

Department für Ökologie
Fachgebiet für Limnologie

Strategien zur wissensbasierten Bildanalyse hoch auflösender
Fernerkundungsdatensätze für das Monitoring gewässernaher
Feuchtgebiete

Thorsten Andresen

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

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr. Wilfried Huber
Prüfer der Dissertation: 1. Univ.-Prof. Dr. Arnulf Melzer
2. Univ.-Prof. Dr. Ulrich Ammer, em.

Die Dissertation wurde am 15.01.2004 bei der Technischen Universität München eingereicht und durch die Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt am 16.04.2004 angenommen.

Strategien zur wissenschaftlichen Bildanalyse hoch
auflösender Fernerkundungsdatensätze für das
Monitoring gewässernaher Feuchtgebiete

1	Einführung	13
2	Stand der Forschung und Methode	17
2.1	<i>Konventionelle Klassifikation von Bilddaten</i>	17
2.2	<i>Pixelbasierte Klassifikation</i>	19
2.2.1	Unüberwachte Verfahren.....	19
2.2.2	Überwachte Verfahren.....	21
2.2.2.1	Entscheidungsregeln	23
2.2.3	Grenzen pixelbasierter Verfahren.....	24
2.3	<i>Kontextbasierte Verfahren.....</i>	26
2.4	<i>Maßstabsebene.....</i>	31
2.5	<i>Objektorientierte und wissensbasierte Klassifikation.....</i>	34
2.5.1	Der Objektbegriff.....	35
2.5.2	Segmentierungsverfahren	38
2.6	<i>Die eCognition-Methode.....</i>	43
2.6.1	Segmentierung in eCognition	43
2.6.1.1	Grundkonzept der Segmentierung in eCognition.....	44
2.6.1.2	Nachbearbeitung und Verbesserung	48
2.6.1.3	Ergebnis der Segmentierung	48
2.6.2	Wissensmanagement in eCognition	49
2.6.2.1	Wissensbasis.....	50
2.6.2.2	Wissensrepräsentation	51
2.6.2.3	Regelwerke und Klassifikation	52
2.7	<i>Klassifikationsqualität</i>	54
2.7.1	Klassische Verfahren.....	54
2.7.2	Fehleranalyse im objektorientierten Umfeld	58
3	Feuchtgebiete und thematisches Umfeld	61
3.1	<i>Bedeutung von Feuchtgebieten.....</i>	61
3.1.1	Ökologische Bedeutung.....	62
3.1.2	Ökonomische Betrachtung	63
3.2	<i>Schutz von Feuchtgebieten</i>	63
3.3	<i>Fernerkundung von Feuchtgebieten.....</i>	65
3.3.1	Grundlagen	65
3.3.2	Angewendete Verfahren.....	67
4	Untersuchungsgebiet und Datenmaterial	71
4.1	<i>Untersuchungsgebiet.....</i>	71

4.2	<i>Satellitendaten</i>	74
4.2.1	Verwendete Szenen	74
4.2.2	Eigenschaften von IKONOS Daten.....	76
4.2.3	Geometrische Korrektur.....	77
4.3	<i>Luftbilder und Orthofotos</i>	81
4.3.1	Verwendete Bildflüge.....	81
4.3.2	Geometrische Korrektur.....	82
4.4	<i>Hyperspektraldaten</i>	84
4.4.1	Eigenschaften des CASI-Sensors	84
4.4.2	Korrekturen	85
4.4.3	Fehler.....	85
4.5	<i>Digitale Höhenmodelle</i>	86
4.5.1	„Kontrollpunktaufnahmen mit GPS“	86
4.5.2	Eigenschaften der berechneten DOMs.....	87
4.6	<i>Geländebegehungen und Kartierungen</i>	88
5	Ergebnisse	89
5.1	<i>Klassifikationsstrategien</i>	89
5.1.1	Klassifikation von IKONOS-Daten	90
5.1.1.1	Vererbungshierarchie und semantische Gruppen im April 2001:	93
5.1.1.2	Vererbungshierarchie und semantische Gruppen im August 2001	96
5.1.1.3	Vererbungshierarchie der multisaisonalen Daten August & April	98
5.1.2	Klassifikation von CASI-Daten.....	100
5.1.2.1	Vorausscheidung eindeutiger Klassen (nach Löschenbrand 2003).....	101
5.1.2.2	Detaillierte CASI-Klassifikation	102
5.1.3	Klassifikation von Orthofotos	104
5.1.4	Strategieunterschiede.....	107
5.2	<i>Objektdefinitionen</i>	108
5.3	<i>Klassifikationsergebnisse und –qualität</i>	115
5.3.1	Klassenbeschreibungen	115
5.3.2	IKONOS Klassifikationsergebnisse	118
5.3.2.1	Vorklassifikationen April und August – Level 4	119
5.3.2.2	Detaillklassifikation Moor – Level 1.....	121
5.3.2.3	Detaillklassifikation Feuchtgebiete – Level 1	123
5.3.2.4	Detaillklassifikation Wasser und Gewässervegetation – Level 2.....	127
5.3.2.5	Klassifikation innerhalb vorgegebener Grenzen	130
5.3.3	CASI-Klassifikationsergebnisse.....	134
5.3.4	Orthofoto Klassifikationsergebnisse	137
5.3.5	Klassifikationsverbesserung durch Verschneidung	142

6	Diskussion	145
6.1	<i>Datenvorverarbeitung</i>	<i>145</i>
6.2	<i>Klassifikationsstrategien</i>	<i>147</i>
6.3	<i>Objektdefinitionen</i>	<i>151</i>
6.3.1	Anwendung der Objektdefinition	153
6.3.2	Nutzung externer Daten	155
6.3.3	Vergleich der Objektdefinitionen	155
6.4	<i>Klassifikationsergebnisse und –qualität</i>	<i>156</i>
6.4.1	Vorklassifikation	156
6.4.2	Detailklassifikation	157
6.4.3	Landschaftsveränderung	158
6.5	<i>Fazit</i>	<i>159</i>
7	Zusammenfassung	163
8	Literaturverzeichnis	167

Abbildungsverzeichnis

Abb. 1: Punktwolken / Cluster in einem dreidimensionalen Merkmalsraum.....	18
Abb. 2: Initiale Verteilung der Clustermittelpunkte beim ISODATA-Verfahren.....	20
Abb. 3: Abgrenzung von Klassen mit dem ISODATA Algorithmus	21
Abb. 4: Überlappende (links) und eindeutig getrennte Signaturen (rechts) in einem theoretischen Merkmalsraum	22
Abb. 5: Erweiterter Merkmalsraum.....	28
Abb. 6: Vergleich der Auftretenshäufigkeit von Grauwerten in zwei unterschiedlichen Klassen	29
Abb. 7: Veränderung der Landschaft bei einer Maßstabsänderung.....	32
Abb. 8: Abhängigkeit verschiedener Landschaftsparameter von der räumlichen Auflösung.	33
Abb. 9: Darstellung des Quadtree-Verfahrens	40
Abb. 10: Segmentierung auf unterschiedlichen Maßstabsebenen.....	43
Abb. 11: Hierarchisches Netzwerk von Bildobjekten auf zwei Ebenen.	49
Abb. 12: Zusammenstellung von Objekteigenschaften aus der eCognition-Datenbank	50
Abb. 13: Stabile und instabile Eigenschaften in der eCognition Objektdatenbank.....	51
Abb. 14: Zugehörigkeitsfunktion eines beliebigen Merkmals aus der Objektdatenbank.	53
Abb. 15: Links: Überschneidung der spektralen Signaturen von Feuchtgebietsvegetation untereinander.	66
Abb. 16: Teiluntersuchungsgebiete.....	73
Abb. 17: Darstellung der Aufnahmesituation des IKONOS-Satelliten im April und August 2001	75
Abb. 18: Das Flugzeug in der IKONOS Szene zeigt den Zeitversatz zwischen PAN-Kanal (a) und den multispektralen Kanälen (b).....	76
Abb. 19a,b,c: Die Geo-Koordinaten der Orthophoto-Referenz des LVA kamen in den IKONOS-Szenen an anderer Stelle zu liegen	78
Abb. 20: Vergleich von Höhenangaben des LVA mit den eigenen GPS Messungen	86
Abb. 21: Schema einer Klassenhierarchie.	89
Abb. 22: Beispiel einer Gegenüberstellung von Vererbungs- (links) und Gruppenhierarchie (rechts) aus eCognition	90
Abb. 23: Texturklassen aus panchromatischen IKONOS-Daten.....	91
Abb. 24: Level 4 - Vorklassifikation (links Vererbung; rechts Gruppierung) IKONOS April 2001.	94
Abb. 25: Level 3 - Thematische Ebene mit Waldinformationen aus IKONOS-Daten August 2001.	94
Abb. 26: Level 2 - Detailklassifikation Wasser (Links Vererbung; Rechts Gruppierung) IKONOS April 2001.	95
Abb. 27: Level 1 - Detailklassifikation Feuchtgebiete (links Vererbung; rechts Gruppierung) IKONOS April 2001.	95
Abb. 28: Level 4 - Vorklassifikation (Links Vererbung; Rechts Gruppierung) IKONOS August 2001	96
Abb. 29: Level 2 - Detailklassifikation Wasser (Links Vererbung; Rechts Gruppierung) IKONOS August 2001	97

Abb. 30: Level 1 - Detailklassifikation Feuchtgebiete (Links Vererbung; Rechts Gruppierung) IKONOS August 2001	98
Abb. 31: "Structure groups" des multisaisonalen Datensatzes für die klassifikationsbasierte Segmentierung	99
Abb. 32: Level 5 und 6 - kombinierte IKONOS-Daten – multisaisonaler Datensatz.....	99
Abb. 33: Level 7 und 3 – Links: Wasser Vorklassifikation; rechts: Detaillierte Reklassifikation auf niedrigerem Level	101
Abb. 34: Level 2 - Detaillierte Feuchtgebietsklassifikation aus den hyperspektralen CASI- Daten	103
Abb. 35: Vererbungshierarchien der Level 2, 3 und 4 der Orthofotoklassifikation	106
Abb. 36: Links: Schilf- und verbuschte Streuwiesenflächen am nordwestlichen Rand des Maisinger Sees.....	115
Abb. 37: Schilfbestände an den Osterseen. Links: Lockere Schilfbestände im Norden (oben) und dichtes Schilf im Süden (unten).....	116
Abb. 38: Links: Randbereich am nordwestlichen Ende des Weidfilzes.....	117
Abb. 39: Links: Weidfilz östlich der Osterseen mit aufgestauten ehem. Entwässerungskanälen (oben) und Aushublöchern (unten).....	117
Abb. 40: Links: <i>Myriophyllum spicatum</i> und <i>Nymphoides peltata</i> in einer Staustufe am Nordende der Osterseen	118
Abb. 41: Klassifikation von IKONOS, April 2001	119
Abb. 42: Klassifikation von IKONOS, August 2001	120
Abb. 43: Klassifizierte Hochmoorkerne des Weid- bzw. Schechenfilzes östlich der Osterseen. IKONOS April 2001	121
Abb. 44: Klassifizierte Hochmoorkerne des Weid- bzw. Schechenfilzes östlich der Osterseen. IKONOS August 2001	122
Abb. 45: IKONOS April 2001. Detaillierte Feuchtgebietsklassifikation der südlichen Osterseen.....	124
Abb. 46: IKONOS August 2001. Detaillierte Feuchtgebietsklassifikation der südlichen Osterseen.....	124
Abb. 47: IKONOS April 2001. Detaillierte Feuchtgebietsklassifikation der nördlichen Osterseen.....	125
Abb. 48: IKONOS August 2001. Detaillierte Feuchtgebietsklassifikation der nördlichen Osterseen.....	125
Abb. 49: Detailklassifikation Wasser (Level 2). IKONOS August 2001 südliche Osterseen	127
Abb. 50: Detailklassifikation Wasser (Level 2). IKONOS August 2001 nördliche Osterseen	128
Abb. 51: Multisaisonale IKONOS-Klassifikation	129
Abb. 52: Gewässervegetation im Detail. Staustufe Bodenbach.....	130
Abb. 53: Klassifikation innerhalb von Grenzen der Biotoptypenkartierung östlich von Starnberg. IKONOS August 2001.....	131
Abb. 54: Klassifikation innerhalb der Biotoptypenkartierung am Maisinger See, westlich von Starnberg. IKONOS August 2001.....	132

Abb. 55: Fehlklassifikationen am Maisinger See, westlich von Starnberg. IKONOS August 2001	133
Abb. 56: Klassifikation der CASI-Daten am Weid- und Schechenfilz östlich der Osterseen	134
Abb. 57: Klassifikation „Iffeldorfer Seengruppe“, Befliegung 2000 Level 2	137
Abb. 58: Klassifikation „Iffeldorfer Seengruppe“ Befliegung 1976 Level 2	138
Abb. 59: Klassifikation „Iffeldorfer Seengruppe“ Befliegung 1956 Level 2	138
Abb. 60: Klassifikation „Nördliche Osterseen“ Befliegung 1999 ohne DOM Level 2	140
Abb. 61: Klassifikation „Nördliche Osterseen“ Befliegung 1999 mit DOM Level 2	140
Abb. 62: Orthofotoklassifikation innerhalb von klassifizierten IKONOS-Schilfobjekten	143
Abb. 63: Zeitreihe der Verbuschung aus Orthofotos am nördlichen Rand des Weidfilzes...	144

Tabellenverzeichnis

Tab. 1: Allgemeine Form einer Fehlermatrix, mit Standardfehlermaßen	56
Tab. 2: Der IKONOS-Satellit auf einen Blick	76
Tab. 3: Fehlerwerte bei unterschiedlich hoher Anzahl von Passpunkten.....	79
Tab. 4: Ablaufschema einer objektorientierten Klassifikation von IKONOS-Daten	91
Tab. 5: Segmentierungsparameter für panchromatische IKONOS-Daten	91
Tab. 6: Segmentierungsparameter für multispektrale IKONOS-Daten	92
Tab. 7: Unterscheidbare Klassen der IKONOS-Szenen vom 24.04.2001 und 12.08.2001	93
Tab. 8: Segmentierungsparameter für multisaisonale IKONOS-Daten.....	98
Tab. 9: Ablaufschema einer objektorientierten Klassifikation multisaisonaler IKONOS-Daten	100
Tab. 10: Ablaufschema einer Klassifikation hyperspektraler CASI-Daten	101
Tab. 11: Klassen der finalen CASI-Auswertung	103
Tab. 12: Ablaufschema einer Klassifikation von s/w Luftbild-Daten.....	104
Tab. 13: Jahrgänge der verwendeten Luftbildzeitreihe, X = Höhenmodell vorhanden.....	105
Tab. 14: Gegenüberstellung der mit unterschiedlichen Sensoren erkannten Klassen.....	107
Tab. 15: Objektdefinitionen im Vergleich: Wasserflächen insgesamt	109
Tab. 16: Detaillierte Klassendefinition der Wasserklassen auf Level 4 für IKONOS August 2001	110
Tab. 17: Objektdefinitionen im Vergleich: Flachwasser	111
Tab. 18: Objektdefinitionen im Vergleich: Feuchtgebiete insgesamt	111
Tab. 19: Objektdefinitionen im Vergleich: Vegetation im Gewässer (vor allem Schwimmblatt)	112
Tab. 20: Objektdefinitionen im Vergleich: offene (Hoch-)Moorbereiche, ohne Verbuschung	112
Tab. 21: Objektdefinitionen im Vergleich: Verbuschte Feuchtgebiete ohne Hochmoorbereiche	113
Tab. 22: Objektdefinitionen im Vergleich: Dichte Schilfröhrichtbestände.....	114
Tab. 23: Objektdefinitionen im Vergleich: Lockere Schilfbestände, seggendominiert.....	114
Tab. 24: IKONOS-Klassifikationsqualität auf Level 1. Klasse: Dichtes Schilf	126
Tab. 25: IKONOS-Klassifikationsqualität auf Level 1. Klasse: Schilf/Seggen-Mosaik in Wassernähe	126
Tab. 26: IKONOS-Klassifikationsqualität auf Level 1. Klasse: Seggendominiertes Niedermoor	126
Tab. 27: Klassifikationsqualität der Wasserklassen. IKONOS August 2001	128
Tab. 28: Klassifikationsqualität der Gewässervegetationsklassen. IKONOS multisaisonale Auswertung.....	130
Tab. 29: Klassifikationsqualität der detaillierten Schilfklassen am Maisinger See. IKONOS August 2001	132
Tab. 30: Produzentengenauigkeit der CASI-Klassifikation (verändert nach Löschenbrand 2003)	135
Tab. 31: Benutzergenauigkeit der CASI-Klassifikation (verändert nach Löschenbrand 2003)	135

Tab. 32: Produzentengenauigkeit der Klassifikation „Iffeldorfer Seengruppe“ 2000	139
Tab. 33: Benutzergenauigkeit der Klassifikation „Iffeldorfer Seengruppe“ 2000	139
Tab. 34: Produzentengenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 ohne DOM	141
Tab. 35: Benutzergenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 ohne DOM .	141
Tab. 36: Produzentengenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 mit DOM	142
Tab. 37: Benutzergenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 mit DOM	142
Tab. 38: Detaillierte Klassenhierarchie IKONOS April 2001	184
Tab. 39: Detaillierte Klassenhierarchie IKONOS August 2001	193

1 Einführung

Der Rat der Sachverständigen für Umweltfragen schreibt in seinem Sondergutachten „Allgemeine Ökologische Umweltbeobachtung“:

„Umwelt ist ein komplexes System, das mit den bisher angewandten sektoralen Instrumenten allein nur unzulänglich beeinflusst und gestaltet werden kann; diese führen oft nur zur Verschiebung eines Umweltproblems von einem Umweltmedium in ein anderes.“ (Der Rat der Sachverständigen für Umweltfragen, zit. in Schönthaler 2002)

Globale Umweltveränderungen zwingen eine neue Betrachtungs- und Bewertungsweise auf. Das macht neue Methoden zur Beobachtung und Analyse dieser Veränderungen erforderlich. Die Verantwortung für die Analyse und Bewertung der relevanten Daten obliegt den Behörden der EU sowie des Bundes und Länder. Für eine abgestimmte Überwachung zwischen den Behörden von Bund und Ländern ist u. a. eine einheitliche Datenbasis notwendig. Dabei ist eine Umsetzung von Maßnahmen nur mit einer breiten Akzeptanz in der Öffentlichkeit erreichbar (Schönthaler 2002). Zur Visualisierung der Veränderungen in der Umwelt kann insbesondere die Fernerkundung beitragen und so ggf. die gesellschaftliche Wahrnehmung von Problembereichen beeinflussen.

Bei der Überwachung von Umweltveränderungen im globalen und regionalen Bereich ist die Fernerkundung bereits heute ein häufig eingesetztes Werkzeug. Operationelle Systeme wie die Landsat Satelliten stellen zusammen mit automatisierbaren statistischen Auswerteverfahren, bereits seit Jahren Umweltdaten zur Verfügung.

Moderne Satelliten, beispielsweise der seit 1999 im Orbit befindliche IKONOS, bieten eine erheblich höhere räumliche Auflösung. Der Anwendungsbereich dieser Daten erstreckt sich bis in die lokale Ebene. Hochdetaillierte Auswertungen von gefährdeten Bereichen können mit der regelmäßig verfügbaren Information aus dem All durchgeführt werden. Die hierbei anfallende Datenmenge ist immens. Zur Auswertung dieser hohen Informationsmenge werden neue Verfahren benötigt. Das Ziel sind seit vielen Jahren automatisierte Verfahren für die Erhebung und zur Aktualisierung von Geodaten mit Hilfe der Fernerkundung.

Ziel der vorliegenden Arbeit ist es, automatisierbare Auswertestrategien auf der Basis objektorientierter Bildanalyseverfahren zu entwickeln. Mit diesen Verfahren sollen Daten unterschiedlicher, räumlich sehr hoch auflösender Fernerkundungssensoren so ausgewertet werden, dass die Ergebnisse vergleichbar sind und sich ergänzen.

Der Schwerpunkt liegt auf der Analyse sehr hoch auflösender IKONOS Satellitendaten sowie in der Integration der Klassifikation von Orthofotos¹ und flugzeuggetragenen Hyper-

¹ Orthofotos sind entzerrte und geometrisch korrigierte Luftbilder. Das Gelände wird hierbei in senkrechter Parallelprojektion auf eine horizontale Ebene abgebildet und das Luftbild dabei so verändert, dass es geometrisch die Eigenschaften einer Karte besitzt (Albertz 2001, S.158).

spektraldaten. Mit Hilfe von möglichst einfachen Regelwerken sollen Eigenschaften von Objekten der realen Welt so formuliert werden, dass diese in den unterschiedlichen Bilddaten mit vergleichbaren Regeln erkannt werden.

Der thematische Fokus liegt auf der Klassifikation von gewässernahen Feuchtgebieten, insbesondere der Erfassung von Schilfgürteln und deren Veränderung sowie auf der Klassifikation der Wasserfläche und submerser Makrophyten. Im Vordergrund steht hier die besondere Bedeutung von Feuchtgebieten, insbesondere die Wasserreinigung, die ausgleichende Wirkung als Wasserspeicher und Retentionsraum bei Hochwässern und nicht zuletzt die große Artenvielfalt der Flora, die eine genau so vielfältige Fauna zur Folge hat. Die besonderen Eigenschaften von Feuchtgebieten, die sie zum thematischen Inhalt dieser Arbeit gemacht haben und Maßnahmen zu deren Schutz, werden in Kapitel 3 genauer besprochen.

Diese Arbeit ist Bestandteil des Projektes AQUATIC. Ziel dieses Projektes ist die Klassifikation der Landoberfläche im ufernahen Bereich oberbayerischer Seen unter Anwendung einer objektorientierten Analyse sehr hoch auflösender Satellitendaten. Im Rahmen dieses Projektes werden die Landnutzung sowie Waldgebiete in einer weiteren Doktorarbeit bearbeitet (Mott unveröff.).

Fernerkundung und Planungsprozesse

Die folgende Begriffsdefinition der Fernerkundung soll nur eine kurze Einführung in das Thema bieten. Detaillierte Beschreibungen hierzu finden sich in diversen Lehrbüchern zum Thema.

Folgt man der Definition des Deutschen Instituts für Normung e.V., speziell der **DIN 18716/3 ("Photogrammetrie und Fernerkundung: Begriffe der Fernerkundung")**, dann wird Fernerkundung verstanden 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.“ (Deutsches Institut für Normung e.V. (DIN) 1997)

Die Fernerkundung nimmt also reflektierte oder emittierte Strahlung der Erdoberfläche auf, bildet diese ab und wertet sie aus. Mit diesem Werkzeug können große, teilweise unzugängliche Gebiete schnell und effektiv überwacht werden.

In dieser Arbeit werden die gängigen Auswerteverfahren mit Bezug auf sehr hoch auflösende Daten analysiert und modernen objektorientierten Verfahren gegenüber gestellt. Sie sind

deshalb gesondert und ausführlich im Stand der Forschung in Kapitel 2 sowie in der Beschreibung der Methodik des verwendeten Verfahrens unter Punkt 2.5 beschrieben.

Sehr hoch auflösende FE-Daten (Satelliten- und auch Luftbilder) der IKONOS-Generation liefern Informationen auf einer Maßstabsebene, die für aktuelle, umweltbezogene Fragestellungen notwendig ist. Sie bieten einen sehr hohen Informationsgehalt bei guter Interpretierbarkeit, hoher Bildschärfe, Präzision sowie eine hohe Bildreinheit und -integrität. Der IKONOS-Satellit befindet sich seit 1999 im Orbit. Er liefert auf Anforderung Bilder mit einer Auflösung von vier Metern multispektral und einem Meter panchromatisch. Flugzeuggetragene Sensoren bieten darüber hinaus im Falle von Luftbildern oder digitalen Scannern (wie HRSC-A) noch deutlich höhere räumliche Auflösungen bis zu 20 cm oder darunter. Hyperspektrale Sensoren² hingegen liefern zusätzlich sehr hohe spektrale Auflösungen mit teilweise hunderten von Spektralkanälen, i. d. R. aber bei etwas verringerter räumlicher Auflösung im Bereich von einem bis fünf Metern.

Für die Überwachungsanforderungen oder die Bestandsaufnahme, die sich aus den in neuen Richtlinien (vgl. Abschnitt 3.1) ergeben, kann die Fernerkundung wichtige Beiträge leisten. Landnutzungen und vor allem die Landbedeckung sowie Veränderungen in Feuchtgebieten und Gewässern können mit Fernerkundungsmethoden erkannt und quantifiziert werden.

Im Rahmen von Planungsprozessen in Behörden wurden und werden Fernerkundungsdaten im Bereich des Monitorings von geschützten Biotopen sowie zur Fortschreibung von Biotopkartierungen genutzt. Im Wesentlichen werden hier aber Luftbilder oder flugzeuggetragene Scannerdaten verwendet (Tschach 2002). Seit etwa Mitte der 80er Jahre werden CIR Luftbilder in Behörden zur Unterstützung der seit den 70er Jahren landesweit durchgeführten selektiven Kartierung von Biotop- und Nutzungstypen im Maßstab 1:10.000 eingesetzt. Diese werden bislang von Bearbeitern visuell ausgewertet, was eine Gefahr der Subjektivität dieser Auswertungen beinhaltet und einen hohen Zeitaufwand erfordert. Eine Veränderungsanalyse mit Fernerkundungsdaten kann, u. a. nach Tschach (2002), zur Kostenreduktion beitragen, da nur noch veränderte Bereiche mit teuren Feldkampagnen überprüft werden müssen. Die unter hohem Kostendruck stehenden Behörden können mit Hilfe der Fernerkundung große Teile ihrer Monitoringpflichten, die sich aus den neuen EU-weiten Vorgaben ergeben, erfüllen.

Eine operationelle Auswertung von sehr hoch auflösenden Daten, seien es nun Satelliten- oder Luftbilder, ist mit bisher verwendeten Methoden, wie den pixelbasierten statistischen Auswerteverfahren, nicht befriedigend möglich. Diese können die Komplexität sehr hoch aufgelöster Daten nicht verarbeiten. Neue Methoden zur Auswertung sind daher notwendig.

² Hyperspektrale Sensoren – besitzen eine sehr hohe spektrale Auflösung, d. h. sie decken i. d. R. den Bereich des visuellen Spektrums und des nahen Infrarots mit sehr vielen schmalen und eng beieinander liegenden Kanälen ab. Geringe spektrale Unterschiede in der Reflexion von Landoberflächen können so theoretisch besser erkannt werden.

In dieser Arbeit wird ein objektorientiertes Verfahren angewendet. Dieses Verfahren wird im Methodenteil in Kapitel 2.5 detailliert beschrieben. Es stehen damit neue Möglichkeiten zur Verfügung, um auf der Basis von übertragbaren Regelwerken vergleichbare Klassifikationen zu schaffen, die eine einfachere und objektivere Auswertung von Einzelbildern und Zeitreihen ermöglichen.

2 Stand der Forschung und Methode

2.1 Konventionelle Klassifikation von Bilddaten

„Automatic interpretation of aerial photographs has been a dream in remote sensing, ...” (Matsuyama 1987, S.305)

Fernerkundungssensoren auf Satelliten oder Flugzeugen erfassen die Reflexion der Erdoberfläche in verschiedenen Bereichen des elektromagnetischen Spektrums. Sie bilden diese Reflexion in Grauwerten kodiert in den Punkten (Pixeln³) eines Bildes ab. Die Eigenschaften oder Merkmale der unterschiedlichen Kanäle bilden den so genannten Merkmalsraum, der für die Auswertung mit Hilfe von Klassifikationsverfahren genutzt wird.

Das gemeinsame Ziel von **Klassifikationsverfahren** ist die automatische Einteilung aller Punkte in einem Bild in diskrete Landbedeckungsklassen (Lillesand und Kiefer 2000, S.532). Objekte eines Bildes sollen anhand ihrer Merkmale, i. d. R. ihrem Grauwert, mit Hilfe von Klassifikationsverfahren zu Klassen zusammengefasst werden. Unbekannte Objekte sollen anschließend diesen Klassen möglichst eindeutig zugeordnet werden (Bähr und Vögtle 1998, S.77).

Die Auswertung von Bilddaten lässt sich grundsätzlich in zwei Bereiche einteilen. Auf der einen Seite stehen die klassischen, **pixelbasierten** Klassifikationsverfahren und auf der anderen Seite die **regionenorientierten** Verfahren, welche Objekte analysieren. Die ersteren beziehen nur die Grauwerte einzelner Bildpunkte in ihre Analyse ein. Im Gegensatz dazu berücksichtigt die zweite Gruppe von Verfahren zusätzlich die Nachbarschaft von Bildsegmenten sowie Zusatzinformationen.

Merkmalsraum

Der **Merkmalsraum** ist die räumliche Repräsentation der Eigenschaften bzw. **Merkmale** eines Fernerkundungsdatensatzes.

Inhärente Merkmale eines Fernerkundungsdatensatzes sind im Falle der klassischen Bildanalyse die n Spektralkanäle eines Sensors. Aus diesen n -Merkmalen wird ein Koordinatensystem mit rechtwinklig aufeinander stehenden Achsen gebildet. Diese spannen einen n -dimensionalen Merkmalsraum auf (Bock 1995). Jeder Bildpunkt kann als Komponente eines n -dimensionalen Vektors, dem Merkmalsvektor bzw. Grauwertvektor, angesehen werden (Bakker et al. 2001).

³ Pixel = Bildpunkt, Kurzform von *picture element* (eng.)

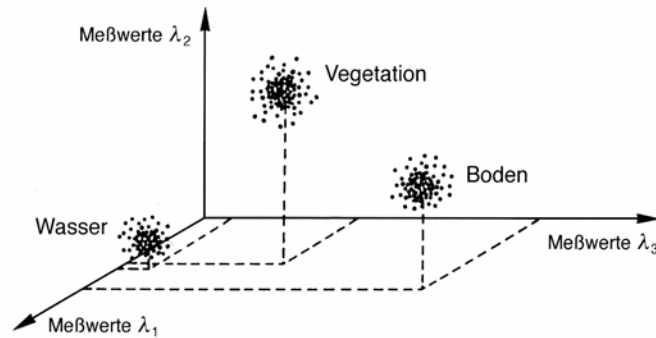


Abb. 1: Punktwolken / Cluster in einem dreidimensionalen Merkmalsraum (aus Albertz 2001)

Beispielsweise wird der Merkmalsraum eines multispektralen IKONOS-Satellitenbildes über seine vier Kanäle im blauen, grünen, roten und infraroten Bereich des elektromagnetischen Spektrums gebildet.

Aussagen über die erfassten Objekte werden bezüglich ihres Reflexions- bzw. Absorptionsverhaltens in Abhängigkeit von der Wellenlänge getroffen.

Oft werden transformierte Merkmale anstelle der spektralen Werte für die Analyse herangezogen. Allerdings verbessern zu viele Merkmale eine Klassifikation nicht unbedingt und sie erhöhen die Rechenzeit zum Teil erheblich (Ton et al. 1991).

Jeder Bildpunkt im Datensatz wird in Form eines Grauwert- oder **Merkmalsvektors** über alle Merkmale beschrieben und hat eine eindeutige Position im Merkmalsraum (Jähne 2002, S.545).

Eine **Klasse** bildet Punkthaufen aufgrund individueller Unterschiede der einzelnen Pixel im Merkmalsraum. Unterschiedliche Klassen liegen an signifikant unterschiedlichen Stellen im Merkmalsraum (siehe Abb. 1). Idealerweise können diese so genannten *Cluster* eindeutig abgegrenzt werden (Albertz 2001, S.162). In realen Datensätzen sind diese *Cluster* jedoch oft nicht so deutlich voneinander getrennt oder überlappen sich gar. Der Grund dafür sind etwa nur in begrenztem Umfang zur Verfügung stehende oder ungünstig gewählte Merkmale. **Eine fehlerfreie Klassifikation ist deshalb in der Praxis selten.**

Die unterschiedlichen Verfahren der Bildauswertung werden in den nachstehenden Abschnitten vorgestellt, um deren unterschiedliche Arbeitsweise aufzuzeigen und die Gründe für den Einsatz eines wissensbasierten Systems herauszuarbeiten.

Zunächst werden die verschiedenen pixelbasierten Verfahren dargestellt (2.2). In Abschnitt 2.3 werden dann einige der so genannten kontextbasierten Verfahren besprochen. Diese stellen die Grundlage der heutigen objektorientierten bzw. wissensbasierten Bildanalyseverfahren dar. In Kapitel 2.5 wird die Arbeitsweise der aktuellen objektorientierten Bildanalyse am Beispiel des Programms eCognition im Detail erläutert.

2.2 Pixelbasierte Klassifikation

Ein Pixel oder Bildpunkt ist die kleinste Informationseinheit in einem digitalen Bild. Eine weitere Zerlegung dieser Einheit führt zu keinem Informationsgewinn, sondern nur zu einer Wiederholung der bekannten Information (Fisher 1997).

Ein Computer kann im Gegensatz zu einem menschlichen Interpreten sehr gut und mit hoher Präzision Grauwerte unterscheiden und auf dieser Basis z. B. Klasseneinteilungen vornehmen (Albertz 2001, S.160).

Die Verfahren der **multispektralen Klassifikation** machen sich diese hohe Präzision zu Nutze. Mit Hilfe unterschiedlicher statistischer Verfahren werden über die Häufung von Grauwerten im Merkmalsraum Klassen gebildet.

Die Klassifikationsverfahren der „klassischen“ Bildanalyse lassen sich in zwei Gruppen einteilen: **Überwachte Verfahren** benötigen Vorwissen eines Interpreten für die Klassifikation. Sie werden in 2.2.2 detaillierter vorgestellt. Bei **unüberwachten Verfahren** liegt eine solche Vorinformation nicht vor. Neben diesen beiden Verfahren gibt es hybride Verfahren, welche die Auswerteverfahren kombinieren und z. B. beim *guided clustering* bereits Vorinformationen, ähnlich den Trainingsgebieten der überwachten Verfahren (siehe 2.2.2), nutzen.

2.2.1 Unüberwachte Verfahren

Diese Verfahren versuchen mit Hilfe einer **Cluster-Analyse** alle Pixel eines Bildes in eine bestimmte Anzahl von Klassen zu unterteilen.

Bei einigen Verfahren wird die Anzahl der gewünschten Klassen vorgegeben. Im Prinzip ist hierfür ebenfalls Vorwissen notwendig. Cluster-Verfahren sollen inhärente statistische Muster eines Datensatzes erkennen (ERDAS 1997, S.225). Die Definition der Klassen ist ausschließlich von den Daten selbst abhängig (Bock 1995, S.11). Die Häufigkeitsverteilung innerhalb des Datensatzes sowie die Anzahl der Klassen sind unbekannt.

Die unüberwachten Verfahren gelten als objektiver bei der Klassengenerierung als überwachte Klassifikationen. Sie benötigen aber nach diesem Schritt ebenfalls einen Bearbeiter, um die Klassen nachträglich in sinnvolle Landbedeckungseinheiten zu überführen. Im Gegensatz dazu werden die unüberwacht klassifizierten Daten mit Referenzdaten wie z. B. Kartierungen oder den Ergebnissen von Geländebegehungen verglichen, um ihnen eine Bedeutung zuzuweisen.

Da Cluster-Analysen inhärente spektrale Muster im Datensatz aufspüren, besteht die Schwierigkeit darin, dass diese nicht unbedingt mit bestehenden Mustern der Realität übereinstimmen müssen. Aus diesem Grund werden unüberwachte Verfahren häufig nur für die Vorbereitung einer überwachten Klassifikation genutzt. Mit ihnen kann die spektrale Trennbarkeit von Klassen im Voraus festgestellt werden bzw. es kann überprüft werden, ob gewählte Klassen nicht wiederum in einzelne Teilklassen zerfallen (Albertz 2001, S.164).

Im Folgenden soll das *Isodata*-Verfahren als der bekannteste Vertreter der unüberwachten Klassifikation näher vorgestellt werden.

ISODATA - Verfahren

Der Begriff *Isodata* steht für „*Iterative Self-Organizing Data Analysis*“. Dieses Verfahren stammt aus den späten 60er Jahren und wurde von Ball und Hall (1967) entwickelt.

Dieser Algorithmus wiederholt die vollständige Klassifikation eines Datensatzes so lange, bis ein bestimmtes Abbruchkriterium erreicht ist. Dabei werden statistische Maße so lange verändert, bis die Grauerhäufungen im Datensatz erkennbar sind. Das Verfahren benötigt kaum Vorinformationen. Neben der Anzahl der Cluster wird zusätzlich die Angabe der maximal erlaubten Iterationen benötigt. Als Abbruchkriterium wird die Anzahl der Pixel in Prozent angegeben, die bei der nächsten Iteration unverändert bleiben müssen. Durch die Angabe der maximalen Anzahl der Cluster wird dennoch ein Vorwissen durch den Anwender vorausgesetzt. Er muss den Datensatz und das Gebiet kennen, um abschätzen zu können, wie viele verschiedene Landbedeckungen vorkommen und wie gut diese sich spektral trennen lassen.

Der Prozess beginnt mit der willkürlichen Festlegung von Clustermittelpunkten irgendwo im Datensatz. Die Mittelwerte dieser Cluster werden entlang einer Geraden verteilt (vgl. Abb. 2).

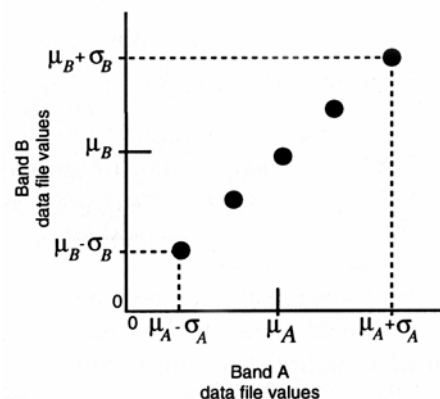


Abb. 2: Initiale Verteilung der Clustermittelpunkte beim ISODATA-Verfahren (ERDAS 1997)

Im nächsten Schritt muss die spektrale Distanz der restlichen Pixel im Bild zu den Clustermittelwerten bestimmt werden. Im Prinzip sind auch andere Entscheidungsregeln einsetzbar, das *Isodata*-Verfahren nutzt aber die der minimalen euklidischen Distanz.

Ein Pixel wird demjenigen Cluster zugewiesen, zu dem es die geringste spektrale Distanz aufweist. Das Ergebnis ist eine thematische Ebene mit den vorläufigen Klassenzugehörigkeiten (siehe Abb. 3). Die zweite Iteration berechnet die Mittelwerte der Cluster auf der Basis der enthaltenen Pixelwerte neu und verschiebt die Clustermittelwerte entsprechend im Merkmalsraum. Jetzt werden sämtliche Pixel wieder mit den neuen Mittelwerten verglichen und ggf. einem neuen Cluster zugewiesen.

Dieses Verfahren wird solange durchgeführt, bis eine der am Anfang definierten Abbruchbedingungen erfüllt ist. Wenn nach einem Iterationsschritt keine signifikanten Änderungen an der Lage der Clustermittelpunkte mehr stattfinden, dann soll das Verfahren beendet werden. Falls der Anteil der unverändert bleibenden Pixel und damit auch der Clustermittelpunkte

diesen Grenzwert nicht erreicht, fungiert als zweite Abbruchbedingung die maximale Anzahl der Iterationsschritte.




Abb. 3: Abgrenzung von Klassen mit dem ISODATA Algorithmus (Bakker et al. 2001)

Ein Vorteil dieses Algorithmus ist seine Fähigkeit, die spektralen Muster eines Datensatzes sehr gut aufzuspüren. Aufgrund seiner iterativen Vorgehensweise verzerrt er das Ergebnis nicht. Nachteile sind die erforderliche hohe Rechenzeit und das notwendige Vorwissen. Da die maximale Anzahl der Cluster vorher festgelegt werden muss, ist ein Anwender bemüht, möglichst keine evtl. vorkommende Klasse auszulassen. Das kann zu einer Vielzahl von Klassen führen, die später wieder aggregiert werden müssen.

2.2.2 Überwachte Verfahren

Bei dieser Gruppe von Klassifikationsverfahren wird im Vergleich zu unüberwachten Verfahren von Anfang an Vorwissen in die Auswertung miteinbezogen. Aus Trainingsgebieten werden für das gesamte Bild gültige Statistiken für die einzelnen Klassen berechnet (Bähr und Vögtle 1998, S.170). Anhand dieser Statistiken kann jeder Bildpunkt über seinen Grauwertvektor im Merkmalsraum eindeutig derjenigen Klasse zugewiesen werden, zu der er die größte Ähnlichkeit aufweist.

Um eindeutige Trainingsgebiete auszuwählen, ist ein hoher Grad an **Vorwissen** über das Untersuchungsgebiet notwendig. Diese Informationen werden im Vorfeld, z. B. bei Geländekampagnen, erhoben oder stammen aus vorhandenem Kartenmaterial bzw. bestehenden, älteren Klassifikationen.

In der **Trainingsphase** wird nun zunächst die sog. **spektrale Signatur** aus den Grauwertvektoren der Bildpunkte innerhalb der Trainingsgebiete ermittelt. Diese spektrale „Beschreibung“ der Klassen kann in zwei Formen geschehen (ERDAS 1997, S.233), als:

1. **Parametrische Signaturen:** Sie basieren auf statistischen Parametern wie Mittelwert oder der Kovarianzmatrix.
2. **Nicht-parametrische Signaturen:** Sie basieren auf Polygonzügen, die im Merkmalsraum die Grenzen einer Klasse festlegen.

Spektrale Signaturen sollten ihre Klassen eindeutig beschreiben, was bedeutet, dass möglichst keine Überschneidungen im Merkmalsraum vorkommen sollen.




Abb. 4: Überlappende (links) und eindeutig getrennte Signaturen (rechts) in einem theoretischen Merkmalsraum (ERDAS 1997)

In der praktischen Anwendung wird es aber immer zu Überschneidungen kommen, was die Trennung von Klassen erschwert. Im Prinzip kann jedes Merkmal für die Erzeugung von Signaturen genutzt werden. So sind auch Signaturen unter Einbeziehung von digitalen Höhenmodellen (DHM) oder anderen externen Datenquellen möglich, um die Klassentrennung zu verbessern.

Anschließend werden in der **Klassifikationsphase** die Grauwertvektoren der unklassifizierten Pixel mit denen der Trainingsgebiete verglichen. Mit Mitteln der statistischen Entscheidungstheorie wird nun festgelegt, zu welcher Klasse ein Bildpunkt die größte Ähnlichkeit hat. Dieser Klasse wird er zugewiesen.

Es gibt eine Vielzahl statistischer Klassifikationsverfahren, die in den Lehrbüchern zur Bildverarbeitung detailliert beschrieben sind (Albertz 2001, Bähr und Vögtle 1998, Lillesand und Kiefer 2000, Mather 1999, Richards und Jia 1999, Schowengerdt 1997). Im Folgenden soll nur kurz auf die bekanntesten dieser Verfahren eingegangen werden. Gemeinsam ist allen diesen Verfahren, dass sie die Pixel eines Bildes anhand ihres Grauwertvektors sowie

statistischer Kennwerte klassifizieren. Klassen werden durch diese Kennwerte charakterisiert. Sie nehmen einen bestimmten Bereich im Merkmalsraum ein und stellen sich dort als Punktwolke dar (siehe auch Abb. 1). Die verschiedenen Klassifikationsmethoden unterscheiden sich lediglich durch die Art und Weise wie sie die Regionen im Merkmalsraum charakterisieren bzw. konstruieren (Lohmann 1991).

2.2.2.1 Entscheidungsregeln

Die **Parallelepiped**-Entscheidungsregel erzeugt im n -dimensionalen Merkmalsraum Hexaeder zur Abgrenzung der Regionen. Unklassifizierte Pixel werden nun daraufhin geprüft, ob sie in eines dieser Hexaeder fallen und dann einer Klasse zugeordnet. Dabei können auch Bildpunkte unklassifiziert bleiben. Probleme entstehen bei sich überlappenden Regionen. Hier können die n -dimensionalen Hexaeder wiederum in kleinere Objekte zerfallen.

Eine der wichtigsten Entscheidungsregeln ist das **Minimum-Distance-Verfahren** (Verfahren der nächsten Nachbarschaft). Hier werden die Mittelwerte für die Grauwerte der Trainingsgebiete in jedem Kanal berechnet. Unklassifizierte Pixel werden derjenigen Klasse zugeteilt, zu der sie den geringsten Abstand im Merkmalsraum aufweisen. Die Streuung der Gauwerte innerhalb einer Klasse wird nicht berücksichtigt, wodurch Fehlklassifikationen möglich sind (Albertz 2001, S.166).

Das **Maximum-Likelihood-Verfahren** ist, mit Variationen, das am häufigsten eingesetzte in der Fernerkundung. Der Rechenaufwand ist bei diesem **Verfahren der größten Wahrscheinlichkeit** ungleich höher als beim zuvor vorgestellten Verfahren der nächsten Nachbarschaft. Dieses Verfahren setzt eine Normalverteilung der Grauwerte um den Mittelpunkt jeder Klasse im Merkmalsraum voraus. Es berechnet aufgrund statistischer Kenngrößen die Wahrscheinlichkeit, mit der unklassifizierte Bildpunkte zu einer Klasse gehören (Albertz 2001, S.166). Cluster werden als statistische Wahrscheinlichkeitsdichtefunktionen im n -dimensionalen Merkmalsraum berechnet. Für jeden Grauwertvektor wird die Zugehörigkeitswahrscheinlichkeit zu jedem Cluster berechnet (Jähne 2002, S.557). Basis ist die Mahalanobis-Distanz zwischen dem Pixel und dem Schwerpunkt einer Klasse. Sie ist ein Maß dafür, wie „typisch“ ein Pixel für die jeweilige Klasse ist.

Allgemeine Gleichung für den *Bayesian/Maximum-Likelihood*-Klassifikator nach Erdas (1997, S.251):

$$(1) \quad D_c = \ln(a_c) - \left[\frac{1}{2} \ln(|C_c|) \right] - \left[\frac{1}{2} (X_k - M_c)^T C_c^{-1} (X_k - M_c) \right],$$

mit: D_c = (gewichteter) Abstand zur Klasse c ; X_k = Merkmalsvektor eines unklassifizierten Pixels; M_c = Mittelwertvektor der Trainingspixel von Klasse c ; C_c = Varianz-/Kovarianzmatrix der Trainingspixel von Klasse c ; a_c = a priori-Wahrscheinlichkeit, dass ein unklassifiziertes Pixel Mitglied der Klasse c ist (beim Wert 1,0 greift nur die *Maximum-Likelihood*-Entscheidungsregel).

Mit Hilfe einer Dichtefunktion wird für alle unklassifizierte Bildpunkte die Wahrscheinlichkeit berechnet, mit der sie in ihre jeweilige Klasse fallen. Falls ein Schwellenwert für die Klassenzugehörigkeit festgelegt wurde, können Pixel auch unklassifiziert bleiben.

Der **Bayes-Klassifikator** modifiziert die *Maximum-Likelihood*-Entscheidungsregel dahingehend, dass die Wahrscheinlichkeit des Auftretens von Klassen vorher gewichtet werden kann. Der Parameter a_c in der vorstehenden Gleichung (1) beschreibt die Bayes-Entscheidungsregel. *Maximum-Likelihood* geht davon aus, dass alle Klassen mit gleicher Wahrscheinlichkeit im Bild auftreten können, was aber bei vielen realen Untersuchungsgebieten nicht der Fall ist und deshalb zu falschen Annahmen führt.

2.2.3 Grenzen pixelbasierter Verfahren

Alle oben vorgestellten Klassifikationsverfahren betrachten nur die Grauwerte einzelner Pixel isoliert voneinander. Die räumliche Nachbarschaft eines Bildpunktes bleibt dabei i. d. R. völlig unberücksichtigt. Eine Entscheidung über die Zugehörigkeit eines Pixels zu einer Klasse kann aber häufig nur unter Berücksichtigung seiner Umgebung erfolgen. Insbesondere bei der immer weiter ansteigenden Auflösung der Fernerkundungsdaten können einzelne Bildpunkte kaum noch ohne Berücksichtigung ihres Kontextes korrekt klassifiziert werden. Ebenso lassen sich semantische Objekte wie Industriekomplexe, Einkaufszentren, Parkanlagen etc. nicht mit rein pixelbasierten Verfahren erfassen, da diese Objekte sich aus unterschiedlichen Unterobjekten zusammensetzen, was die Berücksichtigung der Umgebung bei der Klassifikation voraussetzt. Dies ist bei rein pixelbasierten Verfahren nicht der Fall. Zudem sind sich die inhärenten spektralen Eigenschaften vieler Klassen sehr ähnlich. Sie überlagern sich im Merkmalsraum (vgl. Gurney und Townshend 1983).

Eine stillschweigende Annahme traditioneller Klassifikationsverfahren ist, dass reale Landbedeckungen perfekt durch eine Anzahl von quadratischen Bildpunkten dargestellt werden können (Fisher 1997, S.680). Eine weitere Annahme ist, dass diese Pixel eine homogene Landoberfläche repräsentieren. Das führt weiter zu der Hypothese, dass jedes Pixel zu genau einer Landbedeckungsklasse gehört (Kartikeyan et al. 1994).

Parametrische Verfahren wie die *Maximum-Likelihood*-Methode sind stark abhängig von dem verwendeten Dichtemaß, hier die Normalverteilung. Wenn die Grauwerte einer Klasse nicht normalverteilt sind, führt dies zu Fehlern in der Klassifikation. Probleme bei der Klassenzuweisung entstehen ebenfalls, wenn Grauwerte innerhalb einer Klasse zu stark streuen. Hierbei lassen sich nach Kartikeyan (1994) klassenabhängige und klassenunabhängige Variationen unterscheiden. Probleme entstehen vor allem dann, wenn Klassen sich im Merkmalsraum überlappen.

Externe, **klassenunabhängige** Ursachen wie die physikalischen Eigenschaften der Landoberfläche, atmosphärische Störungen oder die Variabilität der Sensorcharakteristik beeinflussen die Güte einer Klassifikation bzw. deren Übertragbarkeit auf andere FE-Daten und Aufnahmezeitpunkte. Zusätzliche Probleme entstehen durch Variationen in den Klassen selbst (**klassenabhängige Variation**). Sie basieren auf den gewählten Trainingsgebieten.

Werden hier Unterschiede z. B. in der Dichte des Landbedeckungstyps mit erfasst, wird so die Streubreite der Grauwerte innerhalb einer Klasse beeinflusst. Klassen mit einer großen Streuung ihrer Grauwerte sind daher anfälliger für Überlagerungen im Merkmalsraum.

Anders gelagerte Probleme bereiten die hoch und **sehr hoch aufgelösten FE-Datensätze**. Objekte zerfallen bei diesen in eine Anzahl zusammengehörender Sub-Komponenten und werden als diskrete Einzelobjekte wahrnehmbar (Guindon 1997). Hier setzen sich auch relativ kleine Objekte wie Baumkronen, Autos oder auch Hausdächer aus mehreren Bildpunkten zusammen. Diese Pixel haben unterschiedlichste Grauwerte, z. B. kann sich eine Baumkrone aus mehreren Bildpunkten zusammensetzen, die zum Teil im Schatten liegen, zum Teil von der Sonne beschienen sind und zum Teil von einem Nachbarbaum überlappt werden. Alle diese Bildpunkte gehören aber zu dem einen Objekt Baumkrone und sollen natürlich auch zusammen als ein Objekt klassifiziert werden. Ein weiteres Beispiel ist Bebauung. Diese Landbedeckungsklasse ist komplex und sehr heterogen. Sie kann i. d. R. nicht über eine typische spektrale Gesamtreflexion beschrieben werden, sondern durch die Kombination von kleinen Segmenten, die aus den unterschiedlichsten Klassen stammen (Guindon 1997, Johnsson 1994).

Das Problem der Komplexität in den Landbedeckungsklassen bei sehr hoch auflösenden Daten wird auch bei Baker et al. (1991) beschrieben. Hier werden u. a. die komplexen physikalischen Eigenschaften der Landoberfläche angesprochen wie auch die **räumliche Variabilität innerhalb von Objekten**, die komplexe Mischung aus unterschiedlichen Spezies und die Unschärfe von natürlichen Vegetationsgrenzen. Bei sehr hoch auflösenden Daten kommt das Problem hinzu, dass diese Produkte zurzeit die räumliche Qualität mit einer verringerten spektralen Auflösung „erkaufen“. Die Sensoren bieten i. d. R. nur vier Spektralkanäle, was im Vergleich zu den sieben Kanälen von Landsat einen großen Verlust an spektraler Information bedeutet.

Ein im Prinzip die gesamte Bildanalyse betreffendes Problem entsteht aus der Diskrepanz, dass FE-Sensoren und traditionelle Klassifikationsverfahren „nur“ die **Landbedeckung** erfassen, menschliche Interpreten aber oft **Landnutzungen** vergleichen möchten. So kann beispielsweise eine klassifizierte Grasfläche zu Landwirtschaft, zu Erholungsnutzung oder auch zu Wohnnutzung gehören. Solche Entscheidungen können insbesondere pixelbasierte Verfahren überhaupt nicht treffen. Im englischen Sprachgebrauch wird streng zwischen „*land use*“ und „*land cover*“ unterschieden, während das im Deutschen nicht unbedingt durchgehalten wird. Die Landbedeckung bezieht sich direkt auf die physikalischen Eigenschaften einer aufgenommenen Fläche, also das, was der Satellit „sieht“. Landnutzung hingegen ist ein kulturelles Konzept, welches semantische Klassen beinhaltet (vgl. Bock 1995, S.27).

Die traditionelle Klassifikation sehr hoch auflösender Datensätze führt aufgrund oben erwähnter Probleme oft zu sehr unzusammenhängenden Objekten im Klassifikationsergebnis, d. h. individuelle Pixel werden anders klassifiziert als ihre direkten Nachbarn

(Stuckens et al. 2000, S.290). Dieser „*Salt-and-Pepper-Effekt*“ kann zwar zum Teil durch Filterungen des Ergebnisbildes abgemildert werden, lässt sich aber nicht ganz vermeiden. Herkömmliche Verfahren lassen sich nur begrenzt um die Information der räumlichen Beziehungen erweitern. Der Merkmalsraum muss deshalb vorher mit extern berechneten, zusätzlichen Merkmalen ergänzt werden. Das kann allerdings zu einer Dimensionalität führen, die rechentechnisch kaum mehr analysierbar ist.

2.3 Kontextbasierte Verfahren

“Basically, the effect of context is that a pixel’s most probable interpretation when viewed in isolation changes when viewed in some context.” (Haralick und Joo 1986, S.997)

Es gibt seit Jahrzehnten viele Ansätze, die Nachteile rein pixelbasierter Verfahren zu vermindern. Kontextbasierte Klassifikationsverfahren betrachten Bildpunkte nicht mehr isoliert voneinander, sondern nutzen deren Umgebung und betrachten die räumliche Nachbarschaft.

Diese räumliche Information lässt sich in drei Gruppen unterteilen (Tilton et al. 1982):

1. Strukturinformation
2. Texturinformation
3. Kontextinformation

Bei Punkt 1 können Regelwerke oder eine Art Grammatik genutzt werden, um diese **Strukturinformationen** zu beschreiben. Objekte bestehen aus bestimmten Mustern und folgen bestimmten Regeln.

Texturen sind sich periodisch wiederholende Muster, die aufgrund der räumlichen Verteilung von Grauwertunterschieden zu Stande kommen (vgl. Jähne 2002, S.435).

Kontextinformationen beziehen die Umgebung eines Bildpunktes in die Klassifikation mit ein. Dieser Ansatz entspricht der Tendenz, dass in der Natur einige Landoberflächen in einem bestimmten Kontext häufiger auftreten als andere (Tilton et al. 1982).

Verfahren, die diese räumliche Information für die Klassifikation nutzen, lassen sich nach Bock (1995, S.29) in sechs Gruppen einteilen (vgl. Gurney und Townshend 1983, Kartikeyan et al. 1994):

1. Nachbearbeitungsverfahren
2. *Stacked-Vector*-Verfahren
3. *Compound-Decision*-Verfahren
4. Relaxations-Verfahren
5. Häufigkeitsbasierte Verfahren
6. Regionenorientierte Verfahren
7. Neuronale Netze

Moderne objektorientierte Verfahren basieren im Prinzip auf diesen Entwicklungen und den in diesem Kapitel vorgestellten Verfahren. Sie nutzen allerdings fortgeschrittenere Methoden und integrieren unterschiedliche Ansätze im Sinne des Bildverstehens (nach Guindon 1997), um die Klassifikation zu verbessern und „erklärbarere“ Ergebnisse zu erzielen. Objektorientierte Verfahren werden am Beispiel des Programms eCogniton detailliert in Kapitel 2.5 vorgestellt.

Nachbearbeitungsverfahren

Die Nachbearbeitung mittels Filterung ist ein sehr einfaches und vergleichsweise schnelles Verfahren, um Ergebnisse herkömmlicher Klassifikationen zu verbessern.

Hierbei wird das gesamte Bild geglättet. Der Filter ist i. d. R. ein Mittelwert-, Modal- oder auch *Majority*-Filter. Die Umgebung des jeweiligen Pixels wird durch ein quadratisches Fenster mit üblichen Kantenlängen von 3x3, 5x5 oder 7x7 Pixeln berücksichtigt.

Der betrachtete Bildpunkt wird nun reklassifiziert und der Klasse zugeordnet, die in seiner Umgebung am häufigsten auftritt. Aufgrund der daraus resultierenden Generalisierungseffekte wird das Ergebnisbild „glatter“ und Fehlklassifikationen im Pixelbereich können so erfolgreich beseitigt werden. Die oben beschriebenen Probleme des „*Salt-and-Pepper*-Effektes“ lassen sich so allerdings nicht eliminieren.

Eine weitere Möglichkeit der Nachbearbeitung von Ergebnissen aus spektralen Klassifikationen beschreiben Fung und Chan (1994). Sie klassifizieren einen Datensatz erneut auf der Basis der spektralen Vorklassifikation und einem Satz von Entscheidungsregeln. In einem 7x7 Pixel großen Fenster werden die Anteile der Landbedeckungen erfasst und mit komplexen WENN-DANN-Beziehungen neuen Klassen wie z. B. der Klasse Industriegebiet zugewiesen.

Solche Nachbearbeitungsverfahren versuchen Informationen zu rekonstruieren, die bei der vorhergehenden Klassifikation verloren gegangen sind. Die regelbasierte Reklassifikation ist hingegen leistungsfähiger. Allerdings ist ein sehr hohes Maß an Vorwissen erforderlich, um diese Regeln zu erstellen. Nachbearbeitungsverfahren sind im Prinzip Generalisierungsprozesse bei denen Details der ursprünglichen Klassifikation verloren gehen (Fung und Chan 1994).

Stacked-Vector-Verfahren

Diese Methode erweitert die oben beschriebenen statistischen Klassifikationsverfahren um künstliche Kanäle, die den Raumbezug der einzelnen Pixel beschreiben.

Über Fenster mit festgelegter Größe werden für jedes Pixel aus den spektralen Grauwerten der Umgebung raumbezogene Merkmale abgeleitet (z. B. Varianz). Dem mittleren Pixel im Fenster wird die Ausprägung dieser Raummerkmale zugeordnet und so werden neue, künstliche Kanäle berechnet. Anschließend werden das Bild und der erweiterte Merkmalsraum mit einer der statistischen Entscheidungsregeln klassifiziert (siehe auch 2.2.2). So

lassen sich die oben kritisierten pixelbasierten Verfahren um eine Raumkomponente erweitern.

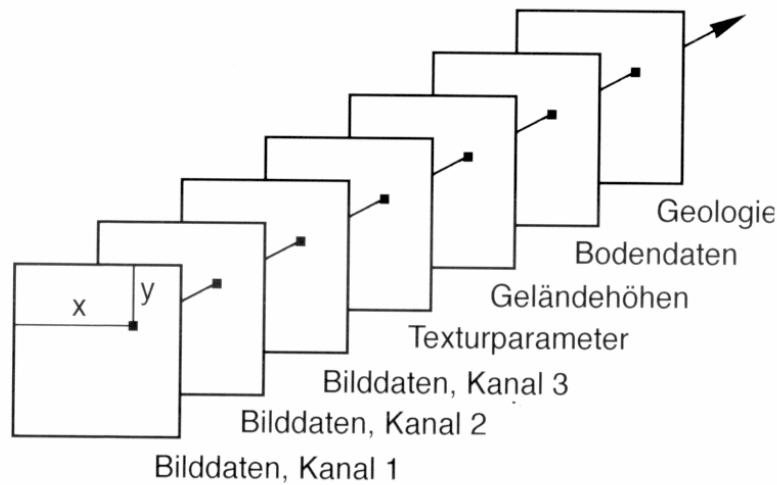


Abb. 5: Erweiterter Merkmalsraum (Albertz 2001)

Nachteile ergeben sich daraus, dass die Merkmalsgenerierung sehr rechenintensiv ist und die Merkmale oft nur aus einem Spektralkanal gleichzeitig abgeleitet werden können. Des Weiteren muss entschieden werden, welche Merkmale überhaupt für die Objektbeschreibung geeignet sind. Letzteres ist allerdings ein Problem, dass viele der „neuen“ Methoden teilen: die fehlenden Qualitätsmaße für die Merkmale.

