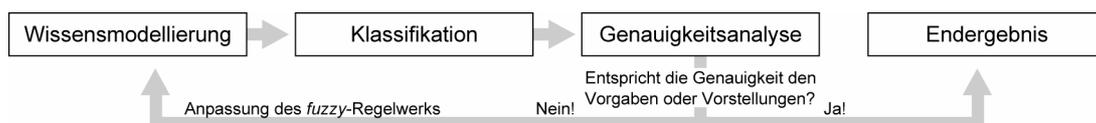
In eCognition stehen dem Benutzer weitere Werkzeuge für eine automatische Genauigkeitsanalyse zur Verfügung. So lassen sich Zuverlässigkeitskarten ausgeben. In diesen Karten wird die Verlässlichkeit einer Klassifikation dargestellt. Wie bereits erwähnt, kann ein Bildobjekt mehreren Klassen zu verschiedenen Anteilen zugewiesen werden. Die **Zuverlässigkeitskarte** gibt die Differenz der maximalen *fuzzy*-Klassenzuweisung zu einer eventuellen weiteren Klassenzuweisung an. Somit ist auf einen Blick ersichtlich, wie verlässlich eine Ergebniskarte ist. In Abbildung 11b ist eine Zuverlässigkeitskarte beispielhaft dargestellt.



**Abb. 12b:** Übersicht zu einer Zuverlässigkeitskarte. IKONOS Echtfarbenbild (A), entsprechende Klassifikation (B), Zuverlässigkeitskarte (C). Die Wasserflächen sind „unsicher“ klassifiziert, da in diesem Fall das verwendete Klassifikationsregelwerk nur ungenau zwischen Seeflächen und Flachwasser differenziert. Der Bearbeiter hat damit einen Hinweis darauf, daß die Gewässer genauer beschrieben werden sollten.

In der vorliegenden Arbeit wurde auf die Ausgabe einer Zuverlässigkeitskarte verzichtet, denn sie ist nur eingeschränkt aussagekräftig, wenn eine Ebene unter Zugriff auf andere Ebenen klassifiziert wird. Ein „unsicheres“ Überobjekt kann zum Beispiel zu einem „sicher“ klassifizierten Objekt auf einer untergeordneten Ebene führen. Eine Zuverlässigkeitskarte, wie von der Software vorgesehen, ist also mit „Vorsicht“ zu verwenden.

Sollte das Ergebnis der Genauigkeitsanalyse nicht den Vorgaben des Projektes oder den Vorstellungen des Bearbeiters entsprechen, so müssen Fehlklassifikationen oder Instabilitäten untersucht und das Klassifikationsregelwerk hinreichend angepaßt werden. Die Vorgehensweise der objektorientierten Methode kann dementsprechend als iterativer Prozeß verstanden werden (Abb. 12).



**Abb. 13:** Iterativer Ablauf der objektorientierten Klassifikation: Wissensmodellierung - Klassifikation - Genauigkeitsanalyse - eventuell Anpassung der Klassenregelwerke.

## 3.8 Ergebnis

### 7. Schritt

Die Endprodukte einer objektorientierten Klassifikation sind:

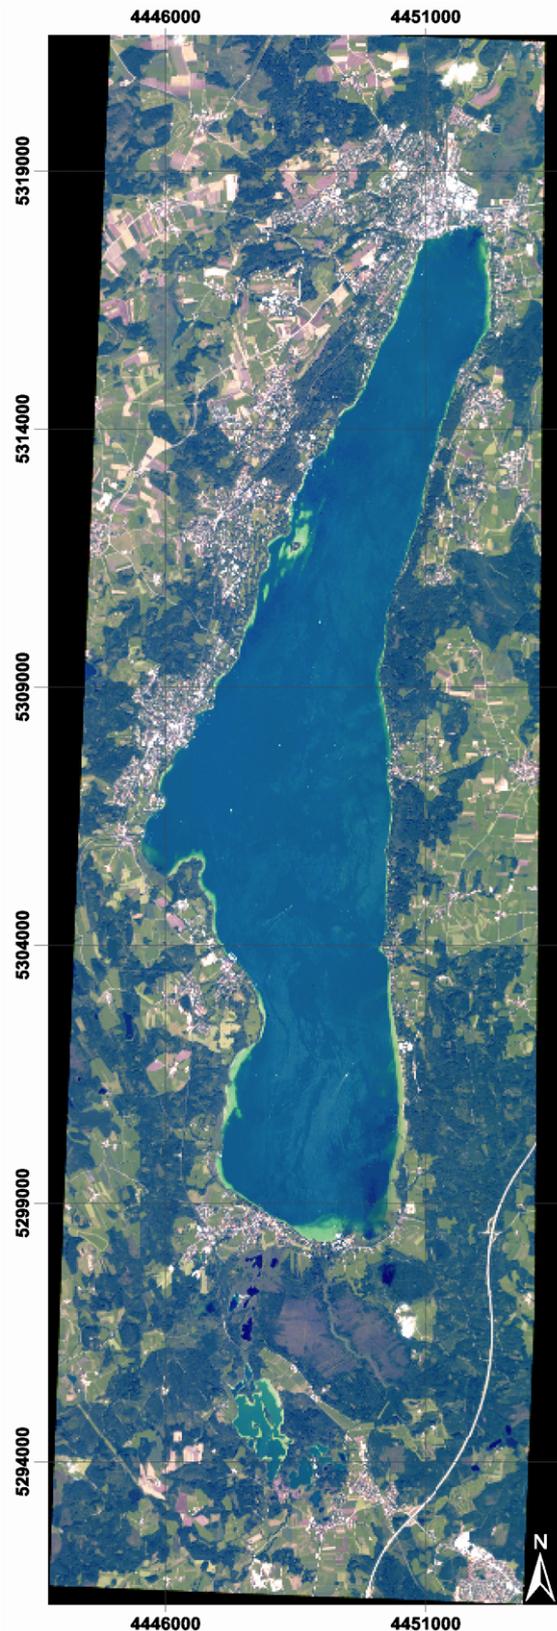
1. **Eine digitale thematische Karte im GIS-kompatiblen ArcView-Shape-Format:** der Nutzer hat die Möglichkeit, den Ergebnisdatensatz in ein Geographisches Informationssystem zu übertragen, dort zu verwalten, weiterzuverarbeiten und digital oder in Druckform auszugeben.
2. **Eine Datenbankdatei mit den Objekteigenschaften:** sämtliche Objekteigenschaften können für jedes Bildobjekt exportiert und an die ArcView-Shape-Datei angehängt werden.
3. **Eine Genauigkeitsanalyse:** sie liefert eine Konfusionsmatrix mit entsprechenden Produzenten- und Benutzergenauigkeiten, die Auskunft über eventuelle Fehlklassifikationen gibt.
4. **Eine digitale Verlässlichkeitskarte:** in dieser Karte sind die *fuzzy*-Zugehörigkeitswerte für jedes Objekt verzeichnet. Somit stellt sie die Verlässlichkeit der Zuweisung in Zusammenhang mit dem verwendeten Klassifikationsregelwerk dar.
5. **Ein Klassifikationsregelwerk:** in diesem Regelwerk sind sämtliche Klassenbeschreibungen und Zugehörigkeitsfunktionen gespeichert. Es läßt sich beliebig für weitere Projekte verwenden und auf andere Gebiete übertragen.

In den beiden folgenden Kapiteln findet sich eine Beschreibung des Untersuchungsgebiets dieser Studie sowie der bearbeiteten Datengrundlagen. Im Anschluß daran wird Umsetzung der Ablaufstruktur aus Kap. 3 anhand dreier Fallstudien in Kapitel 6 dargestellt.

## 4 Untersuchungsgebiet

Das Untersuchungsgebiet des Projekts AQUATIC umfaßt den Starnberger See und die Region um die Osterseen. Es liegt etwa 20 km bis 55 km südwestlich von München und verteilt sich auf 15 Gemeinden innerhalb der Landkreise Starnberg, Bad Tölz und Weilheim-Schongau. Die Gesamtfläche des Untersuchungsgebiets wird durch die Ausdehnung der verfügbaren IKONOS-Satellitendaten vorgegeben und beträgt ca. 265 km<sup>2</sup> (Abb. 13). Naturschutzfachlich interessant sind vor allem die Feuchtflächen, die eine Vielzahl von geschützten Tier- und Pflanzenarten beheimaten. Eine Fläche von 74 km<sup>2</sup> sind als Naturschutz-, FFH- (Fauna-Flora-Habitat nach 92/43/EWG) oder SPA- Gebiete (Special-Protected-Area nach 79/409/EWG) ausgewiesen, wobei das SPA-Gebiet Starnberger See allein 56 km<sup>2</sup> umfaßt und vollständig in die FFH-Gebietsfläche integriert ist.

Das Untersuchungsgebiet liegt im Ammer-Loisach-Hügelland und ist als unruhig bewegte Eiszerfallandschaft mit typischen glazialen Geländemorphologien zu charakterisieren. Vor allem die Würm-Eiszeit, die vor etwa 25000 Jahren ihren Höhepunkt hatte und vor 12000 Jahren dann deutlich abklang, hinterließ ihre Spuren in der formenreichen Morphologie. Diese ist geprägt durch typische Eisrandterrassen und die Formtypen Oser, Kames und Drumlins. Beim Starnberger See handelt es sich um einen Zungenbeckensee, der durch den Isar-Loisach-Gletscher während der Würm-Eiszeit geformt wurde (BODECHTEL 1965). Ursprünglich besaß der Starnberger See eine erheblich größere Ausdehnung als heute und umfaßte auch die Osterseen, das Weidfilz sowie das nördlich des Sees gelegene Leutstettner Moor (MEYER und SCHMIDT-KALER 2002). Diese Bereiche verlandeten nach der letzten Eiszeit in Folge einer allmählichen Wasserpiegelsenkung um 18 m bis 20 m. Auch die Geomorphologie der südlich des Starnberger Sees gelegenen Osterseen wurde durch den Isar-Loisach-Gletscher geprägt. Die Osterseen sind eine Kette aus 19 unterschiedlichen Seen, die über Kanäle miteinander verbunden sind und über den Bodenbach



**Abb. 14:** IKONOS-Aufnahme des Untersuchungsgebiets vom 18.08.2001 in Echtfarben: rot: 0,63 - 0,69  $\mu\text{m}$ , grün: 0,52 - 0,60  $\mu\text{m}$ , blau: 0,4

in den Starnberger See abfließen. Diese Seen sind sogenannte Toteisseen. Während des Rückzugs des Isar-Loisach-Gletschers brachen Eismassen ab und blieben zurück. An den Rändern der nur langsam abschmelzenden Toteisblöcke lagerte sich fluvioglaziales Schottermaterial ab (BODECHTEL 1965). Die Schotterdecke brach nach dem Abschmelzen der Eisblöcke ein und bewirkte so die typischen kesselförmigen Vertiefungen der Osterseen (Toteisbecken). Die Seen werden nahezu ausschließlich durch unterirdische Quellen mit kalkreichem und nährstoffarmem Wasser gespeist (RAEDER 1990), worin auch die Ursache für die vergleichsweise schwache Verlandungstendenz der Seen besteht (AMMER und PRÖBSTL 1991). Aufgrund des Vorkommens verschiedenster ökologischer Gesellschaften auf sehr kleinem Raum wurden die Osterseen schon früh als „*vortreffliche Studienobjekte auch hinsichtlich ihrer Abhängigkeit voneinander*“ erkannt (POHL 1979). Die Osterseen gehören zu den wenigen erhaltenen kalkreichen oligotrophen Gewässern Bayerns und bilden gemeinsam mit dem Weidfilz das Naturschutzgebiet „Osterseenlandschaft“.

### **Naturraum**

Das Landschaftsbild ist durch einen kleinräumigen Wechsel von verschiedenen Elementen geprägt. Dies sind vor allem Siedlungen, Kulturland, Wälder und freie Moorflächen. Mais, Kartoffeln und Getreide sind die überwiegend angebauten Feldfrüchte, doch beschränken sich die landwirtschaftlichen Aktivitäten in der Hauptsache auf Grünlandnutzung. Es finden sich extensive, nicht gedüngte Wiesen- und Weidegebiete sowie intensive, gedüngte und ertragsstarke Wiesen- und Weideflächen. Ökologisch besonders interessant sind die extensiv genutzten Trockenrasen und die Vielzahl an artenreichen Streuwiesen. Das Gesamtgebiet ist zu einem großen Teil bewaldet und wird entsprechend forstwirtschaftlich genutzt. Auch Überreste der für diesen Naturraum typischen Waldgesellschaften (Buchen-Tannen-Fichten-Wälder, Bruchwälder, edellaubbaumreiche Auen- und Schneeheide-Kiefern-Wälder und Moorrandwälder bestehend aus Latschen und Föhren) sind zu finden (AMMER und PRÖBSTL 1991, POTT 1995). In den Feuchtgebieten des Untersuchungsgebiets existieren baumfreie, zum Teil verbuschte Hochmoorbereiche, Kalkflachmoore (Niedermoore), kleinere Verlandungszonen sowie große Flächen mit Röhricht- und Seggenbeständen (AMMER und PRÖBSTL 1991, ANDRESEN 2004).

Innerhalb des gesamten Untersuchungsgebietes wurden kleinere Testgebiete ausgewählt, welche für das Gebiet typische Landschaftsstrukturen aufweisen. In diesen Testgebieten wurden verschiedene methodische Ansätze unter Nutzung von hochauflösenden Luftbildern, multisaisonalen IKONOS-Daten und externen GIS-Datenebenen entwickelt. Im folgenden werden die angewendeten Methoden und Ergebnisse des Projektes AQUATIC im Teilbereich Landnutzung anhand verschiedener Anwendungsbeispiele vorgestellt.

## 5 Datengrundlagen

### 5.1 IKONOS-Satellitendaten

Im Rahmen des AQUATIC-Projektes wurden zwei IKONOS-Satellitenaufnahmen, vom Beginn (24.04.2001) und vom Ende (12.08.2001) der Vegetationsperiode des Jahres 2001, untersucht. Beide Szenen wurden um ca. 10.15 Uhr vormittags aufgezeichnet. Jeweils eine multispektrale und eine panchromatische Aufnahme wurden erworben. Die Bilder waren aufgrund äußerst günstiger Wetterbedingungen nahezu wolkenfrei. Zum damaligen Zeitpunkt betragen die Kosten 18 \$/km<sup>2</sup> für panchromatische Daten und 24 \$/km<sup>2</sup> für multispektrale Daten. Der finanzielle Gesamtaufwand allein für die Daten betrug knapp 25000 \$.

Der IKONOS-Satellit (betrieben von der amerikanischen Firma SpaceImaging) ist im September 1999 erfolgreich in den Orbit gestartet und liefert seit Januar 2000 Daten der Erdoberfläche. IKONOS war 1999 das System mit der höchsten Sensoraufösung, das kommerziell für die zivile Nutzung verfügbar war (TOUTIN und CHENG 2000). Zum jetzigen Zeitpunkt existieren u. a. mit QuickBird (Digital Globe), EROS-A1 (ImageSat) und SPOT-5 (Spot Image) eine große Auswahl an hochauflösenden Systemen zur Erdbeobachtung.

IKONOS gehört zu den Satelliten mit einer fast polaren Erdumlaufbahn. Sein Orbit führt mit einer leichten Neigung über die Pole (Inklination: 98,1°) und verfolgt eine sonnensynchrone Flugbahn. Das bedeutet, daß ein Gebiet immer zur gleichen Sonnenortszeit überflogen wird. Aufgrund der sonnensynchronen Umlaufbahn ist bei allen Aufnahmen ein vergleichbarer Sonnenwinkel gesichert. Der Satellit bewegt sich in 681 km Höhe um die Erde und hat nach 98 Minuten diese einmal vollständig umkreist. Die Aufnahmebreite beträgt 11,3 km im Nadir und 13,8 km bei einem Schrägblickwinkel (*Off-Nadir*) von 26°. Im multispektralen Aufnahmemodus beträgt die Auflösung 4 m und im panchromatischen Modus 1 m. Die vier multispektralen Bänder liegen im sichtbaren Bereich des Spektrums (blau: 0,45-0,52 µm, grün: 0,52-0,60 µm, rot: 0,63-0,69 µm) und dem nahen Infrarotbereich (NIR: 0,76-0,90 µm). Das panchromatische Band (verkürzt auch PAN-Band bzw. PAN-Kanal) reicht von 0,45 µm bis 0,90 µm und geht damit ebenfalls bis in den nahen Infrarotbereich. Der nominale Wiederholungszyklus, also das zeitliche Intervall bis zu einem erneuten Überflug in gleicher Orbital-Position, beträgt 140 Tage (DECH et al. 2003). Durch die Möglichkeit, den Sensor sowohl in Flugrichtung als auch quer zur Flugrichtung zu schwenken, ist ein Wiederholungszyklus von drei Tagen möglich (MANSBERGER 2000).

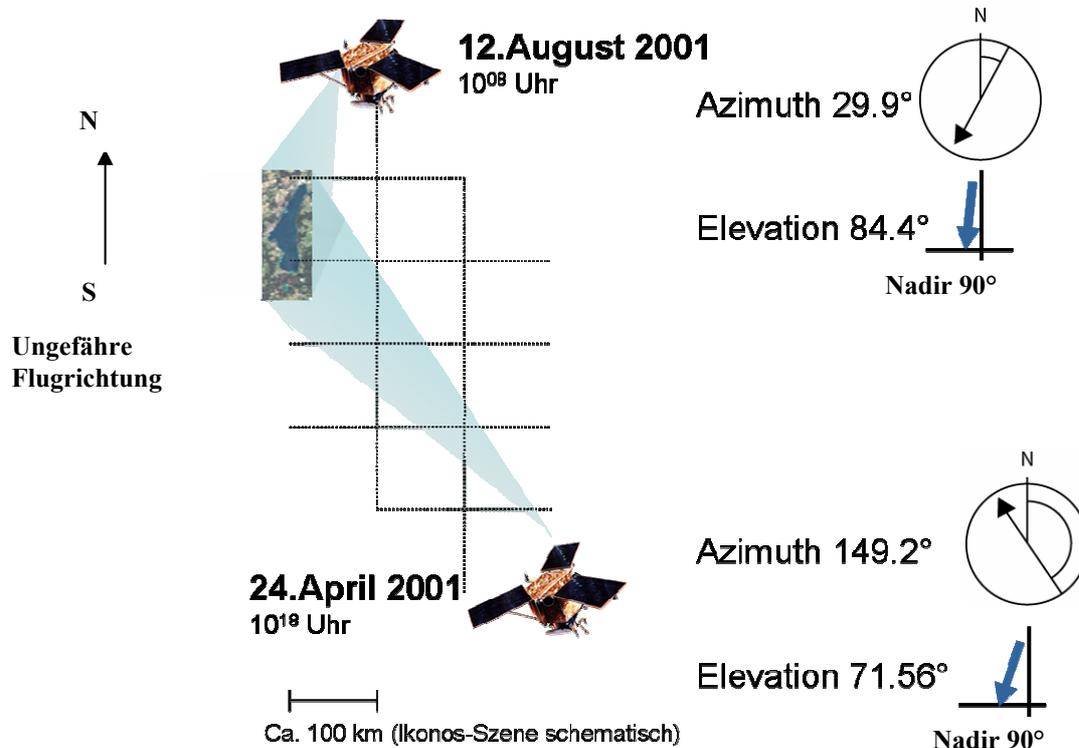
SpaceImaging bietet verschiedene Bildprodukte an, die sich hauptsächlich bezüglich der Genauigkeit der Georeferenzierung unterscheiden. Im Projekt AQUATIC wurde das GEO-Produkt verwendet, welches nicht orthorektifiziert<sup>1</sup> ist und laut SPACEIMAGING (2002) eine beschränkte Lagegenauigkeit von +/- 25 m exklusive Geländeverzerrungen aufweist. DIAL und GRODECKI (2001) stellten bei ihrem GEO-Produkt allerdings Verzerrungen von bis zu 600 m bei flachen Aufnahmewinkeln fest. Die in dieser Arbeit verwendeten Daten waren ursprünglich auf UTM (Universal Transverse Mercator)-Ellipsoid WGS-84 referenziert. Laut GERLACH (2002) stützt sich die Georeferenzierung des GEO-Produkts auf die direkte Sensororientierung von IKONOS, welche durch eine Kombination von GPS, Inertialsystem und Sternensensoren errechnet wird. Im März 2003 wurden zu den beiden IKONOS-Aufnahmen von SpaceImaging Daten zu Aufnahmesituation (IGM: *image geometry model*) kostenfrei

---

<sup>1</sup> Orthorektifikation: Übertragung in eine orthogonale Projektion

nachgeliefert, so daß das GEO-Produkt zu einem ORTHOKIT-Produkt aufgewertet werden konnte. Das IGM enthält Koeffizienten für eine Polynomialtransformation, die das Sensormodell hochgenau nachbilden (auch RPC, *rational polynomial coefficient*). Diese Informationen sind notwendig, um die Daten in Kombination mit einem Geländemodell hochgenau zu orthorektifizieren.

Die schematische Darstellung in Abbildung 14 gibt Auskunft über die Aufnahmebedingungen der beiden IKONOS-Szenen.



**Abb. 15:** Aufnahmesituation für die bearbeiteten IKONOS-Szenen. „Elevation“ beschreibt den vertikalen Winkel des Sensors zur horizontalen Ebene. „Azimuth“ beschreibt den horizontalen Blickwinkel im Uhrzeigersinn des Sensors mit Nullpunkt im Norden.

### 5.1.1 Radiometrie der IKONOS-Aufnahmen

Die Bilddaten haben eine radiometrische Tiefe von 11 Bit, das bedeutet, daß 2048 Grauwerte pro Band möglich sind (vgl. Landsat-TM: 8 Bit: 256 Grauwerte möglich). Die panchromatischen Daten werden standardmäßig einer Grauwerttransformation unterzogen, während die multispektralen Aufnahmen ungestreckt ausgeliefert werden. Durch die Grauwertstreckung des PAN-Kanals ist ein hoher Detailreichtum gegeben: Es waren zum Teil Straßenmarkierungen, Boote oder Hochspannungsleitungen erkennbar. Allerdings fanden sich auch einige Übersteuerungspunkte, die in Nord-Süd-Richtung gestreckt waren (Abb. 15). Diese Fehler waren ausschließlich in den PAN-Daten zu finden. Auch MEINEL und REDER (2001) fanden bei einer Studie 0,08 % der Fläche des panchromatischen Bildes übersteuert und dementsprechend fehlerhaft. In Abbildung 15 sind beispielhaft Übersteuerungspunkte aus der IKONOS-PAN-Aufnahme vom April 2001 dargestellt.



**Abb. 16:** Übersteuerungspunkt (roter Kreis) in der IKONOS-PAN-Aufnahme vom April (A). Die August-Aufnahme (B) ist radiometrisch korrekt und weist keine Übersteuerungspunkte auf.

Die im Projekt AQUATIC verwendeten Daten zeigten, abgesehen von einigen Übersteuerungspunkten, keine weiteren radiometrischen Auffälligkeiten. Die Übersteuerungspunkte konnten nicht korrekt klassifiziert werden, was allerdings aufgrund der geringen betroffenen Fläche nicht ins Gewicht fiel.

### 5.1.2 Georeferenzierung und Lagegenauigkeit der IKONOS-Aufnahmen

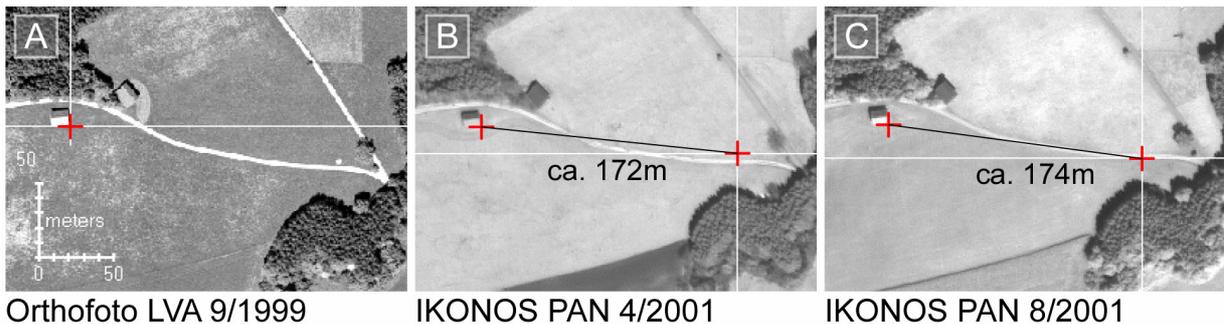
Um eine Weiterverarbeitung der Ergebnisse des Projektes AQUATIC in einem GIS zu ermöglichen und um einen einheitlich referenzierten Geodatenbestand zu gewährleisten, wurden die IKONOS-Daten in das in Deutschland übliche Gauß-Krüger-Koordinatensystem übertragen.

Geometrische Entzerrung und Prozessierung von Fernerkundungsdaten haben eine wichtige Schlüsselstellung bei der Integration, Analyse und Verwaltung von Geodaten aus verschiedenen Quellen. Nach TOUTIN (2004) und ALBERTZ (2001) lassen sich grundsätzlich zwei Richtungen der geometrischen Entzerrung für Fernerkundungsdaten unterscheiden:

1. Im **geometrischen (oder empirischen) Ansatz** wird auf eine Modellierung der Aufnahmegeometrie verzichtet. Es werden lediglich Paßpunkte im Referenz-Datensatz und dem zu entzerrenden Bild gesucht und anhand der Paßpunkte ein geometrisches Modell zur Entzerrung errechnet.
2. Im **photogrammetrischen (oder physischen) Ansatz** wird die Aufnahmegeometrie im Raum und die Blickwinkelgeometrie rekonstruiert (innere und äußere Orientierung (vgl. dazu ALBERTZ 2001)). Diese Geometrien sind zum Teil aus den mitgelieferten Metadaten ableitbar bzw. sind als Näherungswerte verfügbar. Meist werden auch topologisch bedingte Verzerrungen mit Hilfe eines Geländemodells (DGM) korrigiert.

Zur Bestimmung des Transformationsmodells werden in beiden Verfahren Paßpunkte benötigt. Das sind Punkte, die in den Bilddaten eindeutig identifizierbar sind und deren Koordinaten aus einem übergeordneten Referenzsystem bekannt sind (ALBERTZ 2001). Für die Referenzierung der IKONOS-Daten wurden Paßpunkte aus Orthophotos des Bayerischen Landesvermessungsamts (LVA) verwendet.

Die IKONOS-Daten wurden von UTM Zone 32 auf Gauß-Krüger Zone 4 (Sphäroid: Bessel, Datum: Potsdam) referenziert. Unter Verwendung der Standardumrechnung von ERDAS Imagine (LEICA GEOSYSTEMS 2002b) wurden Ungenauigkeiten von bis zu 180 m zu einer Orthophotoreferenz des LVA (Auflösung 40 cm) festgestellt. Auch lagen die beiden IKONOS-Szenen nicht bildpunktgenau aufeinander (Abb. 16).



**Abb. 17:** Unter Verwendung der Standardumrechnung der Fernerkundungsapplikation Erdas Imagine 8.5 von UTM auf Gauß-Krüger kam die Geokoordinate des Referenzpunktes aus dem Orthophoto des LVA (A) jeweils an anderer Stelle auf den IKONOS PAN Daten (B/C) zum Liegen.

Die Betreiberfirma SpaceImaging selbst empfiehlt, das GEO-Produkt ausschließlich für Anwendungen zu nutzen, die keine hohen Lagegenauigkeiten voraussetzen (SPACEIMAGING 2002).

Im Rahmen dieser Arbeit wurden drei Verfahren zur Georeferenzierung untersucht:

1. **Polynomialtransformation** 2ter Ordnung: bei diesem Standardverfahren wird die Position der unbekannt Koordinaten durch Interpolation der Koordinaten der Paßpunkte errechnet (LEICA GEOSYSTEMS 2002a).
2. **IKONOS-Sensormodell** aus ERDAS Imagine 8.5.1: bei diesem Modell werden die von SpaceImaging mitgelieferten Aufnahmegeometrie-Daten, also die IGMs genutzt.
3. **IKONOS-Sensormodell** aus PCI Orthoengine 7.1: das Modell errechnet Näherungswerte für die Aufnahmegeometrie aus den mitgelieferten Metadaten der IKONOS-Aufnahmen. Dieses Modell wurde von TOUTIN (2003) entwickelt.

Die erste Methode ist ein rein geometrischer Ansatz, bei dem kein Geländemodell verwendet wird, um topographische Verzerrungen herauszurechnen. Aus diesem Grund eignet sich dieses Verfahren nur für Regionen mit geringer Geländetopologie und Bilddaten mit stetigen, mathematisch nachvollziehbaren Verzerrungsfehlern. Bei den photogrammetrischen Verfahren (2 und 3) werden die Aufnahmegeometrien und Geländehöhen berücksichtigt. Als Geländemodell wurde das Basis-DGM-25 des Bayerischen Landesvermessungsamtes verwendet. Es hat eine Gitterweite von 50 m \* 50 m.

Als Maß für die Angabe des Fehlers einer Referenzierung hat sich der „Mittlere Quadratische Fehler“ (MQF) etabliert. Der MQF entspricht der Abweichung der Paßpunkte zu der vom Modell errechneten Position und hat als Einheit die Auflösung der zu referenzierenden Daten (bei IKONOS-PAN 1 m). Für eine qualitativ gute Referenzierung sollte er kleiner als eins sein (LEICA GEOSYSTEMS 2002a). In Tabelle 2 sind die MQFs der angewendeten Referenzierungsmethoden für die IKONOS-PAN-Daten (24.04.2001) angegeben.

**Tab. 2:** MQF der angewendeten Verfahren.

Modell	Anzahl Paßpunkte	MQF-Fehler [m]
1. Polynom 2ter Ordnung	116	4,68
2. Sensormodell ERDAS	14	1,00
3. Sensormodell PCI	14	0,90

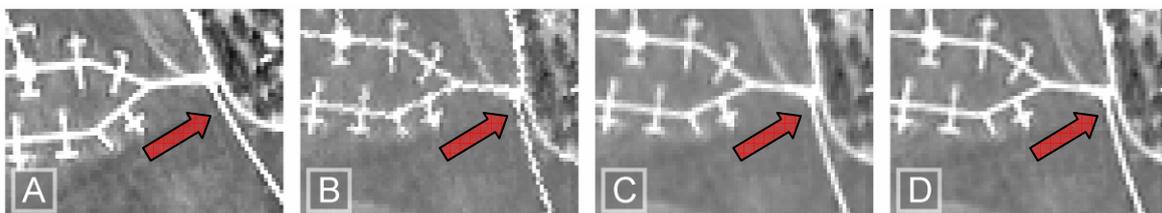
Die besten Ergebnisse lieferte das Berechnungsmodell von TOUTIN (2003), das in der Photogrammetrie-Software PCI Orthoengine ab Version 7.1 implementiert ist.

### 5.1.3 Resampling

Durch die Georeferenzierung werden die Daten des Eingabebilds in einem Ausgabebild neu geordnet. Da das Raster von Eingabebild und Ausgabebild nicht mehr exakt dasselbe ist, stellt sich das Problem der Grauwertzuweisung. Der Vorgang der Grauwertzuweisung wird als *Resampling* bezeichnet. Drei *Resampling*-Verfahren sind allgemein verbreitet:

1. **Nächster-Nachbar-Methode:** der Grauwert jenes Bildpunkts des Eingabebilds wird übernommen, der den berechneten Koordinaten des Ausgabebildes am nächsten liegt. Methodisch bedingt kann ein geometrischer Fehler von bis zu einem halben Bildpunkt entstehen. Dies kann bei ursprünglich geraden Strukturen eine zerlegte oder unzusammenhängende Erscheinung im Ausgabebild verursachen.
2. **Bilineare Interpolation:** sie berechnet den gesuchten Grauwert durch lineare Interpolation zwischen den vier benachbarten Grauwerten. Mit diesem Verfahren werden kontrastreiche Bildkanten geglättet.
3. **Bikubische Interpolation:** dabei werden die Werte der 4x4 umliegenden Bildpunkte verwendet. Das Verfahren stellt somit eine Interpolation höherer Ordnung dar.

In Abbildung 17 werden die drei *Resampling*-Verfahren anhand eines Bildausschnitts verglichen. Beim Nächster-Nachbar-Verfahren (Abb. 17 (B)) sind Treppeneffekte erkennbar, während bei der bilinearen (Abb. 17 (C)) bzw. bikubischen Interpolation (Abb. 17 (D)) die Kanten „verwaschen“ wirken und dadurch die spektralen Informationen beeinträchtigen.



**Abb. 18:** Vergleich der drei *Resampling*-Verfahren: Original IKONOS Rot-Band (A), Nächster-Nachbar-Methode (B), Bilineare Interpolation (C), Bikubische Interpolation (D). Der rote Pfeil deutet auf dieselbe Straße in allen drei *Resampling*-Beispielen (B - C). Hier ist der Unterschied besonders deutlich zu erkennen.

Für die IKONOS-Daten in dieser Arbeit wurde als *Resampling*-Methode die Nächster-Nachbar-Methode verwendet. Damit wurde ein gewisser Verlust an Darstellungsqualität in Kauf genommen, weil die oberste Prämisse war, die ohnehin eingeschränkten spektralen Informationen nicht weiter zu verändern. Aus demselben Grund empfehlen auch RICHARDS und JIA (1999) diesen Ansatz zu verwenden.

## 5.2 Luftbilder

Die im Projekt AQUATIC verwendeten Luftbildaufnahmen stammen alle vom Bayerischen Landesvermessungsamt (LVA) und wurden als Senkrechtaufnahmen in Zentralperspektive aufgenommen. Die Analyse multitemporaler Schwarz/Weiß-Luftbilder ist auf ein Testgebiet um Iffeldorf und die südlichen Osterseen beschränkt. Bearbeitet werden Luftbilder aus den Jahren 1956, 1976 und 2000, die analog oder digital vorliegen. Eine Übersicht der Luftbilder gibt Tabelle 3.

**Tab. 3:** Bearbeitete Luftbilder.

Aufnahmezeitpunkt	Luftbildtyp	Aufnahmemmaßstab	Bildpunktauflösung
06/1956	Analoge Stereoluftbilder	1 : 8000	0,70 m
06/1976	Analoge Luftbilder	1 : 25000	0,60 m
09/2000	Digitale Orthophotos	1 : 15000	0,40 m

Das Luftbild aus dem Jahr 2000 wurde vom LVA in digitaler Form bereits als Orthophoto geliefert. Die Luftbilder von 1956 und 1976 lagen als analoge Abzüge aus den historischen Archiven des LVA vor. Bei „Roh-Bildern“ in Zentralperspektive treten Maßstabsunterschiede auf, die abhängig von der Position im Bild und von der Geländetopologie sind. Diese Maßstabsunterschiede oder Verzerrungen mußten durch Orthorektifikation korrigiert werden, um einen Vergleich mit bestehenden Geodaten und Landkarten zu ermöglichen. Das bedeutet, daß die Bilder von der ursprünglichen Zentralperspektive durch eine differentielle Entzerrung in eine orthogonale Projektion gebracht wurden.

Nachstehend wird der komplexe Vorgang der Orthobilderstellung kurz dargestellt. Umfassende Informationen dazu finden sich bei KONECNY (1984).

Für die Orthobilderstellung sind folgende Schritte notwendig:

1. **Scannen der Luftbilder.**
2. Berechnung der **inneren und äußeren Orientierung** anhand von Paßpunkten, Rahmenmarken und Kammerdaten.
3. **Differentielle Entzerrung** anhand eines digitalen Geländemodells und Ableitung eines **Ortholuftbilds.**

zu 1.) Beim **Scannen der Luftbilder** wurden verschiedene Scannermodelle, Scanauflösungen und Einstellungen getestet. Grundsätzlich läßt sich feststellen, daß insbesondere die Kontrasteinstellungen beim Scannen erheblichen Einfluß auf die Qualität haben. Nach dem Scan-Vorgang liegen die Luftbilder von 1956 und 1976 in digitaler Form als unkomprimierte Grafikdatei (TIF-Dateiformat) mit einer Datentiefe von 8 Bit (256 Graustufen) vor.

zu 2.) Die photogrammetrische Bildmessung stützt sich auf die geometrische Rekonstruktion des Aufnahmevorgangs. Dabei wird zwischen **innerer und äußerer Orientierung** unterschieden. Die innere Orientierung ist definiert durch die räumliche Lage des Projektionszentrums relativ zur Bildebene. Eine konstante innere Orientierung ist durch die feste Verbindung des Objektivs mit dem Kamerakörper gewährleistet. Die innere Orientierung beschreibt somit die geometrischen Abbildungseigenschaften der eingesetzten Luftbildkamera. Parameter, welche zur Berechnung der inneren Orientierung notwendig sind, lassen sich aus Flugprotokollen und der Rahmenmarke eines Luftbildes lesen. Die **äußere Orientierung** beschreibt die Lage der Aufnahmekammer im Raum, d.h. hier wird der geometrische Bezug zwischen Bild- und Geländeebene hergestellt. Zur Berechnung der äußeren Orientierung werden die Koordinaten des Projektionszentrums und die drei Rollwinkel im Raum benötigt. Während eines Bildfluges können diese Parameter meist nicht mit ausreichender Genauigkeit bestimmt werden. Sie lassen sich aber nachträglich über Paßpunkte bestimmen.

zu 3.) Für die **differentielle Entzerrung** werden die Photogrammetrie-Applikationen Orthobase Pro von ERDAS Imagine (Version 8.5) und Orthoengine von PCI Geomatica (Version 8.2) verwendet. Anhand der inneren und äußeren Orientierung, der Paßpunkte mit x-, y- und z- Koordinaten sowie eines Geländemodells (DGM-25) werden die digitalen Luftbilder von der Zentralprojektion in eine Orthogonalprojektion umgerechnet und als digitale **Ortholuftbilder** gespeichert.

Moderne photogrammetrische Analysesoftwarepakete erlauben eine benutzerfreundliche Durchführung des gesamten Vorgangs der Orthobilderstellung. So lassen sich Paßpunkte einfach angeben, Geländemodelle implementieren und die innere und äußere Orientierung automatisch berechnen.

Die Bildflüge der Jahre 1956 und 1976 wurden auf die beschriebene Weise orthorektifiziert. Sechs der verwendeten Paßpunkte waren Referenzpunkte, die vom LVA angegeben wurden. Zusätzlich wurden vier Paßpunkte mit einem Differential-GPS (Trimble TDC2-GPS-Empfänger) gemessen. Zudem wurden Paßpunkte aus den Orthobildern des Jahres 2000 ausgelesen. In Tabelle 4 ist eine Übersicht zur Orthorektifikation der Luftbilder von 1956 und 1976 dargestellt. Als topographische Grundlage wurde für die Bilder aus dem Jahr 1956 das aus ihnen abgeleitete Oberflächenmodell (DOM) verwendet. Für die Bilder von 1976 diente zusätzlich zu den Paßpunkten ein Geländemodell (DGM) auf Basis von Höhenlinienkarten (1 : 5000) des LVA als Grundlage.

**Tab. 4:** Übersicht zur Orthorektifikation der gescannten Luftbilder 1956 / 1976.

Aufnahmezeitpunkt	Anzahl	Zahl der Paßpunkte	RMS-Fehler	DGM/DOM
06/1956	9 Stereoluftbilder	6	0,77	abgeleitetes DOM
06/1976	2 Luftbilder	10	2,58	DGM-25 des LVA

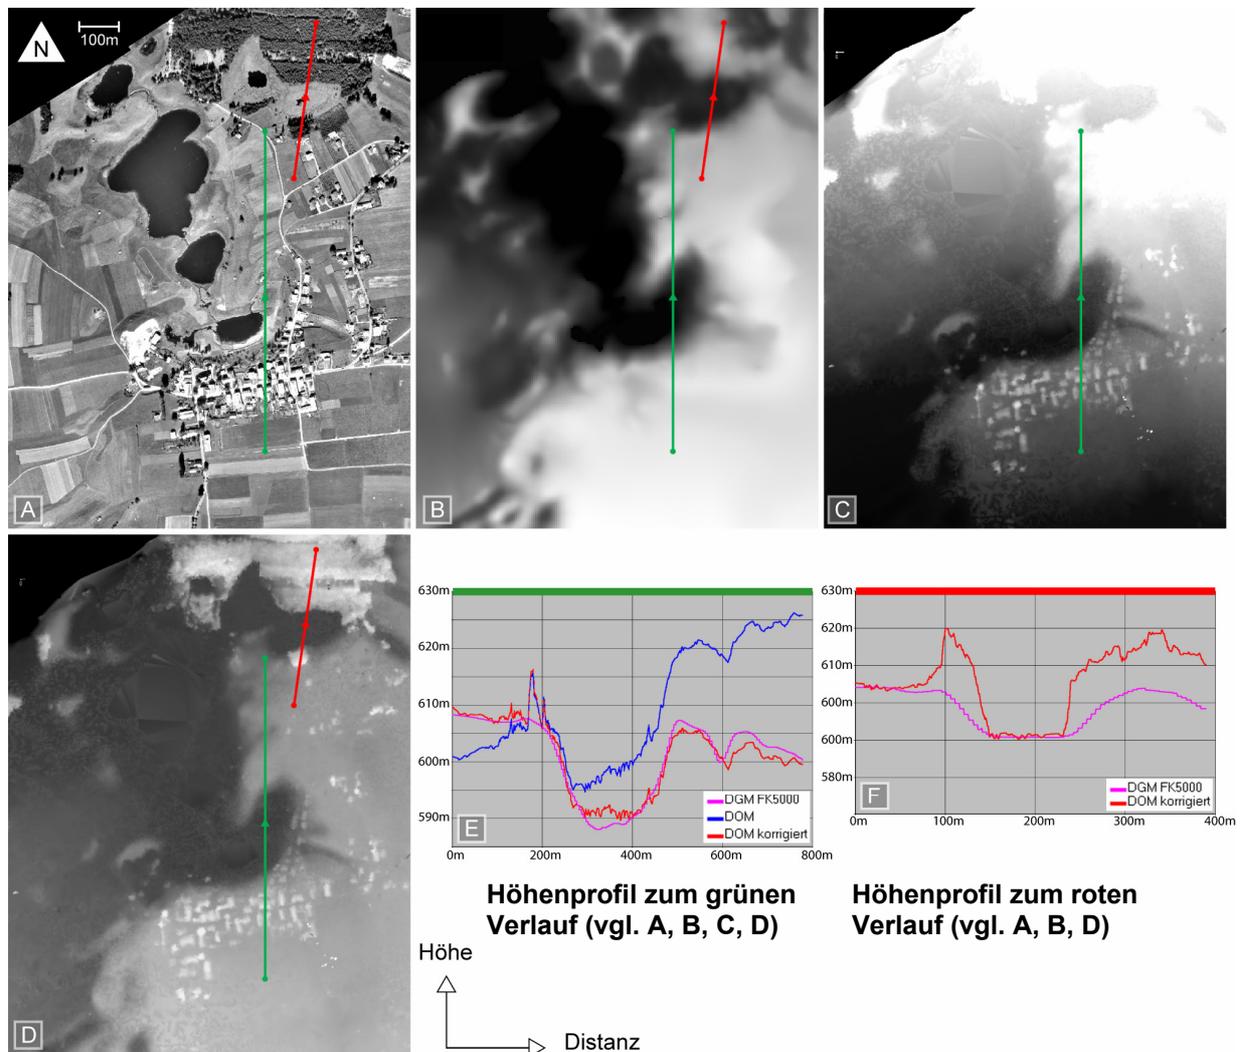
Die resultierenden digitalen Orthobilder (1956 und 1976) wurden auf ihre größte gemeinsame Überdeckung mit dem Orthobild aus dem Jahr 2000 zugeschnitten. Daraus ergab sich ein Untersuchungsgebiet von 128 ha Größe, das in Abbildung 18 dargestellt ist.



**Abb. 19:** Testgebiet „Iffeldorfer Seengruppe“. Orthobild vom Juni 2000.

## Digitales Oberflächenmodell aus den Luftbildern von 1956

Die Ableitung von digitalen Oberflächenmodellen (DOM) aus den Stereoluftbildpaaren des Jahres 1956 wurde mit Orthobase Pro von ERDAS Imagine durchgeführt. Das Ergebnis ist in Abbildung 19 (C) dargestellt und wies einen Helligkeits-Gradienten in Nord-Süd-Richtung auf. Die Ursache für diesen Fehler konnte nicht ermittelt werden und lag vermutlich in der Abschattung der Luftbilder im Randbereich. Das DOM war in seiner ursprünglichen Form für eine weitere Auswertung nicht geeignet. Da der Gradient einen linearen Zusammenhang erwarten ließ, konnte er durch eine Korrekturfunktion herausgerechnet werden. Durch Auslesen zweier Punkte aus dem Höhenmodell auf einer Nord-Süd-Tangente wurde ein lineares Gleichungssystem aufgestellt. Dementsprechend wurde mit ERDAS Imagine ein Korrekturmodell erstellt und das Oberflächenmodell überarbeitet. Ein Vergleich der Höhenprofile des unkorrigierten (Abb. 19 (C)) und des korrigierten Oberflächenmodells (Abb. 19 (D)) mit den digitalisierten Höhenkarten des LVA (Abb. 19 (B)) ist in der Profilgrafik in Abbildung 19 (E) gezeigt. Die Qualität des korrigierten Oberflächenmodells war sehr gut. Baumgruppen, Häuser und zum Teil auch Schilf wiesen deutliche Höhenunterschiede zum Gelände auf. Im Höhenprofil aus Abbildung 19 (F) heben sich die Baumgruppen erkennbar ab.



**Abb. 20:** Luftbild von 1956 (A), Geländemodell aus Höhenkarten des LVA (B), unkorrigiertes Oberflächenmodell mit deutlichem Helligkeits-Gradienten in Nord-Süd Richtung (C), korrigiertes Oberflächenmodell (D), Höhenprofile zum grünen Profil (E) und zum roten Profil (F). In (E) ist der Helligkeitsgradient des unkorrigierten DOM blau dargestellt.

Bei automatisch abgeleiteten Oberflächenmodellen treten häufig Interpolationsfehler auf, die sich in falschen Höhenwerten oder unerklärlichen Bruchkanten äußern. Dies liegt an mangelnden „*Matching*“-Punkten in den Stereobildpaaren (LEICA GEOSYSTEMS 2002b). Eine visuelle Überprüfung des Oberflächenmodells ergab einige Ungenauigkeiten und Fehler bei der (vermeintlich flachen) Seefläche und bei abrupten Höhenunterschieden (z. B. Häuserkanten oder Waldrändern). Hier interpolierte der automatische Algorithmus zum Teil falsch und erzeugte Kanten oder „fließende“ Übergänge.

Für einen perspektivischen Eindruck wird das Oberflächenmodell mit dem Luftbild überlagert (Abb. 20). In der perspektivischen Darstellung ist der (falsche) allmähliche Höhenanstieg bei Häuserkanten oder Baumgruppen sichtbar.



**Abb. 21:** Perspektivische Darstellung des DOM (1956) mit überlagertem Luftbild (1956). Bei abrupten Höhenunterschieden z. B. bei Hauskanten (in A, roter Pfeil) oder bei Baumgruppen (in B, roter Pfeil) werden die Oberflächenhöhen interpoliert und wirken aus diesem Grund unscharf.

Die Blickrichtung von Abbildung 20 (A) entspricht dem grünen Profil aus Abbildung 19, während die Blickrichtung von Abbildung 20 (B) entlang des roten Profils aus Abbildung 19 verläuft. Trotz der Interpolationsfehler war das korrigierte Oberflächenmodell eine wertvolle Informationsquelle. Durch die Objekthöhe wurden zusätzliche Hinweise auf bestimmte Landbedeckungstypen gegeben. In Abbildung 20 ist zu erkennen, daß Häuser oder Baumgruppen sich vom übrigen Gelände erheben. Mit anspruchsvollen Photogrammetrie-Applikationen ist diese zusätzliche Informationsebene mit überschaubarem Arbeitsaufwand ableitbar, sofern Stereoluftbilder verfügbar sind. Insbesondere bei Schwarz/Weiß-Luftbildern, wo die bildliche Information sich auf eine einzige Grauwertebene beschränkt, ist die Objekthöhe bei der Klassifikation außerordentlich hilfreich.

## 5.3 GIS-Daten

### 5.3.1 Seeuferkartierung (SUK) Bayern

Im Rahmen dieser Arbeit wird eine Fallstudie durchgeführt, bei der die räumlichen und thematischen Ungenauigkeiten eines GIS-Datensatzes anhand von aktuellen Fernerkundungsdaten korrigiert und aktualisiert werden. Um das Potential des objektorientierten Ansatzes in diesem Kontext zu prüfen, wird beispielhaft ein Ausschnitt der Seeuferkartierung (SUK) der Osterseen von 1987 verarbeitet. Dabei sollte untersucht werden, ob eine Fortschreibung der SUK - wie sie BRANDES und LUTZ (1996) vom LfU fordern - mit Hilfe der Fernerkundung möglich ist. Dazu wird die SUK digitalisiert und georeferenziert. Trotz der deutlichen Lageungenauigkeiten, die auf die Herstellungsweise im Jahr 1987 zurückzuführen sind, kann die thematische Information genutzt und weitergeführt werden.

Die SUK Bayern geht auf Überlegungen an der Bayerischen Landesstelle zurück, die bereits vor mehr als 30 Jahren angestellt wurden. Für die südbayerischen Seen über 100 ha Größe wurde ein Entwicklungskonzept aufgestellt, das Aussagen traf, welche Uferbereiche der Erholungsnutzung und welche dem Naturschutz vorbehalten sein sollten. (LUTZ 1986) Um auch lokale Fach- und Planungsfragen zu beantworten, wurden in den Jahren 1979 bis 1987 landesweit weitere 160 Seen im Maßstab 1 : 5000 kartiert. Dabei wurden in einer Zustandsbeschreibung wichtige Merkmale eines Sees (z. B. Seefläche, Tiefe), Aussagen zum Landschaftsbild, Besonderheiten in Fauna und Flora, Erholungsmöglichkeiten und naturschutzrechtlich geschützte Gebiete im engeren Seebereich zusammengestellt (BRANDES und LUTZ 1996). Die SUK ist trotz ihrer topographischen Ungenauigkeit nach wie vor eine häufig verwendete Entscheidungsgrundlage bei Planungsvorhaben (LUTZ, mündl. Mitteilung 2003).

### **5.3.2 Biotopkartierung Bayern**

Die Biotopkartierung enthält grundlegende Informationen über Lage, Verbreitung, Häufigkeit und Zustand naturschutzfachlich wertvoller Flächen in Bayern (im Maßstab 1 : 5000). Insbesondere naturnahe Lebensräume wie Moore und Streuwiesen oder Trocken- und Magerstandorte werden erfaßt (LFU 2002). Im Auftrag des Bayerischen Landesamtes für Umweltschutz wurden im Zeitraum von 1985 bis 2003 etwa 4 % der Landesfläche außerhalb der Alpen kartiert, wobei ein Großteil der erfaßten Flächen unter Naturschutz steht. Die Informationen aus der Kartierung sind sehr detailliert und dienen beim Aufbau der Klassenregelwerke als Orientierungshilfe. Konkrete Referenzbildobjekte werden mit ihrer Hilfe interaktiv ausgewählt.

Das Bayerische Landesamt für Umweltschutz stellt die Biotopkartierung im digitalen Format zum kostenlosen Herunterladen im ArcView-Shape-Format zur Verfügung (LFU 2005).

### **5.3.3 Nutzungskartierung der Osterseen**

Im Rahmen einer an der Limnologischen Station angefertigten Diplomarbeit wurde eine detaillierte Landnutzungskartierung des Osterseengebiets durchgeführt (KANGLER 2003). Die Kartierung basiert auf einer visuellen Interpretation der in Kapitel 5.2 beschriebenen Orthophotos aus dem Jahr 2000. Umfangreiche Geländekampagnen der Interpretin begleiteten den Fertigungsprozeß. Dieser Datensatz wird als Referenz für die Genauigkeitsanalyse bei der Klassifikation der Orthophotos aus dem Jahr 2000 verwendet. Für einen direkten Vergleich der Klassifikationen müssen die Klassenschemata „harmonisiert“ werden. Die Klassen der Nutzungskartierung werden so zusammengefaßt, daß ein direkter Vergleich mit der Klassifikation der Orthophotos möglich ist. Die Ergebnisse dieses Vergleichs werden in Kapitel 6.2 näher beschrieben.

### **5.3.4 Geländekampagnen**

Zur Auswahl der Referenzflächen wurden im Vorfeld im gesamten Untersuchungsgebiet umfangreiche Geländekampagnen durchgeführt. Die dabei ermittelten Referenzflächen dienten als Orientierung für den Aufbau der Klassenregelwerke. Die ausgewählten Flächen wurden photographisch dokumentiert und teils auch mit GPS-Messungen festgehalten.

Für die Verifikation der Ergebnisse der IKONOS-Klassifikation wurden weitere Geländekampagnen durchgeführt. In den Jahren 2002 und 2003 wurden jeweils in den Monaten April und August mehr als 500 Flächen kartiert, photographiert und mittels GPS-Punkten dokumentiert.

## 6 Fallstudien

Der in Kapitel 3 entwickelte Ablauf einer objektorientierten Analyse wird in diesem Kapitel anhand von drei Fallstudien dargestellt. Zuerst werden die Ergebnisse, die bei der Anwendung des objektorientierten Ansatzes für IKONOS-Satellitendaten erreicht wurden, vorgestellt (Kap. 6.1). Anschließend werden die gesammelten Erfahrungen aus der Fallstudie „Analyse von Luftbildern“ dargestellt (Kap. 6.2), und schließlich werden die bei einer kombinierten Auswertung von GIS- und Fernerkundungsdaten erzielten Ergebnisse präsentiert (Kap. 6.3).

### 6.1 Analyse von hochauflösenden IKONOS-Satellitendaten

#### 6.1.1 Fragestellung

Analysiert wurden zwei hochauflösende IKONOS-Aufnahmen aus verschiedenen Vegetationsperioden. Die zentrale Frage war, welche Objektattribute sich für eine Klassendifferenzierung eignen und wie sich „Wissen“ für eine Klassifikation modellieren läßt. Dieses Wissen umfaßt sowohl die spektralen Reflexionseigenschaften einer Klasse als auch ihren strukturellen Aufbau sowie die topologischen Beziehungen zu anderen Klassen. Des weiteren wurde erörtert, auf welche Weise sich die Reflexion der Landbedeckung über die Vegetationsperiode von April bis August verändert, und ob sich aus Daten zweier Aufnahmezeitpunkte synergistische Informationen ableiten lassen. Die Frage nach der Genauigkeit der Ergebnisse des objektorientierten Ansatzes wurde durch einen Vergleich mit Felddaten und ausgesuchten Referenzflächen geklärt.

In einem ersten Schritt wurden die Daten beider Aufnahmezeitpunkte getrennt voneinander bearbeitet. Das Klassifikationsregelwerk wurde zuerst für die April-Daten entwickelt und anschließend auf die August-Aufnahme übertragen und angepaßt. Bei der Analyse der multitemporalen Zusammenhänge und der Untersuchung der Objekteigenschaften mit dem Statistikprogramm SPSS wurden beide IKONOS-Aufnahmen gemeinsam segmentiert (um gleiche Bildobjekte zu gewährleisten).

Für die Entwicklung eines objektorientierten Klassifikationsregelwerks wurde ein **Kernuntersuchungsgebiet** rund um die Osterseen ausgewählt. Diese Gebietsauswahl umfaßte alle Landbedeckungstypen, die innerhalb der gesamten IKONOS-Aufnahmen vertreten waren. Auch der südliche Teil des FFH- und Naturschutzgebiets Osterseen war vollständig abgedeckt. Das Kernuntersuchungsgebiet umfaßte eine Fläche von ca. 2000 ha. Hinsichtlich des Klassifikationsmaßstabs wurden die Vorgaben der Landesanstalt für Land- und Forstwirtschaft (LWF) und des Landesamts für Umweltschutz (LfU) aus der Kartieranleitung für Lebensraumtypen der Fauna-Flora-Habitat-Richtlinie berücksichtigt (LfU und LWF 2003). Demnach wurden Landbedeckungs- bzw. Landnutzungsklassen im Maßstab 1 : 5000 mit einer Mindestkartiergröße von 0,01 ha erfaßt.

Um die Übertragbarkeit und weiterführende Nutzung der Klassifikation und des erarbeiteten Klassifikationsregelwerks zu gewährleisten, wurde das verwendete **Klassenschema** am normierten Kartierschlüssel des Bundesamts für Naturschutz (BFN 2002) ausgerichtet. Die Klassenbezeichnungen wurden übernommen und der entsprechende Schlüsselcode in Klammern dahinter gesetzt. Gesucht wurden die Klassen „Bäume, Feldgehölze, Gebüsche (6000)“, „Wälder (7000)“, „Siedlung, Verkehr, Freizeit (9000)“ und „Landwirtschaftliche Nutzflächen (4000)“. Soweit eine weitere Trennung möglich war, wurden die genannten Klassen weiter aufgegliedert, was der detaillierten Beschreibung der einzelnen Klassen in Kapitel 6.4 zu entnehmen ist.

Die Klassen „Binnengewässer (2000)“, „Ufervegetation (2100)“, „Röhrichtvegetation (2200)“ und „Moor, Sümpfe (3000)“ wurden in dieser Studie als Feuchtgebiete zusammengefaßt betrachtet. Die spektralen Eigenschaften der „Feuchtgebiets“-Klassen waren von Interesse, um bei den Klassendefinitionen Fehlzusweisungen zu vermeiden. Die finale Abgrenzung der Feuchtgebiete wurde im wesentlichen aus den Ergebnissen des Projektpartners übernommen und ist hier nur in gekürzter Form dargestellt. Eine ausführliche Beschreibung der Feuchtgebietsklassifikation im Untersuchungsgebiet findet sich in der Dissertation des Projektpartners (ANDRESEN 2004).

### 6.1.2 Eingangsdaten

Untersucht werden die in Kapitel 5.1 beschriebenen IKONOS-Aufnahmen.

### 6.1.3 Segmentierung

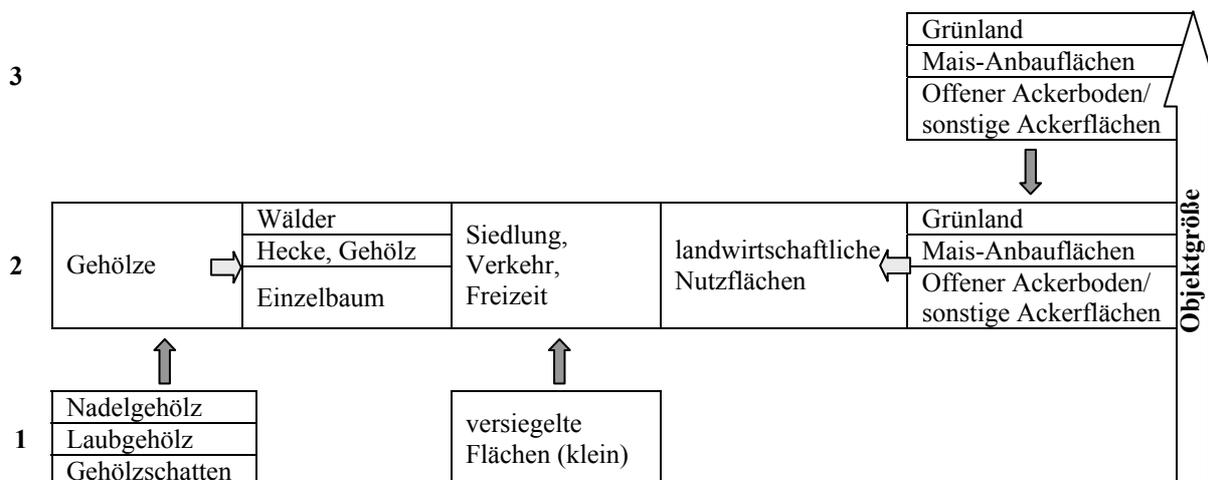
Die Segmentierung der IKONOS-Daten erfolgte auf drei Skalenebenen mit drei verschiedenen Parameter-Einstellungen. Drei Skalenebenen erwiesen sich als ausreichend, um die gesuchten Zielklassen in ihren räumlichen Ausprägungen zu repräsentieren. Auf jeder Ebene wurden also Bildobjekte mit verschiedenen großen Flächen- und Formausprägungen erzeugt. Dabei wiesen die Zielklassen in den einzelnen Ebenen verschiedene Merkmalsausprägungen auf. Manche der Klassen wurden durch kleinere Bildobjekte besser „getroffen“ (z. B. Gehölze), während andere in ihrem Erscheinungsbild großflächiger waren (z. B. landwirtschaftliche Nutzflächen). Dementsprechend wurden für jede der drei Ebenen iterativ verschiedene Parameter geprüft und ihre Eignung bewertet. Die Bewertung der Segmentierungsqualität führte der Bearbeiter durch und richtete sich danach, wie gut die Landbedeckungsklassen durch die Bildobjekte vertreten waren. Die Ebene mit dem größten Maßstab, also Ebene 1, wurde zuerst erstellt. Der verwendete *Scale*-Parameter nahm von Ebene 1 bis Ebene 3 zu, was bedeutet, daß die Bildobjektgröße ebenfalls zunahm bzw. die Betrachtungsskala abnahm.

Auf **Skalenebene 1** mit den kleinsten Segmenten wurden Gehölze klassifiziert. Die kleinen Bildobjekte entsprachen der räumlichen Ausprägung auch kleiner Gehölzgruppen, weshalb diese Segmentierungsebene hierfür sehr gut geeignet war. Nach einem ersten Klassifikationsdurchlauf wurden Schatten in Gehölzbeständen extrahiert, indem die Klassifikation der Schatten - ähnlich der Vorgehensweise eines Interpreten - aus dem Zusammentreffen von Farbe (Schatten = dunkel) und räumlichen Kontext (Nachbarschaft zu Gehölzen) erfolgte. Ferner wurden auf Ebene 1 kleine „versiegelte Flächen“ detektiert. Diese lagen innerhalb von Siedlungsgebieten und Straßenzügen.

Auf **Skalenebene 2** mit größeren Segmenten wurden die Informationen von Ebene 1 übernommen. Eine Abfrage der Zusammensetzung der Unterobjekte war möglich, da die Bildobjekte sowohl nachbarschaftlich als auch zwischen den Ebenen miteinander vernetzt waren (Kap. 3.4.2). Auf diese Weise erlaubt der objektorientierte Ansatz, Informationen über verschiedene Objektskalenebenen auszutauschen. Die Gehölz-Unterklassen inklusive der Gehölzschatten von Ebene 1 wurden abgefragt und zu „Gehölze Ebene 2“ auf Ebene 2 zusammengefaßt. Anhand von Kontextbeziehungen und der Flächengröße wurden „Gehölze Ebene 2“ in die Klassen „Wälder (7000)“ und „Bäume, Feldgehölze, Gebüsche (6000)“ aufgegliedert. Ferner wurden auf Ebene 2 die „versiegelten Flächen“ von Ebene 1 abgefragt und mit weiteren Attributen verknüpft, um „Verkehrsflächen (9200)“ und „Siedlung/Gewerbe (9100)“ zu klassifizieren. Die Voraussetzung für die Klassenzugehörigkeit war, daß die Bildobjekte einen Anteil an versiegelten Flächen in den Unterobjekten auf Ebene 1 aufweisen müssen. Das Expertenwissen, daß eine Verkehrs-, Siedlungs-, oder Gewerbefläche meist einen hohen

Anteil versiegelter Fläche aufweist, konnte so in Regelwerke umgesetzt werden. War die Bedingung „versiegelte Unterobjekte“ erfüllt, so wurde nach Form und Textur geprüft. Bei hoher Textur und fraktaler Form des Bildobjektes wurde die Klasse „Siedlung/Gewerbe (9100)“ zugewiesen. War die Form des Segments länglich, so wurde die Klasse „Verkehrsflächen (9200)“ zugewiesen. Die Unterscheidung von „Siedlung/Gewerbe (9100)“ und „Verkehrsflächen (9200)“ war zum Teil nicht exakt und beinhaltete auch die Klasse „Freizeit- und Erholungsflächen (9300)“, die sich nicht separat abtrennen ließ. So wurden diese drei Klassen zu „Siedlung, Verkehr und Freizeit (9000)“ zusammengefaßt.

Auf **Skalenebene 3** wurden „Landwirtschaftliche Nutzflächen (4000)“ klassifiziert. Diese setzten sich aus „Wiesen, Weiden und sonstiges Grünland (4200)“ und „Ackerland (4100)“ zusammen. Diese kleinste Objektskalenebene war am besten geeignet, um flächige Landbedeckungsklassen zu finden: Durch großflächige Bildobjekte wurde die spektrale Varianz dieser Klassen (z. B. hervorgerufen durch Ackerfurchen oder natürliche Inhomogenitäten) integriert. Neben den spektralen Mittelwerten diente zur Klassenbeschreibung auch die Form eines Bildobjektes. Ackerland tendiert zu stark geometrischen Formen, während Grünland eher der Landschaft angepaßte Formen aufweist. Diese Formeigenschaften waren erst auf der kleinmaßstäblichen Ebene 3 deutlich ausgeprägt und wurden im Regelwerk entsprechend beurteilt. Auf Ebene 2 wurde wiederum die Information der übergeordneten Ebene 3 abgefragt und zusammengefaßt, diesmal durch Abfrage der Überobjekte. Die Ebene 2 kann als „Ergebnis“-Ebene betrachtet werden, da hier die Klassifikationen der über- und untergeordneten Ebenen zusammengefaßt werden. Die Abbildung 21 gibt einen Überblick, welche Klassen in den jeweiligen Segmentierungsebenen klassifiziert werden.



**Abb. 22:** Übersicht der Segmentierungsebenen. Die Klassifikation wird auf drei Skalenebenen durchgeführt - mit zunehmenden Objektgrößen von 1 bis 3. Die dunklen Pfeile symbolisieren die topologischen Zusammenhänge, z. B. die Klasse „Gehölze Ebene 2“ auf Ebene 2 greift auf die Information aus Ebene 1 zu (Nadelgehölz/ Laubgehölz/ Gehölzschatten). Die hellen Pfeile zeigen beispielhaft die thematischen Zusammenhänge der Ebene 2, z. B. die Klasse „Landwirtschaftliche Nutzflächen“ bildet eine Gruppe aus den Klassen „Grünland“, „Mais-Anbauflächen“ und „Offener Ackerboden /sonstige Ackerflächen“.

Einen weiteren Einfluß auf die Segmentierung hatte die Implementierung der Feuchtgebietsklassifikation des Projektpartners (ANDRESEN 2004). Diese Daten lagen im ArcView-Shape-Format vor und wurden als thematische Informationsebene eingelesen, um die Ergebnisse des Projektes AQUATIC zusammenzuführen. Da extern zugeführte Polygongrenzen bei der Segmentierung mitbetrachtet werden, unterschieden sich die Bildobjekte zum Teil in ihrer Formausprägung zu den ursprünglich generierten Bildobjekten, was sich jedoch im Blick auf das Ergebnis nicht negativ auswirkte.

Wie aus den Beispielen deutlich wurde, floß bereits Wissen bei der Erstellung und Planung der Segmentierungsebenen ein, z. B. das Wissen über die Form- und Flächenausprägung einer Klasse sowie Wissen über die multiskalaren Zusammenhänge der Klassen zwischen den Skalenebenen. Es war die Erfahrung des Experten, die bei Auswahl und Bewertung der Segmentierungsebenen eine Rolle spielte. Dieses Wissen mußte über die Segmentierungsparameter eingebracht werden, wobei diese dann durch „*Trial and Error*“-Experimente ermittelt wurden. Die im Rahmen dieser Arbeit gefundenen Parameter erwiesen sich für hochauflösende IKONOS-Daten und die beschriebene Fragestellung als ideal. Aufgrund der Vielfältigkeit des untersuchten Gebietes, das einen repräsentativen Querschnitt der Landschaft Bayerns darstellt, ist zu erwarten, daß diese Segmentierungsparameter bei anderen Untersuchungsgebieten ebenfalls zu guten Resultaten führen werden.

Eine Übersicht über die gewählten Segmentierungsparameter gibt Tabelle 5.

**Tab. 5:** Übersicht der Segmentierungsparameter.

Objektskalenebene	Scale-Parameter	Color / Shape	Smoothness / Compactness	Gewichtung der Kanäle				
				1	2	3	4	PAN
Ebene 3	210	0,8 / 0,2	0,1 / 0,9	1	1	1	1	1
Ebene 2	180	0,8 / 0,2	0,4 / 0,6	1	1	1	1	1
Ebene 1	90	0,8 / 0,2	0,7 / 0,3	1	1	2	5	10

Die Gewichtung der *Color*- und *Shape*-Parameter (Kap. 3.4.1) verhält sich jeweils wie 0,8 zu 0,2. Eine stärkere Gewichtung der Form (*Shape*) wurde getestet, erwies sich allerdings als nicht sinnvoll, da sich der Segmentierungsalgorithmus dann zu wenig an den Bilddaten orientierte und nicht nachvollziehbare Bildobjekte generierte. Die Gewichtung von *Smoothness* und *Compactness* (oder der Segmentierungsparameter im allgemeinen) ist nur in Zusammenhang mit den auf diesen Objektskalenebenen gesuchten Klassen zu verstehen: die Klassen auf Objektskalenebene 1 zeigten fraktalere Abgrenzungen (z. B. Gehölze) als die Klassen, die auf Ebene 3 detektiert wurden (z. B. Ackerflächen). Dem wurde mit einer unterschiedlichen Gewichtung von *Smoothness*- und *Compactness*-Parametern Rechnung getragen.

Verschiedene Datenkanäle wurden bei der Segmentierung unterschiedlich stark betont, hatten also einen unterschiedlichen Einfluß auf die Form der Segmente. Auf Ebene 1 wurden der PAN-Kanal und der NIR-Kanal erkennbar stärker gewichtet (Tab. 5). Der PAN-Kanal ist höher aufgelöst und eignet sich daher für räumlich detailliertere Bildobjektgrenzen. Des weiteren sind PAN- und NIR-Band aussagekräftig, was die Unterscheidung von Laub -und Nadelgehölzen betrifft, die auf dieser Ebene klassifiziert werden. Die Segmentierung der Ebenen 2 und 3 verwendete jeweils gleich gewichtete Datenkanäle, da für die hier gesuchten Klassen keine spektralen „Präferenzen“ feststellbar waren.

Der nächste Schritt in der Prozeßkette war die Modellierung verschiedener Arten von Wissen, das bei einer Klassifikation eine Rolle spielt.

#### 6.1.4 Wissensmodellierung

Bei der Entwicklung der Regelwerke für die Klassentrennung flossen verschiedene Aspekte ein. Bestimmend waren hier Expertenwissen z. B. in Form der Kartieranleitung des Bundesamts für Naturschutz (BFN 2002), bzw. Fernerkundungsliteratur über typische oder untypische Spektral-, Struktur- und Formausprägungen der gesuchten Klassen. Daneben war die Analyse von Referenzbildobjekten entscheidend. Für jede der gesuchten Klassen wurden zahlreiche repräsentative Trainingsbildobjekte ermittelt. Die Auswahl dieser Referenzobjekte beruhte auf Feldkenntnissen (kombiniert mit GPS-Messungen) und dem Erscheinungsbild eines Bildobjektes in Fernerkundungsdaten (IKONOS und Luftbilder). Auch die Biotopkartierung Bayern (Kap. 5.3.2) lieferte in diesem Zusammenhang

wertvolle Referenzinformationen. Insgesamt wurden knapp 500 Referenzbildobjekte ausgewählt, mit 15 bis 60 Vertretern pro Klasse. Die bedeutsamen Objektattribute der Referenzobjekte wurden hinsichtlich der Eignung für eine Trennbarkeit der Klassen mittels der Werkzeuge aus eCognition untersucht. Um einzelne Objekteigenschaften diesbezüglich eindeutiger zu beurteilen, wurden auch Analysen mit dem Statistikprogramm SPSS durchgeführt. Das Programm SPSS ist für diese Untersuchung sehr gut geeignet, da sich die Verteilungsmuster der Objekteigenschaften der Referenzklassen genau analysieren und darstellen lassen. Wenn nicht anders beschrieben, wurden für diese Untersuchung Referenzobjekte aus Segmentierungsebene 2 verwendet.

Als besonders zielführend und aussagekräftig erwies sich der Vegetationsindex NDVI, auf den im nächsten Abschnitt gesondert eingegangen wird. Anschließend folgen detaillierte Beschreibungen der Regelwerke für die einzelnen Zielklassen.

### **Vegetationsindex NDVI**

In nahezu allen Klassenbeschreibungen wurde der Vegetationsindex NDVI (*Normalized Difference Vegetation Index*) genutzt, weswegen er hier gesondert dargestellt wird. Um diesen Index auch in eCognition verwenden zu können, wurde auf die Möglichkeit zurückgegriffen, über Formeln eigene Objektattribute zu generieren. Dies geschieht über das Werkzeug „*Customized Feature*“. Mit diesen **maßgeschneiderten Eigenschaften** lassen sich sämtliche Objektattribute innerhalb von eCognition über arithmetische Operationen miteinander verbinden und auf diese Weise neue Objektattribute generieren. Die Formel für den NDVI konnte so umgesetzt werden.

Das *Customized Feature*-Werkzeug ist ausgesprochen hilfreich, erspart es doch die konventionelle Berechnung von künstlichen digitalen Datenkanälen in einem Bildprozessierungsprogramm. Mit diesem Werkzeug läßt sich zweifach Zeit sparen: zum einen ist der konventionelle Berechnungsvorgang deutlich zeitaufwendiger, zum anderen nimmt mit jedem zusätzlichen digitalen Kanal der Datenumfang und somit auch die Prozessierungsdauer eines Projektes zu.

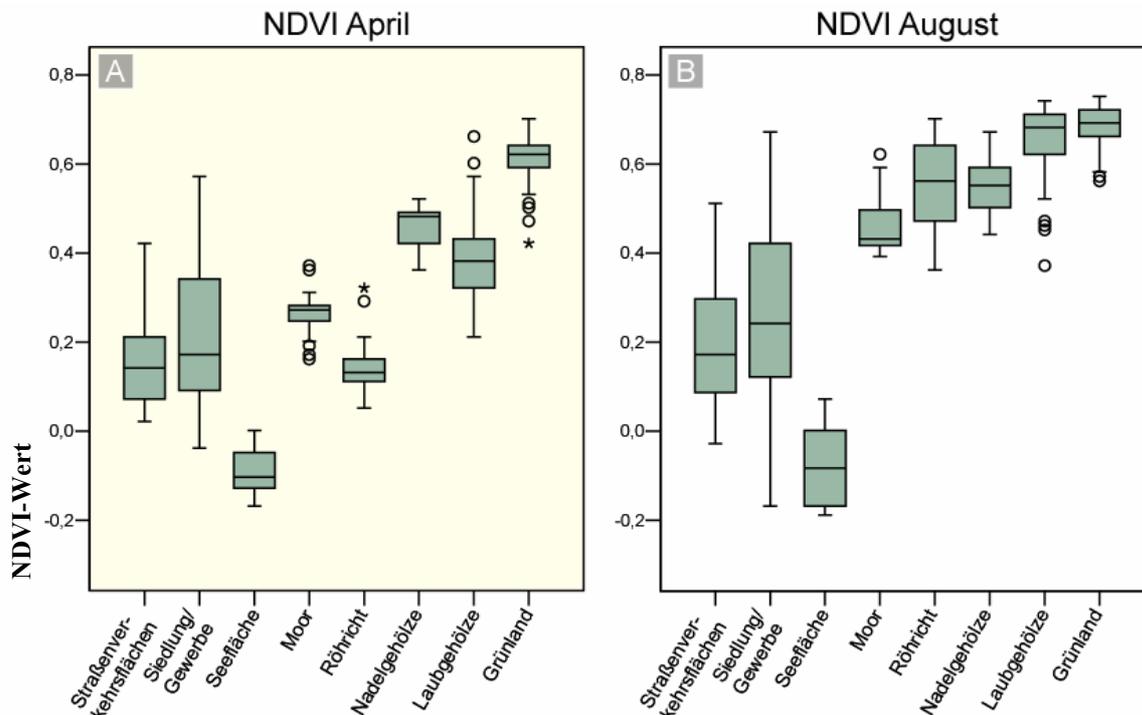
Die Häufigkeitsverteilung der NDVI-Objektwerte von Referenzbildobjekten wird für ausgewählte Klassen in Form von Box-Whisker-Plots<sup>1</sup> in Abbildung 22 gezeigt. Diese Box-Whisker-Plots, im folgenden nur Boxplots genannt, wurden mit SPSS (Version 10.0) erstellt. Ein Boxplot ist eine sehr übersichtliche graphische Darstellung der Verteilungsstatistiken.

Besonders die Ausreißer und Extremwerte waren in einem Regelwerk schwierig zu modellieren, da sie in ihrer Merkmalsausprägung nicht der Mehrzahl der Mitglieder ihrer Klasse entsprechen. Sie bildeten Ausnahmen. Der Prozeß der Klassenmodellierung ist gewisserweise als Optimierungsproblem zu verstehen: es gilt, die Zahl der Ausnahmen, also den Ausschlußfehler, zu minimieren, ohne dabei zu viele Bildobjekte falsch zu klassifizieren. Die Boxplotdarstellung eignete sich insbesondere dann sehr gut, wenn mehrere Klassen hinsichtlich ihrer Verteilung in einer Eigenschaft miteinander verglichen

---

<sup>1</sup> Boxplot (Schachteldiagramm) ist eine graphische Darstellung metrischer Daten. Die Tendenz der Verteilung, die Streuung, der Median-Wert wie auch die Spannweite werden übersichtlich dargestellt. Die Box selbst enthält die mittleren 50% der Beobachtungen und geht demzufolge vom unteren bis zum oberen Quartil. Der Median ist als Linie innerhalb der Box eingezeichnet. Er ist ein Maß für den am häufigsten auftretenden Wert. Dies ist insbesondere bei schiefen oder mehr gipfeligen Verteilungen von größerem Informationswert als der Mittelwert. Die von der Box ausgehenden Linien werden „Whisker“ genannt und markieren den Quartilbereich bis zum Minimum bzw. Maximum der Verteilung, ohne die Ausreißer zu betrachten. Ausreißer (Kreise) sind so definiert, daß sie zwischen 1,5 und drei Boxlängen vom oberen oder unteren Rand der Box entfernt sind. Extremwerte (Sterne) liegen noch weiter außerhalb.

werden. Auch die *fuzzy*-Zugehörigkeitskurven konnten entsprechend der Häufigkeitsverteilung (aus den Boxplots ableitbar) genau modelliert werden.



**Abb. 23:** Boxplotdarstellung für den Vegetationsindex NDVI über ausgewählte Klassen. Die allgemeine Zunahme der NDVI-Werte über die Vegetationsperiode von April (A) bis August (B) ist deutlich erkennbar.

Die Landnutzungsclassen „Straßenverkehrsflächen“ und „Siedlung/ Gewerbe“ wiesen tendenziell niedrige Werte auf, waren aber sowohl im April als auch im August relativ breit gestreut. „Seefläche“ zeichnete sich ebenfalls durch niedrige NDVI-Werte aus, die allerdings im August leicht zunahm. Auffällig war der sprunghafte Anstieg bei den Classen „Moor“ und „Röhricht“. In den vermoorten Bereichen hatte die Vegetationsentwicklung Ende April noch kaum eingesetzt. Viele der Flächen waren mit abgestorbenen Pflanzen aus dem Vorjahr bedeckt. Genauso waren die Röhrichtbestände im April noch nicht sichtbar ausgetrieben. Auch hier dominierten abgestorbene Schilfhalmle des letzten Jahrs das Erscheinungsbild. Im August hatten diese Flächen ihre maximale Vegetationsentfaltung, was mit den hohen NDVI-Werten in Einklang steht. Die Gehölzclassen „Laub-“ und „Nadelgehölz“ ließen sich mittels der April-Daten von den übrigen Classen trennen, was bedeutet, daß eine Abgrenzung anhand des NDVI möglich war. Im August stiegen hauptsächlich die Werte bei Laubgehölzen erheblich an, so daß auch eine Differenzierung zu Nadelgehölzen erreichbar war. Auffällig waren bei „Laubgehölzen“ einige Ausreißer mit sehr niedrigen Werten. Hierbei handelte es sich vermutlich um abgestorbene oder stark beschattete Laubbäume. Die Klasse „Grünland“ besaß im April die höchsten NDVI-Werte. Das Grünland erschien in der April-Aufnahme bereits in sattem Grün. In der Augustaufnahme stiegen die Werte nochmals an, da sich die Grasvegetation dieser Flächen voll entfaltet hat.

Zusammenfassend kann dem NDVI eine gute Eignung für die Abgrenzung „grüner“ Vegetation auf Objektebene zugeschrieben werden. Die NDVI-Werte zeichneten den Verlauf der Vegetationsperiode hervorragend nach und waren dementsprechend auch bei der Untersuchung multisaisonaler Zusammenhänge sehr wertvoll.

In den folgenden drei Unterkapiteln werden die Classenbeschreibungen für die wichtigsten Landbedeckungs- bzw. Landnutzungstypen des Untersuchungsgebiets dargestellt. Die Beschreibung

beginnt jeweils mit einer allgemeinen Darstellung der Klasse (mit Geländephographien). Darauf folgen eine Charakterisierung anhand verschiedener Objektattribute und eine detaillierte Beschreibung der Regelwerke. In jedem Kapitel wird ein Gesichtspunkt der objektorientierten Analyse genauer untersucht. Bei **Gehölzen** (Kap. 6.1.4.1) werden die Spektraleigenschaften auf Objektebene behandelt. Bei **Siedlungsgebieten und Verkehrsflächen** (Kap. 6.1.4.2) stehen die iterative Vorgehensweise bei der Klassifikation und die Untersuchung verschiedener Objektattribute im Vordergrund. Im Abschnitt **landwirtschaftliche Nutzflächen** (Kap. 6.1.4.3) wird insbesondere auf die Veränderung des Informationsgehalts eines Formattributs über die verschiedenen Skalenebenen eingegangen.

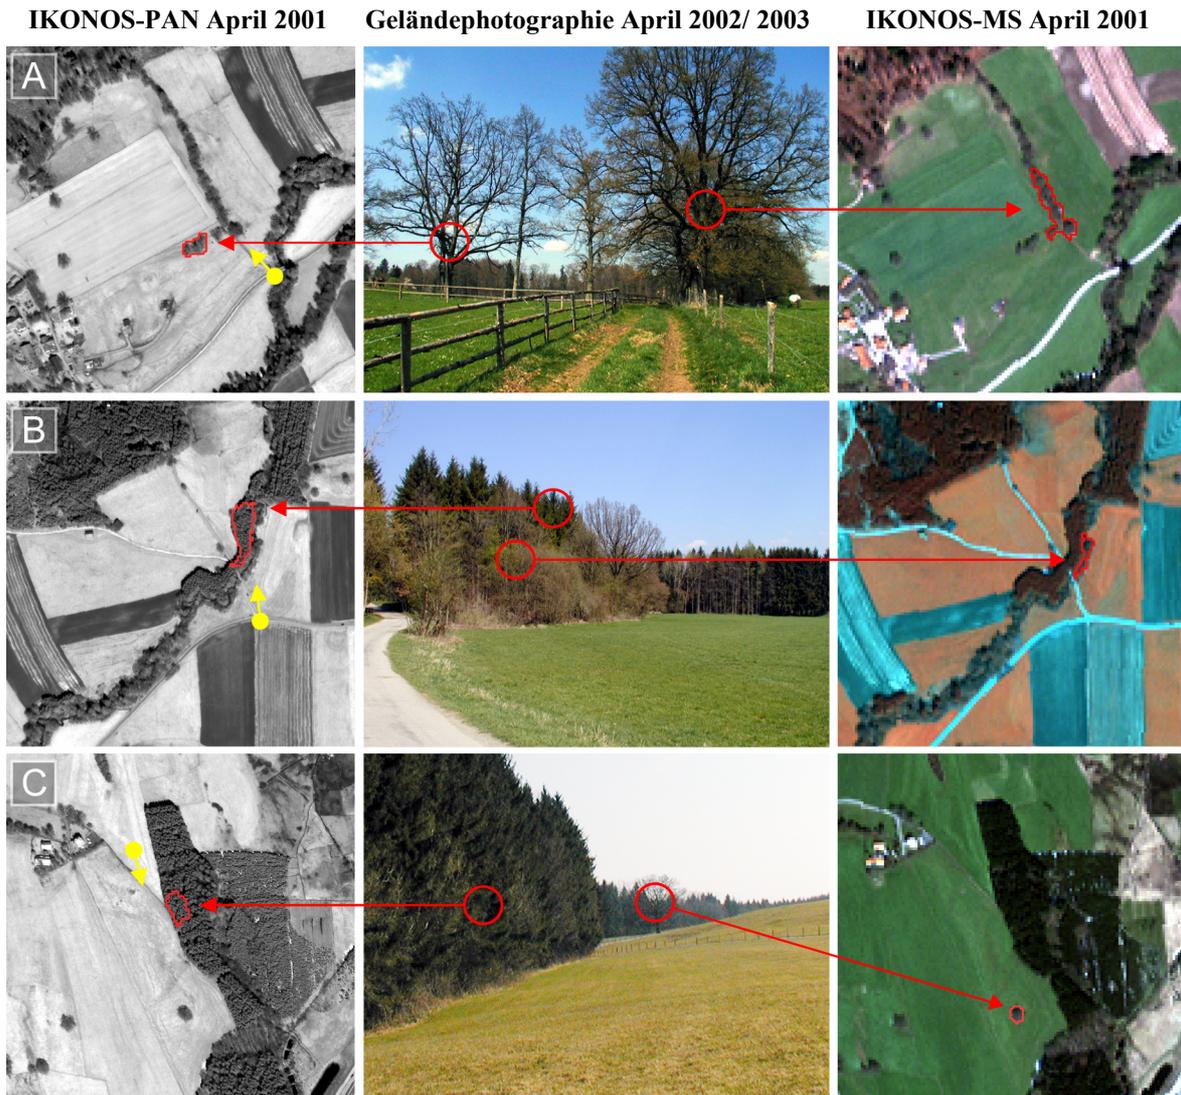
#### **6.1.4.1 Detaillierte Klassenbeschreibung: „Gehölze“**

Auf der niedrigsten Segmentierungsebene (Skalenebene 1) wurden Laub- und Nadelgehölze klassifiziert. Die Segmente waren hier klein genug, um „unverfälschte“ Spektralsignale aufzuweisen und groß genug, um aussagekräftige Texturparameter zu besitzen. Die Klasse „Gehölze“ gliederte sich in die Unterklassen „Laubgehölze“, „Nadelgehölze“ und „Gehölzschatten“ auf.

Trotz oder gerade wegen der hohen Auflösung der IKONOS-Daten war die Klassifizierung schwierig. Lediglich die Unterscheidung von Laub- und Nadelgehölzen war möglich. Schattenflächen innerhalb geschlossener Waldbestände konnten über Nachbarschaftsabfragen klassifiziert und in die Gehölzklassen integriert werden. Der Begriff „Nachbarschaft“ wird in dieser Arbeit in einem engeren Sinn verstanden und bedeutet nicht „in der Nähe“, sondern „angrenzend an“.

Die Erkennung von naturschutzfachlich wertvollen Einzelbäumen sowie von frei stehenden Feldgehölzen und Gebüschern konnte über Nachbarschaftsbeziehungen und dem Einsatz von Schwellenwerten bei den Segmentgrößen erreicht werden. Dies ist von praktischer Bedeutung, weil ökologisch bedeutsame Strukturen wie Feldgehölze oder freistehende Gehölzgruppen z. B. im Rahmen des „Integrierten Verwaltungs- und Kontrollsystems“ (INVEKOS) der Bayerischen Landesanstalt für Landwirtschaft erfaßt werden sollen (RINTELEN 2004).

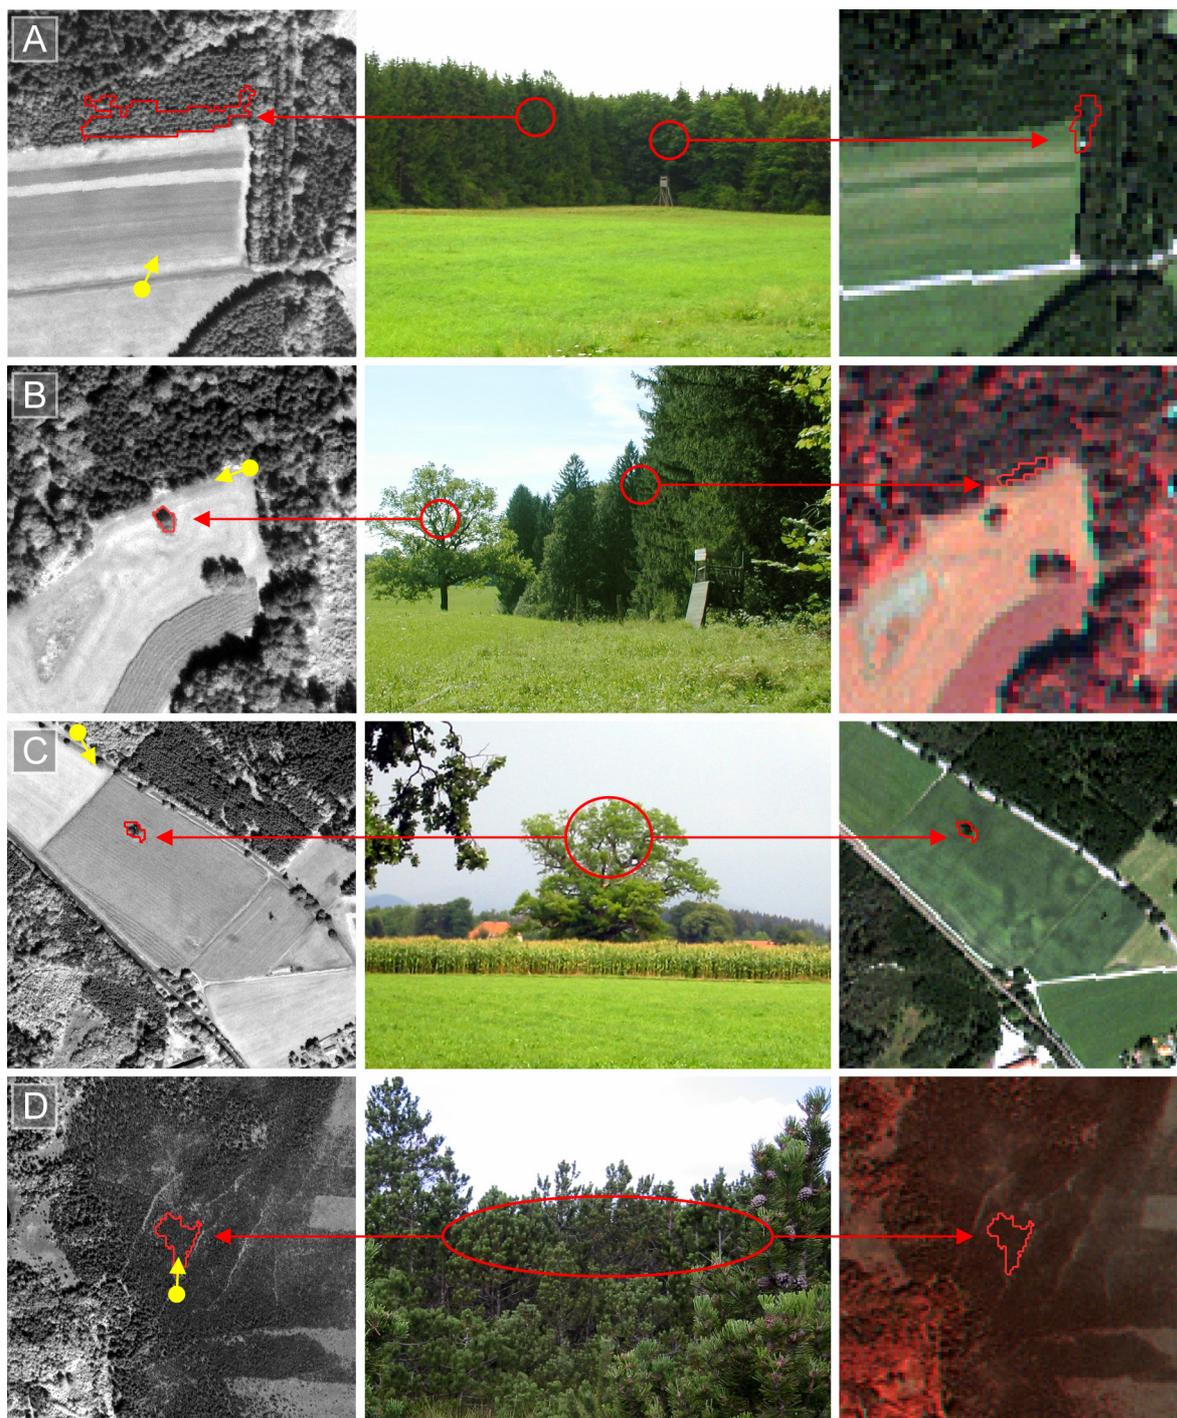
Um eine Vorstellung zu geben, auf welche Weise verschiedene Laub- und Nadelgehölztypen aus dem Untersuchungsgebiet in den IKONOS-PAN-Daten und in den multispektralen (MS) IKONOS-Daten abgebildet sind, werden in Abbildung 23 (April) und Abbildung 24 (August) repräsentative Geländephographien von Gehölzen und ihr entsprechendes Aussehen im IKONOS-Satellitenbild gezeigt. Auch die Objektkontur, die durch die Segmentierung generiert wurde, ist in den Abbildungen in rot abgebildet. Der Ursprung des roten Pfeils weist vom Bildobjekt auf die entsprechende Vegetationseinheit in der Geländephographie. Zur genauen Lokalisation der Gehölze kamen im Gelände zusätzlich GPS-Messungen zum Einsatz.



**Abb. 24:** Gegenüberstellung von Geländeaufnahmen (mittig, vom April 2002/2003) und den entsprechenden Objekten in panchromatischen IKONOS-Daten (links) und multispektralen IKONOS-Daten (rechts) vom 24.04.2001. Laubgehölz westlich von Iffeldorf (A), Ufergehölz naturnaher Fließgewässer (Steinbach) im FFH-Gebiet „Moor- und Drumlinlandschaft zwischen Hohenkasten und Antdorf“ (B), Fichtenforst und Solitäreiche südöstlich von Iffeldorf (C). (A) und (C) sind multispektral in Echtfarbkombination, (B) in NIR-Farbkombination. Die roten Pfeile und Konturen markieren die Objekte. Der gelbe Pfeil zeigt jeweils die Blickrichtung der Geländeaufnahme.

Die Abbildung 23 zeigt verschiedene Gehölztypen zu Beginn der Vegetationsperiode. Obschon nicht ausgetriebene Laubgehölze im April sowohl in den PAN- als auch in den multispektralen Daten einen „unscharfen“ Eindruck machen (Abb. 23 (A, B, rechts)), wurden die Laubgehölz-Bildobjekte durch die automatische Segmentierung sehr gut erfaßt (rote Objektkontur). Aus dem Vergleich der Laubgehölze in den Geländephotographien (Abb. 23 (A, B, mittig)) wird die hohe Vielfalt der Wuchsformen dieser Klasse ersichtlich. Auch Nadelgehölze hatten in den dargestellten Beispielen im April ausreichend guten Kontrast zur Umgebung (Abb. 23 (B, C, links)), so daß plausible Objektkonturen generiert wurden. Nadelgehölze wiesen in den PAN-Daten einen dunklen Grauton auf und waren leicht texturiert (Abb. 23 (B, links)). Wie in Abbildung 23, werden in Abbildung 24 Geländephotographien (mittig) von Laub- und Nadelgehölzen gezeigt, diesmal gegen Ende der Vegetationsperiode im August.

**IKONOS-PAN August 2001    Geländeaufnahme August 2002/ 2003    IKONOS-MS August 2001**



**Abb. 25:** Gegenüberstellung von Geländeaufnahmen vom August 2002/2003 (mittig) und den entsprechenden Objekten in panchromatischen IKONOS-Daten (links) und multispektralen IKONOS-Daten (rechts) vom 12.08.2001. Forst nordöstlich von Staltach (A), Forst und Solitäreiche südlich von Gut Schwaig (B), Solitäreiche nördlich von Staltach (C), Kiefern im FFH-Gebiet Weidfilz (D). (A) und (C) sind multispektral in Echtfarbkombination, (B) und (D) in NIR-Farbkombination. Die roten Pfeile und Konturen markieren die Objekte. Der gelbe Pfeil zeigt jeweils die Blickrichtung der Geländeaufnahme.

Auffallend sind in Abbildung 24 die Objektkonturen des Fichtenforstes (A) oder der Kiefern (D). Sie erscheinen dem Betrachter nicht plausibel, denn sowohl beim Fichtenforst (A) als auch bei den Kiefern (D) erscheint die getroffene Objektbegrenzung als willkürlich bzw. zu klein. Die Ursache ist hier bei den Einstellungsparametern für die Segmentierung zu suchen. Über den *Scale*-Parameter wird eine

maximal erlaubte Heterogenität eingestellt, wobei dieser Wert mit der Maximalgröße eines Bildobjekts korreliert. Sobald die maximale Heterogenität erreicht wird, erfolgt keine weitere Vergrößerung des Bildobjekts. Wenn also der Kontrast zur Umgebung bzw. die Grenzlinie zu anderen Landbedeckungstypen nicht eindeutig ist, aber die maximale Heterogenität für ein Bildobjekt erreicht ist, dann entstehen für den Betrachter schwer nachvollziehbare Formen. Ist der Kontrast zur Umgebung deutlich wie bei den Einzelbäumen in Abbildung 24 (B, links und C), so wird eine Struktur durch ein Bildobjekt sehr genau erfaßt.

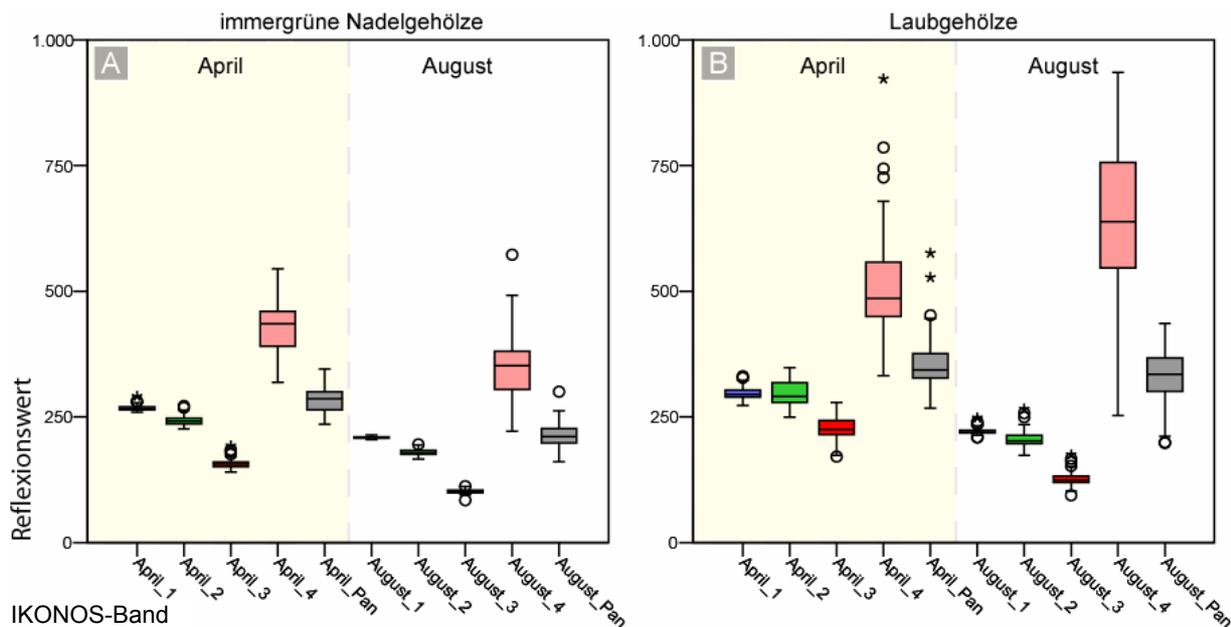
Aus Abbildung 23 und Abbildung 24 wird außerdem erkennbar, daß Nadelgehölze verschiedener Arten und Wuchsformen im Untersuchungsgebiet auftreten (Abb. 23 (B), 24 (D)). Für Laubgehölze gilt das genauso (Abb. 23 (A), 24 (C)). Zudem hatte im April der Austrieb der Laubgehölze noch nicht stattgefunden (Abb. 23 (A)). Trotz der hohen räumlichen Auflösung der Daten war keine Differenzierung der Baumarten anhand der Kronengestalt möglich. Dies stimmt mit Erfahrungen HILDEBRANDTS (1996) überein, der für die Beurteilung der Kronenform einen Bildmaßstab von ca. 1 : 1000 für erforderlich hält. Die hier verwendeten IKONOS-Daten lagen lediglich im Maßstab 1 : 10000 vor.

Im Vorfeld der Klassifikation war zu klären, wie spezifische Reflexionseigenschaften der Gehölze in IKONOS-Daten abgebildet werden, um diese in Regelwerken zu formalisieren. Dabei war entscheidend, ob die Erfahrungen und das Wissen über das Reflexionsverhalten einer Landbedeckungsklasse von der Bildpunktebene auf Objektebene übertragbar sind.

### **Spektraleigenschaften der Klassen „Laubgehölze“ und „Nadelgehölze“**

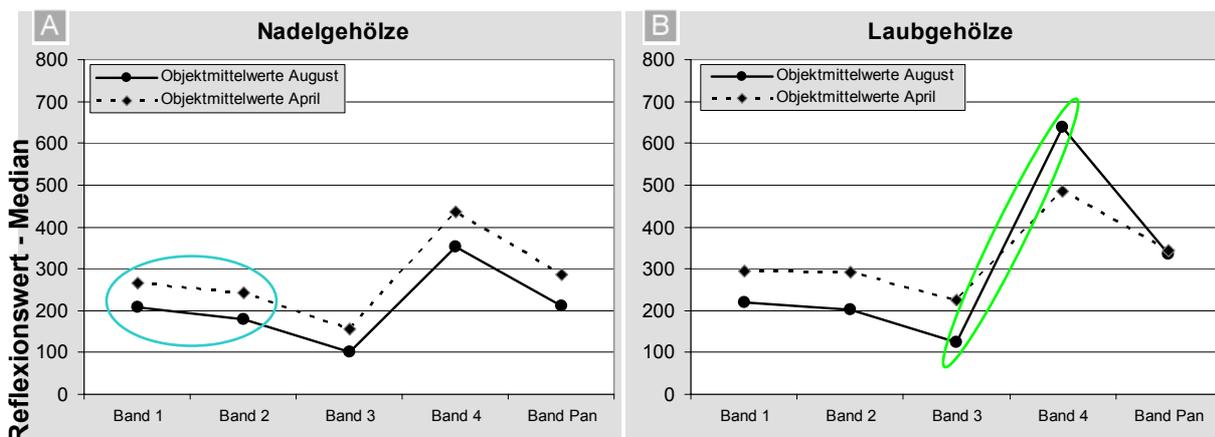
Bei Pflanzen wird die Reflexionsantwort im sichtbaren Spektrum vor allen Dingen von der Absorption durch die Blattpigmente bestimmt. Grüne und gesunde Blatt- und Nadelorgane zeigen ein typisches Reflexionsverhalten: die Blattpigmente absorbieren im blauen und im roten Spektrum und weisen ein Reflexionsmaximum im grünen Spektralbereich auf. Aus diesem Grund erscheinen gesunde Blätter grün. Im nahen Infrarot (NIR) absorbieren Blattpigmente dagegen fast nicht. Die Menge der reflektierten und transmittierten NIR-Strahlung ist abhängig von Art und Zustand der Strukturen der Blattoorgane. Insbesondere Laubblätter reflektieren im nahen Infrarot stärker als Nadeln.

Die Frage, ob die Kenntnis über die für die Bildpunktebene gültigen Reflexionseigenschaften auch für die Objektebene zutrifft, wurde mit einer Boxplot- und einer Signaturanalyse untersucht. In Abbildung 25 sind die spektralen Objektmittelwerte für Nadel- und Laubgehölze in Form von Boxplots dargestellt.