Compound-Decision-Verfahren

Um generelle Abhängigkeiten in einem Datensatz zu handhaben, bietet sich die Theorie der *compound decision* an. Diese kontextbasierte Methode entscheidet über die Klassenzugehörigkeit eines Pixels auf der Basis der Werte aller anderen Punkte im Bild. Diese Methode ist u. a. bei Haralick und Joo (1986) oder bei Tilton et al. (1982) im Detail nachzulesen.

Bei diesen Verfahren wird unterstellt, dass keinerlei räumliche Korrelation zwischen benachbarten Pixeln im Merkmalsraum besteht. Diese Annahme kann für niedrig aufgelöste Daten gelten, bei sehr hoch aufgelösten Bildern besteht jedoch eher ein starker Zusammenhang zwischen benachbarten Pixeln.

Relaxations-Verfahren

Im Vergleich zu den *Compound-Decision*-Methoden wird bei diesem Verfahren die Wahrscheinlichkeit der Zugehörigkeit eines Bildpunktes zu einer Klasse anhand der Wahrscheinlichkeit der Klassenzugehörigkeiten seiner Nachbarn berechnet (Kartikeyan et al. 1994). Das Verfahren ist iterativ und verändert in jedem Durchgang ggf. die Klassenzugehörigkeiten. Mit dem Fortschreiten des Prozesses gehen immer mehr Kontextinformationen ein, da immer mehr Nachbarpixel klassifiziert vorliegen.

Das Verfahren ist sehr rechenintensiv, da Pixel immer nur paarweise verglichen werden, was als konzeptioneller Nachteil gegenüber den *Compound-Decision*-Verfahren gesehen wird.

Häufigkeitsbasierte Verfahren

Diese Verfahren nutzen für die eigentliche Klassifikation die in 2.2.2.1 beschriebenen Entscheidungsregeln. Sie berechnen zusätzlich vorher für jedes Pixel die Häufigkeit des Auftretens seines Grauwertes in einem Fenster vorbestimmter Größe. Mit Ausnahme der Randbereiche eines Bildes wird für das mittlere Pixel innerhalb des Fensters die Häufigkeit seines Auftretens berechnet und als Wert zugewiesen. Bei multispektralen Bildern oder wenn mehrere Merkmale vorliegen, wird eine Häufigkeitstabelle über den Merkmalsvektor berechnet und dem Pixel zugewiesen.

Dieses Verfahren kann auch in der Nachbearbeitung eingesetzt werden. Gong und Howarth (1992) klassifizieren einen Datensatz zunächst mit Hilfe der *Maximum-Likelihood-Methode*, anschließend werden dann die Pixel anhand der Häufigkeit der Landbedeckungen reklassifiziert.

Solche Verfahren setzen voraus, dass sich Landbedeckungsklassen anhand der unterschiedlichen Zusammensetzung der sie bestimmenden Bildpunkte unterscheiden lassen. Gerade in bebauten Gebieten können die Auftretshäufigkeiten von Grauwerten in unterschiedlichen Klassen sehr ähnlich sein.




Abb. 6: Vergleich der Auftretenshäufigkeit von Grauwerten in zwei unterschiedlichen Klassen (Bock 1995)

Das oben gezeigte Beispiel (Abb. 6) stammt aus einer Arbeit von Bock (1995). Es vergleicht die Zusammensetzung eines vereinfachten Einkaufszentrums mit der Zusammensetzung eines Wohngebietes. Die Häufigkeitstabelle ist für beide Fenster gleich, die Bedeutung jedoch grundverschieden.

Regionenorientierte Verfahren

Diese Verfahren versuchen, das Problem der Komplexität sehr hoch auflösender Fernerkundungsdaten durch eine Segmentierung der Bilddaten zu verringern.

Neben der Heterogenität der Grauwerte ist u. a. der Grauwertübergang von Pixelwerten ein Problem. Eine ausgeprägte Eigenschaft von räumlichen Zusammenhängen ist in Multispektraldaten die Redundanz, d. h. der Übergang eines Pixels i in ein Pixel j ist größer, wenn $i = j$ als wenn $i \neq j$ ist (Kettig und Landgrebe 1976). Um solche Übergänge zu verarbeiten, bieten sich regionenorientierte Verfahren an.

Pixel werden anhand eines Homogenitätsmaßes zu Bildobjekten oder Regionen gruppiert. Es gibt in der Vergangenheit viele Beispiele für Segmentierungstechniken, z. B. die ECHO-Technik von Kettig und Landgrebe (1976). Ein moderner Ansatz ist das Verfahren der *multiresolution segmentation* von Baatz und Schäpe (2000). Da dieses Verfahren die

Grundlage der hier verwendeten objektorientierten Klassifikation mit dem Programm eCognition ist, wird das Verfahren in Kapitel 2.6.1 näher beschrieben.

Auch regionenorientierte Verfahren können atmosphärische Störungen oder Änderungen der Sensorcharakteristik nicht ausgleichen (Kartikeyan et al. 1994). Sie sind aber sehr effektiv bei der Beseitigung der spektralen Heterogenität im Bild. Zusätzlich können für jedes Objekt neue Parameter berechnet werden, z. B. Form oder Flächeninhalt, die ebenfalls in die Klassifikation einbezogen werden können.

Ein gewisses Problem solcher Ansätze ist jedoch deren Abhängigkeit von der Segmentierung. Mit ihr steht und fällt die Qualität der Klassifikation. Qualitätsmaße für die Segmentierung gibt es allerdings nach wie vor nicht. Zu erwähnen ist in diesem Zusammenhang die *regions-per-pixel-ratio*, welche die Anzahl der generierten Regionen mit der Gesamtzahl der Pixel im Bild vergleicht. Ein auf diese Weise normalisierter Wert ermöglicht den Vergleich unterschiedlicher Segmentierungen (Ryherd und Woodcock 1996). **Per-Parcel-Ansätze** umgehen das Problem, indem sie Regionen aus externen Vektordaten integrieren. Aplin et al. (1999) kombinieren simulierte hoch auflösende Satellitendaten mit Vektorinformationen zur Klassifikation. Sie erzielen im Vergleich zu klassischen Methoden bessere Ergebnisse.

Neuronale Netze

Klassifikatoren auf der Basis neuronaler Netze haben in den letzten Jahren einen hohen Verbreitungsgrad erreicht. Hierbei wird ein reales Nervensystem im Computer sehr abstrakt simuliert. Künstliche neuronale Netze bestehen aus stark idealisierten Neuronen, die mittels gerichteter Stränge miteinander in Verbindung treten. Über diese werden Informationen in Form der Aktivierung der Zellen ausgetauscht (Bock 1995, S.37). Das „Wissen des Systems“ wird über diese Verbindungen bzw. deren Stärke oder Gewicht repräsentiert.

Zu den besonderen Eigenschaften eines neuronalen Netzes zählt vor allem seine Lernfähigkeit. In einem iterativen Prozess wird mit Hilfe von Trainingsdatensätzen ein Netz so trainiert, dass jedes Eingangsneuron einen Datensatz zugewiesen bekommt und im Voraus weiß, welche Ausgabe es erzeugen soll. Das Ziel ist die genaue Reproduktion dieser Ausgabe. Der Vergleich von Eingabe und Ausgabe führt im Fehlerfall zu einer Modifikation der Gewichte an den Verbindungen, bis die Fehler minimiert sind.

Neben der Lernfähigkeit spricht für die Verwendung neuronaler Netze ihre Eigenschaft der automatischen Generalisierung, d. h. es besteht eine geringere Empfindlichkeit gegenüber gestörten oder verrauschten Daten.

Die Arbeitsweise eines neuronalen Netzes ist wenig transparent und entspricht eher einer black box. Die Verwendung von Regelwerken ist im Gegensatz hierzu für den Anwender deutlich anschaulicher und nachvollziehbarer (vgl. auch Kapitel 2.5).

2.4 Maßstabsebene

„... relationships between remotely sensed data and ground data derived at one scale will not be the same at another.“ (Curran und Atkinson 2002, S.132)

Der Maßstab spielt in der Bildanalyse eine erhebliche Rolle, da die Unterscheidbarkeit von Objekten direkt von ihm abhängt. Unabhängig von unterschiedlichsten Definitionen des Maßstabs bezieht sich die folgende Diskussion nur auf räumliche Beziehungen. Der räumliche Maßstab hat nach Benson und MacKenzie (1995) zwei Komponenten: Einerseits die Pixelgröße, also die Auflösung, und andererseits die Ausdehnung des Bilddatensatzes.

Die Varianz der Grauwerte innerhalb der beobachteten Objekte (**räumliche Frequenz** einer Szene) an der Erdoberfläche ist direkt abhängig von der Auflösung und steigt mit größerem Maßstab an (Curran und Atkinson 2002). Der Unterschied zwischen Auflösung und Maßstab besteht darin, dass die Auflösung die durchschnittliche Größe der von einem Pixel abgedeckten Region auf dem Boden angibt. Der Maßstab beschreibt hingegen die Distanz oder die Abstraktionsebene, mit der ein bestimmtes Problem betrachtet wird (Baatz et al. 2002). Die Bedeutung von **Maßstab und Pixelgröße** ist also im Prinzip genau gegensätzlich (Curran und Atkinson 2002). Ein großer Maßstab beschreibt ein kleinräumiges Phänomen und bedeutet gleichzeitig eine hohe räumliche Auflösung bzw. eine geringe Pixelgröße.

Die Auflösung eines Bildes stellt einen Teilaspekt der Genauigkeit dar und gibt zu einem gewissen Grad die erreichbare Präzision an (Bartelme 2000, S.232).

Untersuchungen haben gezeigt, dass Maßstabsänderungen direkt die Klassifikationsqualität beeinflussen. Vor allem aufgrund der hohen spektralen Varianz führt ein größerer Maßstab demnach zu einer geringeren Gesamtgenauigkeit (Marceau und Hay 1999). Wie auch schon bei der Diskussion der Nachteile pixelbasierter Verfahren erläutert wurde, müssen diese deshalb bei hohen räumlichen Auflösungen versagen (siehe 2.2.3).

Man spricht in diesem Zusammenhang auch von der so genannten kleinsten kartierbaren Einheit (*minimum mapping unit* - MMU). Sie repräsentiert die kleinste Einheit im Bild, welche als diskretes Objekt dargestellt wird. Die Wahl einer adäquaten Auflösung bzw. MMU für ein Problem ist die Aufgabe des Experten. Bei Fernerkundungsdaten ist diese allerdings vorgegeben. So liegt die MMU bei Landsat TM7 Daten bei 0.09 ha, also 30x30m pro Pixel, während sie bei IKONOS-Daten zwischen 16 m² multispektral und 1m² panchromatisch liegt. Unterschiedliche Maßstäbe verändern das dargestellte Landschaftsbild beträchtlich. Bei einer größeren MMU werden fragmentierte und spärlich vorkommende Objekte zurückgedrängt, während zusammenhängende großflächige Klassen noch dominanter werden (Saura 2002). Mit der Wahl einer „*minimum mapping unit*“ wird der Detailgrad einer Auswertung bestimmt und die Komplexität eines Bildes direkt beeinflusst (siehe Abb. 7).




Abb. 7: Veränderung der Landschaft bei einer Maßstabsänderung. Links: 1:5000; Rechts: 1:50.000 (Arbuckle et al. 1998)

Woodcock und Strahler (1987) haben in einer grundlegenden Arbeit den Zusammenhang zwischen Maßstab und räumlicher Varianz von Bildpunkten nachgewiesen. Sie stellen in verschiedenen Tests die räumliche Auflösung der lokalen Varianz gegenüber und können dann Aussagen treffen, ab welcher Stufe der Informationsgehalt maximal ist. Ein Beispiel ist die Zusammensetzung eines Baumes, der mit sinkender Auflösung (MMU wird größer) von immer weniger Rasterzellen repräsentiert wird. Gleichzeitig sinkt die Wahrscheinlichkeit, dass diese eine Ähnlichkeit mit den Nachbarpunkten haben. In der Folge steigt die lokale Varianz (Woodcock und Strahler 1987).

Abhängig von dem thematischen Hintergrund unter dem ein Datensatz ausgewertet wird, ändern sich die relevanten Objekte für die jeweilige Analyse. Objekte, die für eine Untersuchung wichtig sind, können dabei gleichzeitig auf unterschiedlichen Maßstabsebenen abgegrenzt werden. Es wird aber normalerweise nach einer adäquaten Auflösung gesucht. Marceau und Hay (1999) merken dazu an, dass eine Auflösungsstufe respektive Maßstabsebene allein vermutlich nicht ausreicht, um alle für die jeweilige Fragestellung erforderlichen Klassen zu unterscheiden. So untersuchten Niemann et al. (1997), inwieweit die Kombination von Daten unterschiedlicher Auflösung einen Informationsgewinn bietet. Benson und MacKenzie (1995) haben die Auswirkungen einer stufenweisen Vergrößerung des Maßstabs auf die Klassifikationsergebnisse überprüft. Dabei stellten sie fest, dass sich die Wasserfläche in ihrem Untersuchungsgebiet um 44% verringert und nur 2% der Seen erhalten bleiben, wenn die Auflösung mittels eines *Majority*-Filters von 20 m auf 1.1 km verändert wird. Die Abnahme der Seenan Zahl war exponentiell, während die Wasserfläche nahezu linear abnahm (siehe Abb. 8 a und c).




Abb. 8: Abhängigkeit verschiedener Landschaftsparameter von der räumlichen Auflösung. (Benson und Mackenzie 1995)

Diese Probleme betreffen auch regionenbasierte Klassifikationsverfahren, selbst wenn sich hier theoretische Ebenen mit unterschiedlichen Auflösungsstufen ableiten ließen.

2.5 Objektorientierte und wissensbasierte Klassifikation

Nach Guindon (1997) hat sich parallel zu der zivilen Fernerkundung der militärische Bereich vorwiegend mit der Analyse sehr hoch auflösender Luftbilddaten beschäftigt. Dabei sind Bildanalyseysteme entstanden, die eine andere Herangehensweise an Bilddaten entwickelt haben. Dieser Ansatz wird auch als Bildverstehen (*image understanding*) bezeichnet. Schlüsselcharakteristika sind nach Guindon (1997):

1. Analyse von Objekten bzw. Eigenschaften anstelle isolierter Bildpunkte. Bilddaten werden vorher in **Regionen** segmentiert.
2. Das Bildverstehen arbeitet **wissensbasiert** im Gegensatz zum Training der statistischen Verfahren, d. h. es gehen Informationen über die inhärenten strukturellen Eigenschaften der realen Objekte und ihrer erwarteten Zusammenhänge ein.
3. Die Analyse wird auf unterschiedlichen **Ebenen** des räumlichen Kontextes durchgeführt. *Bottom-up* Ansätze, d. h. bildgesteuert, und *top-down*-Ansätze, d. h. modellgesteuert, werden in diesem Zusammenhang eingesetzt.
4. Die Klassifikation bestimmter **Teilmengen der Bildobjekte** ist möglich (*limited-goal strategy*), z. B. sollen nur Flugzeuge auf Flughäfen klassifiziert werden. I. d. R. wird dies in zwei Schritten erreicht. Zunächst erfolgt die grobe Klassifikation der gesamten Szene. Anschließend werden nur die Flughäfen erneut detaillierter klassifiziert.
5. Frühe Arbeiten im Bereich des Bildverstehens konnten nur mit einem Kanal umgehen. Höheninformationen mussten z. B. aus den Schattenlängen geschätzt werden. Heute wird diese Information aus der Analyse von Stereobildpaaren gewonnen.
6. Es wird sehr stark zusätzliche, **externe Information** einbezogen, diese aber auch während des Analyseprozesses neu geschaffen.

Ziele dieses Systems sind a) neue Bilddaten aufzunehmen, b) sie mit bestehender Rauminformation zu verknüpfen, c) ein Modell für die komplette Szene auf der Basis von bestehenden Teilmodellen abzuleiten, d) Bereiche mit Änderungen aufzeigen und diese Änderungen auszuwerten und e) den Interpreten bei der Bewertung und Aufnahme der Änderungen zu unterstützen.

Das Verständnis komplexer Szenen erfordert detailliertes Expertenwissen und die Kenntniss, dieses zu modellieren (Matsuyama 1987).

Das Programm *eCognition* der Firma *Definiens* kann unter dem Aspekt der Kombination von unterschiedlichen Verfahren in die Kategorie der Systeme des Bildverstehens eingeordnet werden. Das Konzept von *eCognition* beruht auf der Annahme, dass semantische Information notwendig ist, um eine weitere Verbesserung der Bildinterpretation zu erreichen. Diese Information kann nicht von einzelnen Pixeln repräsentiert werden, sondern nur von „aussagekräftigen“ Bildobjekten und ihren wechselseitigen Beziehungen. Vor der eigentlichen Klassifikation wird daher eine Segmentierung in homogene Regionen

durchgeführt. „Neue“ Objektinformationen werden in einer Datenbank abgelegt und anschließend entweder regelbasiert oder mit einem statistischen Klassifikator ausgewertet.

2.5.1 Der Objektbegriff

Auf den folgenden Seiten wird sehr oft von Objekten die Rede sein. Es scheint daher notwendig zu erläutern, was jeweils unter diesem Begriff verstanden wird. Obwohl im realen, fernerkundlichen Verfahrensablauf die Segmenterzeugung der erste Schritt ist, wird aus Gründen der Verständlichkeit zunächst der Begriff „Objekt“ näher erläutert. Segmentierungsverfahren werden später in Abschnitt 2.5.2 beschrieben. Die Begriffe Objekte und Segmente werden in der Folge synonym verwendet.

Erkenntnistheoretische Betrachtungen

Der Begriff Objekt wird in unserem Sprachgebrauch sehr häufig, nahezu inflationär eingesetzt, ohne dass eine Definition dafür angeboten wird, was im jeweiligen Zusammenhang gemeint ist. Im Folgenden soll vom Begriff der „Objektorientierung“ in der Informatik und daraus abgeleiteter Objektbegriffe die Rede sein. Hesse und von Braun (2001) stellen in ihrem Aufsatz „Wo kommen die Objekte her? Ontologisch-erkenntnistheoretische Zugänge zum Objektbegriff“ zunächst folgende Fragen:

Wo sind Objekte verankert?

Wie kommen Objekte zustande (Genese)?

Wie werden bestehende Objekte erkannt (Identifikation)?

Wie werden erkannte Objekte klassifiziert (Typisierung)?

Wie sind Objekte miteinander verbunden (Beziehungen)?

Mit Hilfe der Erkenntnistheorie stellen sie fest, dass Objekte nicht a priori gegeben sind, sondern im Laufe eines Erkenntnisprozesses, also auf der Basis von Analysen und dem Angleichen von Weltansichten durch unterschiedliche Betrachter erzeugt werden. Im Gegensatz dazu steht die philosophische Richtung des Realismus, die davon ausgeht dass Objekte außerhalb des Bewusstseins bereits existieren und sie deshalb objektiv erfassbar und beschreibbar sind. Umgesetzt auf Fragestellungen dieser Arbeit bedeutet dies, dass die Objekte, die beobachtet und überwacht werden sollen, erst in gemeinsamen Diskussionen zwischen Fernerkundler und Anwender z. B. in einer Behörde festgelegt werden müssen.

Der Blick auf die Welt erfolgt immer aus der Sicht des jeweiligen Betrachters und seines thematischen Hintergrundes und ist daher verzerrt und eingeschränkt. Aus diesem Grund lässt sich auch nie eindeutig feststellen, wie viele Objekte in einem Raum existieren. Die Beantwortung dieser Frage hängt immer von der Definition des Objektbegriffes ab.

Umwelt

In der realen Welt betrachten wir täglich Objekte. Je nach Abstraktionsebene, thematischem Hintergrund und Zusammenhang ändern sich diese. Es besteht ein direkter Zusammenhang zu der gewählten, in Abschnitt 2.4 diskutierten Maßstabsebene. Wir reden beispielsweise entweder vom Schilfgürtel oder von der einzelnen Schilfpflanze, die sich wiederum aus Unterobjekten, wie Halm, Blättern und Rhizom zusammensetzt. Diese Objekte haben Eigenschaften (steht im Wasser, treibt im April/Mai aus) und Funktionen (Wasserreinigung,

Habitat). Thematisch sieht ein Landwirt das Schilf anders als ein Fischer, der wiederum eine andere Sichtweise hat als der Vogelschützer.

Aufgrund des täglichen Umgangs mit natürlichen Objekten besteht eine Gewöhnung an diese Betrachtungsweise. Die Arbeit mit einem objektorientierten Konzept ermöglicht somit einen natürlicheren Blick auf die betrachtete Umwelt.

Informatik

In der Datenverarbeitung setzt sich die objektorientierte Sichtweise schon seit längerer Zeit mehr und mehr durch. Der Begriff **objektorientierte Programmierung** ist hier fest eingeführt. Die Grundlage ist die sog. Kapselung (Saurer und Behr 1997, S.60), d. h. Objekte werden mit ihren Eigenschaften und Funktionen gespeichert. Objekte im Sinne der Informatik können ihre Eigenschaften vererben, sie sind klassifizierbar, aggregier- und generalisierbar. Ein Objekt Sportsitz gehört zu dem Oberobjekt Sportauto, welches sich aus diversen weiteren Unterobjekten zusammensetzt. Objekte sind also funktional abgegrenzte Einheiten, die zu einer bestimmten Klasse gehören. Sie sind hierarchisch angeordnet und können baum- oder netzartig in semantischen Netzen strukturiert sein. Durch die gleichrangige Speicherung von Eigenschaften und Funktionen „weiß“ jedes Objekt, wie es auf bestimmte Operationen zu reagieren hat. Das kann von Objektklasse zu Objektklasse bei gleichen Operationen zu unterschiedlichem Verhalten führen (Polymorphismus).

Eines der wesentlichsten Konzepte der Objektorientierung ist die Vererbung. (Ober-) Objekte können grob definiert werden und sukzessive immer weiter über ihre Unterobjekte verfeinert werden. Diese erben die Eigenschaften und Funktionen ihrer übergeordneten Objekte, was zu einer Reduzierung von redundanter Information in den Datenbanken führt.

Datenbanken

Innerhalb der Datenbankentwicklung wurde das Prinzip der Objektorientierung zunächst nicht verfolgt. Die Entwicklung von Datenbanksystemen ist historisch gesehen auch älter. Objekte werden in nicht speziell objektorientierten DB-Systemen als Entitäten abgelegt. Je nach Konzept, sei es als Baumstruktur, hierarchisch oder als relationales Datenbanksystem werden die Objekte in einer Struktur abgelegt, die ihren Eigenschaften nicht voll gerecht wird.

Beispielsweise legen Relationale Datenbanksysteme Objekte, also Entitäten, in Tabellen ab. In diesen entspricht eine Spalte einem Attribut. Tabellen können über sog. Schlüsselfelder verknüpft werden. Über solche Relationen können Objekte modelliert werden, was sehr kompliziert ist und Rechenzeit beansprucht. Funktionen bzw. das Verhalten von Objekten können nicht oder nur umständlich modelliert werden. Relationale Datenbanken sind aber i. d. R. die Basis für bestehende geographische Informationssysteme und voll in diese integriert. Inzwischen existieren rein objektorientierte DB-Systeme, die obige Probleme nicht aufweisen, da die Objekte in ihrer ursprünglichen Form mit Eigenschaften und Funktionen gespeichert werden. Allerdings wird das relationale Modell in der Anwendung vielfach bevorzugt, da die Industrie sich bislang nicht auf Standards bei objektorientierten Systemen einigen konnte, (vgl. de Lange 2002, S.303f).

Das relationale DB-Modell wurde im Laufe der Zeit um einige Funktionen aus der objektorientierten Welt erweitert. Das daraus hervorgegangene, sog. objekt-relationale Modell ist in der Lage, Objektidentitäten (d. h. die Darstellung in der DB erfolgt durch Surrogate mit indirekten Referenzen oder durch direkte Referenzen auf das Objekt) anstelle von Schlüsseln zu speichern sowie Vererbung und Klassenhierarchien zu handhaben. Bei diesem sind auch die Standardisierungsbemühungen weiter fortgeschritten (vgl. de Lange 2002, S.303).

Geoobjekte

Zunächst wurde der Objektbegriff in den Geowissenschaften unabhängig von dem der Informatik verwendet (de Lange 2002, S.157). Dennoch sind Geoobjekte mit den Objekten in der Informatik vergleichbar. So lassen sich (Geo)Objektklassen bilden, mit Geoobjekten als Instanzen, die dem Prinzip der Kapselung (siehe oben) konsequent folgen. Im **GIS** werden reale oder abstrakte Objekte der Umwelt beschrieben (Bartelme 2000, S.23). Abhängig von der Maßstabsebene werden hier die Objekte als Punkt, Linie oder Fläche abgelegt. Die Eigenschaften eines Objektes gliedern sich im GIS in strukturelle, geometrische (inkl. Topologie) und thematische Eigenschaften.

Probleme in der Definition und Abgrenzung der Objekte ergeben sich aus den oben angeführten unterschiedlichen Betrachtungsweisen. So wird der Naturschützer ein Biotop und dessen Funktionen mit völlig anderen Augen sehen als ein Tourist, für den die Erholung im Vordergrund steht. Hier müssen die relevanten Objekte in einem eigenen (Erkenntnis-) Prozess definiert werden.

Eine andere Form des Objektbegriffs kennt die Kartographie schon länger. In der Planausgabe, dem letzten Schritt bei der Erzeugung von Karten, wird von **kartographischen Modellen** gesprochen. Hier werden im Gegensatz zu den bisherigen Überlegungen Objektklassen hinsichtlich ihrer Darstellung betrachtet. Die Attribute spielen hierbei ebenfalls eine Rolle. Das bedeutet, dass etwa der Name einer Stadt beispielsweise in Großbuchstaben zu erscheinen hat. Innerhalb eines digitalen kartographischen Modells (DKM) entspricht die Definition und Verwendung des Objektbegriffes demjenigen in einem GIS.

Auch im Planungsbereich wird mit einem Objektbegriff gearbeitet. Da beispielsweise unterschiedliche Fachdisziplinen verschiedene Informationen der **automatisierten Liegen-schaftskarte (ALK)** vorziehen, werden hier abweichende Grundeinheiten, sprich Objekte, gebildet. Im Hinblick auf die angestrebte Automatisierung findet eine strikte Trennung von Objekten und Elementargeometrie statt. Objekte sind hier fachliche Einheiten, die je nach Fachgebiet und Sichtweise unterschiedliche elementargeometrische Einheiten kombinieren (Saurer und Behr 1997, S.185).

Im Gegensatz dazu wird im **amtlichen topographisch-kartographischen Informationssystem (ATKIS)** die Landschaft selbst in Objekten strukturiert. Im Sinne der objekt-orientierten Programmierung sind sie hier geometrisch begrenzte und durch einheitliche

Attribute und Relationen gekennzeichnete Einheiten (AdV 1989 zit. in Saurer und Behr 1997, S.186). Jedem Objekt ist hier ein digitales Landschaftsmodell (DLM)⁴ beliebiger Natur zugeordnet.

Fernerkundung

Die Anwendung des Prinzips der Objektorientierung ist in der **Fernerkundung** vergleichsweise neu. Es wird zurzeit nur vom Programm eCognition konsequent angewendet. Im Unterschied zu dem oben erläuterten Objektbegriff der Informatik sind hier nur die Vererbung und die Klassifizierung realisiert.

Nach einem Segmentierungsschritt liegen zunächst spektral homogene Segmente oder Objektprimitive vor. Sie besitzen alle die gleichen Eigenschaften, nur in unterschiedlichen Ausprägungen, und ihr Verhalten ist im Prinzip bei allen Operationen dasselbe. Erst nach einer Klassifikation aufgrund ausgewählter Eigenschaften werden Objektprimitive zu Objekten mit ausgesuchten Eigenschaften. Diese können dann vererbt werden, müssen aber nicht! Ebenso sind nach der Klassifikation semantische Objekte möglich, die unterschiedliche Objekte zusammenfassen (Aggregation).

Im Unterschied zu dem Objektbegriff in kartographischen Modellen können Objekte im Fall der Fernerkundung aufgrund des unscharfen „fuzzy“-Verfahrens auch zu mehr als einer Klasse zugeordnet werden. In der Kartographie, bei ATKIS oder ALK wird dagegen mit einer strengeren Abhängigkeit gearbeitet. Da hier Grenzen eindeutig sein müssen, gehören Objekte immer nur einer Klasse an. In der Natur sind Objekte allerdings nicht immer eindeutig zu trennen, besonders wenn sie in Übergangszonen liegen.

Die wesentliche Unterscheidung zu den bisherigen Klassifikationsverfahren ist, dass nun mit homogenen Bildobjekten (Objektprimitiven) gearbeitet wird, um **aussagekräftige Objekte** zu erzeugen. Aussagekräftige Objekte sind somit die wichtigste Voraussetzung für eine wissensbasierte Klassifikation von Fernerkundungsdaten. Die mit den geeigneten Verfahren segmentierten Regionen sind die **Objekte** oder zunächst, da noch unklassifiziert, die **Objektprimitive** eines Bildes. Es handelt sich um untereinander disjunkte Teilgebiete eines Bildes mit der Eigenschaft, dass jeder Bildpunkt einer Region mindestens einen Nachbarn hat, der derselben Region angehört (Bähr und Vögtle 1998, S.128).

2.5.2 Segmentierungsverfahren

Basis aller weiteren Operationen in regionenbasierten Systemen wie eCognition ist die Ableitung von homogenen Segmenten. Bildobjekte werden in verschiedensten Auflösungen unter Berücksichtigung ihrer Umgebung extrahiert. So können einige Probleme sehr hoch auflösender Daten wie etwa die spektrale Heterogenität innerhalb zusammenhängender Objekte vermindert werden.

⁴ Ein digitales Landschaftsmodell (DLM) ist eine digitale Abbildung einer Landschaft, die aber im Gegensatz zu herkömmlichen Kartendarstellungen nicht generalisiert ist. Erst durch einen kartographischen Überarbeitungsprozess wird das DLM in ein kartographisches Modell inklusive der erforderlichen Generalisierung und Signaturen überführt (Saurer und Behr 1997).

„What should a good segmentation be? Regions of an image segmentation should be uniform and homogeneous with respect to some characteristic such as grey tone or texture.” (Haralick und Shapiro 1985, S.101)

Die Segmentierung ist ein Prozess, welcher ein Bild in spektral homogene Regionen unterteilt (Guindon 1997). Für die Ableitung von homogenen Regionen mittels Segmentierung gibt es eine Vielzahl von Ansätzen. Segmentierung ist vergleichbar mit einem *Clustering* Prozess. Der Unterschied besteht darin, dass *Cluster*-Verfahren im Merkmalsraum arbeiten und Segmentierungstechniken den geometrischen Raumbezug nutzen (Haralick und Shapiro 1985).

Das Erreichen der im obigen Zitat erwähnten Ansprüche ist schwierig. Typischerweise sind Regionen, die einem strengen Homogenitätskriterium folgen, löchrig und sie haben unruhige, fraktale Grenzen (Haralick und Shapiro 1985). Umgekehrt können zu viele Segmente verschmelzen und Grenzen verschwinden, wenn angrenzende Regionen nur durch sehr große Grauwertunterschiede getrennt werden.

Haralick und Shapiro (1985) benennen sechs Gruppen von Segmentierungsverfahren, die sich hinsichtlich der verwendeten Technik unterscheiden:

- *measurement space guided spatial clustering*
- *single linkage region growing schemes*
- *hybrid linkage region growing schemes*
- *centroid linkage region growing schemes*
- *spatial clustering*
- *split and merge schemes.*

Weitere wichtige Segmentierungsverfahren sind:

- *Quadtree*-Verfahren
- Wasserscheidentransformation
- *Density Slicing*
- Unüberwachte Klassifikation
- Wissensbasierte Segmentierung
- Multiskalare Segmentierung

Measurement space guided spatial clustering

Diese Methode ist einer **unüberwachten Klassifizierung** und damit einem Clusterverfahren ähnlich, worauf weiter unten noch näher eingegangen wird.

Single und hybrid linkage region growing schemes

Diese beiden Verfahren sind *region growing*-Algorithmen, die Pixel mit ihren Nachbarn vergleichen. Bei Ähnlichkeit werden die Pixel mit einer Kante verbunden. Beide Verfahren unterscheiden sich vor allem durch ihre Definition der Ähnlichkeit. Das erste nutzt nur die

Differenz zweier benachbarter Bildpunkte, das zweite vergleicht mehrere Nachbarschaften und definiert einen Eigenschaftsvektor pro Pixel.

Centroid linkage region growing schemes

Hierbei handelt es sich ebenfalls um ein *region growing* Verfahren, es geht aber anders als die beiden vorgehenden Verfahren vor. Ausgehend von Startpunkten wird das Bild gescannt und Pixelwerte mit den Mittelwerten bestehender Regionen verglichen. Anhand dieser Information wird das weitere Vorgehen entschieden. Die ECHO-Technik von Kettig und Landgrebe (1976) gehört in diese Gruppe, ebenso das Verfahren der ***multiresolution segmentation***.

Spatial clustering

Beim *spatial clustering* wird eine Histogrammmethode mit *region growing* verbunden. Zunächst werden die höchsten Grauwerte im Merkmalsraum festgestellt, diese im Bild gesucht und dann die Pixel mit den nächst niedrigeren Werten verglichen und diese ggf. zu Regionen fusioniert.

Split and merge schemes

Diese Gruppe von Verfahren, die *split and merge schemes*, entsprechen den **Quadtree-Verfahren** und werden dort detaillierter beschrieben.

Quadtree Verfahren

Diese *split and merge*-Verfahren betrachten im ersten Schritt das gesamte Bild als initiales Segment, welches sukzessive in kleinere Segmente unterteilt wird (Haralick und Shapiro 1985). Der erste Schritt ist die Prüfung, ob unterschiedliche Grauwerte vorliegen. Wenn das der Fall ist, wird das Bild unterteilt. Dieser Vorgang wird dann mit den Teilbildern wiederholt, bis nur noch homogene Regionen unterschiedlicher Größe übrig sind. Es wird in verschiedenen Varianten eine Baumstruktur erstellt.




Abb. 9: Darstellung des Quadtree-Verfahrens (Bartelme 2000)

Die bekannteste Methode erzeugt in jedem Durchgang genau vier Nachfolgeregionen (siehe Abb. 9) und wird deshalb *quad tree* genannt (Bartelme 2000, S.254). Aufgrund der

sukzessiven Aufteilung in immer kleinere, quadratische Regionen wirken deren Grenzen oft eckig und künstlich.

Wasserscheidentransformation

Nach Fleck et al. (1997) kann mit Hilfe eines modifizierten Flutungsalgorithmus ein Bild in homogene Bereiche segmentiert werden. Die Grauwerte eines Bildes werden als Höheninformation angesehen und die Szene sukzessive „geflutet“. Bereiche, an denen Kanten nicht geschlossen sind, werden am Auslaufen erkannt und in dem Algorithmus geschlossen. So bleiben am Ende Regionen im Bild übrig.

Da i. d. R. Regionen nicht durch einheitlich hohe Grauwerte an den Grenzen gekennzeichnet sind, sondern durch Grauwertunterschiede, wird das Verfahren auf Gradientenbilder angewendet (Fleck et al. 1997).

Density slicing

Das *density* oder *level slicing* ist eine einfache Histogrammoperation im Merkmalsraum. Die Grauwerte entlang der x-Achse des Histogramms werden in Klassen (Level) eingeteilt. Alle Grauwerte, die in ein bestimmtes Intervall fallen, werden als ein Grauwert dargestellt (Lillesand und Kiefer 2000, S.489). Die Folge im Bild sind unterschiedliche Ebenen, sog. *slices*. Diese Methode kann keine räumlichen Zusammenhänge berücksichtigen und erzeugt Regionen nur anhand relativ grober Abgrenzungen im Merkmalsraum.

Unüberwachte Klassifikation

Ein weiteres einfaches Verfahren der Segmentierung von homogenen Bildbereichen ist die Nutzung von unüberwachten, pixelbasierten Klassifikationsverfahren (siehe auch 2.2.1). Das Homogenitätskriterium für die Erzeugung von Regionen ist hier die Klassenzugehörigkeit. Nach Haralick und Shapiro (1985) gehören diese Methode und die vorher beschriebene des *density slicing* zu der Gruppe der *measurement space guided spatial clustering* Methoden.

Bei diesen Verfahren bestehen grundsätzlich die gleichen Probleme wie sie bei den Klassifikationsverfahren geschildert wurden. So werden nur einzelne Bildpunkte betrachtet und es wird nur auf der Basis der Grauwertvektoren im Merkmalsraum segmentiert. Unterschiedliche Regionen, die sich im Merkmalsraum überlagern, lassen sich nur schwer trennen. Diese Verfahren sind stark abhängig von den Bedingungen zum Zeitpunkt der Aufnahme der FE-Daten (Baatz et al. 1998).

Die Verfahren eignen sich gut, um eine bestimmte Anzahl von im Merkmalsraum eindeutig getrennten Clustern zu segmentieren, wenn diese auf einem homogenen Hintergrund liegen (Haralick und Shapiro 1985).

Ryherd und Woodcock (1996) kombinieren in einem Ansatz Textur- und Spektralmerkmale für die Auswertung und beschreiben eine Weiterentwicklung bestehender Verfahren. Der Verzicht auf Texturinformationen kann nach Bruniquel-Pinel und Gastellu-Etchegorry (1998) zu Auswertefehlern bei unüberwachten Verfahren führen.

Wissensbasierte Segmentierung

In einem wissensbasierten Ansatz nutzen Ton et al. (1991) eine automatisch extrahierte, räumliche Vorinformation für die Segmentierung von Landsat-Daten. Dieses hierarchische System extrahiert zunächst vegetationsbestandene Bereiche, Nicht-Vegetation und unsichere Bereiche anhand eines Vegetationsindexes.

In einem zweiten Schritt wird die Klasse Nicht-Vegetation unterteilt, indem so genannte Kerninformationen (vorher extrahierte Informationen über Straßen, Wasser, Vegetation etc.) mit den Pixeln dieser Klasse überlagert werden. Kontextinformation und Spektralwerte identifizieren dann urbane Bereiche und unbestandene Landoberfläche.

Als dritter, rekursiver Schritt wird die Klasse Vegetation untergliedert. Kerninformation wird überlagert, Startpunkte werden in bestimmten Bereichen gelegt und diese mit Hilfe von *region growing*-Verfahren vergrößert. Spektralinformationen und Kerninformation werden genutzt, um diese Bereiche zu identifizieren.

Zusätzlich werden bei diesen Verfahren Regeln formuliert, um Bereiche, die eine Komposition verschiedener Landbedeckungen darstellen, zu klassifizieren. Zum Beispiel wird jede 13x13 Pixel große Umgebung eines Bildpunktes gescannt. Wenn über 30 % der Pixel Straße sind und 20 % Vegetation oder mehrdeutig sind, bzw. mehr als 95 % Nicht-Vegetation oder mehrdeutig sind, dann ist der Bildpunkt als urban zu kennzeichnen (Ton et al. 1991).

Ein Ansatz von Gorte (1998) geht darüber hinaus, indem er in die Segmentierung die Berücksichtigung von Klassenzugehörigkeiten einfließen lässt. Ähnliche Ansätze verfolgt auch das Verfahren der *multiresolution segmentation*, das im Folgenden vorgestellt wird.

Multiskalare Segmentierung

In ihrer Erläuterung gängiger Segmentierungsansätze enden Haralick und Shapiro (1985) mit der Aussage, dass eine Segmentierung, die die Semantik der Objekte mit einbezieht eine wesentlich tiefere Analyse der Bildinformation gestattet.

Baatz und Schäpe (2000) schlagen ein Verfahren namens *multiresolution segmentation* vor. Dieses überprüft vor der Fusion die Homogenität benachbarter Objekte und berücksichtigt zusätzlich die potenzielle Heterogenität des zukünftigen fusionierten Objektes (siehe auch Baatz et al. 1998). Ähnlich dem Verfahren von Ton et al. (1991) können auch hier Vorinformationen einfließen. Dies geschieht entweder in Form externer Information, die dem Datensatz als Pseudokanal hinzugefügt wurde, oder als klassifikationsbasierte Korrektur der segmentierten Bereiche in einem zweiten Schritt. Im folgenden Abschnitt wird das Verfahren der *multiresolution segmentation* genauer beschrieben.

Die mit diesen Verfahren segmentierten Regionen stellen die Objekte in einem Bild dar (Kettig und Landgrebe 1976). Wie aber schon bei der Vorstellung regionenbasierter Klassifikationsverfahren besprochen, gilt für alle Segmentierungsverfahren, dass es immer noch an zuverlässigen Maßen für die Qualität von Segmentierungsergebnissen fehlt (siehe 2.3).

2.6 Die eCognition-Methode

2.6.1 Segmentierung in eCognition

Ziel des Segmentierungsverfahrens in eCognition ist die Ableitung von so genannten **aussagekräftigen Bildobjekten** (*meaningful image objects*) gleichzeitig **auf unterschiedlichen Maßstabsebenen**. Die Abbildung (Abb. 10) stellt den gleichen Ausschnitt eines Satellitenbildes auf drei unterschiedlich segmentierten Maßstabsebenen dar. Mit Ausnahme der Angabe einer Toleranzschwelle als Abbruchkriterium wird kein weiteres Vorwissen bei dieser Methode benötigt.



Abb. 10: Segmentierung auf unterschiedlichen Maßstabsebenen. Links: Originalbild; Mitte: Kleine Objekte; Rechts: Große Objekte → kleiner Maßstab. Der rote Kasten zeigt als Beispielobjekt ein Feuchtgebiet

Die Segmentierung soll die folgenden Ziele erfüllen (Baatz et al. 1998, Baatz und Schäpe 2000):

1. Hohe Qualität: Homogene Segmente für optimale Trennung und Repräsentation von Bildregionen
2. Segmentierung in beliebiger Auflösung: Interessierende Objekte existieren üblicherweise auf unterschiedlichen Skalenebenen, deshalb ist der Maßstab anpassbar
3. Vergleichbare Auflösung: Fast alle Objekteigenschaften sind maßstabsabhängig (Farbe, Textur, Form), nur Objekte ähnlicher Auflösungen sind vergleichbar
4. Aufbau einer hierarchischen Objektstruktur
5. Trennbarkeit von Bildbereichen, auch wenn diese im Merkmalsraum überlappen
6. Nutzung beliebig dimensionaler Daten
7. Reproduzierbarkeit
8. Allgemeingültigkeit: Anpassbar auf beliebige Daten und Fragestellungen
9. Geschwindigkeit

Die Ergebnisse von Segmentierungsverfahren können mathematisch/statistisch noch so gut bewertet werden, sie müssen einem **Qualitätskriterium** standhalten, das Ungenauigkeiten und Fehler sehr schnell aufspürt, nämlich dem menschlichen Auge (Baatz et al. 2002). Ausgehend davon werden für dieses Verfahren im Voraus von den Autoren Qualitätsanforderungen definiert. Eine Logik soll durch Beachten folgender Maßgaben das

„Segmentieren“ des menschlichen Auge-Hirn-Systems nachvollziehen. Das bedeutet qualitativ, dass lokale Kontraste gleichmäßig verarbeitet und von der Segmentierung Regionen gleicher Dimension erzeugt werden.

Quantitativ wird das folgendermaßen formuliert:

1. Die durchschnittliche Heterogenität eines Objektes soll minimiert werden.
2. Die durchschnittliche Heterogenität eines Objektes gewichtet mit seiner Größe in Pixeln soll minimiert werden.
3. Die durchschnittliche Heterogenität von Pixeln soll minimiert werden. Jeder Pixel wird mit der Heterogenität des Bildobjektes gewichtet, zu dem es gehört.

Dieses Verfahren der so genannten *fractal net evolution* nutzt ein dynamisches semantisches Netz, welches die Objekte im Bild hinsichtlich der oben definierten Qualitätskriterien optimiert (Blaschke 2000).

2.6.1.1 Grundkonzept der Segmentierung in eCognition

Die verwendete Prozedur ist mit dem von Haralick und Shapiro (1985) besprochenen Grundkonzept des *centroid linkage region growing scheme* vergleichbar.

Aufgrund der Geschichtlichkeit (vgl. Baatz und Schäpe 2000) dieses Verfahrens ist es aber nicht sinnvoll, ein Bild systematisch Pixel für Pixel mittels eines Filters abzutasten, weil das Abtasten systematische Fehler nach sich ziehen kann.

Daher ist es von Vorteil, dass die Segmentierung eines Bildes mit einer **Sequenz von Bildobjekten**, die genau einen Bildpunkt enthalten beginnt. Diese müssen zwei Bedingungen erfüllen:

1. Jeder/s Punkt/Objekt darf nur einmal pro Durchgang bearbeitet werden
2. Anschließende Fusionen sollen so weit wie möglich entfernt voneinander ablaufen

Die in dem Programm eCognition verwendete Lösung besteht aus Sequenzen, die systematisch die Punkte wählen, welche eine maximale Distanz zueinander haben. Auch bei dieser Lösung ist ein stochastischer Einfluss vorhanden, der im Extremfall für unterschiedliche Segmente bei gleichen Startparametern sorgt.

Je mehr Startpunkte es gibt, desto differenzierter kann der Segmentierungsalgorithmus arbeiten und Gleichbehandlung von heterogenen und homogenen Bildbereichen gewährleisten. Dieses Verfahren wird *distributed treatment order* genannt und findet bei drei der vier weiter unten vorgestellten Entscheidungsregeln Verwendung. In jedem weiteren Schritt werden zwei angrenzende Objekte fusioniert. Die Fusion basiert auf lokalen Homogenitätskriterien. Die Fusion oder Auftrennung von Objekten endet, wenn die Toleranzschwelle erreicht ist.

Bestimmung der Homogenität

Für die Bestimmung der Homogenität stehen zwei unterschiedliche Techniken zur Verfügung. Das eine Verfahren vergleicht die gewählten Homogenitätsmaße zweier benachbarter Bildpunkte direkt. Das andere Verfahren berechnet die potenzielle Homogenität eines zukünftigen Objektes nach der Fusion. Als **Homogenitätsmaß** dient die durchschnittliche gewichtete Standardabweichung der Farbmittelwerte der Bildobjekte. Ziel ist es, die sich in der Standardabweichung⁵ bzw. Varianz ausdrückende Heterogenität gemittelt über jedes Bildelement möglichst gering zu halten.

Im Folgenden werden die verwendeten Homogenitätsmaße des **direkten Vergleichs von Segmenten** beschrieben (aus Baatz et al. 1998). Im einfachsten Fall wird der Mittelwert der Grauwerte innerhalb eines Objektes gemäß der unten stehenden Ungleichung verglichen:

$$(2) \quad |m_1 - m_2| < \alpha$$

mit: α = Toleranzschwelle; m_1 und m_2 sind die Objektmittelwerte der beteiligten Bildsegmente

Wenn zusätzlich die Standardabweichung der Merkmalsverteilungen berücksichtigt wird, kann die Qualität der Segmentierung weiter verbessert werden und die obige Ungleichung verändert sich folgendermaßen:

$$(3) \quad \frac{|m_1 - m_2|}{\sigma_1 + \sigma_2} < \alpha$$

Der Unterschied im Mittelwert geteilt durch die Summe der Standardabweichungen muss bei dieser Ungleichung kleiner sein als die vorgegebene Toleranzschwelle. Die Parameter σ_1 und σ_2 repräsentieren den lokalen Objektbezug. Je heterogener die Segmente sind, desto toleranter wird der Unterschied im Mittelwert bewertet (Baatz et al. 1998). Bei kleinen Segmenten, für die keine repräsentative Standardabweichung berechnet werden kann, wird stellvertretend entweder eine Standardabweichung genommen oder sie wird aus dem gesamten Bild berechnet.

Nach erfolgter Fusion kann sich die Ähnlichkeit eines Segmentes entsprechend der beiden obigen Ungleichungen verhalten. Dies bedeutet, dass die Toleranzen immer wieder neu bezogen auf ein Objekt festgelegt werden müssen.

Bei großen Segmenten können aufgrund der Merkmalsverteilung wesentlich sicherere Entscheidungen getroffen werden. Allerdings ist der Fehler bei falsch fusionierten großen Segmenten erheblich größer. Deshalb wird hier die Größe eines Objektes als Gewichtungsfaktor mit einbezogen.

⁵ Die Standardabweichung eines Bildobjektes ist ein Maß für die Heterogenität der Pixel innerhalb dieses Objektes.

Diese direkt vergleichenden Homogenitätsparameter können auch kombiniert werden, so dass der Unterschied in den Mittelwerten und der Unterschied in den Standardabweichungen bewertet wird, um stabilere Ergebnisse zu erzielen.

Der zweite Typ der Homogenitätskriterien vergleicht den **potenziellen Zustand** eines Objektes nach der Fusion zweier Segmente mit deren Homogenität vor der Fusion. Je geringer der Heterogenitätseintrag in die Segmentierung, desto geringer ist auch der Merkmalsunterschied der betroffenen Bildobjekte (Baatz et al. 1998). Hierbei wird ebenfalls die Größe der Bildobjekte über die Anzahl der in ihnen enthaltenen Bildelemente berücksichtigt. Allgemein wird dieser Typ so beschrieben:

$$(4) \quad \Delta h_{gew} = (n_1 + n_2)h_{neu} - (n_1h_1 + n_2h_2) < \alpha$$

mit: Δh_{gew} = eingetragene Heterogenität = Differenz zwischen der mit der Größe der jeweiligen Segmente gewichteten Heterogenität der Segmente h_1 und h_2 nach der Fusion und vorher

Zu diesem zweiten Typ gehört ebenfalls ein Vergleich der gewichteten Standardabweichung, der gewichteten Mittelwerte sowie der gewichteten Varianz. Letztere wird beispielhaft in der folgenden Ungleichung dargestellt:

$$(5) \quad \Delta \text{var}_{gew} = n_1(\text{var}_{neu} - \text{var}_1) + n_2(\text{var}_{neu} - \text{var}_2) < \alpha$$

Das vorgestellte Verfahren ist ebenfalls in der Lage, **Bereiche mit kontinuierlichem Farbverlauf** zu segmentieren. Hierzu wird der durchschnittliche Abstand des durchschnittlichen Farbwertes der betroffenen Bildelemente zu einer Regressionsfläche dieser Farbmittelwerte im Ortsraum ermittelt. Dieses Maß für die Heterogenität kann dann in die allgemeine Ungleichung des zweiten Typs (siehe oben) eingesetzt werden.

Multispektrale Fernerkundungsdatensätze bestehen aus mehreren Kanälen. Im Folgenden wird die **Behandlung der Homogenitätskriterien bei n -Kanälen** beschrieben.

Im einfachsten Fall kann ein absolutes Kriterium genutzt werden, d. h. dass über alle Kanäle das Homogenitätskriterium erfüllt sein muss. Das trägt der Tatsache Rechnung, dass auch ein Unterschied in nur einem Kanal besagt, dass die Bildstrukturen unterschiedlich sind. Eine weitere Möglichkeit ist die Gewichtung der Kanäle. Es werden Homogenitätskriterien in allen Kanälen ermittelt, aufsummiert oder gemittelt, um dann mit Hilfe der Gewichtung zu besseren Ergebnissen zu kommen (Baatz et al. 1998). Die Anpassung der obigen Formel sieht in ihrer allgemeinen Form so aus:

$$(6) \quad \Delta \text{var}_{gew} = \sum_c w_c (n_1(\text{var}_{neu} - \text{var}_1) + n_2(\text{var}_{neu} - \text{var}_2)) < \alpha$$

mit: w_c der Gewichtungsfaktor des jeweiligen Kanals c ist.

Formhomogenität

Zusätzlich zu rein spektralen Homogenitätskriterien können bei der Segmentierung auch Parameter für die Form eines Objektes genutzt werden. Ein Beispiel ist die Berechnung der idealen kompakten Form über die Beziehung der Kantenlänge l und der Wurzel aus der Objektgröße n . Das entspricht der Kantenlänge eines Quadrates mit der Kantenlänge n Pixel (Baatz und Schäpe 2000):

$$(7) \quad h = \frac{l}{\sqrt{n}}$$

Entscheidungsregeln

Wie oben gezeigt, werden sozusagen „Kostenfunktionen“ der Fusionsparameter für jede mögliche Fusion berechnet. Diese beschreiben den „Grad der Übereinstimmung“ von angrenzenden Segmenten. Eine Fusion findet statt, wenn der „Grad der Übereinstimmung“ kleiner ist als ein gegebener „kleinster Grad der Übereinstimmung“, der in eCognition als *scale parameter* bezeichnet wird.

Die zugehörige **Entscheidungsregel** bewertet die Homogenität der Objekte (*degree of fitting*) anhand von vier Konzepten:

1. **Einfache Passung (*fitting*):** Die Fusion von Objekt A mit irgendeinem Nachbarn findet dann statt, wenn Homogenitätskriterium erfüllt ist.
2. **Bestpassung (*best fitting*):** Ein Objekt A wird mit seinem Nachbar fusioniert, wenn das Homogenitätskriterium bezogen auf das Abbruchkriterium, den *scale parameter*, erfüllt ist.
3. **Gegenseitige Bestpassung (*local mutual best fitting*):** Diese Methode soll für Objekt A jeweils den Nachbarn B finden, bei dem das Homogenitätskriterium am besten erfüllt ist. Gleichzeitig wird für Objekt B der Nachbar C gesucht, auf den das Homogenitätskriterium am besten zutrifft. Anschließend wird geprüft, für welches Segmentpaar das Homogenitätskriterium wechselseitig am besten erfüllt ist, also ob z. B. „Objekt C“= „Objekt A“ ist. Wenn das nicht der Fall ist, dann wird der Zyklus wiederholt mit B für A und C für B. So wird das am besten passende Paar in der direkten Umgebung von Objekt A gefunden. Die beste Homogenität findet sich selbst bei hoher spektraler Varianz in der direkten Umgebung von Objekten. Auch Objekte mit unterschiedlicher Textur werden symmetrisch behandelt. Die Bildobjekte wachsen gleichmäßig, was zu vergleichbaren Objektgrößen führt.
4. **Globale Bestpassung (*global mutual best fitting*):** Im gesamten Bildbereich werden diejenigen nachbarschaftlichen Objekte gesucht, bei denen das Homogenitätskriterium am besten erfüllt ist. Anschließend wird das Paar von angrenzenden Objekten fusioniert, auf welches das Homogenitätskriterium in der gesamten Szene am besten zutrifft. Hier wird keine so genannte *distributed treatment*

order verwendet, d. h. Objekte wachsen nicht gleichmäßig. Als Folge kann ein Ungleichgewicht zwischen Regionen mit geringem und hohem Kontrast auftreten.

Da sich das Homogenitätsmaß der Objekte bei einer Fusion oder Trennung verändert, ist das Segmentierungsverfahren **iterativ**, d. h. es wird mehrfach durchgeführt, bis das Ergebnis konvergiert und trotz weiterer Bearbeitung stabil bleibt (Baatz et al. 1998). Bildelemente, die vorher das Homogenitätskriterium nicht erfüllt haben, können jetzt evtl. zueinander passen und Bildelemente, die bislang Bestandteil eines Segmentes sind, können jetzt nicht mehr passen.

Kurz zusammengefasst ist die *multiresolution segmentation* eine *region growing / region merging* Prozedur: Das Verfahren beginnt mit pixelgroßen Objekten. Diese werden durch Anwendung eines Homogenitätskriteriums so lange fusioniert, bis die gewichtete Heterogenität der Objekte minimiert ist. Durch die Verteilung der Startobjekte über die gesamte Szene und simultanes Wachstum der Segmente wird sichergestellt, dass Objekte vergleichbarer Größe entstehen.

2.6.1.2 Nachbearbeitung und Verbesserung

Es kann vorkommen, dass ein Bildelement gleichzeitig zu zwei benachbarten Segmenten gehört. Für solche Fälle ist eine Randkorrektur vorgesehen. Dafür kann entweder das gleiche Homogenitätskriterium wie bei der Fusion verwendet werden, oder alle Bildelemente der betroffenen Segmente werden dann erneut geprüft. Auf der niedrigsten Segmentebene wird aber ein gesondertes Kriterium verwendet. Dieses ist ähnlich der *maximum-likelihood*-Entscheidungsregel (siehe 2.2.2.1), die für den Merkmalsmittelwert und die Standardabweichung der betroffenen Segmente eine Normalverteilung annimmt. Die entsprechende Formel liefert einen Erwartungswert \hat{p} , mit dem die Zugehörigkeit eines Bildelementes zum jeweiligen Segment festgestellt werden kann (Baatz et al. 1998). Ist die Zugehörigkeit zum Nachbarsegment größer, wird das Bildelement aus seinem bisherigen Segment herausgelöst und mit dem anderen fusioniert. Falls nach dieser Prozedur ein Segment nicht mehr zusammenhängend ist, wird es zerlegt.

Für mehrere Kanäle wird die gesamte Zugehörigkeitswahrscheinlichkeit eines Bildpunktes über das geometrische Mittel der einzelnen Wahrscheinlichkeiten in jedem Kanal berechnet. So kann eine schlechte Zugehörigkeit in einem Kanal durch eine sehr gute in einem anderen kompensiert werden. Besonders schlechte Zugehörigkeiten werden aber durch die Verwendung des geometrischen Mittels dennoch berücksichtigt.

Die entstandenen aussagekräftigen Bildobjekte können anhand semantischer Information, basierend auf einer vorangegangenen Klassifikation, erneut segmentiert werden (*classification based segmentation*).

2.6.1.3 Ergebnis der Segmentierung

Der oben vorgestellte Segmentierungsalgorithmus erzeugt ein **hierarchisches** Netzwerk von miteinander verbundenen Bildobjekten (siehe Abb. 11). Die Bildobjekte liegen in verschiedenen Auflösungen segmentiert vor (Baatz et al. 1998) und repräsentieren die

Bildinformation auf verschiedenen **Maßstabsebenen** gleichzeitig. Durch Änderung der Toleranzschwelle können jederzeit neue Ebenen durch Fusionierung oder Trennung von Objekten eingefügt werden.




Abb. 11: Hierarchisches Netzwerk von Bildobjekten auf zwei Ebenen. Ebene 2 enthält einzelne Bildpunkte, die auf Ebene 1 zu aussagekräftigen Objekten zusammengefasst sind.

Die Bildobjekte sind miteinander verbunden, so dass jedes Objekt seine Nachbarn sowie seine Ober- bzw. Unterobjekte „kennt“. Die **Topologie** dieses Netzwerks ist so definiert, dass die Grenzen der Objekte konsistent sind, d. h. Grenzen von Unterobjekten verlaufen innerhalb der Grenzen des Oberobjektes. Jede neue Ebene wird direkt aus ihren Unterobjekten erzeugt, die entsprechend der vorgegebenen Toleranzschwelle und des Homogenitätskriteriums „nur“ noch fusioniert werden.

Während der Segmentierung wird eine **Objektdatenbank** erzeugt, die neben spektralen Eigenschaften der Objekte diverse zusätzlich berechnete Eigenschaften enthält. Über die mit den vorgestellten Methoden abgeleiteten Regionen stehen also viel mehr Informationen zur Verfügung, als rein pixelbasiert arbeitende Verfahren nutzen können. Es sind z. B. Größe (Flächeninhalt); Form, Umfang und Textur jedes Objektes bekannt. Des Weiteren kann jetzt die Topologie, also die Beziehungen zu klassifizierten Nachbarobjekten, herangezogen werden.

2.6.2 Wissensmanagement in eCognition

Allen wissensbasierten Systemen ist die explizite Modellierung des Vorwissens gemein (Grove 2000). Die Bildinformation wird mit unterschiedlichen Methoden, z. B. Segmentierung, extrahiert und in Datenbanken abgelegt. In der Formalisierung dieses Wissens unterscheiden sich die verschiedenen Verfahren. Beispielsweise können komplexe Regelwerke die Objekte beschreiben, hierarchische Strukturen genutzt oder semantische Netze eingesetzt werden.

Da sich Objekte innerhalb einer Klasse in der Natur selten exakt gleichen, wird zur Interpretation Erfahrungswissen benötigt (Grove 2000, S.10). Die Formalisierung dieses Wissens dient zur Erstellung einer generischen Beschreibung der Objekte bzw. der

gesamten Szene. Wertebereiche für unterschiedliche Objekteigenschaften berücksichtigen im **objektspezifischen Wissen** diese Unschärfe in der Natur. **Strukturelles Wissen** beschreibt die Zusammensetzung komplexer semantischer Objekte. Die räumlichen Beziehungen von Objekten werden durch das **topologische Wissen** erfasst. Zeitliche Veränderungen von Objekten werden über das **temporale Wissen** dargestellt.

2.6.2.1 Wissensbasis

Wie oben bereits beschrieben, erzeugt das Segmentierungsverfahren in eCognition während des Segmentierungsprozesses eine **Datenbank** mit Informationen zu jedem Bildobjekt. Diese Informationen enthalten neben den reinen Spektralwerten und deren Statistik wie Mittelwert und Standardabweichung auch Informationen über die Nachbarschaft von Objekten. Hier kann zwischen den direkt angrenzenden so genannten Nachbarn erster Ordnung (Guindon 2000) und weiter entfernten Nachbarschaften unterschieden werden. Bezogen auf die direkte Nachbarschaft kann z. B. die Differenz der Grauwerte zum Nachbarn ausgewertet werden. Für eine vollständige Liste aller nutzbaren Eigenschaften sei auf das Handbuch von eCognition verwiesen (Baatz et al. 2002). Ein Ausschnitt der berechneten Parameter ist in der folgenden Abbildung (Abb. 12) dargestellt.

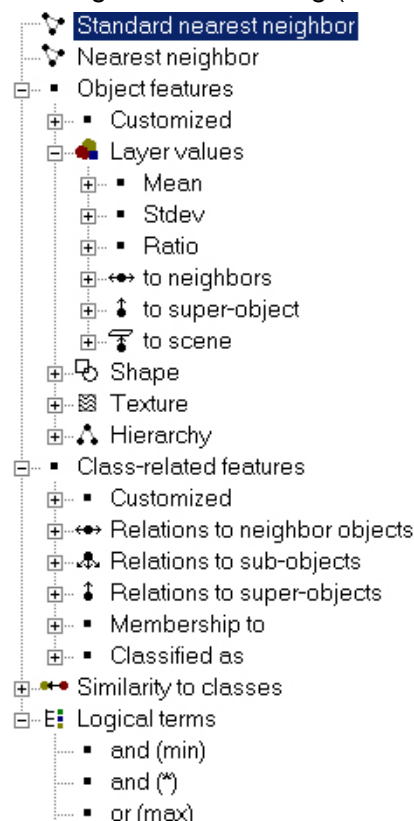


Abb. 12: Zusammenstellung von Objekteigenschaften aus der eCognition-Datenbank (eCognition Screenshot)

Hinsichtlich ihrer Bedeutung für die spätere Formalisierung dieser Informationen sollen hier noch die klassifikationsbasierten Nachbarschaftsparameter erwähnt werden. Ausgehend von einem ersten erfolgreichen Klassifikationsschritt können nun Objekteigenschaften wie die Distanz oder die Länge der Grenze zu einer bestimmten Klasse ausgewertet werden. So

lassen sich z. B. Inseln sehr leicht unterscheiden, indem sie als diejenigen Objekte definiert werden, die zu 100% von Wasser umgeben sein müssen.

Die große Anzahl der Objekteigenschaften stellt den Interpreten vor das Problem, diese zu bewerten und die relevanten auszuwählen (vgl. *stacked vector* Ansatz in 2.3). Die Eigenschaften lassen sich zum Teil in **stabil** und **instabil** untergliedern (vgl. Mott et al. 2002). Als instabil gelten spektrale Eigenschaften, die direkt abhängig von den Aufnahmebedingungen sind. Parameter wie Zustand der Atmosphäre, Änderungen der Sensorcharakteristik oder Sonnenstand (Aufnahmezeitpunkt) beeinflussen direkt das aufgenommene Bild, so auch die spektralen und die daraus abgeleiteten Objekteigenschaften wie auch Texturen.

Stabil sind semantische Eigenschaften, welche z. B. die relative Lage von Objekten beschreiben. So wird sich ein Feuchtgebiet immer in einer gewissen Nähe zu Wasser befinden, unabhängig von seiner spektralen Ausprägung.

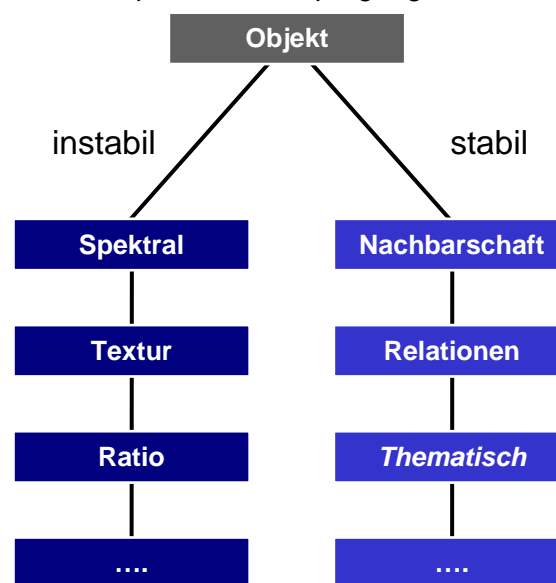


Abb. 13: Stabile und instabile Eigenschaften in der eCognition Objektdatenbank

Externe Daten wie Kartierungen oder Informationen aus Geographischen Informationssystemen (GIS), werden auch bei diesem Verfahren in Form von Pseudokanälen vorher zu dem Datensatz hinzugefügt. Sie können wahlweise auch schon bei der Segmentierung genutzt werden, um künstliche Grenzen z. B. aus Katasterkarten einzubinden.

GIS-Daten selbst stellen bereits symbolische Szenenbeschreibungen dar. Diese können zwar Fehler enthalten, sie vereinfachen aber den Klassifikationsprozess und erhöhen nach Growe (2000, S.13) die Vollständigkeit und Korrektheit der symbolischen Szenenbeschreibung.

2.6.2.2 Wissensrepräsentation

Für die Repräsentation des gespeicherten beschreibenden Wissens bieten sich einige Ansätze an. Eine formale Sprache kann Begriffe und deren Beziehungen darstellen. Sie gilt aber als zu starr, da Unsicherheiten sich nur schwer beschreiben lassen (Growe 2000, S.14). Semantische Netze sind eine Art gerichtete Graphen. Sie sind in besonderem Maße geeignet, Beziehungen zwischen Objekten darzustellen. Knoten sind Begriffe oder

Sachverhalte und gewichtete Kanten stellen die Beziehungen zwischen ihnen dar (Bartelme 2000, S.247).

Das Konzept der Wissensrepräsentation in eCognition basiert auf **Regelwerken**, kombiniert mit einem **semantischen Netz**. Es werden im Prinzip zwei Netze erzeugt: eines enthält semantische Struktureinheiten (Objekte), das zweite enthält semantische Wissensseinheiten (Regeln). Für die Auswertung werden beide Netze miteinander kombiniert (vgl. Baatz et al. 2001). Innerhalb der eCognition Regelwerke gibt es die Klassenhierarchie, welche aus Klassen (Objektdefinitionen) aufgebaut ist. Regelwerk ist ein Oberbegriff, der die Klassenhierarchie und die enthaltenen Klassen umschreibt. Beide Begriffe, Regelwerk und Klassenhierarchie, werden im Folgenden auch synonym benutzt.

Regeln repräsentieren das Wissen in WENN-DANN-Beziehungen. Es gibt einen Bedingungs- und einen Anwendungsteil der Regel. Wenn der erste erfüllt ist, dann wird die Regel ausgeführt. Für die Problemlösung, d. h. falls mehr als eine Regel zutrifft, ist eine sog. Inferenzmaschine verantwortlich.

Die ersten Klassifikationsschritte in eCognition sind datengetrieben, d. h. sie folgen einem *bottom-up*-Ansatz. In weiteren iterativen Klassifikationsschritten steht immer mehr semantisches Wissen über die Objekte zur Verfügung. Das Ergebnis ist ein räumliches, semantisches Netzwerk klassifizierter Bildobjekte (Baatz et al. 2002). Objektklassen, die mit Hilfe der Regelwerke definiert werden, lassen sich auf zwei unterschiedliche Arten in eCognition hierarchisch kombinieren. Die Objektklassen können einer **Vererbungsstrategie** von Eltern- und Kindklassen folgen. Objekte wie Feuchtgebiete können hier mit allgemeingültigen Eigenschaften definiert werden und diese Information an Unterklassen wie Schilf, Streuwiese, Moor etc. vererben. Hierbei wird berücksichtigt, dass Objekte bei höheren Auflösungen in Subobjekte zerfallen, die Klassifikationsgenauigkeit aber bei Erkennung von Detailklassen nicht unbedingt ansteigt (vgl. Congalton 1991). Die Detailgenauigkeit steigt an, je tiefer die Klassenhierarchie sich verzweigt (Baatz et al. 2002).

Unterschiedliche Maßstabsebenen der Segmentierung lassen sich so auch in der Klassenhierarchie abbilden, so dass hier beispielsweise Unterklassen wie Schilf und Seggen zur Oberklasse Feuchtgebiet kombiniert werden. Parallel dazu wird eine Hierarchie semantischer Objektklassenbeziehungen (**Gruppenhierarchie**) aufgebaut. So können Klassen mit unterschiedlichen Attributen zu einer gemeinsamen semantischen Oberklasse mit einer neuen Bedeutung kombiniert werden (Baatz et al. 2002). Semantische Oberklassen benötigen nicht zwingend eine eigene Klassenbeschreibung. Beispielsweise lassen sich Objektklassen wie „Gebäude“, „Strasse“ oder „Wasser“ zu einer Oberklasse „Nicht-Vegetation“ zusammenfassen.

2.6.2.3 Regelwerke und Klassifikation

Jede Objektklasse wird mit den für sie repräsentativen Eigenschaften über Regelwerke definiert. Die Informationen über die relevanten Eigenschaften stammen aus Expertenwissen, Kartieranleitungen und vorhergehenden Datenanalysen von eCognition. Letztere bewerten den Einfluss bestimmter, vorgegebener Merkmalskombinationen für die

Klassentrennung im Merkmalsraum statistisch. Regelwerke setzen sich aus Kombinationen repräsentativer Eigenschaften zusammen. Der Wertebereich einzelner Eigenschaften kann auf zwei Arten definiert werden. Einerseits erfolgt die Definition auf der Basis der Kombination eindimensionaler **Zugehörigkeitsfunktionen**, welche den Wertebereich jeder Eigenschaft mittels Kurven beschreiben (siehe Abb. 14). Zugehörigkeitsfunktionen definieren die Bedingung, wann ein Objekt einer Klasse angehören soll.

Der Anwendungsteil der Regel, also die Zuordnung zur Klasse, wird ausgeführt, wenn die Bedingung erfüllt ist. Das entspricht einer WENN-DANN-Regel, die über logische Operatoren mit anderen verknüpft werden kann. Beispielsweise muss ein Objekt innerhalb eines bestimmten Grauwertbereiches im Infrarotkanal liegen UND zu 100% von der Klasse Wasser umgeben sein, damit es als Insel erkannt wird.

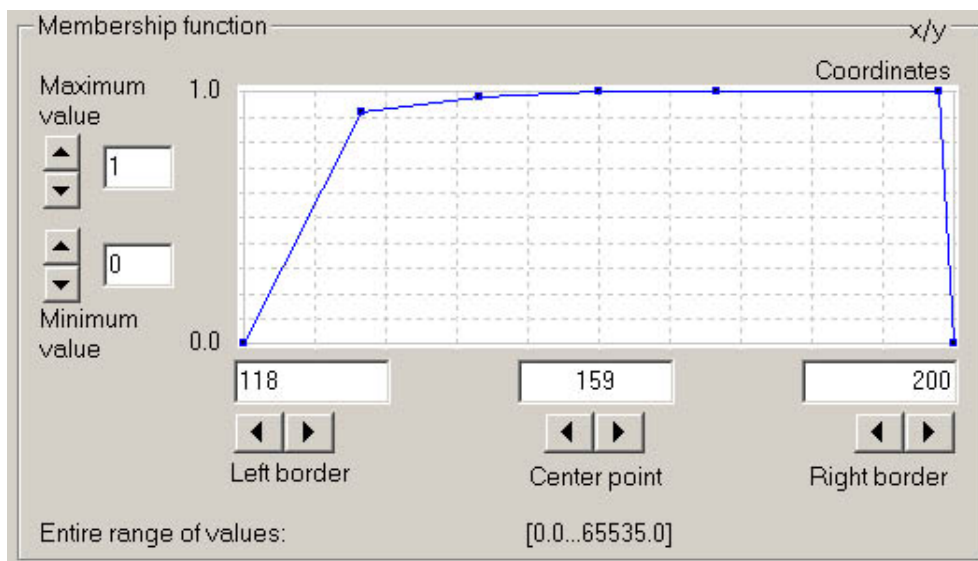


Abb. 14: Zugehörigkeitsfunktion eines beliebigen Merkmals aus der Objektdatenbank. Die Kurve legt den Wertebereich für eine bestimmte Eigenschaft fest (Screenshot aus eCognition)

Die zweite Möglichkeit ist ein **Minimum-Distance-Klassifikationsverfahren** der nächsten Nachbarschaft, das in einem definierbaren, multidimensionalen Merkmalsraum arbeitet (Baatz et al. 2002). Der Merkmalsraum wird in eCognition aus den Objekteigenschaften in der Datenbank gebildet. Er ist in dem Sinne definierbar, dass er im Prinzip alle Eigenschaften enthalten kann.

Beide Verfahren entsprechen einer überwachten Klassifikation. Die erste Methode ermöglicht die direkte Formulierung des Wissens über die Bildobjekte. Beim zweiten Verfahren ist es notwendig, Trainingsobjekte zu suchen.

Beide Klassifikationsverfahren können mit dem oben erwähnten logischen Operatoren kombiniert werden und ermöglichen die **Definition unscharfen Wissens (fuzzy classification)**. Das Ziel der Einführung einer Unschärfe ist die Verringerung der Komplexität, indem scharfe Klassentrennungen durch unscharfe ersetzt werden (Binaghi et al. 1999). Scharfe Klassengrenzen können die semantische Flexibilität, die in komplexen Landbedeckungskategorien enthalten ist, nicht erfassen. Mit *fuzzy*-Verfahren ist es möglich, dass Bildobjekte vom Klassifikationsverfahren mehreren Klassen zugeordnet werden und/oder nur zu einem bestimmten Anteil einer Klasse angehören, z. B. nur zu 60% sicher

Grünland sind. So kann auch der Grad der Überlappung von verschiedenen Klassen untersucht werden (Baatz et al. 2002).

Für eine spätere Ableitung von Karten aus dem Klassifikationsergebnis müssen diese unscharfen Klassen wieder in scharfe Klassen umgewandelt werden (*defuzzification*). Das geschieht durch Anwendung eines *Ranking*-Prozesses, der auf Entscheidungsregeln basiert. Diejenige Klasse mit der höchsten Wahrscheinlichkeit wird zugewiesen. Allerdings wirkt bei gleichen Klassenzugehörigkeiten eine stochastische Komponente bei diesem Prozess.

Klassifikationen können und sollten in mehreren Durchgängen erfolgen, da sich Klassifikationsergebnisse erst nach einigen **Iterationen** stabilisieren. Wenn viele klassenbezogene Parameter eingesetzt werden, also Parameter, die sich auf bereits erfolgreich klassifizierte Objekte beziehen (z. B. Distanz zu Wasser), sind immer mindestens zwei Durchgänge notwendig. So existieren in einem ersten Durchlauf konsequenterweise noch keinerlei klassifizierte Objekte, so dass Abfragen wie „relative Grenze zur Klasse Feuchtgebiet“ nicht funktionieren. Erst im folgenden Durchlauf können auch solche Abfragen greifen und Objekte (neu) zugeordnet werden. Es können beliebig viele Klassifikationsvorgänge durchlaufen werden, nach fünf Iterationen ist das Ergebnis aber i. d. R. stabil.

Die Verhältnisse in der Realität lassen sich mit dieser Methode genauer abbilden. Weitere Vorteile unscharfer Klassifikationsverfahren liegen in der Möglichkeit, die Trennbarkeit von Klassen bzw. die Eignung der gewählten Objekteigenschaften zur Klassentrennung zu bewerten. Auch die Eignung der zu Grunde liegenden Datenbasis kann damit kritisch betrachtet werden (Baatz et al. 2002).

2.7 Klassifikationsqualität

„It looks good“ is not a valid accuracy statement. A classification is not complete until it has been assessed.” (Congalton 1991, S.45)

Wenn eine Klassifikation erfolgreich durchgeführt wurde, besteht die Notwendigkeit, die Genauigkeit des Endproduktes zu ermitteln (Mather 1999, S.206). Genauigkeit beschreibt wie „dicht“ eine Messung bzw. Klassifikation an den wahren Wert heran kommt (Smits et al. 1999). Was jeweils als Realität angesehen wird, ist oft Definitionssache, d. h. es muss vereinbart werden, womit Klassifikationsergebnisse verglichen werden und was sie abbilden sollen (vgl. dazu die Objektdefinition in 2.5.1).

2.7.1 Klassische Verfahren

Aussagen über die Qualität von Klassifikationsergebnissen lassen sich über die Kombination unterschiedlicher Techniken treffen. Häufigste Methode ist die Fehleranalyse über einen Vergleich mit Referenzdaten.

Die Analyse von Fernerkundungsdaten ist mit hohen Kosten verbunden. Einerseits sind dies die sehr teuren Daten selbst, welche natürlich mit einem möglichst hohen Informationsgewinn ausgewertet werden sollen. Auf der anderen Seite fallen die sehr aufwendigen und damit teuren Geländebegehungen ins Gewicht, die notwendig sind um Referenzdaten zu

erhalten. Smits et al. (1999) kombinieren zum Zweck einer umfassenden, die Kosten berücksichtigenden Qualitätsanalyse gängige Fehlermaße mit Kostenanalysen und Aussagen zur Effektivität. Ausschlaggebend für die Qualität der Ergebnisse ist die Wahl eines angemessenen Verfahrens für die Bildanalyse. Zudem müssen Aussagen zu dessen Eignung und der Maßstabsebene getroffen werden, die noch sinnvoll ausgewertet werden kann.

Für die Fehleranalyse werden lagespezifische Verfahren eingesetzt, die neben der statistischen Aussage über den Anteil richtig klassifizierter Bildpunkte auch Aussagen über die gegenseitigen Abhängigkeiten zwischen den Klassen ermöglichen (de Lange 2002, S.410).

Fehleranalyse

Historisch gesehen kann die Entwicklung der Genauigkeits- oder Fehleranalyse (*accuracy assessment*) in vier Abschnitte eingeteilt werden (Foody 2002):

1. Visuelle Kontrolle → hochgradig subjektiv
2. Quantifizierung anhand der räumlichen Ausdehnung von Klassen im Vergleich mit der Referenz → oft richtige Größen aber falsche Lokalisierung
3. Ableitung von einfachen Genauigkeitsmaßen wie der Gesamtgenauigkeit
4. Analyse auf Basis einer Fehlermatrix

Bei vielen Anwendern herrscht ein gewisser Mangel an Bewusstsein für die Wichtigkeit der Genauigkeitsanalyse, was zu schwerwiegenden Fehlern bei der Arbeit mit Fernerkundungsdaten führen kann. Kurzfristige Fehler machen sich für den Benutzer in der ineffektiven Nutzung der wertvollen Satellitendaten bemerkbar, beispielsweise aufgrund mangelhafter oder nicht angepasster Algorithmen. Langfristige Auswirkungen betreffen eher die Hersteller von Bildanalyse-Systemen, da zum Teil Klassifikationsalgorithmen verwendet werden, die nicht für die geplanten Anwendung oder die vorhandenen Daten geeignet sind, was vermeidbare Fehler zur Folge hat (Smits et al. 1999).

Fehler entstehen in Klassifikationen aus den unterschiedlichsten Gründen, z. B. aufgrund von Mischpixeln (Überlappung von Klassen), unscharfen Übergangsbereichen, dynamischen Zonen, klasseninterner Variabilität (Kovarianz), einem Mangel an Trainingsdaten, topographischen Abschattungseffekten etc.

Es lassen sich **thematische** und **nicht-thematische Fehler** unterscheiden. Thematische Genauigkeit bezeichnet die Übereinstimmung zwischen der Klassifikation und der Referenz. Nicht-thematische Fehler stammen üblicherweise aus einer Missinterpretation der Genauigkeit, typischerweise einer Unterbewertung. Sie deuten oft auf eine mangelnde geometrische Registrierung der Fernerkundungsdaten mit den Referenzdaten hin (Foody 2002). Die räumliche Verteilung der Fehler ist oft nicht zufällig, sondern folgt einem bestimmten Muster. Viele Fehler treten gehäuft an Bildrändern oder -übergängen auf, sie sind stark mit einer ungenauen Geokodierung verbunden.

Bei den gängigen Verfahren der Fehleranalyse wird die Klassifikation mit Referenzdaten verglichen. Für die Referenzdaten wird angenommen, dass deren Quellen korrekt sind. Das können eigene Geländebegehungen oder auch bestehende Kartierungen bzw. ältere Klassifikationsergebnisse, z. B. visuelle Analysen sein. Die Annahme, dass Fotointerpretationen als Referenz zu 100% korrekt sind, ist allerdings selten richtig und kann zu scheinbar sehr schlechten Klassifikationsergebnissen führen (Congalton 1991).

Auch jede Karte ist nur ein vereinfachtes Modell der Wirklichkeit und enthält somit Fehler, ebenso enthalten thematische Karten Generalisierungen (Smits et al. 1999, Woodcock und Gopal 2000).

Vorgehensweise

Zur Genauigkeitsanalyse werden **Testgebiete**, die vorher nicht als Trainingsgebiete (siehe auch 2.2.2) genutzt wurden, mit den Klassifikationsergebnissen verglichen. Diese Testgebiete werden aufgrund einer i. d. R. zufälligen Stichprobe ausgewählt. Es gibt aber auch andere Verfahren der Auswahl von Testgebieten, z. B. das sog. *cluster sampling* (vgl. Congalton 1991, de Lange 2002, Rahman et al. 2003).

Der Vergleich erfolgt in so genannten **Konfusions-** oder **Fehlermatrizen** (*confusion matrix*), in welchen die Klassifikationsergebnisse der Referenz gegenübergestellt werden (siehe Tab.1). In diesen Matrizen bzw. Tabellen können die Daten aus mehreren Perspektiven betrachtet werden.

		Referenz				
		Klasse 1	Klasse 2	...	Klasse N	
Klassifikation	Klasse 1	a ₁₁	a ₁₂	...	a _{1N}	$\sum_{k=1}^N a_{1k}$
	Klasse 2	a ₂₁	a ₂₂	...	a _{2N}	$\sum_{k=1}^N a_{2k}$

	Klasse N	a _{N1}	a _{N2}	...	a _{NN}	$\sum_{k=1}^N a_{Nk}$
		$\sum_{k=1}^N a_{k1}$	$\sum_{k=1}^N a_{k2}$...	$\sum_{k=1}^N a_{kN}$	$n = \sum_{i,k=1}^N a_{ik}$
		$OA = \frac{\sum_{k=1}^N a_{kk}}{\sum_{i,k=1}^N a_{ik}}$	$PA(Klasse_i) = \frac{a_{ii}}{\sum_{i=1}^N a_{ki}}$		$UA(Klasse_i) = \frac{a_{ii}}{\sum_{i=1}^N a_{ik}}$	
		OA = overall accuracy	PA = producer's accuracy	UA = user's accuracy		

Tab. 1: Allgemeine Form einer Fehlermatrix, mit Standardfehlermaßen (nach Baatz et al. 2002)

Es handelt sich dabei um Tabellen mit Zahlenwerten, die in Reihen und Spalten angeordnet sind. Diese stellen die Anzahl der Trainingspixel, die richtig klassifiziert wurden, den realen Landbedeckungen aus der Referenz gegenüber (Smits et al. 1999). Werte in der Diagonalen zeigen korrekt klassifizierte Elemente. Werte, die um die Diagonale angeordnet sind, repräsentieren Fehlklassifikationen.

Smits et al. (1999) sehen in der Erstellung von Fehlermatrizen den schwächsten Punkt in der gesamten Fehleranalyse. Probleme ergeben sich aus der subjektiven Wahl des Klassifikationsschemas (Klassenbenennungen), der Trainingsgebiete sowie der Referenzdaten und der Strategie.

Analyse

Fehlermatrizen können mit relativ einfachen **deskriptiven statistischen Methoden** ausgewertet werden. Hierbei wird z. B. die **Gesamtgenauigkeit** (*overall accuracy*) über den Quotienten aus allen korrekt klassifizierten Pixeln (Summe der Hauptdiagonalen) und der Gesamtzahl aller Pixel berechnet. Die Fehler innerhalb einzelner Klassen können auf eine ähnliche Weise berechnet werden, wobei Genauigkeitsmaße für die Betrachtung aus unterschiedlichen „Blickwinkeln“ berechnet werden, zum einen aus Sicht des Nutzers und zum anderen aus Sicht des Herstellers.

Die so genannte **Benutzergenauigkeit** (*user's accuracy*) wird durch eine Division der richtig klassifizierten Pixel mit der Summe einer Reihe berechnet. Dieser Wert beschreibt den **Einschlussfehler** (*error of commission*), d. h. Pixel, die als Bestandteil einer Landbedeckung klassifiziert wurden, nach den Referenzdaten aber einer anderen Klasse angehören. Anders die **Herstellergenauigkeit** (*producer's accuracy*), welche durch die Division der richtig klassifizierten Pixel mit der Spaltensumme berechnet wird. Dieser Wert beinhaltet den **Ausschlussfehler** (*error of omission*), d. h. diejenigen Pixel, die innerhalb einer Landbedeckungsklasse von dem jeweiligen Verfahren nicht richtig klassifiziert wurden. Aus der Konfusionsmatrix können Inhomogenitäten in den Trainingsgebieten oder den Klassendefinitionen sowie Schwierigkeiten in der Klassenzuteilung erkannt werden (de Lange 2002, S.411).

Analytische Techniken können die Analyse der Fehlermatrix noch erweitern. Da Fernerkundungsdaten normalerweise diskrete Werte liefern, werden hier vor allem diskrete multivariate Techniken genutzt. Die FE-Daten sind meist binomial oder multinomial verteilt, so dass Verfahren, die eine Normalverteilung voraussetzen, nicht anwendbar sind.

Ein Schritt ist die **Normalisierung der Fehlermatrix** (Congalton 1991). Hierbei werden Unterschiede in den Trainingsgebietsgrößen eliminiert, wodurch die einzelnen Werte von unterschiedlichen Matrizen direkt vergleichbar werden. Ebenso lässt sich jetzt eine **normalisierte Gesamtgenauigkeit** berechnen, die ein etwas sichereres Fehlermaß als die einfache Gesamtgenauigkeit darstellt.

Neben der differenzierten Auswertung der Konfusionsmatrix kann die Klassifikationsgenauigkeit auch über einzelne Werte wie den Kontingenzkoeffizienten⁶ ausgedrückt werden. Dazu gehört eine andere multivariate diskrete Technik der KHAT Statistik, der sog. **Kappa-Koeffizient** (auch Kappa-index oder KIA - *Kappa index of accuracy*). Dieser berücksichtigt die oben erwähnten Auslassungs- und Einschlussfehler und fasst die Informationen der Fehlermatrix zusammen (vgl. Congalton 1991, de Lange 2002, Lillesand und Kiefer

⁶ Kontingenzkoeffizient = Modifikation des Phi-Koeffizienten für Variablen mit mehr als zwei Ausprägungen. Dieser bewertet die Stärke des Zusammenhangs von Variablen und basiert auf dem χ^2 -Test.

2000, Mather 1999). Der Kappa-Koeffizient kann Werte zwischen 0 und 1 annehmen, wobei 0 für fehlende und 1 für völlige Übereinstimmung zwischen dem Ergebnis der Klassifikation und der Referenz steht. Werte $\geq 0,75$ stehen für eine gute, Werte $< 0,4$ für eine schlechte Klassifikationsgenauigkeit.

Der Kappa-Wert ist sehr leistungsfähig, einerseits in der Auswertung einzelner Fehlermatrizen und andererseits im Vergleich verschiedener Matrizen (Congalton 1991). Insbesondere dann, wenn unterschiedliche Klassifikatoren am gleichen Datensatz getestet werden, kann der Kappa-Koeffizient zum Vergleich herangezogen werden (Mather 1999). Diese Werte müssen unter Berücksichtigung der statistischen Verteilung der Testdaten und zusätzlich vor dem Hintergrund des Klassifizierungsziels bewertet werden. Die klassische Fehleranalyse, z. B. der Kappa-Koeffizient, gewichtet alle Fehler gleich (Foody 2002). Die Bedeutung von Fehlern kann aber auch von der Wichtigkeit der Klasse abhängen, insbesondere dann, wenn diskrete Klassen versuchen, ein Kontinuum zu repräsentieren. Dem kann dadurch Rechnung getragen werden, dass z. B. ein gewichteter Kappa-Koeffizient berechnet wird, wobei allerdings die Auswahl der Gewichtung vermutlich eher subjektiv sein wird.

Ein weiteres Bewertungsproblem ergibt sich daraus, dass harte Klassifikatoren die unscharfen Übergänge der Natur nicht richtig darstellen können. Pixel werden genau einer Klasse zugeordnet, was voraussetzt, dass ein Bild aus thematisch „reinen“ Pixeln besteht (Foody 2002).

Keines der besprochenen Verfahren zur Genauigkeitsanalyse ist für jeden Fall geeignet. Das bedeutet auch, dass es keinen einzelnen Wert gibt, der die Genauigkeit von Klassifikationen vollständig beschreibt. Jedes Genauigkeitsmaß basiert auf einer anderen Betrachtungsweise der Information in der Fehlermatrix (Stehman 1997). Unterschiedliche Verfahren widersprechen sich deshalb oft und zeigen unterschiedliche Klassifikationsgenauigkeiten an (Stehman 1997).

Aufgrund der immer höheren räumlichen Auflösung wird ein Problem immer deutlicher: die Unvereinbarkeit zwischen Genauigkeit und Komplexität. Wenn die Komplexität eines Systems zunimmt, wird die Möglichkeit, präzise und signifikante Aussagen über dessen Verhalten zu treffen abnehmen (Zadeh 1973).

Dennoch sind Fehlermaße ein unerlässliches Teilergebnis jeder Bildanalyse. Sie geben in jedem Fall den qualitativen Gesamttrend an und stellen darüber hinaus den analytischen Schlüssel zur Diskussion der Ergebnisse dar.

2.7.2 Fehleranalyse im objektorientierten Umfeld

„Unfortunately, in their present form the error matrix and the derived accuracy measures are appropriate only for hard classification.“ (Binaghi et al. 1999, S.936)

Die bisher vorgestellten Methoden sind nur zum Teil geeignet, die Ergebnisse von so genannten weichen Klassifikationsverfahren wie z. B. der unscharfen Klassifikation (*fuzzy*

classification), in eCognition zu bewerten. Für die konventionelle Fehleranalyse müssen die Ergebnisse der weichen Klassifikationsverfahren wieder in scharfe Klassen übertragen werden (**defuzzification**) was mit einem Informationsverlust verbunden ist (Binaghi et al. 1999). Deshalb muss die Fehleranalyse den Eigenschaften dieser Klassifikationsverfahren angepasst werden. Mehrdeutige Objekte, die durch Überlappungen im Merkmalsraum entstehen, bedeuten nicht automatisch eine Fehlklassifikation: es gibt nur keine Klasse, der diese Objekte eindeutig zugewiesen werden können (Baatz et al. 2002).

Ältere Genauigkeitsmaße berechnen eine Korrelation zwischen den Anteilen der korrespondierenden Zugehörigkeit von Klassifikation und Referenz. Andere berechnen Distanzmaße. Da die Fehlermatrix ein umfassendes Werkzeug zur Genauigkeitsanalyse eines Klassifikationsergebnisses ist, basieren auch Ansätze des *fuzzy accuracy assessment* darauf. Die Matrix wird dabei nach Binaghi et al. (1999) dahingehend verändert, dass der Grad der Zugehörigkeit zu einer Klasse mit der Referenz verglichen wird. Als Ergebnis wird dann der Grad an Übereinstimmung ausgegeben. Auch einfache Maße der deskriptiven Statistik wie die Gesamtgenauigkeit sind hier berechenbar.

Baatz et al. (2002) nutzen zur Quantifizierung des Fehlers direkt den Grad der Zugehörigkeit von Objekten zu einer Klasse. Je mehr Objekte einen hohen Zugehörigkeitsgrad aufweisen, desto eindeutiger bzw. sicherer ist das Objekt klassifiziert. Zusätzlich werden weitere Parameter pro Objektklasse berechnet, so der minimale und maximale Grad der Zugehörigkeit, der Mittelwert sowie die Standardabweichung. Ein direkter Vergleich der besten mit der zweitbesten Zugehörigkeit gibt an wie gut Objektklassen getrennt werden können. Je größer die Differenz, desto sicherer ist eine Klassenzuweisung möglich. Zusätzlich werden in eCognition, jeweils auf der Basis der „besten“ Klassifikation eines Objektes, auch die klassischen Fehlermaße wie die oben besprochenen, berechnet. Neben der Gesamtgenauigkeit, der Produzenten- und Benutzergenauigkeit stehen ebenfalls „*Hellden's*“ und „*Short's*“ Genauigkeitsmaße zur Verfügung. Letztere gewähren einerseits den optimistischsten (*Hellden*) und andererseits den pessimistischsten (*Short*) Blick auf die Qualität eines Klassifikationsergebnisses (Baatz et al. 2002).

3 Feuchtgebiete und thematisches Umfeld

“The nation behaves well if it treats the natural resources as assets which it must turn over to the next generation increased, and not impaired, in value.” (Theodore Roosevelt (1907))

Die Feuchtgebiete dieser Erde haben vielfältige Bedeutungen für die Erhaltung von Arten und für die Regulierung der Wasserversorgung. In Zeiten des Rückgangs der globalen Trinkwasserressourcen ist es besonders notwendig, Feuchtgebiete zu erhalten. Angesichts ihrer weltweiten Zerstörung ist es geboten, sie unter besonderen Schutz zu stellen und moderne Überwachungsmechanismen zur Sicherstellung der Schutzmaßnahmen zu entwickeln.

In Deutschland stehen zurzeit ca. 2 % der Feuchtgebiete unter dem Schutz von internationalen Maßnahmen, die im Zuge des inzwischen von über 100 Staaten unterzeichneten Abkommens von Ramsar 1971 auf diese Gebiete angewendet wurden. Zu den aktuell geschützten Gebieten (Bundesamt für Naturschutz (BfN) 2001) gehören u. a. die Küstengebiete der Nordsee, Teile des Bodensees, der Ammersee und der Starnberger See.

Die Kartierung und Beobachtung von Feuchtgebieten mit Satellitendaten bietet Vorteile im Vergleich zu Methoden, die mit Luftbildern oder der Feldbegehung arbeiten, weil sie schneller einen größeren Überblick schaffen und in Bereiche vordringen, die für Kartierer im Gelände unzugänglich sind. Ozesmi und Bauer (2002) weisen darauf hin, dass Sensoren von Satelliten und flugzeuggetragenen Systemen sehr unterschiedliche Daten liefern, diese sich aber hervorragend ergänzen. Aufgrund ihres regelmäßigen Überflugs eignen sich Satelliten für die saisonale oder jährliche Überwachung. Ihr großer Aufnahmebereich ermöglicht die Erfassung der umgebenden Landschaft von Feuchtgebieten und Gewässern. Sie ermöglichen so eine umfassendere Betrachtung. Dem stehen die sehr hohe räumliche Auflösung und die zeitnahe Verfügbarkeit von flugzeuggetragenen Sensoren gegenüber, da Befliegungen bei günstigen Wetterbedingungen jederzeit auf Anforderung durchgeführt werden können.

3.1 Bedeutung von Feuchtgebieten

Die regelmäßig überfluteten oder wassergesättigten Feuchtgebiete wurden lange nur als Ödländer (Campbell und Markl 1997) angesehen, bis ihre besondere Bedeutung und ihre Vielzahl an Funktionen im System der Natur erkannt wurden. Dazu gehören die Filterung von Wasser, die Funktion als Lebensraum für an Wasser und Feuchtgebiete gebundene Tierarten und nicht zuletzt die Regulierung des Wasserhaushaltes.

Feuchtgebiete immobilisieren Schwermetalle, regulieren den Wasserabfluss sowie den Transport von Nährstoffen (vgl. Reichholf 1988, United States Environmental Protection Agency (EPA) 2002). Große Bedeutung kommt den Feuchtgebieten als Retentionsflächen bei der Flutprävention zu. Die häufigen punktuellen wie auch flächigen Oberflächenabflüsse werden von Feuchtgebieten gefiltert weiter gegeben.

Neben diesen Funktionen und haben sie auch eine Bedeutung für die Erholung. Aufgrund ihrer natürlichen Eigenart und ihres ästhetischen Reizes haben Feuchtgebiete schon immer eine Anziehungskraft auf den Menschen ausgeübt.

3.1.1 Ökologische Bedeutung

Hydrologie, Boden und die vorkommende Vegetation stellen die Hauptkomponenten von Feuchtgebieten dar. Die Kombination und das Zusammenwirken dieser Bestandteile führen zu den besonderen Eigenschaften von Feuchtgebieten:

Hervorzuheben ist insbesondere die **Wasserspeicherkapazität**, welche maßgeblich den Regulierungseffekt von Feuchtgebieten z. B. bei Flutereignissen bestimmt.

Wesentlich hierfür ist die Größe der Feuchtgebiete sowie die Ausdehnung der zugehörigen Wasserfläche, deren Wasserabfluss und die Veränderungen des Wasserspiegels. Auch kleine Feuchtgebiete, die selbst keine bedeutende Speicherkapazität aufweisen, können wichtige Beiträge zur ökologischen Leistungsfähigkeit eines Raumes im Kontext miteinander vernetzter Feuchtgebiete leisten (United States Environmental Protection Agency (EPA) 2002).

Ein Feuchtgebiet funktioniert – vereinfacht ausgedrückt - wie ein großer natürlicher Schwamm, welcher Wasser speichert und kontrolliert an die Umgebung abgibt. Das hat nicht nur Einfluss auf die Stärke von Flutereignissen, sondern reduziert durch die Verringerung der Fließgeschwindigkeit auch die Erosion. Die Bodenerosion wird auch in Trockengebieten gebremst, da der Boden nicht vollständig austrocknet und daher nicht vom Wind abgetragen wird. Grundwasserspeicher werden aufgefüllt, was einen direkten Einfluss auf den Basisabfluss in angrenzenden Oberflächengewässern hat. Die Speicherwirkung beeinflusst das Klima der Umgebung in der Form, dass z. B. Spätfrostschäden aufgrund der frostmildernden Wirkung des Gewässers und der wassergesättigten Feuchtbereiche verringert werden (Reichholf 1988).

Eine weitere wesentliche Funktion ist die **Wasserfiltration**. Nachdem die Fließgeschwindigkeit des Wassers durch die Feuchtgebiete gebremst wurde, kann dieses versickern, suspendiertes Material kann sedimentieren, Nähr- oder auch Schadstoffe können von der Vegetation und Mikroorganismen aufgenommen oder von Bodenpartikeln immobilisiert werden. Aufgrund des häufig hohen pH-Wertes von Niedermoor- und Sumpfbereichen können Schwermetalle an Bodenpartikel gebunden werden. Ein großer Teil der Verschmutzung im Wasser wird so natürlicherweise von Feuchtgebieten festgelegt und damit dem Kreislauf entzogen.

Bei der Vegetation spielt für die Beurteilung des Zustandes eines Feuchtgebietes im Wesentlichen Vegetationsstruktur, Wachstumspotential, Artenvielfalt, Artenvorkommen und Artenzusammensetzung eine Rolle. Die **biologische Produktivität** in Feuchtgebieten zählt zu der höchsten der Erde, vergleichbar mit tropischen Regenwäldern (United States Environmental Protection Agency (EPA) 2002). Aufgrund der Vielfalt und Struktur bieten

Feuchtgebiete, speziell die Schilfgürtel, vielen Arten wildlebender Tiere, vor allem Vögeln und Fischen, **Brut- und Lebensräume**.

Insbesondere an oberbayerischen Seen ist in den letzten Jahrzehnten ein geradezu dramatischer Schilfrückgang abgelaufen. Ein deutlicher Rückgang der Schilfbestände am Westufer des Starnberger Sees und im Bereich der Roseninsel wurde erstmals in den Jahren 1974 und 1975 beschrieben (Goslich 1975). Danach haben Untersuchungen von Melzer und Hermann (1980) und von Henschel et al. (1992) den Umfang des Schilfrückgangs im Litoral des Starnberger Sees nachgewiesen. Am nordwestlichen Ufer zwischen Starnberg und Possenhofen ist der Schilfgürtel vollständig verschwunden.

3.1.2 Ökonomische Betrachtung

Noch im letzten Jahrhundert war die **Urbarmachung** von Feuchtgebieten ein vordringliches Ziel der Binnenkolonisation. Neben der Nutzung nach der Trockenlegung als Weide- oder Ackerflächen wurden auf diese Weise auch die für den Menschen gefährlichen Brutstätten von Krankheitserregern beseitigt – noch im 19. Jahrhundert gab es Malaria in fränkischen Weihergebieten (Reichholf 1988, S.180). Auch die Abtorfung zur Gewinnung von Brennmaterial führte zu einem starken Nutzungsdruck auf Feuchtgebiete und zu deren Rückgang.

Diesen direkten Nutzen der Feuchtgebiete stehen gesamtgesellschaftliche Nutzen entgegen, die allerdings nur schwer in Geldwerten auszudrücken sind. Sie ergeben sich u. a. aus der Summe der positiven Einflüsse auf die Verlangsamung von Erosion, die Dämpfung von Überflutungsereignissen und Eignung intakter Feuchtlebensräume für die Erholung.

Vornehmlich die Hochwasserkatastrophen der letzten Jahre haben die Bedeutung der Feuchtgebiete als Teil der Retentionsräume ins Bewusstsein der Bevölkerung gerückt. Leschine et al. (1997) stellten in einer Untersuchung die Kosten für Erhaltungs- oder Renaturierungsmaßnahmen den finanziellen Auswirkungen der Veränderung von Feuchtgebieten gegenüber. Sie kommen zu dem Schluss, dass nicht notwendigerweise die Erhaltung der Feuchtgebiete hinter der weiteren Entwicklung dieser zurückstehen muss. Dadurch sind auch Hinweise auf die Schattenkosten gegeben worden, auf die sich die Allgemeinheit einstellen muss, wenn die Retentionsfähigkeit dieser Lebensräume weiter verringert wird.

3.2 Schutz von Feuchtgebieten

Aufgrund ihrer Bedeutung für die Umwelt und für den Menschen sind in den letzten Jahren auf internationaler und nationaler Ebene eine Reihe von Maßnahmen zum Schutz von Gewässern und Auen zahlreich verabschiedet worden.

An erster Stelle der Maßnahmen zum internationalen Schutz von Feuchtgebieten ist die so genannte **Ramsar-Konvention** zu nennen. Diese wurde am 2. Februar 1971 im Ort Ramsar im Iran von 18 Nationen unterzeichnet. Inzwischen sind dieser Konvention ca. 120 Nationen beigetreten. Zunächst nur zum Schutz der Feuchtgebiete als Lebensraum für Wat- und Wasservögel konzipiert, steht heute die Entwicklung von Feuchtgebieten als Ökosystem im Vordergrund (BfN News 01.02.2001). Der dauerhafte Schutz dieser Bereiche soll durch naturverträgliche und nachhaltige Nutzung sichergestellt werden. Da die Ramsar-Konvention

keine verbindlichen Vorschriften enthält, werden in Deutschland Feuchtgebiete mit internationaler Bedeutung über nationales Naturschutzrecht über die Einstufung als Naturschutzgebiet oder als Nationalpark sowie über vertragliche Vereinbarungen (Vertragsnaturschutz) geschützt.

Die **Flora-Fauna-Habitat-Richtlinie (FFH-Richtlinie)** soll nach ihrem Inkrafttreten am 21. Mai 1992 ein kohärentes Schutzsystem für die biologische Vielfalt in der EU zur Verfügung stellen. Im Vordergrund steht die Erkenntnis, dass der Schutz einzelner Habitats nicht ausreicht, sondern erst durch Berücksichtigung eines Biotopverbundes den Ansprüchen unterschiedlicher Arten gerecht werden kann. Seit April 1998 ist die FFH-Richtlinie (92/43/EWG) zusammen mit der Vogelschutzrichtlinie (79/409/EWG) von 1979 unter der Bezeichnung **Natura 2000** in nationales Recht umgesetzt und somit rechtsverbindlich geworden.

Definiert sind in den Anhängen I, II und IV 112 Tier- und Pflanzenarten sowie 87 Lebensraumtypen unter die auch die ufernahen Gebiete und die gewässernahen Feuchtgebiete fallen. In den Artikeln der FFH-Richtlinie wird ein Gebietsmanagement gefordert (Art. 6). Die Staaten sind angehalten, ein Überwachungssystem zu entwickeln (Art. 11) und regelmäßige Zustandsberichte (Monitoring) zu verfassen (Art. 17).

Als weiteres Instrument europäischer Gewässerpolitik ist in den letzten Jahren die **EG-Wasserrahmenrichtlinie** (im Folgenden EG-WRRL) entwickelt worden. Dieses am 22. Dezember 2000 verabschiedete Regelwerk hat zum Ziel, die in den einzelnen Mitgliedsstaaten sehr unterschiedlichen Regelungen zum Schutz der Gewässer zu vereinheitlichen und bestehende Schutzmaßnahmen zu verbessern. Als Ziel wird in Artikel 1 der Schutz der „aquatischen Ökosysteme und der von ihnen abhängenden Landökosysteme und Feuchtgebiete“ festgeschrieben. Als Leitbild gilt der so genannte „sehr gute ökologische Zustand“ vom Menschen unbeeinflusster Gewässer (Korn 2001). Instrumente sind Managementpläne wie der z. B. Gewässerentwicklungsplan.

Gewässerentwicklungsplanung

Neben den internationalen (insbesondere europäischen) Richtlinien beinhalten aber auch das deutsche Wasser- und Naturschutzrecht sowie die Agenda 21 die Forderung nach Gewässerentwicklungsplänen (Bayerisches Landesamt für Wasserwirtschaft (BLfW) 2001). Ziel dieser Gewässerentwicklungs- bzw. Gewässerpflegeplanung (als regionales Planungsinstrument) ist die Lenkung von Ausbau- und Unterhaltungsmaßnahmen, um mit einem Minimum an steuernden Eingriffen die natürliche Funktionsfähigkeit von Gewässerökosystemen zu erhalten (Deutscher Verband für Wasserwirtschaft und Kulturbau e.V. (DVWK) 1999).

Dafür sind Arbeitsschritte definiert, die u. a. eine Gebietsübersicht erfordern, aus welcher ein Leitbild formuliert wird. Eine Bestandsaufnahme von Morphologie, Wasserqualität und Lebensgemeinschaften ist die Grundlage für eine Bewertung des Istzustandes.

3.3 Fernerkundung von Feuchtgebieten

Die oben dargestellten Verpflichtungen zur Beobachtung und Entwicklung von Gewässern und Feuchtgebieten erfordern aktuelle und großräumig verfügbare Daten. Damit wird die Fernerkundung zu einem wichtigen Werkzeug der Inventarisierung und Überwachung. Im Rahmen der vorliegenden Arbeit soll gezeigt werden, wie mit den neuen Methoden sehr große Gebiete (vgl. 4.1) überwacht und klassifiziert werden können. Weil sich Daten flugzeuggetragener Fernerkundungssensoren und die Informationen von Erdbeobachtungssatelliten gut ergänzen, werden zusätzlich die Ergebnisse aus automatischen Luftbildklassifikationen und der Analyse hyperspektraler CASI-Daten integriert.

Im Folgenden werden hierzu bestehende Verfahren aus der Literatur vor- und der neuen Klassifikationsmethode gegenüber gestellt.

3.3.1 Grundlagen

Das Spektrum der elektromagnetischen Strahlung, die auf die Erde auftrifft, ist im Bereich zwischen 400 und 2.500 nm am energiereichsten. Durch atmosphärische Fenster begünstigt, trifft hier die wesentliche Strahlung auf die Erde. In diesen Wellenlängenbereichen spielt sich die überwiegende Reflexion von Vegetation ab. Abhängig vom Wasser- oder Chlorophyllgehalt der Blattorgane zeigen sich charakteristische Reflexionskurven für unterschiedliche Vegetationsbedeckungen (vgl. auch Hildebrandt 1996, Lillesand und Kiefer 2000, Richards und Jia 1999). Veränderungen der Vegetation sowie Folgen von Stress oder Verschmutzung zeigen sich ebenfalls in diesem Wellenlängenbereich und können mit Fernerkundungssensoren erkannt und aufgezeichnet werden (Goldberg 1998). Nach Untersuchungen von Murtha (1982) reagieren Pflanzen nach einem physischen Schaden zunächst mit der so genannten Bleichsucht/Vergilbung (Chlorose). Veränderungen in Pflanzen lassen sich im Infrarotbereich schneller als im Bereich des sichtbaren Lichts erkennen. Mit Hilfe von Spektroradiometern konnte gezeigt werden, dass Stress oft einen Anstieg der Reflexion im grünen und roten Bereich des Lichts auslöst. Eine Dehydrierung der Vegetation lässt sich im gelben Spektrum nachweisen. Generell zeigt die Vegetation in Feuchtgebieten ein ähnliches Verhalten, nämlich den Anstieg der Reflexion im sichtbaren Bereich des Lichts, da nach der Ausbleichung weniger Chlorophyll für die Reflexion zur Verfügung steht. Gleichzeitig führt die Zerstörung von Zellen zu einem Rückgang der Reflexion im Infraroten Wellenlängenbereich (vgl. Goldberg et al. 1999).

Gegenüber analogen Luftbildern bieten Satellitendaten den Vorteil, dass die spektrale Information in getrennten Kanälen aufgenommen wird und nicht kombiniert in einem Farbbild aggregiert ist. Zudem hängt die korrekte Darstellung im Luftbild stark vom verwendeten Filmmaterial ab.

Eines der größten Probleme bei der Klassifikation von Feuchtgebieten ist die Trennbarkeit von Klassen. Spezifische Arten in Feuchtgebieten überlagern sich im u. U. Merkmalsraum, so ist die Reflexion von *Phragmites australis* und *Juncus sp.* (Binse) sehr ähnlich. Probleme ergeben sich aber auch bei der Abgrenzung der gesamten Feuchtgebietsvegetation von Landvegetationsklassen. Insbesondere Forstbereiche und hier oft die beschatteten Gebiete

sowie diverse Formen von Wiesen und Weiden überschneiden sich im Merkmalsraum mit den Feuchtgebieten (Abb. 15).




Abb. 15: Links: Überschneidung der spektralen Signaturen von Feuchtgebietsvegetation untereinander. Rechts: Überschneidung von Feuchtgebieten mit Landvegetation. Dabei wird jeweils das nahe Infrarot dem Rotkanal gegenübergestellt (aus Ozesmi und Bauer 2002)

Daher ist es schwer, Feuchtgebiete auf trockeneren Standorten aus Satellitendaten zu erkennen. Gewässernahe Feuchtgebiete lassen sich dagegen aufgrund ihrer Nachbarschaft zu offenen Wasserflächen leichter identifizieren. Insbesondere die objektorientierten Methoden versprechen hier Hilfe. In Forstbereichen gibt es ebenfalls Überschneidungen. Stuckens et al. (2000) beschreiben dieses Problem. Sie vermuten die Ursache der Trennungsschwierigkeiten darin, dass Wälder im betrachteten Untersuchungsgebiet oft auf feuchten Standorten stehen. Dennoch konnten sie mit Hilfe der ECHO-Technik (vgl. Abschnitt 2.3) eine ausreichend genaue Trennung der Vegetationskomplexe erreichen. Auch andere Untersuchungen zeigen, dass sich Nadelbaumstandorte nur schwer von Sümpfen im Übergangsbereich von Wasser und Vegetation unterscheiden lassen, die eine sehr ähnliche Reflexion aufweisen (Ernst und Hofer 1979 zit. in Ozesmi und Bauer 2002).

Die wesentlichen Vor- und Nachteile der Satellitenfernerkundung im Rahmen der Feuchtgebietsbeobachtung haben Ozesmi und Bauer (2002) wie folgt dargestellt:

Vorteile:

- kontinuierliches Monitoring aufgrund regelmäßigen Überflugs zu gleicher Tageszeit
- sehr große Gebiete werden „gleichzeitig“ flächendeckend erfasst
- in Kombination mit Luftbildern wird der Informationsgewinn erhöht
- Änderungen in der Natur werden relativ schnelle erkannt

Nachteile:

- Wasserstandsschwankungen verändern das spektrale Signal von Feuchtgebieten
- Verbrannte Flächen überschneiden sich spektral mit Wasser

- Periphyton⁷ kann im Spätsommer zu spektralen Konfusionen führen
- z. B. *Typha* (Rohrkolben) weist große Variationen in der Bestandsgröße auf, was die Erkennung erschwert

Klassen wie agrarisch geprägte Flächen, Feuchtgebiete und Wasserklassen sollten sich allerdings mit jedem Fernerkundungssensor mehr oder weniger exakt unterscheiden lassen. Es gilt, dass sich Wasser im Prinzip am leichtesten erkennen lässt, gefolgt von den feuchten, sumpfigen Bereichen. Bei Laubwald im Feuchtgebiet und bei immergrünen Feuchtwäldern wird die Erkennung schwieriger.

Der **Aufnahmezeitpunkt** spielt eine besondere Rolle. So lassen sich am Anfang der Vegetationsperiode die noch braunen **Schilfbestände** leichter von der bereits grünen Umgebung abgrenzen, allerdings haben sie dann ihre volle Ausbreitung noch nicht erreicht. Diese liegt am Ende der Vegetationsperiode, dann entstehen allerdings wieder stärkere spektrale Überschneidungen z. B. mit Grünland. **Schwimblattgesellschaften** lassen sich nur in der Vegetationsperiode von Juni bis August erkennen; im April oder Mai sind sie noch nicht vorhanden. Ebenso hängt die „Erkennbarkeit“ von Wasser vom Aufnahmezeitpunkt ab. Wasser ist im Prinzip die einfachste der zu bestimmenden Klassen, insbesondere wenn Informationen aus dem Infrarotbereich zur Verfügung stehen. Allerdings sollen bei sehr hoch auflösenden FE-Daten auch kleine Kanäle und kleinere Wasserflächen erkannt werden. Diese sind aber oft sehr flach, der Grund ist von Makrophyten bedeckt oder es kommt Schwimmblattvegetation (z. B. Teichrose) vor, die das Signal so beeinflusst, dass die Reflexion ansteigt und auch im Wasser die spektralen Überschneidungen zunehmen. Da die Wahl des Aufnahmezeitpunktes so wichtig für die Erkennung von Objekten ist, sollte dieser immer von Experten aus unterschiedlichen Fachgebieten festgelegt werden (Klemas 2001). Außerdem kann es hilfreich sein, Aufnahmen von verschiedenen Zeitpunkten innerhalb einer Vegetationsperiode (Beginn und Ende) kombiniert zu analysieren (vgl. Lunetta und Balogh 1999).

3.3.2 Angewendete Verfahren

Die in der Vergangenheit überwiegend eingesetzten Methoden zur Erkennung und Überwachung von Feuchtgebieten basierten in erster Linie auf der visuellen Interpretation von Luftbildern (CIR oder Farbe) sowie auf Satellitendaten im mittel auflösenden Bereich. Multispektrale Sensoren wie Landsat TM oder der auf dem indischen IRS-1A oder 1B fliegenden LISS II oder auch SPOT XS liefern Auflösungen bis 20 m. Feuchtgebiete können so nur in einem großen Zusammenhang erkannt werden, da die kleinste kartierbare Einheit zwischen 0,09 ha und 0,04 ha liegt. Neuere hochauflösende Satelliten haben bislang kaum Eingang in die Feuchtgebietsfernerkundung gefunden. Moderne Klassifikationsmethoden werden, vor allem aufgrund der schwierigen spektralen Unterscheidbarkeit (siehe oben), hingegen häufiger angewendet. In der Literatur finden sich zahlreiche Beispiele für kombinierte, regelbasierte Fernerkundungs- und GIS-Ansätze.

⁷ Periphyton = Pflanzlicher Aufwuchs auf Steinen, Pflanzen u. a. Substraten. Überwiegend Algen, auch Bakterien und Pilze.

Satellitendaten

Lunetta und Balogh (1999) beispielsweise klassifizieren ausgedehnte Feuchtgebiete in Maryland und Delaware anhand von Landsat TM5 Daten. Zum Einsatz kommt dabei ein regelbasierter Ansatz. Dieser unterscheidet in vorklassifizierten Bildern zunächst in einem GIS in hydrische und nicht-hydrische Bereiche, um diese Information dann mit einer statistischen Landbedeckungsklassifikation zu kombinieren. Die Ergebnisse verbessern sich durch dieses Verfahren. Die Autoren erwarten eine weitere Verbesserung durch die Kombination multisaisonaler Aufnahmen.

Houhoulis und Michener (2000) erkennen Veränderungen in Feuchtgebieten mit multispektralen SPOT XS Daten und kombinieren diese mit externen Kartierungen des amerikanischen *National Wetland Inventory* (NWI). Durch diese Vorabgrenzung vermeiden sie ebenfalls die spektrale Konfusion zwischen Feuchtgebieten, landwirtschaftlicher Nutzung und Wäldern. Dieser regelbasierte Ansatz wird einerseits für die Veränderungsanalyse (change detection) genutzt, andererseits für Aktualisierung der NWI-Karten.

Multispektrale Daten des SPOT Satelliten werden von Jensen et al. (1993) zur Veränderungsanalyse von Rohrkolben- und Teichrosenbeständen am Savannah River in South Carolina eingesetzt. Sie nutzen multisaisonale Daten für die Erkennung, vor allem der Schwimmblattvegetation, und kombinieren diese mit panchromatischen SPOT Daten.

Sader et al. (1995) weisen für Feuchtwälder nach, dass ein regelbasierter GIS-Ansatz die Klassifikationsqualität gegenüber rein statistischen Verfahren signifikant steigert.

Ebenfalls den Sensor LISSII auf dem etwas neueren IRS 1B Satelliten setzen Kindscher et al. (1998) für die Analyse von Feuchtgebieten im Grand Teton Nationalpark in Wyoming ein. Sie arbeiten auf der Basis unüberwachter statistischer Verfahren. Shaikh et al. (2001) können in Australien mit Hilfe der hohen spektralen Auflösung multitemporaler Landsat-Daten eine Beziehung zwischen dem Wasserspiegel im Fluss und Feuchtgebietsüberschwemmungen herstellen.

Luftbilder

Marshall und Lee (1994) setzen zur Kartierung von aquatischen Makrophyten Luftbilder ein. Sie verwenden Daten von Juli bis August und Farbluftbilder anstelle der für Vegetation eigentlich besser geeigneten CIR-Luftbilder, da letztere eine geringere Eindringtiefe ins Wasser haben.

Williams und Lyon (1997) zeigen das Potential multitemporaler, historischer Luftbilder auf. Sie analysieren die Reaktion von Feuchtgebieten an den Great Lakes auf Wasserspiegelschwankungen. Mit Hilfe der visuellen Auswertung einer Luftbildzeitreihe von 1936 bis 1985 können sie nachweisen, dass es zum Teil bis zu fünf Jahre benötigt, bis sich Feuchtgebiete von einem Hochwasser erholen. Demgegenüber reagieren verbuschte Feuchtgebiete sehr viel schneller auf die Schwankungen und Feuchtwälder dehnen sich bei Hochwasser sogar aus.