**Abb. 26:** Boxplotdarstellung für die spektralen Mittelwerte der Referenzflächen für die Klassen „Nadelgehölze“ (A) und „Laubgehölze“ (B). Für „Nadelgehölze“ wurden 42 Referenzbildobjekte geprüft; für „Laubgehölze“ 62 Referenzbildobjekte.

Nadelgehölze wiesen in der April- und in der August-Aufnahme eine sehr ähnliche Verteilung der Werte auf (Abb. 25 (A)), was im Signaturdiagramm (Abb. 26 (A)) besonders deutlich wird. Die Werte waren im August allerdings nach unten verschoben. Die Spannweiten der Spektralwerte, also die Differenz aus Maximalwert und Minimalwert, blieben dagegen nahezu identisch. Bei Laubgehölzen traten verglichen mit Nadelgehölzen in allen Bändern eine höhere Streuung der Spektralwerte auf, was aus den größeren Boxen zu schließen ist (Abb. 25 (B)). Das bedeutet auch, daß Laubgehölze ein variables spektrales Erscheinungsbild besitzen. Besonders fällt die extreme Streuung der Werte im NIR-Band sowohl in der August-Aufnahme als auch in der April-Aufnahme auf. Im April waren zusätzlich Ausreißer und Extremwerte zu finden. Die Umsetzung im Regelwerk mußte für dieses Attribut daher entsprechend weit gefaßt werden. Im folgenden Signaturdiagramm (Abb. 26) wird die Veränderung des Reflexionsverhaltens im Verlauf der Vegetationsperiode deutlicher.



**Abb. 27:** Signaturdiagramm für die Klassen "Nadelgehölze" (A) und "Laubgehölze" (B). Gezeigt wird der Signaturverlauf anhand der Objektmittelwerte aller IKONOS-Bänder für April (gestrichelte Linie) und August (durchgehende Linie). Die Reflexionswerte von Band 1 sind größer als die von Band 2, was auf die fehlende Atmosphärenkorrektur zurückzuführen ist (A, blaue Ellipse). Auffällig ist der deutliche Sprung der Reflexionswerte der Laubgehölze von Band 3 zu Band 4 im August (B, grüne Ellipse).

Für Nadelgehölze war der Verlauf der Signatur bei den verschiedenen Aufnahmezeitpunkten nahezu identisch, mit dem Unterschied, daß im August die Signale aller Bänder abgeschwächt waren (Abb. 26 (A)). Die Stetigkeit der Abschwächung läßt eine abweichende Kalibrierung des Sensors vermuten, doch spielten hier auch Anisotropie-Effekte eine Rolle, die durch die unterschiedlichen relativen Sonnenwinkel beider Aufnahmen bedingt waren (Abb. 14). Bei vergleichbaren Sonnenständen wurde die April-Aufnahme in Richtung der Sonneneinstrahlung erfaßt, während die August-Aufnahme im Gegenlicht aufgenommen wurde. Die Abschwächung trat ebenfalls bei Laubgehölzen für die Signaturen des sichtbaren Spektrums auf (Abb. 26 (B)), wobei hier die fehlende Belaubung im April den deutlichsten Einfluß auf die Signatur hatte. Auffällig, aber nicht überraschend, war bei Laubgehölzen im August der Sprung vom roten Band zum nahen Infrarotband (Abb. 26 (B, grüne Ellipse)). Die vollständig ausgewachsene Belaubung beeinflusste hier die Reflexionsantwort. In der April-Aufnahme waren die Laubgehölze größtenteils noch unbelaubt, weshalb dort der Unterschied zwischen roten Band und nahen Infrarotband geringer ausfiel.

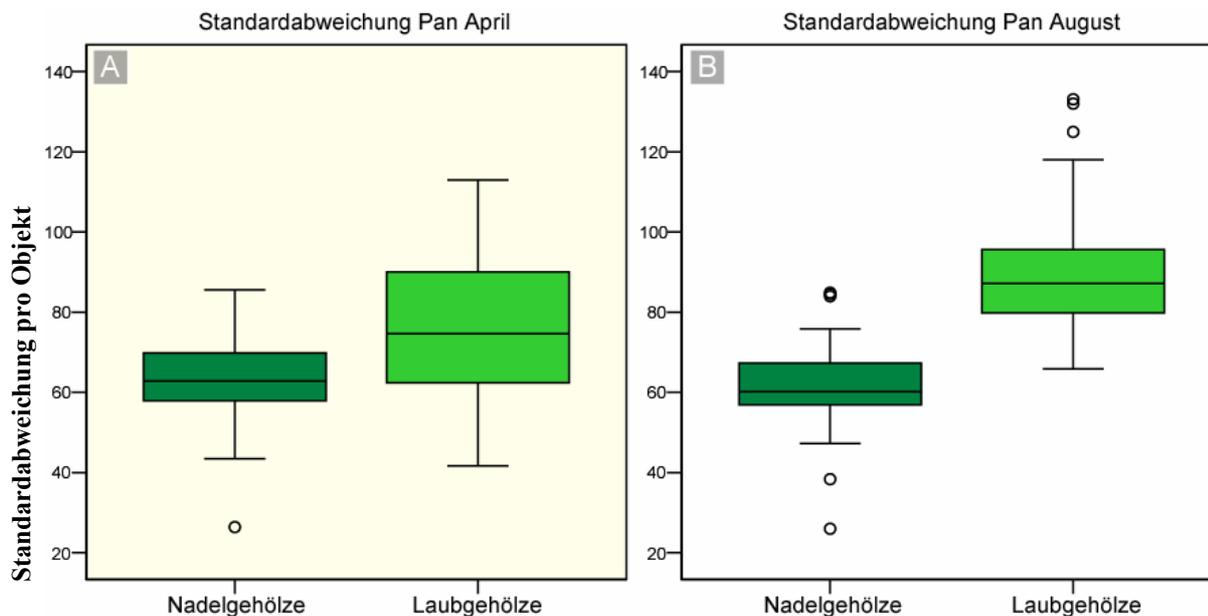
Gut erkennbar ist in Abbildung 26 (A, blaue Ellipse) die fehlende Atmosphärenkorrektur beider Aufnahmen: bei vitaler Vegetation ist die Reflexion bei korrigierten Daten im blauen Band (1) immer geringer als die Reflexion im grünen Band (2). Bei den vorliegenden Messungen verhielt es sich umgekehrt. Ursache dafür ist die sogenannte Rayleigh-Streuung in der Atmosphäre. Im Rahmen des Projekts AQUATIC wurde aus Kostengründen auf eine Atmosphärenkorrektur verzichtet. Die Atmosphäre beeinflusst vor allem den kurzwelligen, blauen Bereich des Spektrums und erhöht (fälschlicherweise) die Reflexionswerte. Auf das Ergebnis der Klassifikation wirkte sich die fehlende Atmosphärenkorrektur jedoch nicht aus.

Die Erfahrungen der Boxplot- und Signaturanalyse bestätigten, daß sich das Expertenwissen über die Reflexionseigenschaften von Vegetation auch auf der Objektebene abbildet. Diese aus den Verteilungstatistiken gewonnene Erkenntnis wurde in Form von Regelwerken umgesetzt.

Die Analyse von Textureigenschaften stellte den nächsten Schritt beim Aufbau der Regelwerke dar. Diese Muster und Grauwertvariationen der Objekte sind ein wichtiges Entscheidungsmerkmal bei der visuellen Interpretation. Wie bereits erwähnt, ermöglichte es der objektorientierte Ansatz, verschiedenste Textureigenschaften bei der Klassifizierung miteinzubeziehen und erlaubte dadurch eine Erweiterung der Klassenbeschreibung um aussagekräftige Merkmale.

### **Textureigenschaften der Klassen „Laubgehölze“ und „Nadelgehölze“**

Als sinnvolles Merkmal für die Trennung von Laub- und Nadelgehölzen erwies sich die Standardabweichung im PAN-Kanal, denn dieses Attribut steht zu der Textur eines Objektes in direkter Beziehung. Struktur- und schattenbedingte Variationen der Kronenoberfläche wurden im PAN-Kanal durch unterschiedliche Standardabweichungen abgebildet. Dies liegt zum einen an der hohen Auflösung, zum anderen an der Infrarotinformation des PAN-Kanals. Der Vergleich der Boxplots zur Standardabweichung im PAN-Kanal zeigte deutliche Unterschiede in den Werten der beiden Gehölzklassen an beiden Aufnahmezeitpunkten (Abb. 27).



**Abb. 28:** Boxplotdarstellung für die Standardabweichung pro Objekt im PAN-Kanal für „Nadelgehölze“ (immergrün) und „Laubgehölze“. Die Verteilung der Werte ist im April (A) weniger unterschiedlich als im August (B). Für „Nadelgehölze“ wurden 42 Referenzsegmente geprüft; für „Laubgehölze“ 62 Referenzsegmente.

Im Frühjahr und Sommer nahm die Standardabweichung der Laubgehölze höhere Werte an als die der Nadelgehölze (Abb. 27 (A)), wobei im April deutlichere Überschneidungen auftraten. Dieses Ergebnis war leicht nachzuvollziehen, denn zu beiden Zeitpunkten war das Erscheinungsbild der Laubgehölze abwechslungsreicher: im April schimmerte zum Teil der Boden durch die unbelaubten Äste und die feinen Aststrukturen bewirkten ein insgesamt „verschwommenes“ Bild (Abb. 23 (A)). Im August bedingten der Aufbau der Baumkronen von Laubbäumen sowie die strukturelle Vielfalt der Laubgehölze (Feldgehölze, Gebüsche, etc.) hohe Variationen der Reflexionswerte innerhalb der Objekte. Die Nadelgehölze im Untersuchungsgebiet bestehen größtenteils aus Fichtenforsten und eng stehenden Kiefernwäldern. Sie wiesen ein homogeneres Erscheinungsbild auf, weil die Bestandsstruktur deutlich regelmäßiger aufgebaut ist.

Eine weitere Gehölzklasse beschrieb die Schattenflächen, die innerhalb geschlossener Wälder vor allem auf Lichtungen auftreten.

### **Klasse „Gehölzschatten“**

Das Klassenregelwerk für „Gehölzschatten“ modellierte die Kennzeichen beschatteter Lichtungen. Bei der Klassifikation von „Gehölzschatten“ konnte der Vorteil des objektorientierten Ansatzes genutzt werden, indem kontextbezogenes Wissen einbezogen wurde. Die beschatteten Lichtungen, hervorgerufen durch Windwurf, Kahlschlag oder junge Aufforstungsflächen, hatten im sichtbaren Spektrum sehr geringe Reflexionen. Unter Verwendung des Attributs „direkte Nachbarschaft“ zu einer Gehölzklasse und der Vorgabe, daß eine Maximalgröße des Objektes von 500 m<sup>2</sup> nicht überschritten werden durfte, ließ sich die Klasse „Gehölzschatten“ ausreichend genau definieren. Ähnlich der Vorgehensweise eines Interpreten wurde so eine Fläche abhängig von ihrer Umgebung, ihrer Farbe und ihrer Größe charakterisiert.

### **„Gehölze Ebene 1“: „Nadelgehölze“, „Laubgehölze“, „Gehölzschatten“**

Der Übersichtlichkeit halber wird bei der Beschreibung des Regelwerks unterschieden zwischen Objektattributen, die sich ausschließlich aus den Werten der Spektralbänder errechnen (im folgenden

**Spektraleigenschaften** und **Textureigenschaften**) und Objektattributen, die einzig durch den objekt-orientierten Ansatz verfügbar sind (im folgenden **Objekteigenschaften**). Die Objekteigenschaften werden weiter differenziert in Formattribute (**Form**) und topologische Beziehungen (**Topologie**).

Die Gehölzklassen auf Ebene 1 wurden in der Klasse „Gehölze Ebene 1“ zusammengefaßt. Die entsprechende Gruppenstruktur ist in Abbildung 28 dargestellt. Die Vaterklasse „Gehölze Ebene 1“ war eine rein thematische Klasse ohne eigene Zugehörigkeitsfunktionen.



**Abb. 29:** Klassenhierarchie Gehölze Ebene 1. Die Gruppe „Gehölze Ebene 1“ setzt sich aus den Klassen „Nadelgehölze“, „Laubgehölze“ und „Gehölzschatten“ zusammen.

Die Regelwerke für die Gehölzklassen sind in den Abbildungen 29, 30 und 31 schematisiert dargestellt.

Nadelgehölze:							
Spektraleigenschaften		April		August			
		Min	Max	Min	Max		
Blau (1)		192	290	Blau (1)		180	240
Grün (2)		147	290	Grün (2)		142	200
Rot (3)		76	195	Rot (3)		72	135
NIR (4)		168	610	NIR (4)		150	515
PAN		160	380	PAN		130	290
NDVI		0,36	0,7	NDVI		0,34	0,6
Textureigenschaften		April		August			
<i>ODER</i>				<i>ODER</i>			
- geringe Homogenität (PAN)		0,14	0,1469	- geringe Homogenität (PAN)		0,14	0,1469
- Standardabweichung (PAN)		20	90	- Standardabweichung (PAN)		20	90
Objekteigenschaften							
Fläche / Form		Min	Max	Topologie	Bemerkung		
-		-	-	-	- Ebene 1 - Vaterklasse „Gehölze Ebene 1“		

**Abb. 30:** Regelwerk der Klasse „Nadelgehölze“. Während sich die Zugehörigkeitsbereiche für die Spektraleigenschaften bei den Aufnahmezeitpunkten jeweils unterscheiden, sind die Gültigkeitsbereiche der Textureigenschaften identisch.

Das Klassenregelwerk in Abbildung 29 kann folgendermaßen interpretiert werden: die Klasse „Nadelgehölze“ hatte im April definierte Zugehörigkeitskurven für die Spektraleigenschaften in den Bändern Blau (1), Grün (2), Rot (3), NIR (4) und PAN. Da sich der NDVI direkt aus den Spektraleigenschaften errechnet, wurde er auch in die Kategorie **Spektraleigenschaften** aufgenommen. Hinter den Spektralkanälen - in der nächsten Spalte - ist der Kurvenverlauf der Zugehörigkeitsfunktion vereinfacht in Symbolform dargestellt. Das Symbol zeigt, daß es sich um eine nach links und rechts begrenzte Kurve handelte. Das bedeutet, daß Spektraleigenschaften, die kleiner sind als das Minimum (Min) und größer sind als das Maximum (Max), keine Zugehörigkeit zu diesem Objektattribut aufwiesen. Dazwischen liegt der Wertebereich, in dem *fuzzy*-Zugehörigkeiten zugewiesen wurden. Sofern nicht anders beschrieben, wurden die einzelnen Zugehörigkeitsfunktionen über den Operator *UND* miteinander verknüpft. Im unteren Tabellenabschnitt sind die Zugehörigkeitskurven für die **Textureigenschaften** dargestellt. Die beiden hier verwendeten Attribute, „Homogenität (PAN)“ und „Standardabweichung (PAN)“ sind über einen „*ODER*“-Operator miteinander verknüpft worden, d.h. daß mindestens eine der beiden Zugehörigkeitskurven zutreffen muß. Die Erfahrung zeigte, daß nicht alle vorkommenden strukturellen Variationen mit nur einer Textureigenschaft abgebildet werden konnten, wohl aber mit der Vereinigungsmenge, die sich aus beiden Textureigenschaften ergibt. Reine

**Objekteigenschaften** wie Formattribute und topologische Beziehungen wurden nicht verwendet, weil die Klasse ausreichend gut mit Spektral- und Texturattributen definiert werden konnte. Als Bemerkung sei angefügt, daß die Klasse „Nadelgehölze“ auf Objektskalenebene 1 klassifiziert wurde. Während die Regelwerke für die Spektraleigenschaften jeweils für die Aufnahmezeitpunkte April und August angepaßt werden mußten, galt die Definition der Textureigenschaften sowohl für den Beginn (April) als auch für die fortgeschrittene Vegetationsperiode (August).

<b>Laubgehölze:</b>							
<b>Spektraleigenschaften</b>		<b>April</b>		<b>August</b>			
		Min	Max	Min	Max		
Blau (1)		206	320	Blau (1)		206	250
Grün (2)		155	345	Grün (2)		170	275
Rot (3)		85	330	Rot (3)		79	205
NIR (4)		260	990	NIR (4)		240	990
PAN		195	450	PAN		220	487
NDVI		0,25	0,5	NDVI		0,4	0,8
<b>Textureigenschaften</b>		<b>April</b>		<b>August</b>			
<b>ODER</b>				<b>ODER</b>			
geringe Homogenität (PAN)		0,12	0,13	geringe Homogenität (PAN)		0,104	0,1047
Standardabweichung (PAN)		40	120	Standardabweichung (PAN)		40	140
<b>Objekteigenschaften</b>							
Fläche / Form		Min	Max	Topologie	Bemerkung		
-		-	-	-	- Ebene 1 - Vaterklasse „Gehölze Ebene 1“		

**Abb. 31:** Regelwerk der Klasse „Laubgehölze“.

Das Klassenregelwerk für „Laubgehölze“ (Abb. 30) entspricht im Aufbau demjenigen für Nadelgehölze. Die Klasse „Laubgehölze“ unterschied sich deutlicher hinsichtlich der beiden Aufnahmezeitpunkte, was eng mit der Entwicklung der Laubgehölze während der Vegetationsperiode zusammenhing. Besonders stark spiegelte sich die Entwicklung im Vegetationsindex NDVI wider. Der Wertebereich lag dabei im August wesentlich höher. Im Gegensatz zu den Nadelgehölzen veränderten sich hier auch die Texturwerte. Die Homogenität des Kronendachs nahm zum Sommer ab, und die gültigen Werte für die Standardabweichung im PAN nahmen zu. Vor allem Einzelbäume, Feldgehölze, Gebüsche und Laubwaldränder wiesen einen hohen Texturwert auf.

<b>Gehölzschatten</b>							
<b>Spektraleigenschaften</b>		<b>April</b>		<b>August</b>			
		Min	Max	Min	Max		
geringe Helligkeit		194	205	geringe Helligkeit		180	190
<b>Objekteigenschaften</b>							
Fläche / Form		Topologie		Bemerkung			
- Fläche > 500 m <sup>2</sup>		- gemeinsame Grenze mit „Gehölze Ebene 1“ > 55 %		- Ebene 1 - Vaterklasse „Gehölze Ebene 1“			
<b>Klassenausschluß</b>							
- nicht „Binnengewässer (2000)“							

**Abb. 32:** Regelwerk der Klasse „Gehölzschatten“.

Die beschatteten Waldflächen wurden über die spektrale Eigenschaft „Helligkeit“ ausgewählt. Das war ein generiertes *Customized Feature*, das sich aus den gemittelten Werten der Bänder des sichtbaren Spektrums errechnete:  $\frac{(\text{Band } 1 + \text{Band } 2 + \text{Band } 3)}{3}$ .

Schattenflächen zeigten konstant dunkle Reflexionen in allen Bändern des sichtbaren Spektrums. Die geringe „Helligkeit“, kombiniert mit der Bedingung „unmittelbare Nachbarschaft zu einer

Gehölzklasse“ (Laub- oder Nadelgehölz), erlaubte die Detektion von Schattenflächen innerhalb von Baumbeständen und an Waldrändern. Voraussetzung für die Klassenzugehörigkeit war, daß mehr als 55 % der Objektkontur, zu einem Objekt das bereits als „Gehölze Ebene 1“ klassifiziert wurde, angrenzen mußte. Dieser Schwellenwert wurde empirisch über „*Trial-and-Error*“-Experimente ermittelt. Um Verwechslungen mit Wasserflächen (ebenfalls geringe Helligkeit) zu vermeiden, wurde die Bedingung gestellt, daß „Gehölzschatten“ keine gleichzeitige Zugehörigkeit zur Klasse „Binnengewässer (2000)“ aufweisen durften. Durch den objektorientierten Ansatz konnten also fehlerhafte Klassenzuweisungen ausgeschlossen bzw. spektrale Verwechslungen (Seefläche - Schatten) vermieden werden.

Vom Ablauf her wurden in einem ersten Klassifikationsdurchlauf die Klassen „Laubgehölze“ und „Nadelgehölze“ detektiert. Anschließend konnten in einem weiteren Klassifikationsdurchlauf benachbarte Schattenflächen gefunden werden.

### „Gehölze Ebene 2“: „Bäume, Feldgehölze, Gebüsche (6000)“ und „Wälder (7000)“

Die auf Ebene 1 detektierten Gehölzklassen wurden auf Objektskalenebene 2 übertragen und zwar als Klasse „Gehölze Ebene 2“. Auf dieser Segmentierungsebene wurde die Zusammensetzung der Unterobjekte abgefragt. Bedingung war, daß mehr als 90 % der Fläche eines Objektes der Ebene 2 auf Ebene 1 mit „Gehölzen Ebene 1“ („Laub-“, „Nadelgehölze“ oder „Gehölzschatten“) bedeckt sein mußte. Dabei wurden „klassenfremde“ Anteile von unter 10 % toleriert. Auf diese Art wurden Informationen von Ebene 1 für die Klassifikation von Ebene 2 genutzt und somit Informationen auf eine kleinere Objektskalenebene übertragen. Das Regelwerk ist in Abbildung 32 dargestellt.

Gehölze Ebene 2		
Objekteigenschaften		
Fläche / Form	Topologie	Bemerkung
-	- > 90% der Fläche haben „Gehölze Ebene 1“ Unterobjekte	- Ebene 2

Abb. 33: Regelwerk der Klasse „Gehölze Ebene 2“.

Die Klasse „Gehölze Ebene 2“ war die Vaterklasse der Gehölzklassen auf dieser Objektskalenebene. Die Vererbungsstruktur, die auch der Gruppenstruktur entspricht, wird in Abbildung 33 vorgestellt.

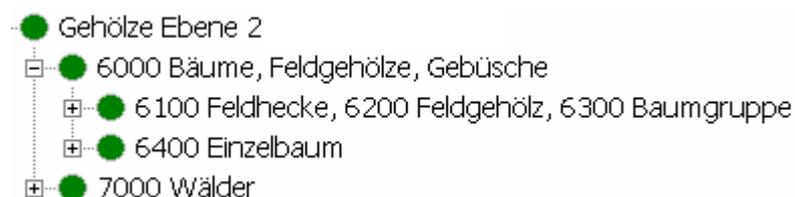


Abb. 34: Vererbungs-/Gruppenstruktur der Gehölzklassen auf Segmentierungsebene 2. Die Zugehörigkeitsregeln werden von der Vaterklasse jeweils auf die Sohnklassen vererbt.

Der nächste Schritt war die Unterscheidung der Klassen „Bäume, Feldgehölze, Gebüsche (6000)“ und „Wälder (7000)“. Diese beiden Klassen waren „Söhne“ der Klasse „Gehölze Ebene 2“ und erbten die Bedingung der Vaterklasse, daß mindestens 90 % der Fläche in Ebene 1 mit „Gehölze Ebene 1“ bedeckt sein mußte. Die Diskriminierung der Unterklassen (6000..., 7000...) erfolgte anhand von Flächengrößen und Nachbarschaftsbeziehungen.

**„Bäume, Feldgehölze, Gebüsch (6000)“**

*„Bäume, Feldgehölze und Gebüsch sind vom Wald isolierte, in der freien Landschaft außerhalb geschlossener Ortschaften vorkommende punkt-, linien- oder flächenhafte (Größe unter 0,5 bis 1 ha, Mindestbreite 5 m) Biotop“* (BFN 2002).

Mit dem Methodenpool von eCognition konnte die Beschreibung aus der Kartieranleitung direkt umgesetzt werden (BFN 2002). Das Auftreten *in der freien Landschaft* konnte durch Nachbarschaftsbeziehungen definiert werden. Bedingung war hier, daß Objekte von „Gehölze Ebene 2“ nicht in unmittelbarer Nachbarschaft angrenzen durften, also isoliert in der Landschaft stehen mußten. Da Feldgehölze ausschließlich *außerhalb geschlossener Ortschaften* (BFN 2002) vorkommen, wurde die Klasse „Siedlung, Verkehr, Freizeit (9000)“ ebenfalls als unmittelbare Nachbarklasse ausgeschlossen bzw. Bäume, die von Siedlungsklassen umgeben waren, wurden in diese integriert. Die Größenordnung von maximal 1 ha Fläche konnte im Regelwerk direkt formalisiert werden. Für die Mindestbreite wurde keine Regel aufgestellt, da 5 m im Bereich der Bildpunktauflösung der Multi-spektraldaten lagen. Kleinere Strukturen wurden nicht detektiert. Das Regelwerk stützte sich ausschließlich auf Formparameter und topologische Beziehungen (Abb. 34).

<b>Bäume, Feldgehölze, Gebüsch (6000)</b>		
<b>Objekteigenschaften</b>		
Fläche / Form	Topologie	Bemerkung
- Fläche < 1 ha	- gemeinsame Grenze mit „Gehölze Ebene 2“ < 10 % - nicht angrenzend an „Siedlung, Verkehr, Freizeit (9000)“	- Ebene 2 - erbt Zugehörigkeiten von „Gehölze Ebene 2“

**Abb. 35:** Regelwerk der Klasse „Bäume, Feldgehölze, Gebüsch (6000)“.

Eine Differenzierung in „Feldhecke (6100), Feldgehölz (6200), Baumgruppe (6300)“ und „Einzelbaum (6400)“ war über die Definition weiterer Schwellenwerte für die Flächenausdehnung erreichbar. Die Erfahrung zeigte, daß eine Gehölzstruktur von weniger als 700 m<sup>2</sup> Fläche ein Einzelbaum war (Abb. 35), wohingegen Gehölze mit mehr als 700 m<sup>2</sup> Fläche (max. 10000 m<sup>2</sup>) der Klasse „Feldhecke (6100), Feldgehölz (6200), Baumgruppe (6300)“ angehörten (Abb. 36). Der vergleichsweise hohe Schwellenwert von 700 m<sup>2</sup> läßt sich mit der Tatsache begründen, daß bei Einzelbäumen häufig Gehölzschatten in dasselbe Bildobjekt integriert wurden. Dadurch vergrößerte sich die Flächenausdehnung. Ein Formparameter für die Beschreibung von Baumgruppen („eher länglich“) hat sich als nicht sinnvoll erwiesen, da die Zahl der Ausnahmen zu groß war.

<b>Einzelbaum (6400)</b>		
<b>Objekteigenschaften</b>		
Fläche / Form	Topologie	Bemerkung
- Fläche < 700 m <sup>2</sup>	-	- Ebene 2 - erbt Zugehörigkeiten von „Gehölze Ebene 2“ - erbt Zugehörigkeiten von „Bäume, Feldgehölze, Gebüsch (6000)“

**Abb. 36:** Regelwerk der Klasse „Einzelbaum (6400)“.

<b>Feldhecke (6100), Feldgehölz (6200), Baumgruppe (6300)</b>		
<b>Objekteigenschaften</b>		
Fläche / Form	Topologie	Bemerkung
- Fläche > 700 m <sup>2</sup>	-	- Ebene 2 - erbt Zugehörigkeiten von „Gehölze Ebene 2“ - erbt Zugehörigkeiten von „Bäume, Feldgehölze, Gebüsche (6000)“

**Abb. 37:** Regelwerk der Klasse „Feldhecke (6100), Feldgehölz (6200), Baumgruppe (6300)“.

Die Bedingung, daß die Flächengröße 1 ha nicht unterschreiten darf, wurde von der Vaterklasse „Bäume, Feldgehölze, Gebüsche (6000)“ geerbt.

### „Wälder (7000)“

*„Waldflächen sind mit Bäumen und Sträuchern bedeckte Flächen, die in der Regel forstwirtschaftlich genutzt werden. Wälder sind die natürliche Vegetation auf den meisten Standorten Mitteleuropas. Kahlschlag, Windwurfflächen, Vorwälder und Aufforstungsflächen sowie Walränder sind eingeschlossen“* (BFN 2002).

Für die Klasse „Wälder (7000)“ ließ sich nach der Definition des Bundesamts für Naturschutz (BFN 2002) ein einfaches Regelwerk erstellen. Wälder zeichneten sich durch direkte Nachbarschaft zu anderen „Gehölze Ebene 2“-Objekten *ODER* einer Flächengröße von mehr als 1 ha aus.

<b>Wälder (7000)</b>		
<b>Objekteigenschaften</b>		
Fläche / Form	Topologie	Bemerkung
- Fläche > 1 ha	<i>ODER</i> - Grenze zu „Gehölze Ebene 2“ > 10%	Ebene 2 erbt Zugehörigkeiten von „Gehölze Ebene 2“

**Abb. 38:** Regelwerk der Klasse „Wälder (7000)“.

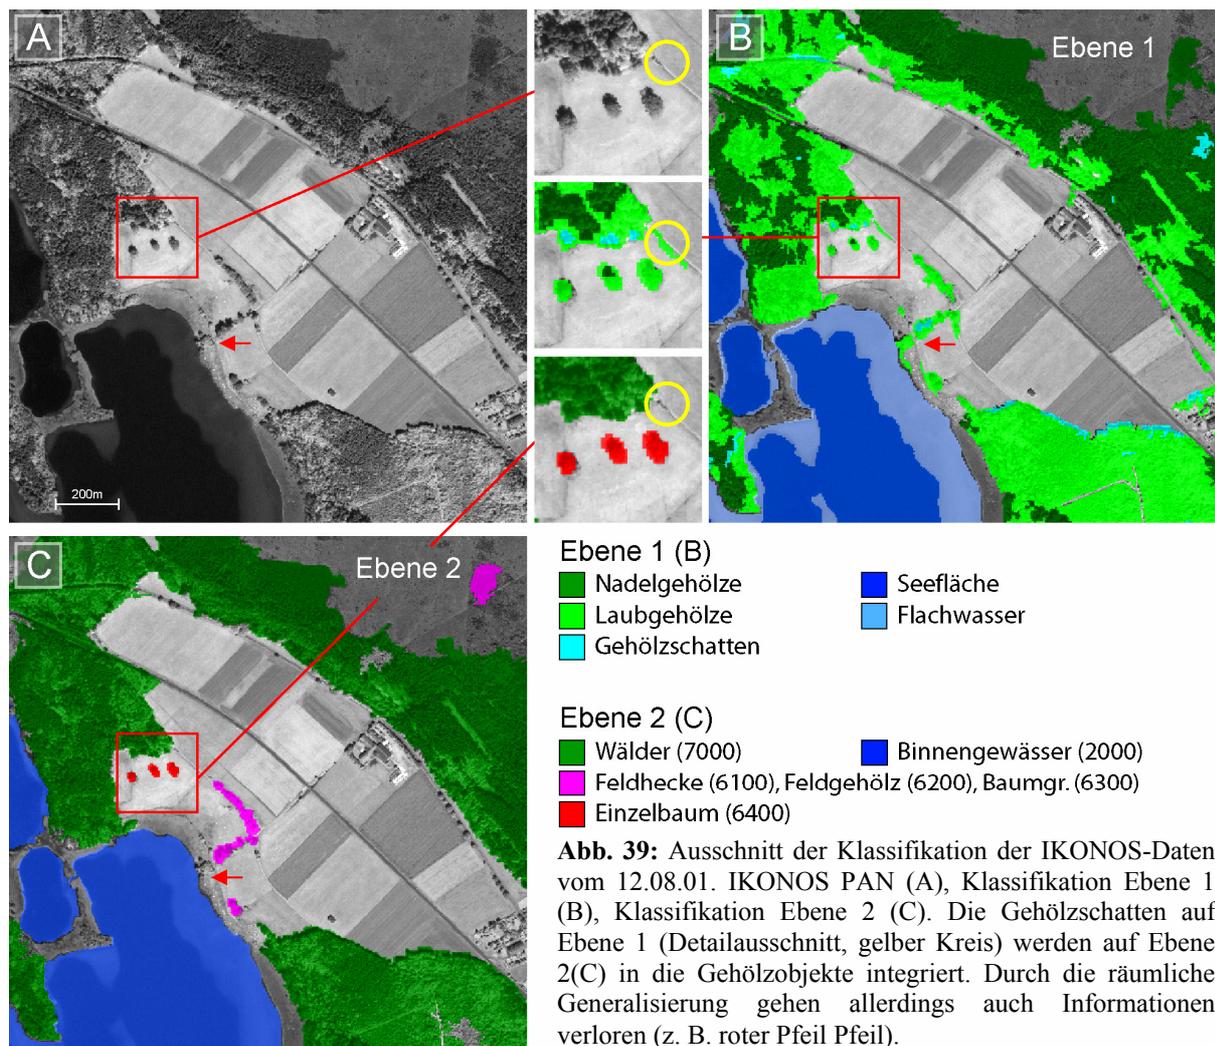
### Zusammenfassung der Klasse Gehölze

Wie dargestellt, wurden bei der Klassifikation von Gehölzen unterschiedliche Möglichkeiten des objektorientierten Ansatzes genutzt:

- Klassifikation auf unterschiedlichen Objektskalenebenen
- Kombination von Spektral- und Textureigenschaften
- Implementierung von Expertenwissen, z. B. durch Definition von Flächengrößen aus der Kartieranleitung oder durch Nachbarschaftsbeziehungen, die ein Interpret unbewußt verwendet

Nachdem die Gehölze auf der Segmentierungsebene 1 durch Textur und Spektraleigenschaften detektiert wurden, war eine Übertragung dieser Information auf die größere Objektskalenebene möglich. Auf Segmentierungsebene 2 wurden ausschließlich reine Objekteigenschaften verwendet. Hier konnten die Gehölze durch Nachbarschaftsbeziehungen und Flächen-Schwellenwerte entsprechend dem Kartierschlüssel (BFN 2002) klassifiziert werden.

In Abbildung 38 ist ein Ausschnitt einer Klassifikation der August-Daten dargestellt.

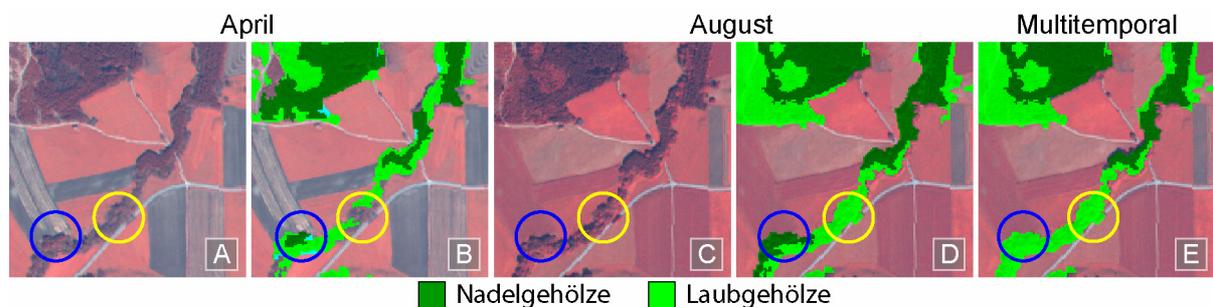


Auf der Objektskalenebene 2 (Abb. 38 (C)) waren die Segmentflächen größer und dementsprechend wurden manche Strukturen nicht mehr so detailliert erfaßt. Dies hatte sowohl negativen als auch positiven Einfluß: zum einen wurden gewünschte Strukturen wie Kleinsträucher zu sehr generalisiert und waren als Segment auf Ebene 2 nicht mehr aufgelöst (Abb. 38, roter Pfeil). Zum anderen wurden fehlerhafte Zuweisungen beseitigt, die auf spektralen Verwechslungen gründeten (Abb. 38, Detailausschnitt, gelber Kreis).

### Multisaisonale Zusammenhänge bei Gehölzen

Wie durch die Boxplotanalysen bestätigt werden konnte, wandeln sich Signaturen und Gestaltmerkmale im Lauf der Vegetationsperiode. Diese Tatsache liegt jeder multisaisonalen Klassifikation zugrunde. Bei Laubgehölzen trat dies besonders deutlich auf.

Durch eine kombinierte Abfrage des NDVI an beiden Aufnahme-Zeitpunkten (April, August) ließen sich Laub- und Nadelgehölze genauer identifizieren, als wenn nur der NDVI eines Aufnahme-Zeitpunkts für die Erstellung der Regelwerke herangezogen wurde. Gehölze, die im April deutlich niedrigere NDVI-Werte aufwiesen als im August, wurden der Klasse „Laubgehölze“ zugewiesen. Waren die Unterschiede des NDVI beider Aufnahmezeitpunkte weniger ausgeprägt, so war dies ein Indiz für eine Zuweisung zur Klasse „Nadelgehölze“. Zudem war die Schattenbildung im April aufgrund der unbelaubten Gehölzstrukturen weit weniger ausgeprägt. Schattenflächen, sofern nicht durch die Klasse „Gehölzschatten“ ausgeschlossen, wurden im August zum Teil als „Nadelgehölze“ fehlklassifiziert. In Abbildung 39 werden Klassifikationen für Gehölzstrukturen beider Zeitpunkte einander gegenüber gestellt.



**Abb. 40:** Darstellung der multisaisonalen Zusammenhänge. Aufgrund der fehlenden Beblätterung können verschiedene Laubgehölzflächen in der April-Aufnahme (A) nicht detektiert werden (B) (z. B. gelber Kreis). In der August-Aufnahme (C) werden stark beschattete Laubgehölzstrukturen fälschlich zu Nadelgehölzen zugewiesen (D, z. B. blauer Kreis). Durch die gemeinsame Auswertung der Aufnahmen beider Zeitpunkte können solche Fehler minimiert werden (E, z. B. blauer und gelber Kreis).

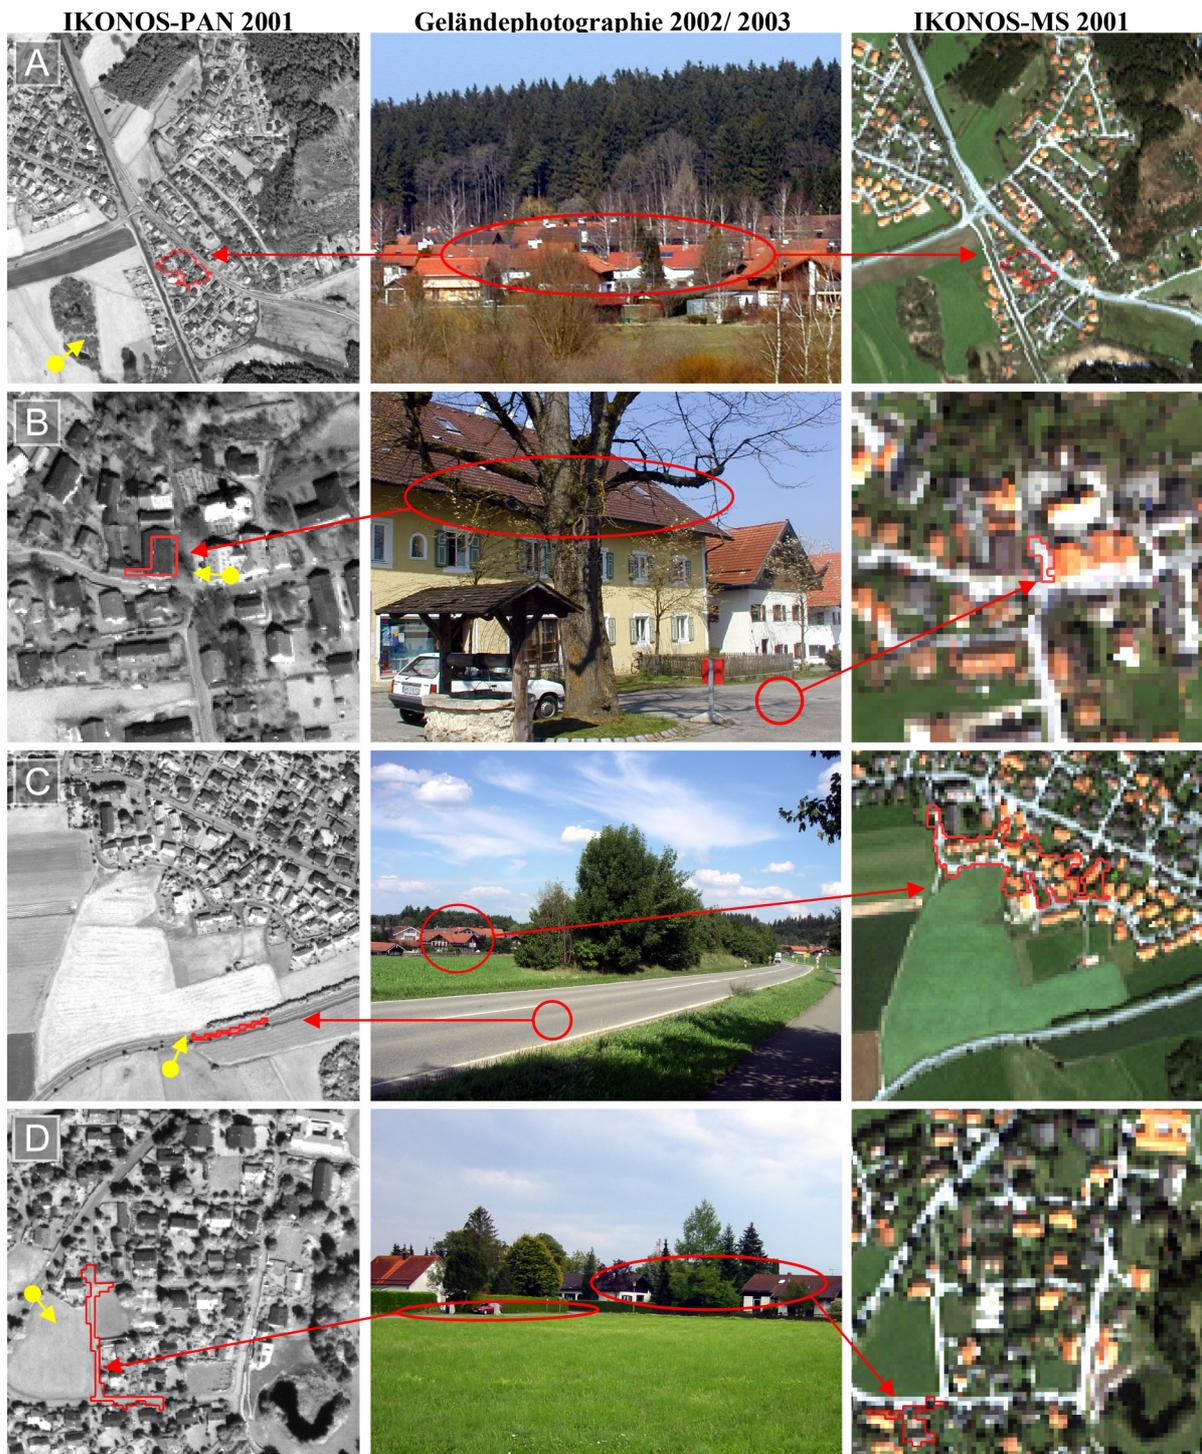
#### **6.1.4.2 Detaillierte Klassenbeschreibung: „Siedlung, Verkehr, Freizeit und Erholung (9000)“**

*„Die Kartiereinheit 9000 umfaßt Flächen, die von baulichen Anlagen und Verkehrseinrichtungen mehr oder minder stark geprägt sind. Hinzu treten Flächen, die von Freizeit- und Erholungseinrichtungen geprägt sind“* (BFN 2002).

Die Landnutzungsklasse „Siedlung, Verkehr, Freizeit und Erholung (9000)“ setzt sich aus verschiedenen Landbedeckungstypen zusammen. Die Reflexionssignale dieser Klasse stammen z. B. von versiegelten Flächen, Hausdächern, Grünflächen und Bäumen. Versiegelte Flächen treten in Form von Straßen, Parkplätzen oder Gewerbeflächen auf. Hausdächer können Flachdächer oder beziegelte Schrägdächer besitzen. Zu den Grünflächen werden beispielsweise Gartenwiesen, öffentliche Grünanlagen oder Sportplätze gerechnet. Bäume kommen als Allee- oder Gartenbäume vor.

Während sich manche der genannten Elemente spektral nicht unterscheiden, wie Gartenwiesen und öffentliche Grünanlagen, sind ein Teil der Landbedeckungen durch sehr unterschiedliche Reflexions-signaturen charakterisiert. So können Dachziegel z. B. rot oder braun gefärbt und durch das Schrägdach bedingt, beschattet oder von der Sonne angestrahlt sein. Ein Flachdach wiederum zeigt, verursacht durch seinen Schutzanstrich, eine völlig andere Reflexion. Auch die Teerdecke versiegelter Flächen kann abhängig vom Alter oder der Nutzungsintensität des Belags unterschiedliche Reflexions-eigenschaften aufweisen. Um die vielfältigen Formen und komplexen Wechselbeziehungen der Klasse „Siedlung, Verkehr, Freizeit und Erholung (9000)“ zu erfassen, wurde im Rahmen dieser Arbeit eine **iterative Klassifikationsstrategie** entwickelt.

In der folgenden Abbildung 40 sind exemplarisch einige Geländeaufnahmen und die entsprechenden Objektkonturen in den IKONOS-Daten abgebildet. Aus den Photographien wird die hohe Komplexität dieser Landnutzungs-klasse deutlich.



**Abb. 41:** Gegenüberstellung von Geländeaufnahmen (April/August 2002/2003) und den entsprechenden Bildobjekten in IKONOS-PAN-Daten (links) und multispektralen IKONOS-Daten (rechts) vom 24.04.2001 (A, B) und vom 12.08.2001 (C, D). Siedlung in Eurach (A), Vitusplatz in Iffeldorf (B), Straße und Siedlung in Iffeldorf (C), Straße und Siedlung in Seeshaupt (D). Die roten Pfeile und Konturen markieren die Objekte, der gelbe Pfeil zeigt jeweils die Blickrichtung der Geländeaufnahme.

### **Aufbau und Zusammensetzung der Klasse „Siedlung, Verkehr, Freizeit (9000)“**

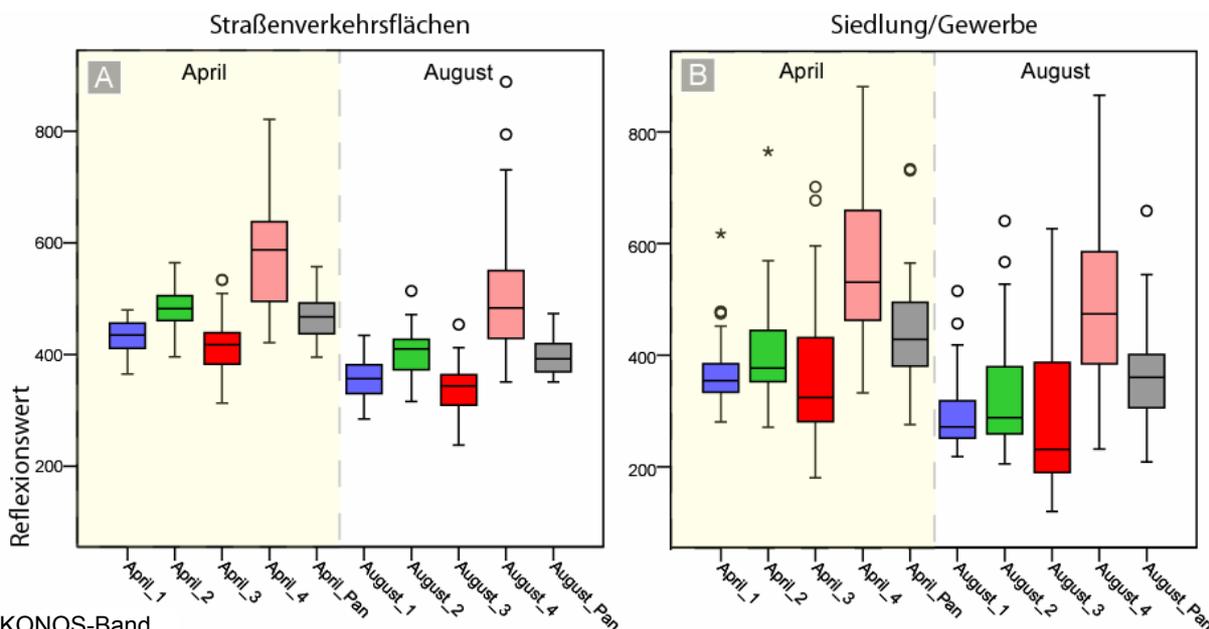
Wie eingangs erwähnt, weisen verschiedene Elemente der Klasse unterschiedliche Reflexionseigenschaften auf. Bedingt durch Schattenwurf und abweichende Beleuchtungswinkel können identische Oberflächenmaterialien verschiedenartige Reflexionsantworten hervorrufen. Komplex aufgebaute Landnutzungsklassen lassen sich daher eher durch die Zusammensetzung ihrer Elemente

beschreiben als durch ihre gemittelte Reflexion. Die Reflexionsantwort dieser Klasse wird in der Hauptsache von drei Faktoren geprägt: der Reflexion vegetationsfreier Flächen, der Reflexion von Grünflächen und Bäumen sowie von der außerordentlich hohen Variationsbreite der Reflexion der verschiedenen Elemente im Siedlungsbereich.

Die Klasse „Siedlung, Verkehr, Freizeit (9000)“ setzte sich aus „Siedlung/ Gewerbe (9100)“ und „Verkehrsflächen (9200)“ zusammen. Diese beiden Unterklassen wurden separat untersucht und in Regelwerken modelliert. Die Klasse „Freizeit-, Erholungs-, und Grünflächen (9300)“ konnte aufgrund mangelnder Unterscheidungskriterien nicht detektiert werden. Diese Flächen wurden bei der Klassifikation in die Klasse „Siedlung/ Gewerbe (9100)“ integriert. Die Abgrenzung der Siedlungs- und Straßenklasse zu anderen Landbedeckungen erfolgte durch eine Kombination aus NDVI, Spektral- und Textureigenschaften sowie topologischen Beziehungen. Topologische Beziehungen bildeten die Grundlage der in dieser Arbeit entwickelten iterativen Klassifikationsstrategie. Die genaue Vorgehensweise wird im Abschnitt „Iterative Klassifikationsstrategie zur Detektion von „Siedlung, Verkehr, Freizeit (9000)“ ausführlich erklärt. Im folgenden werden typische Spektral-, Textur- und Objekteigenschaften für Straßenverkehrs- und Siedlungsflächen kurz beleuchtet.

### Spektraleigenschaften von Straßenverkehrsflächen und Siedlungsflächen

Die Boxplotanalysen beschränkten sich auf Referenzobjekte von Straßenverkehrsflächen (35 Referenzobjekte) und Siedlungsflächen (64 Referenzobjekte). Die Referenzobjekte der Straßenverkehrsflächen setzten sich ausschließlich aus Asphaltstraßen zusammen. Verkehrsbegleitgrün und straßenbegleitende Bäume wurden bei der Analyse nicht berücksichtigt. In Abbildung 41 sind die Häufigkeitsverteilungen in den Spektralbändern als Boxplots dargestellt.



IKONOS-Band

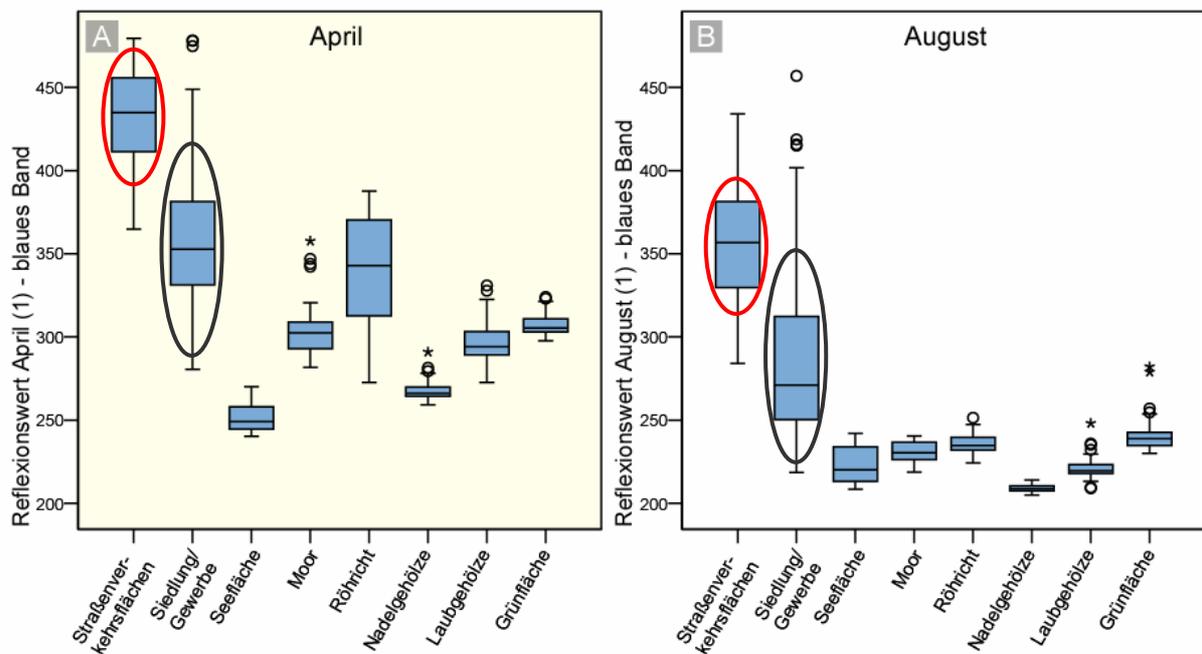
**Abb. 42:** Boxplotdarstellung der Spektraleigenschaften von Straßenverkehrsflächen (A) und Siedlungs- und Gewerbeflächen (B).