Moderne Sensoren

Sehr hoch auflösende Satellitendaten haben bislang kaum Eingang in die Erkundung von Feuchtgebietsstandorten gefunden. Im Bereich der Analyse von Überflutungsschäden gibt es eine Untersuchung, die IKONOS Daten mit Hilfe des objektorientierten Ansatzes von eCognition auswertet (van der Sande 2001). Mit eCognition wird die Landnutzung in den Satellitendaten klassifiziert, welche dann in einem Modell zusammen mit Tiefendaten für die Schadensermittlung genutzt werden.

Die Bedeutung von Radarsatellitendaten für ökologische Studien wächst ebenfalls. Moderne multifrequenz- und multipolarisierte Systeme können hierfür erfolgreich eingesetzt werden. Pope et al. (1994) nutzen AIRSAR Daten, um auf der Basis von biophysikalischen Indizes Feuchtgebiete, Wälder und Landwirtschaft in den Tropen Zentralamerikas zu klassifizieren.

In Deutschland gibt es Untersuchungen zur Wasserqualität an Seen der Mecklenburger Seenplatte mit Hyperspektraldaten und IRS 1C Satellitendaten (Thiemann und Kaufmann 2000, Thiemann und Kaufmann 2002). In diesen Untersuchungen werden Chlorophyll-a Gehalte der Seen, Secci-Tiefen und Trophieparameter der untersuchten Seen abgeleitet.

Zusammenfassung

Aus den aufgeführten Beispielen lassen sich folgende Erkenntnisse ableiten: Zum einen werden immer noch sehr oft mittel auflösende Daten verwendet, die sich zur Erkennung großflächiger Feuchtgebiete eignen (Landsat, SPOT, IRS). Zum anderen ist die räumliche Auflösung dieser Sensoren aber zu gering, um die Anforderungen der bestehenden Richtlinien auf lokaler Ebene umzusetzen. Bei Landsat Daten sind bei einer MMU von 0.09ha mindestens neun Pixel notwendig, um ein Objekt zu identifizieren (Ozesmi und Bauer 2002). Arbuckle et al. (1998) kommen in ihrer Untersuchung von Feuchtgebieten in Neuseeland mit SPOT-Daten zu dem Schluß, dass unbedingt hoch auflösende FE-Daten verwendet werden sollten. Diese müssen in Verbindung mit ausgedehnten Feldbegehungen ausgewertet werden.

An den obigen Beispielen erkennt man, dass unterschiedlichste Klassifikationsverfahren zum Einsatz kommen. Die visuelle Analyse spielt nach wie vor eine große Rolle. Unüberwachte Verfahren werden entweder als Vorverarbeitungsschritt oder mit einer sehr großen Anzahl von Klassen (>200) verwendet. Es zeigt sich aber, dass trotz der vergleichsweise hohen spektralen Auflösung der landsatähnlichen Sensoren oft kombinierte regelbasierte Ansätze genutzt und externe Daten eingebunden werden müssen, um die Klassifikation zu verbessern bzw. die Unterscheidung von Objekten zu ermöglichen. Kommen multitemporale FE-Daten zum Einsatz, bietet sich eine Hauptkomponententransformation an (PCA – principal components analysis). Die ersten drei Hauptkomponenten trennen Vegetationsunterschiede (HK1), Feuchteunterschiede (HK2) und unterscheiden Feuchtgebiete von Trockenstandorten (HK3).

Vegetationsindizes sind ebenfalls hilfreich bei der Unterscheidung von Landbedeckungen. Hier werden oft der NDVI⁸ aber auch Indizes auf Basis des fünften Landsatkanals verwendet. Das Potential der Auswertung von Luftbildern ist nicht ausgeschöpft. Allein die oben beschriebene Untersuchung zeigt, dass mit den Daten, die in Archiven bereits existieren, langjährige Analysen möglich sind (Williams und Lyon 1997). Mit einer automatisierbaren Auswertung in Verbindung mit anderen FE-Daten und modernen Verfahren ließe sich dieses Potential weiter und effektiver ausschöpfen.

⁸ NDVI = Normalized difference vegetation index. Vegetationsindex, der durch Normalisierung der Berechnung die Unterschiede in vegetationsfreien und vegetationsbestandenen Flächen betont. Je höher der NDVI, desto vitaler die Vegetation.

4 Untersuchungsgebiet und Datenmaterial

4.1 Untersuchungsgebiet

Die verwendeten Satellitenbildszenen umfassen die Uferbereiche des gesamten Starnberger Sees sowie die südlich anschließenden Osterseen. Das Untersuchungsgebiet umfasst in der Länge ca. 30 km, etwas nördlich von Starnberg beginnend und reicht bis ca. 1 km südlich der Ortschaft Iffeldorf. Die Breite beträgt ca. 9 km, so dass die gesamten Uferbereiche des Starnberger Sees enthalten sind. Innerhalb dieses ca. 265 km² großen Gebietes wurden sechs Haupttestgebiete festgelegt (Abb. 16).

Das Untersuchungsgebiet liegt ca. 40 km südlich von München im oberbayerischen Voralpengebiet. Das Gebiet zählt zu den wichtigsten Naherholungsgebieten des Münchner Raums. Teile des Starnberger Sees und der größte Teil der Osterseen sind als Naturschutzgebiet ausgewiesen.

Entstehung

Die morphologische Entwicklung des Starnberger Sees wurde lange Zeit kontrovers diskutiert. Die schlüssigste Theorie (Munthe 1910 zitiert in Rothpletz 1917) besagt, dass es sich beim Starnberger See um ein vorrisszeitliches Flusstal handelt. Dieses wurde durch Glazialerosion des Walchensee-Teilgletschers des Isar-Loisach-Gletschers während der Würm-Eiszeit zu einem Zungenbeckensee umgestaltet. Das ursprünglich überflutete Gebiet dehnte sich wesentlich weiter aus als heute. Reste wie das Leutstettener Moor im Norden und das Osterseengebiet im Süden zeugen von dieser ursprünglichen Größe.

Die Osterseen hingegen stellen eine Kette von 19 Toteisseen dar, die während der Rückzugsphase des Isar-Loisach-Gletschers entstanden sind. In diesem Gebiet brachen Teile des Gletschers ab und blieben als so genannte Toteisblöcke liegen. Um sie herum lagerten sich Schmelzwassersedimente ab. Nach Ende des Abschmelzprozesses blieben dann die charakteristischen Formen der Toteisseen oder –seebecken zurück. Sie besitzen sehr kleine Flachwasserzonen und fallen danach steil in die Tiefe ab.

Morphologie

Das gesamte Gebiet um den Starnberger See und die Osterseen ist stark glazial geprägt. In der Landschaft finden sich daher viele klassische Formen der Glazialmorphologie. Neben den Grund-, End- und Seitenmoränen, welche von den Gletschermassen aufgeschoben wurden, finden sich ebenso Eisrandterrassen, Toteislöcher, Oser, Kameszüge und Drumlinfelder.

Oser sind langgestreckte, gewundene Rücken, die auf Sedimentation in subglazialen Schmelzwasserrinnen zurückzuführen sind. Beispiel dafür sind Landbrücken zwischen Seen, ehemalige Untiefen und Iffeldorfer und Staltacher Os, ebenso die Marieninsel im Großen Ostersee (Meyer und Schmidt-Kaler 2002). Die hügelige Landschaft um die Osterseen wird zusätzlich von Kames geprägt. Diese Struktur entsteht durch Aufsedimentieren von grobklastischem Material zwischen Toteisblöcken, welches dann nach Abschmelzen dieser als rückenartige Form zurück bleibt. Drumlins wie sie am Westufer des Starnberger Sees

oder im Eberfinger Drumlinfeld zu finden sind, entstanden durch Überformung von Grundmoränen. Es handelt sich um sanft ansteigende, in Richtung der Eisbewegung (hier Nord-Süd-Richtung) ausgerichtete, stromlinienförmige Hügel mit steiler Luv- und flacher Leeseite (vgl. Press und Siever 1995).

Hydrologie

Der Starnberger See wurde gegen Ende der letzten Eiszeit von seinem Hauptzufluss, der Loisach, abgeschnitten. Dadurch besitzt er als einziger Voralpensee keine direkten Zuflüsse aus dem Gebirge. Sein wesentlichster oberirdischer Zufluss erfolgt über den Bodenbach aus den Osterseen, welche ebenfalls keinen bedeutenden Zufluss aus den Alpen besitzen. Aus diesem Grund erfahren der Starnberger See und die Osterseen nur einen geringen Sedimenteintrag. Das ist eine der wichtigsten Voraussetzungen für den Erhalt dieser Seen. Aufgrund des relativ kleinen Einzugsgebiets weist der Starnberger See nur geringe Wasserspiegelschwankungen auf. Die Kapazität seines Abflusses, der Würm, ist begrenzt, weshalb der See als Wasserspeicher fungiert.

Gespeist werden der Starnberger See und die Osterseen hauptsächlich durch Niederschläge, welche hier durchschnittlich 1100 mm/Jahr betragen und zusätzlich durch unterirdische Grundwasserquellen. Das Grundwasser in diesem Gebiet steht sehr hoch an und ist durch das Ausgangssubstrat, die Moränenschotter der Eiszeit, sehr stark kalkhaltig. Das gesamte Grundwasserregime wird durch die Morphologie des Gebietes beeinflusst, was sich in zahlreichen Quelltrichtern (Limnokrenen) sowie Grund- und Sickerwasseraustritten zeigt. Es weist eine hohe Dynamik auf, von Troll (1938) beschrieben als Toteiskarst und reagiert sehr schnell auf Niederschläge im Einzugsgebiet. Besonders die Osterseen sind zum Teil sehr stark grundwasserbeeinflusst. Das Wasser strömt den Seen mit einer gleich bleibenden Temperatur von ca. 9 °C zu, was einen direkten Einfluss auf den Temperaturhaushalt der Seen hat. Es handelt sich bei den grundwasserbeeinflussten Seen wie dem Waschsee, dem Schiffhüttensee, Sengsee, Herrensee, Stechsee, Gröbensee, Gartensee und Lustsee, um so genannte sommerkalte und winterwarme Seen, die immer ein gleichmäßiges Temperaturregime aufweisen und ständig Nährstoffe sowie Sauerstoff zugeführt bekommen.

Boden

Die Böden im Untersuchungsgebiet sind sehr heterogen und ändern sich kleinräumig sehr. Durch die glaziale Überformung werden verbreitet Jungmoränenmaterial, Schotter und Moorböden angetroffen.

Vorherrschende Bodentypen sind Parabraunerden, Pseudogleye evtl. mit Schluff, sowie Nieder- und Hochmoortorfe sowie Hang- und Quellgleye. Dominierend in der gesamten Gegend um den Starnberger See sind Parabraunerden. Diese werden mit dem hygrischen Typ als mäßig frisch bzw. in Regionen am Alpenrand mit ca. 1300 mm Niederschlag pro Jahr als frisch bezeichnet. Insgesamt sind die hier anzutreffenden Böden eher feucht bis nass (staunass bei Pseudogleyen). In Tiefenlagen kommen an feuchten Standorten Niedermoorböden vor, südlich von Seeshaupt existieren noch Hochmoorkomplexe, die sich u. a. aufgrund der hohen Niederschläge bilden konnten.

Naturräumliche Ausstattung

Es handelt sich bei dem ausgewählten Untersuchungsgebiet um einen Teil des Ammer-Loisach-Hügellandes im Naturraum voralpines Hügel- und Moorland (Thommes et al. 1996).

Auf kleinem Raum wechseln sich viele Landschaftselemente ab. So existieren in kurzen Abständen Siedlungen, Wälder, Moore, Seen und Kulturland. Letzteres wird überwiegend als Wiese oder Weide genutzt, Äcker kommen im gesamten Gebiet kaum vor.

Das Gebiet ist zu fast 50% mit Wald bestanden, mit dem größeren Anteil im Süden. Vorwiegend finden sich mit Fichten aufgeforstete Bereiche, vereinzelt kommt auch die potentiell natürliche Vegetation, z. B. Tannen-Buchen Wälder, Auenwälder sowie Bergkiefern auf den Moorböden der Gegend vor.

In den zahlreichen Feuchtgebieten existieren teilweise verbuschte Hochmoorbereiche, Kalkflachmoore (Niedermoore), große Verlandungszonen sowie große Anteile an Röhricht- und Seggenbeständen.

Große Teile des Gebietes stehen unter Naturschutz. Zu den ausgewiesenen Gebieten gehören das Leutstettener Moor, der Karpfenwinkel am Starnberger See, ein Teil des Ostufers des Starnberger Sees, das Bernrieder Filz und die Osterseen. Mit Ausnahme des Karpfenwinkels wurden die vorhandenen Naturschutzgebiete ebenfalls als FFH-Gebiete ausgewiesen. Darüber hinaus sind zusätzliche FFH-Gebiete gemeldet worden, dazu gehören das Westufer des Starnberger Sees (Seeseiten bis Bernried), der Röhrichtgürtel bei St. Heinrich sowie die Moorlandschaft zwischen Hohenkasten und Antdorf. Nahezu das gesamte Untersuchungsgebiet steht unter Landschaftsschutz.

Das Gebiet ist überwiegend vom Starnberger See und den kleineren Osterseen geprägt. Als bedeutenderes Fließgewässer tritt nur die Würm am Nordende des Starnberger Sees in Erscheinung.



Abb. 16:

Teiluntersuchungsgebiete

Teiluntersuchungsgebiete

In dem gesamten Gebiet wurden sechs kleinere Testgebiete mit unterschiedlicher Charakteristik ausgesucht. Mit diesen wurden die Regelwerke für die spätere Klassifikation entwickelt und die Übertragbarkeit getestet.

Die hauptsächlich genutzten Gebiete befinden sich im Süden des Untersuchungsgebietes (Nummer 4, 5 und 6). Darunter fallen die südlichen **Osterseen** (Nr. 6), mit der Iffelder-, der Staltacher- und der Osterseekette sowie die nördlichen Osterseen (Nr. 5) mit der Seeshaupter Seenkette. Hinzu kommt im Süden das Gebiet bei **St. Heinrich** (Nr. 4) mit größeren Schilfbeständen am Starnberger See. Mit diesen drei Gebieten werden auch große Teile des Weid- und des Schechenfilzes, einem der verbliebenen Hochmoorkomplexe in dieser Gegend, erfasst.

Diese Testgebiete zeichnen sich durch nahezu ungestörte Schilfbestände an den Seeufern und in den angrenzenden Bereichen aus.

Im Norden, westlich des Starnberger Sees, befindet sich ein weiteres Testgebiet (Nr. 3), der **Maisinger See**. Er weist aufgrund seiner Entstehung und Morphologie eine vergleichbare Charakteristik wie die südlichen Testgebiete auf. Der Maisinger See ist in ein 117 ha umfassendes Naturschutzgebiet eingebettet. Der See selbst liegt in einem Becken, welches von einem Moränengürtel nahezu vollständig umschlossen wird. Im Untergrund befinden sich Seetone, welche als Stauschicht dienen. Im Nordosten entwässert der See durch die Maisinger Schlucht. Es handelt sich um einen flachen (max. Tiefe 2m), inzwischen vermoorten Restsee, der heute nur noch künstlich für die Fischzucht aufgestaut wird. Der See ist daher stark eutroph. Der Maisinger See ist weiträumig von Schilf umgeben. Es schließt sich ein vermoortes Gebiet im Westen an.

Etwas nördlich, bei **Hadorf** liegt ein kleineres Testgebiet (Nr. 2). Dieses umfasst einen kleinen Privatforst, der durch Fichtenbestände, Laubbäume und Mischwaldzonen charakterisiert ist.

Östlich von **Starnberg**, am nördlichen Rand des Untersuchungsgebietes, befindet sich das letzte Testgebiet (Nr. 1). Es handelt sich um ein kleineres Feuchtgebiet mit vermoorten Bereichen und Röhrichtzonen. Es wird von der Würm durchflossen. Hier dominieren vor allem Großseggen, aber auch Röhrichtbestände, Flachmoore, Feucht- und Bruchwälder kommen vor.

4.2 Satellitendaten

Mitte der 90er Jahre hatten amerikanische Firmen erste hoch auflösende Satellitensensoren angekündigt. Zunächst mussten allerdings Verluste der Satelliten EarlyBird 1, IKONOS 1 und QuickBird 1 hingenommen werden. Im September 1999 gelang der Start und die Inbetriebnahme von IKONOS 2, dessen Daten seit Anfang 2000 operationell aufgezeichnet werden. Seit Mitte 2001 liefert Quickbird 2 noch höher aufgelöste Bilder (0.6 m im PAN-Kanal), mit ebenfalls 4 Spektralkanälen bis ins nahe Infrarot hinein.

4.2.1 Verwendete Szenen

Für das AQUATIC-Projekt wurden 2 Aufnahmen als sog. GEO-Produkt bestellt: Eine am Anfang (Beginn des Zeitfensters am 5. April 2001) und eine zum Ende der Vegetationsperiode (Beginn des Zeitfensters am 15. Juli 2001). Der Datenbezug erfolgte über die

GAF/EUROMAP GmbH. Im März 2003 wurden von Space Imaging die sog. RPC-Daten⁹ kostenfrei nachgereicht, so dass nun von einem ORTHOKIT-Produkt mit höherer Präzision gesprochen werden kann.

Nachfolgende Abbildung gibt einen Überblick über die Aufnahmesituationen im April und im August.




Abb. 17: Darstellung der Aufnahmesituation des IKONOS-Satelliten im April und August 2001

Die Situation im April erwies sich als etwas ungünstiger, da der Aufnahmewinkel mit 71° relativ flach war, d. h. die Bildobjekte „kippen“ stärker nach außen als in der Augustszene.

Der Sonnenstand war bei beiden Aufnahmen vergleichbar (Azimuth ca. 153°, Elevation ca. 54°), was aufgrund der sonnensynchronen Umlaufbahn des Satelliten und damit jeweils gleicher Überflugzeit um ca. 10:15 Morgens und etwa im gleichen zeitlichen Abstand zum Sonnenhöchststend im Juni, zu erwarten war. Aufgrund des Rückwärtsblicks des Sensors bei der August-Aufnahme (Flugrichtung Süd-Nord) erscheinen die Schatten länger, tatsächlich ist aber nur die Schatten werfende, dunkle Seite des jeweiligen Objekts zusätzlich zu sehen.

⁹ RPC – rational polynom coefficients = Rechnerisch aus den Flugdaten des Satelliten während des Überflugs abgeleitete Koeffizienten für die Polynomverzerrung bei der Geokodierung der Szenen

4.2.2 Eigenschaften von IKONOS Daten

IKONOS befindet sich auf einer polar umlaufenden Bahn um die Erde und führt mit einer leichten Neigung (98.1°) über die Pole. Dadurch kann ein Gebiet auf der Erde stets zur gleichen Ortszeit und damit auch unter vergleichbaren Beleuchtungssituationen überflogen werden. Der Satellit befindet sich in 681 km Höhe und benötigt 98 Minuten für einen Umlauf. Seine Sensoren sind schwenkbar, so dass es theoretisch möglich ist, alle 3 Tage Aufnahmen desselben Gebietes der Erde zu bekommen.

Der Satellit ist mit zwei Sensoren ausgestattet, einem **panchromatische Sensor** und einem **Multispektral-Sensor** mit 4 Bändern.

Datum des Starts	24.09.1999 Vandenberg Air Force Base, Ca
Laufbahn	98.1 Grad, sonnensynchron
Zahl der Erdumläufe	14.7 alle 24 Stunden
Höhe	681 km
Bodenauflösung	Nadir: 0.82 m PAN 3.2 m Multispektral 26° Off-Nadir 1.0 m PAN 4.0 m Multispektral
Spektralbereich	PAN 0.45-0.90 μm Blau 0.45-0.52 μm Grün 0.51-0.60 μm Rot 0.63-0.70 μm IR 0.76-0.85 μm
Schwadbreite	11.3 km im Nadir 13.8 km im 26° Off-Nadir
Zeitpunkt beim Äquator-Überflug	Nominell 10:30 solar time

Tab. 2: Der IKONOS-Satellit auf einen Blick (SPACE IMAGING 2002)

Die beiden Sensoren nehmen zeitversetzt auf. Kellenberger (2002) hat einen zeitlichen Versatz ca. 0.36 sec nachgewiesen (vgl. auch Abb. 18).



Abb. 18: Das Flugzeug in der IKONOS Szene zeigt den Zeitversatz zwischen PAN-Kanal (a) und den multispektralen Kanälen (b)

Das im Projekt verwendete GEO-Datenprodukt ist grob geometrisch korrigiert und, bezogen auf das WGS 84-Ellipsoid, in die UTM-Projektion entzerrt worden. Die Georeferenzierung

basiert auf der direkten Sensororientierung von IKONOS, die durch eine Kombination von GPS, Inertialsystem und Sternensensoren hergestellt wird (Gerlach 2002). Die Genauigkeit liegt bei 25 m, wenn das Geländereief nicht berücksichtigt wird. Bei steilem Aufnahmewinkel und bei Landschaften mit großen Höhenunterschieden kann jedoch davon ausgegangen werden, dass Punkte bis zu einigen hundert Meter falsch liegen (Dial und Grodecki 2001).

Mittlerweile ist auch ein GEO ORTHO KIT erhältlich, bei welchem den Bildern geometrische Informationen zur Aufnahmesituation beiliegen (IGM - *Image Geometry Model*). Diese Informationen beinhalten Koeffizienten für eine Polynomialtransformation, welche das Sensormodell hochgenau nachbilden (daher auch oft als RPC, *rational polynomial coefficients*, bezeichnet).

Dieses Modell beschreibt das Verhältnis zwischen dreidimensionalem Aufnahmegelände und zweidimensionalem Bild. Solche Informationen sind notwendig, um die Bilder hochgenau zu orthorektifizieren. Das exakte mathematische Modell ist aufgrund seiner Unhandlichkeit (ca. 183 Seiten) nicht veröffentlicht (Dial und Grodecki 2001). Bei Vergleichen zwischen der Methode, die mit dem IGM auskommt, und der Methode, die das tatsächliche Sensormodell verwendet, hat sich ein maximaler Fehler von 0.04 Pixeln ergeben (Gerlach 2002). Jacobsen et al. (2002) sind im Übrigen der Ansicht, dass auch ohne IGM preisgünstig und qualitativ zufrieden stellende Entzerrungen der Bilder möglich sind.

Radiometrische Qualität:

Im panchromatischen Kanal der Bilder sind bei hoher Kontrasteinstellung Linien von Straßen- oder Sportplatzmarkierungen oder auch Schatten von Hochspannungsleitungen erkennbar. Untersuchungen am Institut für Geodäsie und Photogrammetrie der ETH Zürich zeigen aber, dass die Grauwertkanten trotz der hohen Auflösung nicht gut definiert sind und bei automatischer Bildanalyse (z. B. Kantenextraktion) zu Problemen führen (Kersten et al. 2000). Im panchromatischen Kanal konnten einige wenige Übersteuerungspunkte festgestellt werden, davon einige in einer nach Nord-Süd verlaufenden lang gestreckten Form. Bei der ca. 270km² großen Szene wurden 15 solcher Bildfehler entdeckt. Die Fehler sind nur im panchromatischen Kanal, nicht aber in den Multispektral-Kanälen auszumachen, was sich mit Erfahrungen aus anderen Untersuchungen deckt (Meinel und Reder 2001).

Da sehr günstige Wetterverhältnisse herrschten, liegen bei beiden Aufnahmen nahezu wolkenfreie Bilder vor.

4.2.3 Geometrische Korrektur

Die GEO-Produkte der IKONOS-Aufnahmen zeigen erwartungsgemäß große Fehler. Reliefbedingte Verzerrungen werden bei der Erstellung nicht berücksichtigt, geographisch exakte Passpunkte wurden von Space Imaging nicht eingesetzt. Die folgende Abbildung (Abb. 19) zeigt den Versatz in den beiden IKONOS-Szenen im Vergleich zur Referenz, den Orthofotos des Landesvermessungsamtes. Aufgrund dieser Lagefehler mussten die Satellitenbilder erneut geokodiert und in das Gauß-Krüger Koordinatensystem überführt werden.




Abb. 19a,b,c: Die Geo-Koordinaten der Orthophoto-Referenz des LVA kamen in den IKONOS-Szenen an anderer Stelle zu liegen. Der Unterschied beträgt bis zu 180 Meter. Dabei ist zu beachten, dass auch die IKONOS-Szenen nicht übereinander liegen.

Grundsätzlich sind Verfahren zu unterscheiden, die entweder die Aufnahmesituation zu rekonstruieren versuchen (photogrammetrischer Ansatz) oder die RPC-Daten von Space Imaging implementieren sowie solche, die nur mit Passpunkten auskommen. Ein

Höhenmodell steigert in der Regel die erreichbare Genauigkeit. Einen guten Überblick über die verschiedenen Verfahren geben Di et al. (2002)

Für das Projekt wurden drei verschiedene Methoden getestet:

- Die **Polynomial-Transformation** gilt als unkomplizierte Variante, bei der die Koordinaten über Interpolation ermittelt werden. Hierbei fließen nur Passpunkte ein. Deshalb ist dieses Verfahren nur für relativ flache oder kleinräumige Gebiete geeignet.
- Das **IKONOS Sensor Modell** ist implementiert in Erdas Imagine 8.5.1. und verwendet das *Image Geometry Model* (IGM) von SpacelMaging, welches die *rational polynomial coefficients* (RPCs) beinhaltet.
- Ein **parametrisches, „rigoroses“ Sensormodell**, welches die Sichtwinkel bei der Aufnahme berücksichtigt und damit dem eigentlichen Sensormodell sehr nahe kommt. Das Modell ist in der Bildverarbeitungssoftware PCI EasiPace (ab Version 7.0) als Zusatzmodul enthalten. Mit einem Höhenmodell ausreichender Genauigkeit sind hochpräzise Korrekturen möglich.

Für die Sensormodelle wurden jeweils dieselben Passpunkte verwendet. Bei der Polynomialtransformation waren diese bei weitem nicht ausreichend und mussten ergänzt werden. Die Passpunkte wurden aus den Orthophotos des Bayerischen Landesvermessungsamtes (LVA) aus dem Jahre 1999 mit einer Bodenauflösung von 0,4 m abgegriffen. Des Weiteren wurde bei den Sensormodellen ein Höhenmodell mit einer Rasterauflösung von 50x50 m verwendet.

Polynomialtransformation

Eine Polynomialtransformation ist den Interpolationsverfahren zuzuordnen. Hier werden die unbekanntenen neuen Koordinaten eines Pixels durch Interpolation zwischen benachbarten Passpunkten berechnet. Dabei sind Transformationen verschieden hoher Ordnungen zu unterscheiden. So entspricht eine Transformation erster Ordnung einer linearen Transformation, d. h. ein Bild kann damit lediglich gedreht, verdreht oder in seiner Auflösung verändert werden. Mit Transformationen höherer Ordnung (nicht linear) können auch Verzerrungen korrigiert werden. Letztendlich ergaben sich die besten Ergebnisse mittels einer Polynomialtransformation zweiter Ordnung und der Angabe von 116 Passpunkten. Dabei ergab sich ein RMS¹⁰ von 4.6786 (x:2.4932, y:3.959).

	Anzahl der GCPs ¹¹	RMS (x, y)	Visuelle Prüfung
1	7	0.72 (0.45, 0.56)	-
2	201	9.56 (4.67, 8.22)	0
3	116	4.68 (2.49, 3.96)	+

Tab. 3: Fehlerwerte bei unterschiedlich hoher Anzahl von Passpunkten.

¹⁰ RMS – *residual mean square error* = Fehlermaß für die Lagegenauigkeit von Passpunkten

¹¹ GCP – *ground control point* = Referenzpunkt zur Geokodierung von Bilddaten

Bei Transformationen höherer Ordnung ändert sich der RMS nicht wesentlich. Dieses Ergebnis ist im Vergleich zu anderen IKONOS-Polynomialtransformationen (Meinel und Reder 2001, Toutin und Cheng 2000) als gut zu bezeichnen.

Um mit dieser Methode eine höchstmögliche Lageübereinstimmung zwischen den beiden Szenen zu erhalten, musste die unkorrigierte Augustszenen an das transformierte Bild vom April per *rubber sheeting* angepasst werden. Bei einer visuellen Überprüfung ergaben sich aber diverse Stellen, an denen beide Szenen nur schlecht aufeinander passten. Diese Bereiche waren unregelmäßig über die Szenen verteilt und lagen innerhalb der Testgebiete, so dass von der Verwendung dieser Bilder Abstand genommen wurde.

IKONOS Sensor Modell

Die Bildverarbeitungssoftware ERDAS unterstützt ab Version 8.5.1 mit einem IKONOS Sensor Modell die Orthorektifizierung. Dabei wird das *Image Geometry Modell* (IGM) von Space Imaging eingelesen und das Modell mit weiteren Passpunkten und einem Höhenmodell verbessert.

Bei der Verwendung von nur 14 Passpunkten lag der RMS bei 1.00 (x: 0.58; y: 0.81), auch die visuelle Überprüfung bestätigte das gute Ergebnis.

Rigorous IKONOS Sensor Modell

Für die Verarbeitung der IKONOS-Daten steht im Modul Orthoengine der Bildverarbeitungssoftware PCI EasiPace gleichfalls ein spezielles Sensormodell (Toutin und Cheng 2000) zur Verfügung (ab Version 7.1). Dabei werden keine RPC-Files benötigt. Die Aufnahmegeometrie wird aus den Sichtwinkeln, die in den Metadaten der Bilder enthalten sind, berechnet. Das Modell wurde von Toutin und Cheng (2000) entwickelt, die auch umfangreiche Tests durchgeführt haben. Dabei ergaben sich im Vergleich zum teuren PRECISION-Produkt von SpaceImaging bessere Ergebnisse - vorausgesetzt, es liegt ein entsprechend genauer Referenzdatensatz vor.

Bei diesem Modell kommen die gleichen 14 Passpunkte und das Höhenmodell zum Einsatz. Es ergeben sich (bei gutem Ergebnis durch die visuelle Überprüfung) folgende RMS:

PAN-Kanal	0.90 (x: 0.48; y: 0.76)
MS-Kanäle	0.53 (x: 0.40; y: 0.61)

Fazit

Stehen Höhenmodell und gute Passpunkte zur Verfügung, ergeben sich deutliche Verbesserungen der Lagegenauigkeit. Mittlerweile sind bei der gängigen Bildverarbeitungssoftware spezielle Modelle (z. B. das *Image Geometry Model* mit den von *Space Imaging* gelieferten RPCs) für den IKONOS-Sensor implementiert oder als Modul verfügbar. Sind keine Module oder Höhenmodelle vorhanden, kann auch eine Polynomialtransformation zumindest eine deutliche Verbesserung der geometrischen Genauigkeit liefern.

Das Modell von Toutin und Cheng (2000), implementiert in *PCI Orthoengine*, erzeugte bei den Versuchen die genauesten Ergebnisse (RMS unter 1.0 m). Die Daten werden mit der *nearest neighbour*-Methode interpoliert. Im weiteren Verlauf dieser Arbeit werden die mit diesem Ansatz korrigierten Daten für die Analyse verwendet.

4.3 Luftbilder und Orthofotos

4.3.1 Verwendete Bildflüge

Folgende Orthofotos und Luftbilder stehen zur Verfügung:

- Digitale Orthofotos des Bayerischen Landesvermessungsamtes (LVA) von 1999 bzw. 2000 mit einer Bodenauflösung von 40 cm. Diese liegen im Blattschnitt der 1:5.000er Flurkarten vor.
- Analoge Luftbilder (ebenfalls LVA) von 1999 und 2000 im Standardluftbildformat 23x23 cm, Bildmaßstab 1:15.000
- Analoge Luftbilder aus dem Archiv des LVA von
 - 1956: Mit einer Reihenmesskammer von Zeiss RMK 21/18 Topar im Auftrag der Photogrammetrie München GmbH am 24.09.1956 befliegen. Bildgröße: 18x18 cm, Kammerkonstante 209.87 mm, Bildmaßstab 1:8.000
 - 1964: Mit einer RMK A 15/23 am 17.08.1964 und am 13.07.1965 befliegen. Bildgröße: 23x23 cm, Bildmaßstab 1:24.000, Kammerkonstante 152.6 mm
 - 1976: Ebenfalls mit einer RMK A 15/23 am 25.06.1976 befliegen. Bildgröße: 23x23 cm, Bildmaßstab 1:25.000, Kammerkonstante 152.6 mm

Digitalisierung der analogen Luftbilder

Die Qualität der Digitalisierung ist abhängig von der radiometrischen und geometrischen Auflösung und Genauigkeit. Dabei ist eine hohe Auflösung auch mit hohen Datenmengen verbunden.

Bei der Orthorektifizierung der aktuellen Luftbilder wurden verschiedene Erfahrungen mit Scannermodellen und Auflösungen gemacht, um die Auswirkungen auf die Ableitung des Oberflächenmodells aufzuzeigen. Diese Erfahrungen sind jedoch nicht verifizierbar, da die Scanner nur jeweils für kurze Zeit verfügbar waren und die umfangreichen Einstellmöglichkeiten nicht ausreichend getestet werden konnten. Grundsätzlich ist jedoch anzumerken, dass vor allem die Kontrasteinstellungen beim Scannen erhebliche Auswirkungen auf die Berechnung der Oberflächenmodelle haben.

Die aktuellen Luftbilder (1999/2000) wurden mit hoher Auflösung (2500 dpi, ca.12 μm) mit einem A3-Scanner der Firma Heidelberg (Modell Topaz) und einem photogrammetrischen Präzisionsscanner der Firma Zeiss (Modell Scai) gescannt.

Dieses Material lieferte später, bei der Berechnung der Oberflächenmodelle gute Ergebnisse. Allerdings konnten aus Zeitgründen und wegen technischer Hindernisse nur wenige Luftbilder mit dem hochwertigen Scanner verarbeitet werden. Der restliche Teil, vor allem die historischen Luftbilder, wurden mit einem handelsüblichen DIN/A3 Flachbettscanner (mit 600 bis 1200 dpi) digitalisiert.

4.3.2 Geometrische Korrektur

Die digitalen Orthophotos des LVA waren vollständig entzerrt und geometrisch korrigiert. Sie mussten nicht weiter aufbereitet werden.

Die Luftbilder aus den Jahren 1956, 1964, 1965 und 1976 konnten nicht als Orthophotos erworben werden, sondern mussten erst orthorektifiziert werden. Auch die aktuellen Luftbilder von 1999/2000 wurden erneut orientiert, damit ein digitales Oberflächenmodell abgeleitet werden konnte.

Bei der Erstellung von Orthofotos werden folgende Arbeitsschritte unterschieden:

- Digitalisierung der Photos
- Berechnung der inneren und äußeren Orientierung mit Hilfe von Passpunkten, Rahmenmarken und Kammerdaten
- Berechnung der differentiellen Entzerrung über die Informationen aus einem digitalen Geländemodell
- Ausgabe des Orthobildes

Wenn möglich wurden die Oberflächenmodelle anstatt des Höhenmodells verwendet, um die geometrische Genauigkeit der Orthofotos noch zu steigern. Als Folgeprodukte lassen sich Mosaik aus zusammenhängenden Photos errechnen oder, wenn Stereo-Bildpaare vorliegen, auch Oberflächenmodelle bzw. Höhenschichtlinien ableiten. Bei der Erstellung der Orthofotos kamen die Module Orthobase Pro (Erdas Imagine 8.5) und Orthoengine 8.2 (PCI Geomatics) zum Einsatz.

Innere und äußere Orientierung

Allgemein beruht die photogrammetrische Auswertung auf der geometrischen Rekonstruktion des Aufnahmevorgangs. Dabei wird zwischen innerer und äußerer Orientierung unterschieden. Die innere Orientierung beschreibt die Lage des Projektionszentrums zur Bildebene, mit der äußeren Orientierung wird die Lage der Aufnahmekammer im Raum rekonstruiert, d. h. der geometrische Bezug zwischen Bild- und Geländeebene hergestellt. Eine detaillierte Darstellung zur inneren und äußeren Orientierung findet sich im Endbericht zum Projekt AQUATIC und in der Arbeit von Rogg (2003).

Passpunktbestimmung

Für die Bestimmung der Passpunkte reichte im Fall der historischen Bilder (geringe Auflösung von 55 bis 70 cm) die Genauigkeit der digitalen Orthofotos des Bayerischen Landesvermessungsamtes (LVA) aus.

Für die Bearbeitung der höher aufgelösten (40 cm) Luftbilder von 1999/2000 konnte auf die Kartei der photogrammetrischen Passpunkte des LVA zurückgegriffen werden. Sechs solcher Passpunkte, deren Genauigkeit im cm-Bereich liegt, konnten verwendet werden und wurden um vier selbst gemessene GPS-Punkte ergänzt. Bei den eigenen Messungen kam der TDC2-GPS-Empfänger der Firma Trimble mit differenzieller Korrektur (Echtzeit) zum Einsatz. Die Genauigkeit der Messungen liegt im Bereich derer des LVA.

Ergebnisse der Orthofoto- bzw. Oberflächenmodellberechnungen

1956

Bildflug vom 24.09.1956

Mosaik aus 9 Luftbildern

Interpolation mit *Cubic Convolution* auf eine Bodenauflösung von 0.7 m

RMS: 0.7727 (Total)

Als Höhenmodell wurde das abgeleitete DOM verwendet.

1964

Bildflug vom 17.08.1964

Mosaik aus 3 Luftbildern

Interpolation mit *Cubic Convolution* auf eine Bodenauflösung von 0.55 m

RMS: 1.7505 (total)

Als Höhenmodell wurde das DGM 5 verwendet.

1965

Bildflug vom 13.07.1965

Mosaik aus 3 Luftbildern

Interpolation mit *Cubic Convolution* auf eine Bodenauflösung von 0.55 m

RMS: 2.2199 (total)

Als Höhenmodell wurde das DGM 5 verwendet.

1976

Bildflug vom 25.06.1976

Mosaik aus 2 Luftbildern

Interpolation mit *Cubic Convolution* auf eine Bodenauflösung von 0.55 m

RMS: 2.577 (total)

Als Höhenmodell wurde das DGM 5 verwendet.

Diese Bilder überlappen sich nur zu ca. 23%, deshalb wurde auf eine DOM-Generierung verzichtet.

1999/2000

Orthofotos des LVA

Bodenauflösung von 0.4 m

Berechnung erfolgte vom LVA; keine weitere Korrektur

Bildflug vom 15.09.1999

Mosaik aus 3 Luftbildern

Zur Ableitung eines digitalen Oberflächenmodells mit 1.0 m Bodenauflösung

6 Passpunkte aus der LVA-Kartei

4 gemessene Punkte

RMS 1.1227 (Total)

4.4 Hyperspektraldaten

Im Vergleich zu Luftbildern weisen Scannerdaten eine wesentlich stabilere Radiometrie auf. Sie lassen sich deshalb mit Hilfe von Klassifizierungsverfahren einfacher auswerten. Daten werden digital geliefert und es stehen Kanäle unterschiedlicher Wellenlängen getrennt zur Verfügung. Im Projekt kamen Daten des Hyperspektralsensors **CASI** (*compact airborne spectral imager*) zum Einsatz.

Seit Mitte der 80er Jahre sind neue, flugzeuggetragene Sensoren verfügbar, die reflektiertes Licht in sehr vielen (teilweise hunderten) und sehr eng beieinander liegenden Kanälen aufzeichnen. So sind genaue Charakterisierungen der Spektralkurven von Bildpunkten im sichtbaren und infraroten Spektrum möglich. Aufgrund ihrer hohen Anzahl an Kanälen werden diese Sensoren als hyperspektral bezeichnet (vgl. Richards und Jia 1999, S.22). Multispektrale Sensoren besitzen eine deutlich geringere Anzahl von Spektralkanälen. Zudem weisen sie Lücken im abgedeckten Spektrum auf, in denen keine Information gesammelt wird.

Sehr hoch auflösende Daten hyperspektraler Sensoren sind zurzeit nur von flugzeuggetragenen Systemen erhältlich. Satellitengestützte Systeme arbeiten im Moment in Auflösungsbereichen von 30 m (Hyperion¹²), 18 m (CHRIS/Proba¹³) oder schlechter (z. B. 300 m bei MERIS¹⁴). Zukünftige sehr hoch auflösende Hyperspektralsensoren, z. B. Nachfolger des OrbView 4 mit 8 Metern bei 200 Kanälen, sind in Planung.

4.4.1 Eigenschaften des CASI-Sensors

Der CASI-Scanner wurde 1989 von der kanadischen Firma ITRES Instruments entwickelt. Es handelt sich um einen flugzeuggetragenen, hyperspektralen *Pushbroom*-Sensor.

¹² Hyperion - Sehr hoch auflösender Sensor, mit 220 Spektralkanälen (von 0.4 bis 2.5 μm). Der Sensor nimmt pro Bild eine Landoberfläche von 7.5 km mal 100 km auf.

¹³ CHRIS - Der *Compact High Resolution Imaging Spectrometer* arbeitet im sichtbaren Licht und NIR von 400 nm bis 1050 nm mit 63 Spektralkanälen, bei 36 m, oder mit 18 Kanälen mit voller Auflösung (18 m).

¹⁴ MERIS - Ein Sensor der ESA für ozeanographische-, atmosphärische- und Landanwendungen, im Spektralbereich von 400 – 1050 nm in 15 Kanälen.

Die Aufnahmen erfolgen entweder im „*spectral mode*“, der es beim CASI ermöglicht, die Reflexion in 288 Kanälen (bei 12 bit) mit einem Abstand von mindestens 1,8 nm zu erfassen, oder im „*spatial mode*“, der bis zu 50 Kanäle à 11 nm Bandbreite aufzeichnet (programmierbar). Aufgrund seines räumlichen Auflösungsvermögens zwischen 0,5 und 5 m (CASI-2 bis 10 m) Pixelkantenlänge wird der CASI zu den sehr hoch auflösenden Systemen gezählt (Ehlers 2002). Die Aufnahmen erfolgten in diesem Fall im Wellenlängenbereich von 480-930 nm mit 44 Kanälen in 11-14 nm-Intervallen. Die räumliche Auflösung der Bilddaten beträgt 3x3 m/Pixel, bei einer Flughöhe von ca. 2500 m. Bedingt durch den Aufnahmewinkel ergibt sich so eine Flugstreifenbreite von etwa 1,7 km.

Vor der Bearbeitung wurden die ursprünglich aus 44 Kanälen gewonnenen Bilddaten auf 20 Kanäle reduziert. Der neu entstandene Datensatz enthält einen Kanal im Übergangsbereich zwischen blau und grün, vier Kanäle im grünen, einen im gelben, einen im Übergang von gelb zu rot, acht im roten Bereich des Spektrums und fünf Kanäle im nahen Infrarotbereich. Ein Übergangsbereich zwischen Rot und Nahem Infrarot (NIR), in dem sich der *Red Edge*¹⁵ befindet und der vor allem zur Darstellung von Vegetation geeignet ist, liegt zwischen dem 10. und 15. Kanal.

Die radiometrische Auflösung des Datensatzes wurde aus Datenreduktionsgründen im Vorfeld von 12 auf 8 bit reduziert. Eine Analyse der ursprünglichen Histogramme zeigt, dass Reflexionswerte größer 255 Ausreißer bzw. Baustellenpixel waren. Aus diesem Grund wurden bei der Reduktion diese Bereiche einfach abgeschnitten bzw. auf 255 gesetzt.

4.4.2 Korrekturen

Radiometrische Korrekturen werden beim CASI in der Regel durch Kalibrierung bereits während des Fluges vorgenommen. Über einen internen Referenzstrahler, dessen Strahldichte bekannt ist, können den gemessenen Grauwerten absolute Strahldichtewerte zugeordnet werden (Hildebrandt 1996).

Geometrische Fehler ergeben sich dadurch, dass eine Scanneraufnahme in Flugrichtung zwar in Parallel-, senkrecht zur Flugrichtung jedoch in Zentralperspektive erfolgt. Letztere bedingt eine zu den Bildrändern hin immer größer werdende Verzerrung. Bewegungen des Sensorträgers durch Rollen, Kippen und Drehen des Flugzeugs wurden bereits direkt nach der Aufnahme korrigiert. Die Georeferenzierung der Daten erfolgte an der Limnologischen Station Iffeldorf. Als Referenz dienten Orthofotos des Landesvermessungsamts, wobei als Bezugssystem Gauß-Krüger Zone 4 diente. Anschließend wurden die einzeln aufgenommenen Bildstreifen zu einem Gesamtdatensatz zusammengesetzt.

4.4.3 Fehler

Aufgrund einer Limitierung der Prozessierungssoftware musste der Datensatz in zwei Hälften, also jeweils zehn Kanäle getrennt voneinander, verarbeitet werden. Vermutlich

¹⁵ Red Edge - Wendepunkt der Steigungskurve zwischen Rot und NIR. Er kann näherungsweise als Mittelwert zwischen Reflexionsmaximum und -minimum berechnet werden. Je höher der Wert ist, desto höhere Chlorophyll-Konzentrationen können angenommen werden (Jago et al. 1999).

wurde bei den zweiten zehn Kanälen ein abweichender Passpunktsatz verwendet, so dass an Übergängen zwischen den einzelnen Flugstreifen ein Versatz zwischen den ersten und den zweiten zehn Kanälen auftritt.

Bereiche mit wenig markanten Stellen bieten kaum Möglichkeiten, Passpunkte zu setzen. Dies wirkt sich vor allem bei den Hochmooren aus. Hier ist eine Krümmung der normalerweise geradlinigen Entwässerungskanäle zu erkennen.

4.5 Digitale Höhenmodelle

Auf Basis der analogen Höhenlinienkarten im Maßstab 1:5.000 des LVA wurde bereits in einem vergangenen Projekt an der Limnologischen Station Iffeldorf ein digitales Geländemodell mit einer Höhengenaugigkeit von $\pm 0,5$ m erstellt.

Im Projekt lagen Stereoluftbilder der Jahre 1999, 1976, 1964 und 1956 vor. Aus diesen wurden, mit Ausnahme des Jahres 1976, digitale Oberflächenmodelle (DOM) berechnet.

4.5.1 „Kontrollpunktaufnahmen mit GPS“

Um ein Orthophoto bzw. ein Oberflächenmodell zu berechnen, werden neben den genauen Informationen über die Bildflugdaten der Luftbildpaare zusätzlich Passpunkte im Gelände als Referenz benötigt. Da vom Landesvermessungsamt für das Bearbeitungsgebiet nur wenige Punkte vorlagen, wurden zusätzlich mit einem GPS-Gerät (Trimble TDC2-GPS mit differenzieller Korrektur) Punkte eingemessen. Ziel der GPS-Messungen war nicht nur eine möglichst hohe Lagegenauigkeit, sondern auch eine möglichst genaue Höheninformation, die zur Berechnung der Oberflächenmodelle benötigt wird. Um die Genauigkeit der Messungen abzuschätzen, wurden Testmessungen an Vermessungspunkten des LVA gemacht und deren Angaben mit den eigenen Messungen verglichen (Abb. 20).




Abb. 20: Vergleich von Höhenangaben des LVA mit den eigenen GPS Messungen

Die ermittelten Abweichungen (Abb. 20) von den Angaben des Landesvermessungsamtes wurden für die Zwecke der Luftbildinterpretation als akzeptabel eingestuft. In einem Gebiet mit großen naturbelassenen Flächen wie Moorflächen oder Wäldern ist die geforderte, gleichmäßige Verteilung der Passpunkte über das Gelände schwierig. In den historischen

Aufnahmen sind noch weniger geeignete Punkte zu finden, da damals das Straßennetz und die Besiedelung geringer waren, bzw. sich Straßenverläufe geändert haben. Für das ganze Testgebiet konnten 23 geeignete Punkte eingemessen werden.

4.5.2 Eigenschaften der berechneten DOMs

Zunächst wurde von der Überlegung ausgegangen, dass eine möglichst hohe räumliche Auflösung der gescannten Luftbilder die höchste Genauigkeit bei der Erstellung eines Oberflächenmodells ergibt. Deshalb wurden die benötigten Luftbilder zunächst direkt beim LVA mit 12 µm digitalisiert. Aufgrund der Erfahrungen bei der Digitalisierung (siehe oben) wurde erkannt, dass aufgrund der Körnigkeit des Films (Auskunft eines Mitarbeiters des Instituts für Photogrammetrie und Geoinformation in Hannover) die Ergebnisse nicht brauchbar waren. Detaillierte Qualitätskontrollen der einzelnen Oberflächenmodelle konnten nicht durchgeführt werden. Visuelle Überprüfungen zeigen aber an einigen Stellen, dass die Flächengenauigkeit oft nicht ausreicht, um diese Daten später bei der Klassifikation zusätzlich zu nutzen. Den zum Teil extremen Schlagschatten, z. B. in den Bildern von 1956, wurde oft die gleiche Höheninformation wie dem angrenzenden Wald zugewiesen.

Die folgenden Oberflächenmodelle konnten aus den Stereoluftbildern berechnet werden:

Bildflug vom 24.09.1956

Mosaik aus 9 Luftbildern

Interpolation mit *Cubic Convolution*. Bodenauflösung: **0.7 m**

RMS: 0.7727 (Total)

Als Höhenmodell wurde das abgeleitete DOM verwendet.

Bildflug vom 17.08.1964

Mosaik aus 3 Luftbildern

Interpolation mit *Cubic Convolution*. Bodenauflösung: **0.55 m**

RMS: 1.7505 (total)

Als Höhenmodell wurde das DGM 5 verwendet.

Bildflug vom 25.06.1976

Mosaik aus 2 Luftbildern

Interpolation mit *Cubic Convolution*. Bodenauflösung: **0.55 m**

RMS: 2.577 (total)

Als Höhenmodell wurde das DGM 5 verwendet.

Die Bilder überlappen sich nur mit ca. 23%, deshalb wurde **auf eine DOM-Generierung verzichtet**.

Bildflug vom 15.09.1999

Mosaik aus 3 Luftbildern

Zur Ableitung eines digitalen Oberflächenmodells. Bodenauflösung: **1.0 m**

6 Passpunkte aus der LVA-Kartei

4 Selbstgemessene Punkte RMSE 1.1227 (Total)

4.6 Geländebegehungen und Kartierungen

Zum Zweck der späteren Verifizierung und für die Verwendung als Trainingsgebiete wurden Teilbereiche des Untersuchungsgebietes in Geländebegehungen untersucht. Zusätzlich liegen unterschiedliche Kartierungen vor, die im Folgenden kurz beschrieben werden:

1. **Biotoptypenkartierung** (BayLfU), 1985-2003. Die Biotopkartierung Bayern gliedert sich in vier Bereiche: die so genannte Flachlandkartierung außerhalb der Alpen und Städte, seit 2003 als Fachkartierung fortgeführt, die Alpenbiotopkartierung, die Stadtbiotopkartierung sowie einige Spezialkartierungen. Die Kartierer ermitteln die Biotope in der Landschaft mit Hilfe von Ortho-Luftbildern. Die Grenzen der Biotopflächen werden in das Luftbild eingezeichnet und später digitalisiert. Biotope werden in verschiedene Typen unterteilt, die sich aufgrund ihrer Gelände- und Standorteigenschaften, dem Vorkommen von Pflanzenarten und ihren Lebensgemeinschaften sowie ihrer Entstehung voneinander unterscheiden. Bei diesen Biotoptypen handelt es sich zum einen um natürlich entstandene Flächen, wie Hochmoore und Felsvegetation, zum anderen um Gebiete, die aufgrund früherer landwirtschaftlicher Nutzung (z. B. Hecken und Streuwiesen) oder als Folge von Rohstoffgewinnung (z. B. Abbaustellen) entstanden sind.
2. **Seeuferkartierung**: Diese Kartierung wurde für die Osterseen auf der Basis von schwarz-weiß Orthofotos (M1:10.000), im Rahmen eines GIS-Kurses an der Limnologischen Station in Iffeldorf im Oktober 2000 und 2001 angefertigt. Aufgrund von Fehlern in der Kartierung wurde diese 2002 in intensiven Geländekampagnen überprüft und komplett überarbeitet (vgl. Kangler 2003). Vom Starnberger See liegen ebenfalls Seeuferkartierungen aus den Jahren 1986 und 2000 vor.
3. **Lebensraumkartierung**: Diese Kartierung wurde ebenfalls im Rahmen eines GIS-Kurses an der Limnologischen Station auf der Basis des Pflege- und Entwicklungsplans des NSG Osterseen (BayLfU 1987) erstellt. Sie wurde im Oktober 2000, im Rahmen einer Diplomarbeit (Geiß 2001) aktualisiert. Als Grundlage dienten Orthofotos von 1990, Luftbilder aus dem Jahr 1979 und Flurkarten im Maßstab 1:5.000.
4. **Landnutzungskartierung**: Diese Kartierung aus dem Jahr 2002 wurde im Rahmen einer Diplomarbeit an der Limnologischen Station erstellt (Kangler 2003). Die angegebenen Landnutzungsklassen wurden für den Vergleich mit den Klassifizierungen zusammengefasst. Die Gruppe Wasser besteht beispielsweise aus den Landnutzungsklassen „Seefläche“ „künstlicher Teich / natürlicher Weiher“ und „Schwimmblattvegetation“

5 Ergebnisse

In diesem Kapitel werden zunächst unterschiedliche Strategien, d. h. die unterschiedlich aufgebauten Klassenhierarchien für die Klassifikation der jeweiligen Datengrundlagen dargestellt und verglichen. Aufgrund der verschiedenartigen Charakteristika der Daten müssen sich auch die Vorgehensweisen für ihre Auswertung unterscheiden. Sie führen aber immer zu vergleichbaren Ergebnissen. So können später in einem multisensoralen und multi-temporalen Ansatz Veränderungen im Untersuchungsgebiet erkannt werden. Die Definition einzelner, übertragbarer Objekte ist das wesentliche Ziel. Die Objektdefinitionen werden in Punkt 5.2 detailliert am Beispiel ausgewählter Objekte der IKONOS-Klassifikation dargestellt und den Objektdefinitionen für Orthofotos und CASI-Daten gegenüber gestellt. Diese Informationen werden hier verdichtet wiedergegeben. Die exakten Klassenhierarchien und die genauen Definitionen der Objekte befinden sich in Anhang 1 dieser Arbeit.

Anschließend werden die Daten klassifiziert und die Genauigkeit der einzelnen Klassifikationsergebnisse wird anhand von bestehenden Klassifikationen sowie anhand von Ergebnissen von Geländebegehungen analysiert.

5.1 Klassifikationsstrategien

Die verwendeten Datengrundlagen weisen sowohl in ihrer räumlichen als auch der spektralen und radiometrischen Auflösung Unterschiede auf. Daher war es notwendig, auch die Regelwerke für die Klassifikation entsprechend unterschiedlich aufzubauen.

Für jeden Datensatz gibt es wiederum unterschiedliche Herangehensweisen, die zum gleichen Ziel führen sollen. Der grundsätzliche Aufbau einer Klassenhierarchie ist deshalb von den Vorlieben oder dem „Stil“ des bearbeitenden Experten abhängig. Das Ergebnis, also die Klassifikation, soll hingegen zu einem hohen Grad vergleichbar sein.

Darstellungsweise

Um die Sprachregelung von eCognition durchzuhalten und um den Bezug zu den englischen Bezeichnungen der IKONOS-Klassenhierarchie zu behalten, wird im Folgenden anstatt des deutschen Wortes Ebene der Begriff Level verwendet. Die Darstellung der Klassenhierarchien in eCognition ist eine spezielle Art des Dendrogramms, das sich horizontal und nicht vertikal entwickelt. Wie die Abbildung (Abb. 21) zeigt, ist die Aussage aber identisch.




Abb. 21: Schema einer Klassenhierarchie. Links: eCognition Darstellung; rechts: Darstellung Beispielhaft als Baumstruktur

Die inhaltlich unterschiedlichen Hierarchien für Gruppen und Vererbung werden in eCognition gleich dargestellt. Beide Hierarchien werden im Folgenden jeweils in den einzelnen Levels gegenüber gestellt und besprochen. Die Vererbungshierarchien (immer links in den folgenden Abbildungen stehend) stellen die Weitergabe der Eigenschaften von Ober- an Unterklassen dar, während die Gruppenshierarchien (auf der rechten Seite der folgenden Abbildungen) logische Zusammenfassungen von Klassen zu semantischen Gruppen zeigen. Letztere müssen nicht immer mit der Vererbung übereinstimmen, haben i. d. R. aber eine ähnliche Struktur.





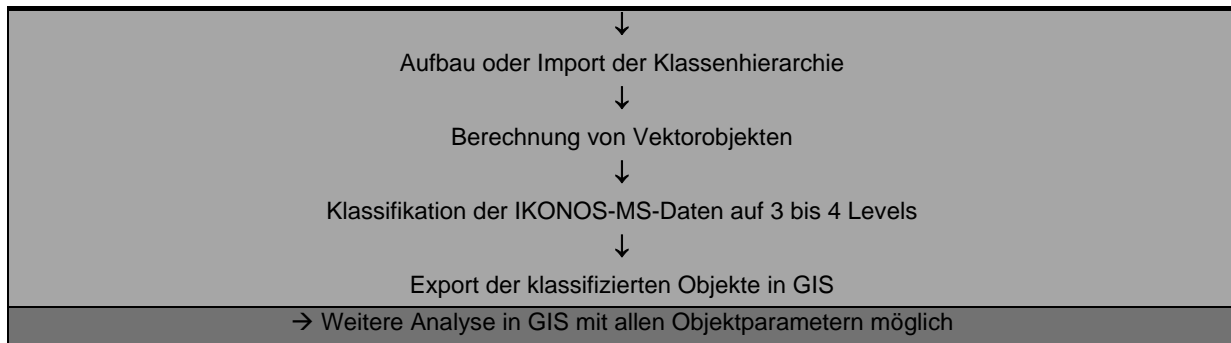
Abb. 22: Beispiel einer Gegenüberstellung von Vererbungs- (links) und Gruppenshierarchie (rechts) aus eCognition

Die Klassen der IKONOS-Klassifikation wurden konsequent mit englischen Namen bezeichnet, um Internationalität zu gewährleisten.

5.1.1 Klassifikation von IKONOS-Daten

Die eigentliche Landbedeckungsklassifikation erfolgte auf Basis der multispektralen IKONOS-Daten. Die Daten des hoch auflösenden panchromatischen Kanals wurden gesondert klassifiziert und in Form externer Information in die eCognition-Projekte integriert.





Tab. 4: Ablaufschema einer objektorientierten Klassifikation von IKONOS-Daten

Klassifikation der panchromatischen Daten

Zunächst wurden in einem ersten Schritt über Texturparameter Rauigkeitsklassen (Texturklassen) aus den panchromatischen IKONOS-Daten abgeleitet. Diese wurden als zusätzlicher Kanal in ein eCognition Projekt eingebunden. Objekte wurden nur auf einem Level segmentiert, die Segmentierungsparameter wurden empirisch ermittelt (Tab. 5).

Segmentierungsparameter				
	Kanalgewichtung	Scale Parameter	Homogenität	Ø Segmentgröße
Level 1 (Textur)	PAN = 1	250	Color = 0.7 Smoothness = 0.5	12000

Tab. 5: Segmentierungsparameter für panchromatische IKONOS-Daten

Der PAN-Kanal wurde aufgrund von Texturen in die fünf Klassen „rau“, „glatt“ („Wasser“ und „nicht-Wasser“) sowie „mittel“ unterteilt (Abb. 23).



Abb. 23: Texturklassen aus panchromatischen IKONOS-Daten

Tests ergaben, dass der Parameter „*GLCM homogeneity*“¹⁶ die besten Ergebnisse bei der Klassifikation von Texturunterschieden erzielte. Es wurden raue Bereiche (überwiegend Waldgebiete) von weniger texturierten Gebieten (oft verbuschte Bereiche in Mooren oder Feuchtgebieten) und Bereichen mit glatten Oberflächen abgegrenzt. Letztere wurden aufgrund der Grauwerte des PAN-Kanals noch grob in Wasser und nicht Wasser unterschieden. Im Anschluss wurde diese klassifizierte Information für die Analyse der multispektralen Daten genutzt.

¹⁶ *GLCM homogeneity* – Texturparameter, der aus der Grauwertübergangsmatrix (*GLCM – grey level co-occurrence matrix*) berechnet wird. Ein hoher Wert steht für ein in seinen Grauwerten homogenes Objekt.

Klassifikation der multispektralen Daten

Die multispektralen IKONOS-Daten wurden auf drei bis vier Levels klassifiziert, die jeweils unterschiedliche Maßstabsebenen repräsentieren. Es wurde streng hierarchisch vorgegangen und zunächst ein grober Level für eine Vorklassifikation segmentiert. Darunter erfolgte eine feinere Segmentierung für einen Level, der thematische Informationen z. B. aus einer externen Klassifikation enthalten kann. Die untersten zwei Levels, welche eine große Maßstabsebene repräsentieren, enthielten jeweils eine detaillierte Klassifikation der Wasserflächen bzw. Feuchtgebiete (siehe Tab. 6).

Segmentierungsparameter				
	Kanalgewichtung	Scale Parameter	Homogenität	∅ Segmentgröße
Level 4 (Vorklass.)	Blau = 1 Grün = 1	40	Color = 0.8 Smoothness = 0.8	280 - 320
Level 3 (Wald)	Rot = 1 NIR = 1	25	Color = 0.8 Smoothness = 0.5	90 - 125
Level 2 (Wasser)	Pca1 = 0 Pca2 = 0	10	Color = 0.8 Smoothness = 0.8	18 - 22
Level 1 (Feuchtg.)	Pca3 = 0	10	Color = 0.8 Smoothness = 0.8	18 - 22

Tab. 6: Segmentierungsparameter für multispektrale IKONOS-Daten

Da die Kontrollmöglichkeiten zur Einstellung der Segmentierungsparameter in eCognition sehr begrenzt sind, wurden auch hier die Werte empirisch ermittelt. Das bedeutet, in einem langwierigen Prozess wurden Tests durchgeführt und es wurde die Qualität der entstandenen Objekte visuell überprüft. Subjektiv entstanden bei den verwendeten Parametern die „besten“ Objekte. Es bleibt anzumerken, dass es weitere Parameterkombinationen gibt, die Verbesserungen in Teilbereichen bringen, in anderen Bereichen aber Objekte der übrigen Klassen verschlechtern. Das Segmentierungsverfahren von eCognition ist im Vergleich mit anderen Verfahren dieser Art stabil und erzeugt durchgehend sehr gute Ergebnisse (vgl. Neubert und Meinel 2003).

Innerhalb des Projektes AQUATIC wurden die Klassifikationsaufgaben aufgeteilt, so dass jeweils zielgerichtet an bestimmten thematischen Teilbereichen gearbeitet wurde. Im Rahmen dieser Arbeit wurden die Regeln für die Klassifikation von Wasser, Makrophyten und Feuchtgebieten entwickelt. Objekte wie Acker, Wald, Grünland und anthropogene Flächen werden vom Projektpartner ebenfalls im Rahmen einer Dissertation bearbeitet (Mott unveröff.). Die in beiden Arbeiten definierten Objekte können jeweils als externe thematische Level eingebunden werden und dienen so der gegenseitigen Verbesserung oder der Vervollständigung einer Klassifikation.

Klassenabgrenzungen pro Level im April und August 2001	
Level 4: Vorklassifikation	Offene Wasserfläche – <i>open water</i> Submerse Vegetation – <i>submerged vegetation</i> (nicht im April) Kanäle – <i>channels</i> Kanäle mit Vegetation – <i>channels with submersed vegetation</i> Potentielle Feuchtgebiete – <i>potential wetlands</i> Potentielle offene Moorflächen – <i>potential open moor areas</i> Grünland (Wiese/Weide) – <i>grassland (pasture/meadow)</i> Abgeerntete Felder – <i>harvested fields</i>
Level 3: Wald thematisch	Wald (thematisch aus externer Klassifikation) – <i>external forest</i>
Level 2: Wasser detailliert	Tiefwasser – <i>deep water</i> Flachwasser (dunkel/hell) – <i>shallow water (dark/light)</i> Flachwasser/submerse Veg. – <i>shallow water/subm. veg.</i> (nicht im April) Kleine Kanäle (korrigiert) – <i>small channels (corrected)</i>
Level 1: Feuchtgebiete det.	Verbuschte offene Hochmoore – <i>open moor, shrub encroachment</i> Offene Hochmoore – <i>open moor</i> Dichte Schilfbestände – <i>reed dense crop</i> Schilf/Seggen am Wasser – <i>reed/sedge mosaic close to water</i> Niedermoor (seggendominiert) – <i>sedge dominated lowland moor</i> Verbuschte Feuchtgebiete – <i>forested wetlands/bushland</i>

Tab. 7: Unterscheidbare Klassen der IKONOS-Szenen vom 24.04.2001 und 12.08.2001

Die Klassifikation der Aprildaten enthielt aufgrund des Aufnahmezeitpunktes am Beginn der Vegetationsperiode weniger Klassen, da submerse Makrophyten und die Schwimmblattvegetation noch nicht entwickelt waren und somit auch in den Daten nicht klassifiziert werden konnten.

Klassifikationen erfolgten immer in fünf Durchläufen, bis ein stabiles Ergebnis erreicht wurde (vgl. hierzu Abschnitt 2.6.2.3). Insbesondere die Klasse der Feuchtgebiete benötigte Nachbarschaftsinformationen zur Klasse Wasser, die zunächst in einem ersten Klassifikationsdurchlauf erzeugt werden mussten.


Trotz des Einflusses durch den Aufnahmezeitpunkt führten die Klassenhierarchien führten zu vergleichbaren Klassifikationen. Die Regelwerke weichen in einzelnen Bereichen voneinander ab (Tab. 7), da Objekte zu den jeweiligen Zeitpunkten in anderen Ausprägungen erscheinen. So ist Schilf im April noch durch tote Halme dominiert und erscheint braun, während es im August voll ausgetrieben ist und die Reflexion im grünen Spektralbereich dominiert.

5.1.1.1 Vererbungshierarchie und semantische Gruppen im April 2001:

Level 4 – Vorklassifikation, April 2001

Aufgrund des frühen Aufnahmezeitpunktes am Beginn der Vegetationsperiode entfielen in diesem Regelwerk Klassen für submerse Vegetation. Nur in flachen Kanälen existierte bereits Vegetation, die eine zweite, gesonderte „Kanal“-Klasse notwendig machte. Im Wesentlichen wurden alle Klassen dieses Levels innerhalb einer Hierarchiestufe klassifiziert. Es gibt keine Unterklassen. Eine Ausnahme stellte das Wasser dar, das seine Definition (siehe Anhang 1) weitervererbt und in Kanäle sowie offene Wasserfläche unterteilt wurde.

In der Gruppendefinition spiegelt sich das in zwei semantischen Gruppen wider, zum einen die offenen Wasserflächen, zum anderen Kanäle (Abb. 24).




**Abb. 24: Level 4 - Vorklassifikation (links Vererbung; rechts Gruppierung) IKONOS April 2001.
Der Wert in Klammern gibt die Segmentierungsebene an, I4 = Level 4**

Dieser Level dient zur Abgrenzung grober Landbedeckungseinheiten im Vorfeld. Die niedrigeren Levels arbeiten im Anschluss nur noch innerhalb der hier klassifizierten Bereiche. Einzelne Klassen werden in Abschnitt 5.2 erläutert und einander gegenüber gestellt.

Level 3 – Externe Information, April 2001

Aufgrund der Möglichkeit, zielgerichtet zu klassifizieren, wurden Klassen, die nicht primär zu Feuchtgebieten oder Wasserbereichen gehören, nicht direkt als Objekt definiert. Wenn nötig wurden diese aus externen Klassifikationen oder digitalen Kartenwerken hinzugefügt. In diesem Fall ist eine Waldmaske eingesetzt worden (Abb. 25). Diese stammte ebenfalls aus einer Klassifikation der vorgestellten IKONOS-Daten (vgl. Mott unveröff.). Die Waldmaske wurde zunächst als richtig angesehen und genutzt, um die Vorklassifikation der potentiellen Feuchtgebiete ggf. zu korrigieren. Die Feuchtgebiete durften nur noch außerhalb dieser Waldmaske existieren. Umgekehrt wurden aber auch die klassifizierten Feuchtgebietsobjekte für die Korrektur der Waldmaske herangezogen.

Bei dieser Klasse gibt es keine abweichende Gruppierung, da bereits alle Waldobjekte von der Waldmaske („forest“) erfasst sind.



**Abb. 25: Level 3 - Thematische Ebene mit Waldinformationen aus IKONOS-Daten August 2001.
Der Wert in Klammern gibt die Segmentierungsebene an, I3 = Level 3**

Level 2 – Wasser, April 2001

Der frühe Aufnahmezeitpunkt spiegelt sich auch in diesem zweiten Level wider. Klassen, die Wasser mit einem Anteil an submerser Vegetation beschreiben, werden nicht benötigt. Alle anderen Klassen wurden unter eine Oberklasse („water level 2“) gruppiert, damit sie später einfacher abgefragt werden konnten. Mit Ausnahme der Klasse „small channels corr“ erben alle anderen Wasserklassen die Eigenschaften von „water_GR“ (Abb. 26). Diese Strategie schließt aus, dass eine Klassifikation außerhalb der Wasser- und Feuchtgebietsgrenzen von Level 4 erfolgt. Eine Ausnahme bildet die Klasse „small channels corr“, da sie aufgrund der

fünf Klassifikationsdurchläufe sonst Probleme in der Abfrage verursacht. Es wurde eine sehr enge Nachbarschaft zu den bestehenden Wasserklassen genutzt. Wenn die „*small channels*“ Klasse ebenfalls in die Gruppe „*water_GR*“ fällt, würde sie ebenfalls die Nachbarschaft zu sich selbst abfragen. Eine Folge wären Fehlklassifikationen in Bereichen, die benachbart sind, aber definitiv kein Wasser mehr sein können.




Abb. 26: Level 2 - Detailklassifikation Wasser (Links Vererbung; Rechts Gruppierung) IKONOS April 2001. Der Wert in Klammern gibt die Segmentierungsebene an, I2 = Level 2

Level 1 – Feuchtgebiete, April 2001

Die Abbildung unten (Abb. 27) zeigt, dass die detaillierte Klassifikation der Feuchtgebiete den komplexesten Teil der Klassenhierarchie ausmacht. Mit Hilfe der Klasse „*wetland area from level 4*“ wurden die Grenzen der potentiellen Feuchtgebiete und Moorflächen von Level 4 in diesen Level übertragen, so dass nur noch innerhalb dieser Grenzen gearbeitet wurde. Im Falle der eingebundenen externen Waldmaske sind bewaldete Gebiete bereits ausmaskiert worden. Für die Wasserflächen wurde die detaillierte Klassifikation von Level 2 direkt genutzt.




Abb. 27: Level 1 - Detailklassifikation Feuchtgebiete (links Vererbung; rechts Gruppierung) IKONOS April 2001. Der Wert in Klammern gibt die Segmentierungsebene an, I1 = Level 1

Niedermoorbereiche wurden mit Hilfe von drei Klassen definiert, die zu einer semantischen Gruppe („*sedge dominated lowland moor*“) gehören. Die Klasse „*reed_GR*“ grenzt Schilfbereiche im Vorfeld ab und vererbt ihre Informationen an zwei Unterklassen. Mit Hilfe von diesen zwei Klassen („*reed dense crop*“ und „*reed/sedge mosaic close to water*“) wurden dichte Schilfbestände von solchen mit lockerem Bestand abgegrenzt, deren Eigenschaften oft von Seggenbeständen dominiert wurden. Alle Klassen, die „*fill in*“ im Namen tragen dienen dazu, Lücken in Bereichen zu schließen, die zu 90% von einer bestimmten Klasse umgeben sind, aber nur aufgrund einer erweiterten spektralen Objektdefinition klassifiziert werden konnten.

Moorklassen konnten nur innerhalb der auf Level 4 klassifizierten potentiellen Moorbereiche weiter untergliedert werden. Diese Information wurde auf die Kindklassen „*open moor*“ und „*moor, shrub encroachment*“ weitervererbt. Diese wiederum unterteilen die Moorflächen aufgrund der im ersten Schritt aus den PAN-Daten abgeleiteten Texturinformation in offene und verbuschte Bereiche, welche zusammen eine semantische „Moor“-Gruppe bilden.

Mit der Klasse „*forested wetland/bushland*“ wurden ebenfalls anhand von Texturinformationen Bereiche innerhalb der Feuchtgebiete abgegrenzt, die mit Bäumen oder Büschen, bestanden sind.

5.1.1.2 Vererbungshierarchie und semantische Gruppen im August 2001

Level 4 – Vorklassifikation, August 2001

Auch im August wurde die Vererbung auf Level 4 nur für die Klasse Wasser genutzt. Wasser wurde als Oberklasse für Kanäle („*channels*“) und offene Wasserflächen („*open water*“) definiert (Abb. 28 links). Letztere war beispielsweise gekennzeichnet durch eine niedrige spektrale Reflexion im NIR, einen sehr niedrigen NDVI (keine Vegetation) sowie eine geringe Textur (bestimmt durch den Parameter Homogenität der GLCM) und hohe Werte in der Ratio blau/NIR. Des Weiteren durfte ein Objekt nicht bereits erfolgreich als Kanal klassifiziert sein, um bei mehreren Klassifikationsdurchläufen die Klasse Kanal abzusichern. Die exakte Definition der Klasse innerhalb der Klassenhierarchie befindet sich in Anhang 1. Einzelne Klassen werden zusätzlich detailliert in Abschnitt 5.2 erläutert.




Abb. 28: Level 4 - Vorklassifikation (Links Vererbung; Rechts Gruppierung) IKONOS August 2001. Der Wert in Klammern gibt die Segmentierungsebene an, 14 = Level 4

Die oben aufgeführten Eigenschaften der Klasse Wasser wurden an die Unterklassen „channels“ und „open water“ weitervererbt. Diese beiden Klassen unterscheiden sich aufgrund der Definition von Länge zu Breite eines Objektes. Da Kanäle i. d. R. länglicher sind, werden sie vom restlichen offenen Wasser abgegrenzt.

Semantische Gruppen (dargestellt in Abb. 28 rechts) wurden nur für die Wasser- und Kanalklassen (siehe Markierung) kreiert, um die spätere Abfrage zu vereinfachen. So muss z. B. auf Level 2 nur noch abgefragt werden, ob ein auf Level 4 existierendes Objekt bereits als Kanal klassifiziert ist. Kanäle mit Vegetation sind in dieser Gruppe bereits mit enthalten und werden so ebenfalls berücksichtigt.

Level 3 – Externe thematische Informationen, August 2001

Bei dem Augustregelwerk wurde ebenfalls die Waldklassifikation des Projektpartners zur Anpassung der Feuchtgebietsobjekte als externer Layer genutzt. Die Verwendung dieser Information erfolgte entsprechend der Auswertung im April (siehe dort).

Level 2 – Wasser, August 2001

Der in Abb. 29 dargestellte Level 2 enthält eine detaillierte Klassifikation der Wasserflächen. Die Vererbung erfolgt hier von einer übergeordneten Wasserklasse („Wasser_GR“), um durch die Kindklassen die Wasserfläche in Tiefwasser- und Flachwasserbereiche zu unterteilen. Diese Klassen arbeiten innerhalb der in Level 4 bereits abgegrenzten Wasser- und potentiellen Feuchtgebietsklassen und korrigieren diese gegebenenfalls. Um noch nicht erfasste Flächen zu klassifizieren, existieren außerhalb der Vererbungshierarchie zwei weitere Klassen, die zum einen submerse Vegetation („shallow water/submersed vegetation“) erfassen und zum anderen sich in kleinste Kanäle „vortasten“ („small channels (corrected)“). Die Gruppenhierarchie zeigt hier, dass nahezu alle Wasserklassen in der Gruppe „water_GR“ zusammengefasst wurden. Auch hier bildet die Klasse „small channels (corrected)“ die bewusste Ausnahme, die Fehlklassifikationen vermeiden hilft.




Abb. 29: Level 2 - Detailklassifikation Wasser (Links Vererbung; Rechts Gruppierung) IKONOS August 2001. Der Wert in Klammern gibt die Segmentierungsebene an, I2 = Level 2

Level 1 – Feuchtgebiete, August 2001

Die Klassenhierarchie für die Augustdaten unterscheidet sich strategisch nicht von der für die Aprildaten. Einzelne Klassen wurden teilweise über unterschiedliche Parameter definiert. Eine Darstellung dieser Unterschiede findet in Abschnitt 5.2 statt.




Abb. 30: Level 1 - Detailklassifikation Feuchtgebiete (Links Vererbung; Rechts Gruppierung) IKONOS August 2001. Der Wert in Klammern gibt die Segmentierungsebene an, I1 = Level 1

5.1.1.3 Vererbungshierarchie der multisaisonalen Daten August & April

Bei der Auswertung der multisaisonalen Daten wurden die multispektralen IKONOS-Szenen von April und August zusammen mit den panchromatischen Bildern in einem eCognition Projekt kombiniert.

Segmentierungsparameter				
	Kanal Gewichtung	Scale Parameter	Homogenität	Ø Segmentgröße
Level 2 (class seg.)	Aug. Blau = 1 Aug. Grün = 1 Aug. Rot = 1 Aug. NIR = 1 Aug. PAN = 0	0 (klassifikations- basiert)	Color = 0.8 Smoothness = 0.8	2800
Level 1 (Feuchtg.)	Apr. Blau = 1 Apr. Grün = 1 Apr. Rot = 1 Apr. NIR = 1 Apr. PAN = 0	100	Color = 0.8 Smoothness = 0.8	2300

Tab. 8: Segmentierungsparameter für multisaisonale IKONOS-Daten

Zunächst wurden die gleichen Parameter wie bei der Multispektralklassifikation für die Segmentierung genutzt. Aufgrund der Verwendung von sehr hoch auflösenden panchromatischen Kanälen weichen die Objekte von der ursprünglichen Segmentierung ausschließlich bei den multispektralen IKONOS-Daten ab. Sie scheinen insgesamt kleiner, obwohl die durchschnittliche Objektgröße sich im gleichen Rahmen bewegt. Aus diesem Grund wurde ein Level 1 mit größeren Objekten segmentiert (Tab. 8) und klassifiziert (siehe Klassenhierarchie in Abb. 32). Direkt im Anschluss wurde auf Basis dieser Klassifikation ein hierarchisch höher liegender Level 2 erzeugt (*classification based segmentation*), in dem Feuchtgebiets- und Wasserobjekte entsprechend der „*structure groups*“ (Abb. 31) zusammengefasst wurden. Das bedeutet, dass alle aneinander angrenzenden Objekte der gleichen Klasse zu einem Objekt vereinigt wurden.




Abb. 31: "Structure groups" des multisaisonalen Datensatzes für die klassifikationsbasierte Segmentierung

Im Anschluss an diese Schritte wurde der neu entstandene Level klassifiziert. Hier sollten mit Hilfe von Formparametern Fehlklassifikationen in offensichtlichen Acker- oder Wiesenstrukturen sowie zum Teil beschattete Einzelbäume, die ebenfalls fälschlich als Feuchtgebiet klassifiziert wurden, korrigiert werden. Diese Problembereiche werden in der Diskussion in Abschnitt 6.2 noch einmal aufgegriffen. Mit dieser Information wird Level 5 erneut klassifiziert, und diese Fehler auch hier beseitigt.


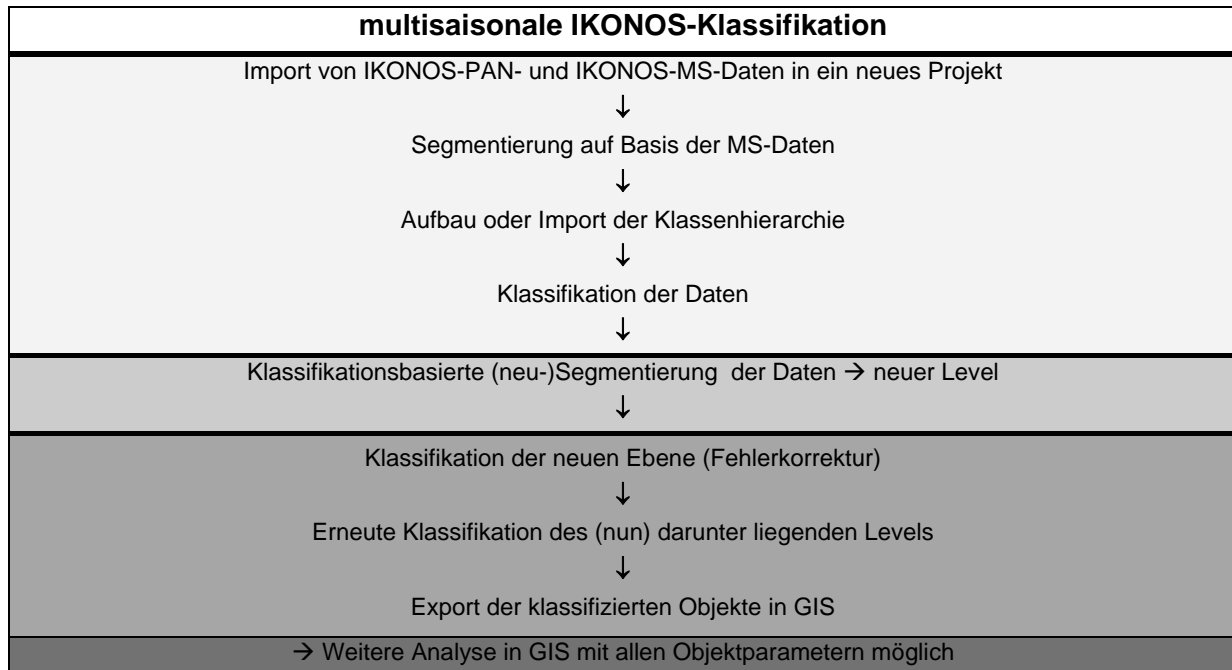


Abb. 32: Level 5 und 6 - kombinierte IKONOS-Daten – multisaisonaler Datensatz (Links Vererbung; Rechts Gruppierung) . Der Wert in Klammern gibt die Segmentierungsebene an, l6 = Level 6

Aufgrund der Kombination zweier Aufnahmezeitpunkte der IKONOS Daten ließen sich zum einen Feuchtgebietsklassen einfacher beschreiben (vgl. auch Anhang 1), zum anderen Objekte, die einen starken Jahresgang aufwiesen, überhaupt erst klassifizieren. Submerse Makrophyten und Schwimmblattvegetation („*water lilies*“) kamen nur in der Augustaufnahme an Stellen vor, die im April als Wasser klassifiziert wurden.

Die Gruppenhierarchie (Abb. 32 rechts) weicht nur auf Level 5 von der Vererbungshierarchie ab, in welcher die Objekte „*water lilies*“ und „*submerged macrophytes*“ zunächst Eigenschaften der Vaterklasse „*water*“ erben, aber semantisch der Gruppe Feuchtgebiet zugeordnet werden. Die folgende Tabelle (Tab. 9) zeigt das komplette Ablaufschema der multisaisonalen Klassifikation. Es ist etwas einfacher strukturiert als die Schemata der bisher

vorgestellten Klassenhierarchien. Die Klassifikation stellt aber hohe Anforderungen an Rechenleistung und Speicherplatz.



Tab. 9: Ablaufschema einer objektorientierten Klassifikation multisaisonaler IKONOS-Daten

5.1.2 Klassifikation von CASI-Daten

Die hyperspektralen CASI Daten wurden ebenfalls in einem streng hierarchischen Verfahren klassifiziert. Es wurden zunächst auf unterschiedlichen Levels in verschiedenen Maßstabsebenen thematisch übergeordnete Klassen ausgeschieden (Tab. 10).

Auch hier wurden die Parameter für die Segmentierung aus den vorher erwähnten Gründen (vgl. Abschnitt 5.1.1) in mehreren Testläufen ermittelt. Auf drei Maßstabsebenen wurden zunächst 4 Levels erzeugt. In einem zweiten Schritt wurden weitere Levels einer größeren Maßstabsebene hinzugefügt. Drei verschiedene Ansätze wurden miteinander visuell verglichen:

1. Segmentierung unter Einbeziehung aller Kanäle
2. Gewichtung ausschließlich der ersten 18 Kanäle
3. ausgesuchte Kanäle aus dem blauen, grünen, roten Spektrum und dem NIR.

Trotz aller theoretischen Überlegungen zeigte der erste Ansatz unter Einbeziehung aller vorhandenen Kanäle die besten Ergebnisse. Für detaillierte Angaben zur Segmentierung der Datensätze sei auf die Diplomarbeit von Löschenbrand (2003) im Rahmen des Projektes AQUATIC verwiesen.



Tab. 10: Ablaufschema einer Klassifikation hyperspektraler CASI-Daten

5.1.2.1 Vorausscheidung eindeutiger Klassen (nach Löschenbrand 2003)

Die hier zum Teil abweichenden Klassennamen sind durch den anderen Bearbeiter zu erklären. Die Klassen des Endergebnisses stimmen inhaltlich jedoch überein.

Level 7: Wasser - Nicht-Wasser

Wasser ließ sich mit Hilfe der den CASI-Daten einfach über die Nutzung einer Ratio (blau/rot (Lichtenthaler et al. 1996)) abgrenzen. Fehlklassifikationen wurden vermieden und fehlende Objekte später bei der Detailklassifikation auf Level 3 ergänzt (Abb. 33).



Abb. 33: Level 7 und 3 – Links: Wasser Vorklassifikation; rechts: Detaillierte Reklassifikation auf niedrigerem Level; CASI-Daten. Der Wert in Klammern gibt die Segmentierungsebene an, 3 = Level 3

Level 6: Wald - Nicht-Wald

Wälder wurden bereits auf diesem Level in reine Fichtenbestände, Nadelmischwald und Laubmischwald unterteilt. Die im Testgebiet vorhandenen Moorwälder konnten nicht klassifiziert werden. Sie verteilen sich auf die drei Waldklassen. Bereiche mit geringem Beschriftungsgrad wurden der Klasse Laubmischwald zugeordnet.

Level 5: anthropogene - nicht anthropogene Bereiche

Da für die Klassifikation natürliche Flächen relevant sind, wurden hier versiegelte Flächen zusammen mit landwirtschaftlich genutzten Flächen als anthropogene Bereiche klassifiziert. Versiegelte Bereiche wurden in Siedlungsfläche und Straßen unterschieden, landwirtschaftliche Objekte in Äcker, Wiesen und abgeerntete Bereiche unterteilt.

Level 4: offene Hochmoorflächen - andere Feuchtgebiete

Bereits auf diesem Level konnten in den Moorbereichen offene Hochmoorflächen von Flächen mit Verbuschungsstadien abgegrenzt werden. Moorbereiche mit Verbuschungstendenzen werden in der Endklassifikation einer Waldklasse zugeordnet. Die vorhandenen Entwässerungsgräben ließen sich aber aufgrund des über die Segmentierung gewählten Maßstabs erst auf einem unteren Level (Level 2: Feuchtgebiete detailliert) klassifizieren.

5.1.2.2 Detaillierte CASI-Klassifikation


Level 3: Wasser detailliert

Fehlklassifikationen z. B. aufgrund ungünstig segmentierter Objekte auf Level 4, die als Feuchtgebiet klassifiziert wurden, konnten hier korrigiert werden. Verbindungskanäle zwischen den Osterseen wurden erkannt. Ebenso wurden Bereiche mit Gewässervegetation klassifiziert (vgl. Abb. 33 Klasse „*water + vegetation (3)*“)

Level 2: Feuchtgebiete detailliert

Die auf dem vierten Level grob als „Rest“ abgegrenzten Feuchtgebiete wurden hier im Detail erneut klassifiziert. Im Wesentlichen wurde ein Distanzparameter zu Wasser eingesetzt, um zu vermeiden, dass Waldlichtungen und Waldränder fälschlich als Feuchtgebiet klassifiziert werden. Da sich das Projekt AQUATIC mit naturschutzrelevanten Flächen der Uferbereiche beschäftigt und aufgrund von Definitionen in der Literatur (vgl. Sader et al. 1995), ist die Verwendung dieses Parameters zulässig.

Fehlklassifizierte Waldbereiche wurden in Feuchtwälder und „echte“ Fehlklassifikationen unterschieden. Des Weiteren wurden hier Flächen mit hohem und niedrigem Schilfanteil klassifiziert. Der Rest ist Wasser oder Schatten, der den Waldlichtungen zugeordnet wurde.



**Abb. 34: Level 2 - Detaillierte Feuchtgebietsklassifikation aus den hyperspektralen CASI-Daten.
Der Wert in Klammern gibt die Segmentierungsebene an, 2 = Level 2**

Level 1: Zusammengefasste Landbedeckungsklassifikation


Die Zusammenführung aller Teilklassifikationen auf einem gemeinsamen Level ermöglichte die Unterscheidung der folgenden Klassen (die detaillierten Klassenhierarchien befinden sich im Anhang der Diplomarbeit von Löschenbrand (2003)):

Gruppe	Klasse
Offene Hochmoorflächen	Offene Hochmoorflächen (Verbuschungsstadien auf offenen Hochmoorflächen) Entwässerungsgräben (renaturiert)
Feuchtgebiete	Gehölzdominierte Bereiche (Einzelbäume) Feuchtfächen mit geringem Schilfanteil Feuchtfächen mit hohem Schilfanteil
Wasser	Flachwasser Tiefwasser
Wald	Fichtenwald(-forst), Reinbestand Nadelmischwald Laubmischwald Waldlichtungen
Landwirtschaft	Ackerland Wiese und Weide Abgeerntete Flächen
Versiegelte Flächen	Siedlung und Verkehr

Tab. 11: Klassen der finalen CASI-Auswertung

5.1.3 Klassifikation von Orthofotos

Die Einbindung von panchromatischen Luftbildern bzw. Orthofotos erfolgte unter anderem aufgrund ihrer deutlich höheren räumlichen Auflösung. Diese ist für die angestrebte lokale Maßstabsebene unverzichtbar. Vor allem wurden sie aber wegen der vielerorts vorhandenen Luftbildarchive mit herangezogen. Luftbildarchive können mit Hilfe von Zeitreihen multitemporale Auswerteverfahren für die Analyse von Landschaftsveränderungen in einem großen Maßstab unterstützen.



Tab. 12: Ablaufschema einer Klassifikation von s/w Luftbild-Daten

Bei der Auswertung der Orthofotos wurde ähnlich wie bei den CASI-Daten ein streng hierarchischer Ansatz verfolgt. Auf vier Levels wurden zunächst sichere Klassen ausgeschieden, um im weiteren Verlauf auch die heterogenen, schwer zu klassifizierenden Bereiche, wie Feuchtgebiete zu erfassen.

Es werden möglichst stabile Merkmale verwendet, um Klassen abzugrenzen. Wird ein digitales Oberflächenmodell verwendet, dann wird der Höheninformation der Vorzug vor der sehr variablen Grauwertinformation gegeben.

Bei diesem Auswertungsansatz wurden innerhalb der Levels zwei und vier die Hauptklassen hierarchisch abgegrenzt. Die Klassen wurden hier zunächst grob unterschieden in „Wasser“ – „nicht Wasser“, darunter in „Siedlung“ – „nicht Siedlung“ und weiter in „Wald“ – „nicht Wald“ (vgl. Abb. 35). Unterhalb der Hauptklassen wurden aber, soweit auf diesem Level bei der jeweiligen Objektgröße möglich, Detailklassen ausgewiesen. Beispielsweise konnten unterhalb der Klasse „nicht Wald“ auf Level 2 detailliert Feuchtgebietsklassen unterschieden werden. Sichere Klassen, also vergleichsweise leicht zu klassifizierende Objekte, stehen in der Klassenhierarchie an oberster Stelle. Wasserflächen lassen sich trotz der eingeschränkten spektralen Information der Orthofotos vergleichsweise leicht anhand ihrer Homogenität und der niedrigen Grauwerte abgrenzen (vergleiche auch Tab. 15 in Abschnitt 5.2). Der

unklassifizierte Rest fällt so automatisch in die Klasse „nicht Wasser“ und wird dann wie oben beschrieben weiter behandelt.

Für die Auswertung lag ein multitemporaler Datensatz aus mehreren Jahren (Tab. 13) vor, dessen einzelne Aufnahmen jeweils andere Charakteristika (vgl. Abschnitt 4.3) aufwiesen. Aus diesem Grund bestehen leichte Unterschiede in den Klassenhierarchien der einzelnen Jahre.

Jahrgang	1956	1964	1976	1999	2000
Höhenmodell	X	X		X	X

Tab. 13: Jahrgänge der verwendeten Luftbildzeitreihe, X = Höhenmodell vorhanden

Beispielsweise ändert sich die Klassenhierarchie des Jahres 1999 dahingehend, dass mit Nutzung des Oberflächenmodells neben den reinen Feuchtgebieten zusätzlich Gehölze in Feuchtgebieten sowie Hochmoorbereiche ausgewiesen werden können.

Für die spätere Übertragung wurde eine erste Klassenhierarchie für das Testgebiet „Iffeldorfer Seengruppe“ erstellt. Zu den hier verwendeten Testgebieten muss erwähnt werden, dass es sich, mit Rücksicht auf die hohe räumliche Auflösung der Orthofotos sowie des DOMs und den daraus resultierenden Anforderungen an die Rechenzeit, um Ausschnitte der in 4.1 vorgestellten Testgebiete handelt. Nach Übertragung dieser ersten Klassenhierarchie müssen in den einzelnen Jahren mit Rücksicht auf die unterschiedlichen Eigenschaften der Luftbild-Daten Anpassungen durchgeführt wurden. Die eigentliche Strategie zur Klassifikation, also die Klassenhierarchie, bleibt aber dieselbe.




Abb. 35: Vererbungshierarchien der Level 2, 3 und 4 der Orthofotoklassifikation (die Gruppenerbungen sind identisch aufgebaut und werden nicht gesondert dargestellt). Die mit L- kodierte Werte geben die Segmentierungsebene an, L2 = Level 2

Das Konzept, zunächst sichere Klassen auszuscheiden, unterstützt die Forderung nach möglichst einfachen und leicht übertragbaren Klassenhierarchien. Aus der obigen Abbildung (Abb. 35) ist leicht erkennbar, dass „einfach“ relativ zu sehen ist. Bei den Orthofotos steht nur sehr wenig Information aus Grauwerten zur Verfügung, und auch abgeleitete Merkmale wie Textur trennen Klassen nicht immer eindeutig. Aus diesem Grund sind Klassendefinitionen, die sich im Merkmalsraum überlappen, häufiger. Um solche Überschneidungen zwischen einzelnen Klassen weitestgehend zu vermeiden, wurden sehr viele Teilklassen erstellt, z. B. sechs Klassen nur für die Erfassung von Flachwasserbereichen. Diese Klassen wurden in eCognition zu semantischen Gruppen zusammengefasst und stellen sich für den späteren Anwender als eine Klasse „Flachwasser“ dar. Eine detaillierte Beschreibung der Klassifikationsstrategie wurde im Rahmen einer Diplomarbeit im Projekt AQUATIC angefertigt (Rogg 2003).

5.1.4 Strategieunterschiede

Die verwendeten Datengrundlagen weisen sehr unterschiedliche Charakteristika auf. Um zu vergleichbaren Klassifikationsergebnissen zu kommen, bzw. um die Ergebnisse mit einem multisensoralen Ansatz zu verbessern, müssen die jeweiligen Herangehensweisen voneinander abweichen. Zusätzlich ist die Vorgehensweise immer auch vom jeweiligen Bearbeiter geprägt, da es keinen „Königsweg“ zum gewünschten Ziel gibt (siehe hierzu auch in der Diskussion die Abschnitte 6.2 und 6.3).

Klasse	IKONOS	CASI	Orthofotos
Wasser	X	X	X
Tiefes Wasser	X	X	X
Flachwasser	X	X	X
Verbindungskanäle	X	X	X
Submerse Makrophyten	X	Aufnahmezeitpunkt	Aufnahmezeitpunkt
Schwimmblattvegetation	X	Aufnahmezeitpunkt	O (nur 1956)
Boote	Räuml. Auflösung	Räuml. Auflösung	X
Schilf	X	X	X
Dichtes Schilf	X	X	Keine spektrale Diff.
Seggendominiert	X	X	Keine spektrale Diff.
Verbuschtes Feuchtgebiet	X	X	X
Moor	X	X	X
Offene Moorbereiche	X	X	O (als Hochmoor)
Verbuschte Moorbereiche	X	O (als Feuchtwald)	Keine spektrale Diff.
Entwässerungskanäle	X	X	Nicht im Testgebiet
Wald	O (als externer Layer [*])	X	X
Einzelgehölz	X	Räuml. Auflösung	X
Siedlungsgrün	Räuml. Auflösung	Keine Differenzierung	X
Lichtung	Spektrale Überlappung	X	Spektrale Überlappung
Lineare Gehölze	X	Segmentierung	X
Siedlung/Verkehr	O (als externer Layer [*])	O (versiegelte Fläche)	X
Siedlung	X	Keine weitere Unterteilung gefordert	X
Straßen	X		X
Landwirtschaft	O (als externer Layer [*])	X	Nicht bearbeitet
Wiese/Weide	X	X	
Acker	O (Mais)	X	
Acker abgeerntet	X	X	

* der externe Layer stammt aus der objektorientierten IKONOS-Klassifikation des Projektpartners

Tab. 14: Gegenüberstellung der mit unterschiedlichen Sensoren erkannten Klassen: X = erkannte Klasse; O = teilweise erkannte Klasse; Text = Begründung für Fehlklassifikationen

Die obige Tabelle (Tab. 14) zeigt, dass der überwiegende Teil der klassifizierten Landbedeckungen sensorübergreifend erkannt wird. Natürlich ergeben sich Abweichungen, für die in der Tabelle stichwortartig Begründungen angegeben sind (genauer hierzu in der

Diskussion, in Abschnitt 6.3). Diese Differenzen sind auf die Unterschiedlichkeit der Datensätze zurückzuführen. So lassen sich beispielsweise Boote auf der Seefläche nur mit Hilfe der sehr hohen Auflösung der Orthofotos sinnvoll segmentieren und klassifizieren. Für die spektrale Differenzierung von dichtem Schilf und eher seggendominierten Beständen sowie bei offenen und verbuschten Moorbereichen sind die Orthofotos allerdings eher ungeeignet. Auch die zusätzlichen Objekteigenschaften aus eCognition konnten diese spektralen „Mängel“ nicht kompensieren, da auch Texturparameter oft nicht in der Lage waren, die erfolgreich erkannten Oberklassen Schilf und Moor weiter zu differenzieren.

Der Unterschied zeigt sich bereits in der allgemeinen Herangehensweise. Während die Auswertung der CASI-Daten streng hierarchisch auf unterschiedlichen Levels jeweils Oberklassen ausgeschieden hat, die dann sukzessive auf niedrigeren Levels verfeinert wurden, folgen die IKONOS- und Orthofotoklassifikationen nicht so streng diesem Schema. Mit Hilfe der Orthofotos wurden zwar ebenfalls hierarchisch auf mehreren Levels Oberklassen erzeugt, diese wurden aber bereits innerhalb der Klassenhierarchie für den jeweiligen Level differenziert (vgl. Abb. 34). Die IKONOS-Klassenhierarchie stützt sich im Gegensatz zu den beiden vorher erwähnten auf Teilklassifikationen des panchromatischen Datensatzes und versucht zunächst auf nur einem Level einer hohen Hierarchiestufe eine Vorklassifikation auszuweisen. Diese wird dann in mehreren Schritten auf niedrigeren Levels einer größeren Maßstabsebene erneut detailliert klassifiziert (vgl. Tab. 7).

5.2 Objektdefinitionen

Um die vorliegenden Datensätze vergleichbar zu klassifizieren, ist es notwendig, jeweils gleiche Objekte herauszuarbeiten. Aufgrund der unterschiedlichen spektralen, geometrischen und radiometrischen Charakteristika der Datengrundlagen führt dieser Ansatz jeweils zu einer spezifischen Auswahl und Kombination von Objekteigenschaften für die Klassifikation.

Im Folgenden werden die verwendeten Objektparameter tabellarisch einander gegenüber gestellt und mit Informationen für eine visuelle Interpretation dieser Objekte verglichen. Die Angaben zur visuellen Interpretation stammen überwiegend aus einer Kartieranleitung des Bundesamtes für Naturschutz (1995). Zusätzlich wurden Hinweise zur Interpretation von Landbedeckungen u. a. aus Dierßen und Dierßen (2001), Reichholf (1988) und Sader et al. (1995) berücksichtigt.

Dieses Expertenwissen bzw. die Erfahrungswerte eines Interpreten lassen sich oft nicht direkt und vollständig in der Logik der Regelwerke von eCognition abbilden. Bei der Übertragung muss der Fernerkundungshintergrund berücksichtigt werden, d. h. der im Vergleich mit der menschlichen Erfahrung eingeschränkte Informationsgehalt der Luft- bzw. Satellitenbilder. Ebenso muss aber auch die zusätzliche Information wie etwa das erweiterte spektrale „Wissen“ oder die große räumliche Abdeckung bei der Objektbeschreibung beachtet werden (vgl. hierzu auch Abschnitt 6.3).

Die folgenden tabellarischen Angaben stellen jeweils aggregierte Informationen dar. Das bedeutet, dass hierbei Vererbungsstrukturen nicht angegeben sind, sondern verwendete Objekteigenschaften auch über hierarchische Strukturen und mehrere verbundene Klassen hinweg zusammen in die Beschreibung eingehen.

Diese Darstellung der verwendeten Objekteigenschaften ist in dieser Form „nur“ für den Überblick und zur Gegenüberstellung der Klassendefinitionen erzeugt worden. Die exakten Klassendefinitionen inklusive der Wertebereiche und Zugehörigkeitsfunktionen sind zu komplex und unübersichtlich für diesen Zweck. Sie befinden sich deshalb vollständig im Anhang zu dieser Arbeit sowie in den Anhängen zu den Diplomarbeiten von Löschenbrand (CASI-Daten) und Rogg (Orthofotos) (Löschenbrand 2003, Rogg 2003). Die Klassendefinitionen aus dem Anhang können direkt in eCognition-Regelwerke umgesetzt werden und dienen quasi als „Kochrezept“ für die in dieser Arbeit entwickelten Regelwerke¹⁷. Anpassungen sind je nach Unterschiedlichkeit der betreffenden Daten, z. B. Aufnahmezeitpunkt, notwendig, aber i. d. R. gering. Es müssen nur die spektralen und die von diesen abhängigen Parameter (die so genannten instabilen Eigenschaften) angepasst werden. Im Folgenden sind die Gegenüberstellungen für ausgewählte Klassen tabellarisch mit anschließenden Kommentaren dargestellt:








Wasser visuell*:	Wasser eCognition IKONOS:	Wasser eCognition CASI:	Wasser eCognition Orthofotos:
Dunkel, fast schwarz im NIR Flachwasser erscheint in Blau und grün Homogen Große Flächen	Spektraler Mittelwert NIR Texturparam.: Homogenität NDVI Blau/NIR Verhältnis Länge zu Breite <i>(als Abgrenzung zu Kanälen)</i>	Ratio: blau(489nm)/NIR(739nm) – nach Lichtenthaler Spektr. Mittelwert NIR (922nm)	Spektr. Mittelwert Luftbild Texturparam.: Homogenität Formindex Mittlere spektr. Abweichung zu den Nachbarobjekten
* Visuell: Farbton bezieht sich auf CIR Falschfarbendarstellung (nach Bundesamt für Naturschutz (BfN) 1995)			

Tab. 15: Objektdefinitionen im Vergleich: Wasserflächen insgesamt

Die Klasse **Wasser** (Tab. 15) lässt sich im Normalfall sehr einfach klassifizieren, insbesondere wenn Spektralkanäle im nahen Infrarot zur Verfügung stehen.

In dieser (Ober-)Klasse sollten möglichst alle Wasserobjekte integriert werden, unabhängig davon, ob es sich um tiefes Wasser, Flachwasser oder Bereiche mit Vegetation handelt. Entsprechend aufwendig zeigt sich auch die IKONOS-Klassendefinition, die zusätzlich zum NIR auch einen Texturparameter, einen Vegetationsindex (NDVI) und die Ratio Blau/NIR benötigt. Aufgrund der vielen zur Verfügung stehenden Spektralkanäle ist die Definition auf Basis der CASI-Daten einfacher. Eine Kombination aus einer Blau/NIR-Ratio (nach Lichtenthaler (vgl. Drexel 2002, Löschenbrand 2003)) und nahem Infrarot bei 922 nm reicht hier für die Beschreibung aus. Die Orthofotos bieten nur einen Kanal und decken mit diesem ausschließlich das Spektrum des sichtbaren Lichts ab. Deshalb ist die Definition hier im Vergleich deutlich schwieriger und benötigt neben den Grauwerten zusätzlich Texturparameter, Formindizes und die Intensitätsunterschiede zu Nachbarobjekten.


¹⁷ eCognition bietet auch in seiner aktuellen Version 3.0 keine Möglichkeit, neue Klassenhierarchien aus Klassen unterschiedlicher, bereits bestehender Klassenhierarchien zusammenzusetzen. Deshalb wurde als Übergangslösung und einzige Möglichkeit der vollständigen Darstellung die Form der Tabellen im Anhang gewählt.

LEVEL 4: WASSER – IKONOS (AUGUST 2001)				
Vererbung	Klasse	Verwendete Objekteigenschaften	(Grau-) Wertebereich	Zugehörigkeitsfunktion
Level → → channels → open water	water	<i>And (min)</i> Ratio: blau / NIR Texturwert im NIR: GLCM Homogeneity NDVI Spektraler Mittelwert NIR Nicht bereits als “channels” klassifiziert	0.8/1/1.2 0.05/0.055/0.06 0.33/0.34/0.35 305/310/315 0/0.4/0.8	    
LEVEL 4: OFFENE WASSERFLÄCHE				
Level → water →	open water	<i>And (min)</i> Verhältnis Länge zu Breite Nicht bereits Mitglied von Klasse “channels”	12/13/14 0/0.5/1	 
Die Objekteigenschaften sind hier zur besseren Lesbarkeit umgangssprachlich dargestellt. In eCognition finden sie in dieser Form keine Verwendung, existieren aber selbstverständlich alle in der Objektdatenbank.				

Tab. 16: Detaillierte Klassendefinition der Wasserklassen auf Level 4 für IKONOS August 2001. Der Inhalt der Markierung wird im Text näher erläutert

Die oben stehende Tabelle (Tab. 16) stellt beispielhaft die vollständige Objektdefinition der Klasse Wasser auf Level 4 in der IKONOS-Klassifikation dar¹⁸.

Zur Lesart: Die Spalte „Vererbung“ zeigt mit einem Pfeil hinter dem Namen an, von welcher Klasse Objekteigenschaften geerbt wurden. Ein Pfeil vor einer Klassenbezeichnung markiert, an welche (Unter-)Klasse Eigenschaften vererbt werden. Die Spalte „Klasse“ enthält den Klassennamen. Die folgende Spalte enthält die verwendeten Eigenschaften inklusive ihrer logischen Verknüpfungen. Der „Wertebereich“ gibt zusammen mit der letzten Spalte die Zugehörigkeitsfunktion der jeweiligen Eigenschaft wieder.

Dieses Beispiel bleibt das einzige dieser Art im Ergebnisteil dieser Arbeit. Es soll an dieser Stelle illustrieren wie Objekteigenschaften kombiniert werden, und die logische Struktur der Objektdefinition innerhalb eines Regelwerks demonstrieren. Gezeigt wird, dass die für den obigen Vergleich (Tab. 15) notwendige Vereinfachung gerechtfertigt ist, Klassen aber über komplexere logische Verknüpfungen von Eigenschaften und Vererbungsstrukturen definiert werden. Es kann aber nur aus dieser Art von Tabelle der verwendete Wertebereich pro Objekteigenschaft ermittelt werden. Aus der Tabelle ist direkt ablesbar, dass z. B. eine geringe Reflexion im nahen Infrarot (Spektraler Mittelwert NIR in der fünften Zeile, markiert) mit Grauwerten unterhalb von 315 aufgrund der dargestellten Funktion () die Definition von Wasserflächen bestimmt. Sinnvoll einordnen lässt sich diese Information nur mit dem Hintergrundwissen, dass sich der Wertebereich des IKONOS-Sensors über 4096 Graustufen (12 bit) erstreckt.

Im Folgenden werden weitere Objektdefinitionen gegenüber gestellt. Es wird jedoch nicht mehr auf die jeweiligen hierarchischen Abhängigkeiten oder Wertebereiche eingegangen. Hierfür sei auf den Anhang verwiesen.

¹⁸ Im Gegensatz zu den Tabellen im Anhang, welche die gesamte Klassenhierarchie enthalten, sind hier nicht die exakten Bezeichnungen der Objekteigenschaften aus der Datenbank verwendet worden, sondern umgangssprachliche Entsprechungen, um die Lesbarkeit zu verbessern.

Flachwasser visuell*:	Flachwasser eCognition IKONOS:	Flachwasser eCognition CASI:	Flachwasser eCognition Orthofotos:
Flachwasser erscheint in Blau und grün Homogen Große Flächen	<i>Nach Abgrenzung von Wasserobjekte auf höherem Level:</i> Spektraler Mittelwert grün Spektraler Mittelwert rot Spektraler Mittelwert NIR	<i>Nach Abgrenzung von Wasserobjekte auf höherem Level:</i> Spektraler Mittelwert rot	<i>Beispielhaft für 1999:</i> Spektraler Mittelwert Texturparam.: Homogenität Mittlere Diff. zu Nachbarobj. Nicht Tiefwasser Rel. Grenze zu Tiefwasser Rel. Grenze zu Flachwasser

* Visuell: Farbton bezieht sich auf CIR Falschfarbendarstellung (nach Bundesamt für Naturschutz (BfN) 1995)

Tab. 17: Objektdefinitionen im Vergleich: Flachwasser

Nach der bereits erfolgten Abgrenzung der Wasserfläche stellt sich die Definition von **Flachwasserobjekten** (Tab. 17) einfacher dar. Bei den IKONOS-Daten sind nur spektrale Eigenschaften notwendig, bei den CASI-Daten wird nur ein einziger spektraler Wert benötigt. Eine Ausnahme bilden hier wiederum die Orthofotos. Die IKONOS-Definition folgt zum Teil der Angabe in der Kartieranleitung und bezieht die Reflexion im grünen Spektrum mit ein. Bei den Orthofotos müssen ein zusätzlicher Texturparameter und die Grauwertdifferenz zu Nachbarobjekten einbezogen werden. Darüber hinaus wird die Grenze zu bereits klassifizierten Tiefwasserobjekten und zu sich selbst, also bereits klassifizierten (vgl. 2.6.2.3) Flachwasserbereichen, herangezogen.

Feuchtgebiete visuell*:	Feuchtgebiete eCognition IKONOS:	Feuchtgebiete eCognition CASI:	Feuchtgebiete eCognition Orthofotos:
Dominiert von Hydrophyten Substrat ist wassergesättigt Nähe zu Wasserkörpern Geringe Hangneigung (<8%); Topographische Position in Mulden	Distanz zu Wasser NDVI Spektraler Mittelwert Blau Spektraler Mittelwert Rot Spektraler Mittelwert NIR NIR-Blau Standardabw. Blau Standardabw. Rot Nicht Wasser Nicht Wald (externe Info.)	<i>Nach Vorabgrenzung sicherer Klassen, wie z. B. Wasser oder anthropogen:</i> Spektraler Mittelwert Blau Spektraler Mittelwert NIR ⁽¹⁵⁾ Distanz zu Wasser Form: Länge/Breite	Distanz zu Tiefwasser Spektr. Mittelwert Rel. Grenze zu aquat. Schilf Rel. Grenze zu Flachwasser Rel. Grenze zu Feuchtgeb. Rel. Grenze zu Tiefwasser Kurze Grenze zu Gebäude Nicht Flachwasser Nicht Tiefwasser

* Visuell: Definition nach Sader et al. (1995, S.137), aus Feldbegehungen und nach NWI

Tab. 18: Objektdefinitionen im Vergleich: Feuchtgebiete insgesamt

Die allgemeine Klasse **Feuchtgebiete** ist sehr viel schwieriger zu definieren (Tab. 18). Aufgrund der Beschränkung auf Feuchtgebiete in der Nähe offener Wasserflächen ist die Verwendung der Eigenschaft Nähe bzw. Distanz zu Wasserkörpern erlaubt. Eine gewisse Entfernung zu Wasser darf bei allen Objektdefinitionen nicht überschritten werden. Die Abgrenzung von Hochmooren wird so allerdings erschwert und macht eine eigene Klasse notwendig. Die Angaben aus der visuellen Kartierung können mit Ausnahme der Distanzbeziehung überwiegend nicht direkt übernommen werden aber das Vorkommen von Hydrophyten und das wassergesättigte Substrat lassen sich über niedrige Grauwerte in den spektralen Objekteigenschaften, vor allem im NIR, ausdrücken, was auch bei allen drei Definitionen durchgehalten wird. Alle Objektdefinitionen verwenden jeweils Informationen von Oberobjekten, die bereits auf höheren Levels abgegrenzt wurden. Bei IKONOS dürfen Objekte nicht bereits als Wasser klassifiziert sein, während bei CASI über die hierarchische Strategie ohnehin nur noch innerhalb unklassifizierter Bereiche gearbeitet wurde. Die

Klassendefinition für die Orthofotos erfolgte über die relative Grenze zu benachbarten, evtl. im Merkmalsraum überlappenden Objektklassen.

Gewässervegetation visuell*:	Gewässervegetation eCognition IKONOS:	Gewässervegetation eCognition CASI:	Gewässervegetation eCognition Orthofotos: Nur 1956
<i>Schwimmbblatt:</i> Hellrosa Teppich Horizontale Strukturen Rote Schlieren im Wasser	Spektraler Mittelwert Rot Spektraler Mittelwert NIR Rel. Grenze zu Wasser (evtl. vollständig umgeben von Wasser) Im April klassifiziert als Wasser – im August nicht	Ratio: blau(489nm)/NIR(739nm) – nach Lichtenthaler Rel. Grenze zu Wasser Nicht Verbindungskanal Nicht Wasser Keine Wald Oberobjekte	<i>Schwimmbblatt:</i> Spektraler Mittelwert Rel. Grenze zu Wasser Nicht Wasser Nicht Wald Nicht Siedlung/Verkehr Innerhalb Feuchtgebiet

* Visuell: Farbton bezieht sich auf CIR Falschfarbendarstellung (nach Bundesamt für Naturschutz (BfN) 1995)

Tab. 19: Objektdefinitionen im Vergleich: Vegetation im Gewässer (vor allem Schwimmbblatt)

Die **Vegetation innerhalb von Wasserflächen** (Tab. 19) unterteilt sich in Schwimmbblatt- (Teich- (*Nuphar lutea*) oder Seerose (*Nymphaea alba*)) und submerse Vegetation (z. B. Tannenwedel (*Hippuris vulgaris*), Laichkraut (*Potamogeton spp.*) oder Tausendblatt (*Myriophyllum spicatum*). Sie lassen sich mit den in dieser Arbeit verwendeten Methoden und Daten aber nicht unterscheiden und werden als eine Klasse, „Gewässervegetation“ ausgewiesen. Eine Ausnahme bildet die Kombination beider Aufnahmezeitpunkte der IKONOS-Daten, welche die Erkennung vereinfacht. Anhand dieser Daten ist es möglich, mit Hilfe spektraler Eigenschaften nämlich der Grenze zu Wasser und den zeitlichen Unterschied zwischen April und August diese Informationen detaillierter herauszuarbeiten. Die CASI-Daten lassen sich in dieser Hinsicht aufgrund des späten Aufnahmezeitpunktes (Mitte September 1999) kaum auswerten. Bei den Orthofotos kann nur in den Daten aus dem Jahr 1956 die Klasse Schwimmbblatt erkannt werden. Nach Ausschluss von Klassen wie Wasser und Wald reicht ein einfaches spektrales Merkmal zusammen mit der relativen Grenze zu Wasser aus.

Moor (Hochmoor) visuell*:	Moor (Hochmoor) eCognition IKONOS:	Moor (Hochmoor) eCognition CASI:	Moor (Hochmoor) eCognition Luftbilder:
Regelmäßig verlaufende Parzellen (wg. menschl. Nutzung) - Gräben Heterogene Darstellung bzgl. Farbe und Textur Späte Vegetationsentwicklung Scharfgekörmte Musterung	<i>April:</i> Spektraler Mittelwert blau Spektraler Mittelwert rot Spektraler Mittelwert NIR Mittelwert 2. Hauptkomp. Mittlere Diff. zu Nachbarn im blauen Kanal NIR – blau Standardabweichung blau Nicht Feuchtgebiet <i>August zusätzlich:</i> NDVI Mittelwert 1. Hauptkomp. Rel. Grenze zu Moor Unklassifiziert	<i>Nach Vorabgrenzung sicherer Klassen, wie z. B. Wasser oder anthropogen:</i> Spektr. Mittelwert NIR (750nm) Distanz zu Wasser Rel. Grenze zu offenen Moorflächen	Spektraler Mittelwert Mittlerer Höhenwert Distanz zu Siedlung Nicht Flachwasser Nicht Siedlung Nicht Straßen

* Visuell: Farbton bezieht sich auf CIR Falschfarbendarstellung (nach Bundesamt für Naturschutz (BfN) 1995)

Tab. 20: Objektdefinitionen im Vergleich: offene (Hoch-)Moorbereiche, ohne Verbuschung

Wie bereits weiter oben bei den Feuchtgebieten angedeutet (S. 111), bereitet die Definition der Moorbereiche, speziell der **Hochmoorbereiche**, Schwierigkeiten (Tab. 20). Während sich die visuelle Kartierung überwiegend auf Strukturen der anthropogenen Nutzung verlassen muss, zeichnen sich Moorbereiche in Fernerkundungsdaten durch die spektrale Reflexion ihrer Vegetation aus. Diese ist tendenziell eher heterogen, weshalb die Objektdefinitionen komplexer werden. Vor allem bei den IKONOS-Daten werden diverse Parameter zusätzlich benötigt. Diese müssen die starke Heterogenität der Moor-Objekte berücksichtigen, beispielsweise über die „Standardabweichung“ oder die „mittlere Differenz zu benachbarten Objekten“. Für die Beschreibung dieser Klassen in den CASI-Daten bzw. den Orthofotos vereinfacht sich die Definition aufgrund der strengeren hierarchischen Vorgehensweise, die nach dem Ausschlussprinzip nur noch passende Objekte übrig lässt. In den Orthofotos lassen sich diese Bereiche aber nur mit Hilfe der Höheninformation aus dem DOM klassifizieren.

Verbuschte Feuchtg. visuell*:	Verbuschte Feuchtg. eCognition IKONOS:	Verbuschte Feuchtg. eCognition CASI:	Verbuschte Feuchtg. eCognition Luftbilder:
Dominiert von Hydrophyten Aufgelockerte Textur („gestört“ von Einzelbäumen und Büschen) Substrat ist wassergesättigt Nähe zu Wasserkörpern Geringe Hangneigung (<8%); Topographische Position in Mulden	<i>Nach Vorabgrenzung von Feuchtgebieten:</i> Distanz zu Wasser Texturparam.: Homogenität Spektraler Mittelwert rot Spektraler Mittelwert NIR	<i>Nach Vorabgrenzung sicherer Klassen, wie z. B. Wasser oder anthropogen:</i> Spektr. Mittelwert bl. (489nm) Spektr. Mittelwert rot (693nm) Spektr. Mittelwert NIR (750nm) Spektr. Mittelwert NIR (853nm) Grenze zu Waldobjekten Rel. Grenze zu Feuchtgebiet Nicht Waldlichtung	<i>Nach Erfassung der Einzelbäume auf niedrigem Level:</i> Rel. Fläche der Einzelbäume innerhalb von Feuchtgebietsobjekten

* Visuell: Definition angepasst nach Sader et al. (1995, S.137), aus Feldbegehungen und nach NWI

Tab. 21: Objektdefinitionen im Vergleich: Verbuschte Feuchtgebiete ohne Hochmoorbereiche

Die Objektdefinition von **verbuschten Feuchtgebieten** (Tab. 21) orientiert sich im Wesentlichen an der Abgrenzung der Feuchtgebiete (siehe oben) bzw. arbeitet nur noch innerhalb der abgeleiteten Feuchtgebiete.

Während bei den IKONOS-Daten Texturparameter zur Erkennung der verbuschten und damit rauerer Bereiche dienen, werden bei den Orthofotos zunächst Einzelbäume auf einem niedrigeren Level, der kleinere Objekte enthält, klassifiziert und letztlich deren Lage im Feuchtgebiet abgefragt. Aufgrund von Problemen mit stark ansteigender Rechenzeit bei Verwendung von Texturparametern wurde auf deren Nutzung bei den CASI-Daten verzichtet. Deshalb ist hier die Definition weniger präzise, da sie nur mit Hilfe von spektralen Eigenschaften in Kombination mit klassenbasierten Merkmalen zu angrenzenden Waldgebieten versucht, verbuschte Bereiche zu klassifizieren.