Bei Straßenverkehrsflächen war an beiden Aufnahme-Zeitpunkten ein vergleichbares Signal zu erwarten, da diese Klasse nicht von der Vegetationsperiode beeinflusst wird. Ebenso wie bei den Gehölzen, waren die Reflexionsantworten im August schwächer als im April (Abb. 41 (A)). Dies hängt mit der unterschiedlichen Blickrichtung des Sensors zusammen. Was allerdings festzuhalten bleibt, ist

die Tatsache, daß sich die Bandbreiten der Spektraleigenschaften von April zum August kaum veränderten.

Die Klasse „Siedlung/Gewerbe“ hingegen zeigte über die Zeit Veränderungen in ihrem Reflexionsverhalten (Abb. 41 (B)). Neben der allgemeinen Abschwächung veränderte sich vor allem die Reflexion im roten Band und dem nahen Infrarot. Die Länge der Whisker und die Größe der Box nahmen bei diesen Bändern im August zu. Das bedeutet, daß die Variabilität der Bildobjekte anstieg. Dies läßt sich mit der gestiegenen Vitalität des Vegetationsanteils dieser Klasse erklären.

Der Vergleich der Boxplots ergab, daß eine Differenzierung der beiden Klassen ausschließlich anhand der Spektralinformationen der beiden Aufnahme-Zeitpunkte nicht möglich war: in jedem der vier Bänder traten überschneidende Spektraleigenschaften auf. Der blaue Kanal, der vor allem bei Straßenverkehrsflächen hohe Werte aufwies, zeigte die geringsten Überschneidungsbereiche. Dies galt sowohl zwischen den beiden Klassen als auch zu anderen Landbedeckungen (Abb. 42). Der Experte weiß, daß versiegelte Flächen im blauen Bereich des Spektrums hohe Reflexionswerte aufweisen. Diese Eigenschaft wurde zur Differenzierung zu anderen Landbedeckungsklassen verwendet und ist in Abbildung 42 dargestellt.

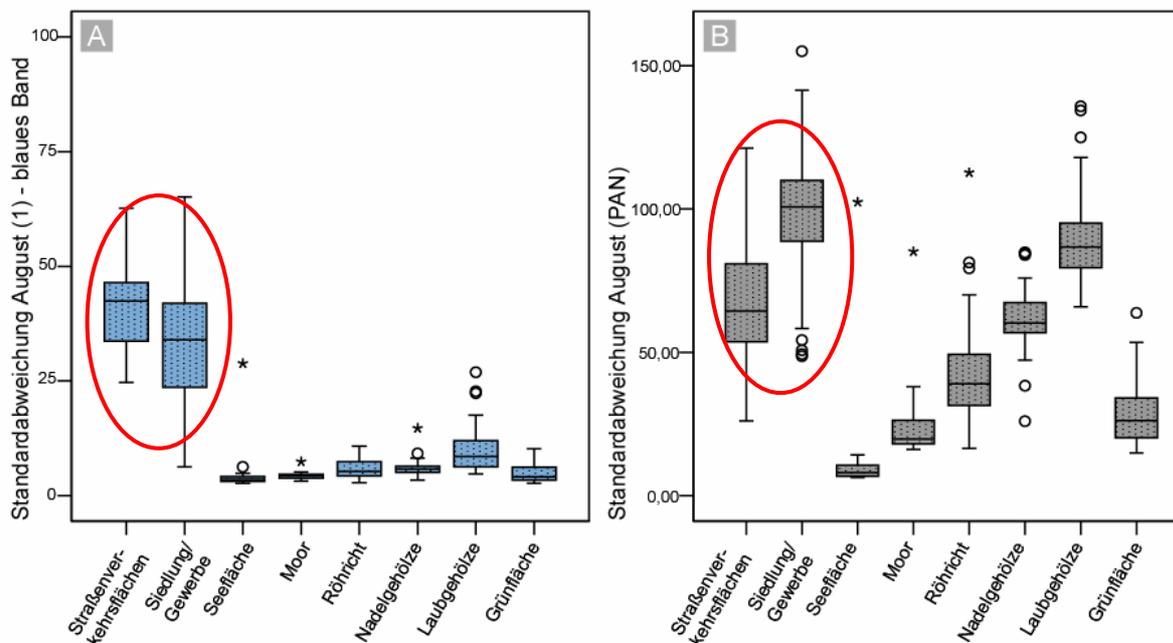


**Abb. 43:** Boxplotdarstellung der Reflexionswerte im blauen Band für ausgewählte Klassen. Die Spektralwerte für Straßen und Siedlung (rote Ellipse) sind sowohl in der April-Aufnahme (A) als auch in der August-Aufnahme (B) isoliert. Die Siedlungs- und Gewerbeflächen (schwarze Ellipse) sind wesentlich weiter gestreut und überschneiden sich deutlicher mit anderen Landbedeckungsklassen.

Aus der Boxplotanalyse wurde anschaulich, daß insbesondere Straßenverkehrsflächen durch sehr hohe Reflexionswerte im blauen Band repräsentiert waren (Abb. 42 (rote Ellipse)). Die Siedlungs- und Gewerbeflächen wiesen sowohl im April als auch im August Überschneidungen zu anderen Klassen auf (Abb. 42 (schwarze Ellipse)). Im April waren die Überschneidungen besonders offensichtlich, was unterstreicht, daß dieses Merkmal allein nicht ausreichte, um die Siedlungsklassen treffsicher von anderen Klassen zu differenzieren.

## Textureigenschaften von Straßenverkehrsflächen und Siedlungsflächen

Da die Abgrenzung von Siedlungs- und Gewerbeflächen mit Hilfe spektraler Informationen - trotz umfangreicher Forschung der letzten Jahre - nicht befriedigend gelang, waren andere Entscheidungshilfen heranzuziehen. Sehr gut eignete sich hierfür die Textureigenschaft „Standardabweichung pro Bildobjekt“, wie Abbildung 43 belegt.

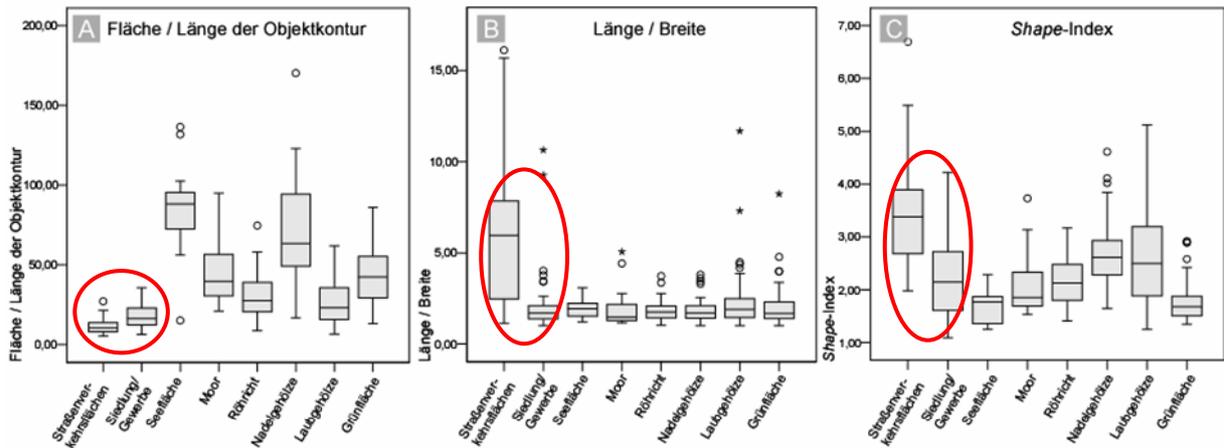


**Abb. 44:** Boxplotdarstellung der Textureigenschaft „Standardabweichung pro Objekt“ für Werte des blauen Bandes (A, August-Aufnahme) und des PAN-Kanals (B, August-Aufnahme) für ausgewählte Klassen. Während die Straßen und Siedlungsflächen (rote Ellipse) bei der Standardabweichung im blauen Band (A) eine weitgehend isolierte Verteilung aufweisen, gibt es bei der Standardabweichung des PAN-Kanals (B) deutliche Überschneidungen mit anderen Klassen.

Es wiesen nämlich im blauen Band einzig Straßenverkehrs- und Siedlungsflächen hohe Standardabweichungen auf (Abb. 43 (A)), wohingegen im PAN-Kanal auch bei anderen Klassen hohe Standardabweichungen auftraten (Abb. 43 (B)). Auffällig war hier, daß die spektrale Varianz der Siedlungs- und Gewerbeflächen im höher aufgelösten PAN-Kanal deutlicher hervortrat als im blauen Band (Abb. 43 (B)).

## Objekteigenschaften von Straßenverkehrsflächen und Siedlungsflächen

Straßenverkehrskörper werden von einem Interpreten aufgrund der typisch länglichen Formen und des Vernetzungscharakters sofort erkannt. Siedlungsgebiete sind eher unregelmäßig geformt und gehorchen keiner Regel. Auch Hausgärten, Bäume oder öffentliche Grünflächen sind bei Siedlungsflächen kleinräumig verteilt. Außerdem stellt sich die Frage, wie gut der verwendete Segmentierungsalgorithmus die Formen der Straßenkörper und Siedlungsflächen abbildet, und welche Formattribute in diesem Zusammenhang aussagekräftig sind. In Abbildung 44 sind Boxplots von Formattributen für ausgewählte Klassen im Vergleich zueinander dargestellt.

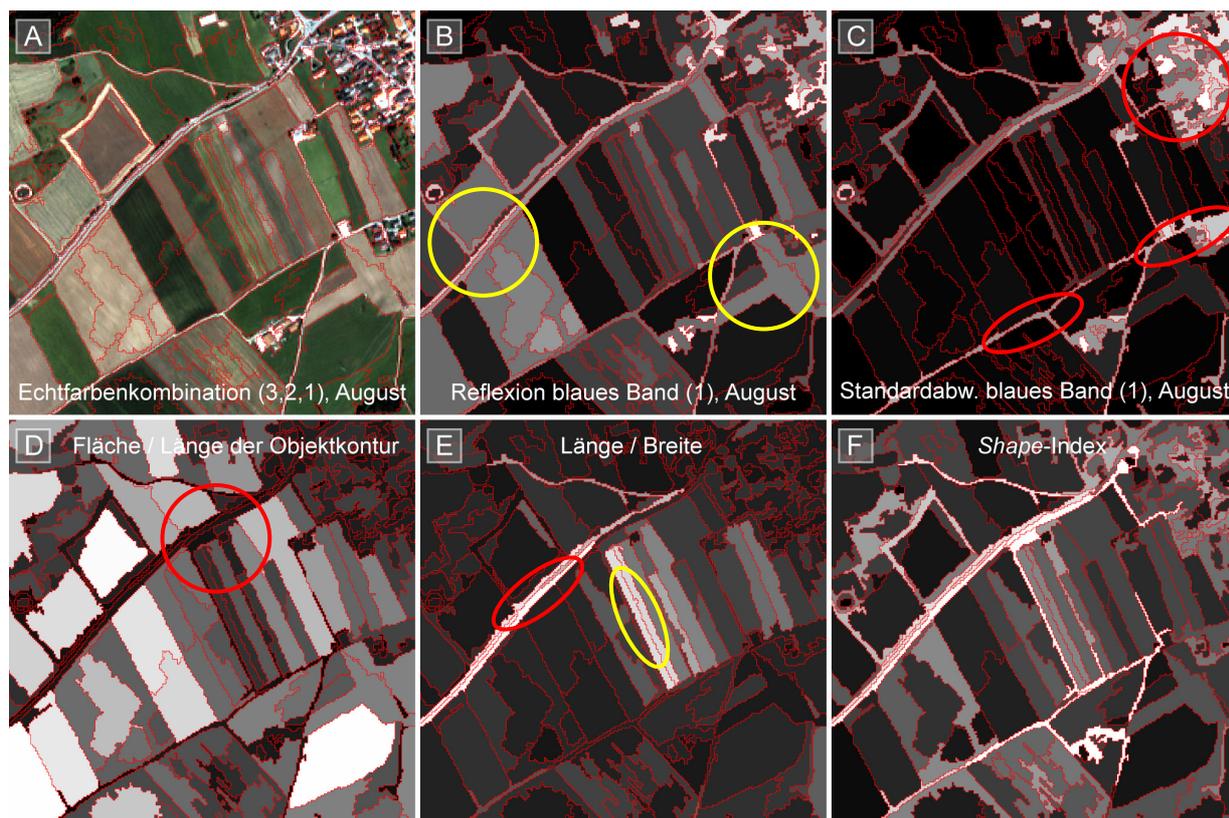


**Abb. 45:** Formattribute. Die Referenzobjekte für Straßen und Siedlungen (rote Ellipse) liegen bei dem Formattribut „Fläche / Länge der Objektkontur“ relativ isoliert im unteren Bereich der Beobachtungen (A). Bei „Länge / Breite“ stechen insbesondere Straßenverkehrsflächen mit einer breiten Verteilung und hohen Werten hervor (B). Der *Shape-Index* (C) indes ist wenig aussagekräftig. Hier gibt es breite Überschneidungen zu allen übrigen Klassen.

Das Formattribut „Fläche / Länge der Objektkontur“ zeigte bei den Straßenverkehrs- und Siedlungs-/Gewerbeflächen deutlich kleinere Werte als die anderen Klassen, wenngleich es auch hier Überschneidungen gab (Abb. 44 (A)). Im Prinzip gibt dieses Attribut Auskunft wie „dünn“ ein Bildobjekt ist. Während „Länge / Breite“ nur bei gradlinigen Straßenobjekten aussagekräftig ist (Abb. 44 (B)), greift „Fläche / Länge der Objektkontur“ auch bei Objekten die unregelmäßig geformt sind (z. B. bei Kreuzungen oder Kurven). Bei „Länge / Breite“ fielen in erster Linie die hohen Werte der Straßenverkehrsflächen auf, obschon Überschneidungen zu anderen Klassen existierten. Der *Shape-Index*<sup>1</sup> hatte hier wenig Aussagekraft (Abb. 44 (C)), denn die Häufigkeitsverteilungen des *Shape-Indexes* überschneiden sich vielfach (wenngleich die Werte bei Straßenverkehrsflächen tendenziell höher als die der anderen Klassen waren).

Einen Überblick über einen Teil der analysierten Objektattribute gibt die Abbildung 45. Die Erkenntnisse aus der Boxplotanalyse werden hier beispielhaft für ein kleines Testgebiet visualisiert, wobei die Objektattribute flächig pro Bildobjekt dargestellt sind.

<sup>1</sup> Der *Shape-Index* beschreibt Verhältnis von Umfang zu Fläche im Vergleich zu einem Kreis gleicher Fläche. Er ist ein Maß der Flächenkomplexität und gibt Auskunft über die fraktale Dimension eines Objektes. Je höher der Wert, desto länger ist die Grenzlinie und desto komplexer ist das Bildobjekt.



**Abb. 46:** Übersicht zu Objektattributen von Straßen- und Siedlungsflächen. Je heller der Grauwert, um so höher ist der Objektwert. IKONOS-Bild (A). Spektraleigenschaft „Blaues Band“ (B), ähnliche Werte haben zum Teil Äcker (gelb umrandet). Textureigenschaft „Standardabweichung blaues Band (C), hohe Werte für Straßen- und Siedlungsflächen (rot umrandet). Formeigenschaft „Fläche/ Länge d. Objektkontur“ (D), niedrige Werte für Straßen- und Siedlungsflächen (rot umrandet). Formeigenschaft „Länge/ Breite“ (E), hohe Werte für Straßen (rote Ellipse), aber auch für längliche Ackerstrukturen (gelb umrandet). Formeigenschaft *Shape-Index* (F), keine Zuordnung zu einem bestimmten Landbedeckungstyp möglich.

Aus den Boxplotanalysen und aus der Abbildung 45 war ersichtlich, daß keine der Spektral-, Textur-, und Formeigenschaften für sich genommen eine absolute Abgrenzung zu anderen Klassen erlaubte. Aber es zeigte sich auch, daß es genügend Objekteigenschaften gab, in welchen die Klassen Wertebereiche mit nur geringen Überschneidungen zu anderen Klassen aufwiesen. Wurden diese Eigenschaften über *UND*-Operatoren in einem Regelwerk verknüpft, so wurde die Beschreibung immer genauer und der Suchraum immer mehr eingeschränkt. Weist also ein Bildobjekt bestimmte Spektraleigenschaften auf (z. B. hohe Reflexion im blauen Band) *UND* bestimmte Textureigenschaften (z. B. hohe Standardabweichung im blauen Band) *UND / ODER* eine bestimmte Form auf (z. B. Bildobjekt ist eher länglich), so ist die Schlußfolgerung auf Zugehörigkeit zu einer Klasse zutreffend (z. B. Bildobjekt ist eine Straße). Der Aufbau eines Regelwerks ist demnach ein Zusammenlegen von Indizien, die miteinander verknüpft eine Schnittmenge aus verschiedenen Bedingungen bilden.

Im folgenden werden die einzelnen Schritte, die zur Identifikation der Klasse „Siedlung, Verkehr, Freizeit (9000)“ führen, beschrieben. Anhand dieser Klasse wird das „iterative Herantasten“ an eine Zielklassifikation dargestellt.

## Iterative Klassifikationsstrategie zur Detektion von „Siedlung, Verkehr, Freizeit (9000)“

Die **iterative<sup>1</sup> Vorgehensweise** erlaubte es schrittweise, Geoinformation aufzubauen. Es wurde mit Rückkopplung iteriert, d.h. die Klassifikationsergebnisse eines Schritts dienten als Informationsgrundlage für den jeweils nächsten Schritt. Iterationen wurden solange durchgeführt bis das Ergebnis befriedigend war oder sich durch weitere Iterationen nicht mehr veränderte. Klassifikationsdurchlauf und Iteration werden im Rahmen dieser Arbeit analog verwendet.

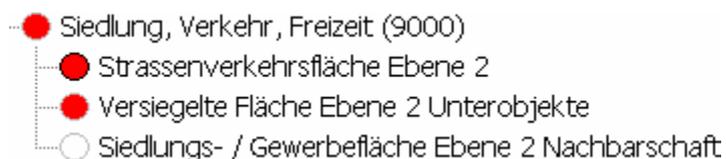
### 1. Klassifikationsdurchlauf: „Versiegelte Flächen Ebene 1“

Im **ersten Klassifikationsdurchlauf** wurden auf der Objektskalenebene 1 mit den kleinsten Bildobjekten versiegelte Flächen detektiert. Im Regelwerk wurde diese Klasse als „Versiegelte Flächen Ebene 1“ bezeichnet. Sie war eine reine „Hilfsklasse“ und stellte ein Informationselement der Zielklasse „Siedlung, Verkehr, Freizeit und Erholung (9000)“ auf Ebene 2 dar. Es galt die Annahme, daß Siedlungsbereiche einen gewissen Anteil an versiegelter Fläche aufweisen. Durch kleine Bildobjektgrößen traten in dieser Objektskalenebene wenig Mischsignaturen auf, so daß versiegelte Elemente anhand ihrer niedrigen NDVI-Werte und einer hohen Reflexion im blauen Band detektiert werden konnten. Die gefundenen Flächen lagen innerhalb von Siedlungsbereichen und Straßenzügen. Auf Ebene 1 wurden nur „sichere“ Bildobjekte klassifiziert, denn ein Fehler auf Ebene 1 hätte zu einem großflächigeren Fehler auf Ebene 2 führen können.

### 2. Klassifikationsdurchlauf und weitere Iterationen: „Siedlung, Verkehr, Freizeit (9000)“

*„Die Kartiereinheit 9000 umfaßt Flächen, die von baulichen Anlagen und Verkehrseinrichtungen mehr oder minder stark geprägt sind. Hinzu treten Flächen, die von Freizeit- und Erholungseinrichtungen bestimmt sind“* (BFN 2002).

Die folgenden Schritte wurden auf Objektskalenebene 2 durchgeführt. Erst hier wurde die eigentliche Zielklasse „Siedlung, Verkehr, Freizeit (9000)“ detektiert. Diese Klasse setzte sich aus drei Unterklassen zusammen (Abb. 46), welche die vielseitigen Aspekte und topologischen Beziehungen dieser Landnutzungsklasse beschrieben.



**Abb. 47:** Klassenhierarchie der Klasse „Siedlung, Verkehr, Freizeit (9000)“. Die Klassenhierarchie entspricht auch der Gruppenshierarchie.

Die Vaterklasse „Siedlung, Verkehr, Freizeit (9000)“ war eine rein thematische Klasse, die keine Zugehörigkeitsfunktionen enthielt. In dieser Klasse wurden die Definitionen der drei Unterklassen gruppiert. Die Unterklassen beschrieben folgende Elemente:

1. „**Straßenverkehrsfläche Ebene 2**“: klassifiziert längliche Straßenelemente.
2. „**Versiegelte Flächen Ebene 2 Unterobjekte**“: nutzt die Information der Unterobjekte von Ebene 1 („Versiegelte Fläche Ebene 1“) und verknüpft diese mit weiteren Bedingungen.
3. „**Siedlungs- / Gewerbefläche Ebene 2 Nachbarschaft**“: prüft benachbarte Bildobjekte. Vaterklasse zur „Siedlung, Verkehr, Freizeit (9000)“ nach Spektral-, Textur-, und Formeigenschaften. „Passende“ Bildobjekte werden integriert. Des weiteren werden abhängig von ihrer Größe, um-

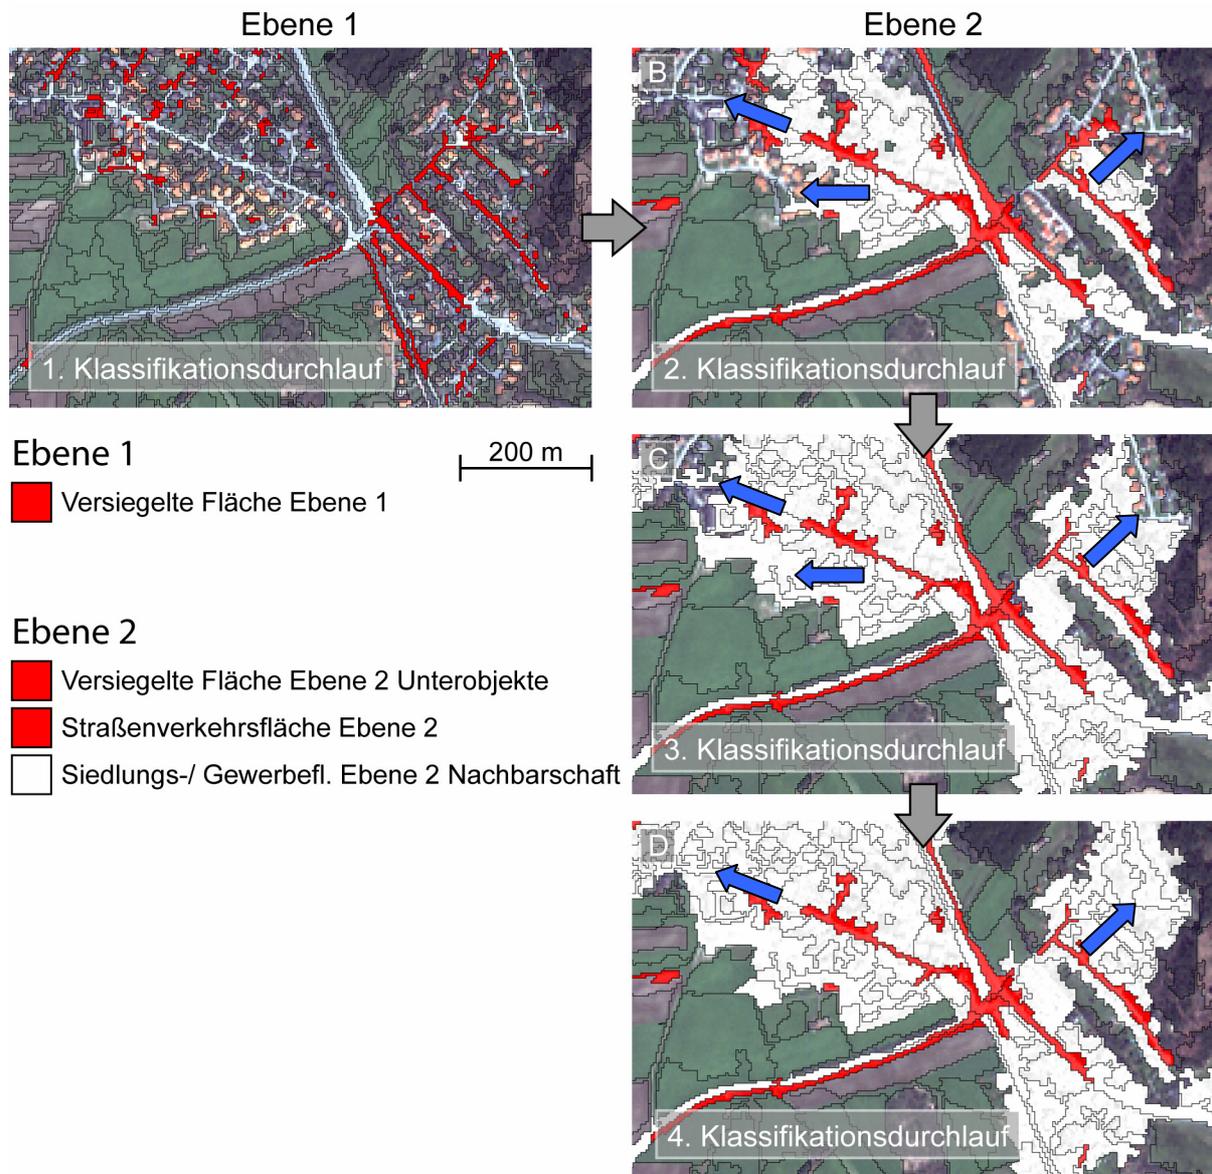
<sup>1</sup> Der Begriff *iterativ* kommt aus dem Lateinischen (*iterare* - wiederholen) und beschreibt in Zusammenhang mit der objektorientierten Klassifikation das stufenweise, aber gerichtete Annähern an die Zielklassifikation.

schlossene Grünflächen und Gehölze dieser Klasse zugewiesen. Diese Klasse „wächst“ mit jeder Iteration.

Schon beim Aufbau des Regelwerks wurde erkennbar, daß sich Verkehrsflächen (Straßen und Schienen) nicht von Siedlungs- und Gewerbeflächen trennen ließen. Die Ähnlichkeit der beiden Klassen zueinander war zu groß.

Der **zweite Klassifikationsdurchlauf** der iterativen Vorgehensweise hatte zum Ziel, die Grundelemente der Klasse „Siedlung, Verkehr, Freizeit (9000)“ auf Ebene 2 zu detektieren. Diese Grundelemente wurden durch die Klassenregelwerke von „Straßenverkehrsfläche Ebene 2“ und „Versiegelte Flächen Ebene 2 Unterobjekte“ beschrieben. „Straßenverkehrsfläche Ebene 2“ beschrieb eindeutige Straßen anhand von Spektral- und Formeigenschaften, während „Versiegelte Flächen Ebene 2 Unterobjekte“ den Anteil an „Versiegelte Fläche“ in den Unterobjekten abfragte und Spektraleigenschaften prüfte. Die dabei klassifizierten Bildobjekte dienten dann bei **weiteren Iterationen** als **Initiationskeime**. An diesen Flächen „wuchs“ die Siedlungsklasse. Dieses Vorgehen ist unmittelbar mit dem Wahrnehmungsprozeß eines menschlichen Auswerters vergleichbar: ist einmal eine Straße oder ein Parkplatz erkannt, so wird die direkte Umgebung dieses Objekts beurteilt. Wohnflächen sind zu solchen Verkehrswegen benachbart. Dieses Wissen ließ sich über Nachbarschaftsbeziehungen implementieren. Wenn Spektral- und / oder Textureigenschaften benachbarter Bildobjekte (benachbart zu bereits gefundenen Vertretern der Klasse „Siedlung, Verkehr, Freizeit (9000)“) für Hausdächer, Gärten oder eine Straßenflächen sprachen, dann wurden diese benachbarten Objekte implementiert. Das Ablaufschema in Abbildung 47 gibt einen Überblick über die iterative Klassifikationsstrategie.

## Iterative Vorgehensweise bei der Klassifikation von „Siedlung, Verkehr, Freizeit (9000)“



**Abb. 48:** Iterativer Klassifikationsablauf. Auf Ebene 1 werden versiegelte Flächen detektiert (A), die auf Ebene 2 in nächsten Klassifikationsdurchlauf abgefragt werden (B). Die roten Flächen sind als Initiationskeime zu verstehen, an welchen die Siedlung „wächst“. Graduell wird das Siedlungsgebiet (weiß) bei jeder Iteration selektiv erweitert (C, D, z. B. blaue Pfeile).

Im Programm eCognition 3.0 war das iterative Klassifikationsvorgehen nicht korrekt gelöst. Während eines Klassifikationsdurchlaufs griff das Programm im selben Durchlauf auf bereits aktualisierte Klassenzugehörigkeiten zurück. Das hatte zur Folge, daß in einem Durchlauf mehr Objekte klassifiziert wurden, als durch das Regelwerk vorgegeben. In der Praxis spielte diese Eigenart keine Rolle, denn es wurden so viele Klassifikationsdurchläufe angesetzt, bis das Ergebnis stabil war. Nach der fünften Iteration änderte sich die Klassenausdehnung von „Siedlung, Verkehr, Freizeit (9000)“ nicht mehr. Die detaillierten Beschreibungen der ermittelten Klassenregelwerke (die zu einem „gesunden“ Wachstum führen) sind im folgenden dargestellt.

## „Versiegelte Fläche Ebene 1“, „Straßenverkehrsfläche Ebene 2“ und „Versiegelte Flächen Ebene 2 Unterobjekte“

Versiegelte Fläche Ebene 1						
Spektraleigenschaften			April		August	
	Min	Max		Min	Max	
Blau (1)	400	435	Blau (1)	292	295	
NDVI	0,3	0,31	NDVI	0,42	0,421	
Textureigenschaften			April		August	
Standardabweichung (1)	25	30	Standardabweichung (1)	30	35	
Objekteigenschaften						
Fläche / Form	Min	Max	Topologie	Bemerkung		
ODER			-	- Ebene 1		
Fläche/ Länge d. Objektkontur	2,57	2,58				
Länge/ Breite	4,85	4,86				

Abb. 49: Regelwerk der Klasse „Versiegelte Flächen Ebene 1“.

Straßenverkehrsfläche Ebene 2						
Spektraleigenschaften			April		August	
	Min	Max		Min	Max	
Blau (1)	339	340	Blau (1)	250	270	
Objekteigenschaften						
Fläche / Form	Min	Max	Topologie	Bemerkung		
Fläche	200	6000	-	- Ebene 2 - Vaterklasse: „Siedlung, Verkehr, Freizeit (9000)“		
ODER						
Fläche/ Länge d. Objektkontur	3,6	3,61				
Länge/ Breite	12	13,5				

Abb. 50: Regelwerk der Klasse „Straßenverkehrsfläche Ebene 2“. Nur „sichere“ Straßenverkehrsflächen werden erfaßt. Diese Klasse bildet einen Initiationskeim für das iterative Wachstum von „Siedlungs-/ Gewerbefläche Ebene 2 Nachbarschaft“. Die Zugehörigkeiten für Objekte auf Ebene 2 sind weiter gefaßt als auf Ebene 1, da aufgrund der größeren Objektfläche hier mehr Mischsignaturen auftreten.

Versiegelte Flächen Ebene 2 Unterobjekte						
Spektraleigenschaften			April		August	
	Min	Max		Min	Max	
Blau (1)	400	425	Blau (1)	220	235	
NIR (4)	450	460	NIR (4)	270	370	
			NDVI	0,385	0,42	
Objekteigenschaften						
Fläche / Form	Topologie			Bemerkung		
-	> 0,1 % Flächenanteil „Versiegelte Fläche Ebene 1“ in den Unterobjekten			- Ebene 2 - Vaterklasse: „Siedlung, Verkehr, Freizeit (9000)“		

Abb. 51: Regelwerk der Klasse „Versiegelte Flächen Ebene 2 Unterobjekte“. Durch Abfrage der Unterobjekte und Verknüpfung mit weiteren Bedingungen werden „sichere“ versiegelte Flächen auf Ebene 2 erfaßt. „Versiegelte Flächen Ebene 2 Unterobjekte“ bildet einen Initiationskeim für das iterative Wachstum von „Siedlungs-/ Gewerbefläche Ebene 2 Nachbarschaft“.

### „Siedlungs-/ Gewerbefläche Ebene 2 Nachbarschaft“

Allgemein galt die Bedingung für die Klasse „Siedlungs-/ Gewerbefläche Ebene 2 Nachbarschaft“, daß ein Bildobjekt eine gemeinsame Grenze von mindestens 22 % (der eigenen Objektkontur) mit der Vaterklasse „Siedlung, ... (9000)“ aufweisen mußte. Der Wert von 22 % wurde empirisch ermittelt und hat sich bei der verwendeten Segmentierung als zweckmäßig erwiesen. War diese Bedingung erfüllt,

konnten verschiedene andere Bedingungen zu einer Klassenzugehörigkeit führen. Aufgrund der Vielfältigkeit der Zusammensetzung von „Siedlungs-/ Gewerbefläche Ebene 2 Nachbarschaft“ wurden die Verknüpfungen über den *ODER*-Operator geschlossen:

1. Wenn es sich um eine Vegetationsfläche handelt, also der NDVI-Wert für Vegetation spricht und das Objekt zu mindestens 85 % mit der Vaterklasse „Siedlung, ... (9000)“ angrenzt. Dies trifft auf Bäume, Hausgärten und Grünflächen zu.
2. Wenn das Bildobjekt entweder im blauen (1) oder im roten Band (3) eine hohe Textur aufweist. Hierunter fallen Straßenflächen, verschiedenste Hausdachtypen und Bildobjekte, die mehr als einen Bedeckungstyp aufweisen.
3. Wenn die Fläche klein ist, also weniger als 1000 m<sup>2</sup> aufweist und das Bildobjekt zu mehr als 75 % von der Vaterklasse eingeschlossen ist. Dies bedeutet, daß kleine eingeschlossene Flächen in die Klasse integriert werden.

Die Abbildung 51 zeigt das entwickelte Regelwerk. Das Schema ist nach den obigen Punkten gegliedert

<b>Siedlungs-/ Gewerbefläche Ebene 2 Nachbarschaft</b>							
<b>Topologie</b>				<b>Bemerkung</b>			
generell muß diese Klasse > 22 % Nachbarschaft zu „Siedlung,...(9000)“ aufweisen				Ebene 2 Vaterklasse: „Siedlung, Verkehr, Freizeit (9000)“			
<b>1. Spektraleigenschaften</b>	<b>April</b>			<b>August</b>			
		Min	Max			Min	Max
NDVI		0,28	0,5	NDVI		0,28	0,7
verknüpft mit der Bedingung > 85 % Nachbarschaft zu „Siedlung,... (9000)“	<i>Vegetationsflächen, die fast gänzlich von Siedlungsflächen eingeschlossen sind werden implementiert</i>			verknüpft mit der Bedingung > 85 % Nachbarschaft zu „Siedlung,... (9000)“			
<b>2. Textureigenschaften</b>							
<i>ODER</i>				<i>ODER</i>			
Standardabweichung (1) 	35	42		Standardabweichung (1) 	30	35	
Standardabweichung (3) 	72,5	77,5		Standardabweichung (3) 	45	48	
<b>3. Objekteigenschaften</b>							
Fläche / Form							
Fläche < 1000m <sup>2</sup> verknüpft mit der Bedingung > 75 % Nachbarschaft zu „Siedlung,... (9000)“ <i>Kleine Flächen, die fast gänzlich von Siedlungsflächen eingeschlossen sind, werden integriert</i>							

Abb. 52: Regelwerk der Klasse „Siedlungs-/ Gewerbefläche Ebene 2 Nachbarschaft“.

### Zusammenfassung „Siedlung, Verkehr, Freizeit (9000)“

Wie dargestellt, wurden bei der Klassifikation von besiedelten Flächen unterschiedliche Möglichkeiten des objektorientierten Ansatzes genutzt:

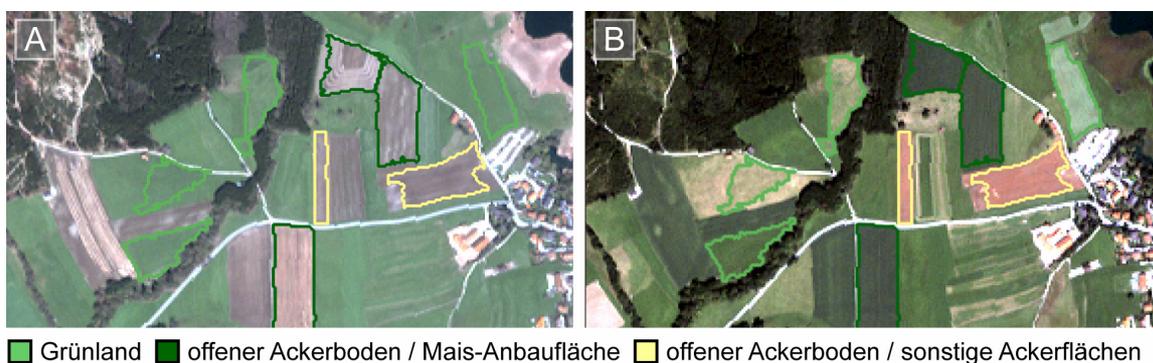
- Kombination von Spektral-, Textur und Formeigenschaften
- Klassifikation auf verschiedenen Skalenebenen
- Iterative Vorgehensweise durch Nutzung von topologischen Beziehungen

Ausgehend von einer initialen, „sicheren“ Klassifikation ließ sich die Ausdehnung der Klasse „Siedlung, Verkehr, Freizeit (9000)“ schrittweise aufbauen. Durch Kombination von topologischen Beziehungen und „herkömmlichen“ Objektattributen wurde direkt Einfluß darauf genommen, welche angrenzenden Bildobjekte hinzugefügt wurden: die Klasse wuchs „selektiv“. Das iterative Vorgehen bei der Klassifikation ist in dieser Form ein neuer Ansatz.

### 6.1.4.3 Detaillierte Klassenbeschreibung: „Flächen der Landwirtschaft (4000)“

„Flächen die dem Ackerbau, der Wiesen- und Weidewirtschaft, dem Erwerbgartenbau, dem Obstbau, den Baumschulen sowie dem Weinbau dienen“ (BfN 2002).

Die hier beschriebenen Flächen unterliegen regelmäßigem anthropogenem Einfluß, der z. T. innerhalb von sehr kurzer Zeit zu unterschiedlichen Spektralsignaturen führen kann (z. B. durch Herbizideinsatz, Mahd oder Ernte). Landwirtschaftliche Nutzflächen sind je nach Anbaufrucht und Jahreszeit starken Schwankungen in ihrem Erscheinungsbild unterworfen. Aus diesem Grund waren bei dieser Klasse multisaisonale Zusammenhänge von besonderem Interesse. Die Differenzierung landwirtschaftlicher Nutzflächen erfordert Kenntnisse über die Vielschichtigkeit und Variationsbreite von Agrarflächen. In Abbildung 52 sind drei für das Gebiet typische landwirtschaftliche Nutzungen jeweils in der April- und August-Aufnahme gezeigt.



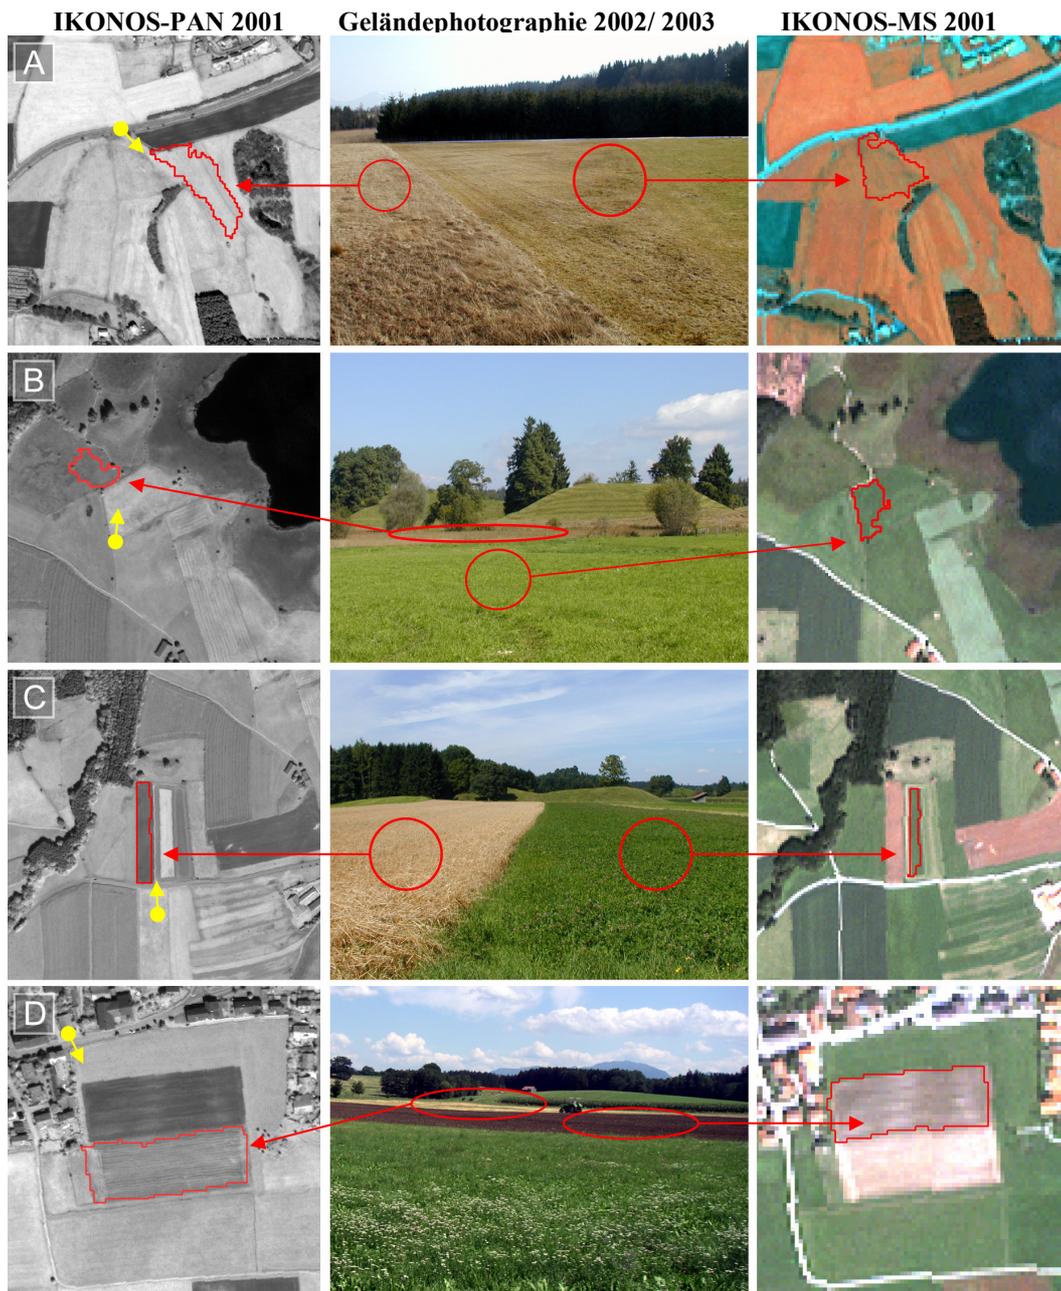
**Abb. 53:** Übersicht zu multisaisonalen Aspekten bei landwirtschaftlichen Nutzflächen. IKONOS-Aufnahme in Echtfarbenkombination vom April 2001 (A) und August 2001 (B). Die Umrandungen entsprechen den Objektkonturen auf Ebene 3. Mais-Anbauflächen (dunkelgrün) und sonstige offene Ackerböden (gelb) die in den August-Daten detektierbar sind, sind April sind im April vegetationsfreie, offene Ackerböden. Grünland (hellgrün) ist im April bereits vital. In der August-Aufnahme wird die hohe Variationsbreite der Klasse Grünland deutlich: unterschiedliche Trockenheitsgrade haben Auswirkung auf die Signatur.

Im Untersuchungsgebiet war ein großer Teil der Agrarflächen Wirtschaftsgrünland. **Grünland** entspricht in diesem Zusammenhang keinem Vegetations-, sondern einem Nutzungsbegriff für regelmäßig gemähte und / oder beweidete, überwiegend von Gräsern bewachsene Flächen. Die Reflexionsantwort von Grünland war sowohl im April als auch im August von hohen NDVI-Werten geprägt. Der Einfluß der Mahd, die Düngungsintensität und der Feuchtegrad des Bodens führten zu vielfältigen Erscheinungstypen. Unterschiedliche Grünlandklassen wurden im Rahmen dieser Arbeit nicht unterschieden. Abgesehen von einigen Streuwiesen, die kurz nach der Mahd aufgenommen wurden, waren die IKONOS-Aufnahmen für eine Differenzierung zu unselektiv: Magergrünland (z. B. mit Textur - hervorgerufen durch lockere Grasvegetation), Feuchtwiesen (z. B. mit NIR-Signal - hervorgerufen durch Bodenfeuchte) oder Weideland (z. B. mit Textur - hervorgerufen durch Beweidungsspuren) ließen sich nicht trennen. Auch sehr ausgedehnte Grünflächen, die der Erholungsnutzung dienen und außerhalb von Siedlungsgebieten liegen wie Golfanlagen oder parkähnliche Gärten konnten mangels Unterscheidungskriterien nicht differenziert werden. Auf einem Teil der Ackerflächen im Untersuchungsgebiet wurde **Mais** kultiviert. Das satte Grün dieser Flächen wies im August hohe NDVI-Werte auf. Bei der Anbaufrucht Mais waren die multisaisonalen Zusammenhänge sehr ausgeprägt, denn Maisfelder waren im April durchgehend gepflügt. **Getreidefelder** konnten nicht detektiert werden. Sie waren im August bereits abgeerntet. Auch Hackfrüchte ließen sich nicht finden. Felder, bei welchen das Spektralsignal des Bodens dominiert, wurden der Klasse „**Offener Ackerboden / sonstige**

„Ackerflächen“ zugewiesen. Die Klasse „Mais-Anbaufläche“ und die Klasse „Offener Ackerboden / sonstige Ackerflächen“ bildeten zusammen die Klasse „Ackerland (4100)“.

Die Klassifikation der landwirtschaftlichen Nutzflächen wurde auf der Objektskalenebene 3 durchgeführt. Hier zeigten Bildobjekte am eindeutigsten die typischen Formausprägungen. Ackerflächen waren meist annähernd rechteckig und regelmäßig geformt. Spuren der Bewirtschaftung, wie Pflugspuren oder gemähte Grasreihen wurden von Bildobjekten auf Ebene 3 nicht abgebildet.

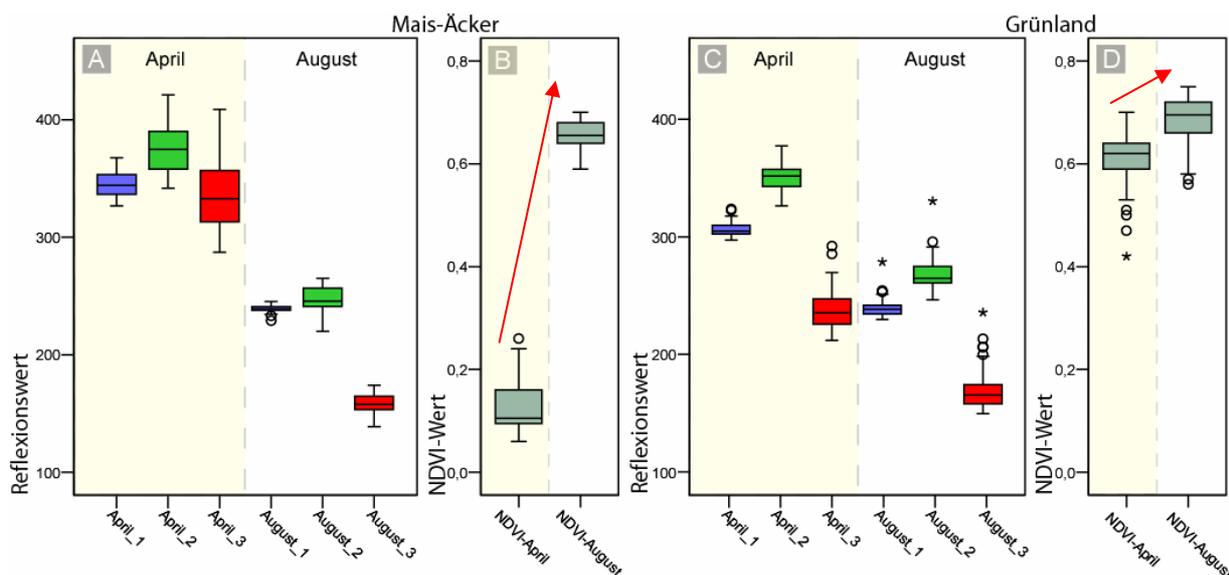
In den folgenden Abbildung 53 werden Grünlandflächen und ackerbaulich genutzte Flächen in der Geländephotographie und den IKONOS-Daten dargestellt.



**Abb. 54:** Grünland und Ackerland. Gegenüberstellung von Geländeaufnahmen (April/ August 2002/ 2003) und den entsprechenden Bildobjekten in IKONOS-PAN-Daten (links) und multispektralen IKONOS-Daten (rechts) vom 24.04.2001 (A) und vom 12.08.2001 (B, C, D). Grünland südl. von Iffeldorf (A), Feuchtgrünland im Naturschutzgebiet Osterseen (B), abgeerntetes Feld und Futterwiese südl. von Gut Schwaig (C), abgeerntetes Feld /gepflügter Acker südl. von Iffeldorf (D). Die roten Pfeile und Konturen markieren die Objekte, der gelbe Pfeil zeigt jeweils die Blickrichtung der Geländeaufnahme.

## Spektraleigenschaften von Mais-Anbaufläche und Grünland

Nachstehend sollen die spezifischen Spektraleigenschaften von Grünland (57 Referenzobjekte) und Mais-Anbauflächen (26 Referenzobjekte) dargestellt werden. Andere Feldfrüchte wie Getreide oder Raps wurden nicht näher analysiert, da sich diese mit den vorhandenen IKONOS-Aufnahmen (bedingt durch die Aufnahmezeitpunkte) nicht detektieren ließen. Wie eingangs erwähnt, ist bei Agrarflächen die Entwicklung und Veränderung der Reflexionseigenschaften über die Vegetationsperiode von besonderem Interesse. Dies wird durch die Boxplots der Spektraleigenschaften beider Aufnahmezeitpunkte in Abbildung 54 wiedergegeben. Es sind nur die Bänder des sichtbaren Spektrums abgebildet, da die Information des nahen Infrarot Bandes in dem ebenfalls dargestellten Vegetationsindex NDVI integriert ist.



**Abb. 55:** Boxplotdarstellung der Spektraleigenschaften im sichtbaren Spektrum und des Vegetationsindex NDVI für Mais-Anbauflächen (A, B) und Grünland (C, D). Während die NDVI-Werte bei Mais-Anbauflächen im Lauf der Vegetationsperiode sprunghaft ansteigen, zeigen Grünflächen eine eher mäßige Zunahme (B und D, roter Pfeil).

Mais-Anbauflächen wiesen im April noch keinen Bewuchs auf. Wirtschaftsgrünland hatte zu jenem Zeitpunkt bereits ausgetrieben. Sehr gut zu erkennen, war bei Mais-Anbauflächen die Veränderung der Signatur über die Zeit (Abb. 54 (A)). Es wandelte sich vor allen Dingen die Differenz vom grünen Band (2) zum roten Band (3). Auffällig war auch der Sprung im Vegetationsindex NDVI (Abb. 54 (B, roter Pfeil)). Grünland veränderte sein relatives Reflexionsverhalten kaum über die Vegetationsperiode (Abb. 54 (C)). Der schon beschriebene Abfall der Reflexion in der August-Aufnahme war auch hier zu beobachten (bei ähnlichem Status der Landbedeckung). Obschon Grünland im August variationsreicher erschien (bedingt durch Mahd, Düngung, etc.), schlug sich dies nicht im Reflexionsverhalten nieder. Weder Whisker noch Boxen waren im August größer als im April. Das bedeutet, daß sich die Abweichungen innerhalb des natürlichen Toleranzbereiches bewegten. Lediglich Ausreißer und Extremwerte traten vermehrt auf (Abb. 54 (C)). Die NDVI-Werte von Grünland waren im August etwas höher als im April (Abb. 54 (D)), was auf die höhere Biomasse im August zurückgeführt werden konnte. Der NDVI-Wert war nicht vom allgemeinen Abfall der Reflexion im August betroffen, da bei seiner Berechnung die Differenz und das Verhältnis zwischen NIR (4)- und rotem Band (3) zum Tragen kommen. Solche Indizes oder Verhältnisse zwischen den Bändern sind von der Instabilität des Sensorsignals weniger beeinflusst und eignen sich daher sehr gut, um eine Klasse zu beschreiben.

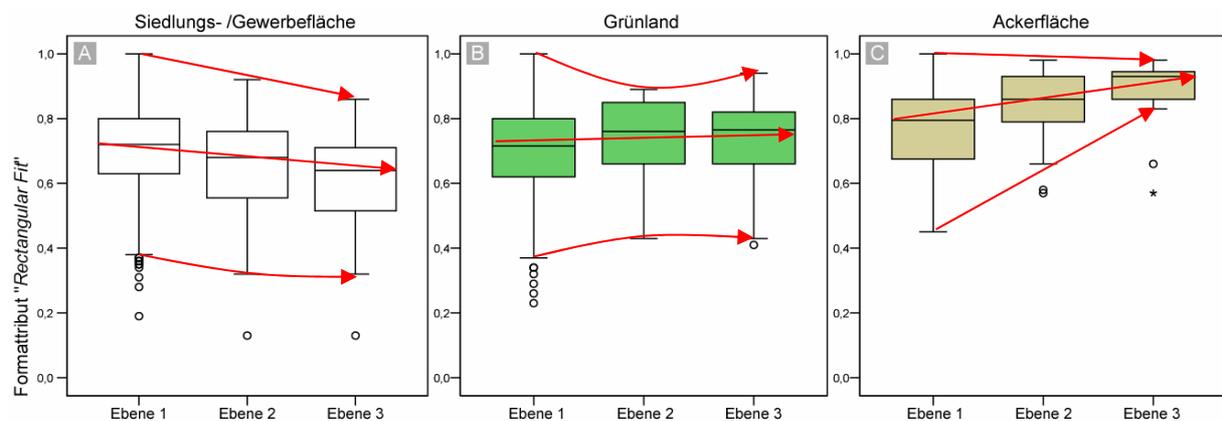
Sowohl bei Mais-Anbauflächen als auch bei Grünland waren die Erfahrungen mit dem Vegetationsindex NDVI von der Pixelebene auf Bildobjekte übertragbar.

Unterschieden sich Mais-Anbauflächen und Grünland in der April-Aufnahme naturgemäß sehr deutlich, so waren bei den Reflexionswerten im August Überschneidungen vorhanden. Zu diesem Zeitpunkt war das Spektralsignal allein für eine Unterscheidung dieser beiden landwirtschaftlichen Nutzflächen nicht ausreichend.

### Detailstudie Formeigenschaften

Bei der objektorientierten Analyse ist der Beobachtungsmaßstab durch die räumliche Ausprägung der Bildobjekte gegeben. Ein Klassifikationskriterium, das ausschließlich auf Objektebene zur Verfügung steht, ist die Form eines Bildobjektes. Allerdings besitzt die Form nur dann Aussagekraft, wenn sie die typischen Formausprägungen einer Landbedeckung auch korrekt wiedergibt. Auf verschiedenen Skalenebenen, die durch eine Segmentierung generiert wurden, unterschieden sich diese Ausprägungen.

Eine Untersuchung, welche Skalenebene sich für die Repräsentation einer Landnutzungs Klasse am besten eignet, lag nahe. Bereits bei der Wahl der Segmentierungs-Ebenen und -Parameter floß Wissen über das Auftreten bzw. Nicht-Auftreten einer Klasse bei einem bestimmten Maßstab ein. Am Beispiel von Ackerflächen, Grünland und Siedlungsgebieten wurden unterschiedliche Formausprägungen über drei Objektskalenebenen untersucht. Dabei sollte die Erfahrung überprüft werden, daß Äcker eher zu rechteckigen Formen tendieren, während Grünland und Siedlungsgebiete überwiegend unregelmäßig geformt sind. Ob sich dieses Wissen sinnvoll in den automatischen Auswerteprozess integrieren läßt, und wie sich Formattribute über die Objektskalenebenen verändern, wurde durch eine Boxplotanalyse geklärt. Untersucht wurde exemplarisch das Formattribut „*Rectangular Fit*“<sup>1</sup> (Abb. 55).



**Abb. 56:** Boxplotdarstellung des Formattributs *Rectangular Fit* über die Skalenebenen. Die Werte nehmen für Siedlungs- und Gewerbeflächen mit kleiner werdendem Maßstab ab (A). Bei Grünland ist kein eindeutiger Trend erkennbar (B), während Ackerflächen sich mit zunehmender Bildobjektgröße immer mehr durch eine rechteckige Form beschreiben lassen (C). Die roten Pfeile zeigen Tendenz der Werte über die Ebenen.

**Siedlungs- und Gewerbeflächen** zeigten einen abnehmenden Trend beim Formattribut *Rectangular Fit*. Das bedeutet, daß mit zunehmender Objektgröße Siedlungsgebiete immer unregelmäßiger in den Bildobjekten geformt waren (Abb. 55 (A)). Die Bandbreite der Werte war jedoch auf allen drei Ebenen groß. **Grünland** ließ über die Ebenen keinen Trend erkennen und war, wie Siedlungsflächen auch,

<sup>1</sup> Diese Objekteigenschaft gibt Auskunft darüber, in welchem Umfang ein Bildobjekt einem Rechteck gleicht. Der Wertebereich liegt zwischen 0 und 1, wobei sich ein Bildobjekt mit dem Wert 1 durch ein Rechteck optimal beschreiben läßt und ein Wert gegen 0 eine fraktale Form bedeutet.

relativ breit gestreut (Abb. 55 (B)). Vor allem Weideflächen und Grünland auf Grenzstandorten (absolutes Grünland) wiesen unregelmäßige Formen auf.

Bei **Ackerflächen** veränderte sich der Informationsgehalt des Formattributs über die Objektskalenebenen: der Wert nahm mit kleiner werdendem Beobachtungsmaßstab zu, während die Variationsbreite der Beobachtungen abnahm. Die Tendenz, daß Ackerobjekte eine rechteckige Form aufweisen, wird deutlich. In Abbildung 55 (C) ist klar erkennbar, daß die Breite der Verteilung über die Objektskalen abnimmt. Daraus ist zu folgern, daß das Formattribut über die Objektskalenebenen immer aussagekräftiger wird.

Gleichwohl kann die Form eines Bildobjektes nicht für sich allein stehen. Die Extremwerte außerhalb der Box bestätigen, daß ein Acker nicht einer geometrischen Form entsprechen muß, denn die klein strukturierten Besitzverhältnisse in Bayern bringen auch unregelmäßig geformte Ackerflächen mit sich. Dennoch zeigt die Boxplotanalyse zweifelsfrei, daß die Form bei Ackerflächen ein wertvolles Indiz ist. Dieser „Hinweis“ ist jedoch erst auf einer kleineren Objektskalenebene inhaltsreich.

### „Landwirtschaftliche Nutzflächen (4000)“

Landwirtschaftliche Nutzflächen wurden in der Klasse „Landwirtschaftliche Nutzflächen (4000)“ zusammengefaßt. Die Klassenhierarchie wird in Abbildung 56 gezeigt. „Landwirtschaftliche Nutzfläche (4000)“ war eine rein thematische Klasse ohne eigene Zugehörigkeitsfunktionen.

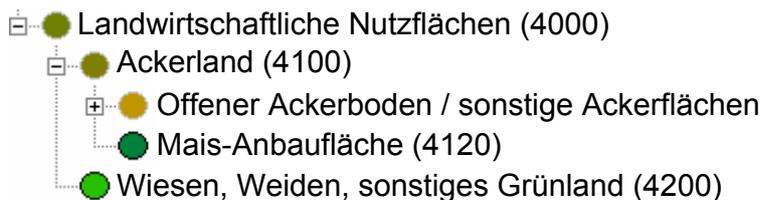


Abb. 57: Klassenhierarchie für landwirtschaftliche Nutzflächen.

## „Ackerland (4100)“

„Nutzflächen, an denen regelmäßig Bodenbearbeitung, Saat, Düngung, Pflege und Ernte von Kulturpflanzen vorgenommen wird, sodaß meist innerhalb eines Jahres der Neuaufbau der Vegetation und ihre Aberntung aufeinander folgen“ (BFN 2002).

Die Klasse „Ackerland (4100)“ hatte als Bedingung eine gewisse Mindestgröße *ODER* einen Mindestwert für die Formeigenschaft *Rectangular Fit* (Abb. 57). Das bedeutet, das Bildobjekt mußte entweder einem Rechteck gleichen oder relativ großflächig sein. Beides sind Indizien für eine Agrarfläche. Die Wertebereiche waren so weit gefaßt, daß sämtliches Ackerland darunter fiel.

Ackerland (4100)				
Objekteigenschaften				
Fläche / Form	Min	Max	Topologie	Bemerkung
<i>ODER</i>			-	- Ebene 3
Fläche 	5000 m <sup>2</sup>			
<i>Rectangular Fit</i> 	0,5			

Abb. 58: Regelwerk der Klasse „Ackerland (4100)“.

„Ackerland (4100)“ vererbte seine Bedingungen an zwei Sohnklassen: „Offener Ackerboden /sonstige Ackerflächen“ und „Mais-Anbaufläche (4120)“.

## „Offener Ackerboden / sonstige Ackerflächen“

Unter „Offener Ackerboden / sonstige Ackerflächen“ fielen im August sämtliche bereits abgeernteten oder schon gepflügten Felder. Mit den zur Verfügung stehenden IKONOS-Daten konnte die Feldfrucht nicht bestimmt werden. Im April stand die Klasse „Offener Ackerboden / sonstige Ackerflächen“ vor allem für gepflügte oder frisch eingesäte Äcker. Solche Bildobjekte wiesen zum Teil ähnliche Spektraleigenschaften wie versiegelte Flächen auf. Insbesondere bei Mischobjekten, die teilweise aus versiegelten Flächen bestanden und zum Teil mit Vegetation bedeckt waren, waren Verwechslungen mit dieser Klasse möglich. Um dies zu vermeiden, wurde die Textureigenschaft „Standardabweichung im PAN-Kanal“ zur Klassenbeschreibung hinzugenommen.

Offener Ackerboden / sonstige Ackerflächen									
Spektraleigenschaften		April			August				
		Min	Max	Min	Max				
Blau (1)		240	333	Blau (1)		252	382		
Grün (2)		226	391	Grün (2)		280	491		
Rot (3)		186	54	Rot (3)		224	549		
NIR (4)		272	720	NIR (4)		331	880		
NDVI		0,25	0,38	NDVI		0,4	0,45		
Textureigenschaften		April			August				
Standardabweichung (PAN)			35	48	Standardabweichung (PAN)			52	53
Objekteigenschaften									
Fläche / Form		Topologie		Bemerkung					
-		-		- Ebene 3 - erbt Zugehörigkeiten von „Ackerland (4100)“					

Abb. 59: Regelwerk der Klasse „Offener Ackerboden /sonstige Ackerflächen“.

## „Mais-Anbaufläche (4120)“

Mais-Anbauflächen konnten nur in der August-Aufnahme klassifiziert werden. Durch die eindeutige Spektralsignatur konnte diese Feldfrucht gut identifiziert werden. Ein satter Grünton, hohe NDVI-Werte und eine typische Flächenausprägung zeichneten diesen Landnutzungstyp aus.

Verwechslungen bestanden zu großflächigen Laubgehölzen, die jedoch durch den Texturparameter „Standardabweichung im PAN-Band“ ausgeschlossen werden konnten. Laubgehölze besaßen im August deutlich höhere Werte. Auch Grünland auf sehr nassen Standorten wies ähnliche Spektraleigenschaften wie Mais-Anbauflächen auf.

<b>Mais-Anbaufläche (4120)</b>				
Spektraleigenschaften		August		
		Min	Max	
Grün (2)		292	295	
NIR (4)		645	1005	
NDVI		0,5	0,8	
<b>Textureigenschaften</b>				
Standardabweichung (PAN)			10	25
<b>Objekteigenschaften</b>				
Topologie			Bemerkung	
-			- Ebene 3 - erbt Zugehörigkeiten von „Ackerland (4100)“	

Abb. 60: Regelwerk der Klasse „Mais-Anbaufläche (4120)“.

### „Wiesen, Weiden, sonstiges Grünland (4200)“

„Landwirtschaftliche Flächen des Grünlandes, die regelmäßig gemäht oder beweidet werden“ (BFN 2002).

In diese Klasse fielen sämtliche Flächen die überwiegend von Gräsern bewachsen sind und die außerhalb von Siedlungen auftreten. Insbesondere im Alpenvorland stellen diese Flächen ein verbreitetes Landschaftselement dar. Die Artenzusammensetzung des Grünlands ist von der Nutzungsintensität und vom Standort abhängig. Wie bereits erwähnt, erwiesen sich IKONOS-Daten als zu undifferenziert, um verschiedene Nutzungsintensitäten, oder Standortcharakteristika wie die Feuchtigkeit des Bodens verlässlich zu erfassen. Zudem fielen auch Flächen in diese Klasse, die hauptsächlich der Erholungsnutzung dienen, wie z. B. Golfplätze oder Badewiesen.

<b>Wiesen, Weiden, sonstiges Grünland (4200)</b>								
Spektraleigenschaften		April			August			
		Min	Max		Min	Max		
Grün (2)		245	400	Grün (2)		236	360	
Rot (3)		120	300	Rot (3)		141	285	
NIR (4)		640	1250	NIR (4)		560	1060	
NDVI		0,42	0,8	NDVI		0,42	0,85	
Spektraleigenschaften		April			August			
Standardabweichung (PAN)			10	91	Standardabweichung (PAN)		10	91
<b>Objekteigenschaften</b>								
Form			Topologie		Bemerkung			
-			-		- Ebene 3			

Abb. 61: Regelwerk der Klasse „Wiesen, Weiden, sonstiges Grünland (4200)“.

## **Zusammenfassung „Landwirtschaftliche Nutzflächen (4000)“**

Bei der Klassifikation von besiedelten Flächen wurden unterschiedliche Möglichkeiten des objektorientierten Ansatzes genutzt:

- Kombination von Spektral- und Textureigenschaften
- Implementierung von Formparametern

Im vorangegangenen Abschnitt wurde gezeigt, daß sich bei Agrarflächen die Entwicklung der Vegetation bzw. der Feldfrüchte sehr gut durch den NDVI bzw. die Veränderung der Signatur wiedergeben lassen.

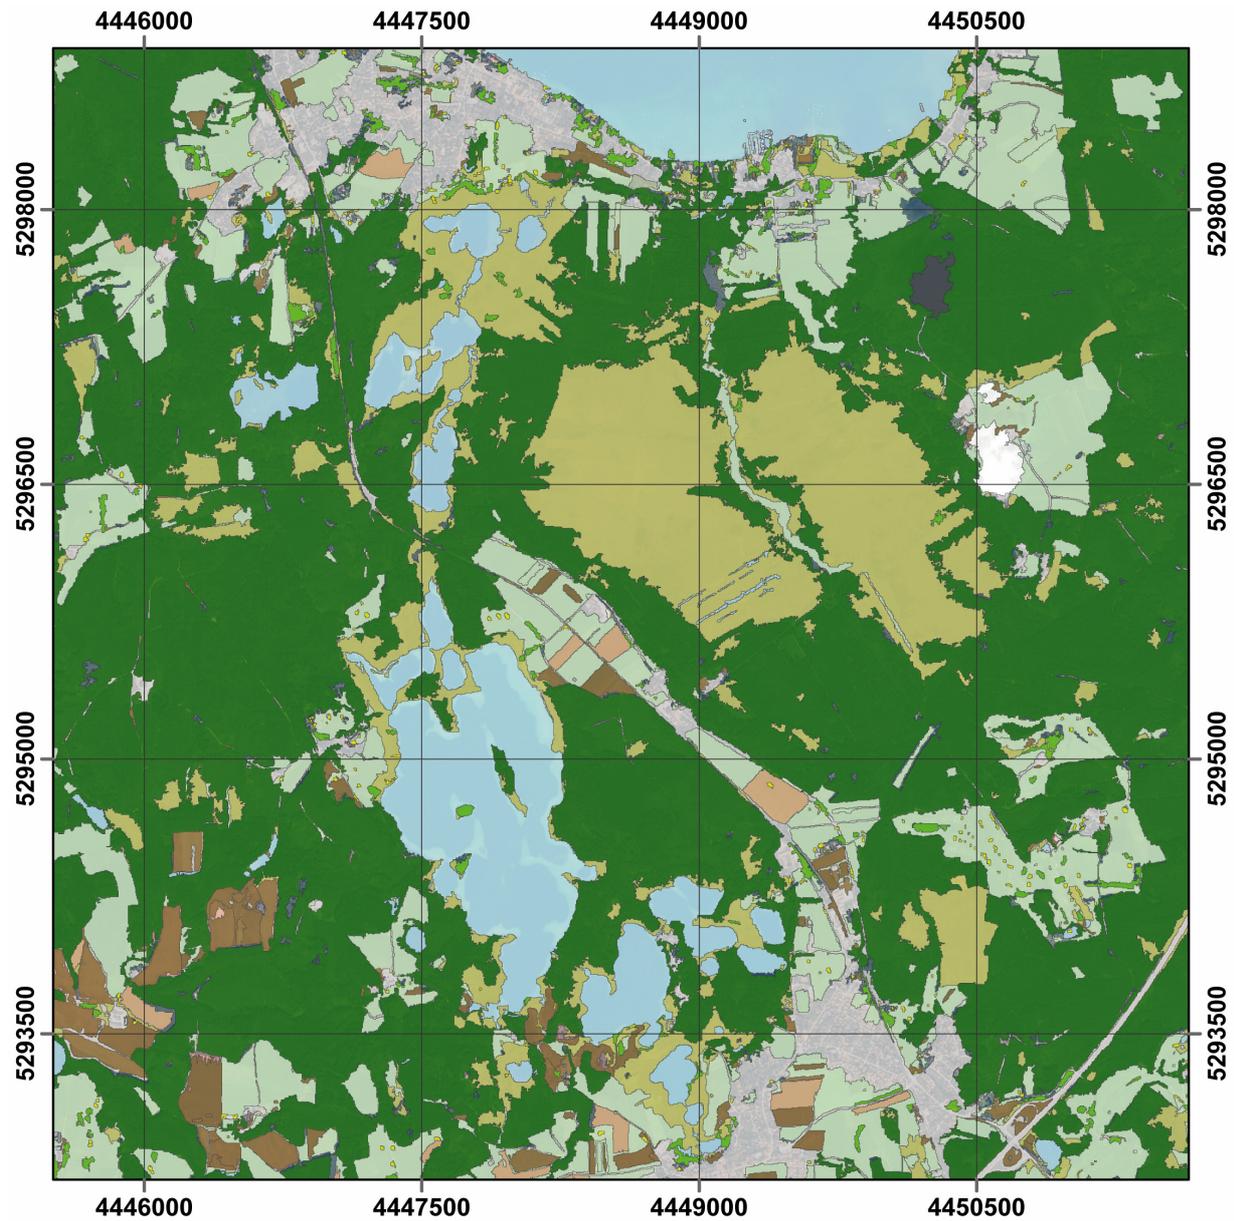
Die Untersuchung des Formparameters *Rectangular Fit* bestätigte die allgemeine Erfahrung, daß Ackerland „eher“ rechteckig geformt ist. Diese Formeigenschaft war allerdings erst auf der Objekt-scalenebene 3 aussagekräftig. Nur auf dieser Ebene gaben die Bildobjekte die Form eines Ackers wieder.

### **6.1.5 Klassifikation**

#### **Zusammenführung der Ergebnisse auf Ebene 2**

Um die Klassifikationsergebnisse des Projektes AQUATIC darzustellen, wurden sie auf der Segmentierungsebene 2 zusammengeführt. Die klassifizierte landwirtschaftlichen Nutzflächen von Ebene 3 wurden durch Abfrage der Überobjekte auf Ebene 2 übertragen. In diesem Zusammenhang wurden auch die Klassifikationsergebnisse der Feuchtgebiete im Untersuchungsgebiet aus den Untersuchungen von ANDRESEN (2004) übernommen. Diese Informationen ließen sich als GIS-Daten einlesen und bei der Klassifikation bewerten. Dabei wurden die Klassen „Binnengewässer (2000)“, „Ufervegetation (2100)“, „Röhrichtvegetation (2200)“ und „Moor, Sümpfe (3000)“ abgefragt und in dieser Studie zur Klasse „Feuchtgebiete“ zusammengefaßt.

In Abbildung 61 wird das zusammengefaßte Ergebnis der Analyse hochauflösender IKONOS-Daten beider Aufnahmezeitpunkte inklusive der externen Feuchtgebietsklassifikation dargestellt.



### Legende

#### Externe thematische Information

- Binnengewässer (2000)
- Feuchtgebiete

#### Siedlungs- und Verkehrsflächen

- Siedlung, Verkehr, Freizeit (9000)

#### Landwirtschaftliche Nutzflächen (4000)

- Mais-Anbaufläche (4120)
- Offener Ackerboden, sonstige Ackerfläche
- Wiesen, Weiden, sonstiges Grünland (4200)

#### Gehölze

- Wälder (7000)
- Feldhecke (6100), Feldgehölz (6200), Baumgruppe (6300)
- Einzelbaum (6400)

#### Sonstige Flächen

- Wolke
- Wolkenschatten



Abb. 62: Zusammengeführte Klassifikation des Kernuntersuchungsgebiets.

## 6.1.6 Genauigkeitsanalyse

Das Ziel der Genauigkeitsanalyse ist es, die Nähe der Ergebnisse zu einem Wert, der als richtig angesehen wird, festzustellen. Im Rahmen dieser Arbeit wurde die Qualität der Klassifikation durch eine Kreuztabelle beschrieben. In dieser Tabelle wird die quantitative Übereinstimmung der Referenzinformation mit den Klassifikationsergebnissen dargestellt (Kap. 3.7.2).

Als Referenzinformation wurden Bildobjekte bzw. Referenzobjekte aus der Segmentierungsebene 2 ausgewählt und einer entsprechenden, „richtigen“ Klasse zugewiesen. Bei der Zuweisung der Referenzklasse wurden Feldkenntnisse aus terrestrischen Kampagnen inklusive GPS-Messungen, wie auch Vor-Ort-Fotografien verwendet. Insgesamt wurden 200 Bildobjekte bestimmt, wobei darauf geachtet wurde, daß diese nicht mit den Referenzflächen, die zur Orientierung beim Aufbau der Regelwerke verwendet wurden, identisch waren. Offene Wasserflächen (Binnengewässer (2000)) und Feuchtgebiete (3000), Ufervegetation (2100) und Röhrichtvegetation (2200)) wurden von der Genauigkeitsanalyse ausgenommen, da diese Klassen im Rahmen des Partnerprojekts untersucht wurden (ANDRESEN et al. 2004). Die Zahl der Referenzobjekte ist in Tabelle 6 pro Klasse dargestellt.

**Tab. 6:** Zahl der Referenzobjekte pro Klasse.

Klasse	Zahl der Referenzobjekte
Wälder (7000)	57
Feldhecke, Feldgehölz, Baumgruppe	10
Einzelbaum (6400)	13
Siedlung, Verkehr, Freizeit (9000)	59
Ackerland (4100)	31
Wiesen, Weiden, sonstiges Grünland (4200)	30

Die Ergebnisse der Genauigkeitsanalysen inklusive der Benutzer- und der Produzentengenauigkeiten werden für die April-Klassifikation in Tabelle 7 dargestellt und für die August-Klassifikation in Tabelle 8 dargestellt. Die Ergebnisse der multisaisonalen Analyse sind in Tabelle 9 zu finden.

**Tab. 7:** Kreuztabelle für die Klassifikation der IKONOS-Daten vom April 2001.

IKONOS-Klassifikation 24.04.2001 (Angaben in [ha])	Referenz-Objekte							Genauigkeit [%]	
	Wälder (7000)	Feldhecke, Feldgehölz, Baumgruppe	Einzelbaum (6400)	Siedlung, Verkehr, Freizeit (9000)	Ackerland (4100)	Wiesen, Weiden, Grünland (4200)	Gesamtergebnis	Benutzer- genauigkeit	Produzenten- genauigkeit
Wälder (7000)	<b>57,62</b>	0,37	0,03	0,27	0,09	-	58,38	99%	91%
Feldhecke, Feldgehölz, Baumgruppe	0,65	<b>0,96</b>	0,05	0,41	-	-	2,07	46%	53%
Einzelbaum (6400)	0,01	-	<b>0,21</b>	-	0,05	-	0,28	76%	30%
Siedlung, Verkehr, Freizeit (9000)	0,07	0,20	0,02	<b>5,37</b>	0,54	0,06	6,26	86%	79%
Ackerland (4100)	0,99	-	0,08	0,17	<b>19,77</b>	0,56	21,58	92%	75%
Wiesen, Weiden, Grünland (4200)	0,22	0,17	0,22	0,42	4,73	<b>12,31</b>	18,08	68%	93%
unklassifiziert	0,48	0,04	-	0,14	1,16	0,25	2,07	unklassifiziert: 1,9%	
Gesamtergebnis	60,05	1,74	0,61	6,79	26,35	13,18	108,72	Gesamtgen.: 89%	$\kappa=0,82$

**Tab. 8:** Kreuztabelle für die Klassifikation der IKONOS-Daten vom August 2001.

IKONOS-Klassifikation 12.08.2004 (Angaben in [ha])	Referenz-Objekte						Genauigkeit [%]		
	Wälder (7000)	Feldhecke, Feldgehölz, Baumgruppe	Einzelbaum (6400)	Siedlung, Verkehr, Freizeit (9000)	Ackerland (4100)	Wiesen, Weiden, Grünland (4200)	Gesamtergebnis	Benutzer- genauigkeit	Produzenten- genauigkeit
Wälder (7000)	<b>62,86</b>	0,03	0,06	-	-	-	62,94	100%	99%
Feldhecke, Feldgehölz, Baumgruppe	0,75	<b>1,75</b>	0,16	-	-	-	2,65	66%	97%
Einzelbaum (6400)	-	0,03	<b>0,39</b>	-	-	-	0,42	92%	56%
Siedlung, Verkehr, Freizeit (9000)	-	-	-	<b>6,72</b>	0,41	-	7,14	94%	98%
Ackerland (4100)	-	-	-	-	<b>22,34</b>	-	22,34	100%	85%
Wiesen, Weiden, Grünland (4200)	-	-	-	-	3,36	<b>13,19</b>	16,55	80%	100%
unklassifiziert	-	-	0,10	0,24	0,24	-	0,57	unklassifiziert	0,5%
Gesamtergebnis	63,60	1,81	0,70	6,96	26,35	13,19	112,61	<b>Gesamtgen.: 95%</b>	<b><math>\kappa=0,92</math></b>

Die erzielten Genauigkeiten können sowohl für die April-Daten als auch für die August-Daten als sehr gut bewertet werden. Die Gesamtgenauigkeit betrug für die Klassifikation der April-Daten 89 % und lag für die August-Klassifikation bei 95 %. Auch die KAPPA-Indizes sprechen für eine hohe Qualität der Klassifikation (April  $\kappa$ : 0,82, August  $\kappa$ : 0,92).

Im einzelnen wurde die Klasse „Wälder (7000)“ bei beiden Aufnahmezeitpunkten nahezu flächendeckend detektiert, während „Feldhecken, Feldgehölze und Baumgruppen“ mit den April-Daten nur etwa zur Hälfte erkannt wurden. Bei den August-Daten waren die Ergebnisse besser: die Produzentengenauigkeit lag bei 97 %, die Benutzergenauigkeit mit 66 % deutlich darunter. Einzelbäume sind zu beiden Zeitpunkten nicht zuverlässig klassifiziert worden. Auffallend war bei Einzelbäumen, daß die Benutzergenauigkeit hier erheblich höher war als die Produzentengenauigkeit. Die Klasse „Siedlung, Verkehr und Freizeit (9000)“ wurde im April etwas weniger gut getroffen als im August: die Siedlungsflächen lagen im August bei etwas mehr als 90 %, bei der April-Klassifikation bewegten sich die Genauigkeiten bei 79 % (Produzentengenauigkeit) bzw. 86 % (Benutzergenauigkeit). Die Klasse „Ackerland“ wurde im April mit einer Produzentengenauigkeit von 75 % erfaßt, wobei die klassifizierten Äcker eine Benutzergenauigkeit von 92 % aufwiesen. Im August lagen die Genauigkeiten bei 85 % bzw. 100 %. Die Klasse „Wiesen, Weiden und Grünland (4200)“ wies im April eine Produzentengenauigkeit von 93 % und eine Benutzergenauigkeit von 68 % auf. Verwechslungen ergaben sich in der Hauptsache zur Klasse „Ackerland (4100)“. Im August lag die Produzentengenauigkeit der Klasse „Wiesen, Weiden, sonstiges Grünland (4200)“ bei 100%, d.h. sämtliche Referenzobjekte wurden korrekt klassifiziert. Wie auch im April ist die Benutzergenauigkeit niedriger.

**Tab. 9:** Kreuztabelle für die multisaisonale Klassifikation.

IKONOS-Klassifikation multi-temporaler Ansatz (Angaben in [ha])	Referenz-Objekte							Genauigkeit [%]	
	Wälder (7000)	Feldhecke, Feldgehölz, Baumgruppe	Einzelbaum (6400)	Siedlung, Verkehr, Freizeit (9000)	Ackerland (4100)	Wiesen, Weiden, Grünland (4200)	Gesamtergebnis	Benutzer- genauigkeit	Produzenten- genauigkeit
Wälder (7000)	<b>62,77</b>	0,02	0,02	-	0,07	-	62,87	100%	99%
Feldhecke, Feldgehölz, Baumgruppe	0,75	<b>1,75</b>	0,17	-	-	-	2,67	65%	97%
Einzelbaum (6400)	0,01	0,03	<b>0,41</b>	-	-	-	0,46	90%	59%
Siedlung, Verkehr, Freizeit (9000)	0,07	-	0,02	<b>6,78</b>	0,44	0,06	7,36	92%	99%
Ackerland (4100)	-	-	0,02	0,05	<b>25,00</b>	0,52	25,59	98%	95%
Wiesen, Weiden, Grünland (4200)	-	-	-	-	0,84	<b>12,61</b>	13,45	94%	96%
unklassifiziert	-	-	0,06	-	0,01	-	0,07	unklassifiziert: 0,1%	
Gesamtergebnis	63,60	1,80	0,70	6,83	26,35	13,19	112,47	Gesamtgen.: 97% $\kappa=0,95$	

Bei der multisaisonalen Auswertung war die Gesamtgenauigkeit mit 97 % ( $\kappa$ : 0,95) höher als bei beiden Zeitpunkten für sich genommen. Auch unklassifizierte Bereiche fielen mit einem Flächenanteil von 0,1 % weniger ins Gewicht. Der Vergleich der Genauigkeitswerte der multisaisonalen Klassifikation mit den Ergebnissen für April bzw. August belegte, daß sich die Klassifikationsergebnisse durch die Verwendung von Daten verschiedener Aufnahmezeitpunkte verbessern lassen.

Die folgenden Tabellen 10, 11 und 12 beschreiben Genauigkeiten, die bei der Unterscheidung von Laub- und Nadelgehölz auf Segmentierungsebene 1 erreicht wurden.

**Tab. 10:** Kreuztabelle für Laub- und Nadelgehölze für die April-Klassifikation.

IKONOS-Klassifikation 24.04.2001 (Angaben in [ha])	Referenz-Objekte			Genauigkeit [%]	
	Laubgehölz	Nadelgehölz	Gesamt- ergebnis	Benutzer- genauigkeit	Produzenten- genauigkeit
Laubgehölz	<b>12,27</b>	4,05	16,32	75%	72%
Nadelgehölz	2,10	<b>44,04</b>	46,14	95%	90%
unklassifiziert	2,64	1,10	3,74	unklassifiziert: 6%	
Gesamtergebnis	17,01	49,20	66,21	Gesamtgenauigkeit: 85%	

**Tab. 11:** Kreuztabelle für Laub- und Nadelgehölze für die August-Klassifikation.

IKONOS-Klassifikation 12.08.2001 (Angaben in [ha])	Referenz-Objekte			Genauigkeit [%]	
	Laubgehölz	Nadelgehölz	Gesamt- ergebnis	Benutzer- genauigkeit	Produzenten- genauigkeit
Laubgehölz	<b>15,83</b>	1,88	17,71	89%	93%
Nadelgehölz	0,91	<b>46,77</b>	47,68	98%	95%
unklassifiziert	0,27	0,54	0,81	unklassifiziert: 1%	
Gesamtergebnis	17,01	49,20	66,21	Gesamtgenauigkeit: 95%	

**Tab. 12:** Kreuztabelle für Laub- und Nadelgehölze für die multisaisonale Klassifikation.

IKONOS- Klassifikation 24.04.2001 (Angaben in [ha])	Referenz-Objekte		Genauigkeit [%]		
	Laubgehölz	Nadelgehölz	Gesamt- ergebnis	Benutzer- genauigkeit	Produzenten- genauigkeit
Laubgehölz	<b>15,98</b>	2,07	18,05	89%	94%
Nadelgehölz	0,91	<b>47,13</b>	48,04	98%	96%
unklassifiziert	0,12		0,12	unklassifiziert: -	
Gesamtergebnis	17,01	49,20	66,21	<b>Gesamtgenauigkeit: 95%</b>	

Wie bereits beschrieben (Kap. 6.1.4.1, Spektraleigenschaften von Laub- und Nadelgehölzen), konnte das Laubgehölz durch die im August voll ausgebildete Belaubung deutlich sicherer und besser detektiert werden. Bei Nadelgehölz waren die Unterschiede naturgemäß gering. Insgesamt brachte auch bei den Gehölzen die multisaisonale Klassifikation die besten Ergebnisse.

## 6.2 Analyse von Luftbildern

### 6.2.1 Fragestellung

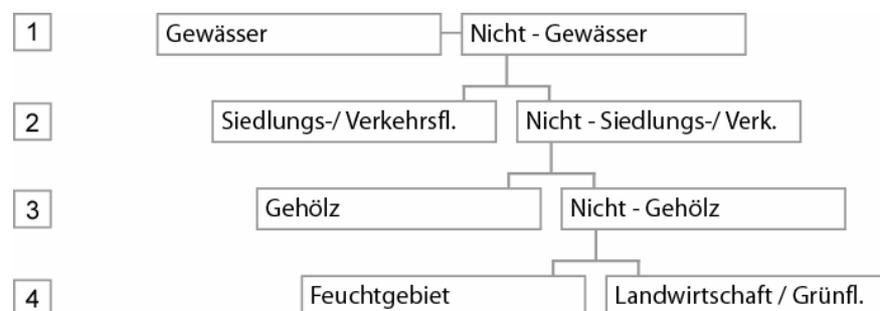
In dieser Fallstudie wurde der **Fragestellung** nachgegangen, inwieweit es mit objektorientierten Analysemethoden möglich ist, die Landnutzung aus aktuellen Schwarz/Weiß-Luftbildern festzustellen und im Vergleich mit älteren Luftbildern die Landschaftsentwicklung zu erfassen. Als Untersuchungsgebiet wurde eine knapp 129 ha große Fläche um Iffeldorf an den südlichen Osterseen gewählt. Schwarz/Weiß-Luftbilder aus den Jahren 1956, 1976 und 2000 (Kap. 5.2) dienten als **Eingangsdaten**. Die Luftbilder lagen digital vor und wiesen eine räumliche Auflösung von 40 cm - 80 cm pro Bildpunkt auf.

### 6.2.2 Segmentierung und Wissensmodellierung

Die **Segmentierung** der Luftbilder wurde jeweils in Abhängigkeit von Auflösung und Belichtungscharakteristik durchgeführt. Die verwendeten Segmentierungsparameter für die Luftbilder des Jahrgangs 2000 sind bei ROGG (2003) beschrieben.

Bei der **Wissensmodellierung** wurde eine andere Strategie verfolgt als bei den IKONOS-Daten. Der Aufbau der Regelwerke orientierte sich an der binären Struktur eines Entscheidungsbaumes. Dahinter stand der Gedanke, daß eine komplexe Entscheidung in eine Reihe von einfacheren Entscheidungen zerlegt werden kann.

Das Klassifikationsregelwerk wurde zunächst für die Luftbilddaten des Jahres 2000 entwickelt. Abbildung 62 zeigt das Schema des prinzipiellen Aufbaus.



**Abb. 63:** Aufbau des Klassifikationsregelwerks in Anlehnung an einen Entscheidungsbaum. Der Baum ist in vier „Entscheidungsstufen“ gegliedert.

Auf jeder Entscheidungsstufe tastete man sich weiter an das Endergebnis heran. Die Klassifikation wurde schrittweise genauer, wobei bereits klassifizierte Bildobjekte von der weiteren Betrachtung ausgeschlossen wurden. Das bedeutet, daß auf jeder Stufe der Suchraum für den nächsten Klassifikationsschritt eingengt wurde. Dieses Konzept entspricht der Vorgehensweise bei der Stratifikation mit Hilfe von externen GIS-Daten.

In einem ersten Schritt wurde „Wasser“ von „Nicht-Wasser“ unterschieden. Diese Unterscheidung war eindeutig, denn Wasserflächen wiesen niedrige Grauwerte und vergleichsweise homogene Texturen auf.

Im zweiten Schritt wurden die „übrigen“, als „Nicht-Wasser“ klassifizierten Bildobjekte weiter aufgegliedert. „Nicht-Wasser“ setzte sich aus „Siedlungs-/ Verkehrsfläche“ und „Nicht-Siedlungs-/

**Verkehrsfläche**“ zusammen. Um Siedlungsgebiete und Straßen zu detektieren, wurden ähnlich wie bei den IKONOS-Daten verstärkt Textur- und Formattribute eingesetzt.

Die Klasse „Nicht-Siedlung“ wiederum bestand aus „**Gehölz**“ und „**Nicht-Gehölz**“. Auch hier waren insbesondere Texturparameter hilfreich, wobei auch der Grauwert der Gehölze niedriger lag als bei den übrigen Landnutzungsklassen und damit ein wichtiges Unterscheidungskriterium lieferte.

Die letzte Unterteilung war diejenige von „Nicht-Gehölz“-Flächen in die Klassen „**Feuchtgebiet**“ und „**Landwirtschaft / Grünfläche**“. Die Klassifikation der Feuchtgebiete im Untersuchungsgebiet gestaltete sich als außerordentlich komplex, denn diese Klasse umfaßte die heterogenen Einheiten Schilfröhricht, Niedermoor-, bzw. Hochmoorflächen und Seggenriede. Nur mittels der vereinfachenden Annahme, daß Feuchtgebiete in unmittelbarer Nähe zu offenen Gewässern auftreten, konnte diese Klasse gefunden werden. Flächen der „Landwirtschaft / Grünflächen“ waren dann diejenigen Bildobjekte, auf welche keine der anderen Klassenbeschreibungen zutraf. Ähnlich wie bei den Feuchtgebieten wurde auch hier eine vereinfachende Annahme getroffen, nämlich daß alle von den anderen Klassenbeschreibungen nicht erfaßten Bildobjekte der Klasse „Landwirtschaft / Grünfläche“ zugehören. Auf das Untersuchungsgebiet traf dies zwar tendenziell zu, doch ist diese Annahme hinsichtlich der Übertragung der Regelwerke mit Vorsicht anzuwenden.

### 6.2.3 Genauigkeitsanalyse

Um die Qualität der Klassifikation zu prüfen, wurde eine **Genauigkeitsanalyse** durchgeführt. Als Referenz diente eine Landnutzungskartierung, die im Rahmen einer Diplomarbeit an der Limnologischen Station erstellt wurde (KANGLER 2003). Für diese Landnutzungskartierung wurden die Luftbilddaten des Jahres 2000 visuell interpretiert und mit terrestrischen Feldkampagnen abgesichert. Für einen sinnvollen Vergleich der Klassifikationsergebnisse von eCognition mit den Referenzdaten wurden die Landnutzungsklassen der visuellen Interpretation thematisch zusammengefaßt und auf die Klassen „Gewässer“, „Feuchtgebiete“, „Landwirtschaft“, „Gehölze“ und „Siedlungs-/ Verkehrsfläche“ beschränkt. Die Ergebnisse des Vergleichs sind in Form einer Kreuztabelle dargestellt (Tab. 13).

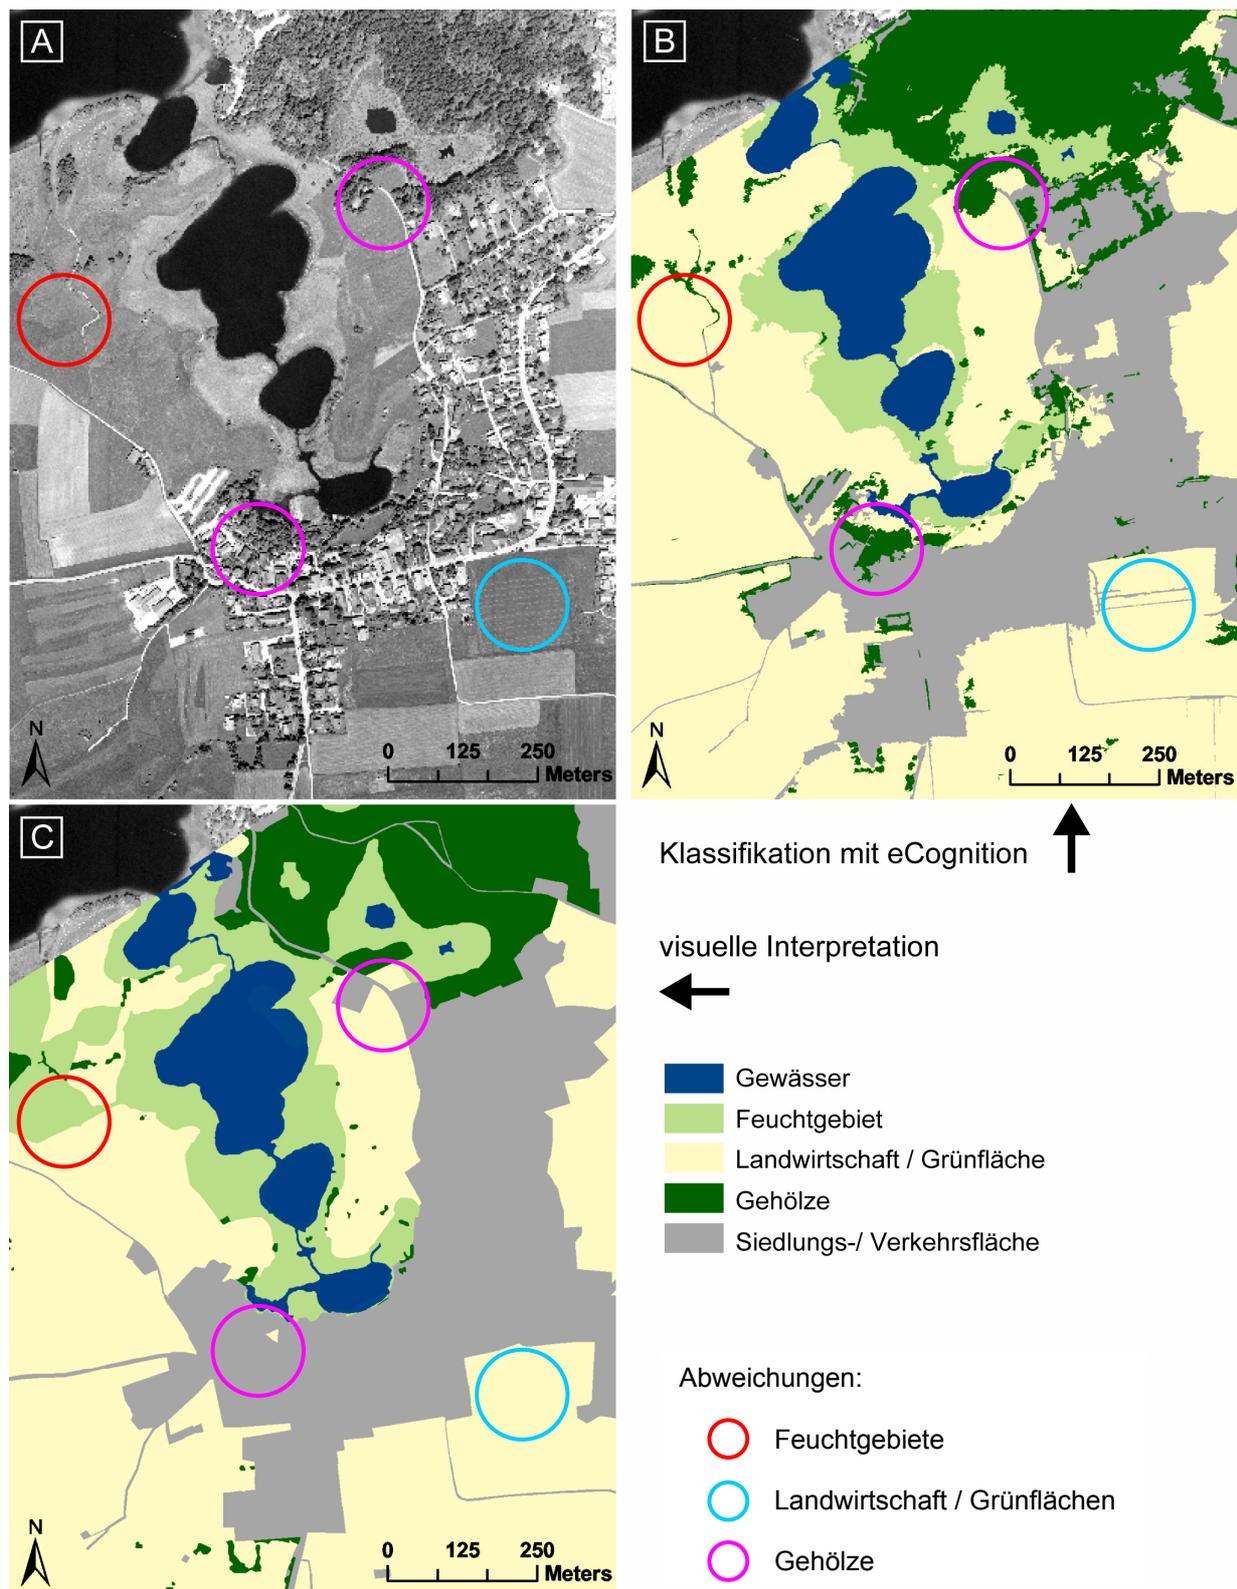
**Tab. 13:** Kreuztabelle für die Klassifikation des Testgebietes „Iffeldorfer Seengruppe“ im Vergleich mit einer visuellen Interpretation.

Luftbildklassifikation 2000 Angaben in [ha]	Referenz, visuelle Interpretation					Genauigkeit (%)		
	Gewässer	Feuchtgebiete	Landwirtschaft / Grünfläche	Gehölze	Siedlungs-/ Verkehrsfläche	Gesamt- ergebnis	Benutzer- genauigkeit	Produzenten- genauigkeit
Gewässer	<b>8,43</b>	0,19	-	-	0,01	8,63	98%	95%
Feuchtgebiete	0,35	<b>8,86</b>	0,28	0,15	0,33	9,97	89%	56%
Landwirtschaft / Grünfläche	0,12	5,44	<b>54,66</b>	0,65	3,60	64,46	85%	96%
Gehölze	0,02	1,27	0,70	<b>11,49</b>	3,68	17,16	67%	91%
Siedlungs- / Verkehrsfläche	-	0,04	1,05	0,39	<b>27,05</b>	28,54	95%	78%
Gesamtergebnis	8,92	15,79	56,69	12,69	34,67	128,76	<b>Gesamtgen.: 86% <math>\kappa=0,80</math></b>	

Insgesamt wurde ein Genauigkeitswert von 86 % ( $\kappa: 0,80$ ) erreicht. Die Analyse der Produzentengenauigkeit (Pixel, die innerhalb einer Landbedeckungsklasse der Referenz als richtig klassifiziert wurden) für das Testgebiet „Iffeldorfer Seengruppe“ 2000 ergab für die Klasse „Gewässer“, daß 95 % der kartierten Wasserflächen erkannt wurden. Die Klasse „Feuchtgebiete“ erreichte 56 % Übereinstimmung. Flächen der Landwirtschaft und Grünflächen wurden zu 96 % erkannt, während von der Klasse „Gehölze“ 91 % erfaßt wurden. Für „Siedlungs- und Verkehrsflächen“ lag die Übereinstimmung mit der Referenzfläche bei 78 %.

Die Analyse der Benutzergenauigkeit (Pixel, die innerhalb einer Landbedeckungsklasse der Klassifikation als richtig klassifiziert wurden) ergab, daß die Gewässerflächen zu 98 % mit der Kartierung übereinstimmten. Landwirtschafts- und Grünflächen hatten hier einen Wert von 85 %. Bei der Klasse „Feuchtgebiete“ stimmte ein Anteil von 89 % der klassifizierten Fläche. „Siedlungs- und Verkehrsflächen“ waren zu 95 % korrekt, während bei der Klasse „Gehölze“ die Übereinstimmung bei „nur“ 67 % lag.

Wo die Verwechslungen und Fehlklassifikationen bestanden, wird aus Abbildung 63 deutlich. In dieser Abbildung werden das Luftbild aus dem Jahr 2000 (Abb. 63 (A)), das **Ergebnis** der Klassifikation mit eCognition (Abb. 63 (B)) und die oben erwähnte Referenzkartierung des Untersuchungsgebiets (Abb. 63 (C)) einander gegenüber gestellt.



**Abb. 64:** Luftbild von 2000 (A), Klassifikation mit eCognition (B), visuelle Interpretation des Untersuchungsgebiets (C). Der rote Kreis zeigt Feuchtgebiete, die mit eCognition nicht detektiert werden. Ackerfurchen, die von eCognition fälschlicherweise als Siedlungs-/ Verkehrsflächen klassifiziert werden, sind im blauen Kreis dargestellt. In den violetten Kreisen liegen Gehölzstrukturen, die bei der visuellen Interpretation in die Siedlungs-/ Verkehrsflächen integriert wurden.