Röhricht (dicht) visuell*:	Röhricht (dicht) eCognition IKONOS:	Röhricht (dicht) eCognition CASI:	Röhricht (dicht) eCognition Luftbilder:
Rosa bis rote Struktur Partiell im Wasser Grenze zu Wasser Senkrechte Linienführung Große Fläche Spätes vegetatives Wachstum	<i>Nach Vorabgrenzung von Feuchtgebieten:</i> Distanz zu Wasser Spektraler Mittelwert Rot Spektraler Mittelwert NIR Relative Grenze zu Wasser Relative Grenze zu Schilf Standardabw. NIR	<i>Nach Vorabgrenzung sicherer Klassen, wie z. B. Wasser oder anthropogen:</i> Spektr. Mittelwert NIR (922nm) Nicht Feuchtwald Nicht Waldlichtung	Spektraler Mittelwert Rel. Grenze zu Tiefwasser Kurze Grenze zu Gebäude Nicht Flachwasser Nicht Tiefwasser

* Visuell: Farbton bezieht sich auf CIR Falschfarbendarstellung (nach Bundesamt für Naturschutz (BfN) 1995)

Tab. 22: Objektdefinitionen im Vergleich: Dichte Schilfröhrichtbestände

Dichte **Röhrichtbestände** (Tab. 22) zeichnen sich in dieser Definition u. a. durch ihre Nähe zu Wasser aus. Deshalb ist auch hier die Nutzung des Distanzparameters zu klassifizierten Wasserobjekten vertretbar. Zusätzlich wird neben den spektralen Werten im roten und infraroten Bereich auch die Standardabweichung im Infrarot herangezogen. Erstere erkennen den hohen Wassergehalt, insbesondere bei Wasserreflexion in weniger dicht stehenden Beständen, letztere berücksichtigt die im Vergleich zu Wasser oder Grünland heterogenere Struktur von Schilfbeständen. Bei den CASI-Daten und den Orthofotos macht sich wiederum die stark hierarchische Arbeitsweise bemerkbar. Hier reicht es aus, zusätzlich zum spektralen Mittelwert Ausschlussklassen (z. B. nicht Feuchtwald) zu definieren.

Röhricht/Seggen visuell*:	Röhricht/Seggen eCognition IKONOS:	Röhricht/Seggen eCognition CASI:	Röhricht/Seggen eCognition Luftbilder:
Nasse bis sehr nasse Standorte Außerhalb von Wasser Auf Niedermoorböden Substrat ist wassergesättigt Nähe zu Wasserkörpern Etwas dunkleres rot als reine Schilfbestände	<i>Nach Vorabgrenzung von Feuchtgebieten:</i> Distanz zu Wasser Spektraler Mittelwert blau Spektraler Mittelwert rot Spektraler Mittelwert NIR Standardabweichung rot Nicht als Schilf klassifiziert Rel. Grenze zu Seggen Rel. Grenze zu Wasser	<i>Nach Vorabgrenzung sicherer Klassen, wie z. B. Wasser oder anthropogen:</i> Keine neue Klasse → gleiche Definition, wie Niedermoor/Seggen Spektr. Mittelwert NIR (922nm) Feuchtgebiet auf Level 4 Nicht Feuchtwald Nicht Waldlichtung	Konnte nicht differenziert werden

* Visuell: Farbton bezieht sich auf CIR Falschfarbendarstellung (nach Bundesamt für Naturschutz (BfN) 1995)

Tab. 23: Objektdefinitionen im Vergleich: Lockere Schilfbestände, seggendominiert

Gemischte **Röhricht- und Seggenbestände** (Tab. 23) zeichnen sich durch eine abnehmende Schilfdichte und zunehmende Dominanz der Seggen im Reflexionsspektrum aus. Mit den IKONOS-Daten konnten diese Bereiche mit einigem Aufwand und Einsatz nahezu aller spektralen Parameter klassifiziert werden. Für die CASI-Daten entspricht deren Ableitung den seggenbestandenen Niedermoorbereichen. Innerhalb von bereits abgeleiteten Feuchtgebieten war hier ein spektraler Mittelwert an der äußersten Grenze des nahen Infrarots ausreichend. Innerhalb der Orthofotos ließ sich diese Klasse nicht mehr unterscheiden.

5.3 Klassifikationsergebnisse und –qualität

Mit Hilfe der Objektdefinition und deren Eingliederung in das jeweilige Regelwerk wurden nun die unterschiedlichen Testgebiete klassifiziert. Die Ergebnisse sind in diesem Abschnitt dargestellt. Die Klassifikationen der CASI-Daten und der Luftbilder sind in den Diplomarbeiten von Löschenbrand (2003) und Rogg (2003) enthalten. Ergebnisse dieser beiden Arbeiten werden daher nur in Ausschnitten präsentiert: Zum einen werden sie thematisch auf Feuchtgebiete eingegrenzt, zum anderen werden sie nur in den Bereichen dargestellt, die zur Verbesserung oder zum Vergleich mit den IKONOS-Klassifikationen dienen. Die Klassifikationsergebnisse der IKONOS-Daten werden in Ausschnitten der angegebenen Teiluntersuchungsgebiete vorgestellt, so dass sie sich mit den Ergebnissen der hyperspektralen Daten und der Orthofotos so gut wie möglich decken. Die verwendeten Genauigkeitsmaße orientieren sich an den in Kapitel 2.7 beschriebenen Verfahren.

5.3.1 Klassenbeschreibungen

Potentielle Feuchtgebiete und Unterklassen (*potential wetlands*)

Klassen wie „Feuchtgebiete“ und „offene Moorbereiche“ lassen sich auf Level 4 nicht sicher klassifizieren und werden deshalb zunächst als „*potential wetlands*“ bzw. „*potential open moor areas*“ bezeichnet.

Die ausgesuchten Teiluntersuchungsgebiete weisen deutliche Unterschiede in der Struktur der Feuchtgebiete auf. Während an den Osterseen die Schilfdichte nach Norden hin abnimmt (siehe Abb. 37), und die ufernahen Feuchtbereiche durch Großseggen- und Schneidriedbestände (*Cladium mariscus*) dominiert werden, existieren beispielsweise im Testgebiet Maisinger See (südwestlich von Starnberg) ausgedehnte Schilfbereiche (*Phragmites australis*) unterschiedlichster Dichte.



Abb. 36: Links: Schilf- und verbuschte Streuwiesenflächen am nordwestlichen Rand des Maisinger Sees. Rechts: Objektausprägung in eCognition




Abb. 37: Schilfbestände an den Osterseen. Links: Lockere Schilfbestände im Norden (oben) und dichtes Schilf im Süden (unten). Rechts: Objektausprägung in eCognition

Während auf Level 4 zunächst nur die potentiellen Feuchtgebiete ausgewiesen werden, können diese auf Level 1 in dichtes Schilf (*dense reed*), Schilf-/Seggenbestände in Wassernähe (*reed/sedge mosaic near water*) und seggendominiertes Niedermoor (*sedge dominated lowland moor*) unterteilt werden.

Entsprechend der Heterogenität der Objekte mussten die Wertebereiche einzelner Objektparameter angepasst und zum Teil unterschiedliche Klassenhierarchien benutzt werden.

Potentielle offene Moorflächen und Unterklassen (*potential open moor areas*)

Innerhalb der identifizierten Hochmoorbereiche (Weid- und Schechenfilz bei Iffeldorf) lassen sich Regionen mit Verbuschungstendenzen von offenen Hochmoorbereichen unterscheiden (vgl. Abb. 38). Am Rande von Hochmooren, am so genannten Randlagg, schließt der Übergangsmoorwald mit Moorbirke, Fichte, Faulbaum und Kiefer an (Bundesamt für Naturschutz (BfN) 1995).



Abb. 38: Links: Randbereich am nordwestlichen Ende des Weidfilzes. Rechts: Objektausprägung in eCognition

Zusätzlich kommen in diesen Gebieten renaturierte, d. h. wiedervernässte ehemalige Entwässerungsgräben vor, die sich ebenfalls gut in den Satellitendaten erkennen lassen.




Abb. 39: Links: Weidfilz östlich der Osterseen mit aufgestauten ehem. Entwässerungskanälen (oben) und Aushublöchern (unten). Rechts: Objektausprägung in eCognition

Im Wesentlichen gehören diese Flächen ebenfalls zu den Feuchtgebieten. Sie sind aber in den Satellitenbildern unterscheidbar und werden deshalb auch in der Klassifikation gesondert als eigene Klasse ausgewiesen.

Wasserflächen mit Unterklassen (*open water*)

Die Wasserflächen in den Testgebieten setzen sich aus Tiefwasserbereichen, Flachwasserzonen, bei denen qualitativ zwei Tiefenstufen unterschieden werden können und kleinen Verbindungskanälen bzw. den weiter oben beschriebenen Entwässerungskanälen im Hochmoorgebiet bei Iffeldorf zusammen. Entsprechend den unterschiedlichen Jahreszeiten kommen bei der Augustaufnahme zusätzlich Bereiche mit Schwimmblattvegetation (Seerose: *Nymphaea alba*, Teichrose: *Nuphar lutea* oder vereinzelt Seekanne: *Nymphoides peltata*) und nahe an der Oberfläche wachsender submerser Vegetation (z. B. Tannenwedel: *Hippuris vulgaris* oder Tausendblatt: *Myriophyllum spicatum*) vor.




Abb. 40: Links: *Myriophyllum spicatum* und *Nymphoides peltata* in einer Staustufe am Nordende der Osterseen. Rechts: Objektausprägung in eCognition. Das Foto links ist ein Ausschnitt aus dem rot markierten Bereich rechts

Diese Bereiche, deren Reflexion von der Vegetation beeinflusst wird, werden in den August-Regelwerken in einer eigenen Klasse berücksichtigt, gehören aber weiterhin zur Gruppe Wasser. Eine eindeutige Unterscheidung, zumindest in Schwimmblatt- und submerser Vegetation, ist in der kombinierten multisaisonalen Auswertung möglich.

5.3.2 IKONOS Klassifikationsergebnisse

Wie in Kapitel 4 in der Beschreibung des Untersuchungsgebietes dargestellt, wurde dieses in unterschiedliche Teilgebiete gegliedert. Die in Abschnitt 5.1.1 und 5.2 erläuterten Klassenhierarchien bzw. Objektdefinitionen wurden an den Testgebieten, welche jeweils die südlichen bzw. die nördlichen Osterseen umfassen, entwickelt. Diese Klassenhierarchien wurden für die anderen Testgebiete übernommen, überprüft und ggf. die Wertebereiche der verwendeten Objektparameter angepasst. Im Folgenden werden Klassifikationsergebnisse dieser Regelwerke in einem Gebiet dargestellt, das drei Teiluntersuchungsgebiete (südliche Osterseen, nördliche Osterseen und St. Heinrich) zusammenfasst. Zur Beurteilung der

Qualität der Ergebnisse wird zusätzlich zur Produzenten- und Benutzergenauigkeit der Kappa-Index (vgl. Abschnitt 2.7.1) für jede Klasse berechnet.

5.3.2.1 Vorklassifikationen April und August – Level 4

Die folgenden Abbildungen (Abb. 41 und Abb. 42) zeigen das Ergebnis der Vorklassifikation. Hierbei wurden im Anschluss an die Bearbeitung mit eCognition die einzelnen Levels an ein GIS übergeben und ggf. mit externen Informationen kombiniert. Dargestellt ist die Vorklassifikation der Feuchtgebiete, Moorbereiche sowie Wasser und Grünland auf Level 4, zusammen mit einer korrigierten, externen Waldklassifikation (Mott unveröff.).




Abb. 41: Klassifikation von IKONOS, April 2001. Übersichtsdarstellung am südlichen Starnberger See und an den Osterseen Kombination von Level 4 mit Waldklassifikation

Im **April 2001** ließen sich **Wasserflächen** aufgrund des frühen Aufnahmezeitpunktes leicht erkennen. Sie wurden mit einer Genauigkeit von knapp über 99 % (Produzenten- und Benutzergenauigkeit sowie Kappa Index von 0,99) klassifiziert¹⁹. Die **offenen Moorflächen** („*potential open moor areas*“) des Weid- und Schechenfilzes stachen bereits im April deutlich hervor. Diese Moorbereiche ließen sich auf diesem Level bereits mit Genauigkeiten von 99,94 % (Benutzergenauigkeit) und 68,75 % (Produzentengenauigkeit) bei einem Kappa-Index von 0,636 erkennen. Solange ohne die Waldmaske gearbeitet wurde, mussten Teile des ufernahen Waldes zunächst den Feuchtgebieten zugeordnet werden. Die

¹⁹ Tabellen mit Genauigkeitsmaßen zu allen Klassen befinden sich im Anhang.

Feuchtgebiete wurden im April nach Korrektur mit der externen Waldmaske mit 94,62 % (Benutzergenauigkeit) und 84,09 % (Produzentengenauigkeit) bei 0,826 (Kappa-Index) sehr gut erkannt. Grünland wurde ebenfalls sehr gut klassifiziert, mit Genauigkeiten von 95,05 % bzw. 82,12 % (Benutzer- bzw. Produzentengenauigkeit) bei einem Kappa-Index von 0,783. Diese verbesserten sich noch auf über 90 % bei einer Kombination mit der Grünlandklassifikation des Projektpartners (vgl. Mott unveröff.).





Abb. 42: Klassifikation von IKONOS, August 2001. Übersichtsdarstellung am südlichen Starnberger See und an den Osterseen, Kombination von Level 4 mit Waldklassifikation

Im **August 2001** waren neben den exakt erkannten **Wasserflächen**, bei denen nun auch die vegetationsbedeckten Bereiche unterschieden wurden, auch die Moorbereiche auffällig. Innerhalb dieser Moorbereiche nahmen die Hochmoorkerne des Weid- und Schechenfilzes östlich der nördlichen Osterseen den größten Raum ein. Diese wurden in der Detailklassifikation auf Level 1 noch genauer in offene Moorbereiche („*open moor*“) und Moor mit Verbuschungsbereichen („*moor, shrub encroachment*“) unterschieden (Abb. 44). Potentielle **Feuchtgebiete** konnten im August nach der Korrektur mit der Waldmaske mit 95,81 % Benutzer- und 82,09 % Produzentengenauigkeit bei einem Kappa-Index von 0,805 klassifiziert werden. Die potentiellen **Moorbereiche** ließen sich auf Level 4 mit einer Genauigkeit von 95,22 % bzw. 80,37 % (Benutzer- und Produzentengenauigkeit) klassifizieren, wobei ein Kappa-Index von 0,762 für diese Klasse berechnet wurde. **Grünland** wurde auf dieser Ebene abgeleitet, um spektrale Überschneidungen zwischen Feuchtgebieten und Grünlandvegetation zu minimieren. Die Klasse „Grünland“ ist eine Kombination der Ergebnisse aus der Grünlandklassifikation dieses Projektes und der

detaillierten Klassifikation in der Arbeit von Mott (unveröff.). Die Grünlandbereiche wurden hierbei mit einer Genauigkeit von 98,43 % (Benutzergenauigkeit) und 94,80 % (Produzentengenauigkeit) bei einem Kappa-Index von 0,938 erkannt. Um die Moorproblematik zu verdeutlichen, werden im Folgenden zunächst die Moor- und Feuchtgebietsklassifikation auf Level 1 und anschließend die Klassifikation der Wasserflächen auf Level 2 dargestellt. Beide Levels repräsentieren ohnehin die gleiche Maßstabsebene (siehe Abschnitt 5.1.1.1).

5.3.2.2 Detailklassifikation Moor – Level 1


Die verbuschten und nicht-verbuschten Bereiche in offenen Hochmoorkomplexen stellten sich im April und August 2001 leicht unterschiedlich dar. Im April (Abb. 43) wurden die offenen Moorflächen („*open moor*“) sehr gut klassifiziert mit 91,36 % bzw. 94,63 % (Benutzer- bzw. Produzentengenauigkeit) bei einem Kappa-Index von 0,934. Hingegen wiesen die verbuschten Bereiche („*moor, shrub encroachment*“) Genauigkeiten von 77,27 % (Benutzergenauigkeit) aber nur 32,66 % (Produzentengenauigkeit) auf, was darauf hindeutet, dass hier zu viele Flächen als verbuschte Bereiche klassifiziert wurden, die in der Referenz einer anderen Klasse angehören. Der Kappa-Index beträgt hier nur 0,301.



**Abb. 43: Klassifizierte Hochmoorkerne des Weid- bzw. Schechenfilzes östlich der Osterseen.
IKONOS April 2001**

In der Detailklassifikation vom August 2001 (Abb. 44) ließ sich die Klasse „*open moor*“ mit einer Genauigkeit von 93,25 % (Benutzergenauigkeit) und 97,01 % (Produzentengenauigkeit) klassifizieren. Für diese Klasse lag der Kappa-Index bei 0,963. Diese sehr guten

Ergebnisse decken sich mit der Qualität der Aprilklassifikation. Aufgrund von Merkmalsüberschneidungen mit bewaldeten Bereichen erreichte die Klasse „moor, shrub encroachment“ nicht diese Genauigkeitsbereiche, lag aber mit 92,19 % bzw. 73,70 % (Benutzer- bzw. Produzentengenauigkeit) deutlich über den Werten des Aprils. Mit 0,717 für den Kappa-Index wurde auch diese Klasse im Vergleich zum April relativ hoch bewertet. Flächenmäßig wurden im Frühjahr mit ca. 72 ha deutlich weniger verbuschte Bereiche klassifiziert als im August (ca. 127 ha). Gründe liegen vermutlich im noch nicht begonnenen Laubaustrieb im April und daraus resultierender Fehlklassifikationen.



**Abb. 44: Klassifizierte Hochmoorkerne des Weid- bzw. Schechenfilzes östlich der Osterseen.
IKONOS August 2001**

Der gesamte Moorbereich wurde vorher mit einer Waldklassifikation (vgl. Mott unveröff.) verschnitten. Dennoch gibt es Bereiche, in denen nicht eindeutig zwischen Wald und verbushtem Hochmoorkomplex unterschieden werden konnte, vor allem da die Übergänge fließend sind. Weil der Fernerkundung lediglich die oberste Schicht eines Oberflächentyps zugänglich ist, wird der Waldklassifikation hier Vorrang eingeräumt. Es handelt sich um einen typischen Fall einer Präferenzierung aufgrund einer vertikalen Merkmalsungleichheit innerhalb eines Objektes. **Wälder** konnten mit einer Genauigkeit von 97,76 % (Benutzerengenauigkeit) bzw. 100 % (Produzentengenauigkeit) klassifiziert werden.

5.3.2.3 Detailklassifikation Feuchtgebiete – Level 1

Innerhalb der auf Level 4 klassifizierten und ebenfalls mit Hilfe der Waldklassifikation (Mott unveröff.) korrigierten Feuchtgebiete konnten die Klassen dichtes Schilf („*reed, dense crop*“), Schilf-/Seggenbestand in Wassernähe („*reed/sedge mosaic close to water*“) sowie seggendominierte Niedermoorbereiche („*sedge dominated lowland moor*“) unterschieden werden. Die südlichen Osterseen weisen relativ reine und dichte Schilfbestände auf, welche nach Norden hin immer lockerer werden und von *Cladium mariscus* oder *Carex*-Arten dominiert werden.




Abb. 45: IKONOS April 2001. Detaillierte Feuchtgebietsklassifikation der südlichen Osterseen. Rot markiert sind schilfbestandene Streuwiesen




Abb. 46: IKONOS August 2001. Detaillierte Feuchtgebietsklassifikation der südlichen Osterseen. Die Streuwiesen aus der Aprilaufnahme sind gemäht




Abb. 47: IKONOS April 2001. Detaillierte Feuchtgebietsklassifikation der nördlichen Oostvaardersplassen




Abb. 48: IKONOS August 2001. Detaillierte Feuchtgebietsklassifikation der nördlichen Oostvaardersplassen

Die vorstehenden Abbildungen (Abb. 45 bis Abb. 48) zeigen die Klassifikationsergebnisse der Schilfbestände an den Osterseen. An den südlichen Osterseen wurden insbesondere am südlichsten See, dem Waschsee die „dichten Schilfbestände“ („*reed dense crop*“, Markierung 1 in Abb. 46) erkannt, während weiter im Norden auch direkt im Uferbereich die Klasse „Schilf/Seggen-Mosaik in Wassernähe“ („*reed/sedge mosaic close to water*“) bzw. in größerer Entfernung von der Wasserfläche die Klasse „seggendominiertes Niedermoor“ („*sedge dominated lowland moor*“) überwog (Markierung 2 in Abb. 48).

An den nördlichen Osterseen (Abb. 47 und Abb. 48) kommt die Klasse „dichtes Schilf“ kaum noch vor. Im April wurden aufgrund der ungünstigeren Aufnahmebedingungen noch einige Objekte als „dichtes Schilf“ klassifiziert, die im August bereits der Klasse „Schilf/Seggen-Mosaik in Wassernähe“ zugeordnet wurden.

Für das zusammengefasste Testgebiet (südliche und nördliche Osterseen) wurden in der Aprilklassifikation etwas geringere Genauigkeitsmaße erreicht als im August. Die folgenden Tabellen fassen die Klassifikationsqualität für Level 1 im April und August kurz zusammen:

Dichtes Schilf (<i>reed dense crop</i>)		
	April 2001	August 2001
Benutzergenauigkeit	61,34%	100%
Produzentengenauigkeit	29,38%	63,30%
Kappa-Index pro Klasse	28,53%	62,72%

Tab. 24: IKONOS-Klassifikationsqualität auf Level 1. Klasse: Dichtes Schilf

An beiden Aufnahmezeitpunkten wurde innerhalb der Referenz die Klasse „dichtes Schilf“ gut bis sehr gut (August) erkannt. Die Benutzergenauigkeit zeigt, insbesondere im April, dass zu viele Objekte als „dichtes Schilf“ klassifiziert wurden.

Schilf/Seggen-Mosaik in Wassernähe (<i>reed sedge mosaic close to water</i>)		
	April 2001	August 2001
Benutzergenauigkeit	78,48%	90,67%
Produzentengenauigkeit	36,43%	61,87%
Kappa-Index pro Klasse	33,43%	59,16%

Tab. 25: IKONOS-Klassifikationsqualität auf Level 1. Klasse: Schilf/Seggen-Mosaik in Wassernähe

Für die Klasse „Schilf/Seggen-Mosaik in Wassernähe“ ergab sich ein ähnliches Bild wie für die Klasse „dichtes Schilf“. Vermutlich waren der frühe Aufnahmezeitpunkt und das abgestorbene Schilf für die vielen Fehlklassifikationen im April verantwortlich (näheres hierzu bei der Diskussion). Innerhalb der Referenzobjekte wurde diese Objektklasse an beiden Aufnahmezeitpunkten gut erkannt.

Seggendominiertes Niedermoor (<i>sedge dominated lowland moor</i>)		
	April 2001	August 2001
Benutzergenauigkeit	56,47%	72,35%
Produzentengenauigkeit	75,34%	92,19%
Kappa-Index pro Klasse	70,98%	90,88%

Tab. 26: IKONOS-Klassifikationsqualität auf Level 1. Klasse: Seggendominiertes Niedermoor

Die Klasse „seggendominiertes Niedermoor“ weicht von den beiden obigen Klassen ab. Innerhalb der wurden vor allem im April zu viele Objekte klassifiziert (geringe Benutzer-genauigkeit), während die Objekte der Referenz jedoch zu über 75 % bzw. 90 % korrekt erkannt wurden. Ein einfaches Zusammenfassen der Klassen „Schilf/Seggen-Mosaik in Wassernähe“ und „seggendominiertes Niedermoor“ führte im April allgemein zu einem Anstieg der Genauigkeiten auf ca. 90 % und im August zu deutlich über 90 % bei der Produzenten- und Benutzergenauigkeit sowie im Kappa-Index.

5.3.2.4 Detailklassifikation Wasser und Gewässervegetation – Level 2

Innerhalb der Wasserflächen ließen sich auf Level 2 Tiefwasserbereiche von unterschiedlichen Flachwasserbereichen abgrenzen. Als dritte Klasse konnten aus den multispektralen Daten vom August 2001 Objekte, die potentiell Gewässervegetation enthalten („*potential submersed vegetation*“), abgeleitet werden. Zusätzlich wurden bei der multispektralen Klassifikation Objekte unterschieden, die Gewässervegetation enthalten. Auch kleine Objekte, wie die Entwässerungskanäle im Hochmoorgebiet (vgl. Abschnitt 5.3.1) oder die Verbindungskanäle zwischen den Osterseen wurden erfasst.




Abb. 49: Detailklassifikation Wasser (Level 2). IKONOS August 2001 südliche Osterseen

Die obige Abbildung (Abb. 49) zeigt die detaillierte Klassifikation der Wasserflächen. Die Aprilklassifikation wird hier nicht dargestellt, da sie sich nur in Details unterscheidet und aufgrund des Aufnahmezeitpunktes die Klasse „Gewässervegetation“ fehlt. Bereits bei dieser Abbildung ist zu erkennen, dass die kleinen Verbindungskanäle in Bereichen in denen sie von Bäumen oder dichtem Schilf nicht überdeckt werden, erfasst wurden. An den nördlichen

Osterseen (Abb. 50) ist diese Detailgenauigkeit noch deutlicher zu beobachten. Die Verbindungskanäle konnten nicht als zusammenhängendes Objekt extrahiert werden, da sie keine eigene Klasse darstellen. Die Kanäle unterscheiden sich von anderen Wasserflächen nur aufgrund ihres Länge- zu Breite-Verhältnisses. Bei einer Vereinigung aller Wasserobjekte würden diese länglichen Objekte Teil der gesamten Seefläche sein und das Länge-zu Breite-Verhältnis nicht mehr stimmen.



Abb. 50: Detailklassifikation Wasser (Level 2). IKONOS August 2001 nördliche Osterseen

Die erreichbare Klassifikationsqualität ist bei den reinen Wasserklassen trotz des Anspruches, auch kleine Strukturen zu klassifizieren, erwartungsgemäß hoch. Bei den potentiell mit Vegetation bedeckten Objekten nahmen die Genauigkeiten teilweise erheblich ab.

Genauigkeitsmaß	Deep water	Shallow water	Shallow water / submerged vegetation
Benutzergenauigkeit	99,463%	91,655%	92,739%
Produzentengenauigkeit	98,643%	98,596%	30,280%
Kappa-Index	94,870%	98,160%	29,409%

Tab. 27: Klassifikationsqualität der Wasserklassen. IKONOS August 2001

Mit Hilfe einer **Kombination der beiden Aufnahmezeitpunkte** ließ sich das Regelwerk zum einen vereinfachen, zum anderen konnten Wasserpflanzen sicher erkannt und in „Schwimmblattvegetation“ sowie „submerse Makrophyten“ unterschieden werden. Da nach erfolgreicher Klassifikation der Gewässervegetation nur noch innerhalb dieser Klasse gearbeitet wurde, konnten die Wertebereiche der verwendeten Parameter auch großzügiger gewählt werden. So wurde hier ebenfalls eine Benutzergenauigkeit von über 90 %, aber nur eine Produzentengenauigkeit von knapp über 30 % erreicht.




Abb. 51: Multisaisonale IKONOS-Klassifikation. Vereinfachung der Regelwerke und Unterscheidung von Gewässervegetation möglich

Die Abbildung oben (Abb. 51) stellt den Ausschnitt der südlichen Osterseen dar. Eine Unterscheidung zwischen „Schwimblattvegetation“ (rosa) und „submersen Makrophyten“ (grün) ist bereits erfolgt. Am Waschsee, dem südlichsten der Osterseen (rot markiert), wurden allerdings submerse Tannenwedel (*Hippuris vulgaris*) fälschlicherweise als „Schwimblattvegetation“ klassifiziert. Da diese Makrophyten häufig, dicht unter und auch über der Wasseroberfläche wachsen, ist diese Fehlklassifikation nicht zu vermeiden. Im nördlich anschließenden Verbindungskanal ist die submerse Vegetation hingegen richtig klassifiziert worden.

Die nächste Abbildung (Abb. 52) stellt Klassifikationsergebnisse für Wasserpflanzen im Detail dar. Es handelt sich um einen Ausschnitt der Staustufe des Bodenbachs, über welchen die Osterseen in den Starnberger See entwässern. Innerhalb dieser Wasserfläche kommen ausgedehnte Flächen mit Schwimblattvegetation (*Nymphoides peltata* und *Nuphar lutea*), aber auch Bereiche mit sehr dicht an der Oberfläche wachsenden Tannenwedeln (*Hippuris vulgaris*) und Tausendblatt (*Myriophyllum spicatum*) vor. Diese Pflanzenteppiche wurden bei der Klassifikation aufgrund ihrer Oberflächennähe und ihrer Dichte (vgl. dazu Abb. 40 auf Seite 118) alle der Klasse Schwimblattvegetation zugeordnet.




Abb. 52: Gewässervegetation im Detail. Staustufe Bodenbach. Die Klasse *submerged macrophytes* kommt in diesem Ausschnitt nicht vor

Innerhalb dieses kleinen Ausschnittes (Abb. 52) wurden nur die eindeutig als Gewässervegetation erkennbaren Objekte als solche klassifiziert. Gewässerbereiche mit wenig Vegetation wurden der offenen Wasserfläche zugeordnet. Der rot markierte Bereich enthält Bäume und blieb hier entsprechend unklassifiziert.

Die erreichbaren Genauigkeiten für die Klassen in dem gesamten Testgebiet sind in der folgenden Tabelle (Tab. 28) angegeben:

Genauigkeitsmaß	<i>Water</i>	<i>Water lilies</i>	<i>Submerged macrophytes</i>
Benutzergenauigkeit	93,939%	88,889%	100,000%
Produzentengenauigkeit	100,000%	100,000%	55,556%
Kappa-Index	100,000%	100,000%	50,388%

Tab. 28: Klassifikationsqualität der Gewässervegetationsklassen. IKONOS multisaisonale Auswertung

Die Werte für die Produzenten- sowie für die Benutzergenauigkeit zeigen, dass auch diese Objekte sehr gut erfasst wurden. Da aufgrund des geringen Vorkommens dieser Klassen in der Gesamtszene ebenfalls nur sehr wenige Referenzobjekte für die Validierung kartiert werden konnten, sind die Auswirkungen auf die Genauigkeitsmaße umso schwerwiegender. Sehr deutlich ist das an dem geringen Wert für die Benutzergenauigkeit bei den submersen Makrophyten zu erkennen.

5.3.2.5 Klassifikation innerhalb vorgegebener Grenzen

Ein Ziel dieser Arbeit war es, bestehende Informationen wie z. B. Kartierungen als externe Ebenen in die Klassifikation einzubeziehen. So sollten zum einen diese Informationen überarbeitet, aber auch die Klassifikationsergebnisse verbessert werden.

Ein Beispiel zeigt die Abbildung unten (Abb. 53), bei der Grenzen eines Feuchtgebietes der Biotoptypenkartierung genutzt wurden. Es handelt sich um des Testgebiet 1 östlich von Starnberg am Ausfluss der Würm. Wie in der Abbildung zu erkennen ist, werden nicht alle in der Biotoptypenkartierung enthaltenen Objekte überarbeitet, sondern nur ein ausgewähltes. Der Grund liegt darin, dass nur Feuchtgebietsobjekte berücksichtigt wurden.

Die Biotoptypenkartierung spricht das gesamte Objekt in Abb. 53 als Hochmoor/Zwischenmoor an, während eine Moorkartierung große Teile als Niedermoor kennzeichnet. Die Nutzung von Grenzen aus der Biotoptypenkartierung erlaubte es, Fehlklassifikationen mit Siedlungsgrün innerhalb von Starnberg oder mit Wasserflächen (überwiegend aufgrund von Schatten) zu vermeiden.




Abb. 53: Klassifikation innerhalb von Grenzen der Biotoptypenkartierung östlich von Starnberg. IKONOS August 2001

Fehlklassifikationen sind auch innerhalb von bestehenden Grenzen nicht ganz auszuschließen. Nicht klassifizierte Bereiche sind auf Fehler zurückzuführen oder es handelt sich um Klassen, die nicht von den hier entwickelten Regelwerken abgedeckt werden, beispielsweise Acker- oder Grünlandflächen (siehe Markierung in Abb. 53).

Ein weiteres Testgebiet liegt wenige Kilometer westlich von Starnberg und umfasst den Maisinger See und das angrenzende Feuchtgebiet. Die Biotoptypenkartierung weist das gesamte Feuchtgebiet als Großseggenried und als Hoch- oder Zwischenmoor aus. Wie aus der Abbildung unten (Abb. 54) ersichtlich wird, wurde die räumliche Differenzierung der Klassifikation auf Level 1 bereits deutlich detaillierter. Der größte Teil des Feuchtgebietes wurde als „seggendominiertes Niedermoor“ mit Genauigkeiten von 88,89 % Produzenten-

und 100 % Benutzergenauigkeit bei einem Kappa-Index von 1 erkannt. Schwieriger waren die Schilfzonen im Uferbereich zu differenzieren, für die deutlich geringere Genauigkeiten (vgl. Tab. 29) erzielt wurden.

Genauigkeitsmaß	<i>Reed dense crop</i>	<i>Reed/sedge mosaic close to water</i>
Benutzergenauigkeit	50,000%	83,333%
Produzentengenauigkeit	77,778%	29,412%
Kappa-Index	74,030%	24,758%

Tab. 29: Klassifikationsqualität der detaillierten Schilfklassen am Maisinger See. IKONOS August 2001




Abb. 54: Klassifikation innerhalb der Biotoptypenkartierung am Maisinger See, westlich von Starnberg. IKONOS August 2001

Falls die Grenzen der Biotoptypenkartierung nicht berücksichtigt werden, kommt es zu diversen Fehlklassifikationen innerhalb der angrenzenden Grünlandobjekte. Ein Beispiel dafür zeigt die Abbildung unten.




Abb. 55: Fehlklassifikationen am Maisinger See, westlich von Starnberg. IKONOS August 2001.
Die Biotoptypenkartierung wird hier nicht verwendet, deren Grenzen sind aber dennoch zur
besseren Orientierung abgebildet

Insgesamt ist zu erkennen, dass sich beide Klassifikationen in wesentlichen Bereichen gleichen, aber ohne Einbindung der Biotoptypengrenzen (Abb. 55) vor allem im Norden Verwechslungen innerhalb der Klasse „dichtes Schilf“ entstehen. Auch hier befindet sich der Feuchtgebietsbereich nur innerhalb der Grenzen der Biotoptypenkartierung (vgl. Abb. 54) in der oberen Abbildung werden aber sehr viele Objekte außerhalb dieser klassifiziert. Bewaldete Flächen werden hier zu Teil der Klasse „*sedge dominated lowland moor*“ zugewiesen (siehe Markierung in Abb. 55). Der größte Teil der Verwechslungen mit Grünland konnte bereits auf Level 4 beseitigt werden, da hier die Klasse „Grünland“ erfolgreich ausgeschieden wurde. Dieser Aufwand ist bei der Nutzung durch die Biotopkartierung vorgegebener (externer) Grenzen nicht mehr notwendig.

Wie die Auswertung der Klassifikationsergebnisse der IKONOS-Daten zeigt, können diese mit der verwendeten Methode mit einer sehr hohen Qualität klassifiziert werden. Die Klassifikationsgenauigkeit sinkt etwas, wenn der betrachtete Maßstab größer, also die Detailtiefe erhöht wird. Die Analyse multitemporaler Daten zweier Aufnahmezeitpunkte verbessert das Ergebnis in Detailbereichen auf einer großen Maßstabsebene, beispielsweise bei der Unterscheidung von Gewässervegetation. Ebenso trägt die Nutzung bestehender Kartierungen zu einer Verbesserung des Klassifikationsergebnisses bei.

5.3.3 CASI-Klassifikationsergebnisse

Im Rahmen dieser Arbeit wurde zusätzlich getestet, ob die hohe spektrale Auflösung von hyperspektralen Daten zu einer weiteren Klassentrennung beitragen kann. Innerhalb der verwendeten CASI-Daten (vgl. Abschnitt 4.4.1) wurden die gleichen Testgebiete ausgewählt. Der Aufnahmezeitpunkt der CASI-Daten ist der 13.09.1999, d. h. am Ende der Vegetationsperiode.




Abb. 56: Klassifikation der CASI-Daten am Weid- und Schechenfilz östlich der Osterseen

Die Abbildung oben (Abb. 56) zeigt den Ausschnitt des Weid- und Schechenfilzes. Hierbei sollten ebenfalls die offenen Moorbereiche von den verbuschten Gebieten abgetrennt werden. Bei einem Vergleich der CASI Klassifikationsergebnisse mit der Klassifikation auf Basis der IKONOS-Daten (vgl. Abb. 44) zeigt sich u. a., dass bei den CASI-Daten verbuschte Flächen zum Teil der Klasse „Feuchtwald“ zugeordnet wurden (siehe Markierung in Abb. 56). Bereits bei diesem Vergleich zeigt sich, dass mit den IKONOS-Daten bessere Ergebnisse zu erzielen sind, dies bestätigen auch Tabelle 30 und 31.

Produzenten- genauigkeit in %	Gewässer	Wald	Acker	Grünland	geringer Schilfanteil	hoher Schilfanteil	offene Hoch- moorflächen	Verbuschungs- stadien auf o.H.	Versiegelung	Gesamtergebnis
<i>Gewässer</i>	92,8	3,1	0,0	0,2	1,0	1,8	1,0	0,1	0,2	100
<i>Wald</i>	0,4	91,6	0,0	1,5	0,3	4,7	0,2	0,0	1,4	100
<i>Acker</i>	0,0	3,0	25,1	67,1	0,0	0,2	0,0	0,0	4,5	100
<i>Grünland</i>	0,1	9,9	4,7	76,9	0,1	1,6	0,0	0,0	6,8	100
<i>geringer Schilfanteil</i>	2,1	16,2	0,0	23,4	14,3	41,8	0,0	0,0	2,3	100
<i>hoher Schilfanteil</i>	10,6	19,9	0,0	7,4	12,5	47,4	1,8	0,0	0,5	100
<i>offene Hoch- moorflächen</i>	2,3	6,0	0,0	0,0	0,0	2,6	81,3	7,7	0,0	100
<i>Verbuschungs- stadien auf o.H.</i>	0,0	52,1	0,0	0,1	0,5	3,2	12,8	31,3	0,0	100
<i>Versiegelung</i>	0,2	24,9	0,8	13,0	0,4	1,9	0,0	0,0	58,7	100

Tab. 30: Produzentengenauigkeit der CASI-Klassifikation (verändert nach Löschenbrand 2003)

Benutzer- genauigkeit in %	Gewässer	Wald	Acker	Grünland	geringer Schilfanteil	hoher Schilfanteil	offene Hoch- moorflächen	Verbuschungs- stadien auf o.H.	Versiegelung
<i>Gewässer</i>	94,7	1,1	0,0	0,2	13,8	5,2	3,2	0,8	0,5
<i>Wald</i>	0,9	84,6	1,0	4,2	10,3	33,0	1,5	0,0	10,8
<i>Acker</i>	0,0	0,2	57,5	16,6	0,0	0,1	0,0	0,0	3,0
<i>Grünland</i>	0,1	2,8	38,3	68,4	0,8	3,6	0,0	0,0	16,4
<i>geringer Schilfanteil</i>	0,2	0,5	0,0	2,3	16,9	10,0	0,0	0,0	0,6
<i>hoher Schilfanteil</i>	3,4	2,3	0,0	2,7	54,2	41,8	1,9	0,0	0,5
<i>offene Hoch- moorflächen</i>	0,7	0,7	0,0	0,0	0,1	2,3	83,8	25,1	0,0
<i>Verbuschungs- stadien auf o.H.</i>	0,0	4,3	0,0	0,0	1,7	2,0	9,6	74,1	0,0
<i>Versiegelung</i>	0,1	3,4	3,1	5,6	2,3	2,0	0,0	0,0	68,2
<i>Gesamtergebnis</i>	100	100	100	100	100	100	100	100	100

Tab. 31: Benutzergenauigkeit der CASI-Klassifikation (verändert nach Löschenbrand 2003)

Die erreichte Klassifikationsgenauigkeit war im Vergleich mit der IKONOS-Klassifikation aus dem August niedriger. Bei dieser wurden für die „offenen Moorflächen“ 93,25 % (Produzentengenauigkeit) und 97,01 % (Benutzergenauigkeit) erreicht. Noch deutlicher wird der Unterschied bei den verbuschten Bereichen im Hochmoor. Hier erreichte die IKONOS-

Klassifikation im August 2001 92,19 % (Produzentengenauigkeit), während die Benutzerengenauigkeit mit 73,70 % ein wenig niedriger lag als bei den CASI-Daten.

Insgesamt wurden trotz der erweiterten spektralen Möglichkeiten der CASI-Daten nicht mehr Klassen erkannt als mit den IKONOS-Aufnahmen (vgl. Tab. 14). Insbesondere im Bereich der Feuchtgebiete wurden Feuchtflächen mit hohem und niedrigem Schilfanteil, Feuchtwälder sowie offene Hochmoorflächen klassifiziert. Im Bereich der Gewässer wurden Tief- und Flachwasserzonen sowie die wiedervernässten ehemaligen Entwässerungskanäle im Hochmoor erkannt. Detaillierter wurde die hyperspektrale Klassifikation bei Wäldern. Da diese, wie auch Ackerland und Grünland, nicht im Fokus dieser Arbeit liegen, wird auf diese Klassen hier aber nicht weiter eingegangen (vgl. hierzu Löschenbrand 2003).

Die Analyse der Klassifikationsergebnisse auf Basis des CASI-Sensors zeigt, dass mit diesen Daten ein vergleichbares Ergebnis wie mit den IKONOS-Daten erreicht werden kann. Wie die Tabellen 30 und 31 im Vergleich mit der Qualität der Ergebnisse in Abschnitt 5.3.2 zeige, ist die Klassifikationsqualität in Teilbereichen geringer, insbesondere bei der Betrachtung größerer Maßstäbe.

5.3.4 Orthofoto Klassifikationsergebnisse

Luftbilder bzw. Orthofotos wurden im Rahmen dieser Arbeit genutzt, um zusätzlich die zeitliche Komponente, d. h. den Blick in die Vergangenheit auszuwerten. Das geschieht zum einen durch die Auswertung von Zeitreihen, aber auch durch die Nutzung der klassifizierten IKONOS-Objektgrenzen als externe Informationsebene bei der Orthofotoklassifikation. Es wird dann nur noch innerhalb dieser Grenzen gearbeitet (vgl. auch Abschnitt 4.6).

Die Auswertung der Orthofotozeitreihen gestaltete sich aufwendiger als die Analyse einzelner Aufnahmen, da die aus unterschiedlichen Jahren stammenden Luftbilder jeweils eine andere Charakteristik aufwiesen. Diese unterschiedlichen Bildeigenschaften mussten in den jeweiligen Klassenhierarchien berücksichtigt werden, d. h. dass für jedes Aufnahmejahr eine eigene, mit denen der anderen Jahre vergleichbare Klassenhierarchie erstellt wurde, entsprechend der Diplomarbeit von Rogg (2003).




Abb. 57: Klassifikation „Iffelder Seengruppe“, Befliegung 2000 Level 2

Aufgrund der geringeren räumlichen Abdeckung der Luftbilder wurden kleinere Ausschnitte der bekannten Teilstestgebiete bearbeitet. Die Abbildung oben (Abb. 57) zeigt die südlichsten fünf Osterseen mit der Ortschaft Iffeldorf. In den Aufnahmen des Jahres 2000 (Abb. 57) können sowohl Feuchtgebiete als auch das aquatische Schilf abgegrenzt werden. Die Orthofotos von 1976 (Abb. 58) ließen diese Unterteilung nicht zu. Aquatisches Schilf konnte hier nicht klassifiziert werden.




Abb. 58: Klassifikation „Iffelder Seengruppe“ Befliegung 1976 Level 2

Ebenso wenig befriedigend im Hinblick auf Schilf waren die Aufnahmen von 1956 (Abb. 59). Allerdings konnten hier zusätzlich Objekte mit Schwimmblattvegetation klassifiziert werden.




Abb. 59: Klassifikation „Iffelder Seengruppe“ Befliegung 1956 Level 2. Die Schwimmblattvegetation ist rot markiert

Eine Verifizierung der Klassifikation konnte aufgrund fehlenden Referenzmaterials nur für die aktuellen Aufnahmen von 1999 und 2000 durchgeführt werden. Die Klassifikationsergebnisse wurden für die Verifizierung mit einer Landnutzungskartierung aus dem Jahr 2002 (vgl. Abschnitt 4.6) verglichen.

		Referenzkartierung					
Klassifikation		Wasser	Siedlung	Wald/Gehölze	Feuchtgebiet	Landwirtschaft	Sonstige Flächen
	Wasser	96%	-	-	1%	-	1%
	Siedlung/Verkehr	-	78%	3%	-	2%	0%
	Wald/Gehölze	-	11%	90%	8%	1%	7%
	Feuchtgebiet	3%	1%	1%	55%	-	27%
	unklassifiziert	1%	10%	6%	36%	97%	65%
	Gesamtergebnis Referenz	100%	100%	100%	100%	100%	100%

Tab. 32: Produzentengenauigkeit der Klassifikation „Iffelder Seengruppe“ 2000

Die Produzentengenauigkeit (Tab. 32) zeigt, dass deutlich über 90% der Wasserflächen mit Hilfe der Luftbilder klassifiziert werden konnten. Die kartierten Feuchtgebiete der Referenz wurden nur zu 55% erkannt. Die Benutzergenauigkeit (Tab. 33) ergibt für Wasser ein ähnliches Bild mit 98% Genauigkeit. Bei den Feuchtgebieten wurden 86% der so klassifizierten Objekte laut Referenzkartierung korrekt erkannt.

		Referenzkartierung						
Klassifikation		Wasser	Siedlung	Wald/Gehölze	Feuchtgebiet	Landwirtschaft	Sonstige Flächen	Gesamtergebnis Klassifikation
	Wasser	98%	-	-	2%	-	-	100%
	Siedlung/Verkehr	-	95%	1%	-	4%	-	100%
	Wald/Gehölze	-	22%	66%	7%	4%	1%	100%
	Feuchtgebiet	4%	3%	2%	86%	2%	3%	100%
	unklassifiziert	-	5%	1%	9%	84%	1%	100%

Tab. 33: Benutzergenauigkeit der Klassifikation „Iffelder Seengruppe“ 2000

Waldflächen wurden ebenfalls mit einer hohen Genauigkeit erkannt, wobei nur 67 % der kartierten Flächen der Referenz „getroffen“, aber 90 % der als Wald klassifizierten Objekte laut Referenz richtig zugeordnet wurden.

Wie die obigen Beispiele illustrieren, konnten Feuchtgebiete mit einer vergleichsweise hohen Genauigkeit klassifiziert werden. Hochmoorbereiche hingegen konnten aus den Luftbildern allein nicht abgeleitet werden. Das Beispiel eines Testgebietes an den nördlichen Osterseen zeigt (Abb. 60 und Abb. 61), dass mit Hilfe der berechneten digitalen Oberflächenmodelle detaillierter gearbeitet werden konnte.

Zunächst wurde der Ausschnitt ohne Nutzung des DOMs klassifiziert (Abb. 60). Feuchtgebiete können auch im ufernahen Bereich der Seen erkannt werden. Der Hochmoorbereich des nördlichen Weidfilzes (siehe Markierungen) blieb jedoch unklassifiziert.




Abb. 60: Klassifikation „Nördliche Osterseen“ Befliegung 1999 ohne DOM Level 2. Die unklassifiziert gebliebenen Moorbereiche sind hier rot und schwarz markiert

Unter Einbeziehung des DOMs konnten zusätzlich zu den bestehenden Klassen „Gehölze“ innerhalb der Feuchtgebiete auch Teile des Hochmoorbereiches klassifiziert werden (Abb. 61).




Abb. 61: Klassifikation „Nördliche Osterseen“ Befliegung 1999 mit DOM Level 2. Die schwarze Markierung ist ein Moorbereich, der jetzt erfolgreich als „Feuchtgebiet“ klassifiziert wurde. Die rote Markierung zeigt ein erfolgreich klassifiziertes Hochmoorobjekt

Aufgrund des Abdeckungsbereiches der verwendeten Kartierung konnte die Verifizierung nicht für das gesamte Testgebiet durchgeführt werden, sondern nur für die im unmittelbaren Uferbereich gelegenen Objekte inklusive der Moorbereiche.

Um die Klassifikationsergebnisse mit der Landnutzungskartierung (Kangler 2003) vergleichen zu können, wurden Klassen folgendermaßen zusammengefasst:

Wasser = Tiefes Wasser, Flachwasser

Siedlung = Siedlung, Straßen

Wald/Gehölze = Wald, Gehölze linear, sonstige Gehölze, Feuchtgebiete

Feuchtgebiet = Feuchtgebiet

Hochmoor = sonstige offene Hochmoorstandorte

Feuchtgebiete der Referenz konnten ohne Nutzung des DOMs nur zu 53 % erkannt werden. Die Qualität der klassifizierten Feuchtgebietsobjekte war aber auch in diesem Ausschnitt mit 92 % Benutzergenauigkeit (Tab. 34) sehr hoch.

		Referenzkartierung				
		Wasser	Wald/Gehölze	Feuchtgebiete	Hochmoor	Landwirtschaft
Klassifikation	Wasser	84%	-	3%	-	-
	Wald/Gehölze	3%	90%	20%	32%	14%
	Feuchtgebiete	9%	1%	53%	-	1%
	sonstige Flächen	1%	4%	1%	1%	3%
	unklassifiziert	3%	5%	23%	67%	82%
	Gesamtergebnis Kartierung	100%	100%	100%	100%	100%

Tab. 34: Produzentengenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 ohne DOM

Die Wasserflächen wurden mit gleich bleibend hoher Genauigkeit von 84 % Produzenten- und 91% Benutzergenauigkeit klassifiziert. Auch die Wald- und Gehölzstrukturen lagen in diesem Qualitätsbereich, mit 90 % bzw. 71 %. Die Klasse „Hochmoor“ war in der Referenzkartierung ausgewiesen, blieb aber wie schon erwähnt bei der Klassifikation ohne DOM unklassifiziert.

		Referenzkartierung					Gesamtergebnis Klassifikation (ha)
		Wasser	Wald/Gehölz	Feuchtgebiete	Hochmoor	Landwirtschaft	
Klassifikation	Wasser	92%	-	8%	-	-	100%
	Wald/Gehölze	1%	71%	15%	10%	3%	100%
	Feuchtgebiete	5%	2%	92%	1%	-	100%
	sonstige Flächen	4%	67%	14%	4%	11%	100%
	unklassifiziert	1%	7%	31%	35%	26%	100%

Tab. 35: Benutzergenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 ohne DOM

Die folgenden Tabellen zeigen, dass sich mit Hilfe des DOMs 57 % Hochmoorflächen aus der Referenzkartierung erkennen ließen (Produzentengenauigkeit, Tab. 36). Von den als Hochmoor klassifizierten Objekten waren laut Referenz aber weit über 90 % richtig klassifiziert (Benutzergenauigkeit, Tab. 37).

		Referenzkartierung				
Klassifikation		Wasser	Wald/Gehölze	Feuchtgebiet	Hochmoor	Landwirtschaft
	Wasser	82%	0%	3%	0%	0%
	Wald/Gehölze	3%	85%	14%	35%	10%
	Feuchtgebiet	9%	3%	71%	2%	2%
	Hochmoor	0%	1%	0%	56%	0%
	unklassifiziert	3%	8%	11%	6%	85%
	Sonstige Flächen	3%	3%	1%	1%	3%
	Gesamtergebnis Referenz	100%	100%	100%	100%	100%

Tab. 36: Produzentengenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 mit DOM

Die Klassifikationsgenauigkeit der Feuchtgebiete konnte mit Hilfe des Oberflächenmodells noch verbessert werden. Sie liegt dann bei 71 % der erkannten Flächen (Produzentengenauigkeit). Die als Feuchtgebiete klassifizierten Objekte waren zu 90 % korrekt (Tab. 37), während sich die Qualität der Klasse „Wasser“ nicht weiter verbessern ließ. Die Produzentengenauigkeit von „Wald- und Gehölzen“ verschlechterte sich hingegen geringfügig von 90 % auf 85 %. Dagegen stieg die Benutzergenauigkeit leicht von 71 % auf 73 %.

		Referenzkartierung					Gesamtergebnis Klassifikation
Klassifikation		Wasser	Wald/Gehölze	Feuchtgebiet	Hochmoor	Landwirtschaft	
	Wasser	90%	0%	10%	0%	0%	100%
	Wald/Gehölze	1%	73%	12%	12%	2%	100%
	Feuchtgebiet	4%	4%	90%	1%	1%	100%
	Hochmoor	0%	4%	0%	96%	0%	100%
	Sonstige Flächen	15%	48%	22%	3%	12%	100%
	unklassifiziert	3%	20%	25%	5%	47%	100%

Tab. 37: Benutzergenauigkeit für das Testgebiet „Nördliche Osterseen“ 1999 mit DOM

Bei der Analyse der Ergebnisse auf Basis der Orthofotos zeigt sich, dass diese vor allem auf einer großen Maßstabsebene sehr gute Ergebnisse erzielen können. Die Qualität der Klassifikationen hängt aber stark von dem zur Verfügung stehenden Luftbildmaterial ab und kann auch trotz der angewendeten objektorientierten Methode nicht immer gleich bleibend gewährleistet werden. Die Ergebnisse zeigen ebenfalls, dass die Nutzung evtl. vorhandener Höhenmodelle die Klassifikation von Objekten vereinfachen kann, insbesondere im Bereich der komplexen Feuchtfächen.

5.3.5 Klassifikationsverbesserung durch Verschneidung

Mit Hilfe der Zeitreihe der Orthofotos konnten innerhalb der aktuellen Grenzen der IKONOS-Klassifikation Entwicklungen der Vorjahre aufgezeigt werden. Aufgrund der hohen räumlichen Auflösung konnten zusätzlich die vergleichsweise groben Grenzen der Satellitenbildklassifikation verfeinert und z. B. die Schilfausdehnung im Detail analysiert werden.

Die folgende Abbildung (Abb. 62) zeigt einen Teil der südlichen Osterseen. Es sind die Schilfgrenzen (blau und schwarz umrandet dargestellt) aus der IKONOS-Klassifikation dargestellt mit den hoch auflösenden Luftbilddaten von 2000 im Hintergrund.

Zusätzlich sind die Klassifikationsergebnisse auf Basis Orthofotos von 1956 (rot) und der Orthofotos aus dem Jahr 2000 (grün), innerhalb der bestehenden aktuellen Grenzen dargestellt. Im Bild sieht man dort, wo die roten Flächen der 56er Schilfbestände durchscheinen die inzwischen etwas verringerte Ausdehnung der Schilfbestände von 2000. Gearbeitet wurde innerhalb der mit IKONOS im Jahr 2001 abgegrenzten Schilfobjekte. Da diese auf Basis der geringer auflösenden Multispektraldaten (4 m) entstanden sind, wirken sie im Vergleich mit den Grenzen im Luftbild gröber.

Da an den Osterseen keine größeren Schilfrückgänge eingetreten sind, lassen sich keine großen Veränderungen erkennen. Es bestehen höchstens saison- oder durch die Daten-grundlage bedingte Unterschiede.




Abb. 62: Orthofotoklassifikation innerhalb von klassifizierten IKONOS-Schilfobjekten

Eine weitere Kombination von Orthofotos mit deutlicher Aussagenerweiterung im Sinne der temporalen Ergebnisverbesserung ist in der folgenden Abbildung (Abb. 63) dargestellt. Am nördlichen Rand des Weidfilzes östlich der Osterseen wurde über drei Zeitpunkte (1964, 1976 und 1999) die Entwicklung des Baum- und Buschbestandes am Hochmoorrand aufgezeigt. Hiermit konnten Verbuschungstendenzen erfasst und analysiert werden.

Rogg (2003) hat bei der Analyse der Verbuschung (Abb. 63) quantitativ nachgewiesen, dass es in dem unten dargestellten Ausschnitt einen Zuwachs an baumbestandener Fläche von

19 ha gab. Über die 35 Jahre dieser Zeitreihe, von 1964 bis 1999, ergab sich somit eine Zunahme von 25 %.

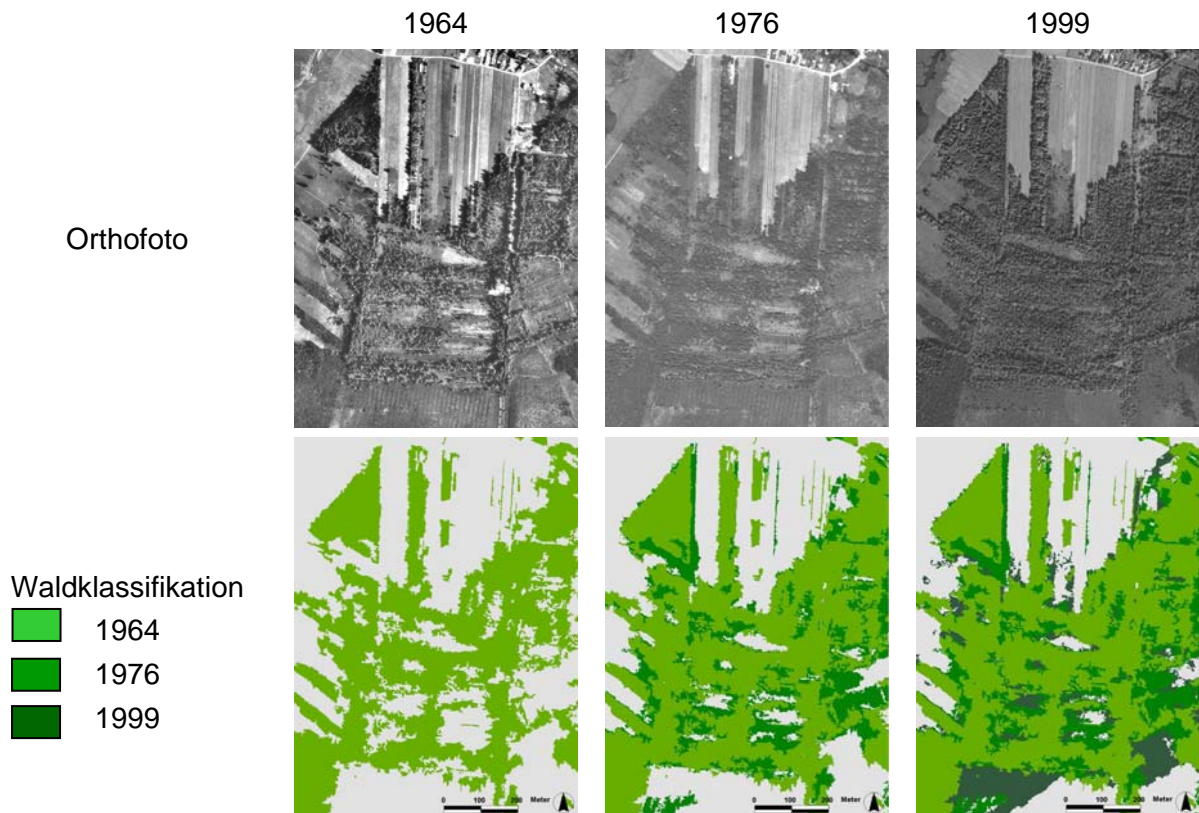


Abb. 63: Zeitreihe der Verbuschung aus Orthofotos am nördlichen Rand des Weidfilzes. Oben: Orthofotos (man beachte die unterschiedliche Qualität). Unten: Klassifikation

Die Genauigkeitsanalysen für die aktuellen Aufnahmen zeigten, dass auch mit Luftbildern gute Klassifikationsergebnisse auf lokaler Ebene erreichbar sind (siehe Abschnitt 5.1.3). Für die älteren Aufnahmen konnten aufgrund fehlenden Referenzmaterials keine statistischen Qualitätsmaße berechnet werden. Eine visuelle Überprüfung machte jedoch deutlich, dass auch hier Objekte überwiegend sehr gut erkannt wurden.

Die Kombination der Unterschiedlichen Fernerkundungsdaten ist dort überlegen, wo auf Basis aktueller, aus Satellitendaten abgeleiteter Grenzen eine Vertiefung der Aussage erreichen lässt. Die Stärke der Luftbilder im Sinne der temporalen Analyse einer Landschaftsentwicklung in der Vergangenheit lässt sich hier optimal mit aktuellsten Daten verbinden.

6 Diskussion

Die Anwendung wissensbasierter Bildanalysemethoden kann die Kartierung im Zuge landschaftspflegerischer und naturschutzfachlicher Fragestellungen mittels Fernerkundung auf der lokalen Maßstabsebene erheblich verbessern. Die in Kapitel 5 dargestellten Klassifikationsbeispiele zeigen, dass mit einem gewissen Aufwand sehr gute Ergebnisse mit zum Teil sehr hohen Genauigkeiten erreichbar sind. Es wird aber auch deutlich, dass natürlich auch diese Verfahren ihre Grenzen haben und Auswertungen beispielsweise auf Artebene weiterhin die Domäne von Vor-Ort-Kartierungen und der Arbeit von Spezialisten bleiben werden. Die Objektivität und die Geschwindigkeit der Auswertung können aber mit wissensbasierten Systemen erhöht werden und die Integration unterschiedlicher Informationsquellen ist ein weiterer Vorteil (Kartikeyan et al. 1995). Auch die Beständigkeit des Ergebnisses nimmt im Vergleich mit menschlichen Interpreten zu. Letztere arbeiten subjektiv, d. h. die gleiche Region wird von unterschiedlichen Kartierern jeweils anders wiedergegeben (Bie und Beckett zit. in Hutchinson 1982). Über Regelwerke wie sie in dieser Arbeit für den Bereich der gewässernahen Kartierung entwickelt wurden können unterschiedliche Fernerkundungsdaten kombiniert werden und bestehende Informationen, wie administrative oder thematische Grenzen, integriert werden. Insbesondere die weitere Nutzung und die Fortschreibung bestehender, in langen Jahren entstandener Geoinformationen ist eine der Stärken des hier angewandten Verfahrens und der entwickelten Regelwerke und Objektdefinitionen.

6.1 Datenvorverarbeitung

Die kombinierte Auswertung unterschiedlicher Datensätze erfordert eine exakte geometrische Anpassung der Datensätze aneinander. Es wurde entschieden, als Basis für die Georeferenzierung die Orthofotos der Bayerischen Vermessungsverwaltung heranzuziehen (vgl. Kapitel 4). Die Anforderungen an die Genauigkeit sind hoch, da der minimale Lagefehler (RMS) unter einem Pixel liegen sollte, was bei den panchromatischen IKONOS-Daten eine Genauigkeit von weniger als einem Meter bedeutet. Dieser Schärfebereich kann auch mit Hilfe der räumlich höher aufgelösten Orthofotos (40 cm) in der Praxis in diesen Bereich kaum erreicht werden. Zudem scheinen Topologie und Blickwinkel bei der Aufnahme die Geometrie der IKONOS-Daten stärker zu beeinflussen. Die in der Fernerkundung aufgestellte Forderung, dass für den Geländeausgleich Höhenmodelle verwendet werden sollen, die eine drei- bis viermal höhere räumliche Auflösung aufweisen als die Bilddaten, kann operationell nicht erfüllt werden (Itten et al. 1991 zit. in de Kok 2001).

Die bei optischen Sensoren geforderten hohen räumlichen Auflösungen - möglichst im Bereich unterhalb von einem Meter - lassen sich heute nur mit Hilfe von Siliziumdetektoren erreichen. Diese können aber nur einen eingeschränkten Spektralbereich im visuellen Spektrum und im nahen Infrarot abdecken. Systeme, die solche Detektoren einsetzen, weisen deshalb eine eingeschränkte spektrale Bandbreite auf (z. B. IKONOS, QuickBird 2). Bei sehr hoch auflösenden satellitengestützten Systemen ist darüber hinaus die spektrale Auflösung auf vier Kanäle beschränkt. Mit steigender räumlicher Auflösung werden immer weniger Reflexionen der Erdoberfläche pro Bildpunkt aufgenommen. Eine Verdopplung der

räumlichen Auflösung bedingt eine Abnahme der theoretisch erfassbaren Photonen pro Bildpunkt um 25 %. Dieser theoretische Wert wird noch weiter durch die atmosphärischen Bedingungen und die Reflexionseigenschaften der jeweiligen Oberflächen reduziert. Im Vergleich zu Luftbildern können die von digitalen Systemen aufgenommenen Signale aber geeicht werden, d. h. in physikalische und besser vergleichbare Messwerte umgewandelt werden. Um dieses zu erreichen, sind komplexe Vorverarbeitungsschritte zur atmosphärischen Korrektur der Daten und zur Korrektur der Topographie notwendig (Richter 1997).

Eine der Stärken des Programms eCognition ist die Fusion unterschiedlicher Daten innerhalb eines Projektes. Dem sind jedoch Grenzen gesetzt. So können zwar Daten unterschiedlicher Auflösungen kombiniert werden, aber eine lagerichtige Orientierung der Daten findet nur statt, wenn die jeweiligen Auflösungen ganzzahlige Vielfache voneinander sind. Dies war einer der Gründe dafür, dass Objekte in eCognition nicht passgenau zu orientieren waren und Versuche, CASI-Daten (3 m) mit den IKONOS-Daten (4 m) zu kombinieren, abgebrochen werden mussten.

Darüber hinaus ist die Nutzung von GIS-Datenebenen in eCognition möglich, wenn auch mit Schwierigkeiten. Auch hier sind Vorverarbeitungsschritte notwendig, da nur Polygonlayer verwendet werden dürfen. Aber auch bei diesen ist es notwendig, dass die Informationen flächendeckend vorliegen. Beispielsweise enthält die in 5.3.2.5 verwendete Biotoptypenkartierung nur Inselpolygone, d. h. einzelne Flächen, die keine gemeinsamen Grenzen haben. Hier war es erforderlich, die Bereiche ohne Information (*no data* Objekte) explizit durch ein Hintergrundpolygon abzudecken. Die hierzu notwendigen Schritte (Digitalisierung und Verschneidung mit der Biotoptypenkartierung) sind nur im Vorfeld mit einem GIS möglich. Versuche, lineare Daten einzubinden, beispielsweise ATKIS Fließgewässerinformationen, waren erfolgreich. Der Vorverarbeitungsaufwand wird dadurch aber weiter erhöht. Bei diesen kommt hinzu, dass Pufferoperationen notwendig sind, um zunächst Polygone zu berechnen. Importfehler von eCognition erzeugen manchmal fehlerhafte, zusätzliche Elemente, für die kein Eintrag in der GIS-Datenbank existiert. Diese führen dann zu weiteren Problemen mit einzelnen, eigentlich nicht vorhandenen Objekt-IDs, so dass daraus Fehlklassifikationen resultieren, welche zurzeit leider nicht zu umgehen sind. Sie treten auch bei völlig fehlerfreien GIS-Daten auf.

Eine Vorverarbeitung von Fernerkundungs- und GIS-Daten ist immer notwendig, insbesondere wenn diese fusioniert werden sollen (nach Wald 1999). Die zurzeit noch vorhandenen Probleme mit eCognition sind vergleichsweise gering und handhabbar. Sie dürfen nur in keinem Fall außer Acht gelassen werden, da sonst mühsam aufgestellte Regeln aufgrund falscher Informationen versagen. Zusammengefasst lassen sich aus den obigen Beispielen vier wesentliche Bedingungen ableiten, die von Vektordaten erfüllt werden müssen:

1. Sie müssen flächendeckend vorliegen, d. h. keine Inselpolygone.
2. „No-data“-Bereiche müssen ggf. als eigenes (Hintergrund-)Polygon erfasst sein.
3. Die Topologie muss korrigiert und konsistent sein → Fehlervermeidung beim Import in eCognition.
4. Lineare Daten können genutzt werden, wenn sie in Polygone umgewandelt werden (durch *buffering*) und die Punkte 1 und 2 beachtet werden.

6.2 Klassifikationsstrategien

Um die vorhandene Datenbasis vergleichbar auszuwerten, sollten Regelwerke geschaffen werden, welche für alle bearbeiteten Fernerkundungsdaten möglichst die gleichen Objekte klassifizieren (vgl. Abschnitt 5.1). Diese eigentlich triviale Forderung führt dazu, dass eine gemeinsame Menge an Objekten von vorneherein koordiniert und datenübergreifend identifiziert werden muss.

Bereits bei der **Segmentierung** müssen die Parameter so gewählt werden, dass Objekte inhaltlich übereinstimmen, denn die gesamte Klassifikation steht und fällt mit der „Qualität“ der Segmentierung. Dabei ist der Begriff Qualität hier relativ zu sehen, da es immer anwendungsbezogen darum geht, welche Objekte abgeleitet werden sollen. Bisher gibt es allerdings keine direkten Qualitätsmaße; es handelt sich nach Ryherd und Woodcock (1996) vielmehr um Ansätze zum Vergleich unterschiedlicher Segmentierungen. Innerhalb einer flächendeckenden Landnutzungsklassifikation existieren Objekte i. d. R. auf mehreren Maßstabsebenen gleichzeitig (Marceau und Hay 1999). Von daher ist die Segmentierung somit einer der wichtigsten Schritte in der gesamten Klassifikationsstrategie, gleichzeitig aber programmbedingt auch derjenige mit den geringsten Einflussmöglichkeiten. Gleichwohl kann das hier eingesetzte Verfahren der multiskalaren Segmentierung (*multiresolution segmentation* (Batz und Schäpe 2000)) empfohlen werden, da es nach Untersuchungen von Neubert und Meinel (2003) im Vergleich mit anderen Segmentierungsverfahren die besten Ergebnisse erzielt. Die Parameter für die Segmentierung wurden empirisch in verschiedenen Testläufen ermittelt.

Der Aufbau der **Regelwerke** ist der zweite Schritt. Es ist ein langwieriger und letztendlich subjektiver Prozess, was aber wie Houhouli und Michener (2000) darlegen, generell ein Problem bei wissensbasierten Systemen ist. Nach Scholles (1999) ist der notwendige Aufwand die Ursache dafür, dass Expertensysteme bisher kaum Anwendung im naturschutzfachlichen Bereich gefunden haben.

Objekte können mit unterschiedlichen Parameterkombinationen beschrieben werden, die dennoch zum gleichen Ergebnis führen. Es gibt fast immer mehr als eine Lösung für ein Klassifikationsproblem (vgl. de Kok et al. 2002). Um diesen Konflikt zu entschärfen und die Anforderung einer möglichst einfachen Übertragbarkeit der Regelwerke zu erfüllen, wurden Objekte so einfach wie möglich definiert (Einsatz möglichst weniger Parameter). Abhängig von der Datengrundlage führt dies zu mehr oder weniger unterschiedlichen Herangehensweisen, wie es in den Abschnitten 5.1 und 5.2 beschrieben wurde. Vor allem deshalb und aufgrund der Heterogenität der verwendeten Datenbasis unterscheiden sich die in Abschnitt 5.1 vorgestellten Klassifikationsstrategien. Für die IKONOS-Daten war es notwendig, eine Vorgehensweise zu entwickeln, die der Charakteristik der beiden Aufnahmezeitpunkte gerecht wird und ein **automatisierbares Verfahren** ermöglicht. Dabei besteht die Schwierigkeit darin, einen Kompromiss zwischen der Aufstellung einer möglichst großen Wissensbasis in eCognition und einem moderaten Verbrauch an Rechenleistung und Speicherplatzbedarf zu finden. Insbesondere bei den speicherhungrigen, sehr hoch auflösenden Bilddaten können sehr schnell die technischen Grenzen von eCognition oder der Speicherverwaltung des Betriebssystems erreicht werden. Aus diesem Grund werden

zunächst die multispektralen IKONOS-Daten in Kombination mit den aus ihnen berechneten ersten drei Hauptkomponenten ausgewertet. Die Texturinformation aus dem panchromatischen Kanal wird in Form klassifizierter Information der Wissensbasis hinzugefügt. Da aus diesen Daten die Textur die wichtigste Information darstellt, wird nur diese anschließend für die eigentliche Klassifikation der Multispektraldaten genutzt (siehe Abschnitt 5.1.1). Die direkte Verwendung der PAN-Daten im eCognition-Projekt würde die Segmentierung stark beeinflussen und die Objekte so verändern, dass eine Anpassung der Objektdefinitionen notwendig würde.

Bei allen Regelwerken wurde eine hierarchische Vorgehensweise bevorzugt. Dem liegt u. a. die Einschätzung von Hay et al. (2001) zugrunde, wonach eine Landschaft ebenfalls als ein hierarchisches Netzwerk betrachtet werden kann. Konsequenterweise sind dann der hier verwendete multiskalare Ansatz und die Arbeit mit unterschiedlichen Maßstabsebenen (Levels) der nächste logische Schritt (Hay et al. 2001).

Klassifikationsstrategie IKONOS

Bei den IKONOS-Daten wird eine Vorgehensweise verfolgt, die zunächst auf Basis der panchromatischen Daten fünf Texturklassen auf einer Maßstabsebene unterscheidet: Das Ergebnis wird dann für die weitere Nutzung exportiert. Bei den **multispektralen Daten** werden zunächst grobe Landnutzungsklassen einer kleinen Maßstabsebene in Form einer Vorklassifikation unterschieden. Diese werden dann zielgerichtet auf einem großen Maßstab der geforderten lokalen Maßstabsebene ausgewertet.

Landbedeckungsklassen wie Wasser, potentielle Feuchtgebiete, potentielle offene Moorbereiche, Grünland und Acker dienen der Vorabgrenzung. Zum einen werden leicht unterscheidbare Klassen wie Wasser und Acker differenziert. Auf der anderen Seite wird versucht Klassen, deren Eigenschaften sich im Merkmalsraum überlagern wie Grünland, potentielle Feuchtgebiete und potentielle offene Moorbereiche möglichst eindeutig voneinander zu trennen. Die Erfassung von Klassen mit möglichst allen Details und Kleinstrukturen auch auf dieser Ebene führt zum Teil zu sehr komplexen Objektdefinitionen.

Bei der Übertragung der für den August-Datensatz entwickelten Regelwerke auf die April-Daten waren erwartungsgemäß Anpassungen erforderlich. Die Struktur der Klassenhierarchie konnte erhalten werden, aber es waren Anpassungen bei den Wertebereichen der meisten Spektralparameter erforderlich (siehe auch Abschnitt 6.3). Bedingt durch den frühen Aufnahmezeitpunkt am Beginn der Vegetationsperiode existiert noch keine submerse Vegetation, die mit Satellitendaten erkannt werden könnte. Die entsprechenden Klassen werden deshalb im April-Regelwerk entsprechend in den Levels zwei und vier auch nicht abgebildet.

Für eine **multisaisonale Auswertung** beider Aufnahmen innerhalb eines eCognition-Projektes wurde die Strategie angepasst (Abschnitt 5.1.1.3). Im Gegensatz zu den vorhergehenden Analysen wurden hier sämtliche IKONOS-Daten in einem Projekt kombiniert. Der Rechenaufwand ist deshalb erheblich. Aus diesem Grund musste die Größe des Testgebietes eingeschränkt werden. Vermutlich infolge der großen Datenmenge gibt es bereits Darstellungsprobleme der multispektralen Daten in eCognition, die sich aber nicht auf die Objekteigenschaften auswirken. Es werden nur noch zwei Levels segmentiert, auf denen

Wasser, Feuchtgebiete, submerse Makrophyten, Schwimmblattvegetation, Acker und baumbestandene Objekte klassifiziert werden. Wie dies bereits Lunetta und Balogh (1999) beschrieben konnte auch bei diesem Ansatz bestätigt werden, dass sich aufgrund der kombinierten Auswertung die Klassenbeschreibungen vereinfachen. Die Hierarchie wird dann deutlich einfacher, was allerdings auch in der Beschränkung auf wenige Klassen begründet ist. Ausgehend von einem initialen Level, auf dem Feuchtgebiete und Wasserklassen getrennt werden, wird anschließend ein neuer Level mit Hilfe einer klassifikationsbasierten Segmentierung erzeugt. Klassifizierte Objekte des ersten Levels werden zusammengefasst. Auf dieser Basis können dann falsch klassifizierte Acker- oder Grünlandbereiche des ersten Levels über ihre Form korrigiert und aus der Feuchtgebietsklasse herausgenommen werden. Im Prinzip kann hier mit der gleichen Strategie auf niedrigeren Levels detailliert klassifiziert werden. Diese rekursive Strategie in mehreren Durchgängen (mindestens drei) ist für hochgenaue, automatisierbare Klassifikationen notwendig.

Klassifikationsstrategie CASI

Die Strategie zur Auswertung der hyperspektralen CASI-Daten verwendet gleichfalls einen hierarchischen Ansatz. Hier werden auf mehreren Levels (jeweils der gleichen Maßstabsebene) zunächst grobe Klassen abgegrenzt, die anschließend detaillierter ausgearbeitet werden. Bemerkenswert war hierbei, dass nur unter Verwendung aller Spektralkanäle die „beste“ Segmentierung erreicht wurde. Alle Versuche, mit ausgewählten Kanalkombinationen zu arbeiten, führten zu schlechteren Ergebnissen (Löschenbrand 2003, S.37f.). Die Ursachen hierfür könnten u. a. in der Redundanz der Spektralkanäle liegen. Diese überdecken sich im Merkmalsraum und bilden evtl. Objekte unterschiedlich ab. Schwerwiegender ist vermutlich aber die Vorauswahl von 20 aus 44 aufgenommenen Kanälen. Diese Vorauswahl wurde mit dem Ziel der Datenreduktion getroffen, ohne die wichtigsten Informationen zu verlieren. Wenn man die Kanalauswahl derartig einschränkt, gibt es im Gegensatz zu dem oben beschriebenen Problem kaum noch redundante Kanäle und alle Informationen sind für eine korrekte Segmentierung notwendig.

Im Vergleich zu der Vorgehensweise bei den IKONOS-Daten wird bei den CASI-Daten eine strengere Hierarchie innerhalb der Maßstabsebenen durchgehalten (siehe Abschnitt 5.1.2). Nach und nach werden sichere Klassen ausgeschieden und anschließend wird nur noch innerhalb der unklassifiziert gebliebenen Restobjekte weitergearbeitet. So werden die CASI-Daten zunächst in „Wasser“ und „nicht-Wasser“ unterschieden, um dann auf einem weiteren Level nur noch die „nicht Wasser“-Bereiche weiter in „Wald“ und „nicht-Wald“ zu unterteilen. Dieses Verfahren wird durchgehalten, bis schließlich die Feuchtgebiete übrig bleiben und detailliert auf Level 2 klassifiziert werden können. Lunetta und Balogh (1999) ziehen ein ähnliches Verfahren vor. Sie klassifizieren auf Basis multisaisonalen Landsat-TM-Daten zunächst hydrische und nicht-hydrische Bereiche, um diese anschließend mit einem regelbasierten Ansatz weiter zu differenzieren.

Klassifikationsstrategie Orthofotos

Die Vorgehensweise für die Klassifikation der Orthofotos entspricht im Prinzip dem hierarchischen Vorgehen bei den CASI-Daten. Im Unterschied zu diesen werden hier jedoch bereits innerhalb eines Levels zunächst die sicheren Klassen wie „Wasser“ abgegrenzt und die restlichen Objekte als „nicht-Wasser“ klassifiziert. Objekte, die sich hier in besonderem Maße im Merkmalsraum überlagern wie „Wasser“ und „Wald“ oder die „Feuchtgebiete“ werden auf weiteren Levels gesondert abgegrenzt (vgl. Abschnitt 5.1.3). Innerhalb dieser Grenzen kann anschließend detailliert gearbeitet werden. Trotz der schon erwähnten starken Unterschiede in den einzelnen Orthofotoaufnahmen bleibt diese Vorgehensweise grundsätzlich immer gleich. Lediglich die objektbeschreibenden Merkmale werden angepasst (siehe Abschnitt 6.3). Aufgrund der fehlenden Spektralinformation in Orthofotos sehen Geneletti und Gorte (2003) davon ab, nur auf dieser Basis auszuwerten. Die Autoren versuchen vielmehr die mangelnde spektrale Information der Orthofotos durch spektrale Informationen aus Landsat-TM-Daten zu kompensieren. Sie kombinieren die bereits vorklassifizierte Information eines Landsatbildes mit der segmentierten, hohen räumlichen Information von Luftbildern. Ihre Vorgehensweise ist aufgrund der unterschiedlichen Datengrundlagen nur zum Teil vergleichbar mit der in dieser Arbeit entwickelten Strategie. Die beiden Autoren analysieren in einem letzten Schritt den Flächenanteil bestimmter Klassen der Landsat-Klassifikation und weisen so den Segmenten des Orthofotos wiederum ihre Klasse zu, was mit dem levelübergreifenden Zugriff auf klassifizierte Objekte bei den in dieser Arbeit vorgestellten Ansätzen vergleichbar ist. Auch Geneletti und Gorte (2003) weisen darauf hin, dass auch bei ihrer Methode die Ermittlung der Segmentierungsparameter und die Entwicklung der Entscheidungsregeln für die Klassifikation die kritischen Punkte darstellen. Da diese Parameter i. d. R. nicht *a priori* ermittelt werden können, wurden die Werte für die Segmentierung und die Klassifikation empirisch ermittelt. Der Zeitaufwand für die Aufstellung der Regelwerke ist auch bei diesem Ansatz hoch. Die Autoren haben ihren Ansatz mit mittelauflösenden Landsatdaten (30 m) und vergleichsweise niedrig auflösenden Orthofotos (7.5 m) getestet. Die Kombination so unterschiedlich aufgelöster Daten scheint schwer vereinbar, und die Übertragbarkeit der Methode auf sehr hoch auflösenden Daten wurde von den Autoren nicht erprobt. Deshalb ist deren Ansatz nicht direkt auf die in dieser Arbeit verwendeten Daten anwendbar.

Fazit

Die dargelegten Strategien, mit unterschiedlichen, dem Datensatz angepassten Regelwerken dasselbe Objekt vergleichbar zu klassifizieren, haben sich als erfolgreich erwiesen. Wie die Tabelle (Tab. 14) im Abschnitt 5.1.4 zeigt, können bei allen verwendeten Datengrundlagen nahezu die gleichen Klassen ausgeschieden werden. Ausnahmen ergeben sich hier vor allem bei den Luftbildern, da sie zum Teil aufgrund ihres Alters einen so eingeschränkten Grauwertbereich aufweisen, dass bestimmte Klassen nicht getrennt werden können. Bei den CASI-Daten werden vor allem vegetationsbedeckte Bereiche innerhalb von Wasserflächen aufgrund des späten Aufnahmezeitpunktes im September 1999 nicht klassifiziert. Dieses Problem ist aber weder den Daten bzw. deren Qualität noch der Klassifikationsstrategie anzulasten, sondern einzig dem Zeitpunkt der Aufnahme. Der Wahl

des Aufnahmezeitpunktes kommt damit eine wesentliche Bedeutung für die Qualität des Ergebnisses zu. Klemas (2001) fordert daher einen Dialog zwischen Experten unterschiedlicher Fachrichtungen, um dieses Problem zu vermeiden und Aufnahmezeitpunkte zu wählen, die für die jeweilige Problemstellung richtig sind.

Die entwickelten Klassenhierarchien sind in ihrer Struktur stabil und führen zu konsistenten Ergebnissen. Wie Kartikeyan et al. (1995) berichten, ändern sich auch hier nur die Parameter (siehe auch Abschnitt 6.3), während die Klassenhierarchie, also die Struktur des Regelwerks, stabil bleibt. Sie kann immer in der gleichen Form auf andere Daten des gleichen Typs übertragen werden. Ein Anpassungsaufwand besteht allerdings immer bei den Objektdefinitionen, nicht aber bei der grundsätzlichen Struktur der Regelwerke (Houhoulis und Michener 2000). Die Übertragung von Regelwerken für Luftbilder auf Satellitenbildaufnahmen ist jedoch nicht möglich, da die Unterschiede in den Datentypen zu groß sind.

6.3 Objektdefinitionen

Die Definition der einzelnen Objekte innerhalb einer Klassenhierarchie ist neben der Segmentierung ein wesentlicher Schritt auf dem Weg zu einer automatisierten Klassifikation. Die Objektdefinition ist mit Abstand der aufwendigste und zeitintensivste Abschnitt der Arbeit. Zunächst muss herausgefunden werden, über welche **Eigenschaften** sich Objekte in der fachspezifischen Realität definieren. Fernerkundungsdaten liefern immer nur ein zeitlich und räumlich eingeschränktes Bild der Realität. Dafür bieten sie zum Teil wesentlich erweiterte spektrale „Erfahrungen“ sowie einen großen räumlichen Überblick. Die Arbeit mit Objekten erweitert zwar die Wissensbasis um wichtige Zusatzinformationen, kann aber gleichzeitig den Blick auf einzelne (Unter-)Objekte durch Generalisierung zum Teil einschränken, denn es steht nur noch die gemittelte Information der Pixel eines Objektes zur Verfügung. Diese Generalisierung ist aber gewollt, um den bereits angesprochenen „salt’n’pepper“ Effekt schon im Vorfeld zu vermeiden. Darüber hinaus stehen Informationen über die statistische Verteilung von Grauwerten innerhalb eines Objektes zur Verfügung. Thematisch sollen nach wie vor auch mit räumlich sehr hoch auflösenden Daten fachliche Objekte detektiert werden, also beispielsweise ein gesamter Schilfbestand und nicht dessen einzelne Bestandteile.

Auf unterschiedlichen **Maßstabsebenen** werden Objekte verschiedenartig repräsentiert und durch andere Eigenschaften charakterisiert (Curran und Atkinson 2002). Ein Experte kann über alle diese Ebenen gleichzeitig arbeiten, Objekte wahrnehmen und beurteilen (vgl. auch Abschnitt 2.4). Das **Expertenwissen**, das ein erfahrener Interpret besitzt, ist in einer Wissensbasis aber nicht oder nur formalisiert in Form externer Information enthalten. Durch die Formulierung von semantischen und physikalischen Regeln und die Kombination unterschiedlichster Fernerkundungs- und Geodaten wird versucht, diesen Mangel an menschlicher Erfahrung bei der Klassifikation zu kompensieren. In den Wissensbasen und Regelwerken fehlen naturgemäß die sinnlich erfassbaren Anteile sowie Intuition und die komplexe menschliche Interaktion, die normalerweise zu einer Entscheidung führen. Laut Scholles (1999) wird das menschliche Wissen bei der Formulierung von Regeln zu einseitig auf Fakten und Regeln reduziert. Dennoch ist für den Erfolg einer Klassifikation eben genau diese Strukturierung des Wissens entscheidend.

Die Gegenüberstellung der unterschiedlichen **Objektdefinitionen** in Abschnitt 5.2 zeigt, dass bestehendes (Experten)Wissen, das oft bereits in Kartieranleitungen (Bundesamt für Naturschutz (BfN) 1995) formalisiert vorliegt, umformuliert werden kann. Mit Hilfe der berechneten Parameter aus Fernerkundungsdaten können Eigenschaften von Objekten in Regeln abgebildet werden. Erst die zusätzlich in der **Objektdatenbank** von eCognition zur Verfügung stehenden Objekteigenschaften wie Lage, Textur, topologische Eigenschaften und besonders die Beziehungen zu Nachbarobjekten, machen die Einbeziehung bestehenden Wissens möglich. Das gilt als der eigentliche Vorteil der Objektorientierung. Objekte werden so abgebildet, dass sie im Sinne ihrer Repräsentation und Manipulation für den Nutzer effizienter sind (Ehlers et al. 1991). Das bedeutet, sie liegen in einer dem Menschen vertrauteren Darstellung vor. Auf der anderen Seite wird damit aber auch deutlich, dass die Verwendung vieler der in eCognition zur Verfügung stehenden Parameter nicht eindeutig ist, und objektcharakterisierende Wertebereiche zum Teil nur empirisch ermittelt werden können (vgl. hierzu auch de Kok 2001, S.63f). De Kok (2001) hat u. a. verschiedene Visualisierungsmethoden getestet, um die Auswahl der Parameterkombinationen zur Klassentrennung zu unterstützen. Parameter in der eCognition-Datenbank werden zu einem RGB-Bild neu kombiniert. Neue Werkzeuge der aktuellen eCognition Version sollen im Vorfeld die Bedeutung einzelner Parameter für die erfolgreiche Klassifikation von Objekten berechnen. Diese Werkzeuge ebenso wie die von de Kok entwickelte Methode erfordern den Experten, der eine sinnvolle Vorauswahl von Parametern liefern muss. In der Folge sind die verwendeten Regeln also heuristischer Natur, da ihre statistische Ableitung nicht immer möglich ist (Buck 2001).

Aus diesen Gründen erfordert die Entwicklung von Regelwerken **Experten**, die Fernerkundungswissen und Fachwissen auf unterschiedlichen Gebieten in sich vereinen (Scholles 1999, Zhu et al. 1998). Die Objektdefinition kann subjektiv geprägt sein, wird aber, da sie auf bestehende Regeln (z. B. Kartieranleitungen) aufbaut, dennoch die Forderung nach Allgemeingültigkeit und Übertragbarkeit erfüllen.

Die geforderte **Übertragbarkeit** ist nur bedingt zu erreichen, da die wesentliche Information von der eine erfolgreiche Klassifikation abhängt die spektrale Reflexion der Erdoberfläche ist (vgl. hierzu auch Abschnitt 3.3). Wenn sie vorliegt, wird diese bevorzugt für die Objektdefinitionen herangezogen. Aufgrund von veränderten Aufnahmebedingungen, -zeitpunkten, Bewölkung, etc. ist aber gerade diese wesentliche Information Schwankungen unterworfen. Die hier entwickelten Regelwerke fangen diese Schwierigkeiten ab, indem sie versuchen, abgeleitete Parameter und klassenbasierte Objekteigenschaften zu betonen, um dann in der Parameterkombination die Wertebereiche pro Parameter großzügig auslegen zu können. Die Objekteigenschaften wurden konsequent in stabil und instabil unterschieden (vgl. Mott et al. 2002). Bei dieser Aufteilung fallen nicht nur spektrale Merkmale in die Kategorie instabil, sondern auch abgeleitete Parameter wie die Standardabweichung der Grauwerte pro Objekt oder die in eCognition zur Verfügung stehenden Ratios. Die Texturparameter würden im Wesentlichen in die Kategorie stabil fallen, da sie aber ebenfalls von der spektralen Ausprägung des Datensatzes abhängig sind, ist diese Einteilung nicht immer durchzuhalten. Aufgrund eines Fehlers der aktuellen eCognition Version 3 weichen

die berechneten Texturparameter identischer Objekte in unterschiedlichen, leicht verschobenen oder vergrößerten Ausschnitten des Gesamtbildes voneinander ab. Hierbei handelt es sich zwar um Änderungen der zweiten Stelle nach dem Komma, was bei einem Wertebereich zwischen 0 und 1 aber schon zu ungewollten Änderungen von Klassen führen kann.

Als stabil wurden semantische Eigenschaften bezeichnet, welche z. B. die relative Lage von Objekten beschreiben. So wird ein Feuchtgebiet immer in einer gewissen Nähe zu Wasser liegen, unabhängig von seiner spektralen Ausprägung. Eine Insel wird immer vollständig von Wasser oder einer anderen Klasse umgeben sein. Der Anpassungsaufwand bei einer Übertragung auf andere Daten wird durch den konsequenten Einsatz stabiler Parameter minimiert. Ein vollständiger Verzicht auf die Verwendung instabiler Objekteigenschaften ist wie oben dargelegt aber nie möglich.

Ein allgemein anerkannter Vorteil von Systemen, die Entscheidungsregeln auf Basis von *fuzzy logic* einsetzen, ist die Fähigkeit, Wissen unscharf formulieren zu können. Wertebereiche müssen nicht genau festgelegt werden und fließende Übergänge der Natur können modelliert werden (vgl. Buck 2001).

Trotzdem ist im Endergebnis nur eine eingeschränkte Übertragbarkeit zu möglich. Die Entwicklung eines einzigen Regelwerkes für unterschiedlichste FE-Daten ist unwahrscheinlich. Selbst die Übertragung auf Szenen des gleichen Sensors, die in einer anderen Vegetationsperiode aufgenommen wurden, ist nur mit großen Anpassungen zu erreichen. Objekte stellen sich im Jahresverlauf unterschiedlich dar: Abhängig von der Vegetationsperiode kann sich die Reflexion erheblich ändern. Von leichten Verschiebungen des Red Edge bis zu kompletten Änderungen in der Reflexion ist jeder Übergang möglich. Beispielsweise tragen Laubbäume im Winter kaum zum reflektierten Signal bei, hier ist eher die Bodenreflexion dominierend. In diesen Fällen verspricht eine Kopplung von Informationen aus den Regelwerken mit Wachstumsmodellen Hilfe. Solche Modelle können die erwartete Reflexion von Vegetationsbeständen in einem gewissen Maß vorhersagen.

6.3.1 Anwendung der Objektdefinition

Ziel war es, in allen Objektdefinitionen möglichst stabile Objekteigenschaften zu verwenden, um von spektralen Unterschieden unabhängig zu sein. Zusammen mit den Informationen aus Expertenwissen bzw. bestehenden Kartieranleitungen wurden die Objektdefinitionen so entwickelt, dass sie möglichst einfach und nachvollziehbar sind. Hierbei können auch bei den komplexen Definitionen alle Schritte später noch nachvollzogen und Fehler schnell eingegrenzt werden (Buck 2001). Die verwendeten Parameter wurden so gewählt, dass sie möglichst genau der Beschreibung von Objekten aus den verwendeten Referenzen entsprechen. So wurde beispielsweise dort, wo es möglich war, klassenbasierten Nachbarschaftsparametern wie der Entfernung von Objekten der Vorzug vor einer spektralen Definition gegeben (vgl. auch Abschnitt 5.2 oder Anhang 1).

Die Verwendung eines Distanzparameters zu Wasserflächen war insofern zulässig, da ohnehin nur Feuchtgebiete im ufernahen Bereich analysiert werden sollten. Die Klassifikationen wurden auf diese Weise vereinfacht, da Überschneidungen im Merkmalsraum

vermieden werden konnten. Auch von Sader et al. (1995) wird ein solches Vorgehen vorgeschlagen, um Fehlklassifikationen zu minimieren.

Die Kombination von Daten unterschiedlicher Vegetationsperioden kann die o. a. Überschneidungsprobleme im Merkmalsraum vermindern. Deshalb wurde in dieser Arbeit als weiterer Ansatz die Nutzung multisaisonaler Aufnahmen vom Beginn und vom Ende der Vegetationsperiode verfolgt. Auch Lunetta und Balogh (1999) argumentieren für eine **kombinierte Auswertung multisaisonaler Aufnahmen**. Sie beobachten bei ihren Analysen eine Steigerung der Gesamtklassifikationsgenauigkeit von 69% auf 88%. Auch Sader et al. (1995) weisen bei der Klassifikation von Feuchtwäldern nach, dass ein regelbasierter GIS-Ansatz signifikant bessere Klassifikationsergebnisse erzielt. Hierbei wird eine unüberwachte Klassifikation einem *Tasseled Cap*-Ansatz, einer hybriden Klassifikation und dem regelbasierten Ansatz gegenüber gestellt. Allerdings ist deren regelbasierter GIS-Ansatz nur bei der Klasse „Feuchtwald“ überlegen. Andere Klassen werden hier vom hybriden Ansatz besser klassifiziert. Probleme bei der Abgrenzung von Klassen, beispielsweise bei Wald, insbesondere Waldschatten, bestehen auch bei den in dieser Arbeit verwendeten Daten. Diese Probleme lassen sich aber mit Hilfe der klassenbasierten Nachbarschaftsparameter weitgehend vermeiden. Aufgrund der mehrfachen Klassifikationsdurchläufe (vgl. 2.6.2.3) können auf jeden Fall Schattenobjekte und dunkle Waldbereiche, die in direkter Nähe von Wald liegen oder vollständig von Wald umgeben sind, erfolgreich zugeordnet werden.

Die in dieser Arbeit verwendeten Regelwerke für die IKONOS-Daten wurden zunächst anhand der Augustaufnahme entwickelt und anschließend auf die Daten des Aprils übertragen. Durch **spektrale Überlagerungen** fallen besonders die Feuchtgebiets-, Moor- und Grünlandklassen auf. Zusätzlich zu den beschreibenden Objekteigenschaften mussten in die Objektdefinition empirische, in eCognition ermittelte Parameter aufgenommen werden, um in Teilbereichen eine Trennung zu ermöglichen. So sind verwendete Parameter wie z. B. die „mittlere spektrale Differenz zu Nachbarobjekten“ oder die Verwendung von Hauptkomponenten in Verbindung mit der originalen spektralen Information nicht aus der Literatur oder dem Expertenwissen ableitbar. In der Praxis hingegen zeigte sich, dass sich einzelne Objekte nur mit Hilfe dieser zusätzlichen Parameter unterscheiden lassen.

Bei der **Übertragung** des Augustregelwerks auf den April waren Anpassungen notwendig. Da sich die Ausprägung der Vegetation, speziell der Feuchtfächen, deutlich von der im August unterscheidet. Zum Beispiel wird Schilf, im Gegensatz zur grünen Reflexion im August, im April von toten Halmen dominiert und erscheint braun. Solche unterschiedlichen Ausprägungen können innerhalb eines einzigen Regelwerkes nur schwer berücksichtigt werden. Zwar ist es möglich, die Information über den Aufnahmezeitpunkt in den Bilddaten zu kodieren und somit in die Objektdefinitionen einzubeziehen, allerdings führt dies nicht unbedingt zu einfachen und übersichtlichen Regelwerken. Auch Veränderungen in der Landbedeckung selbst machen ggf. Anpassungen in den Objektdefinitionen notwendig. So ändert sich beispielsweise die Reflexion einer Streuwiese nach der Mahd erheblich und kann bei Nichtbeachtung zu Fehlklassifikationen führen.

6.3.2 Nutzung externer Daten

Bereits in der Vergangenheit wurde wie Houhoulis und Michener (2000) berichten die Integration von externen Kartierungen für die Vorabgrenzung von Untersuchungsgebieten eingesetzt. Die Autoren beschreiben ein *change detection*-System, das Karten des *national wetland inventory* (NWI) der Vereinigten Staaten mit Hilfe von Satellitendaten und weiteren Kartierungen in einem regelbasierten System aktualisiert. Die Entwicklung von Regelwerken wird hierbei als sehr zeitintensiv beurteilt. Die einmal entwickelten Regeln gelten aber als leicht übertrag- und anpassbar. Auch Growe (2000) beschreibt die Nutzung von GIS-Daten, die den Interpretationsprozess vereinfachen und die Vollständigkeit sowie die Korrektheit seiner Szenenbeschreibungen erhöhen.

Die Ergebnisse dieser Arbeit zeigen, dass die Integration von **externer Geoinformation** z. B. in Form administrativer Grenzen der Biotoptypenkartierung, die Objektdefinition komplexer und einfacher zugleich macht. Im Fall eines möglichst flexiblen Regelwerkes müssten einerseits Regeln für jeden möglichen Fall nebeneinander existieren, andererseits können externe Informationen die komplette Vorklassifikation ersetzen. Mit Hilfe von GIS-Daten ist eine selektive Interpretation von Teilbereichen möglich. Aussagen über die Topologie und die Ausprägung von Objekten können bereits an dieser Stelle gezielt getroffen werden (vgl. Growe 2000). Der obige Widerspruch führt dazu, dass eine Nutzung externen Daten sehr genau im Vorfeld überlegt werden muss. Eine spätere Einbindung solcher Daten in ein bestehendes eCognition-Projekt ist zwar möglich, erfordert aber eine erneute Segmentierung, was i. d. R. zu einer Veränderung der Objekte führt. Das wiederum erhöht den Anpassungsaufwand bei den Objektdefinitionen, der über die reine Einbindung der neuen Information weit hinausgeht.

Das Beispiel der Feuchtgebietsdefinition bei den IKONOS-Daten verdeutlicht beide Fälle. Hier existieren bereits zwei unterschiedliche Definitionen nebeneinander. Zusätzlich wird in jede dieser Regeln die externe Information als weitere Objekteigenschaft eingefügt, welche die Existenz von Waldobjekten beinhaltet. Waldobjekte werden hier über eine externe Kartierung als thematische Information eingefügt und Objekte daraufhin ggf. korrigiert. Die Regeln funktionieren aber auch bei Abwesenheit dieser Waldmaske. Feuchtgebiete beinhalten dann in der Vorklassifikation auch Teile des ufernahen Waldes. Diese Objekte werden später mit den für eine andere Maßstabsebene aufgestellten Regeln korrigiert. Auch für die **Vereinfachung von Regelwerken** kann das Beispiel der Feuchtgebiete dienen. Werden die administrativen Grenzen der Feuchtgebiete aus der Biotoptypenkartierung übernommen wie am Ende des Abschnittes 5.3.2 beschrieben, kann auf die Vorabgrenzung von Grünland und Äckern verzichtet werden. Auch die Abgrenzung der Klassen „potentielles Feuchtgebiet“, „potentielle offene Moorfläche“ und „Wasser“ wären in der Vorklassifikation nicht mehr notwendig. Sie werden aber dennoch klassifiziert, da die Regeln der Objekte auf den detaillierten Maßstabsebenen auf diese Klassen zurückgreifen.

6.3.3 Vergleich der Objektdefinitionen

Die beispielhafte Gegenüberstellung der Objektdefinitionen in Abschnitt 5.2 zeigt die Unterschiedlichkeit der Datengrundlagen deutlich. Insbesondere fällt auf, dass bei den CASI-Daten oft wenige, dann allerdings spektrale Merkmale für die Objektbeschreibung

ausreichen. Die Definition für IKONOS-Daten ist dagegen etwas komplexer, da hier zusätzlich mehr Textur- oder Nachbarschaftsparameter zum Einsatz kommen. Mit Hilfe dieser Zusatzparameter und der Einbindung der vorher berechneten Hauptkomponenten wird die geringe spektrale Auflösung der IKONOS-Daten weitgehend ausgeglichen. Die Objektdefinition für die Orthofotos ist dagegen ungleich komplexer ebenso wie die Struktur der Klassenhierarchien. Dem Mangel an spektraler Information muss hier durch verstärkte Nutzung von Texturparametern und Nachbarschaftsbeziehungen sowie ggf. der Auswertung von Höheninformation entgegen gewirkt werden. Aufgrund dieser Tatsache können hier nicht alle Klassen, die mit IKONOS oder CASI möglich sind, klassifiziert werden.

6.4 Klassifikationsergebnisse und –qualität

Die mit den entwickelten Regelwerken erzeugten Klassifikationen und die erzielten Klassifikationsgenauigkeiten erreichen ein Niveau, das demjenigen vergleichbarer Untersuchungen mit FE-Daten des Landsat-Typs entspricht. Bereits die Klassifikation auf groben Maßstabsebenen mit übergreifenden Klassen erzielen sensorübergreifend Genauigkeiten im Bereich 65 % bis über 90 %. Dies ist deshalb bemerkenswert, weil die Klassifikationsgenauigkeit mit zunehmend höheren räumlichen Auflösungen und dem Anspruch, immer detaillierter zu arbeiten, abnimmt wie Zadeh (1973) betont.

Die Genauigkeitsanalyse der Ergebnisse gestaltete sich insofern schwierig, weil keine Vergleichsbasis vorlag, die für alle Daten genutzt werden konnte. Für die kleineren Testgebiete der Orthofotos und CASI-Daten lagen aktuelle Kartierungen vor, die einen flächendeckenden Vergleich ermöglichten und deshalb bevorzugt wurden. Hierfür wurde eine Kartierung herangezogen, die im Beobachtungszeitraum erhoben wurde (Kangler 2003). Für zusammengesetzte Testgebiete der IKONOS-Klassifikation oder gar für das gesamte Untersuchungsgebiet war diese Referenzkartierung räumlich und thematisch allerdings nicht ausreichend. Deshalb wurden mit Hilfe einer Zufallsauswahl und auf Basis von Expertenwissen zusätzliche Testobjekte ausgewählt und im Gelände überprüft. Mit diesen wurde anschließend angelehnt an Congalton (1991) die **Genauigkeitsanalyse** der IKONOS-Daten durchgeführt.

6.4.1 Vorklassifikation

Es fällt auf, dass hohe Genauigkeiten dort erzielt wurden, wo großflächige Objekte analysiert wurden. So liegen die Werte bei den offenen Hochmoorflächen, bei Wasser und bei der Waldmaske durchgehend über 90 %. Objekte, die flächenmäßig einen erheblich kleineren Anteil haben, werden oft deutlich schlechter bewertet. Die Klassifikationsgenauigkeit bei dichtem Schilf liegt teilweise unter 30 %, ebenso die Werte für submerse Vegetation. Die Erklärung für diese Fehlklassifikationen liegt darin, dass für diese Klassen nur wenige Testobjekte gefunden werden konnten. Des Weiteren liegen Objekte auf dieser großen Maßstabsebene oft in Übergangsbereichen. Ein Experte bewertet deshalb Testobjekte an solchen Stellen manchmal anders als die Regelwerke. Da hier Objekte und nicht einzelne Bildpunkte überprüft werden, wirkt sich ein falsch klassifiziertes Objekt wesentlich stärker aus, wenn nur wenige Testobjekte zum Vergleich zu Verfügung stehen.

Objekte in **Übergangsbereichen** sind für die Klassifikation und die spätere Analyse der Genauigkeit immer schwierig. In diesen Übergangsbereichen, in denen bereits Experten Interpretationsprobleme haben, kann auch ein noch so ausgefeiltes Regelwerk keine allseits befriedigende Lösung bringen. Das klassifizierte Ergebnis ist zwar immer eindeutig, aber bei einer anderen Sichtweise des überprüfenden Experten, je nach Fachgebiet, anders d. h. unter Umständen auch falsch. In besonderem Maße fällt dies bei den Verbuschungsbereichen im Hochmoor auf. Hierbei wird i. d. R. die Waldmaske vorgezogen (vgl. 5.3.2.2), genauso wie ein Förster im Gelände hier Wald klassifizieren würde. Je nach Fragestellung würde ein Biologe das gleiche Gebiet vermutlich als Hochmoor ansprechen. Die Regelwerke müssen sich aber an die Information aus den Fernerkundungsdaten halten. Aus diesen lassen sich verbuschte Bereiche nur inmitten eindeutiger Hochmoorflächen abgrenzen, im Randbereich hingegen werden die Flächen eher dem Wald zugewiesen. Das bedeutet für das Beispiel des Hochmoores, dass ein Objekt immer als Busch oder verbuschter Bereich klassifiziert wird, aber niemals als Busch auf Moorboden. Dieses gilt allerdings nur bei alleiniger Auswertung der Fernerkundungsdaten. Liegt eine exakte Moor- oder Bodenkarte vor, dann kann diese Information, wie in Abschnitt 6.3.2 beschrieben, genutzt werden, um Büsche auf Moorboden zu klassifizieren.

Solche Überschneidungsprobleme gibt es auch zwischen Grünland und Feuchtgebietsobjekten. Hier gilt ebenfalls, dass mit Zusatzdaten die beschreibenden Regeln einfacher gestaltet werden können. Dennoch erfolgte die Klassifikation von Grünland auch auf dieser Maßstabsebene auf einem hohen Niveau mit Genauigkeiten von bis zu 98 %. Wie oben beschrieben werden bei der Auswertung von Fernerkundungsdaten ohne Zusatzinformationen, die Objektdefinitionen schnell komplex. Es müssen sehr viel mehr und evtl. schwer erklärbare Parameter (solche, die ein Objekt nicht direkt beschreiben, wie beispielsweise die „mittlere spektrale Differenz von Nachbarobjekten“) zur Abgrenzung herangezogen werden. Dennoch gelingt bereits auf Level 4 eine eindeutige und qualitativ hochwertige Abgrenzung dieser Klassen voneinander.

6.4.2 Detailklassifikation

Nachdem zunächst übergreifende Klassen auf höheren Levels abgegrenzt wurden, wurde innerhalb dieser **Grenzen im Detail** weiter gearbeitet. Auch hier zeigt sich sensorübergreifend das schon angesprochene Problem. Je detaillierter die Klassifikation wird, desto schwieriger ist es, hohe Klassifikationsgenauigkeiten zu erzielen (vgl. Abschnitt 2.7.1). Beispielsweise können die Werte auch der Detailklassifikation beim Schilf unter 30 % sinken. Bei der IKONOS-Aufnahme vom August liegen sie noch am höchsten mit ca. 63 %. Bei den Orthofotos wurde deshalb entschieden, dass die Feuchtgebietsklassen zusammengefasst werden. Ein weiterer Grund für die Zusammenfassung war die zum Teil schlechte inhaltliche Übereinstimmung der klassifizierten Objekte mit den Klassen der Referenz. In der Referenz wurde Schilf nicht gesondert ausgewiesen. Mit Hilfe der spektralen Information der IKONOS- und insbesondere der CASI-Daten lassen sich Schilfbereiche erkennen und unterscheiden. Im Vergleich dazu ist dies auch mit den Orthofotos nur schwer zu erreichen. Die Regeln werden komplex oder die Detailtiefe lässt sich mit diesen Daten gar nicht erreichen.

Wasser kann aufgrund seiner sehr hohen Energieabsorption im nahen Infrarot (Wasser erscheint hier nahezu schwarz) sehr einfach klassifiziert werden (vgl. u. a. Lillesand und Kiefer 2000, S.19). Auch hier werden bei allen verwendeten Sensoren sehr hohe Klassifikationsgenauigkeiten von ca. 90 % oder weit darüber erzielt. Die kleinen Objekte wie die Verbindungskanäle zwischen den Seen können nur mit der hohen räumlichen Auflösung der verwendeten Sensoren erkannt werden. Da diese Objekte aber immer im Übergangsbereich zwischen Wasser und Land liegen, ist die Gefahr einer Fehlsegmentierung und einer anschließenden Fehlklassifikation hoch. Die Regelwerke für derartig kleine Objekte sind deshalb sehr anfällig für kleinste Änderungen, die im Zuge einer veränderten Segmentierung auftreten können, beispielsweise weil eine neue, externe Informationsebene in ein Projekt eingefügt wurde. Bei den Entwässerungskanälen im Hochmoor zeigt sich diese Problematik in besonderer Weise. Die Objektdefinition für diese Klasse wurde ausschließlich anhand der IKONOS-Daten erstellt. Sie nutzt zur Abgrenzung von anderen Wasserklassen das Länge-zu-Breite-Verhältnis des Objektes. Nach Einfügen der externen Waldmaske und der erneuten Segmentierung hatten sich diese Objekte soweit verändert, dass dieses Verhältnis nicht mehr vom Wertebereich des Parameters in der Objektdefinition erfasst wurde. Eine vollständige Klassifikation war nicht mehr möglich. Daraus lässt sich für die generelle Klassifikationsstrategie ableiten, dass die Verwendung externer Informationen bereits im Voraus geplant werden und auch in die Überlegungen für die Einstellung der Segmentierungsparameter einfließen muss. So betonen Baatz et al. (2002), dass externe thematische Ebenen auch bei der Segmentierung eingebunden sein müssen, wenn deren Informationen in der Klassifikation verwendet werden sollen. Daraus resultieren allerdings wieder Veränderungen der Objekte. Eine flexible Einbindung beliebiger thematischer Ebenen im Laufe des Klassifikationsprozesses ist daher nicht möglich.

Mit Hilfe der **multisaisonalen Auswertung** lassen sich die Ergebnisse verbessern. Zum einen werden bei den submersen Makrophyten deutlich höhere Klassifikationsgenauigkeiten erzielt, zum anderen ist die erfolgreiche Unterscheidung von Schwimmblattbeständen und submerser Vegetation nur mit dieser kombinierten Information möglich.

6.4.3 Landschaftsveränderung

Auch Veränderungen innerhalb der Testgebiete können zu Fehlklassifikationen führen. So ist z. B. eine Mahd von Streuwiesen zwischen den beiden Aufnahmezeitpunkten im Testgebiet durchgeführt worden. Die betroffenen Objekte wurden daher im August nicht mehr als Feuchtgebiet klassifiziert, die Beurteilung dieser Flächen in den Referenzkartierungen verändert sich jedoch nicht, was die Klassifikationsgenauigkeit negativ beeinflusst. Insbesondere bei den Orthofotos ist über den langen Zeitraum, den die Zeitreihe abdeckt, mit solchen Unterschieden zu rechnen. Die Regelwerke und die Klassifikationsergebnisse bilden diese Unterschiede ab. So werden nicht in jedem Jahr die gleichen Klassen unterschieden. Letzteres hängt aber auch mit der sehr unterschiedlichen Bildqualität der Orthofotos zusammen. Nicht nur die Auflösung, Kontrast und Helligkeit sind unterschiedlich, zudem scheint sich nach Beobachtungen von Rogg (2003) der vom Film abgedeckte Spektralbereich sich in den Jahren zu unterscheiden.

Diese Problematik ist in den Regelwerken für die Orthofotos weitestgehend berücksichtigt. Mit ihrer Hilfe wird die Analyse von **Landschaftsentwicklungen** an Hand von Zeitreihen möglich. Fehler sind hierbei nicht vollständig zu vermeiden, sie sind aber i. d. R. von einem Experten leicht zu erkennen und beispielsweise in einem GIS zu beseitigen. Dies macht deutlich, dass schließlich „nur“ neue Werkzeuge für die Unterstützung von Experten entstehen, nicht aber fertige Lösungen, die für sich alleine stehen können oder gar den Anspruch haben, Experten zu ersetzen.

6.5 Fazit

Die Methode der objektorientierten Bildanalyse von sehr hoch auflösenden Fernerkundungsdaten ermöglicht die schnelle Extraktion von flächendeckenden und qualitativ hochwertigen Informationen in kurzen Intervallen:

Erreichte Ziele

- Potentielle Feuchtgebiete lassen sich anhand von räumlich sehr hoch auflösenden Fernerkundungsdaten mit Hilfe einer objektorientierten Methode differenzieren.
- Ein Monitoring der häufig schlecht zugänglichen Feuchtgebiete wird vereinfacht.
- Die Arbeit auf einer lokalen Maßstabsebene sowie das Monitoring von Schilfbeständen oder Verbuschungstendenzen in Hochmooren sind möglich.
- Die multisaisonale Auswertung vereinfacht Regelwerke und Objektdefinitionen. Zusätzliche Informationen über Gewässervegetation können herausgearbeitet werden.

Daten

- Satellitensensoren der IKONOS-Generation liefern Daten, deren Informationsgehalt für ein Monitoring genutzt werden kann, das den Anforderungen der neuen Richtlinien entspricht.
- Durch Nutzung von Luftbildern kann die Entwicklung einer Landschaft zu einem gewissen Grad dokumentiert werden.
- Hyperspektrale Daten liefern in dieser Untersuchung keine zusätzlichen Informationen, vor allem weil dem verwendeten CASI-Sensor aufgrund des eingesetzten Siliziumdetektors Spektralbereiche für die genaue Wasseranalyse fehlen. Für die detaillierte Analyse der Gewässervegetation sind hyperspektrale Daten neuerer Generation aber vermutlich geeignet (vgl. Pinnel, N., laufende Arbeit: Einsatz angewandter Gewässerfernerkundung: Pilotprojekt Waging-Tachinger See).

Methode

- Die erste Entwicklung von Regelwerken ist zeitaufwendig und oft subjektiv geprägt.

- Nach einmaliger Aufstellung der Regeln für jeden Datensatz und für bestimmte Aufnahmezeitpunkte ist eine Übertragung mit leichten Anpassungen möglich.
- Vergleichbare Klassifikationsergebnisse ermöglichen ein sensorübergreifendes Konzept, beispielsweise für eine Zeitreihenanalyse oder die Nutzung höherer Auflösungen von Luftbildern bzw. modernen digitalen Kameras für die weitergehende Analyse oder Kostensenkung.
- Eine Analyse von Fernerkundungsdaten mit dem Ziel, eine Unterscheidung von Arten zu erreichen, ist noch nicht möglich. Die aktuell verfügbaren räumlichen Auflösungen sind noch immer zu gering, und die Überschneidungen der zu analysierenden Objekte im Merkmalsraum sind für eine eindeutige Trennung zu hoch.
- Durch die Entwicklung von transparenten Regelwerken ist jeder Schritt der anschließenden Klassifikation nachvollziehbar und Fehleranalysen sind leichter möglich.

Letztendlich konnte die Frage nach dem **Zeitaufwand** und der immer vorhandenen **Subjektivität** bei der Erstellung der Regelwerke nicht vollständig geklärt werden. Auch das unkalkulierbare Verhalten von Objekten bei einer Neusegmentierung in eCognition unter Einbindung weiterer, externer Daten ist problematisch. Der Aufwand zur Anpassung der Regelwerke könnte hier minimiert werden, wenn die Objekteigenschaften sich weniger stark ändern würden. Insbesondere wenn Rand- und Übergangsbereiche vollständig erfasst werden sollen, ist der Anpassungsaufwand erheblich.

Die Ergebnisse zeigen aber, dass die gewählte Methode in Kombination mit sehr hoch auflösenden Daten hilfreiche Informationen für die Unterstützung in der behördlichen Praxis liefern kann. Die erreichten hohen **Klassifikationsgenauigkeiten** werden auch im Vergleich mit anderen Arbeiten bestätigt, die ebenfalls eine Auswertung mit wissenbasierten Systemen mit Hilfe von Regelwerken durchführen (vgl. Buck 2001, de Kok 2001, Houhoulis und Michener 2000, Lunetta und Balogh 1999, Sader et al. 1995).

Eine übergreifende **Datenfusion** im eigentlichen Sinne (Wald 1999) wird nur bei der kombinierten Auswertung von Fernerkundungs- und GIS-Daten, also der Einbindung externer Information, durchgeführt. Eine direkte Fusion der gesamten vorhandenen Datenbasis in einem eCognition-Projekt wird vermieden. Eine entsprechende Vorgehensweise würde dem Ziel entgegenstehen, möglichst einfache und mit geringem Anpassungsaufwand übertragbare Regelwerke zu erstellen.

Zudem decken die verwendeten Daten unterschiedliche Maßstabsebenen ab, so dass eine **zielgerichtete Auswertung** die erfolgreichere Strategie ist. Der technische Aufwand, alle Daten gemeinsam auszuwerten, wäre ohnehin zu hoch, da Grenzen der Speicherverwaltung sehr schnell überschritten wären und der zeitliche Aufwand allein für die Klassifikation erheblich wäre. Der Benutzer wäre gezwungen, seine Bilddaten zu zerschneiden, einzelne Subsets zu bearbeiten und diese dann später zusammenzufügen. Diese Subsets müssen sich aber großzügig überschneiden, da sonst unterschiedlich segmentierte Objekte in den

Randbereichen Probleme beim späteren Zusammenfügen bereiten. Trotz der bislang überlegenen Segmentierungsmethodik von eCognition (Neubert und Meinel 2003) werden diese Fehler in Randbereichen weiterhin existieren und das Fusionieren von unabhängig bearbeiteten Teilszenen erschweren. Neue Entwicklungen der Firma Definiens wie z. B. das neue eCognition Enterprise versprechen hier Abhilfe. Mit Hilfe dieses Programms können in einer *Client-Server-Umgebung* Klassifizierungsprozesse im „Hintergrund“ ablaufen und evtl. wird es möglich sein, die bisherigen Speicherverwaltungsgrenzen von eCognition auszuweiten.

Eine so genannte *limited goal strategy* (nach Guindon 1997) auch auf inhaltlicher Basis, also die Konzentration nur auf die relevanten Klassen, reduziert noch einmal den Klassifikationsaufwand und ermöglicht eine schnellere Analyse. Auch de Kok (2001) schlägt vor allem aus Kostengründen eine ähnliche Vorgehensweise vor. Er plädiert dafür, Bereiche, die bereits erstinventarisiert sind, mit günstigen, mittelauflösenden Daten (Landsat ETM, Spot 5, IRS 1D) zu überwachen und nur Bereiche, in denen Veränderungen zu erwarten sind bzw. erkannt wurden, mit Daten der IKONOS-Generation, Luftbildern, etc. im Detail zu analysieren.