Obschon die bei der Klassifikation der Luftbilder erhaltenen Genauigkeiten als ausgezeichnet bewertet werden müssen, sind beim Vergleich mit der visuellen Landnutzungsinterpretation folgende Gesichtspunkte herauszustellen: während „**Gewässer**“ sehr gut gefunden wurden, war bei den „**Feuchtgebieten**“ die Produzentengenauigkeit von nur 56 % auffällig, d.h. 44 % der visuell gefundenen Feuchtflächen wurden nicht als solche klassifiziert. Den Hauptanteil machten dabei feuchte Streuwiesen aus (Abb. 63, roter Kreis). Daß diese nicht gefunden wurden, hatte im wesentlichen zwei Ursachen: zum einen die vereinfachende Annahme des Regelwerks, daß nämlich Feuchtflächen nur in unmittelbarer Nähe zu offenen Wasserflächen auftreten. Diese Annahme war selbst im räumlich überschaubaren Untersuchungsgebiet tendenziell nicht richtig. Zum anderen waren keine Grauwert- oder Texturunterschiede zu den landwirtschaftlichen Nutzflächen (in diesem Fall Wiesen- und Weiden) zu erkennen. Wird davon ausgegangen, daß die Referenzkartierung richtig ist, müssen bei der visuellen Interpretation dieser Flächen Vor-Ort-Kenntnisse des Interpreten eingeflossen sein, die bei der automatischen Klassifikation keine Rolle spielten. Bei Flächen der „**Landwirtschaft / Grünflächen**“ lagen die Benutzergenauigkeit bei 85 % und die Produzentengenauigkeit bei 96 %. Verwechslungen bestanden mit Feuchtgebieten (Abb. 63, roter Kreis) und auch mit „Siedlungs- / Verkehrsflächen“. Längliche Ackerfurchen wurden zum Teil nicht korrekt zugewiesen (Abb. 63, blauer Kreis). Auch ein Teil der Grünflächen innerhalb der Ortschaft Iffeldorf fielen in diese Kategorie. Diese Grünflächen waren überwiegend großzügige Gärten, die im Referenzdatensatz in das Siedlungsgebiet integriert wurden. Die Klasse „**Gehölze**“ wies mit 63 % die niedrigste Benutzergenauigkeit auf. Die hauptsächlichlichen Verwechslungen bestanden zur Klasse „**Siedlungs- / Verkehrsflächen**“. Bei der visuellen Klassifikation wurden Gehölze, die innerhalb von vermeintlichen Siedlungsflächen lagen, einfach integriert. Vergleicht man Luftbild und visuelle Interpretation (Abb. 63 (A) und (C), z. B. violette Kreise), so läßt sich feststellen, daß die Integration der Gehölze sehr „großzügig“ vorgenommen wurde. Die Klassifikation der Gehölzstrukturen mit dem objektorientierten Ansatz lag deshalb näher an der Wirklichkeit als die visuelle Interpretation.

#### 6.2.4 Multitemporale Analyse

Bei der Klassifikation der multitemporalen Luftbilder wurde die Auswertung dahingehend erweitert, daß eine Analyse der Aufnahmen verschiedener Zeitpunkte in Abhängigkeit voneinander durchgeführt wurde. Dem lag die Erfahrung zugrunde, daß Landnutzungstypen nicht nur strukturelle Merkmale haben, sondern auch charakteristische Entwicklungstendenzen über die Zeit hinweg aufweisen. So ist z. B. kaum denkbar, daß ein aktuell detektiertes Gewässer in der Vergangenheit eine bebaute Fläche war. Ausgehend von der gegenwärtigen Landnutzung - abgeleitet aus den Luftbilddaten des Jahres 2000 (im folgenden LN 2000) - wurde die Veränderung der Landschaft in der Zeit zurück verfolgt. Die aktuelle Landnutzung wurde als externe Informationsebene hinzugefügt, um die Luftbilder des Jahres 1976 zu klassifizieren. Diese Vorgehensweise kann als Stratifikation verstanden werden, da der Suchraum für bestimmte Klassen eingeschränkt wurde und man durch *a-priori* Wissen die Treffsicherheit der Klassifikation erhöhen konnte. Neben den Bilddaten wurde also auch „zeitliches“ Wissen genutzt.

Am Beispiel „Gehölze“ soll dies verdeutlicht werden: wenn ein Forst im Jahr 2000 detektiert wurde, ist die Wahrscheinlichkeit sehr hoch, daß dieses Gehölz 1976 bereits existiert hat. Der Ursache liegt darin, daß viele dieser Flächen traditionell forstwirtschaftlich genutzt werden und außerdem der Übergang von z. B. einer Grünfläche zu einer Waldfläche Jahrzehnte in Anspruch nimmt. Ähnlich dauerhaft sind Gehölze innerhalb eines Naturschutzgebietes, da die Nutzung dieser Flächen streng reglementiert ist. Das bedeutet, daß die Gehölze im Untersuchungsgebiet vermutlich von einer gewissen zeitlichen

Konstanz geprägt waren (obschon das Naturschutzgebiet Osterseen erst im Jahr 1981 ausgerufen wurde).

Um gewisse Annahmen zusätzlich abzusichern, wurden durch das Regelwerk zudem der Grauwert und die Standardabweichung in den früheren Daten abgefragt. Wenn alle Hinweise für ein Gehölz sprachen, wurde diese Klasse zugewiesen. Hierbei mußte jedoch bedacht werden, daß es durchaus möglich ist, daß Gehölze die 1976 existiert haben, im Jahr 2000 nicht mehr vorhanden sein müssen. Demzufolge konnte die räumliche Stratifikation für Gehölze durch die LN 2000 nicht absolut sein. Diese Zusammenhänge lassen sich in Form einer WENN-DANN-Regel folgendermaßen beschreiben (für die Luftbilddaten 1976):

WENN **Gehölze** in LN 2000

zutreffend: DANN, prüfe ob **Grauwert niedrig** UND **Standardabweichung hoch**

zutreffend: weise Klasse Gehölze zu

falsch: Klassenregelwerk trifft nicht zu

falsch: DANN, prüfe, ob **Grauwert sehr niedrig** UND **Standardabweichung sehr hoch**

zutreffend: weise Klasse Gehölze zu

falsch: Klassenregelwerk trifft nicht zu

Innerhalb der Grenzen der Gehölze der LN 2000, galten für die Daten von 1976 „weichere“ Kriterien als außerhalb. D.h. es wurde die Information der LN 2000 genutzt, um das Auftreten einer Klasse zu früheren Aufnahmezeitpunkten genauer zu prognostizieren. Genauso konnten Straßen, bebaute Flächen, Gewässer und Feuchtgebiete einfacher detektiert werden: eine Fläche die aktuell einer dieser Klassen angehörte, hatte eine höhere Wahrscheinlichkeit, auch in der Vergangenheit dieselbe Landbedeckung gehabt zu haben - dementsprechend waren die Zugehörigkeitsfunktionen weiter gefaßt.

In Tabelle 14 sind die entwickelten Regelwerke für die Detektion der **Landnutzung 1976** dargestellt. In der linken Spalte steht jeweils die Klasse. Die zweite Spalte „1976“ teilt sich auf: in der Spalte „innerhalb LN 2000“ sind die Bedingungen für die entsprechende Klasse dargestellt, falls dieselbe auch in der LN 2000 ausgewiesen wurde, also innerhalb der „stratifizierten“ Bereiche. In der zweiten Spalte „außerhalb LN 2000“ bestehen „strengere“ Kriterien für die entsprechende Klasse, weil diese Bedingungen nur außerhalb der stratifizierten Bereiche gelten und die *a-priori* Wahrscheinlichkeiten deshalb nicht erhöht sind.

**Tab. 14:** Regelwerk für die Luftbilder 1976, unter Verwendung der Vorinformation aus der LN 2000.

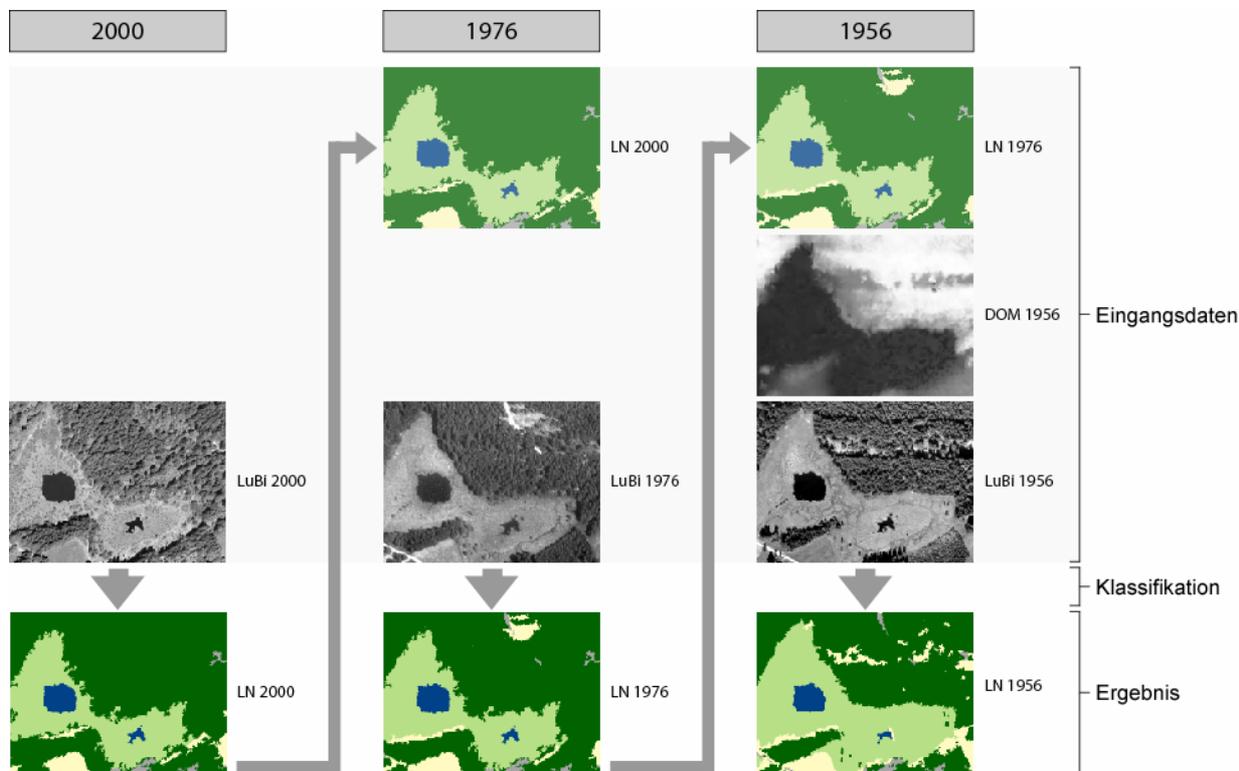
Klasse	1976	
	innerhalb LN 2000	außerhalb LN 2000
Gewässer	- niedriger Grauwert (< 110)	- sehr niedriger Grauwert (< 40) - Nachbarschaft zu Gewässern
Siedlungs-/ Verkehrsfläche	- sehr hoher Grauwert (versiegelte Flächen) (> 195) - hohe Standardabweichung (> 7) ODER - niedriger Grauwert (Hausdächer) (< 85) - hohe Standardabweichung (> 7) ODER - Nachbarschaft zu Siedlungs-/ Verkehrsfläche - hohe Standardabweichung (> 7)	- Klassenausschluß: - Gewässer  - sehr hoher Grauwert (> 200) - hohe Standardabweichung (> 9)
Gehölz	- niedriger Grauwert (< 130) - hohe Standardabweichung (> 6)	- Klassenausschluß: - Gewässer - Siedlungs-/ Verkehrsfläche  - niedriger Grauwert (< 110) - hohe Standardabweichung (> 9) ODER - Nachbarschaft zu Gehölz - niedriger Grauwert (< 110)
Feuchtgebiete	- niedrige Standardabweichung (< 4) - Nachbarschaft zu Feuchtgebieten	- Klassenausschluß: - Gewässer - Siedlungs-/ Verkehrsfläche - Gehölz
Landwirtschaft/ Grünfläche		- Klassenausschluß: - Gewässer - Siedlungs-/ Verkehrsfläche - Gehölz - Feuchtgebiete  - sonstige nicht klassifizierte Bildobjekte

Die **Klassifikation der Luftbilddaten des Jahres 1956** wurde analog durchgeführt, jedoch mit dem Unterschied, daß nicht die LN 2000 als Vorinformation diente, sondern die LN 1976. Aufgrund von anderem Filmmaterial und verschiedenen Belichtungsintensitäten des Films mußten die Wertebereiche der Zugehörigkeitsfunktionen entsprechend angepaßt werden.

Auch in anderer Hinsicht bildete die Klassifikation der Luftbilder aus dem Jahr 1956 einen Sonderfall, denn zusätzlich zu den Bilddaten lag ein digitales Oberflächenmodell (DOM) vor, das aus Stereoluftbildpaaren abgeleitet wurde (Kap. 5.2). Über den Objektparameter „*Mean Difference to Neighbours*“ konnten Höhenunterschiede zu Nachbarobjekten für die Klassenbeschreibung verwendet werden. Insbesondere für die Klasse „Siedlung“ und auch für „Gehölze“ erhöhte dieses zusätzliche Kriterium die Treffsicherheit der Regelwerke. Wie schon bei der Beschreibung der Datengrundlagen erwähnt, ließen sich aus der Differenz zwischen Oberflächenmodell und Geländemodell auch direkt die Objekthöhen ableiten. Diese Objekthöhen waren „nur“ als ein zusätzlicher Hinweis für bestimmte Klassen zu werten. Bedingt durch Interpolationsfehler im DOM, die bei der automatischen Erstellung auftreten, konnten die Objekthöhen nicht unkritisch übernommen werden. Gewässer wiesen demnach

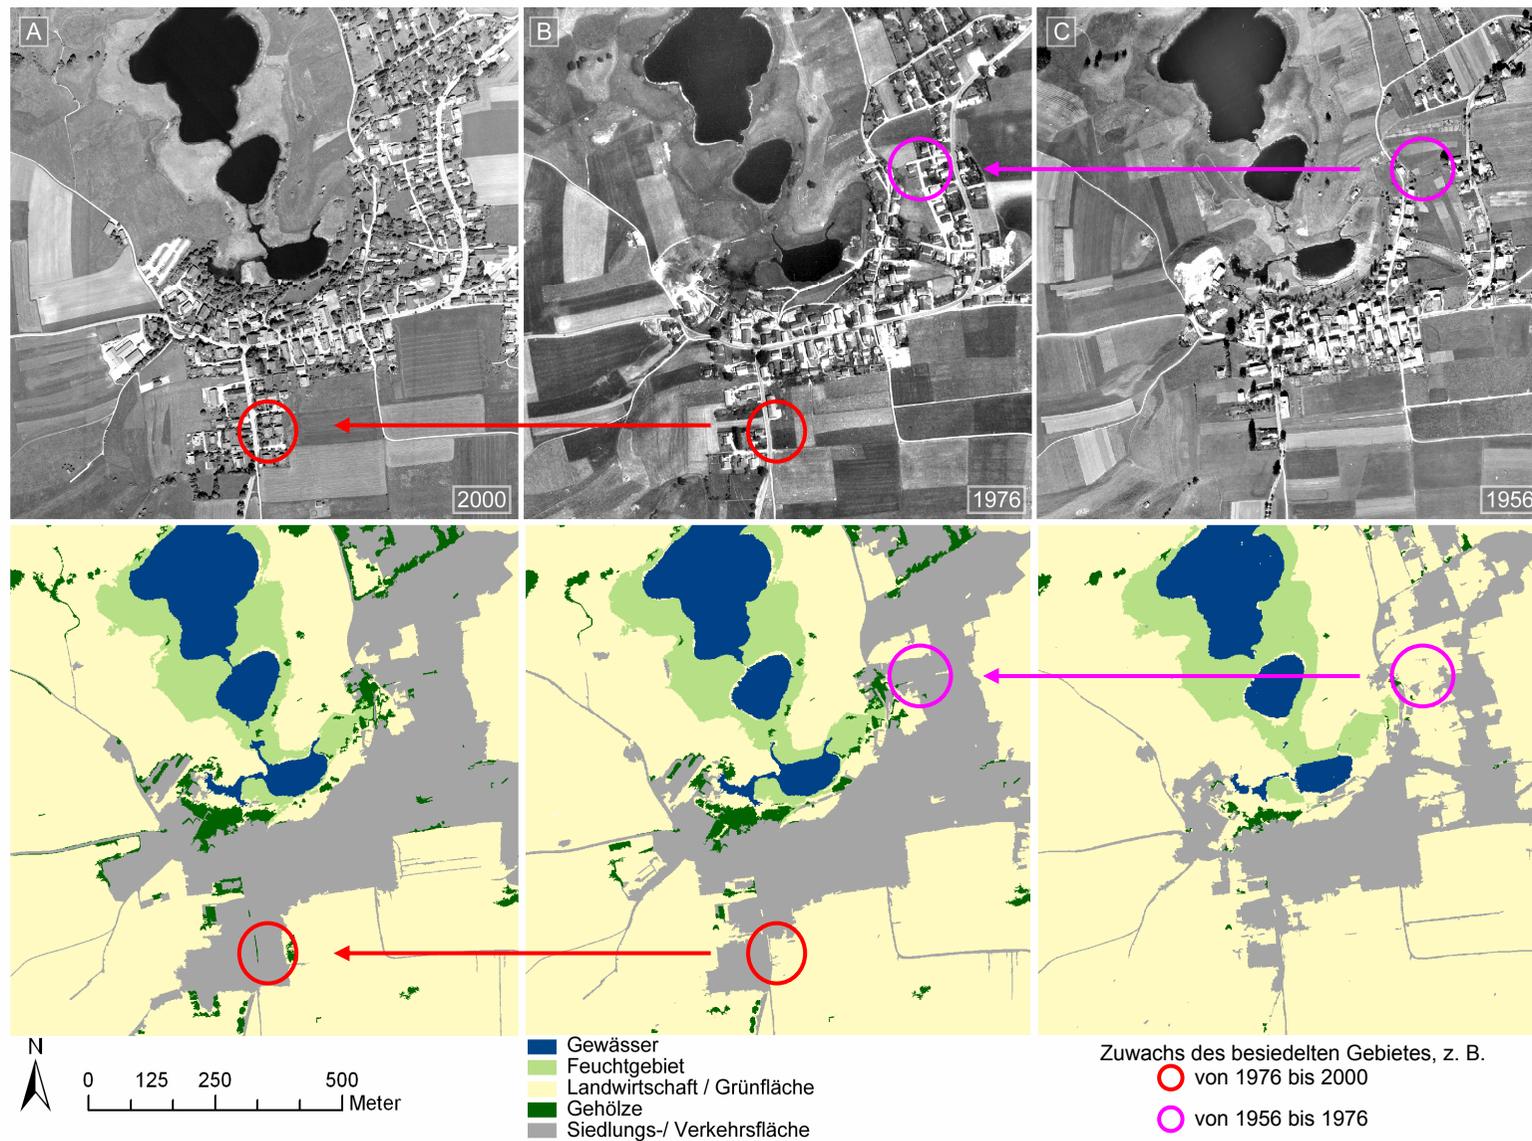
z. B. Höhenschwankungen von bis zu 8 m auf. Auch Objekthöhen von Baumgruppen oder Häusern waren zum Teil im DOM nicht korrekt erfaßt. Dennoch war die Objekthöhe gerade als „nicht obligates“ Merkmal hilfreich und als zusätzliche Informationsebene wertvoll.

Das Schema in Abbildung 64 stellt die Vorgehensweise bei der multitemporalen Luftbildanalyse dar.



**Abb. 65:** Ablaufschema der multitemporalen Luftbildanalyse. Die jeweils aktuellere Landnutzungsinformation dient als Eingangsdatensatz, um *a-priori* das Auftreten einer Klasse genauer zu prognostizieren (LN steht für Landnutzung; LuBi steht für Luftbild).

In Abb. 65 werden die Klassifikationen der Jahre 1956, 1976 und 2000 gezeigt, wobei beispielhaft Veränderungen im Siedlungsbereich der Ortschaft Iffeldorf besonders hervorgehoben werden.

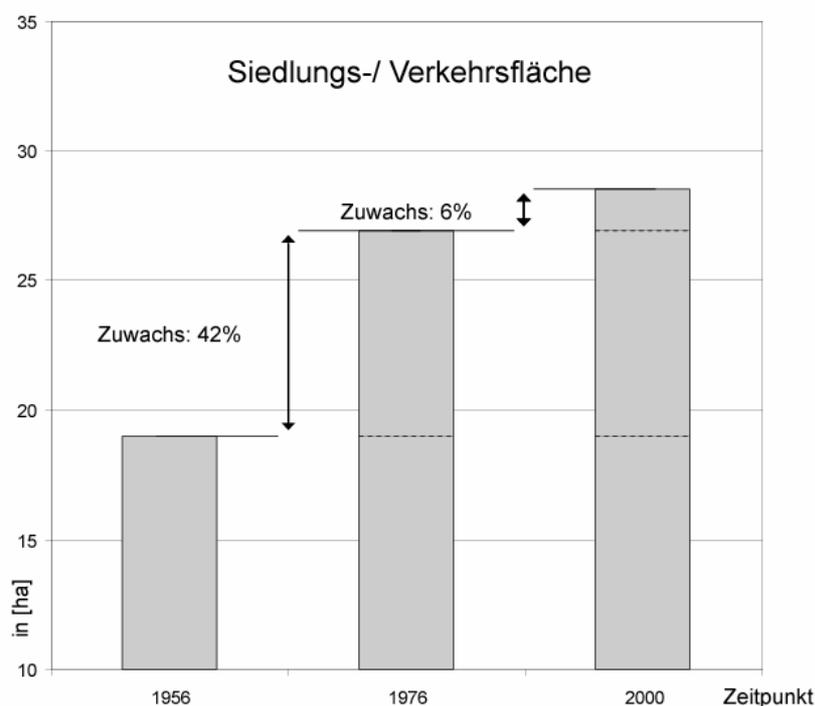


**Abb. 66:** Luftbilder von 2000 (A), 1976 (B) und 1956 (C) mit der entsprechenden Klassifikation mit eCognition darunter. Markiert sind Veränderungen im Siedlungsbereich die im Zeitraum von 1976 bis 2000 (roter Kreis), bzw. 1956 bis 1976 (violetter Kreis) aufgetreten sind.

Eine Genauigkeitsanalyse für die Klassifikationen der Jahre 1956 und 1976 war nicht möglich, da keine adäquaten Referenzdaten vorlagen. Zum Teil wirkten die Siedlungs- und Verkehrsflächen in den Ergebniskarten der Jahre 1956 und 1976 leicht „überklassifiziert“, d.h. etwas zu viele Bildobjekte wurden dieser Klasse zugewiesen. Nichtsdestotrotz schienen die Klassifikationen die realen Verhältnisse zuverlässig wiederzugeben.

### Entwicklungstrends

Siedlungs- und Verkehrsflächen veränderten sich im Untersuchungsgebiet am deutlichsten. Überwiegend landwirtschaftliche Flächen und Grünflächen wurden bebaut. In Abbildung 66 ist die Zunahme der Siedlungs- und Verkehrsflächen graphisch dargestellt.



**Abb. 67:** Zuwachs der Siedlungs- bzw. Verkehrsfläche im Untersuchungsgebiet um die Ortschaft Iffeldorf. Zwischen den Jahren 1956 und 1976 hat die Siedlungs- und Verkehrsfläche um 42 % zugenommen. Gemäßiger ist der Zuwachs von 6 % zwischen den Jahren 1976 und 2000.

Die Analyse ergab, daß die Siedlungs- und Verkehrsflächen in nur 44 Jahren um knapp 50 % zugenommen haben. Deutlich wird auch, daß sich die Zunahme des Flächenverbrauchs offensichtlich verlangsamt hat. Auf einen großen Zuwachs von 42 % zwischen den Jahren 1956 und 1976 folgte ein moderater Anstieg von 6 % zwischen 1976 und 2000.

## 6.3 Kombinierte Auswertung von GIS- und Fernerkundungsdaten

### 6.3.1 Fragestellung

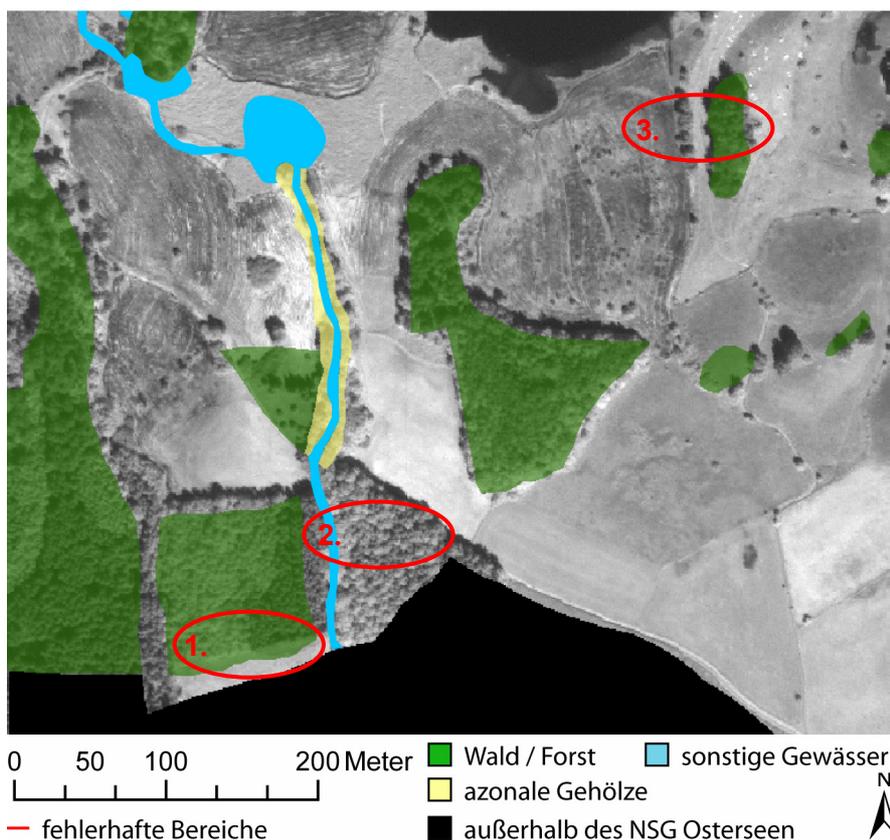
Ein aus der Zusammenführung bzw. kombinierten Auswertung von GIS-Daten und Informationen aus aktuellen Fernerkundungsdaten entstehender Mehrwert wurde bereits vielfach nachgewiesen. Die bisher durchgeführten Studien können in zwei Kategorien eingeteilt werden: sie konzentrierten sich entweder auf die räumliche Aktualisierung von GIS-Daten anhand von Fernerkundungsdaten (SMITS und ANNONI 1999) oder die Nutzung dieser Daten als externe Zusatzinformation, um z. B. Waldgesellschaften anhand von Höhenlagen besser zu differenzieren (BUCK et al. 1999). Die hier vorgestellte Fallstudie vereinigt beide Ansätze: vorhandene Geoinformation wurde thematisch genutzt und im nächsten Schritt aktualisiert. Dabei kamen die topologischen Werkzeuge, die durch den objektorientierten Ansatz zur Verfügung stehen, zum Einsatz.

Als Beispiel wurde ein Ausschnitt aus der Seeuferkartierung Bayerns (SUK, Kap. 5.3.1) im Bereich der Osterseen mit IKONOS-Daten vom August 2001 verglichen. Dabei wurden verschiedene Ungenauigkeiten bzw. Unzulänglichkeiten der SUK daraufhin überprüft, ob und in welcher Weise diese Defizite durch die Zusammenführung der beiden Informationsquellen behoben werden können. Dargestellt wird dies beispielhaft an Gehölz- und Waldbeständen.

Die Basisklassen für Gehölz- und Waldbestände der SUK lauteten „Azonale Gehölze“ und „Wald / Forst“. Unter die Klasse „Azonale Gehölze“ fielen Waldgesellschaften, die an einen bestimmten ökologischen Faktor gebunden sind. In diesem Fallbeispiel waren die azonalen Gehölze durch einen feuchten Bodenstandort geprägt. Konkret handelte es sich um einen dichten, geschlossenen Gehölzsaum entlang des Steinbachs westlich von Iffeldorf. Die hauptsächlich vorkommenden Baumarten waren Ahorn, Esche, Fichte und Eiche. Diese Information war nicht aus den IKONOS-Daten ableitbar, sondern wurde durch eine terrestrische Untersuchung ermittelt. Die Klasse „Wald / Forst“ faßte die übrigen, zum Teil auch forstwirtschaftlich geprägten Waldgesellschaften zusammen.

Die digitale SUK wies aus heutiger Sicht verschiedene „Problemzonen“ auf, die durch die aktuellen IKONOS-Daten korrigiert werden sollten. Wie in Abbildung 67 dargestellt, waren dies:

- **Geometrische Fehler und Lageungenauigkeiten:** verglichen mit den aktuellen IKONOS-Daten fielen Lagefehler und ungenaue Geometrien auf. Die geometrischen Ungenauigkeiten waren durch die Herstellungsweise der SUK bedingt. Im Produktionsjahr 1987 wurde die SUK zunächst als analoges Kartenwerk angefertigt. Die Übertragung in ein digitales Datenformat brachte systembedingte geometrische Ungenauigkeiten mit sich. Als Folge davon lagen die Polygongrenzen zum Teil zwischen 1 m und 10 m verschoben bezogen auf die korrekt georeferenzierten IKONOS-Daten (Abb. 67 (1)). Der Lagefehler war nicht einheitlich und konnte deshalb auch nicht durch ein geometrisches Modell korrigiert werden.
- **Kartierfehler:** ein Teil der Waldflächen sind von der SUK offensichtlich nicht erfaßt worden. Aufgrund der Größe der Bäume müssen diese bereits 1987 existiert haben (Abb. 67 (2)).
- **Aktualität der Kartierung:** zwischen den IKONOS-Aufnahmen und der SUK lagen 14 Jahre. Einige kleinere Baumgruppen und Gehölze wurden in der SUK nicht berücksichtigt. Dies mag am Kartiermaßstab von damals liegen oder u.U. auch daran, daß sich die in den IKONOS-Aufnahmen abgebildeten Gehölze erst in den letzten zwei Jahrzehnten entwickelt haben (Abb. 67 (3)).



**Abb. 68:** IKONOS-PAN-Daten überlagert mit der SUK 1987. Maskiert sind drei Problemzonen: besonders auffallend sind Lagefehler (rote Ellipse, 1) und nicht kartierte Bereiche (rote Ellipse, 2 und 3).

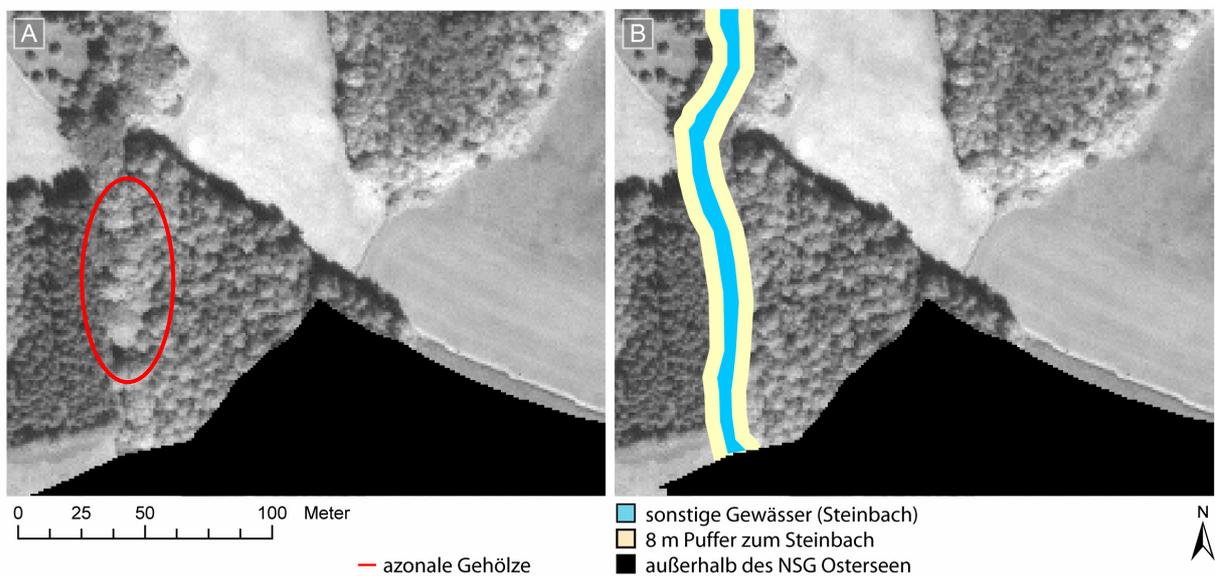
### 6.3.2 Segmentierung und Wissensmodellierung

Die **Eingangsdaten** (IKONOS August-Aufnahme und Shape-Datei der SUK) wurden mit einem *Scale*-Faktor von 40 auf einer Ebene **segmentiert**. Das Homogenitätskriterium war mit einem *Color*-Wert von 0,8 gewichtet, wobei der verbleibende *Shape*-Anteil mit 0,2 auf *Smoothness* und 0,8 auf *Compactness* aufgeteilt wurde. Der vergleichsweise hohe *Compactness*-Parameter führte zu dem gewünschten Ergebnis weniger fraktal geformter Bildobjekte. Die resultierenden Bildobjekte entsprachen einer durchschnittlichen Fläche von 200 m<sup>2</sup>.

Die **Wissensmodellierung** für die Klassen „Azonale Gehölze“ und „Wald / Forst“ nutzte die thematischen Informationen der SUK. Es wurde davon ausgegangen, daß diese Klassen in der Zusammensetzung und Ausprägung im Naturschutzgebiet weitgehend unverändert blieben. Innerhalb der Ausdehnung der Basisklassen in der SUK wurden die aktuellen Spektral- und Texturwerte der IKONOS-Daten abgefragt. Waren die Werte plausibel für Gehölze und Bäume, so wurde die Information der SUK als „richtig“ übernommen. In Bereichen, in denen die IKONOS-Daten mehr auf einen anderen Nutzungstyp hinwiesen, wurden sie keiner Klasse zugewiesen.

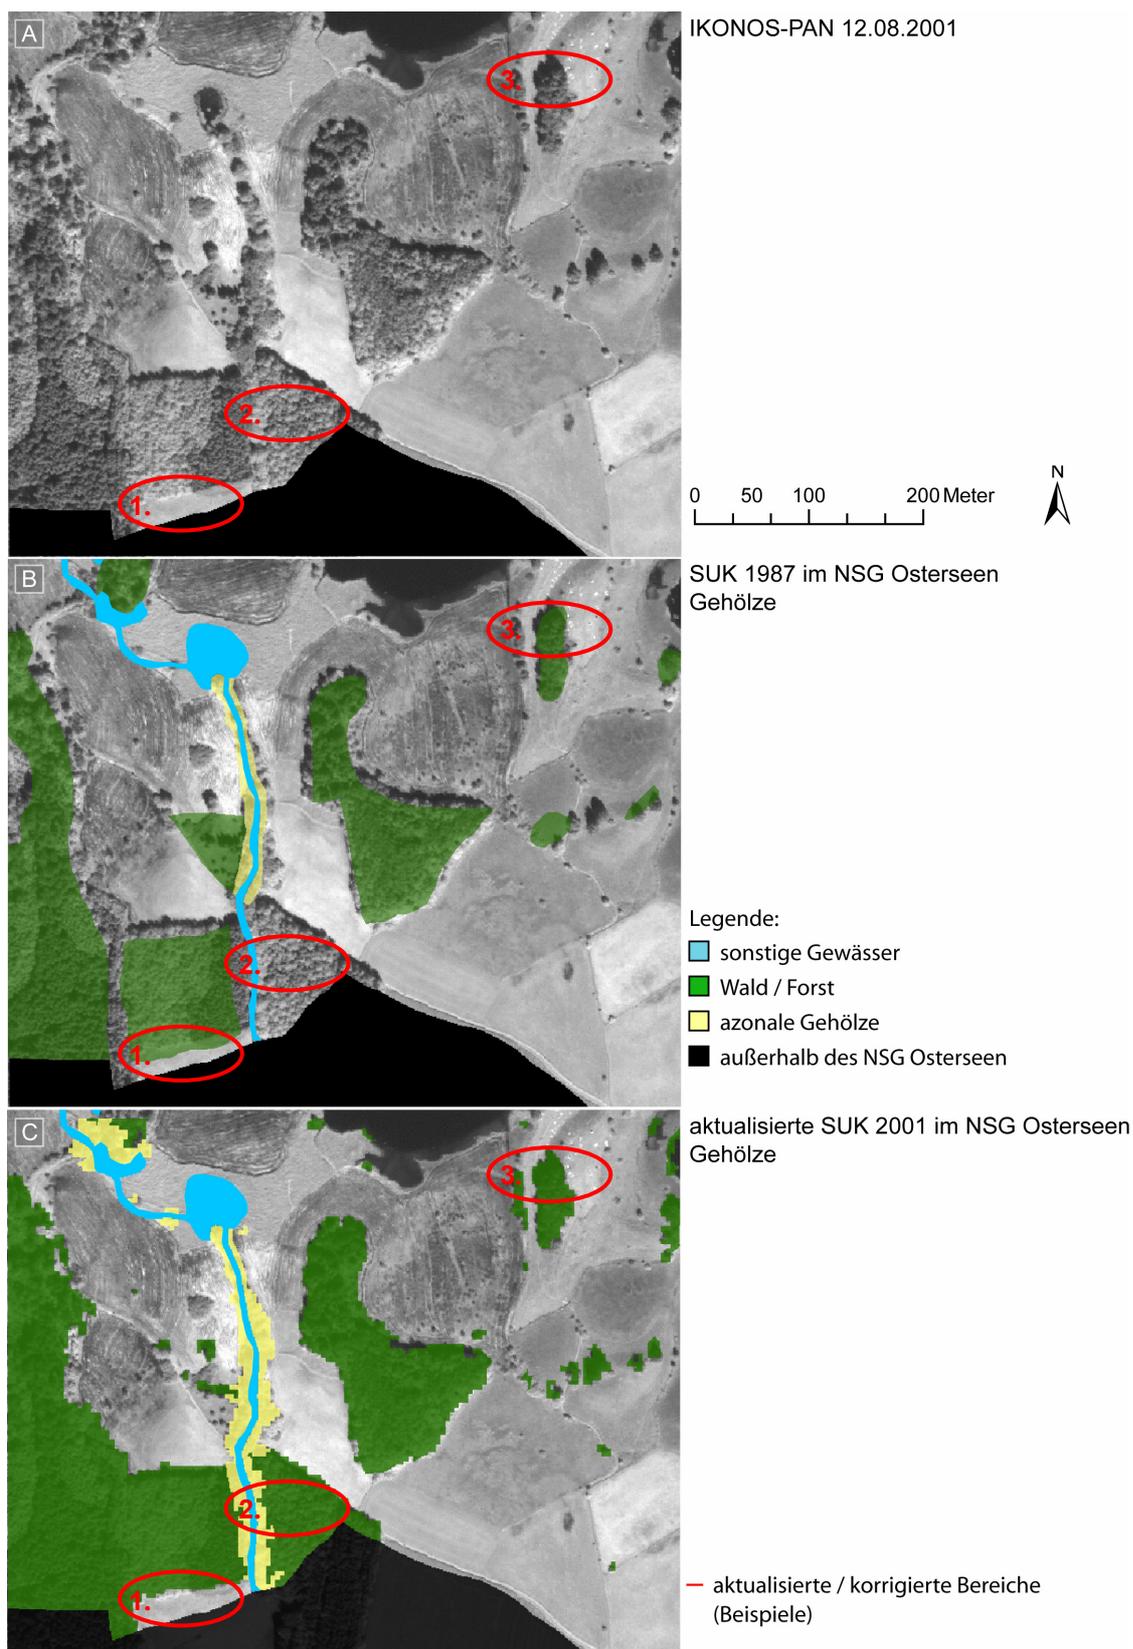
Bei der Klasse „Azonale Gehölze“ wurde die SUK auf eine besondere Weise genutzt. Diese Waldgesellschaften ließen sich aus den IKONOS-Daten allein nicht extrahieren, da sich die Kronenstruktur nur unwesentlich von anderen Waldtypen unterscheidet (obschon in den PAN-Daten visuell ein leichter Textur- und Helligkeitsunterschied feststellbar war (Abb. 68 (A)) Auch der für azonale Waldgesellschaften wichtige Standortfaktor (hier: Feuchtigkeit) ließ sich gleichfalls nicht ermitteln. In der SUK war allerdings der Verlauf des Steinbachs verzeichnet, wenn auch mit dem bereits erwähnten

Lagefehler, der hier 1-4 m betrug. Im Regelwerk für die Klassifikation der azonalen Gehölze wurde der Bachlauf als Feuchtindikator verwendet. Gehölzstrukturen, die innerhalb einer Distanz von 0 m - 10 m zum Steinbach lagen, wurden als azonale Gehölze klassifiziert. Der visuelle Eindruck aus den PAN-Daten und auch Vor-Ort-Untersuchungen bestätigten diese Annahme. Im Regelwerk wurde diese Distanz-Bedingung durch eine *fuzzy*-Beziehung beschrieben: je näher ein Bildobjekt (dessen Textur- und Spektralwerte für ein Gehölz sprechen) am Bachlauf liegt, desto höher ist die Wahrscheinlichkeit, daß es sich um ein azonales Gehölz handelt. Ein Gehölz-Objekt mit einer Distanz von 0 m bis 5 m bekam eine volle *fuzzy*-Zugehörigkeit von 1,0 zur Klasse „Azonale Gehölze“ zugewiesen. Bei einer Distanz von 5 m bis 10 m sank die Zugehörigkeit graduell auf null, was bedeutet, daß Gehölze die mehr als 10 m vom Bachlauf entfernt waren, der Klasse „Wald / Forst“ zugewiesen wurden. Zum besseren Verständnis ist in Abbildung 68 (B) ein Distanzpuffer von 8 m bildlich dargestellt. Ein Vergleich der PAN-Daten (Abb. 68 (A)) und des Distanz-Puffers (Abb. 68 (B)) läßt die Beziehung zwischen dem Verlauf des Steinbachs und den azonalen Gehölzen erkennen.



**Abb. 69:** Azonale Gehölze im NSG Osterseen. Auf der PAN-Szene (A) ist ein leichter Texturunterschied des azonalen Gehölzsaums entlang des Steinbachs erkennbar (Verlauf in (B)). Dieser Unterschied ist jedoch nicht ausreichend um den bachbegleitenden Gehölzsaum korrekt zu klassifizieren. Mit Hilfe der Information aus der SUK, die den Bachlauf des Steinbachs beschreibt (B), läßt sich eine Klassifikationsregel formulieren: „Waldgesellschaften, die in der Nähe des Bachlaufs liegen, werden der Klasse `Azonale Gehölze` zugewiesen“.

Im nächsten **Klassifikationsschritt** ging man von der Nachbarschaft bzw. Distanz zu bereits gefundenen Regionen aus. Waren in der Nähe eines bereits klassifizierten Bildobjekts weitere Gehölze oder Bäume, so wurden diese der nächstgelegenen Klasse entsprechend zugewiesen. Auf diese Weise konnten weitere Baumgruppen erfaßt und den Klassen „Azonale Gehölze“ bzw. „Wald / Forst“ zugewiesen werden. Damit ließen sich die „Problemzonen“ der SUK korrigieren bzw. aktualisieren. Die Abbildung 69 zeigt einen Vergleich der IKONOS-PAN Daten vom August 2001, der SUK von 1987 und der aktualisierten SUK.



**Abb. 70:** Fallbeispiel Seeuferkartierung. IKONOS PAN Szene August 2001 (A), Seeuferkartierung (SUK) aus dem Jahr 1987 über einer IKONOS-PAN Szene aus dem Naturschutzgebiet Osterseen (B). Erkennbar sind Lageungenauigkeiten (1), nicht erfaßte Strukturen (2, 3). In (C) ist die aktualisierte Klassifikation dargestellt. Die vorhandenen Abgrenzungen wurden genauer erfaßt und erweitert (1, 2, 3).

### 6.3.3 Ergebnisse

Die **Genauigkeit** des erzielten **Ergebnisses** wurde visuell abgeschätzt. Die Überprüfung ergab, daß bis auf wenige Einzelbäume die Ausdehnung der Klassen sehr genau abgebildet worden ist. Vor allem in Bezug auf Bereiche, die 1987 nicht als Gehölze erfaßt wurden, war eine erhebliche Verbesserung zu erkennen (Abb. 69 (2)). Der azonale Gehölzsaum entlang des Steinbachs ließ sich durch die zusammengelegte Bewertung der thematischen Information aus der SUK und den Satellitendaten korrekt klassifizieren.

Ferner konnte gezeigt werden, daß eine Aktualisierung der Flächenabgrenzungen automatisiert erreichbar ist. Auch Ungenauigkeiten bei der Co-Registrierung verschiedener Datensätze konnten durch eine intelligente Formulierung von topologischen Beziehungen behoben werden. Die vorgestellten Ergebnisse beschränken sich beispielhaft auf die Darstellung der Ansätze für „Azonale Gehölze“ und „Wald / Forst“. Grundsätzlich sind ähnliche Ergebnisse bzw. Korrekturen auch für andere Klassen der SUK durch eine kombinierte Auswertung von Karteninformationen und aktuelleren Satellitenbilddaten möglich.

## 7 Diskussion

In den vorstehenden Kapiteln wurde gezeigt, auf welche Weise und mit welcher Genauigkeit großmaßstäbliche Landnutzungsinformationen durch die neuen, hochauflösenden Satellitendaten der IKONOS-Generation sowie durch Luftbilddaufnahmen erfaßt werden können. Der objektorientierte Ansatz ermöglichte es, die Wahrnehmung eines Interpretens zu modellieren und dabei Expertenwissen verschiedenster Art in Regelwerken zu formalisieren. Wie anhand der Fallstudien nachgewiesen wurde, konnte die Landnutzung sehr genau, nachvollziehbar und automatisch erfaßt werden.

Die entwickelten Ansätze und Regelwerke zeigen einen neuen, vielversprechenden Weg auf, um die Klassifikation von Fernerkundungsdaten weiter zu operationalisieren. Damit wird es möglich, die Erfassung der Landnutzung, welche für die Umsetzung von Naturschutzrichtlinien (Fauna-Flora-Habitat-Richtlinie, Wasserrahmen-Richtlinie) und landwirtschaftlichen Programmen (Agrarumweltmaßnahmen, Cross Compliance) notwendig ist, effektiver durchzuführen und ein Monitoringsystem aufzubauen mit dessen Hilfe vorhandene GIS-Daten aktualisiert, sensible Bereiche aufgespürt und Veränderungen nachgewiesen werden können. Auf die Notwendigkeit und Bedeutung solcher aktuellen, rasch wiederholbaren und kostengünstigen Informationen der Landnutzung hat u.a. AMMER (2004) hingewiesen.

Die in Kapitel 3 vorgestellte **strukturierte Vorgehensweise** für ein objektorientiertes Klassifikationsprojekt entspricht einer klassischen *Work Breakdown Structure* (Abb. 3). Dabei sind die Einzel-elemente und die notwendigen Schritte, die zum Projekterfolg führen, in hierarchisch gegliederter Form dargestellt. Eine solche Aufgliederung in einzelne Arbeitspakete ist nach WOLF et al. (2004) ein essentieller Teil einer professionellen Projektplanung. Das vorgestellte Konzept gibt zum einen dem Anwender eine umfassende Anleitung, zum anderen erhält der Endnutzer der Klassifikation einen transparenten Überblick, wie Ergebnisse zustande kommen. Auf diese Weise kann der von PRÖBSTL (2004) beschriebenen Skepsis der „Abnehmer“ von Kartenprodukten auf Basis von Fernerkundungsdaten in Bezug auf Qualität und Aussageschärfe entgegen gewirkt werden.

### 7.1 Vorverarbeitung

Ein aufwendiger Vorverarbeitungsschritt war die **Orthorektifikation** der IKONOS-Daten, die nach BALSAVIAS (2004) unbedingte Voraussetzung ist, wenn verschiedene Daten miteinander verglichen werden. Zu Beginn des AQUATIC-Projekts lagen noch keine Daten zur Aufnahmegeometrie vor, die für eine Orthorektifikation notwendig sind. Diese wurden erst nach zwei Drittel der Projektlaufzeit (im März 2003) von SpaceImaging nachgeliefert. Deshalb wurde zunächst versucht, die Entzerrung mit einem geometrischen Polynomial-Modell zu bewerkstelligen. Die dabei erreichten Lagegenauigkeiten wiesen einen Mittleren Quadratischen Fehler (MQF) von mehr als 4,5 m auf (Tab. 1). Nachdem die Aufnahmegeometrie-Daten zur Verfügung standen, wurde eine **photogrammetrische Entzerrung** durchgeführt, die einen MQF von 0,9 m aufwies. Der Vergleich zwischen beiden Methoden bestätigt die Erfahrung von TOUTIN (2004), wonach ein photogrammetrisches Entzerrungsmodell, das die Aufnahmegeometrie eines Datensatzes berücksichtigt, bessere Ergebnisse erzielt als ein geometrisches Modell.

Die Lagegenauigkeiten der IKONOS-Daten bewegten sich insgesamt im Rahmen dessen, was KELLENBERGER (2002) bei der Entzerrung von IKONOS-Daten der Schweiz erreichte. Während

KELLENBERGER (2002) jedoch eine Anzahl von mindestens 20 Paßpunkten pro Szene fordert, hat sich in dieser Studie gezeigt, daß 14 Paßpunkte, die gut über die gesamte Aufnahme­fläche verteilt lagen, ausreichend waren, um Genauigkeiten mit einem **MQF von weniger als 1 m** zu erzielen. Nach LEICA GEOSYSTEMS (2002a) sollte eine Lagegenauigkeit in dieser Größenordnung erreicht werden.

KERSTEN et al. (2000) empfehlen für die Rektifikation von IKONOS-Daten ein Geländemodell mit 0,5 m Auflösung. Die vorliegende Studie ergab, daß bereits eine Auflösung von 50 m ausreicht (z. B. **Basis-DGM-25**), um die geforderten Genauigkeiten zu erzielen. Dies ist eine wichtige Erkenntnis, denn höher aufgelöste digitale Geländemodelle (DGM) sind meist nicht verfügbar und darüber hinaus mit erheblichen Kosten verbunden.

SpaceImaging vertreibt unter dem Namen „Precision-Product“ orthorektifizierte Bilddaten. Bei diesen Daten wird ein maximaler MQF von 1,9 m vom Vertreiber garantiert. Die hier erreichten MQF-Werte waren um mehr als den Faktor zwei besser. Da zum einen die erreichbare **Lagegenauigkeit bei eigenhändiger Entzerrung höher** ist, und zum anderen der **Preisunterschied** zwischen dem rektifizierten Precision-Produkt und dem verwendeten Orthokit-Produkt 80 \$ pro km<sup>2</sup> (Preise vom Mai 2005) beträgt, lohnt es sich die Entzerrung selbst durchzuführen, auch wenn der Aufwand und die Lizenzkosten für ein photogrammetrisches Softwarepaket dabei zu berücksichtigen sind.

## 7.2 Klassifikationsstrategien

Die in dieser Arbeit entwickelten Klassifikationsstrategien für IKONOS-Daten lassen sich in drei wesentliche Arbeitsschritte gliedern. Der erste und entscheidende Schritt war die **Segmentierung** der Bilddaten, denn das Auswertergebnis steht und fällt mit der Qualität der Bildobjekte (JOHANSSON 1994). Bei der darauf folgenden **Wissensmodellierung**, die bislang den „Flaschenhals“ der wissensbasierten Analyse darstellte (BALSAVIAS 2004), erlaubten es die vielfältigen Möglichkeiten des objektorientierten Ansatzes, Expertenwissen in Regelwerken zu formalisieren. Die abschließende **Genauigkeitsanalyse**, die in keiner Studie fehlen sollte (FOODY 2002), bestätigte die Aussagekraft der Ergebnisse.

### Segmentierung

Die gesuchten Landnutzungstypen konnten durch die in dieser Arbeit verwendete Segmentierung sehr gut erfaßt werden. Entsprechend der Studie von NEUBERT und MEINEL (2003) wurde die Qualität der Segmentierung visuell abgeschätzt, weil ein objektiver Bewertungsstandard, wie bereits GUINDON (2000) feststellte, bislang fehlt.

Durch die Segmentierung wurden in sich geschlossene, **zusammenhängende Bildobjekte** erzeugt, die in einem GIS weiterführend analysiert werden können. Dies kommt den Bedürfnissen der Endnutzer entgegen, die häufig, wie beispielsweise in der Wasserwirtschaft (ARZET 2004), eine Verknüpfung von Fernerkundungsdaten und Geografischen Informationssystemen benötigen.

Eine systematische Schwierigkeit ergab sich bei der Klassifikation von **Verkehrskörpern**. Diese konnten zum Teil nicht zusammenhängend erkannt werden, da Fernerkundungsdaten nur eine „Aufsicht“ der Erdoberfläche liefern. Das bedeutet, daß z. B. Straßen oder Eisenbahnschienen, die von Baumkronen verdeckt waren, nicht durchgehend erfaßt werden konnten. Obschon es aus der Photogrammetrie Lösungsansätze für dieses Problem gibt, sind nach HINZ und BAUMGARTNER (2003) noch immer viele der hierbei auftretenden Hindernisse nicht beseitigt. Eine Möglichkeit, um diese

Problematik zu umgehen, ist von RÜCKER et al. (2005) demonstriert worden: in ihrem objektbasierten Ansatz verwendeten sie Flurkarten als Zusatzinformation bei der Segmentierung. Die darin enthaltenen Straßengeometrien ermöglichten die Detektion eines zusammenhängenden Straßennetzes und erlaubten so die Klassifikation der tatsächlichen Bodenbedeckung.

Im objektorientierten Verfahren bestimmt die iterative Auswahl des **Scale-Faktors** bei der Segmentierung die jeweilige Beobachtungsskala. KOCH et al. (2003) weisen darauf hin, daß diese Auswahl der subjektiven Wahrnehmung des Bearbeiters unterliegt und damit die Übertragbarkeit des Verfahrens einschränkt. Auch andere in der Fernerkundungsmethodik häufig eingesetzte Parameter wurden iterativ entwickelt und verbessert, wie z. B. Vegetationsindizes (RONDEAUX et al. 1996). Wird diese Erfahrung auf die im iterativen Verfahren ermittelten Segmentierungsparameter übertragen, so spricht nichts gegen die Verwendung der Parameter auf ähnliche Fragestellungen und Bilddaten. Die Praxis wird zeigen, in welchem Umfang sich die gefundenen Segmentierungseinstellungen bewähren. In diesem Zusammenhang wäre eine Untersuchung wünschenswert, die sich damit befaßt inwieweit die Segmentierung von den unterschiedlichen Aufnahmebedingungen beeinflusst wird.

In einer vergleichenden Studie von NEUBERT und MEINEL (2003) erzielte der Segmentierungsalgorithmus von eCognition gegenüber sechs anderen Algorithmen die besten Ergebnisse. Diese hohe **Qualität der Segmentierung** konnte in der vorliegenden Arbeit bestätigt werden. Lediglich einige wenige Bildobjekte entsprachen nicht den Erwartungen. So wurde beispielsweise ist der Forst in Abbildung 24 (A) durch ein Bildobjekt repräsentiert, das völlig willkürlich erscheint, während die Abgrenzung der Baumreihe in Abbildung 23 (A) sehr gut und genau erfolgte. Auch NEUBERT und MEINEL (2003) fanden bei der eCognition-Segmentierung „bisweilen unsinnige, irregulär geformte Segmente“. Als Ursache dafür konnte eine prinzipielle Eigenheit des verwendeten Segmentierungsalgorithmus identifiziert werden. In den Segmentierungseinstellungen ist die maximal „erlaubte“ Heterogenität eines Segmentes vorgegeben. Wenn der Schwellenwert für die Heterogenität überschritten wird, dann zieht der Algorithmus eine Objektgrenze, die, wenngleich mathematisch abgesichert, nicht immer nachvollziehbar ist. Solche irregulären Grenzen treten nur innerhalb von großflächigen Landbedeckungen auf, wo keine Textur- und Spektralkontraste für eine andere Klasse sprechen. Durch dieses Vorgehen wird verhindert, daß problematische Mischsegmente entstehen, die Elemente aus verschiedenen Klassen enthalten. Aus diesem Grund kann es zur Klassifikation irregulär geformter Bildobjekte kommen, sofern keine obligaten Formattribute verwendet werden.

Die **Form** eines Segmentes korreliert mit den Segmentierungseinstellungen. Da die Komplexität der Landbedeckung nie vollständig durch eine Segmentierung wiedergegeben werden kann (BURNETT und BLASCHKE 2003), ist ein Formattribut immer nur als Indiz zu werten. Die Untersuchung dreier Formattribute (Abb. 44) sowie die bildliche Darstellung verschiedener Formattribute (Abb. 45) belegten diese Hypothese: obschon beispielsweise Straßenverkehrskörper zu einer länglichen Form tendieren, gab es zahlreiche Überschneidungen mit anderen Klassen (Abb. 44). Formattribute können daher nur in Verknüpfung mit weiteren Objekteigenschaften zu einer treffsicheren Detektion führen.

Die Detailstudie der Formeigenschaft *Rectangular Fit* (Abb. 55) ergab, daß die **Segmentierungsskala** einen großen Einfluß auf die Aussagekraft dieses Formattributs hat. Das bedeutet, daß durch intelligente Segmentierungseinstellungen die Aussagekraft von Formattributen erheblich verbessert werden kann. Deshalb muß bereits bei der Wahl der Segmentierungsparameter bekannt sein, welche Klassen auf einer Skalenebene gefunden werden sollen. Die Schlußfolgerung daraus deckt sich mit der Forderung von GUINDON (1997), wonach die Segmentierung eines Bilddatensatzes zielgerichtet verlaufen und sich an dem erwarteten thematischen Bildinhalt orientieren muß.

Zusammenfassend kann gesagt werden, daß sich der in dieser Arbeit verwendete Segmentierungsalgorithmus als erfolgreich erwiesen hat und für Klassifikationsprojekte empfohlen werden kann. Der arbeitsintensive Prozeß der manuellen Delinierung konnte durch die Segmentierung ersetzt werden. Für die Zukunft ist wichtig, daß jede neue Studie über den objektorientierten Ansatz zusätzliche Hinweise für die „optimale“ Segmentierung liefert. Aus diesem Grund sollten **Erfahrungswerte über Segmentierungseinstellungen** in Abhängigkeit von Objektklassen und Sensoreigenschaften gesammelt werden. Dadurch ergäbe sich eine gewisse Standardisierung der Ergebnisse objektorientierter Analysen, vor allem aber könnte das zeitintensive, empirische Herantasten an die „passende“ Segmentierung erheblich vereinfacht werden.

### **Wissensmodellierung**

Bei der für die Auswertung der IKONOS-Daten eingesetzten Wissensmodellierung, wurden Klassifikationsregelwerke aufgebaut. Zu diesem Zweck konnten Objekteigenschaften identifiziert werden, die sowohl für die April- als auch für die August-Szene zielführend waren. Aufgrund der unterschiedlichen Aufnahmebedingungen mußten lediglich die Zugehörigkeitskurven angepaßt werden. DE KOK (2001) beschrieb die Merkmalsauswahl treffend mit „Qual der Wahl“. Aus der großen Fülle von Attributen, die dem Bearbeiter im objektorientierten Ansatz zur Verfügung stehen, muß eine Auswahl getroffen werden, welche die Zielklassen in den Regelwerken definiert. Die „Gretchenfrage“ lautet: Welche Attribute sollen eingesetzt werden um eine Objektklasse zu beschreiben? Wie ANDRESEN (2004) feststellte, führen verschiedene Wege zu vergleichbaren Ergebnissen. Die in dieser Arbeit ermittelten Attribute erwiesen sich für beide IKONOS-Szenen als geeignet. Damit konnte für diesen Datentyp ein wesentlicher Schritt in Richtung einer **Operationalisierung der Auswertung** getan werden, indem für die ausgewählten Zielklassen Attribute identifiziert wurden, die auch für die Klassifikation anderer IKONOS-Szenen verwendet werden können. Die Merkmalsauswahl basierte auf Expertenwissen, empirischen Untersuchungen und Boxplotanalysen und kann für IKONOS-Daten als gesichert betrachtet werden. Eine Übertragung auf andere IKONOS-Szenen erfordert, wie erwähnt, lediglich eine Anpassung der Wertebereiche.

Die hier verwendeten IKONOS-Aufnahmen wurden „vorwärts- und rückwärts-gerichtet“ erfaßt, also in Richtung der Sonneneinstrahlung (20.04.2001) und entgegen der Sonneneinstrahlung (12.08.2001). Nun ist bekannt, daß Gegenlichtaufnahmen weniger Reflexion empfangen als Mitlichtaufnahmen (HILDEBRANDT 1996). Die Boxplotanalysen bestätigten dies. Ein deutlicher Abfall der Reflexionswerte von April zu August war z. B. bei Nadelbäumen (Abb. 25 (A), Abb. 26 (A), Grünland (Abb. 54 (B)) und bei asphaltierten Straßen (Abb. 41 (A)) erkennbar, obwohl sich die Landbedeckung nicht änderte. Die Ursache der Reflexionsabnahme ist ein Phänomen, das als „**Anisotropie** der Reflexion“ bezeichnet wird (HILDEBRANDT 1996). Dabei hängt die Anisotropie vom relativen Winkel des Sensors zur Sonne ab sowie von der Rauigkeit der Oberflächenstrukturen und den Vegetationsgesellschaften. Sie stellt eine eigene Informationsebene dar, welche die Klassifikation von Vegetationsflächen unterstützen kann (KOCH et al. 1993). Die Anisotropie der Reflexion ist Bestandteil aktueller Forschung und wird z. B. in der Präzisionslandwirtschaft (MANAKOS 2003), für die Differenzierung von Schilfbeständen (SCHNEIDER et al. 2004) oder bei forstlichen Anwendungen (SOHLBACH 2002) untersucht. Während die **atmosphärische** und **topographische Korrektur** weitgehend von physikalischen Einflußgrößen abhängen und sich modellieren lassen (RICHTER 1997, HEEGE 2004), ist die Korrektur von blickwinkelabhängigen Auswirkungen auf das Spektralsignal wesentlich komplexer. Die Boxplotuntersuchungen zeigten, daß der Einfluß der Anisotropie auf das Reflexionssignal bei der Anpassung der Wertebereiche immer berücksichtigt werden muß. Das

IKONOS-System kann den Aufnahmesensor nicht nur orthogonal zur Bewegungsrichtung wie bisherige Systeme schwenken (z. B. SPOT-2), sondern hat alle Freiheitsgrade zur Verfügung. Damit erhöhen sich die Möglichkeiten des Aufnahmeblickwinkels für ein Untersuchungsgebiet um ein Vielfaches. Das bedeutet u.a. auch, daß der Einfluß der Anisotropie wesentlich größer sein kann. Bei der Bestellung von IKONOS-Daten hat der Kunde zwar die Möglichkeit Toleranzbereiche für die Steilheit des Aufnahmewinkels zu bestimmen, bezüglich des relativen Blickwinkels zur Sonne bestehen jedoch keine Auswahlmöglichkeiten. Vor allem bei längerfristigen Monitoringprojekten wäre es wünschenswert, wenn der Kunde für den relativen Sonnenwinkel Toleranzbereiche bestimmen könnte. Die damit verbundene Reduktion des Einflusses der Anisotropie würde die Vergleichbarkeit von Satellitenaufnahmen erhöhen und somit den Anpassungsaufwand bei der Erstellung der Regelwerke deutlich verringern.

Im Vorfeld des Aufbaus der Regelwerke wurden zahlreiche **Boxplotanalysen** durchgeführt, um Spektral- und Textur-Eigenschaften von IKONOS-Daten zu untersuchen und um die Attributauswahl nachvollziehbar zu gestalten. Die Visualisierung der Häufigkeitsverteilung durch Boxplots ist in den Naturwissenschaften weit verbreitet (BACKHAUS et al. 1996), hat jedoch bislang keinen Eingang in die objektorientierte Analyse gefunden. Dabei erwiesen sich Boxplots als außerordentlich zweckmäßig, um aussagekräftige Objekteigenschaften auszuwählen, wie z. B. die Analyse der NDVI-Werte gezeigt hat (Kap. 6.4). Bei der objektorientierten Analyse beeinflusst die statistische Verteilung der Objektwerte sowohl die Auswahl der Objekteigenschaften, als auch die Modellierung der Zugehörigkeitsfunktionen. Diese Information kann mittels **Boxplots übersichtlich dargestellt** werden und sollte künftig zum Standard für die Darstellung von Objektattributen gehören.

Darüber hinaus ging aus den Boxplotanalysen hervor, daß insbesondere bei winterkahlen Vegetationsbeständen oder bei landwirtschaftlichen Kulturen, wie z. B. Laubgehölzen (Abb. 26 (B)) oder Mais-Anbauflächen (Abb. 54 (A)) zeitlich prägnante Muster in den **Spektral- und Textureigenschaften** auftreten. Die Kenntnis dieser spezifischen zeitlichen Muster stellte eine zusätzliche Informationsquelle dar. Wie WIENEKE (1990) feststellte, sind Signaturen über die Zeit nicht konstant, da sich Pflanzengesellschaften über die Vegetationsperiode verändern. In dieser Arbeit konnten bei den landwirtschaftlichen Nutzflächen offener Boden, Mais-Anbauflächen und Grünland unterschieden werden. Für eine weitergehende Differenzierung von Agrarflächen könnte eine höhere zeitliche Auflösung weitere Vorteile bringen. In diesem Zusammenhang kann ein **lokaler phänologischer Kalender** hilfreich sein, um die zeitlichen Muster der Landbedeckung, die sich auch in Satellitendaten widerspiegeln, genau zu identifizieren und in einem Regelwerk wiederzugeben.

Die **Übertragbarkeit von Regelwerken** auf andere Fernerkundungsdaten ist eine Grundvoraussetzung eines operationellen Monitoringwerkzeugs. PAX-LENNEY et al. (2001) sehen in übertragbaren Klassifikationsansätzen für Landbedeckungen ein Ziel, dessen Erreichung laut BALTSAVIAS (2004), wohl eine Illusion bleiben wird. Wie beschrieben, war in dieser Arbeit eine einfache Übertragung der Regelwerke ohne Anpassung im Ergebnis unbefriedigend. Als Ursache hierfür ist die Instabilität der Bildgrundlage (Kap. 3.5.1) zu sehen. Obschon durch die **fuzzy-Modellierung** der Landbedeckungsklassen ein gewisser Spielraum gegeben ist, besteht immer die Notwendigkeit, die Zugehörigkeitskurven von instabilen Eigenschaften für jeden individuellen Fernerkundungsdatensatz anzupassen. Um eine Übertragbarkeit auf hohem Niveau zu gewährleisten, wird die Umrechnung der Reflexion in physikalische Meßwerte gefordert (ROBERTS et al. 1997, SCHNEIDER und ZIMMERMANN 2004). Erst dann können spezifische Reflexionsmuster einer Landbedeckung in allgemeingültigen Regelwerken formalisiert werden. Auch hier haben die

Spektralanalysen gezeigt, daß neben der Atmosphäre und der Topographie unbedingt auch der Anisotropie Rechnung getragen werden muß. Bislang werden in Spektraldatenbanken ausschließlich ungerichtete Signaturinformationen verwaltet. Solche Datenbanken sollten jedoch zusätzlich zur Wellenlänge und Landbedeckung auch Informationen zum Blickwinkel im Verhältnis zum Sonnenstand enthalten. Nur dann ist eine Signatur spezifisch, aussagekräftig und vergleichbar und kann die Grundlage eines übertragbaren Regelwerks darstellen.

**Topologische Beziehungen** erlauben es, die Wahrnehmung eines Interpreten in einer Rechnerumgebung „nachzuahmen“ (MATSUYAMA 1987). GURNEY und TOWNSHEND (1983) sehen überhaupt den Schlüssel zur automatischen Klassifikation komplexer Landschaften in der Verwendung topologischer Beziehungen. Vor diesem Hintergrund wurde großer Wert auf die Nutzung der Topologie gelegt. Insbesondere bei hochauflösenden Fernerkundungsdaten ist die verstärkte Nutzung kontextueller Information wichtig (GUINDON 2000). Sowohl multiskalare als auch nachbarschaftliche Beziehungen wurden eingesetzt, um Klassen zu beschreiben und Suchräume zu erweitern. In der vorliegenden Arbeit wurden topologische Beziehungen z. B. bei der Klassifikation von Waldbeständen verwendet (Kap. 6.1.4.1). Gemäß der Definition der Kartieranleitung (BFN 2002) wurden dabei kleinere beschattete Freiflächen in diese Klasse integriert. Ähnlich der Vorgehensweise eines Interpreten wurden Flächen aufgrund ihrer Farbe und geringen Größe zur umgebenden Gehölzklasse hinzugefügt und führten so zu einem homogeneren Ergebnis. BENZ et al. (2004) nennen topologische Beziehungen „höhere“ Merkmale, da sie erst nach einem ersten Klassifikationsdurchlauf verfügbar sind. Diese „höheren“ Attribute erlauben die Formulierung von semantischen Beziehungen der Objektklassen zueinander und sind für spezifische Fragestellungen stabil, d.h. **topologische Beziehungen sind übertragbar**.

Zur Klassifikation von besiedelten Gebieten wurden topologische Beziehungen mit Spektral- und Texturattributen verknüpft abgefragt. Die entwickelten Regelwerke nutzen topologische Beziehungen, die sich über mehrere Objektskalenebenen erstrecken, wie dies beispielhaft in der Detailstudie „**Iterative Klassifikationsstrategie zur Detektion von Siedlung, Verkehr, Freizeit (9000)**“ dargestellt wurde. Bei der hochkomplexen Klasse „Siedlung, Verkehr, Freizeit (9000)“ zeigte sich, daß weder Spektral- (Abb. 43, 45), Textur- (Abb. 43) noch Formattribute (Abb. 44, 45) eine umfassende Trennung erlaubten. HEROLD et al. (2003) beschreiben die Schwierigkeiten bei der Klassifikation urbaner und semi-urbaner Flächen mit bildpunktbasierter Methoden und sehen in einem objektorientierten Ansatz eine Möglichkeit, um diese Flächen genauer zu klassifizieren. Unter Nutzung der Möglichkeiten des **Bildobjektnetzwerks** konnten diese Erwartungen erfüllt werden. Dabei wurde die Siedlungsklasse sowohl unter Berücksichtigung der Unterobjekte, als auch in Bezug auf ihre Nachbarschaft detektiert. Bei dieser Detailstudie galten zwei Hypothesen, welche das „intuitive“ Wissen eines Interpreten beschreiben:

1. Siedlungsgebiete weisen versiegelte Elemente auf.
2. In der unmittelbaren Umgebung von Straßen und Siedlungsgebieten existiert eine höhere Wahrscheinlichkeit, daß selbige Klassen vermehrt auftreten.

Diese Elemente des Alltagswissens wurden in einem Regelwerk formalisiert. Zunächst erfolgte auf einer Ebene mit kleinen Objekten die Detektion versiegelter Flächen. Anschließend wurde dieser „Informationskeim“ auf einer höheren Ebene abgefragt. Hier wurden in einem ersten Schritt Siedlungsobjekte klassifiziert, in deren unmittelbarer Nachbarschaft die Klasse im Zuge der folgenden Klassifikationsschritte „selektiv gewachsen“ ist. In diesem Zusammenhang kann der Begriff der

Stratifikation erweitert werden. Im Gegensatz zur klassischen Stratifikation, bei der ein Suchraum durch eine externe Datenquelle eingeschränkt wird (BUCK 2001), führt das hier beschriebene Vorgehen zu einer schrittweisen Ausdehnung des Suchraums für eine Klasse. Dafür scheint der Begriff **iterative Stratifikation** geeignet: nach jedem Schritt erweitert sich der räumliche Suchraum für eine Klasse und die Zugehörigkeitswahrscheinlichkeiten werden iterativ aktualisiert. Durch ein derartiges „Iterieren mit Rückkopplung“ konnte die Klasse „Siedlung, Verkehr, Freizeit (9000)“ detektiert werden. MOTT et al. (2002b) stellten ein ähnliches Prinzip auf Bildpunktebene vor und konnten zeigen, daß diese Vorgehensweise die Klassifikationsgenauigkeit erheblich verbessert. Sie verweisen dabei auf die Möglichkeit, den iterativen Ansatz auf Bildobjekte zu übertragen, was für Siedlungsgebiete in dieser Studie erfolgreich umgesetzt wurde.

Stabile Eigenschaften wie topologische Beziehungen können auf ähnliche Fragestellungen übertragen werden. Wie TON et al. (1991) in einer frühen Studie fordern, sollten deshalb solche Beziehungen gesammelt und in eine Form gebracht werden, die am Rechner verarbeitet werden kann. Während sich Signaturen aus Daten ableiten lassen, ist die Formulierung von topologischen Beziehungen ein aktiver Prozeß, der Expertenwissen erfordert und den Anspruch von Allgemeingültigkeit hat. Mit eCognition lassen sich solche Beziehungen in einer Rechnerumgebung formalisieren. Die konsequente Fortführung der Idee von TON et al. (1991) ist, eCognition-Regelwerke in einer Datenbank zu sammeln. Eine solche **Regelwerk-Bibliothek** enthält Informationen zum Datentyp, zum Untersuchungsgebiet, zu den modellierten Klassen, den verwendeten Segmentierungsparametern sowie instabilen und stabilen Zugehörigkeitsfunktionen. ECognition gibt die Regelwerke im Format XML<sup>1</sup> aus. Wünschenswert wäre die Entwicklung eines Software-Werkzeugs, das diese Regelwerke ordnet und in einer WEB-gestützten Datenbank ablegt. Das Ziel muß sein das „**Rad nicht immer wieder neu erfinden**“ zu müssen, sondern auf bestehende Erfahrungen und vorhandenes Wissen aufzubauen und dieses zu erweitern.

### **Klassifikationsgenauigkeit**

Die geforderten **großmaßstäblichen Landnutzungsklassifikationen** ließen sich aus IKONOS-Daten ableiten. Die dabei erzielten Genauigkeiten lagen im Rahmen dessen, was auch ein erfahrener Interpret leisten kann (STRAND et al. 2002). Im Gegensatz zum Vorgehen eines Interpreten sind die Ergebnisse der objektorientierten Klassifikation jedoch reproduzierbar.

In dieser Studie lagen die Gesamtgenauigkeiten bei 89 % (April) bzw. 95 % (August). Im Vergleich dazu erzielen bildpunkt-basierte Methoden bei ähnlichen Fragestellungen ein weniger genaues Ergebnis (DREXEL 2002). Zur Klärung der Genauigkeitsfrage wurden GPS-Punkte im Untersuchungsgebiet gemessen und dem entsprechenden Bildobjekt jeweils die Klasse zugewiesen, die am zugehörigen GPS-Punkt im Gelände gefunden wurde. Es wurde angenommen, daß das gesamte Bildobjekt dieselbe Klasse wie der gemessene Bildpunkt aufweist. Diese Annahme konnte mit der Tatsache begründet werden, daß Bildobjekte die Homogenität der Datengrundlage wiedergeben (BAATZ und SCHÄPE 2000) und ein Objekt nur eine Landbedeckung repräsentiert.

Bei einer klassischen Genauigkeitsanalyse werden oft bestehende Landnutzungskarten als Referenz verwendet (FOODY 2002), wobei in einem solchen Fall die Referenz flächig vorliegt. Dagegen wird

---

<sup>1</sup> Extensible Markup Language (XML) ist ein Standard zur Erstellung strukturierter, maschinen- und menschenlesbarer Dateien (WIKIPEDIA.ORG 2005).

das bildpunktbasierte Klassifikationsprodukt von der Pixelgeometrie und von Mischpixeln geprägt und wirkt deswegen inhomogen. BLASCHKE et al. (2000) beschreiben dies als „*Salt and Pepper*“-Effekt<sup>1</sup>, der in der objektorientierten Bildanalyse vermieden wird. Gerade hier liegt die Stärke des objektorientierten Ansatzes: nicht jede pixelgroße Inhomogenität wird erfaßt, sondern es wird durch die Segmentierung über eine Fläche generalisiert. Um zu vermeiden, daß durch die Generalisierung wichtige Details verlorengehen, wie KOCH und IVITS (2002) beobachteten, wurde der Grad der Generalisierung über drei Segmentierungsskalen gestaffelt. So wurden z. B. in der vorliegenden Studie zunächst kleinstrukturierte Laub- und Nadelwälder auf einer Ebene unterschieden, um anschließend auf einer übergeordneten Ebene zu „Wald“ zusammengefaßt zu werden.

Der Mehrwert einer **multisaisonalen Auswertung** (COPPIN et al. 2004) wurde durch die Genauigkeitsanalysen bestätigt: die Gesamtgenauigkeit erhöhte sich durch die Implementierung der „saisonalen“ Komponente. Gegenüber den April-Ergebnissen wurde eine Verbesserung von 8 % erzielt, wenn beide Aufnahmen in die Auswertung eingingen. Der Vergleich zwischen den August-Ergebnissen und der multisaisonalen Auswertung ergab dagegen nur eine geringe Verbesserung zugunsten der multisaisonalen Auswertung (2 %). Bei der Planung eines Klassifikationsprojekts muß deshalb abgewogen werden, ob die Verbesserung der Genauigkeit den finanziellen Mehraufwand einer multisaisonalen Analyse aufwiegt. Aus den Erfahrungen dieser Arbeit kann gefolgert werden, daß **Satellitendaten, die gegen Ende der Vegetationsperiode** erhoben werden, für die hier untersuchten Fragestellungen zur Landnutzung besser geeignet sind. Bei Landbedeckungskartierungen, die als Input für Überschwemmungsmodellierungen dienen, sind z. B. Bilddaten erforderlich, die vor dem Blattaustrieb aufgenommen werden (RIEGER, mündl. Mitteilung 2004). Bei der Verwendung solcher Daten kann der Straßen- oder Flußverlauf besser detektiert werden, da die Strukturen nicht durch Bäume überschirmt werden. ANDRESEN (2004) und JENSEN et al. (1993) konnten zeigen, daß sich auch bestimmte Makrophytengesellschaften nur durch multisaisonale Daten genau bestimmen lassen. Eine allgemeingültige Empfehlung für den optimalen Aufnahmezeitpunkt kann also nicht gegeben werden, sondern muß immer in Zusammenhang mit den Zielvorgaben eines Klassifikationsprojekts gesehen werden.

Nach den Erfahrungen der vorliegenden Arbeit werden für ähnliche Fragestellungen Bilddaten empfohlen, die zu einem mittleren bis späten Zeitpunkt der Vegetationsperiode (Juli / August) aufgenommen werden. Die Klassifikationsgenauigkeit ist dann sehr gut und Laub- und Nadelgehölze können treffsicher unterschieden werden.

### 7.3 Data-fusion

Bei zwei der drei Fallstudien wurde vorhandene Geoinformation in den Auswerteprozess integriert. Die methodische Grundlage ist unter dem Begriff **data-fusion** bekannt und wird nach WALD (1999) wie folgt definiert: „*Verschiedene Datenquellen werden in einem methodischen Rahmen zusammengefaßt bewertet mit dem Ziel, ein qualitativ besseres Ergebnis zu erhalten*“. Bei der Auswertung von **multitemporalen Luftbildern** (Kap. 6.2) wurde in einem ersten Schritt die aktuelle Landnutzung ermittelt und das gewonnene Ergebnis anschließend bei der Klassifikation eines früheren

<sup>1</sup> Dieser Begriff stammt ursprünglich aus der Radar-Fernerkundung und die körnige Bildstruktur von Radardaten, die auf zufällig verteilte Störungen und Interferenzen zurückgehen (RICHARDS und JIA 1999).

Aufnahmezeitpunkts verwendet. Für die **kombinierte Auswertung von GIS- und Fernerkundungsdaten** (Kap. 6.3) wurden bestehende Kartenwerke als *a-priori* Information verwendet und im nächsten Schritt gezielt die Klassen „Azonale Gehölze“ und „Wald / Forst“ geometrisch und thematisch aktualisiert.

## Luftbilder

Die Bedeutung des Luftbildes als Lieferant großmaßstäblicher Landnutzungsinformationen ist für zahlreiche Anwendungen hinlänglich bekannt (HILDEBRANDT 1996). Bisher wurde die Luftbildauswertung in der Praxis meist von einem Interpreten durchgeführt (ARZET 2004), was angesichts der damit verbundenen Kosten die Entwicklung von alternativen Auswertemethoden wünschenswert macht. Das Luftbild hat trotz seiner hohen Auflösung und Detailgenauigkeit noch immer den Mangel *„nur begrenzt automatisch auswertbar zu sein“* (AMMER 2004).

In dieser Arbeit wurde deshalb eine Herangehensweise entwickelt die es erlaubt, **Schwarz/Weiß-Luftbilder** automatisch zu klassifizieren. Dies war für Luftbilder bislang nur bei sehr speziellen Fragestellungen möglich: TÖNJES und GROWE (1998) klassifizierten Straßenzüge, VALTA-HULKKONEN et al. (2003) detektierten Makrophyten aus NIR-Falschfarbenbildern und MCKEOWN et al. (1985) bewerteten Flughafenaufnahmen.

Zwei Herausforderungen, die mit der automatischen Auswertung von Luftbildern verbunden sind, konnten durch den objektorientierten Ansatz angesprochen werden: die **geringe Spektralinformation**, die im Vergleich zu multispektralen Daten einen erheblichen Nachteil darstellt (JENSEN et al. 1986), sowie die **hohe Varianz**, mit der Landbedeckungsklassen bei hochaufgelösten Bilddaten im Merkmalsraum dargestellt werden (KENNEWEG et al. 1991). Wie die Ergebnisse belegen, konnte das spektrale Informationsdefizit durch die verwendeten Form- und Texturparameter ausgeglichen werden, während die hohe Varianz durch die Segmentierung der Luftbilder reduziert werden konnte.

Auch die **thematische Tiefe**, also die Frage wie viele Klassen detektiert werden können, war angesichts der Tatsache, daß lediglich eine Grauwertebene als Information diente, zufriedenstellend. Bei der seit 1987 durchgeführten bayernweiten Luftbildbefliegung durch das LVA, werden seit dem Jahr 2002 nicht mehr Schwarz/Weiß- sondern Farbbilder aufgenommen. Das dürfte einen deutlichen Fortschritt bei der thematischen Genauigkeit mit sich bringen. Generell weckt die technologische Entwicklung auf dem Luftbildkamera-Sektor hohe Erwartungen. Neue digitale Kamera-Typen wie das DMC-Modell von Intergraph Z/I Imaging oder die UltraCam-D von Vexcel Imaging, verfügen über eine Datentiefe von 12 Bit und zeichnen sowohl im sichtbaren Spektrum als auch im nahen Infrarot auf. Die Spektralinformation sowie die hohe Datentiefe werden ein differenzierteres Bild der Landschaft ermöglichen, was dazu führt, daß mehr Klassen detektiert werden können.

Die hier entwickelten Regelwerke erlaubten es, die Landnutzung aus Schwarz/Weiß-Luftbildern mit Genauigkeiten von mehr als 85 % zu klassifizieren. Als Referenz für die Genauigkeitsanalyse diente eine visuelle Interpretation (KANGLER 2003). Die genaue Analyse der Klassifikationsunstimmigkeiten ergab, daß z. B. bei Gehölzstrukturen das Ergebnis des **objektorientierten Ansatzes näher an der Wirklichkeit** lag als die Referenz. Auch CONGALTON (1991) weist darauf hin, daß Referenzdaten, die unter anderen Vorgaben erfaßt wurden als die zu prüfende Klassifikation, zu falschen Schlußfolgerungen bei der Genauigkeitsanalyse führen können. Tatsächlich waren in der vorliegenden Studie mehr Flächen richtig klassifiziert, als nach der Genauigkeitsanalyse zu erwarten gewesen wäre.

## Multitemporale Analyse

Im bayerischen Landesvermessungsamt werden Luftbilder seit Beginn der 40er Jahre archiviert. Sie sind die einzige Fernerkundungsdatenquelle, die eine Analyse der Landschaftsentwicklung über mehr als fünf Jahrzehnte erlaubt. Dabei ist eine konsequente Umweltüberwachung nur möglich, wenn die Entwicklung einer Landschaft im Verlauf der Zeit beobachtet werden kann.

Die Übernahme der Regelwerke der Luftbilder aus dem Jahr 2000 für die Bilddaten der Jahre 1956 und 1976 führte ohne Anpassung der Zugehörigkeitsfunktionen nicht zu befriedigenden Ergebnissen. Unterschiedliche Belichtungsintensitäten, verschiedene Filmmaterialien und differierende räumliche Auflösungen waren die Ursache. Die bei den IKONOS-Aufnahmen beschriebene Instabilität der Reflexion war auch in den Luftbildern festzustellen. Für einen Interpreten stellt dies keine große Einschränkung dar, während sich rechnergestützte Verfahren nicht automatisch an veränderte Helligkeiten oder Kontraste anpassen können (ALBERTZ 2001).

Um den beschriebenen Mangel auszugleichen, wurde eine Idee von SCHNEIDER und AMMER (1998) aufgegriffen und weiterentwickelt. SCHNEIDER und AMMER (1998) schlagen vor, ausgehend von einer Erstinventur, den **Erwartungszustand** für die künftigen dynamischen Veränderungen einer Landschaft, anhand von Modellen zu prognostizieren. Bei der Auswertung der Luftbilddaten der Jahre 1976 und 1956 wurden *a-priori* Wahrscheinlichkeiten für das Auftreten bestimmter Klassen durch Hinzunahme der Klassifikation des jeweils vorherigen Zeitpunkts angepaßt. Auf diese Weise war es möglich einen Erwartungszustand für die dynamischen Veränderungen pro Klasse anzunehmen. So floß mittels der entwickelten Regelwerke Vorwissen über wahrscheinliche und unwahrscheinliche Entwicklungstendenzen ein. Wie auch GROWE (2000) feststellte, wird die Auswertung multitemporaler Luftbilder durch die Integration von **Wissen über zeitliche Zusammenhänge** erheblich erleichtert. GROWE (2000) formalisierte Wissen mit Hilfe von semantischen Netzen. Dadurch konnte er bauliche Veränderungen in Industriegebieten anhand von multitemporalen Luftbildern detektieren. In GROWEs (2000) Ansatz wurden die semantischen Netze über eine komplexe Syntaxsprache aufgebaut. Im Gegensatz dazu wurde in der vorliegenden Arbeit Wissen über eine graphische Benutzeroberfläche in Form von Regelwerken erstellt. Die Handhabung und Anpassung des Wissensmodells wurde dadurch erleichtert.

Die Vorgehensweise bei der Klassifikation historischer Luftbilder entsprach einer Form von **data-fusion**, mit der Eigenart, daß sämtliche Daten innerhalb eines Systems produziert wurden. Dies hatte den Vorteil, daß die Daten verlustfrei übertragen werden konnten und keine Inkonsistenzen aufwiesen, was nach HINTON (1996) bei *data-fusion*-Projekten eine häufige Fehlerquelle darstellt.

Wie die Detailstudie „**Entwicklungstrends**“ zeigt, ließ sich der Zuwachs der Gemeinde Iffeldorf von 1956 bis in das Jahr 2000 verfolgen. Dabei wurde die zunehmende Flächeninanspruchnahme für Siedlungs- und Verkehrsflächen erfaßt. Bayern führt mit einer täglichen Umwidmung von Freiflächen von 18,1 ha (2002) die westdeutschen Bundesländer an (LFU 2004). Diese Zahl ergibt sich aus den Statistischen Jahrbüchern des Bayerischen Landesamts für Statistik, wobei die Datenerfassung nur bis in das Jahr 1981 zurück reicht (LFU 2004). Der hier vorgestellte Ansatz bietet eine Möglichkeit bis in die 1950er Jahre und zum Teil sogar noch weiter zurück zu blicken.

In der vorgestellten Detailstudie ließ sich die Veränderung der **Flächenhaushaltspolitik**, die seit den 1950er Jahren auf Gemeinde-Ebene stattgefunden hat, sehr gut nachzeichnen: während in den Zeiten des Wirtschaftsaufschwungs die Siedlungs- und Verkehrsflächen stark zunahmen, hat der bewußte Umgang mit den Flächenressourcen in Iffeldorf von 1976 bis 2000 zu einem gemäßigeren Wachstum

geführt. Die ermittelten Zahlen liegen allerdings nicht im bayernweiten Trend, wonach der Zuwachs des Flächenverbrauchs nach wie vor zunimmt (LFU 2004). Ursache hierfür ist insbesondere der vermehrte Bau von Ein- und Zweifamilienhäusern auf ehemals landwirtschaftlichen Nutzflächen in suburbanen Räumen (DOSCH 2002). Die Gemeinde Iffeldorf, die im Einzugsgebiet von Penzberg und München liegt, bietet aufgrund ihrer Nähe zum Naturschutzgebiet „Osterseen“ einen attraktiven Wohnstandort. Umso bemerkenswerter ist es, daß die lokale Politik den Flächenverbrauch begrenzen konnte.

### **Integrierte Auswertung von GIS- und Fernerkundungsdaten**

Die Aktualisierung von bestehenden digitalen Kartenwerken mit Fernerkundungsdaten wird als eine bedeutende Anwendung der Fernerkundung betrachtet (HEIPKE et al. 2004). Auch ARZET (2004) schlägt für die Aktualisierung von Seeuferkartierungen (SUK) den Einsatz der Fernerkundung vor. In der Detailstudie aus Kap. 6.3 wurde ein Teil einer SUK der Osterseen mit IKONOS-Daten auf den aktuellen Stand (August 2001) gebracht. Der bearbeitete Ausschnitt enthielt sowohl geometrische als auch thematische Informationen, die in beiden Fällen Ungenauigkeiten aufwiesen. Die Integration von Vektor- und Rasterdaten, die von HINTON (1996) noch als schwierig beschrieben wurde, war mittels des hier verwendeten Ansatzes problemlos möglich.

Wie BUCK (2001) treffend zusammenfaßte, verläuft der integrative Prozeß von Fernerkundung und GIS in zwei Richtungen:

1. Die Ergebnisse und Informationen, die aus Fernerkundungsdaten gewonnen werden, werden genutzt, um die vorhandenen **GIS-Daten** zu **aktualisieren**.
2. Thematische **GIS-Daten** werden als *a-priori* Information zur Unterstützung der Analyse verwendet. Das Ziel ist es dabei, genauere und zuverlässigere Klassifizierungsergebnisse zu gewinnen.

Nach BALTSAVIAS und HAHN (1999) gibt es nur wenige Studien die einen **umfassenden Integrationsansatz** verwirklichen und dabei beide Richtungen bedienen. In der in Kapitel 6.3 dargestellten Fallstudie wurde sowohl die geometrische Ausdehnung der Klasse „Wald / Forst“ mit Fernerkundungsdaten aktualisiert, als auch die thematische Information des Flußlaufs aus der SUK aufgegriffen, um feuchte „Azonale Gehölze“ zu klassifizieren.

Dabei wurde auf die Erfahrung von SADER et al. (1995) zurückgegriffen, wonach sich **feuchte Gehölzstrukturen** kaum durch spektrale Charakteristika von anderen Waldtypen unterscheiden lassen. Das Kronendach gibt die hydrologischen Standortbedingungen nur unzureichend wieder. SADER et al. (1995) schlagen deshalb vor, GIS-Daten als unterstützende Information zu verwenden. Dadurch werden *a-priori* Wahrscheinlichkeiten zur Identifizierung von Feuchtwäldern bei der Klassifikation integriert. Dieser Ansatz hat in der Fallstudie zu guten Ergebnissen geführt.

Für ein hochtechnologisiertes Land wie die Bundesrepublik Deutschland existieren flächendeckend Flurkarten, CORINE-Daten, sowie Kartierungen der naturschutzfachlich wertvollen Gebiete, in Bayern beispielsweise die SUK oder die Biotopkartierung. Solche Geoinformationen sind vielfach vorhanden und sollten für jede Studie als *a-priori* Information in Betracht gezogen werden. Diese Forderung ist nicht neu (TON et al. 1991), wird jedoch bei den meisten fernerkundlichen Analysen nicht beachtet (BALTSAVIAS und HAHN 2000). Nach den hier gemachten Erfahrungen, sollte im Vorfeld einer fernerkundlichen Studie grundsätzlich geprüft werden sollte, welche Informationen bereits vorhanden sind. So lassen sich systematisch bedingte Schwächen von Fernerkundungsdaten ausschalten. Geometrische Informationen, die nicht durch eine Segmentierung abgeleitet werden

können, wie z. B. von Alleebäumen unterbrochene Straßenzüge, lassen sich mit Hilfe von GIS-Daten in die Auswertung einbeziehen (RÜCKER et al. 2005). EHLERS et al. (2003) sowie BUCK (2001) nutzten z. B. Höheninformationen, um Vegetationseinheiten zu unterscheiden, die sich bei ausschließlicher Verwendung von Satellitendaten nicht trennen ließen.

Welcher Mehrwert, durch *data-fusion*-Methoden erreicht werden kann, wird seit langem diskutiert (HUTCHINSON 1982, EHLERS et al. 1989, MCNOLEG 1996, BALTSAVIAS 2004). Übereinstimmend wird darauf hingewiesen, daß eine Integration von GIS- und Fernerkundungsmethoden notwendig ist, wobei die Zusammenführung **mehr als nur die Summe beider Elemente** bedeutet. Aus der dritten Fallstudie dieser Arbeit (Kap. 6.3) geht hervor, daß mit der objektorientierten Arbeitsweise ein methodischer Rahmen geschaffen werden kann, der eine **umfassende Integration von GIS- und Fernerkundung** erlaubt. Behördliche Datenbestände, die innerhalb vieler Jahre aufgebaut wurden, lassen sich auf diese Weise weiter nutzen bzw. aktualisieren.

## 7.4 Schlußfolgerungen für die Praxis

In Zusammenhang mit den auf europäischer und Landesebene erlassenen Programmen und Richtlinien zur Landnutzung, besteht ein erheblicher Bedarf an Geoinformationen z. B. für die **Wasserwirtschaft** (ARZET 2004), für den **Naturschutz** (SCHNEIDER und ZIMMERMANN 2004), besonders aber auch für die **Landwirtschaft** (RINTELEN 2004). Der steigende Informationsbedarf und die immer knapper werdenden finanziellen Mittel erfordern weitgehend automatische Datenerfassungs- und Verarbeitungsmethoden. Vor diesem Hintergrund kann sich die Fernerkundung zu einer Schlüsseltechnologie entwickeln. Im folgenden sollen einige Anwendungsbeispiele vorgestellt werden, bei denen die Ansätze und Landnutzungsklassifikationen, die im Rahmen des Projekts AQUATIC erstellt wurden, sinnvoll weiterentwickelt und genutzt werden können.

Die **Wasserwirtschaft** ist mit der Umsetzung der **Wasserrahmenrichtlinie** (WRRL, 2000/60/EG) befaßt. Mit der WRRL wurde durch das europäische Parlament und den Rat im Oktober 2000 ein europaweit verbindlicher Ordnungsrahmen geschaffen, der den Schutz und die Verbesserung des Zustands von aquatischen Ökosystemen zum Ziel hat. Als Instrument sind u.a. **Gewässerentwicklungspläne** vorgesehen, für welche Landnutzungskarten als Planungsgrundlage dienen. Dabei wird der Einsatz von GIS grundsätzlich empfohlen (LFW 2001). Vor dem Aufstellen eines Gewässerentwicklungsplans müssen die betreffenden Gewässer detailliert beschrieben und die potentiellen Belastungen ermittelt werden. Hier kann die Fernerkundung sowohl bei der **Grundlagenermittlung** (ARZET 2004) als auch bei der **Risikoursachenforschung** einen wichtigen Beitrag liefern.

Mit objektorientierten Methoden und hochauflösenden Fernerkundungsdaten lassen sich sowohl die Landnutzung (Kap. 6.1, Kap. 6.2) als auch sensible Feuchtvegetation (ANDRESEN 2004) gut ermitteln. Diese **Grundlagen** können als GIS-Ebenen ausgegeben werden und anschließend von den Wasserwirtschaftsämtern fachgerecht aufgearbeitet werden. Der notwendige Arbeitsaufwand einer Erst-erfassung kann auf diese Weise reduziert werden. Fernerkundung wird in diesem Zusammenhang als Ergänzung zur bestehenden Kartierungspraxis empfohlen.

In der Praxis werden Gewässer nach einer fünfstufigen Skala eingeteilt, wobei der ökologische Zustand eines Gewässers bewertet wird. Dies geschieht z. T. nach Kriterien, die nicht mit Fernerkundung erfaßt werden können, wie z. B. die chemische Zusammensetzung oder das Makrozoobenthos (LFW 2001). Anders verhält es sich mit der Markrophytenzusammensetzung, die einen

trefflichen Trophieindikator darstellt (MELZER und SCHNEIDER 2001). Erste, experimentelle Studien haben gezeigt, daß Makrophytenvorkommen mit Hilfe von hyperspektralen Bilddaten ermittelt und abgegrenzt werden können (HEEGE 2004). Die Zukunft läßt eine Verbesserung und Weiterentwicklung dieser Ansätze erwarten, so daß der Einsatz von Fernerkundung auch zur **Trophieindikation** realistisch erscheint. Allerdings wird die dafür notwendige spektrale und räumliche Auflösung in naher Zukunft vermutlich nicht durch Satellitendaten zur Verfügung stehen. Hier muß auch mittelfristig auf flugzeuggetragene Sensoren zurückgegriffen werden.

Die Identifikation potentieller **Risiken** für den Zustand eines Gewässers ist ein wichtiger Aspekt bei der Gewässerentwicklungsplanung. Beispiele für mögliche Risikofaktoren sind Siedlungsgebiete in unmittelbarer Nähe von Gewässern oder intensiv genutzte landwirtschaftliche Flächen im Einzugsgebiet. Aus der Nähe solcher Flächen zu Gewässern kann automatisch in Abhängigkeit von der Nutzung das Störungspotential ermittelt werden. Denkbar ist auch, mit *data-fusion* Methoden durch Integration eines DGM die Hangneigung mitzubewerten, um diffuse Stoffquellen zu identifizieren. HOFFMANN et al. (2004) verfolgten mit Hilfe von GIS-Modellen einen ähnlichen Ansatz. In jedem Fall stellt bei Stofftransportmodellen die großmaßstäbliche Landnutzungsinformation aus hochauflösenden Daten eine wichtige Informationsquelle dar.

Im **Naturschutz** legt die **Fauna-Flora-Habitat-Richtlinie** (FFH-RL, 92/43/EWG) des europäischen Rates verbindliche Maßnahmen zur Erhaltung natürlicher Lebensräume fest. Dieser Beschluß bildet das Fundament umweltpolitischer Entwicklungen auf europäischer Ebene und bildet die Grundlage für das Naturschutzprojekt NATURA 2000. Im Rahmen von NATURA 2000 sollen in einem länderübergreifenden Biotopverbundnetz schützenswerte Gebiete ermittelt und deren biologische Vielfalt dauerhaft gesichert werden.

Für ausgewiesene FFH-Gebiete<sup>1</sup> ist ein **Gebietsmanagement** vorgeschrieben. Bei der Umsetzung der FFH-RL empfehlen LFU und LWF (2004) die Erfassung der schützenswerten Lebensraumtypen (LRT, nach Anhang I der FFH-RL) mit Hilfe von Luftbildern im Gelände. Anschließend sollen die Abgrenzungen der LRT digitalisiert und in ein GIS-kompatibles Format übertragen werden. Mit der objektorientierten Methode ist es möglich, über eine große Fläche die Geometrien auf Vektor-Basis zu ermitteln und entsprechende (Vor-)Klassifikationen zu liefern. Diese können den Kartierer im Gelände unterstützen und so eine manuelle Delinierung auf ein Minimum reduzieren. Zudem lassen sich bereits im Vorfeld durch die Integration von externen Daten (z. B. Bodenkarten, Geländemodelle) bestimmte LRT-Vorkommen ausschließen, was die Ausweisung erleichtert und den Aufwand der terrestrischen Begehung begrenzt.

Auch in Zusammenhang mit der **Monitoring- und Berichtspflicht** entsprechend der FFH-Richtlinie ist die Fernerkundung interessant. Fernerkundungsanwendungen können hier unterstützende Informationen liefern, vor allem bezüglich Veränderungen oder etwaigen Verschlechterungen innerhalb einer sensiblen Zone. Dies ist insbesondere bei großflächigen und schwer zugänglichen Gebieten ein erheblicher Vorteil. Objektorientierte Methoden erlauben es, bereits abgegrenzte LRT-Vorkommen als Vorinformation zu integrieren und gezielt Hinweise auf Veränderungen zu detektieren. Kostspielige terrestrische Begehungen im Gelände können so reduziert werden, weil die potentiell gefährdeten Bereiche innerhalb der LRT-Vorkommen für eine Feldkampagne vorselektiert werden können.

---

<sup>1</sup> Nachdem Bayern anfangs zu wenige FFH-Gebiete ausgewiesen hat, kam es zu einer Nachmeldung im September 2004. Aktuell ergibt sich nunmehr für Bayern insgesamt ein NATURA 2000-Gebietsanteil von 11,3 % (1.Quartal / 2005) der Landesfläche.

Ein großer Teil der **landwirtschaftlichen** Betriebe sind heute auf Zuwendungen in Form von Stilllegungsprämien, Ausgleichszahlungen oder anderen Zuschüssen wirtschaftlich angewiesen. Diese Zuwendungen sind auf Landesebene maßgeblich in den sogenannten **Agrarumweltprogrammen** (in Bayern: Kulturlandschaftsprogramm (KULAP), Vertragsnaturschutzprogramm (VNP), Erschwernisausgleich (EA)) festgeschrieben. Auf EU-Ebene werden im Rahmen von **Cross Compliance** Direktzahlungen u.a. an die Einhaltung von Umweltvorschriften<sup>1</sup> gekoppelt (STMLF und STMUGV 2005). Als Verwaltungsinstrument wird zur wirksamen Realisierung der flächenbezogenen Beihilferegulungen das Integrierte Verwaltungs- und Kontrollsystem **InVeKoS** verwendet, das seit Januar 2005 europaweit als GIS-Applikation vorgeschrieben ist.

Bei sämtlichen flächenbezogenen Anträgen ist der Landwirt verpflichtet, einen exakten **Flächen- und Nutzungsnachweis** (FNN) beizufügen (STMLF 2004). Dabei werden den Landwirtschaftsbetrieben von der Landwirtschaftsverwaltung kartographische Unterlagen (Abgrenzungen der Referenzparzellen, Luftbilder) zur Verfügung gestellt. Der Landwirt ist gehalten, diese Unterlagen räumlich zu berichtigen und gegebenenfalls naturschutzfachlich wertvolle Landschaftselemente aus der beihilfefähigen Fläche herauszurechnen. Angesichts des z. T. erheblichen Aufwands der manuellen Flächenkorrektur (AMMER 2004), „verzichteten“ einige Landwirte mit Hilfe der Motorsäge ganz auf wertvolle Landschaftselemente.

Eine Integration der hier entwickelten Methoden (z. B. Detektion von Einzelbäumen oder Feldhecken) in das InVeKOS-System ist in zweierlei Hinsicht von Interesse:

1. Zum einen würde es eine erhebliche Arbeitserleichterung für die betroffenen Landwirte bedeuten, wenn entsprechende Landschaftselemente bereits digitalisiert und gegebenenfalls die korrekte Nettonutzfläche der betroffenen Feldstücke vorgeschlagen wird. In der ersten Fallstudie (Kap. 6.1) wurde gezeigt, daß Gehölzstrukturen aus IKONOS-Daten automatisch erfaßt werden können.
2. Zum anderen könnte die automatische Erfassung von ökologisch bedeutsamen Strukturen auch als Kontrollinstrument zur Überprüfung der Cross Compliance-Regelungen verwendet werden: dem Landwirt ist es untersagt, bestimmte Landschaftselemente wie Baumreihen oder Feldhecken zu entfernen. Die gängige Praxis der Vor-Ort-Prüfungen kann so effektiv unterstützt werden. Eventuelle Verstöße können bereits vorab bekannt werden.

Das von RINTELEN (2004) beschriebene Informationsdefizit der Landwirtschaftsverwaltungen über Lage, Größe und Qualität von Strukturen in der Feldflur kann durch den konsequenten Einsatz von hochauflösenden Bilddaten und objektorientierten Methoden großflächig behoben werden.

---

<sup>1</sup> Konkret ist der Landwirt der „*Erhaltung landwirtschaftlicher Flächen in gutem landwirtschaftlichen und ökologischen Zustand*“ verpflichtet (STMLF und STMUGV 2005).

## 8 Zusammenfassung

Die vorliegende Arbeit hat die Entwicklung von Klassifikationsstrategien zur automatischen Erfassung der Landnutzung aus hochauflösenden Fernerkundungsdaten zum Thema. Im einzelnen wurden IKONOS-Satellitenbilder, multitemporale Luftbilder und die kombinierte Auswertung von bestehenden Kartierungen mit Satellitenbildern mit Hilfe eines objektorientierten Ansatzes untersucht, um großmaßstäbliche Informationen für die Planung und Kontrolle der Landnutzung zur Verfügung zu stellen. Automatische Auswertansätze für Fernerkundungsdaten können sich, angesichts der zunehmenden Monitoring- und Berichtspflichten der Landesbehörden, zu einer Schlüsseltechnologie für Planung und Vollzug entwickeln.

Hochauflösende Fernerkundungsdaten sind mit traditionellen Klassifikationsmethoden bis heute nicht befriedigend auszuwerten, da die Komplexität des Bildinhalts mit erhöhter Auflösung erheblich zunimmt. Aus diesem Grund erfordert die Bearbeitung solcher Daten bisher die kostspielige, manuelle Klassifikation durch einen Interpreten. Der objektorientierte Ansatz bietet eine Möglichkeit, digitale Bilddaten in einem automatischen Verfahrensablauf nachvollziehbar zu klassifizieren. Im Gegensatz zu den traditionellen, automatischen Auswertemethoden werden nicht Pixel sondern Bildobjekte klassifiziert, die mittels einer Segmentierung generiert werden. Ferner sind verschiedene innovative Bildanalysemethoden in diesem Ansatz zusammengeführt worden, wodurch die Integration unterschiedlicher Arten von „Wissen“ in den Klassifikationsvorgang gelang.

Kernstück der Arbeit war die Entwicklung eines strukturierten Auswertekonzepts für ein objektorientiertes Klassifikationsprojekt. Das vorgestellte Konzept gibt Auskunft über die notwendigen Verarbeitungsschritte und unterstützt den Anwender dabei das Datenmaterial fachgerecht zu bearbeiten. Die genau festgelegte Vorgehensweise und die Dokumentation der einzelnen Schritte schafft ein hohes Maß an Transparenz und begegnet damit einer gegenüber der Fernerkundung häufig vorgebrachten Kritik.

Das hier entwickelte Auswertekonzept wurde an drei Fallstudien überprüft. Dabei wurden verschiedene Aspekte des objektorientierten Ansatzes in einem Untersuchungsgebiet rund um die Osterseen im südlichen Oberbayern analysiert. Bei der ersten Fallstudie lag der Schwerpunkt auf der Analyse zweier hochauflösender IKONOS-Satellitendatensätze, die zu Beginn (April) und zum Ende (August) der Vegetationsperiode aufgenommen wurden. Der Fokus der zweiten Fallstudie lag auf der Analyse von aktuellen und historischen Schwarz/Weiß-Luftbildern. Im dritten Fallbeispiel wurde gezeigt, auf welche Weise sich bestehende Kartierungen in den Auswerteprozess integrieren und aktualisieren lassen.

Im einzelnen führten die Fallstudien zu folgenden Ergebnissen:

Die iterativ ermittelten Segmentierungseinstellungen gaben die gesuchten Landnutzungsklassen auf Bildobjektebene sehr gut wieder. Dabei zeigte sich, daß drei Segmentierungsebenen ausreichten, um die unterschiedlichen räumlichen und strukturellen Ausprägungen der Zielklassen zu repräsentieren. Für beide IKONOS-Aufnahmen erwiesen sich die eingesetzten Segmentierungsparameter als sehr geeignet und lassen bei einer Übertragung dieser Parameter bei Projekten mit ähnlicher Fragestellung gleichfalls gute Ergebnisse erwarten.

Besonders hilfreich erwies sich im Vorfeld des Aufbaus der Regelwerke die Anwendung der Boxplotanalyse der Objekteigenschaften. Nach den positiven Erfahrungen mit dieser Art der Analyse wird diese Darstellungsform als Standard für die Untersuchung von Objekteigenschaften empfohlen.

Die Klassifikation von IKONOS-Daten mit objektorientierten Methoden erzielte sehr hohe Gesamtgenauigkeiten. Diese wurden mit Hilfe von Felddaten über eine Konfusionsmatrix bestimmt. Dabei ergab die Auswertung der Aprilaufnahme eine Gesamtgenauigkeit von 89 % ( $\kappa$ : 0,82) und die der Augustaufnahme 95 % ( $\kappa$ : 0,92). Mit 97 % Gesamtgenauigkeit ( $\kappa$ : 0,95) wurden bei der multi-saisonalen Klassifikation die besten Ergebnisse erzielt. Die Werte liegen im Rahmen dessen, was ein erfahrener Interpret leisten kann. Dies bedeutet, daß sich mit dem objektorientierten Ansatz räumliche Informationen aus hochauflösenden Daten auf hohem Niveau automatisch extrahieren lassen.

Die Modellierung der Klassen gelang über eine kombinierte Bewertung von Spektral-, Textur-, Topologie- und Form-Eigenschaften, womit sich ansatzweise die menschliche Wahrnehmung für den Rechner formalisieren ließ. Im Unterschied zur Arbeit eines Interpreten gestaltete sich die Klassifikation auf diese Weise transparent und reproduzierbar. Beim Aufbau der Regelwerke wurden für IKONOS-Daten Objekteigenschaften identifiziert, die eine Trennung verschiedener Landnutzungsklassen zuließen. So konnten Laub- bzw. Nadelgehölze mit Genauigkeiten von 94 % bzw. 96 % klassifiziert werden. Naturschutzfachlich wertvolle Gehölzstrukturen, wie Feldhecken bzw. Einzelbäume ließen sich über Flächengrößen und Nachbarschaftsbeziehungen finden (97 % bzw. 59 % Genauigkeit). Für Siedlungsgebiete wurde das Verfahren der „iterativen Stratifikation“ entwickelt, welche auf topologische Werkzeuge wie z. B. Nachbarschaftsbeziehungen zurückgreift. Diese Vorgehensweise ermöglichte es, die komplexe Klasse der Siedlungsgebiete treffsicher zu detektieren (99 % Genauigkeit). Bei der Klassifikation von landwirtschaftlichen Nutzflächen (95 % Genauigkeit) erwiesen sich vor allem die multisaisonalen Informationen als hilfreich. Insbesondere der Vegetationsindex NDVI gab diese phänologischen Zusammenhänge deutlich wieder. Wichtig war auch der Nachweis, daß Formeigenschaften nur bei bestimmten Segmentierungseinstellungen für landwirtschaftliche Nutzflächen aussagekräftig sind.

In der zweiten Fallstudie ergab die Klassifikation von Schwarz/Weiß-Luftbildern des Jahres 2000 aus der Umgebung der Osterseen im Vergleich zu einer visuellen Interpretation eine Gesamtgenauigkeit von 86 % ( $\kappa$ : 0,80). Eine Überprüfung der Fehlerursachen zeigte indes, daß die automatische Auswertung die Landbedeckung z. T. realistischer wiedergab als die Referenzinterpretation. Bisher wurden Luftbilder hauptsächlich von Photointerpretern durch manuelle Delinierung klassifiziert. Mit den entwickelten Regelwerken konnte ein Weg aufgezeigt werden, der es erlaubt, diesen Datentyp auch mit Hilfe eines Rechners qualitativ hochwertig auszuwerten.

Ausgehend von der Klassifikation der Luftbilder des Jahres 2000, wurde die Änderung der Landnutzung mittels historischer Luftbilder aus den Jahren 1976 und 1956 ermittelt. Dazu wurde eine besondere Vorgehensweise entwickelt, bei der die thematische Auswertung der jeweils späteren Zeitpunkte mitbetrachtet wurde. Unter Berücksichtigung von *a-priori* Wissen über wahrscheinliche bzw. typische Veränderungen in der Landschaft, konnte ein einfacher Regelsatz erstellt werden, der es erlaubte auch ältere, spektral weniger aussagekräftige Luftbilder automatisch auszuwerten. Dies ist ein wichtiger Schritt, um die großen Datenmengen der Luftbildarchive der verschiedenen Behörden umfassend und kostengünstig zu nutzen.

In der dritten Fallstudie wurde eine Seeuferkartierung (SUK) der Osterseen aus dem Jahr 1987 mit IKONOS-Satellitendaten aktualisiert. Zu diesem Zweck wurde über Regelwerke ein methodischer

Rahmen entwickelt, der eine umfassende „Datenintegration“ (*data-fusion*) erlaubte. Dabei wurde der thematische und geometrische Inhalt der SUK überarbeitet und zugleich genutzt, um die Klassifikation zu verbessern. Über diese Vorgehensweise ließ sich ein Ergebnis erzielen, das mit IKONOS-Daten allein nicht zu erreichen gewesen wäre. Unter Bezugnahme auf die thematischen Informationen der SUK gelang es, z. B. azonale Gehölzstrukturen zu klassifizieren, die aus den Bilddaten nicht zu detektieren waren. Der beschriebene Weg kann auf andere *data-fusion*-Projekte übertragen werden und dazu beitragen vorhandene Kartierungen zu aktualisieren. Dieser Aspekt ist auch angesichts der zunehmenden Monitoring- und Berichtspflichten der Landesbehörden von Bedeutung.

Insgesamt zeigen die Ergebnisse welchen Beitrag der neuartige Ansatz einer objektorientierten Auswertung von hochauflösenden Fernerkundungsdaten für die Landnutzungspraxis zu leisten vermag und welche Genauigkeiten mit Hilfe des automatisierten Verfahrens erreicht werden können. Grundlage dafür ist die Formalisierung von Fachwissen in Regelwerken. Wichtig für eine breitere Nutzung objektorientierter Fernerkundungsmethoden ist der Aufbau einer Wissensdatenbank, die Segmentierungseinstellungen und Regelwerke verwaltet, sowie das Reflexionsverhalten verschiedener Landnutzungstypen archiviert. Dabei müssen neben der Spektralsignatur auch phänologische und anisotropische Aspekte berücksichtigt werden.

## 9 Literaturverzeichnis

- ALBERTZ, J. (1997):** Sehen, Wahrnehmen und die Wirklichkeit - Zur Einführung in das Thema. In Albertz, J. [Hrsg]: Wahrnehmung und Wirklichkeit. S.9-40, Band 17 der Schriftenreihe der Freien Akademie, Berlin.
- ALBERTZ, J. (2001):** Einführung in die Fernerkundung: Grundlagen der Interpretation von Luft- und Satellitenbildern. Darmstadt.
- AMMER, U.; MÖSSMER, R. U. BRÖCKER, U. (1983):** Der Beitrag der Fernerkundung zur Erfassung der Waldschäden. Forstwiss Centralbl 102(3), S.149-157.
- AMMER, U., PRÖBSTL, U. (1991):** Freizeit und Natur: Probleme und Lösungsmöglichkeiten einer ökologisch verträglichen Freizeitnutzung. Schriftenreihe Pareys Studentexte Nr. 72, Hamburg/Berlin.
- AMMER, U. (2004):** Erfassung und Beurteilung von Seen und deren Einzugsgebieten mit Methoden der Fernerkundung - Einführung in das Tagungsthema. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.7-10.
- ANDRESEN, T. (2004):** Strategien zur wissensbasierten Bildanalyse hoch auflösender Fernerkundungsdatensätze für das Monitoring gewässernaher Feuchtgebiete. Dissertation, Department für Ökologie, Limnologische Station, TU München, Iffeldorf.
- ANDRESEN, T., MOTT, C., SCHNEIDER, T., MELZER, A. (2004):** Erfassung und Beurteilung von aquatischen und terrestrischen Feuchtgebieten mit sehr hoch auflösenden FE-Daten. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.47-53.
- ARGIALAS, D.P., HARLOW, C.A. (1990):** Computational Image Interpretation Models - an Overview and a Perspective. Photogramm Eng Remote Sens 56 (6), S.871-886.
- ARZET, K. (2004):** Erfassung und Beurteilung von Seen und deren Einzugsgebieten mit Methoden der Fernerkundung - Bedarf aus wasserwirtschaftlicher und naturschutzfachlicher Sicht. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.11-13.
- ATALLAH, L., SMITH, P.J.P. (2003):** Using wavelet analysis to classify and segment sonar signals scattered from underwater sea beds. Int J Remote Sens 24 (21), S.4113-4128.
- ATKINSON, P.M., CURRAN, P.J. (1997):** Choosing an appropriate spatial resolution for remote sensing investigations. Photogramm Eng Remote Sens 63 (12), S.1345-1351.
- ATKINSON, P.M., LEWIS, P. (2000):** Geostatistical classification for remote sensing: an introduction. Comput Geosci 26 (4), S.361-371.
- BAATZ, M., BINNIG, G., ESCHENBACHER, P., MALCHINGER, A., SÖGTROP, M. (1998):** Verfahren zum Segmentieren eines digitalen Bildes. Deutschland, Patent Nr. EP 0 858 051 A2, 12.08.1998, DELPHI Systemsimulation GmbH, München.
- BAATZ, M., SCHÄPE, A. (2000):** Multiresolution Segmentation - an optimization approach for high quality multi-scale image segmentation. In Strobl, J., Blaschke T. [Hrsg]: Angewandte Geographische Informationsverarbeitung. Beiträge zum AGIT-Symposium Salzburg 2000, Heidelberg, S.12-23.
- BAATZ, M., BENZ, U., DEGHANI, S., HEYNEN, M., HÖLTJE, A., HOFMANN, P., LINGENFELDER, I., MIMLER, M., SOHLBACH, M., WEBER, M., WILLHAUK, G. (2002):** eCognition user guide 3. München.
- BACKHAUS, K., ERICHSON, B., PLINKE, W., WEIBER, R. (1996):** Multivariate Analysemethoden. Eine anwendungsorientierte Einführung. Berlin.
- BÄHR, H.-P., VÖGTLE, T. (1998):** Digitale Bildverarbeitung. Anwendung in Photogrammetrie, Kartographie und Fernerkundung. Heidelberg.
- BALL, G.H., HALL, D.J. (1967):** A clustering technique for summarizing multivariate data. Behav Sci 12, S.153-155.

- BALTSAVIAS, E.P., HAHN, M. (1999):** Integration of image analysis and GIS. In: International Archives of Photogrammetry and Remote Sensing 32(7-4-3W6), Valladolid, Spanien, 03.-04.06.1999, S.12-19.
- BALTSAVIAS, E.P., HAHN, M. (2000):** Integrating spatial information and image analysis - one plus one makes ten. In: International Archives of Photogrammetry and Remote Sensing 33(B2), Amsterdam, Holland, 16.-23.07.2002, S.63-74.
- BALTSAVIAS, E.P. (2004):** Object extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems. *Isprs J Photogramm* 58 (3-4), S.129-151.
- BARTEL, A. (2000):** Analysis of landscape pattern: towards a 'top down' indicator for evaluation of landuse. *Ecol Model*, 130 (1-3), S.87-94.
- 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. *Isprs J Photogramm* 58 (3-4), S.239-258.
- BINAGHI, E., MADELLA, P., MONTESANO, M.G., RAMPINI, A. (1997):** Fuzzy contextual classification of multisource remote sensing images. *Ieee T Geosci Remote* 35 (2), S.326-340.
- BLACKBURN, G.A. (1998):** Quantifying chlorophylls and carotenoids at leaf and canopy scales: An evaluation of some hyperspectral approaches. *Remote Sens Environ* 66 (3), S.273-285.
- BLAIR, J.B., RABINE, D.L., HOFFTON, M.A. (1999):** The Laser Vegetation Imaging Sensor: a medium-altitude, digitisation-only, airborne laser altimeter for mapping vegetation and topography. *Isprs J Photogramm* 54 (2-3), S.115-122.
- BLASCHKE, T., LANG, S., LORUP, E., STROBL, J., ZEIL, P. (2000):** Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In Cremers, A., Greve, K. [Hrsg]: *Environmental Information for Planning, Politics and the Public*. Band 2, Marburg, S.555-570.
- BODECHTEL, J. (1965):** Die südlichen Osterseen bei Iffeldorf in Oberbayern. *Erdkunde* 19, S.150-155.
- BOLSTAD, P.V., LILLESAND, T.M. (1992):** Rule-Based Classification Models - Flexible Integration of Satellite Imagery and Thematic Spatial Data. *Photogramm Eng Remote Sens* 58 (7), S.965-971.
- BRANDES, H.G., LUTZ, G. (1996):** Natürliche Seen und Seeufer in Bayern. Ein Rückblick aus ökologischer und landschaftsplanerischer Sicht. In LfU [Hrsg]: *Schriftenreihe des Bayerischen Landesamtes für Umweltschutz* 137, Augsburg, S.81-92.
- BROCKHAUS (1985):** Der neue Brockhaus: Lexikon und Wörterbuch in 5 Bänden und ein Atlas. Wiesbaden.
- BRUZZONE, L., PRIETO, D.F. (2000):** Automatic analysis of the difference image for unsupervised change detection. *Ieee T Geosci Remote* 38 (3), S.1171-1182.
- BUCK, A., DE KOK, R., SCHNEIDER, T., AMMER, U. (1999):** Integration von Fernerkundung und GIS zur Beobachtung und Inventur von Schutzwäldern in den Bayerischen Alpen. In Strobl, J., Blaschke T. [Hrsg]: *Angewandte Geographische Informationsverarbeitung, Beiträge zum AGIT-Symposium Salzburg 1999*, Heidelberg, S.94-101.
- BUCK, A. (2001):** Aufbau, Optimierung und Anwendung eines forstlichen Geoinformationssystems im Gebiet der Bayerischen Alpen - Implementierung eines wissenschaftsbasierten Systems zur Integration von Fernerkundung und GIS. Dissertation, Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt, TU München, Freising/Weihenstephan.
- BFN (2002):** Systematik der Biotoptypen- und Nutzungstypenkartierung (Kartieranleitung). Bundesamt für Naturschutz, Bonn-Bad Godesberg.
- BURNETT, C., BLASCHKE, T. (2003):** A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecol Model* 168 (3), S.233-249.
- CCRS (2001):** Fundamentals of Remote Sensing. Canada Centre for Remote Sensing, Internetseite: [http://www.ccrs.nrcan.gc.ca/ccrs/learn/tutorials/fundam/fundam\\_e.html](http://www.ccrs.nrcan.gc.ca/ccrs/learn/tutorials/fundam/fundam_e.html), Zugriff: 18.06.2001.
- CHAPIN, F.S., ZAVALA, E.S., EVINER, V.T., NAYLOR, R.L., VITOUSEK, P.M., REYNOLDS, H.L., HOOPER, D.U., LAVOREL, S., SALA, O.E., HOBBI, S.E., MACK, M.C., DIAZ, S. (2000):** Consequences of changing biodiversity. *Nature*, 405(6783), S.234-242.

- CONGALTON, R.G. (1991):** A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sens Environ* 37(1), S.35-46.
- COPPIN, P., JONCKHEERE, I., NACKAERTS, K., MUYS, B., LAMBIN, E. (2004):** Digital change detection methods in ecosystem monitoring: a review. *Int J Remote Sens* 25(9), S.1565-1596.
- CROSTA, A.P., SABINE, C., TARANIK, J.V. (1998):** Hydrothermal alteration mapping at Bodie, California, using AVIRIS hyperspectral data. *Remote Sens Environ* 65(3), S.309-319.
- DAS, S., BHANU, B. (1998):** A system for model-based object recognition in perspective aerial images. *Pattern Recognit* 31(4), S.465-491.
- DE KOK, R., SCHNEIDER, T., BAATZ, M., AMMER, U. (1999):** Object based image analysis of high resolution data in the alpine forest area. In: *ISPRS WG I/1, I/3 and IV/4: Sensors and Mapping from Space 1999*, Hannover, 27.-30.09.1999.
- DE KOK, R. (2001):** Objektorientierte Bildanalyse. Ein Lösungsansatz für den automatisierten Einsatz sehr hoch auflösender Satellitendaten für forstliche Fragestellungen. Dissertation, Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt, TU München, Freising/Weihenstephan.
- DECH S., R.K., STRUNZ G., BAUER N. (2003):** European ground segment for high resolution IKONOS data. In: *Proceedings of ISPRS Workshop on High Resolution Mapping from Space*, Hannover, 06.-08.10.2003, CD-Rom.
- DEFRIES, R., HANSEN, M., TOWNSHEND, J. (1995):** Global discrimination of land cover types from metrics derived from AVHRR pathfinder data. *Remote Sens Environ* 54(3), S.209-222.
- DE LANGE, N. (2002):** Geoinformatik in Theorie und Praxis. Berlin.
- DIAL, G., GRODECKI, J. (2001):** Understanding the Geometry of IKONOS Images. *Imaging Notes* 16(5), S.1-2.
- DEUTSCHES INSTITUT FÜR NORMUNG E.V. (DIN) (1997):** DIN 18716-3. Photogrammetrie und Fernerkundung - Teil 3: Begriffe der Fernerkundung. 1997-07, Köln.
- DOSCH, F. (2002):** Auf dem Weg zu einer nachhaltigeren Flächennutzung? Informationen zur Raumentwicklung 1/2, S.31-45.
- DREXEL, K. (2002):** Erfassung der Landnutzung und naturschutzrelevanter Flächen am Starnberger See und im Naturschutzgebiet Osterseen mit Hilfe von Hyperspektraldaten. Diplomarbeit, Department für Ökologie, TU München, Freising/Weihenstephan.
- EHLERS, M., EDWARDS, G., BEDARD, Y. (1989):** Integration of Remote-Sensing with Geographic Information-Systems - a Necessary Evolution. *Photogramm Eng Remote Sens* 55(11), S.1619-1627.
- EHLERS, M., GREENLEE, D., SMITH, T., STAR, J. (1991):** Integration of Remote-Sensing and Gis-Data and Data Access. *Photogramm Eng Remote Sens* 57(6), S.669-675.
- EHLERS, M., GAHLER, M., JANOWSKY, R. (2003):** Automated analysis of ultra high resolution remote sensing data for biotope type mapping: new possibilities and challenges. *Isprs J Photogramm* 57(5-6), S.315-326.
- FERRIER, G., WADGE, G. (1997):** An integrated GIS and knowledge-based system as an aid for the geological analysis of sedimentary basins. *Int J Geogr Inf Sci* 11(3), S.281-297.
- FISHER, P. (1997):** The pixel: A snare and a delusion. *Int J Remote Sens* 18(3), S.679-685.
- FOODY, G.M. (2000):** Estimation of sub-pixel land cover composition in the presence of untrained classes. *Comput Geosci* 26(4), S.469-478.
- FOODY, G.M. (2002):** Status of land cover classification accuracy assessment. *Remote Sens Environ* 80(1), S.185-201.
- FUNG, T., CHAN, K.C. (1994):** Spatial Composition of Spectral Classes - a Structural Approach for Image-Analysis of Heterogeneous Land-Use and Land-Cover Types. *Photogramm Eng Remote Sens* 60(2), S.173-180.
- GERLACH, F. (2002):** Ground sampled distance and image interpretability. *Imaging Notes* 17(3), S.1-2.
- GROSS, H.N., SCHOTT, J.R. (1998):** Application of spectral mixture analysis and image fusion techniques for image sharpening. *Remote Sens Environ* 63(2), S.85-94.

- GROWE, S. (2000):** Wissensbasierte Interpretation multitemporaler Luftbilder. Dissertation, Fachbereich Elektrotechnik und Informationstechnik, Universität Hannover.
- GUINDON, B. (1997):** Computer-Based Aerial Image Understanding: A Review and Assessment of its Application to Planimetric Information Extraction from Very High Resolution Satellite Images. *Can J Remote Sens* 23, S.38-47.
- GUINDON, B. (2000):** Combining Diverse Spectral, Spatial and Contextual Attributes in Segment-Based Image Classification. In: Proceedings of the ASPRS 2000 Annual Conference (auf CD-Rom), Washington D.C., U.S.A., 22.-26.05.2000.
- GURNEY, C.M., TOWNSHEND, J.R.G. (1983):** The Use of Contextual Information in the Classification of Remotely Sensed Data. *Photogramm Eng Remote Sens* 49(1), S.55-64.
- HAALA, N., BRENNER, C. (1999):** Extraction of buildings and trees in urban environments. *Isprs J Photogramm* 54(2-3), S.130-137.
- HARALICK, R., SHANMUGAN, K., DINSTEN, I. (1973):** Textural features for image classification. *Ieee T Syst Man Cyb SMC-3*(1), S.610-621.
- HARALICK, R.M., JOO, H. (1986):** A Context Classifier. *Ieee T Geosci Remote* 24(6), S.997-1007.
- HARALICK, R.M., SHAPIRO, L.G. (1985):** Image Segmentation Techniques. *Comput Vision Graph* 29(1), S.100-132.
- HAY, G.J., BLASCHKE, T., MARCEAU, D.J., BOUCHARD, A. (2003):** A comparison of three image-object methods for the multiscale analysis of landscape structure. *Isprs J Photogramm* 57(5-6), S.327-345.
- HEEGE, T., HÄSE, C., BOGNER, A., PINNEL, N. (2004):** Physikalisch basierte Prozessierung multispektraler Fernerkundungsdaten von Binnengewässern. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.67-71.
- HEIPKE, C., PAKZAD, K., WILTRICH, F. (2004):** Theme issue: Integration of geodata and imagery for automated refinement and update of spatial databases. *Isprs J Photogramm* 58 (3-4), S.127-128.
- HEROLD, M., GARDNER, M.E., ROBERTS, D.A. (2003):** Spectral resolution requirements for mapping urban areas. *Ieee T Geosci Remote* 41(9), S.1907-1919.
- HILDEBRANDT, G. (1996):** Fernerkundung und Luftbildmessung: für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie. Heidelberg.
- HINTON, J.C. (1996):** GIS and remote sensing integration for environmental applications. *Int J Geogr Inf Sci* 10(7), S.877-890.
- HINZ, S., BAUMGARTNER, A. (2003):** Automatic extraction of urban road networks from multi-view aerial imagery. *Isprs J Photogramm* 58(1-2), S.83-98.
- HOFFMANN, F., ZIMMERMANN, S., MELZER, A. (2004):** Stofftransport-Modellierung zur Bestimmung der potentiellen Einträge aus dem Wassereinzugsgebiet. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.79-83.
- HORNFECK, C. (2000):** Landschaftsplanungsrelevante Einsatzmöglichkeiten der Flugzeug- und Satellitenfernerkundung. *Landschaftplanung.NET* 4, Internetseite: [www.landschaftsplanung.net](http://www.landschaftsplanung.net), Zugriff: 18.06.2003.
- HUTCHINSON, C.F. (1982):** Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement. *Photogramm Eng Remote Sens* 48(1), S.123-130.
- JÄHNE, B. (2002):** Digitale Bildverarbeitung. Berlin.
- JAIN, A.K., DUIN, R.P.W., MAO, J.C. (2000):** Statistical pattern recognition: A review. *Ieee T Pattern Anal* 22(1), S.4-37.
- JENSEN, J.R., HODGSON, M.E., CHRISTENSEN, E., MACKEY, H.E., TINNEY, L.R., SHARITZ, R. (1986):** Remote-Sensing Inland Wetlands - a Multispectral Approach. *Photogramm Eng Remote Sens* 52(1), S.87-100.

- JENSEN, J.R., NARUMALANI, S., WEATHERBEE, O., MACKEY, H.E. (1993):** Measurement of Seasonal and Yearly Cattail and Waterlily Changes Using Multidate Spot Panchromatic Data. *Photogramm Eng Remote Sens* 59(4), S.519-525.
- JOHANSSON, K. (1994):** Segment-Based Land-Use Classification from Spot Satellite Data. *Photogramm Eng Remote Sens* 60(1), S.47-53.
- JOSEPH, G. (2000):** How well do we understand Earth observation electro-optical sensor parameters? *Isprs J Photogramm* 55(1), S.9-12.
- KANGLER, G. (2003):** Historisch-geographische Landschaftsanalyse mit GIS als Grundlage für Naturschutzplanung - dargestellt am Gebiet um die Osterseen. Diplomarbeit, Department für Ökologie, Limnologische Station, TU München, Iffeldorf.
- KARTIKEYAN, B., GOPALAKRISHNA, B., KALUBARME, M.H., MAJUMDER, K.L. (1994):** Contextual Techniques for Classification of High and Low-Resolution Remote-Sensing Data. *Int J Remote Sens* 15(5), S.1037-1051.
- KELLENBERGER, T. (2002):** Orthorektifizierung von IKONOS Daten in der Schweiz - Erfahrungen und Genauigkeitsanalysen. CGI Systems Benutzertreffen 2002, Iffeldorf, 24.-25.04.2002.
- KENNEWEG, H., FÖRSTER, B., RUNKEL, M. (1991):** Diagnose und Erfassung von Waldschäden auf der Basis von Spekttralsignaturen. BMFT, Abschlußbericht, Teil B 6, TU Berlin.
- KERSTEN, T., BALSAVIAS, E., SCHWARZ, M., LEISS, I. (2000):** IKONOS-2 CARTERRA GEO - Erste geometrische Genauigkeitsuntersuchungen in der Schweiz mit hochaufgelösten Satellitendaten. *Zeitschrift VPK - Vermessung, Photogrammetrie, Kulturtechnik* 8, S.1-10.
- KETTIG, R.L., LANDGREBE, D.A. (1976):** Classification of Multispectral Image Data by Extraction and Classification of Homogeneous Objects. *Ieee T Geosci Remote* 14(1), S.19-26.
- KOCH, B., SCHNEIDER, T., AMMER, U. (1993):** Expected Radiometric and Spectral Significance of Moms-02 Data for Vegetation Mapping - Calculations Based on System Parameters Applied on Spectral Field-Measurements. *Remote Sens Environ* 46(1), S.73-88.
- KOCH, B., IVITS, E. (2002):** What can Remote Sensing provide for Biodiversity Assessment - BioAssess - a project example. ForestSAT Symposium, Heriot Watt University, Edinburgh, England, 05.-09.08.2002.
- KOCH, B., JOCHUM, M., IVITS, E., DEES, M. (2003):** Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren. *PFG* 3, S.195-204.
- KONECNY, L. (1984):** Photogrammetrie. Berlin/New York.
- KUNTZ, S., ZIMMERMANN, C. (1993):** Inventory of Storm Damages in Northern Black-Wood-Forest Using Satellite Data. *Allg Forst Jagdztg* 164(8), S.150-155.
- LEICA GEOSYSTEMS GIS & MAPPING DIVISION (2002a):** Erdas Field Guide, 6th Edition. Atlanta.
- LEICA GEOSYSTEMS GIS & MAPPING DIVISION (2002b):** Erdas Imagine Orthobase User's guide. Atlanta.
- LFU (2002):** Kartieranleitung - Beschreibung der Biotoptypen. Bayerisches Landesamt für Umweltschutz, Stand 02.2002, Augsburg.
- LFU (2003):** Digitalisierungsanweisungen ABK. Bayerisches Landesamt für Umweltschutz, Stand 03.2003, Augsburg.
- LFU (2004):** Umweltindikatorensystem Bayern. Bayerisches Landesamt für Umweltschutz, Augsburg.
- LFU, LWF (2004):** Kartieranleitung für die Lebensraumtypen nach Anhang I der Fauna-Flora-Habitat-Richtlinie in Bayern. Bayerisches Landesamt für Umweltschutz, Bayerische Landesanstalt für Wald und Forstwirtschaft, 5. Entwurf, Stand April 2004, Augsburg/Freising.
- LFU (2005):** Shapefiles der Biotopkartierung zum Download. Bayerisches Landesamt für Umweltschutz, Internetseite: <http://www.bayern.de/lfu/natur/biotopkartierung/index.html>, Zugriff: 09.01.2005.
- LFW (2001):** Gewässerentwicklungsplanung - Fließgewässer - Merkblatt Nr. 5.1/3. Bayerisches Landesamt für Wasserwirtschaft, München.
- LILLESAND, T.M., KIEFER, R.W. (2000):** Remote sensing and image interpretation. New York.

- LUTZ, G. (1986):** Seeuferuntersuchung Bayern. In LfU [Hrsg]: Schriftenreihe Bayerisches Landesamt für Umweltschutz 67, Augsburg.
- LUTZ, G. (2003):** mündl. Mitteilung an der ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003.
- MALTAMOA, M., EERIKAINEN, K., PITKANENA, J., HYYPPÄ, J., VEHMAS, M. (2004):** Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sens Environ* 90(3), S.319–330.
- MANAKOS, I. (2003):** Informationsableitung aus „Off Nadir“-Reflexionsaufnahmen zur Entscheidungsunterstützung in „Precision Agriculture“. Dissertation, Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt, TU München, Freising/Weihenstephan.
- MANSBERGER, G. (2000):** Erste Erfahrungen mit 1-Meter Satellitendaten von IKONOS. In Schrenk, M. [Hrsg]: Beiträge zum 5. Symposium „Computergestützte Raumplanung“ – CORP2000, Wien, Österreich, 16.-18.02.2000, S.147-150.
- MARCEAU, D.J., HAY, G.J. (1999):** Remote sensing contributions to the scale issue. *Can J Remote Sens* 25(4), S.357-366.
- MATSUYAMA, T. (1987):** Knowledge-Based Aerial Image Understanding Systems and Expert Systems for Image-Processing. *Ieee T Geosci Remote* 25(3), S.305-316.
- MCCKEOWN, D.M., HARVEY, W.A., MCDERMOTT, J. (1985):** Rule-Based Interpretation of Aerial Imagery. *Ieee T Pattern Anal* 7(5), S.570-585.
- MCKNOLEG, O. (1996):** The Integration of GIS, Remote Sensing, Expert Systems and Adaptive Co-Kriging for Environmental Habitat Modelling of the Highland Haggis using Object-Oriented, Fuzzy-Logic and Neural-Network Techniques. *Comput Geosci* 22(5), S.585-588.
- MEINEL, G., REDER, J. (2001):** IKONOS-Satellitendaten - ein erster Erfahrungsbericht. *Kartographische Nachrichten* 1, S.40-46.
- MELGANI, F., AL HASHEMY, B.A.R., TAHA, S.M.R. (2000):** An explicit fuzzy supervised classification method for multispectral remote sensing images. *Ieee T Geosci Remote* 38(1), S.287-295.
- MELZER, A., SCHNEIDER, S. (2001):** Submerse Makrophyten als Indikatoren der Nährstoffbelastung von Seen. In Steinberg, C., Bernhardt, H., Klapper, H. [Hrsg]: *Handbuch Angewandte Limnologie*, VIII-1.2.1, S.1-14.
- MELZER, A., ZIMMERMANN, S., HOFFMANN, F. (2001):** Aktualisierung der Seeuferkartierung für den Starnberger See. Untersuchung im Auftrag des Wasserwirtschaftsamts München, unveröffentlichter Bericht.
- MEYER, R.K.F., SCHMIDT-KALER, H. (2002):** Wanderungen in die Erdgeschichte / Auf den Spuren der Eiszeit südlich von München westlicher Teil. München.
- MOLENAAR, M., CHENG, T. (2000):** Fuzzy spatial objects and their dynamics. *Isprs J Photogramm* 55(3), S.164-175.
- MOTT, C., ANDRESEN, T., ZIMMERMANN, S., SCHNEIDER, T., AMMER, U. (2002a):** “Selective” region growing – an approach based on object-oriented classification routines. In: *IGARSS 2002*, Toronto, Kanada.
- MOTT, C., ANDRESEN, T., ZIMMERMANN, S., SCHNEIDER, T., AMMER, U. (2002b):** „Selektives“ region growing – ein objektorientierter Klassifikationsansatz. In Strobl, J., Blaschke T., Griesebner, G. [Hrsg]: *Angewandte Geographische Informationsverarbeitung. Beiträge zum AGIT-Symposium Salzburg 2002*, Heidelberg, S.363-368.
- MOTT, C., ANDRESEN, T., ROGG, C., SCHNEIDER, T., AMMER, U. (2004a):** A view to the past - change detection of settlements . In: *Proceedings of the Danube Delta annual Symposium 2003*, 18.-22.09.2003. Tulcea, Rumänien.
- MOTT, C., ANDRESEN, T., ROGG, C., SCHNEIDER, T., AMMER, U. (2004b):** Identifizierung und Monitoring von Landnutzungs-/Landoberflächen-Typen in einem multitemporalen/multisensoralen Ansatz. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.55-65.
- NAESSET, E., BJERKNES, K.O. (2001):** Estimating tree heights and number of stems in young forest stands using airborne laser scanner data. *Remote Sens Environ* 78(3), S.328-340.

- NEUBERT, M., MEINEL, G. (2003):** Vergleich von Segmentierungsprogrammen für Fernerkundungsdaten. In Strobl, J., Blaschke T., Griesebner, G. [Hrsg]: Angewandte Geographische Informationsverarbeitung. Beiträge zum AGIT-Symposium Salzburg 2003, Heidelberg, S.323-329.
- OESTEREICH, B. (2001):** Objektorientierte Softwareentwicklung. München.
- PAX-LENNEY, M., WOODCOCK, C.E., MACOMBER, S.A., GOPAL, S., SONG, C. (2001):** Forest mapping with a generalized classifier and Landsat TM data. *Remote Sens Environ* 77(3), S.241-250.
- POHL (1979):** Geplantes Naturschutzgebiet - Osterseen. Bayerisches Landesamt für Umweltschutz, Augsburg.
- POTT, R. (1995):** Die Pflanzengesellschaften Deutschlands. Stuttgart.
- PRÖBSTL, U. (2004):** Welche Informationen zur Landnutzung aus der Fernerkundung benötigen Planungsbüros. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.21-24.
- RAEDER, U.B.C. (1990):** Vergleichende Untersuchung der Phytoplankton Sukzession in 15 Seen des Osterseengebietes. Dissertation, Department für Ökologie, Limnologische Station, TU München, Iffeldorf.
- RAHMAN, A.F., GAMON, J.A., SIMS, D.A., SCHMIDTS, M. (2003):** Optimum pixel size for hyperspectral studies of ecosystem function in southern California chaparral and grassland. *Remote Sens Environ* 84(2), S.192-207.
- RICHARDS, J.A., JIA, X. (1999):** Remote sensing digital image analysis: an introduction. Berlin.
- RICHTER, R. (1997):** Correction of atmospheric and topographic effects for high spatial resolution satellite imagery. *Int J Remote Sens* 18(5), S.1099-1111.
- RINTELEN, P.M. (2004):** Welche Informationen aus der Fernerkundung benötigen die Landwirtschaftsbehörden zur Erfüllung der Auflagen von Programmen und Richtlinien? ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.15-19.
- RIEGER, D. (2004):** mündl. Mitteilung im Dezember 2004 am Bayerischen Landesamt für Wasserwirtschaft.
- ROBERTS, D.A., GREEN, R.O., ADAMS, J.B. (1997):** Temporal and spatial patterns in vegetation and atmospheric properties from AVIRIS. *Remote Sens Environ* 62(3), S.223-240.
- ROGG, C. (2003):** Monitoring von naturschutzrelevanten Flächen mit Hilfe objektorientierter Bildanalyse anhand s/w-Luftbilder im NSG Osterseen. Diplomarbeit, Department für Ökologie, Limnologische Station, TU München, Iffeldorf.
- RONDEAUX, G., STEVEN, M., BARET, F. (1996):** Optimization of soil-adjusted vegetation indices. *Remote Sens Environ* 55(2), S.95-107.
- ROSENZWEIG, R. (2001):** Erkennen ist mehr als Sehen. *Schwerpunkt* 3, S.44-50.
- RÜCKER, G., MOTT, C., RIEGER, D. (2005):** Automatische und visuelle Landbedeckungsklassifikation hoch auflösender Satelliten- und Laserscandaten von Überschwemmungsgebieten: Möglichkeiten und Grenzen. In Strobl, J., Blaschke T., Griesebner, G. [Hrsg]: Angewandte Geographische Informationsverarbeitung. Beiträge zum AGIT-Symposium Salzburg 2005, Heidelberg, in Druck.
- RYHERD, S., WOODCOCK, C. (1996):** Combining spectral and texture data in the segmentation of remotely sensed images. *Photogramm Eng Remote Sens* 62(2), S.181-194.
- SABINS, F.F. (1997):** Remote Sensing. Principles and Interpretation. New York.
- SADER, S.A., AHL, D., LIU, W.S. (1995):** Accuracy of Landsat-TM and Gis Rule-Based Methods for Forest Wetland Classification in Maine. *Remote Sens Environ* 53(3), S.133-144.
- SCHNEIDER, T., AMMER, U. (1998):** Concept and first results of a remote sensing based monitoring system for the Bavarian Alps. In Mayer, H., Wiener, S. [Hrsg]: Research and Monitoring as Key Elements for Sustainable Development in the Limestone Alps Proceedings, Bled, Slovenien, 11.-13.10.1998.
- SCHNEIDER, T., DE KOK, R., BUCK, A., AMMER, U. (2000a):** Monitoring des Schutzwaldes im Alpenraum - bringt der objektorientierte Ansatz den Durchbruch? In: Proceedings of the 3rd International Symposium: Application of Remote Sensing in Forestry, Zvolen, Faculty of Forestry, Technical University, 12.-14.09.2000, S. 73-82.

- SCHNEIDER, T., DE KOK, R., BUCK, A., MANAKOS, I. (2000b):** Objektorientierte Bildanalyse - Paradigmawechsel in der thematischen Auswertung von Erdbeobachtungsdaten? In Landnutzungsplanung und Naturschutz [Hrsg]: Festschrift zur Emeritierung von Professor Dr. Ulrich Ammer Lehrstuhl - Aktuelle Forschungsberichte, Freising, S.234-258.
- SCHNEIDER, T., GEGE, P., MOTT, C. (2004):** Directional measurements for reed differentiation. In ESA Publications Division [Hrsg]: Proceedings of the 2nd ESA CHRIS/Proba Workshop, Frascati, Italien, 28.-30.04.2004.
- SCHNEIDER, T., ZIMMERMANN, S. (2004):** Allgemeine Einführung in das fernkundliche Umfeld. ANL Fachtagung: Erfassung und Beurteilung von Seen und deren Einzugsgebiet mit Methoden der Fernerkundung, LSB 03(2), Laufen/Salzach, 11.-12.09.2003, S.25-36.
- SCHNEIDER, W., STEINWENDNER, J. (1999):** Landcover Mapping by Interrelated Segmentation and Classification of Satellite Images. In: International Archives of Photogrammetry and Remote Sensing 32(7-4-3W6), Valladolid, Spanien, 03.-04.06.1999, S.46-52.
- SEGL, K., ROESSNER, S., HEIDEN, U., KAUFMANN, H. (2003):** Fusion of spectral and shape features for identification of urban surface cover types using reflective and thermal hyperspectral data. *Isprs J Photogramm* 58(1-2), S.99-112.
- SIEGERT, F., HOFFMANN, A.A. (2000):** The 1998 forest fires in East Kalimantan (Indonesia): A quantitative evaluation using high resolution, multitemporal ERS-2 SAR images and NOAA-AVHRR hotspot data. *Remote Sens Environ* 72(1), S.64-77.
- SIEGERT, F., RUECKER, G., HINRICHS, A., HOFFMANN, A.A. (2001):** Increased damage from fires in logged forests during droughts caused by El Nino. *Nature* 414(6862), S.437-440.
- SMITS, P.C., ANNONI, A. (1999):** Updating land-cover maps by using texture information from very high-resolution space-borne imagery. *Ieee T Geosci Remote* 37(3), S.1244-1254.
- SMITS, P.C., DELLEPIANE, S.G., SCHOWENGERDT, R.A. (1999):** Quality assessment of image classification algorithms for land-cover mapping: a review and a proposal for a cost-based approach. *Int J Remote Sens* 20(8), S.1461-1486.
- SOHLBACH, M. (2002):** Der Anisotropie-Effekt in Fernerkundungsdaten operationeller Along-Track-Stereosysteme – Informationsgewinn für forstliche Anwendungen? Diplomarbeit, Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt, TU München, Freising/Weihenstephan.
- SOWMYA, A., TRINDER, J. (2000):** Modelling and representation issues in automated feature extraction from aerial and satellite images. *Isprs J Photogramm* 55(1), S.34-47.
- SPACEIMAGING (2002):** IKONOS Product Guide, Version 1.1.
- STEIN, A., BASTIAANSEN, W.G.M., DE BRUIN, S., CRACKNELL, A.P., CURRAN, P.J., FABBRI, A.G., GORTE, B.G.H., VAN GROENIGEN, J.W., VAN DER MEER, F.D., SALDANA, A. (1998):** Integrating spatial statistics and remote sensing. *Int J Remote Sens* 19(9), S.1793-1814.
- STMLF (2004):** GAP-Reform 2005. RB-Nr. 08/04/44, Bayerisches Staatsministerium für Landwirtschaft und Forsten, München.
- STMLF, STMUGV (2005):** Cross Compliance 2005. RB-Nr. 08/05/05, Bayerisches Staatsministerium für Landwirtschaft und Forsten, Staatsministerium für Umwelt, Gesundheit und Verbraucherschutz, München.
- STRAND, G.-H., DRAMSTAD, W., ENGAN, G. (2002):** The effect of field experience on the accuracy of identifying land cover types in aerial photographs. *International Journal of Applied Earth Observation and Geoinformation* 4(2), S.161-173.
- STREIT, U. (1999):** Einführung in die Geo-Informatik. Institut für Geoinformatik, Universität Münster, Skript zur Vorlesung Version 3.3, Internetseite: <http://ifgivor.uni-muenster.de/vorlesungen/Geoinformatik/>, Zugriff: 17.10.2003.
- SWAIN, P.H., SIEGEL, H.J., SMITH, B.W. (1980):** Contextual Classification of Multispectral Remote-Sensing Data Using a Multiprocessor System. *Ieee T Geosci Remote* 18(2), S.197-203.

- TILTON, J.C., VARDEMAN, S.B., SWAIN, P.H. (1982):** Estimation of Context for Statistical Classification of Multispectral Image Data. *Ieee T Geosci Remote* 20(4), S.445-452.
- TOBLER, W. R. (1970):** A Computer Model Simulating Urban Growth in the Detroit Region. *Econ Geogr* 46, S.234-240.
- TÖNJES, R., GROWE, S. (1998):** Knowledge based road extraction from multisensor imagery. In: *International Archives of Photogrammetry and Remote Sensing* 32(3/1), Valladolid, Spanien, 03.-04.06.1999, S.387-393.
- TON, J.C., STICKLEN, J., JAIN, A.K. (1991):** Knowledge-Based Segmentation of Landsat Images. *Ieee T Geosci Remote* 29(2), S.222-232.
- TOUTIN, T., CHENG, P. (2000):** Demystification of IKONOS. *Earth Observation Magazine* 9(7), S.17-21.
- TOUTIN, T. (2003):** Block bundle adjustment of Ikonos in-track images. *Int J Remote Sens* 24(4), S.851-857.
- TOUTIN, T. (2004):** Review article: Geometric processing of remote sensing images: models, algorithms and methods. *Int J Remote Sens* 25(10), S.1893-1924.
- TOWNSHEND, J., WEI LI, C.J., GURNEY, C., MCMANUS, J. (1991):** Global land cover classification by remote sensing: present capabilities and future possibilities. *Remote Sens Environ* 35(2-3), S.243-255.
- TRODD, N. M. (1995):** Uncertainty in land cover mapping for modelling land cover change. In *Remote Sensing Society [Hrsg]: Proceedings of RSS95 remote sensing in action*, Nottingham, S.1138-1145.
- VALTA-HULKKONEN, K., PELLIKKA, P., TRANSCANEN, H., USTINOV, A., SANDMAN, O. (2003):** Digital false colour aerial photographs for discrimination of aquatic macrophyte species. *Aquat Bot* 75(1), S.71-88.
- VAN DER SANDE, C.J. (2001):** River flood damage assessment using IKONOS imagery. Dissertation, Joint Research Centre, Natural Hazards Unit, Italien, Wageningen University, Holland.
- VITOUSEK, P.M. (1994):** Beyond Global Warming - Ecology and Global Change. *Ecology* 75(7), S.1861-1876.
- WALD, L. (1999):** Some terms of reference in data fusion. *Ieee T Geosci Remote* 37(3), S.1190-1193.
- WIENEKE, F. (1990):** Die Eignung der Fernerkundung für geowissenschaftliche Untersuchungen in Bayern. ANL Fachtagung: Einsatzmöglichkeiten der Fernerkundung in der Landschaftsökologie, LSB 90(1), Laufen/Salzach, S.47-55.
- WIKIPEDIA.ORG (2005):** Extensible Markup Language. Internetseite: [www.wikipedia.org](http://www.wikipedia.org), Suchbegriff „XML“, Zugriff: 20.03.2005.
- WOLF, M.L., MLEKUSCH, R., HAB, G. (2004):** Projektmanagement live. München.
- WOODCOCK, C.E., STRAHLER, A.H. (1987):** The Factor of Scale in Remote-Sensing. *Remote Sens Environ* 21(3), S.311-332.
- ZADEH, L.A. (1965):** Fuzzy Sets. *Inform Control* 8, S.338-353.
- ZADEH, L.A. (1973):** Outline of a new approach to the analysis of complex systems and decision processes. *IEEE T Syst Man Cyb* 3(1), S.28-44.

## Danke

Mein besonderer Dank gilt meinem Doktorvater Prof. Ulrich Ammer, der mir diese Dissertation ermöglichte und mir dabei in vielerlei Hinsicht Unterstützung, wertvolle Anregungen sowie kritische Ratschläge gab. Auch sei Herrn Prof. Arnulf Melzer sehr herzlich gedankt, der mit der Limnologischen Station in Iffeldorf ein einzigartiges Arbeitsumfeld geschaffen hat, das ich nutzen durfte.

Genauso herzlich bedanke ich mich bei Dr. Thomas Schneider, der in allen Phasen der Dissertation sowohl fachlich wie auch menschlich mit Rat und Tat zur Seite stand. Danke, Tomi. Auch möchte ich Frau Dr. Uta Raeder hervorheben, die einen Teil der außergewöhnlichen Iffeldorfer Atmosphäre ausmacht und mit der ich viele interessante Gespräche führen konnte. Dankend erwähnt sei hier Stefan Zimmermann, der von Seiten der Limnologischen Station zum Gelingen des Projekts AQUATIC beitrug.

Ferner danke ich meinen Freunden aus dem Team AQUATIC, Thorsten Andresen und Ralf Schüpferling. Es war ein lehrreiches und fantastisches Miteinander in Iffeldorf. Aus diesem Grund sage ich auch allen anderen Mitarbeitern der Limnologischen Station Iffeldorf ein großes und herzliches Dankeschön. Das angenehme „Miteinander“ aber auch das „Drumherum“ werden mir stets in bester Erinnerung bleiben.

Danke möchte ich den beherzten Lektoren Andrea, Susi, und meinem Bruder Paul sagen. Ohne deren tatkräftige Unterstützung wäre diese Arbeit nicht möglich gewesen. Andi Constantinescu sei an dieser Stelle für seine wichtigen konzeptionellen Hinweise besonders gedankt - auch dafür, daß er zur richtigen Zeit einfach ein offenes Ohr hatte.

Danke an alle Mitarbeiter des Lehrstuhls für Landnutzungsplanung und Naturschutz, denn es war immer eine Freude sie zu treffen.

Gabi möchte ich danken, weil sie stets da war. Genauso bedanke ich mich bei meinen Freunden.

Ein großes Dankeschön gilt meinen Eltern, die mich immer unterstützten.

Vielen Dank an alle!

# Lebenslauf

## ANGABEN ZUR PERSON

Name Claudius Mott

Geburtsdatum 18.06.1974

Staatsangehörigkeit deutsch

## BERUFSERFAHRUNG

2001-2005 Promotion am Department für Ökosystem- und Landschaftsmanagement an der Technischen Universität München

1999-2001 GIS- und Fernerkundungsexperte bei RSS GmbH, München

## UNIVERSITÄRE AUSBILDUNG

1993-1999 Studium der Biologie an der Ludwig-Maximilians-Universität, München  
Abschluß: Diplom-Biologe  
Schwerpunkte: Zoologie, Informatik, Ökologie, Fernerkundung, Botanik

## SCHULAUFBILDUNG

1984-1993 Gymnasium Kirchheim  
Abschluß Abitur

1980-1984 Grundschule in München und in Kirchheim