Eine solche Vorgehensweise würde auch Argumente für den operationellen Einsatz der **Fernerkundung in der behördlichen Praxis** liefern. Bislang hat hier nur die visuelle Auswertung von Orthofotos operationellen Eingang gefunden. Diese Auswertung ist aber im Vergleich mit der wissensbasierten Auswertung auf der Basis einmal angepasster Regelwerke langwierig und teuer. Die Entwicklung von Regelwerken kann nur von Fernerkundungsexperten geleistet werden. Der Aufwand einer Einarbeitung von Anwendern wäre vermutlich zu hoch. Die reine Nutzung und ggf. Anpassung der einmal erstellten Regelwerke aber ist mit deutlich geringerem Aufwand möglich. Eine Integration transparenter Regelwerke in bestehende Abläufe umgeht die Notwendigkeit des Wissens um die komplexe Entwicklung und die detaillierten Zusammenhänge zwischen einzelnen Objekten und deren Eigenschaften im Regelwerk. Die Firma Definiens verfolgt mit einem Konzept auf Basis von Operationen einen ähnlichen Weg. Dieses geht über die reine Regeldefinition hinaus und integriert Regelwerke in komplexe Operationen, die auch mehrere Segmentierungen, Klassifikationsschritte oder auch Löschvorgänge beinhalten können. Dieses geschieht unsichtbar für den Benutzer und wird unter einer Applikationsoberfläche verborgen. Ein aktuelles Beispiel ist das Produkt „*eCognition Forrester*“, das gezielt für die Klassifikation von Waldbeständen eingesetzt werden soll.

Erst seit vergleichsweise kurzer Zeit ist die Fernerkundung in der Lage, neben den Orthofotos auch Satellitendaten zu liefern, die Informationen in dem für Behörden wichtigen Maßstabsbereich ab 1:10.000 und größer bereitstellen. Eine Methode, die sensorübergreifend unterschiedliche Fernerkundungsdaten dort einsetzt, wo sie maximalen Nutzen versprechen, könnte den Kostendruck senken. Tschach (2002) stellt ebenfalls Überlegungen zur Kostenreduktion an. Einsparungen wären möglich, wenn nur noch die in der Bildanalyse als verändert erkannten Bereiche mit teuren Feldkampagnen überprüft werden müssen.

Insbesondere die neuen, europaweiten Richtlinien wie die Wasserrahmenrichtlinie (Das europäische Parlament und der Rat der Europäischen Union 2000), die FFH-Richtlinie (vgl. Bayerisches Staatsministerium für Landesentwicklung und Umweltfragen (StMLU) 2001)

oder auch ältere Schutzkonzepte wie Ramsar fordern von den Behörden in den nächsten Jahren u. a. die Aufstellung von Überwachungskonzepten. Die Fernerkundung kann nun mit den neuen Daten und darauf zugeschnittenen Auswertemethoden auch in diesem Maßstabbereich unterstützen.

Die mehrfach aufgezählten Vorteile der objektorientierten Methode wie sie beispielsweise mit dem Programm eCognition durchgeführt wird, können direkt Argumente für einen behördlichen Einsatz liefern. Es werden zum ersten Mal Werkzeuge bereitgestellt, die vorhandene, in langen Jahren aufgebaute Datengrundlagen nutzen, die so in bestehende Abläufe eingebunden werden können. Die Anwendung der **Fernerkundung in Behörden** liefert:

- Werkzeuge zur Unterstützung von Experten
- Konservierung, zumindest eines Teils des Wissens unterschiedlicher Experten in den entwickelten Regelwerken
- Nutzung vorhandener Datengrundlagen
- Verknüpfung unterschiedlicher Datenebenen (Datenfusion)
- eine direkte Anbindung an GIS mit der gesamten Information aus der Objektdatenbank und liefert weiteren Input für Expertensysteme (vgl. Buck 2001, S.134 f).

Bei der Fernerkundung wie auch beim Anwender muss Klarheit über die Möglichkeiten der Fernerkundung bestehen. Diese dürfen nicht überinterpretiert oder missverstanden werden. Die in dieser Arbeit vorgestellte Methodik soll und kann einen Experten nicht ersetzen. Sie hat vielmehr die Unterstützung, Vereinfachung und Beschleunigung von Arbeitsabläufen zum Ziel.

7 Zusammenfassung

Die Zielsetzung dieser Arbeit war die **Entwicklung von automatisierbaren Auswertestrategien** auf Basis eines objektorientierten Bildanalyseansatzes für die Unterstützung von Monitoringkonzepten, wie sie von aktuellen Richtlinien (EU-WRRL, Natura 2000) vorgeschrieben werden.

In erster Linie wurden räumlich sehr hoch auflösende IKONOS-Satellitendaten auf ihre Anwendbarkeit in solchen automatisierbaren Verfahren überprüft. Ferner wurden hyperspektrale Daten des CASI-Sensors daraufhin getestet, ob sie aufgrund ihrer hohen spektralen Auflösung darüber hinaus fachlich detailliertere Informationen liefern können. Ergänzend wurde eine Zeitreihe von Orthofotos automatisiert mit dem Ziel ausgewertet, einen Rückblick auf vergangene Jahrzehnte der Entwicklung einer Landschaft zu ermöglichen.

Der inhaltliche Fokus dieser Arbeit lag in der **Klassifikation gewässernaher Feuchtgebiete**, der Erfassung von Schilfgürteln, der Analyse von Moorbereichen sowie in der Klassifikation der Wasserfläche und submerser Makrophyten.

Mit der Zunahme der räumlichen Auflösung bei Fernerkundungsdaten steigt die lokale Varianz der Grauwerte innerhalb von Objekten an. Klassifikationsergebnisse herkömmlicher Auswerteverfahren hinterlassen deshalb oft einen sehr unruhigen visuellen Eindruck. Das Auswertungsergebnis kann erheblich verbessert werden, wenn zusätzliche Informationen, z. B. Nachbarschaft, Lage, Höhe mit einbezogen werden. Hierfür ist eine objektorientierte Methodik notwendig. Aus diesem Grund wurde die Bildanalysesoftware eCognition eingesetzt. In einem ersten Schritt werden dabei homogene Objekte erzeugt, die anschließend klassifiziert werden.

Im Unterschied zur traditionellen Vorgehensweise werden Objektklassen mit Hilfe von Regeln definiert, welche unterschiedliche Objekteigenschaften kombinieren. Die Entwicklung dieser **Objektdefinitionen** erfolgte auf der Basis von **Expertenwissen**. Die Formalisierung und Abbildung dieses Wissens in einem Regelwerk führt hinsichtlich Nachvollziehbarkeit und Fehlersuche zu einer transparenten Klassifikation.

Im Rahmen dieser Arbeit wurden die Regeln so formuliert, dass sie mit geringem Anpassungsaufwand übertragbar sind. Der Nachweis wurde erbracht, dass objektorientierte und wissensbasierte Bildanalysemethoden geeignet sind, um räumlich hoch auflösende Fernerkundungsdaten auszuwerten.

Die für die unterschiedlichen Datengrundlagen aufgestellten Regelwerke erzeugen vergleichbare Klassifikationsergebnisse, so dass ein sensorübergreifendes Konzept für eine Landschaftsanalyse zur Verfügung steht.

Die Regelwerke für **IKONOS-Satellitendaten** wurden so entwickelt, dass zunächst grobe Klassen für eine Vorabgrenzung unterschieden werden. Bereits auf dieser Ebene konnte Wasser erwartungsgemäß mit einer Genauigkeit von über 95 %, Feuchtgebiete mit über 80 % sowie Moorbereiche mit einer Genauigkeit von bis zu 90 % unterschieden werden.

Fehlzuzuweisungen treten überwiegend in Übergangsbereichen auf, die auch von Experten im Gelände oft unterschiedlich angesprochen werden. Da Feuchtgebiete im Fokus dieser Arbeit lagen, wurden die Regelwerke so ausgelegt, dass deren Objekteigenschaften ggf. höher gewichtet wurden. In diesem Fall weisen die Regelwerke u. U. zu viele Objekte fälschlicherweise einer Klasse zu (sog. Einschlussfehler), was sich in einer geringeren Benutzer-genauigkeit niederschlägt.

Auf der nächst größeren Maßstabsebene wurden dichte und weniger dichte Schilfbereiche sowie ufernahe, seggendominierte Niedermoorbereiche unterschieden. Aufgrund des höheren Detailgrades sinken die erreichbaren Genauigkeiten erwartungsgemäß ab. Dennoch wurden Werte von über 90 % erreicht.

Bei der Analyse von Verbuschungstendenzen wurden offene Hochmoorflächen mit einer Genauigkeit von über 90 % klassifiziert. In den verbuschten Bereichen sind die erreichbaren Genauigkeiten aufgrund der schwierigen Abgrenzung zu bewaldeten Flächen erwartungsgemäß niedriger, sinken aber nicht unter 70 %.

Eine kombinierte Auswertung multisaisonalen Aufnahmen, vom Beginn und vom Ende der Vegetationsperiode, vereinfacht die Definition einzelner Objekte und die Struktur von Klassenhierarchien erheblich. Die multisaisonale Auswertung ist bei Vegetation, die einen spektral erkennbaren Jahresgang aufweist überlegen. Die Genauigkeitsanalyse weist hier eine sehr gute Klassifikationsqualität bei Schwimmblattgesellschaften von zum Teil über 80% nach. Alternativ und unterstützend zur multisaisonalen Analyse erscheint die Modellierung von Objekten über Wachstumsmodelle sinnvoll.

Von der **Nutzung hyperspektraler CASI-Daten** wurde ein Informationsgewinn, beispielsweise über den Zustand von Schilfbeständen, erwartet. In dieser Arbeit konnte dafür allerdings kein Nachweis erbracht werden.

Vielmehr wurden mit diesen Daten eine vergleichbare Klassifikationsqualität und derselbe Klassenumfang erreicht wie für die IKONOS-Daten. Die Genauigkeit der Ergebnisse lag aber mit ca. 80 % bei den offenen Moorflächen sowie 30 % bis 70 % bei den verbuschten Bereichen zum Teil deutlich unterhalb der Qualität der IKONOS-Klassifikation. Weitere Unterschiede z. B. in der Klassenzusammenstellung ergaben sich aufgrund der verschiedenen Aufnahmezeitpunkte.

Die **automatisierte Auswertung von Orthofotos** ermöglicht einen Zugriff auf die kostengünstigen Informationen in Luftbildarchiven. Das dort existierende Luftbildmaterial reicht zurück bis in die 1940er Jahre. Eine Analyse der Landschaftsentwicklung ist so durch die Auswertung von Zeitreihen innerhalb abgegrenzter Regionen möglich.

Aufgrund der geringen spektralen Information der hier verwendeten Schwarz-Weiss-Orthofotos kann ein Klassenumfang wie bei IKONOS oder CASI prinzipiell nicht erreicht werden.

Die Qualität der erreichten Ergebnisse ist dennoch sehr hoch, aber abhängig von den Objekten und der unterschiedlichen Qualität der Aufnahmen nicht einheitlich. Dennoch wurden auch hier Feuchtgebiete mit Genauigkeiten zwischen 70 % und 90 % klassifiziert.

Mit Hilfe der entwickelten Regelwerke können Informationen in Maßstabsbereichen, die für **naturschutzfachliche Fragestellungen auf lokaler Ebene** notwendig sind, zur Verfügung gestellt werden. So können behördliche Monitoringaufgaben vor allem in schlecht zugänglichen Gebieten unterstützt werden. Die extrahierten Informationen aus Fernerkundungsdaten sind verlässlich und können in Zukunft als **Eingangsparameter für Expertensysteme** oder Wachstumsmodelle dienen. Werkzeuge für die Unterstützung der behördlichen Arbeit im Bereich des Monitorings von naturschutzrelevanten Flächen können auf dieser Basis entwickelt werden.

Für einen effektiven Einsatz der hier entwickelten Methode in Kombination mit existierenden Daten besteht noch weiterer Forschungsbedarf. Ergebnisse lassen sich voraussichtlich verbessern, wenn Informationen behördenübergreifend zur Verfügung gestellt werden und wenn eine gemeinsame Wissensbasis für Auswertungen existiert. Das vorhandene Expertenwissen könnte so, zumindest in den formalisierbaren Bereichen konserviert werden und auch zukünftig für operationelle Verfahren zur Verfügung stehen.

8 Literaturverzeichnis

- Albertz, J.** (2001): Einführung in die Fernerkundung: Grundlagen der Interpretation von Luft- und Satellitenbildern. 2. Auflage, Wiss. Buchges., Darmstadt.
- Aplin, P., Atkinson, P. M., Curran, P. J.** (1999): Fine spatial resolution simulated satellite sensor imagery for land cover mapping in the United Kingdom. *Remote Sens Environ*, 68, 3, 206-216.
- Arbuckle, C. J., Huryn, A. D., Israel, S. A.** (1998): Applications of Remote Sensing and GIS to Wetland Inventory: upland bogs. 10th Colloquium of the Spatial Information Research Centre, University of Otago, New Zealand.
- Baatz, M., Benz, U., Dehghani, S., Heynen, M., Hötje, A., Hofmann, P., Lingenfelder, I., Mimler, M., Sohlbach, M., Weber, M., Willhauk, G.** (2002): eCognition user guide 3. Defeniens, München.
- 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, 80331 München.
- Baatz, M., Schäpe, A.** (2000): Multiresolution Segmentation - an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung. Beiträge zum AGIT-Symposium Salzburg 2000*, Salzburg, XII, 12-23.
- Baatz, M., Schäpe, A., Schmidt, G.** (2001): Verfahren zur Verarbeitung von Datenstrukturen. Deutschland, Patent Nr. DE 199 60 372 A 1, 21.06.2001, Definiens AG, 80331 München, DE.
- Bähr, H.-P., Vögtle, T.** (1998): Digitale Bildverarbeitung. Anwendung in Photogrammetrie, Kartographie und Fernerkundung. 3. Auflage, Wichmann, Heidelberg.
- Baker, J. R., Briggs, S. A., Gordon, V., Jones, A. R., Settle, J. J., Townshend, J. R. G., Wyatt, B. K.** (1991): Advances in Classification for Land Cover Mapping Using Spot Hrv Imagery. *Int J Remote Sens*, 12, 5, 1071-1085.
- Bakker, W. H., Gorte, B. G. H., Horn, J. A., Janssen, L. L. F., Pohl, C., Prakash, A., Reeves, C. V., Weir, M. J. C., Woldai, T.** (2001): Principles of Remote Sensing. An introductory textbook., The International Institute for Aerospace Survey and Earth Sciences (ITC), Enschede.
- Ball, G. H., Hall, D. J.** (1967): A clustering technique for summarizing multivariate data. *Behav Sci*, 12, 153-155.
- Bartelme, N.** (2000): Geoinformatik. Modelle, Strukturen, Funktionen. 3. Auflage, Springer, Berlin, Heidelberg, New York, Barcelona, Hongkong, London, Mailand, Paris, Singapur, Tokio.
- Bayerisches Landesamt für Wasserwirtschaft (BLfW)** (2001): Merkblatt Nr. 5.1/3. Gewässerentwicklungsplanung - Fließgewässer. Bayerisches Landesamt für Wasserwirtschaft.
- Bayerisches Staatsministerium für Landesentwicklung und Umweltfragen (StMLU)** (2001): Schutz des Europäischen Netzes „Natura 2000“.

- Bekanntmachung der der EU gemeldeten FFH-Gebiete und der Europäischen Vogelschutzgebiete Bayerns. Allgemeines Ministerialblatt, 14, 11, 541-616.
- Benson, B. J., Mackenzie, M. D.** (1995): Effects of Sensor Spatial-Resolution on Landscape Structure Parameters. *Landsc Ecol*, 10, 2, 113-120.
- Binaghi, E., Brivio, P. A., Ghezzi, P., Rampini, A.** (1999): A fuzzy set-based accuracy assessment of soft classification. *Pattern Recogn Lett*, 20, 9, 935-948.
- Blaschke, T.** (2000): Objektextraktion und regelbasierte Klassifikation von Fernerkundungsdaten: Neue Möglichkeiten für GIS-Anwender und Planer. 5. Symposium „Computergestützte Raumplanung“ – CORP2000, 153-162.
- Bock, S.** (1995): Ein Ansatz zur polygonbasierten Klassifikation von Luft- und Satellitenbildern mittels künstlicher neuronaler Netze. Dissertation, Geographisches Institut, Universität Kiel, Kiel.
- Bruniquel-Pinel, V., Gastellu-Etchegorry, J. P.** (1998): Sensitivity of texture of high resolution images of forest to biophysical and acquisition parameters. *Remote Sens Environ*, 65, 1, 61-85.
- Buck, A.** (2001): Aufbau, Optimierung und Anwendung eines forstlichen Geo-Informationssystems im Gebiet der Bayerischen Alpen - Implementierung eines wissensbasierten Systems zur Integration von Fernerkundung und GIS. Dissertation, Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt, TU München, Freising/Weihenstephan.
- Bundesamt für Naturschutz (BfN)** (1995): Systematik der Biotoptypen- und Nutzungstypenkartierung (Kartieranleitung). Landwirtschaftsverlag GmbH, Bonn-Bad Godesberg.
- Bundesamt für Naturschutz (BfN)** (2001): Deutschland braucht mehr Feuchtgebiete" Bundesamt ruft am Weltfeuchtgebietstag zum Schutz der Wat- und Wasservögel auf. http://www.bfn.de/07/pm_01_06.htm. Letzter Besuch: 18.10.2003.
- Campbell, N. A., Markl, J.** (1997): Biologie. Spektrum Akademischer Verlag GmbH, Heidelberg, Berlin, Oxford.
- Congalton, R. G.** (1991): A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sens Environ*, 37, 1, 35-46.
- Curran, P. J., Atkinson, P. M.** (2002): Issues of scale and optimal pixel size. In: Stein, A., van der Meer, F.D., Gorte, B. (2002): *Spatial Statistics for Remote Sensing*. Kluwer Academic Publishers, Dordrecht, Boston, London, 115-133.
- RICHTLINIE 2000/60/EG DES EUROPÄISCHEN PARLAMENTS UND DES RATES vom 23. Oktober 2000 zur Schaffung eines Ordnungsrahmens für Maßnahmen der Gemeinschaft im Bereich der Wasserpolitik. EU-Wasserrahmenrichtlinie (EU-WRRL). (2000), vom 22.12.2000, 72 S.
- de Kok, R.** (2001): Objektorientierte Bildanalyse. Ein Lösungsansatz für den automatisierten Einsatz sehr hoch auflösender Satellitendaten für forstliche Fragestellungen. Dissertation, Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt, TU München, München.

- de Kok, R., Buck, A., Schneider, T., U., A.** (2002): Modular project design in object oriented analysis. Fernerkundung und GIS. Neue Sensoren – Innovative Methoden., Salzburg, 33-41.
- de Lange, N.** (2002): Geoinformatik in Theorie und Praxis. Springer, Berlin, Heidelberg, New York, Barcelona, Hongkong, London, Mailand, Paris, Tokio.
- Deutscher Verband für Wasserwirtschaft und Kulturbau e.V. (DVWK)** (1999): Gewässerentwicklungsplanung: Begriffe, Ziele, Systematik. Wirtschafts- und Verl.-Ges. Gas und Wasser, Bonn.
- Deutsches Institut für Normung e.V. (DIN)** (1997): DIN 18716-3. Photogrammetrie und Fernerkundung - Teil 3: Begriffe der Fernerkundung. 1997-07, Köln.
- Di, K., Ma, R., Li, R.** (2002): Geometric Processing of IKONOS Geo Stereo Imagery. Photogramm Eng Rem S, 1-25.
- Dial, G., Grodecki, J.** (2001): Understanding the Geometry of IKONOS Images. Imaging Notes, 16, 5, 1-2.
- Dierßen, K., Dierßen, B.** (2001): Moore. Eugen Ulmer, Stuttgart (Hohenheim).
- 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/Weißenstephan.
- Ehlers, M.** (2002): Fernerkundung für GIS-Anwender - Sensoren und Methoden zwischen Anspruch und Wirklichkeit. In: Blaschke, T. (2002): Fernerkundung und GIS. Neue Sensoren - innovative Methoden. Wichmann Verlag, Heidelberg, 10-23.
- 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, 669-675.
- ERDAS** (1997): ERDAS Field Guide. 4th Edition, ERDAS Inc., Atlanta.
- Fisher, P.** (1997): The pixel: A snare and a delusion. Int J Remote Sens, 18, 3, 679-685.
- Fleck, E., Oswald, H., Wegner, S., Wust, P.** (1997): Segmentierung mit der Wasserscheidentransformation. Spektrum der Wissenschaft, 6, 113-116.
- Foody, G. M.** (2002): Status of land cover classification accuracy assessment. Remote Sens Environ, 80, 1, 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, 173-180.
- Geiß, C.** (2001): Freizeit und Erholung im Naturschutzgebiet Osterseen. Diplomarbeit, Limnologische Station der TU München, WZW, Department für Ökologie, TU München, München.
- Geneletti, D., Gorte, B. G. H.** (2003): A method for object-oriented land cover classification combining Landsat TM data and aerial photographs. Int J Remote Sens, 24, 6, 1273-1286.
- Gerlach, F.** (2002): Ground sampled distance and image interpretability. Imaging Notes, 17, 3, 1-2.

- Goldberg, J.** (1998): Remote Sensing of Wetlands: Procedures and Considerations. <http://www.vims.edu/rmap/cers/tutorial/rsecol.htm>. Letzter Besuch: 28 August 2003.
- Goldberg, J., Perry, J., Anderson, J.** (1999): Remote Sensing of Natural Areas: Procedures and Considerations for Assessing Stress and Pollution. School of Marine Science, Gloucester Point, Virginia.
- Gong, P., Howarth, P. J.** (1992): Frequency-Based Contextual Classification and Gray-Level Vector Reduction for Land-Use Identification. *Photogramm Eng Remote Sens*, 58, 4, 423-437.
- Gorte, B.** (1998): Segmentation pyramid classification. *International Archives of Photogrammetry and Remote Sensing*, 32, B3/1, 225-232.
- Goslich, C.** (1975): Freiflächenplanung für Feldafing und Tutzing am Starnberger See. Diplomarbeit, Institut für Landespflege, TU München, Freising/Weihenstephan.
- Grove, S.** (2000): Wissensbasierte Interpretation multitemporaler Luftbilder. Dissertation, Fachbereich Elektrotechnik und Informationstechnik, Universität Hannover, 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, 38-47.
- Guindon, B.** (2000): Combining Diverse Spectral, Spatial and Contextual Attributes in Segment-Based Image Classification. ASPRS 2000 Annual Conference, Washington D.C.
- 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, 55-64.
- Haralick, R. M., Joo, H.** (1986): A Context Classifier. *IEEE Trans Geosci Remote Sensing*, 24, 6, 997-1007.
- Haralick, R. M., Shapiro, L. G.** (1985): Image Segmentation Techniques. *Comput Vision Graph*, 29, 1, 100-132.
- Hay, G. J., Marceau, D. J., Dube, P., Bouchard, A.** (2001): A multiscale framework for landscape analysis: Object-specific analysis and upscaling. *Landsc Ecol*, 16, 6, 471-490.
- Henschel, T., Melzer, A., Müller, J., Alefs, J., Winkler, R.** (1992): Die limnologische Entwicklung des Starnberger Sees im Fortgang der Abwasserfernhaltung unter besonderer Berücksichtigung der Makrophytenvegetation. Bayerisches Landesamt für Wasserwirtschaft (BayLfW), München.
- Hesse, H.** (1930): Narziß und Goldmund. Suhrkamp, Berlin.
- Hesse, W., v. Braun, H.** (2001): Wo kommen die Objekte her? Ontologisch-erkenntnistheoretische Zugänge zum Objektbegriff. Informatik 2001 - Tagungsband der GI/OCG-Jahrestagung, 25. - 28. September 2001, Bd. II, Wien, 157, 776-781.
- Hildebrandt, G.** (1996): Fernerkundung und Luftbildmessung: Für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie. Wichmann, Heidelberg.

- Houhoulis, P. F., Michener, W. K.** (2000): Detecting wetland change: A rule-based approach using NWI and SPOT-XS data. *Photogramm Eng Remote Sens*, 66, 2, 205-211.
- Hutchinson, C. F.** (1982): Techniques for Combining Landsat and Ancillary Data for Digital Classification Improvement. *Photogramm Eng Remote Sens*, 48, 1, 123-130.
- Jacobsen, K.** (2002): Auswertung von IKONOS-Aufnahmen. Jahrestagung DGPF, 49-57.
- Jago, R. A., Cutler, M. E. J., Curran, P. J.** (1999): Estimating canopy chlorophyll concentration from field and airborne spectra. *Remote Sens Environ*, 68, 3, 217-224.
- Jähne, B.** (2002): *Digitale Bildverarbeitung*. 5. Auflage, Springer, Berlin, Heidelberg, New York, Barcelona, Hong Kong, London, Milan, Paris, Tokyo.
- 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, 519-525.
- Johnsson, K.** (1994): Segment-Based Land-Use Classification from Spot Satellite Data. *Photogramm Eng Remote Sens*, 60, 1, 47-53.
- Kangler, G.** (2003): *Historisch-geographische Landschaftsanalyse mit GIS als Grundlage für Naturschutzplanung - dargestellt am Gebiet um die Osterseen - Diplomarbeit, Limnologische Station, TU München, Freising/Weihenstephan.*
- Kartikayan, 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, 1037-1051.
- Kartikayan, B., Majumder, K. L., Dasgupta, A. R.** (1995): An Expert-System for Land-Cover Classification. *Ieee T Geosci Remote*, 33, 1, 58-66.
- Kellenberger, T.** (2002): Orthorektifizierung von IKONOS Daten in der Schweiz - Erfahrungen und Genauigkeitsanalysen. CGI Systems Benutzertreffen 2002, Iffeldorf.
- Kersten, T., Baltsavias, E., Schwarz, M., Leiss, I.** (2000): IKONOS-2 CARTERRA GEO - Erste geometrische Genauigkeitsuntersuchungen in der Schweiz mit hochaufgelösten Satellitendaten. *VPK*, 8, 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, 19-26.
- Kindscher, K., Fraser, A., Jakubauskas, M. E., Debinski, D. M.** (1998): Identifying wetland meadows in Grand Teton National Park using remote sensing and average wetland values. *Wetlands Ecology and Management*, 5, 265-273.
- Klemas, V. V.** (2001): Remote sensing of landscape-level coastal environmental indicators. *Environ Manage*, 27, 1, 47-57.
- Korn, N.** (2001): Die Wasserrahmenrichtlinie der EU. *Naturschutz und Landschaftsplanung*, 33, 8, 246-248.

- Leschine, T. M., Wellmann, K. F., Green, T. H.** (1997): The Economic Value of Wetlands. Wetlands's Role in Flood Protection in Western Washington. Washington State Department of Ecology, Washington.
- Lichtenthaler, H. K., A., G., Lang, M.** (1996): Non-destructive determination of chlorophyll content of leaves of a green and an aurea mutant of tobacco by reflectance measurements. *J Plant Physiol*, 148, 483-493.
- Lillesand, T. M., Kiefer, R. W.** (2000): Remote sensing and image interpretation. 4th Edition, John Wiley & Sons, New York - Chichester - Weinheim - Brisbane - Singapore - Toronto.
- Lohmann, G.** (1991): An Evidential Reasoning Approach to the Classification of Satellite Images. Deutsches Zentrum für Luft- und Raumfahrt (DLR), Oberpfaffenhofen.
- Löschenbrand, F.** (2003): Erfassung naturschutzrelevanter Feuchtflächen im NSG Osterseen durch objektorientierte Bildanalyse von Hyperspektraldaten. Diplomarbeit, Limnologische Station, TU München, Iffeldorf.
- Lunetta, R. S., Balogh, M. E.** (1999): Application of multi-temporal Landsat 5 TM imagery for wetland identification. *Photogramm Eng Remote Sens*, 65, 11, 1303-1310.
- Marceau, D. J., Hay, G. J.** (1999): Remote sensing contributions to the scale issue. *Can J Remote Sens*, 25, 4, 357-366.
- Marshall, T. R., Lee, P. F.** (1994): Mapping Aquatic Macrophytes through Digital Image-Analysis of Aerial Photographs - an Assessment. *J Aquat Plant Manage*, 32, 61-66.
- Mather, P. M.** (1999): Computer processing of remotely sensed images : an introduction. 2nd Edition, Wiley, Chichester.
- Matsuyama, T.** (1987): Knowledge-Based Aerial Image Understanding Systems and Expert Systems for Image-Processing. *IEEE Trans Geosci Remote Sensing*, 25, 3, 305-316.
- Meinel, G., Reder, J.** (2001): IKONOS-Satellitendaten - ein erster Erfahrungsbericht. *Kartographische Nachrichten*, 1, 40-46.
- Melzer, A., Hermann, M.** (1980): Die quantitative Verbreitung der Makrophytenvegetation des Starnberger Sees. *Berichte der Bayerischen Botanischen Gesellschaft?*, 51, 31-56.
- Meyer, R. K. F., Schmidt-Kaler, H.** (2002): Wanderungen in die Erdgeschichte / 9Auf den Spuren der Eiszeit südlich von Münchenwestlicher Teil. Pfeil Verlag, München.
- Mott, C.** (unveröff.): Objektorientierte..... Dissertation, Lehrstuhl für Landnutzungsplanung und Naturschutz, TU München, Freising.
- Mott, C., Andresen, T., Zimmermann, S., Schneider, T., Ammer, U.** (2002): „Selektives“ region growing – ein objektorientierter Klassifikationsansatz. *Angewandte Geographische Informationsverarbeitung (AGIT)*, Heidelberg, XIV, 363-368.
- Murtha, P. A.** (1982): Detection and analysis of vegetation stress. In: Johannsen, C.J., Sanders, J.L. (1982): *Remote Sensing for Resource Management*. Soil Conservation Society of America, Ankeny, Iowa, 141-158.

- Neubert, M., Meinel, G.** (2003): Vergleich von Segmentierungsprogrammen für Fernerkundungsdaten. *Angewandte Geographische Informationsverarbeitung (AGIT)*, Salzburg, XV, 323-329.
- Niemann, K. O., Goodenough, D. G., Hay, G. J.** (1997): Effect of Scale on the Information Content in Remote Sensing Imagery. *IGARSS*, Singapore, 664-666.
- Ozesmi, S. L., Bauer, M. E.** (2002): Satellite remote sensing of wetlands. *Wetlands Ecology and Management*, 10, 381-402.
- Pope, K. O., Reybenayas, J. M., Paris, J. F.** (1994): Radar Remote-Sensing of Forest and Wetland Ecosystems in the Central-American Tropics. *Remote Sens Environ*, 48, 2, 205-219.
- Press, F., Siever, R.** (1995): *Allgemeine Geologie - Eine Einführung*. Spektrum Akademischer Verlag GmbH, Heidelberg, Berlin, Oxford.
- 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, 192-207.
- Reichholf, J.** (1988): *Feuchtgebiete. Die Ökologie europäischer Binnengewässer, Auen und Moore*. Mosaik Verlag, München.
- Richards, J. A., Jia, X.** (1999): *Remote sensing digital image analysis : an introduction*. 3rd Edition, Springer, Berlin, Heidelberg, New York, Barcelona, Hong Kong, London.
- Richter, R.** (1997): Correction of atmospheric and topographic effects for high spatial resolution satellite imagery. *Int J Remote Sens*, 18, 5, 1099-1111.
- Rogg, C.** (2003): *Monitoring von naturschutzrelevanten Flächen mit Hilfe objektorientierter Bildanalyse anhand s/w-Luftbilder im NSG Osterseen*. Diplomarbeit, Limnologische Station, TU München, Iffeldorf.
- Rothpletz, A.** (1917): *Die Osterseen und der Isar-Vorlandgletscher*. J. Lindauer'sche Universitätsbuchhandlung, München.
- Ryherd, S., Woodcock, C.** (1996): Combining spectral and texture data in the segmentation of remotely sensed images. *Photogramm Eng Remote Sens*, 62, 2, 181-194.
- Sader, S. A., Ahl, D., Liou, W. S.** (1995): Accuracy of Landsat-TM and Gis Rule-Based Methods for Forest Wetland Classification in Maine. *Remote Sens Environ*, 53, 3, 133-144.
- Saura, S.** (2002): Effects of minimum mapping unit on land cover data spatial configuration and composition. *Int J Remote Sens*, 23, 22, 4853-4880.
- Saurer, H., Behr, F.-J.** (1997): *Geographische Informationssysteme. Eine Einführung*. Wiss. Buchges., Darmstadt.
- Scholles, F.** (1999): *Informationssysteme und -verarbeitung 2. Informationssysteme in der Raum und Umweltplanung*. http://www.laum.uni-hannover.de/ilr/lehre/lsv/lsv_XPS.htm. Letzter Besuch: 09.10.2003.
- Schönthaler, K.** (2002): *Ökosystemare Umweltbeobachtung. Vom Konzept zur Umsetzung*. München.

- Schowengerdt, R. A.** (1997): Remote sensing: Models and methods for image processing. 2nd Edition, Acad. Press, San Diego.
- Shaikh, M., Green, D., Cross, H.** (2001): A remote sensing approach to determine environmental flows for wetlands of the Lower Darling River, New South Wales, Australia. *Int J Remote Sens*, 22, 9, 1737-1751.
- 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, 1461-1486.
- Stehman, S. V.** (1997): Selecting and interpreting measures of thematic classification accuracy. *Remote Sens Environ*, 62, 1, 77-89.
- Stuckens, J., Coppin, P. R., Bauer, M. E.** (2000): Integrating contextual information with per-pixel classification for improved land cover classification. *Remote Sens Environ*, 71, 3, 282-296.
- Thiemann, S., Kaufmann, H.** (2000): Determination of chlorophyll content and trophic state of lakes using field spectrometer and IRS-1C satellite data in the Mecklenburg lake district, Germany. *Remote Sens Environ*, 73, 2, 227-235.
- Thiemann, S., Kaufmann, H.** (2002): Lake water quality monitoring using hyperspectral airborne data—a semiempirical multisensor and multitemporal approach for the Mecklenburg Lake District, Germany. *Remote Sens Environ*, 81, 2-3, 228-237.
- Thommes, W., Enders, G., Sachweh, M., Würländer, R., Noack, E.-M.** (1996): *Klimaatlas von Bayern*. Bayerischer Klimaforschungsverbund, München.
- Tilton, J. C., Vardeman, S. B., Swain, P. H.** (1982): Estimation of Context for Statistical Classification of Multispectral Image Data. *IEEE Trans Geosci Remote Sensing*, 20, 4, 445-452.
- Ton, J. C., Sticklen, J., Jain, A. K.** (1991): Knowledge-Based Segmentation of Landsat Images. *IEEE Trans Geosci Remote Sensing*, 29, 2, 222-232.
- Toutin, T., Cheng, P.** (2000): Demystification of IKONOS. *Earth Observation Magazine*, 9, 7, 17-21.
- Troll, C.** (1938): Der Eiszerfall beim Rückzug der alpinen Vorlandgletscher in die Stammbecken. *Verh.III.Intern.Quartärkonferenz*, 152-160.
- Tschach, E.** (2002): Fernerkundungsgestütztes Monitoring naturschutzrelevanter Flächen. 19. DFD-Nutzerseminar, Oberpfaffenhofen, 191-198.
- United States Environmental Protection Agency (EPA)** (2002): *Functions and Values of Wetlands*. Office of Water & Office of Wetlands, Oceans and Watersheds, Washington D.C..
- van der Sande, C. J.** (2001): River flood damage assessment using IKONOS imagery. Doctoral thesis, European Commission, Joint Research Centre, Natural Hazards Unit, Wageningen University, Ispra (Va), Italy.
- Wald, L.** (1999): Some terms of reference in data fusion. *IEEE T Geosci Remote*, 37, 3, 1190-1193.
- Williams, D. C., Lyon, J. G.** (1997): Historical aerial photographs and a geographic information system (GIS) to determine effects of long-term water level















fluctuations on wetlands along the St. Marys River, Michigan, USA. *Aquat Bot*, 58, 3-4, 363-378.



















Woodcock, C. E., Gopal, S. (2000): Fuzzy set theory and thematic maps: accuracy assessment and area estimation. *Int J Geogr Inf Sci*, 14, 2, 153-172.
















Woodcock, C. E., Strahler, A. H. (1987): The Factor of Scale in Remote-Sensing. *Remote Sens Environ*, 21, 3, 311-332.


















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, 28-44.

















Zhu, X., Healey, R. G., Aspinall, R. J. (1998): A Knowledge-Based Systems Approach to Design of Spatial Decision Support Systems for Environmental Management. *Environmental Management*, 22, 1, 35-48.













Klassenhierarchie IKONOS April 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen	
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
4) coarse preclass		Level →	Wetland	<i>or (max)</i> <i>and (min)</i> Distance to open water n. objects IKONOS NDVI Mean ms04nn.img (1) <i>blau</i> Mean ms04nn.img (3) <i>rot</i> Mean ms04nn.img (4) <i>nir</i> Stdev ms04nn.img (1) <i>blau</i> Stdev ms04nn.img (3) <i>rot</i> <i>and</i> Distance to open water n. objects Mean pca04nn.img (1) <i>blau</i> Not Similarity to water <i>or</i> Rel. border to water n. Objects Rel. border to wetland n. Objects	140/150/160 0.1/0.3/0.5 300 /365/430 280/397.5/515 901/902/903 3/15.5/28 15/4575 80/70/90 350/635/920 0/0.5/1 0.28/0.29/0.3	        (gen.)  	zweiteilige Klassifikation, d. h. entweder entspricht Objekt exakt den spektralen Vorgaben des ersten Astes oder es liegt angrenzend zu open water oder wetland , muss dann aber ebenfalls einem weiter gefassten spektralen Merkmal entsprechen
		Level → → Channels → open water	Water	<i>and (min)</i> Blau / nir GLCM Homogeneity, all dir, NIR IKONOS NDVI Mean ms04nn.img (4) <i>nir</i>	1/1.15/1.3 0.059/0.3345/0.61 0.2/0.225/0.25 345/350/355	   	Hier spielen die geringe Rauigkeit der ruhigen Wasseroberfläche, ein niedriger Wert im NDVI (nicht Vegetation) und geringe Reflexion im NIR sowie die negative Ratio in NIR-blau eine Rolle um eindeutige Wasserflächen zu erkennen.

















Klassenhierarchie IKONOS April 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
	Water	Level → Water →	Open Water	<i>and (min)</i> Length/width Not Membersh. To channels (14)	12/13/14 0/0.5/1	 	
	Channels	Level →	Submersed Veg.	<i>and (min)</i> Distance to water n. Objects GLCM Homogeneity, all dir, NIR IKONOS NDVI Mean ms04nn.img (4) <i>nir</i> NIR – blau Stdev ms04nn.img (4) <i>nir</i>	60/62.5/65 0.035/0.0725/0.11 0.25/0.315/0.38 325/327.5/330 -10/-5/0 164/164.5/165	     	
		Level →	Chan.2 Sub. Veg.	<i>and (min)</i> Blau / nir Distance to channels n. objects GLCM Homogeneity, all dir, NIR IKONOS NDVI Length/width Mean ms04nn.img (4) <i>nir</i> Not classified as channels	0.3/0.65/1 100/110/120 0.015/0.0625/0.11 0.15/0.295/0.44 1.5/2/2.5 355/357.5/360 0/0.4/0.8	      	
		Level → Water →	Channels	<i>and (min)</i> Length/Width Length/Width (only main line) Rel. Area of water n. Objects (5) Similarity to water	2.5/2.75/3 4.5/4,75/5 0.1/0.2/0.3	  	





Klassenhierarchie IKONOS April 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
		Level →	Moor area	<i>and (min)</i> Mean diff. to brighter neighb. blue Mean ms04nn.img (1) <i>blau</i> Mean ms04nn.img (3) <i>rot</i> Mean ms04nn.img (4) <i>nir</i> Mean pca04nn.img (2) <i>2.Hk</i> NIR – blau Not similarity to wetlands Stdev blue	100/150/200 240/280/320 160/254.5/403 300/552.5/805 -300/-240/-180 115/152.5/190 12/12.5/13	      	
		Level →	Pasture/Meadow	<i>and (min)</i> IKONOS NDVI Mean ms04nn.img (1) <i>blau</i> Mean ms04nn.img (3) <i>rot</i> Mean pca04nn.img (2) <i>2.Hk</i> Not similarity to wetlands Rel. area of harv. Field n. objects (10) Rel. border to wetlands n. objects Stdev ms04nn.img (3) <i>rot</i> Stdev pca04nn.img (1) <i>1.Hk</i>	0.4/0.575/0.75 270/202.5/335 200/250/300 -190/-187.5/-185 0/0.5/1 0.8/0.9/1 4.5/19.75/35 100/102.5/105	       	

Klassenhierarchie IKONOS April 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
		Level →	harvested field	<i>and (min)</i> IKONOS NDVI Length/width Mean ms04nn.img (1) <i>blau</i> Mean ms04nn.img (3) <i>rot</i> Mean pca04nn.img (2) <i>2.Hk</i> Not rel. border to wetland n. objects Rectangular fit Stdev ms04nn.img (1) <i>blau</i>	0/0.105/0.21 3/3.5/4 320/352.5/385 285/352.5/420 -440/-380/-320 0.8/0.9/1 0.3/0.4/0.5 4.5/10.25/16	       	
2) water detail		Level → → deep water → shallow water → br. shal. water → dark s. water	water_GR	<i>And (min)</i> Mean 4-2 <i>Or (max)</i> Existence of channels (l4) super-objects(2) Existence of water (l4) super-objects(2)	-10/-7.5/-5 0/0.5/1 0/0.5/1	  	
	Water_GR	Level→ water_GR →	deep water	<i>And (min)</i> Mean nir Mean red	140/145/150 100/105/110	 	
	Water_GR	Level→ water_GR → → br. shal. water → dark s. water	shallow water	<i>And (min)</i> Mean nir Mean red	250/255/260 100/105/110	 	
	Water_GR sh. water	Level → Water_GR → Shallow water →	brighter shallow water	<i>And (min)</i> Mean ms04nn.img (2) <i>grün</i>	210.5/210.75/211		
	Water_GR sh. water	Level → Water_GR → Shallow water →	dark shallow water	<i>And (min)</i> Mean ms04nn.img (2) <i>grün</i>	210/210.5/211		













Klassenhierarchie IKONOS April 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen	
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
		Level →	Water corr	<i>And (min)</i> Distance to water_GR n. objects Mean nir [<i>max value 0.8</i>] NIR-blau Not classified as water_GR <i>Or (max)</i> Mean April_rauigkeit_NOSnn250.tif Mean April_rauigkeit_NOSnn250.tif <i>Or (max)</i> Existence of water (l4) super-objects(2) Existence of wetlands (l4) super-objects(2) Rel. border to water_GR n. objects	35/42.5/50 85/172.5/260 -300/-175/-50 0/0.5/1 4/5/6 0/1.55/3.1 0/0.5/1 0/0.5/1 0/0.15/0.3	        	
1) reed/wetland detailed		Level → → moor → reed_GR → lowland moor → low.Moor/lit.M → low moor fill in → forest. wetland	Wetland area	<i>Or (max)</i> <i>And (min)</i> Existence of water (l4) super objects (3) Not Existence of water_GR (l2) s objects (1) Existence of moor areas (l4) super objects (3) Existence of wetlands (l4) super objects (3)	0/0.5/1 0/0.5/1 0/0.5/1 0/0.5/1	   	
	Wetland a.	Level → Wetland area → → moor rough → moor smooth	moor	<i>And (min)</i> Existence of moor areas (l4) super objects (3)	0/0.5/1		
	Wetland a. moor	Level → Wetland area → Moor →	Moor rough	<i>Or (max)</i> Mean April_rauigkeit_NOSnn250.tif Mean April_rauigkeit_NOSnn250.tif	3.5/4/4.5 5.5/6/6.5	 	
















Klassenhierarchie IKONOS April 2001; multispektrale Auswertung						
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen
	Wetland a. Moor	Level → Wetland area → Moor →	Moor smooth	And (min) Not moor rough		
	Wetland a.	Level → Wetland area → → reed dense c. → reed/sedge m.	Reed_GR	Or (max) Distance to water n. objects Rel. border to reed_GR n. objects	0/10/20 0/0.5/1	 
	Reed_GR	Level → Wetland area → Reed_GR →	Reed dense c.			
	Reed dense	Level → Wetland area → Reed_GR →	Aquatic reed	And (min) Mean ms04nn.img (3) <i>rot</i> Mean ms04nn.img (4) <i>nir</i>	370/437.5/505 500/570/640	 
	Reed dense	Level → Wetland area → Reed_GR →	Aq. Reed fill in	And (min) Not Classified as 1 reed/wetland detailed Or (max) Rel. border to aquatic reed n. objects And (*) Rel. border to aquatic reed (l1) n. objects Rel. border to water (l1) n. objects	0/0.5/1 0/0.5/1 0/0.5/1 0/0.05/0.1	   
	Reed_GR	Level → Wetland area → Reed_GR →	Reed/sedge m.			
	Reed/sed ge m	Level → Wetland area → Reed_GR →	Trans/terr reed	And (min) Mean ms04nn.img (1) <i>blau</i> Mean ms04nn.img (3) <i>rot</i> Mean nir Stdev ms04nn.img (3) <i>rot</i>	280/365/450 200/320/440 295/455/615 2/23.5/45	   




















Klassenhierarchie IKONOS April 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
	Reed/sed ge m	Level → Wetland area → Reed_GR →	Trans reed fill in	<i>And (min)</i> Not classified as 1 reed/wetland detailed <i>Or (max)</i> Rel. border to trans./terr. Reed n. objects <i>And (*)</i> Rel. border to trans./terr. Reed n. objects Rel. border to water (l1) n. objects	0/0.5/1 0/0.5/1 0/0.5/1 0/0.05/0.1	   	
		Level → Wetland area →	Lowl. Moor/lit. meadow	<i>And (min)</i> Distance to water (l1) n. objects GLCM Homogeneity,all dir, nir Mean nir Not existence of moor areas (l4) s. objects Not moor (l1) Stdev ms04nn.img (4) <i>nir</i>	0/100/200 0.065/0.0725/0.08 250/435/620 0/0.5/1 50/52.5/55	    	
	Lowland. moor/lit.m.	Level → Wetland area →	Lowland moor 2	<i>And (min)</i> Mean ms04nn.img (3) <i>rot</i> Mean ms04nn.img (4) <i>nir</i> <i>Or (max)</i> Rel. border to lowl.Moor/lit.mead n.objects Rel. border to lowl.moor2 n. objects Stdev ms04nn.img (3) <i>rot</i>	125/137/150 305/407.5/510 0/0.25/0.5 0/0.25/0.5 3/4.5/6	    	
	Lowland moor/lit.m.	Level → Wetland area →	Lowl. Moor fill in	<i>And (min)</i> Not classified as 1 reed/wetland detailed Rel. border to lowl.moor/lit.mead n.objects	0/0.5/1 0.5/0.75/1	 	



















Klassenhierarchie IKONOS April 2001; multispektrale Auswertung						
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen
		Level → Wetland area →	Forested wetland / bushland	<i>And (min)</i> Distance to water n. objects GLCM Homogeneity, all dir, nir Mean nir Mean red	5/17.5/30 0.18/0.1875/0.195 390/420/450 275/277.5/280	   















Tab. 38: Detaillierte Klassenhierarchie IKONOS April 2001

















Klassenhierarchie IKONOS August 2001; multispektrale Auswertung						
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen
4) coarse preclass		Level →	Wetland	<i>or (max)</i> <i>and (min)</i> Distance to open water n. objects IKONOS NDVI Mean ms08nn.img (1) <i>blau</i> Mean ms08nn.img (3) <i>rot</i> Mean ms08nn.img (4) <i>nir</i> NIR-blau Stdev ms08nn.img (1) <i>blau</i> Stdev ms08nn.img (3) <i>rot</i> <i>and (min)</i> Mean pca08nn.img (1) <i>1.HK</i> Meam red Not water <i>or (max)</i> Rel. border to water n. Objects Rel. border to wetland n. Objects	40/50/60 0.255/0.4775/0.7 205 /233.5/262 95/160/225 901/902/903 65/307.5/550 3/13/23 4/34.5/45 400/625/850 210/220/230 0/0.5/1 0.4/0.425/0.45	           













Klassenhierarchie IKONOS August 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen	
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
		Level → → Channels → open water	Water	<i>and (min)</i> Blau / nir GLCM Homogeneity, all dir, NIR IKONOS NDVI Mean ms08nn.img (4) <i>nir</i> Not classified as channels	0.8/1/1.2 0.05/0.055/0.06 0.33/0.34/0.35 305/310/315 0/0.4/0.8	    	Hier spielen die geringe Rauhigkeit der ruhigen Wasseroberfläche, ein niedriger Wert im NDVI (nicht Vegetation) und geringe Reflexion im NIR sowie die negative Ratio in NIR-blau eine Rolle um eindeutige Wasserflächen zu erkennen.
	Water	Level → Water →	Open Water	<i>and (min)</i> Length/width Not Membersh. To channels (14)	12/13/14 0/0.5/1	 	
	Channels	Level →	Channels 2 submersed Veg.	<i>And (min)</i> Distance to channels n. objects GLCM Homogeneity, all dir, nir IKONOS NDVI Length/width Mean ms08nn.img (4) <i>nir</i> Mean pca1 NIR – blau Not classified as channels	100/110/120 0.015/0.0625/0.11 0.25/0.345/0.44 1.5/2/2.5 325/332.5/340 400/412.5/425 -1/54.5/110 0/0.4/0.8	       	

















Klassenhierarchie IKONOS August 2001; multispektrale Auswertung						
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen
		Level →	Submersed Veg.	<i>and (min)</i> Distance to water n. Objects GLCM Homogeneity, all dir, NIR IKONOS NDVI Mean ms08nn.img (4) <i>nir</i> Mean pca1 NIR – blau Not classified as channels	60/62.5/65 0.035/0.0725/0.11 0.25/0.315/0.38 305/310/315 390/405/420 -1/-29.5/60 0/0.4/0.8	      
		Level → Water →	Channels	<i>and (min)</i> Length/Width Length/Width (only main line) Rel. Area of open water n. Objects (5)	2.5/2.75/3 4.5/4,75/5 0.05/0.075/0.1	  
		Level →	Moor area	<i>Or (max)</i> <i>And (min)</i> IKONOS NDVI Mean ms08nn.img (1) <i>blau</i> Mean ms08nn.img (3) <i>rot</i> Mean pca08nn.img (1) <i>1.HK</i> Mean pca08nn.img (1) <i>2.HK</i> NIR – blau Stdev ms08nn.img (1) <i>blau</i> <i>And (min) [max. value 0.6]</i> Classified as unclassified Rel. border to moor areas n. objects <i>[max.0.6]</i>	0.35/0.51/0.67 210/227.5/245 118/159/200 420/547.5/675 -235/-190.5/-146 140/250/360 8/8.25/8.5 0/0.5/1 0.95/0.975/1	        





Klassenhierarchie IKONOS August 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen	
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
		Level →	Pasture/Meadow	<i>and (min)</i> IKONOS NDVI Mean ms08nn.img (1) <i>blau</i> Mean ms08nn.img (3) <i>rot</i> Mean pca08nn.img (2) <i>2.Hk</i> Not similarity to wetlands Rel. area of moor areas n. objects (10) Rel. border to wetlands n. objects Stdev ms08nn.img (3) <i>rot</i> Stdev pca08nn.img (1) <i>1.Hk</i>	0.55/0.66/0.77 233/259/285 135/185/235 -320/-312.5/-305 0/0.5/1 0.8/0.9/1 2/16/30 100/112.5/115	       	
		Level →	harvested field	<i>and (min)</i> Area IKONOS NDVI Mean ms08nn.img (1) <i>blau</i> Mean ms08nn.img (3) <i>rot</i> Mean ms08nn.img (4) <i>nir</i> Mean pca08nn.img (2) <i>2.Hk</i> Not similarity to moor areas Not similarity to wetland Stdev ms08nn.img (1) <i>blau</i>	2000/2250/2500 0.145/0.3825/0.62 240/290/340 180/235/290 930/940/950 -510/-335/-160 100/115/130	      	
2) water detail		Level → → deep water → shallow water → br. shal. water → dark s. water	water_GR	<i>Or (max)</i> Existence of channels (l4) super-objects(2) Existence of subm. veg. (l4) s.objects(2) Existence of water (l4) super-objects(2)	0/0.5/1 0/0.5/1 0/0.5/1	  	

Klassenhierarchie IKONOS August 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
	Water_GR	Level → water_GR →	deep water	And (min) Mean nir Mean red	140/145/150 100/105/110	 	
	Water_GR	Level → water_GR → → br. shal. water → dark s. water	shallow water	And (min) Mean nir Mean red	230/235/240 100/105/110	 	
	Water_GR sh. Water	Level → Water_GR → Shallow water →	brighter shallow water	And (min) Mean ms08nn.img (2) grün	280.5/280.75/281		
	Water_GR sh. Water	Level → Water_GR → Shallow water →	dark shallow water	And (min) Mean ms08nn.img (2) grün	280.5/280.75/281		
		Level →	Water corr	And (min) <small>[max value 0.8]</small> Distance to water_GR n. objects Mean nir <small>[max value 0.8]</small> Not classified as water_GR Or (max) Mean August_rauigkeit_NOSnn250.tif Mean August_rauigkeit_NOSnn250.tif Or (max) Existence of water (l4) super-objects(2) Existence of wetlands (l4) super-objects(2) Rel. border to water_GR n. objects	35/42.5/50 0/00/200 0/0.5/1 0/1.85/3.7 4/5/6 0/0.5/1 0/0.5/1 0/0.15/0.3	       	








Klassenhierarchie IKONOS August 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
	Water_GR	Level →	Shallow water / submerged veg.	<i>And (min)</i> Distance to water_GR n. objects IKONOS NDVI Mean blue Mean nir Mean red <i>Or (max)</i> Mean August_rauigkeit_NOSnn250.tif Mean August_rauigkeit_NOSnn250.tif Existence of subm. vegetation s. objects	30/30.5/31 0.15/0.2875/0.425 190/197.5/205 30/170/310 50/114.5/179 3.9/3.925/3.95 4.3/5.2/6.1 0/0.5/1	       	
1) reed/wetland detailed		Level → → moor → reed_GR → lowland moor → low.Moor/lit.M → low moor fill in → forest. wetland	Wetland area	<i>Or (max)</i> <i>And (min)</i> Existence of water (l4) super objects (3) Not Existence of water_GR (l2) s objects (1) Existence of moor areas (l4) super objects (3) Existence of wetlands (l4) super objects (3)	0/0.5/1 0/0.5/1 0/0.5/1 0/0.5/1	   	
	Wetland a.	Level → Wetland area → → moor rough → moor smooth	moor	<i>And (min)</i> Existence of moor areas (l4) super objects (3)	0/0.5/1		
	Wetland a. Moor	Level → Wetland area → Moor →	Moor rough	<i>Or (max)</i> GLCM Homogeneity, all dir, nir <i>Or (max)</i> Mean April_rauigkeit_NOSnn250.tif Mean April_rauigkeit_NOSnn250.tif	0.19/0.195/0.2 3.5/4/4.5 5.5/6/6.5	  	










Klassenhierarchie IKONOS August 2001; multispektrale Auswertung						
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen
	Wetland a. Moor	Level → Wetland area → Moor →	Moor smooth	And (min) Not moor rough		
	Wetland a.	Level → Wetland area → → reed dense c. → reed/sedge m.	Reed_GR	Or (max) Distance to water n. objects Rel. border to reed_GR n. objects	0/10/20 0/0.5/1	 
	Reed_GR	Level → Wetland area → Reed_GR →	Reed dense c.			
	Reed dense	Level → Wetland area → Reed_GR →	Aquatic reed	And (min) Mean ms08nn.img (3) <i>rot</i> Mean ms08nn.img (4) <i>nir</i>	140/160/180 600/650/700	 
	Reed dense	Level → Wetland area → Reed_GR →	Aq. Reed fill in	And (min) Not Classified as 1 reed/wetland detailed Or (max) Rel. border to aquatic reed n. objects And (*) Rel. border to aquatic reed (l1) n. objects Rel. border to water (l1) n. objects	0/0.5/1 0/0.5/1 0/0.5/1 0/0.05/0.1	   
	Reed_GR	Level → Wetland area → Reed_GR →	Reed/sedge m.			
	Reed/sed ge m	Level → Wetland area → Reed_GR →	Trans/terr reed	And (min) Mean ms08nn.img (1) <i>blau</i> Mean ms08nn.img (3) <i>rot</i> Mean nir Stdev ms08nn.img (3) <i>rot</i>	220/240/260 130/154.5/179 200/425/650 2/8.5/15	   

Klassenhierarchie IKONOS August 2001; multispektrale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
	Reed/sed ge m	Level → Wetland area → Reed_GR →	Trans reed fill in	<i>And (min)</i> Not classified as 1 reed/wetland detailed <i>Or (max)</i> Rel. border to trans./terr. Reed n. objects <i>And (*)</i> Rel. border to trans./terr. Reed n. objects Rel. border to water (l1) n. objects	0/0.5/1 0/0.5/1 0/0.5/1 0/0.05/0.1	   	
		Level → Wetland area →	Lowl. Moor/lit. meadow	<i>And (min)</i> Distance to water (l1) n. objects GLCM Homogeneity,all dir, nir Mean nir Existence of wetlands (l4) s. objects Not moor (l1) Stdev ms08nn.img (4) <i>nir</i>	0/100/200 0.06/0.07/0.08 700/750/800 0/0.5/1 49/50/51	    	
	Lowland. moor/lit.m.	Level → Wetland area →	Lowland moor 2	<i>And (min)</i> Mean ms08nn.img (3) <i>rot</i> Mean ms08nn.img (4) <i>nir</i> <i>Or (max)</i> Rel. border to lowl.Moor/lit.mead n.objects Rel. border to lowl.moor2 n. objects Stdev ms08nn.img (3) <i>rot</i>	125/137.5/150 305/407.5/510 0/0.25/0.5 0/0.25/0.5 3/4.5/6	    	
	Lowland moor/lit.m.	Level → Wetland area →	Lowl. Moor fill in	<i>And (min)</i> Not classified as 1 reed/wetland detailed Rel. border to lowl.moor/lit.mead n.objects	0/0.5/1 0.5/0.75/1	 	

Klassenhierarchie IKONOS August 2001; multispektrale Auswertung						
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen
		Level → Wetland area →	Forested wetland / bushland	<i>And (min)</i> Distance to water n. objects GLCM Homogeneity, all dir, nir Mean nir Mean red	5/17.5/30 0.07/0.08/0.09 300/350/400 170/175/180	   

Tab. 39: Detaillierte Klassenhierarchie IKONOS August 2001

Klassenhierarchie IKONOS April & August; multisaisonale Auswertung							
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich		Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen	
6) wetland - acre		Level → → real wetland → acre/meadow/tree	Wetland/acre/meadow	<i>and (min)</i> Rel area of wetland sub-objects (1)	0/0.5/1		
		Level →	Water	<i>and (min)</i> Rel area of water sub-objects (1)	0/0.5/1		
		Level → Wetland/acre/meadow →	Real wetland	<i>And (min)</i> Not similarity to acre/meadow/tree			
		Level → Wetland/acre/meadow →	Acre/meadow/tree	<i>and (min)</i> not relative border to water (l6) n.-objects Rectangular fit Shape index	0/0.5/1 0.7/0.725/0.75 2/2.05/2.1	  	
		Level → Wetland/acre/meadow → Acre/meadow/tree →	Acre/meadow	<i>and (min)</i> Area	1500/1500.5/1501		
		Level → Wetland/acre/meadow → Acre/meadow/tree →	Tree	<i>and (min)</i> Area	1500/1500.5/1501		

Klassenhierarchie IKONOS April & August; multisaisonale Auswertung						
Level	Gruppe	Vererbung	Klasse	Eigenschaft(en)	Wertebereich	Bemerkungen
Level	Gruppe	Vererbung	Klassenname	Bezeichnung der verwendeten Eigenschaft	Min/Mittelwert/Max	Funktion und Bemerkungen
5) wetland - water		Level → → not water Aug → water apr&aug	Water	<i>And (min)</i> Mean ms04nn.img (4) <i>NIR April</i> Mean ms08nn.img (3) <i>Rot August</i> Rectangular fit	250/255/260 330/325/320 0.999/0.9995/1	  
	Water	Level→ Water →	Water apr&aug	<i>And (min)</i> Mean ms04nn.img (4) <i>NIR April</i> Mean ms08nn.img (3) <i>Rot August</i>	230/235/240 230/235/240	 
	wetland	Level→ water → → subm. Macro. → water lilies	Not water aug	<i>And (min)</i> Not membership to water apr&aug <i>Or (max)</i> Existence of real wetland (l6) super-obj. (1) Existence of water (l6) super-objects (1)	0/0.5/1 0/0.5/1 0/0.5/1	  
	Wetland	Level → Not water aug →	Submerged macrophytes	<i>And (min)</i> Not similarity to water lilies		
	Wetland	Level → Not water aug →	Water lilies	<i>And (min)</i> Mean ms08nn.img (4) <i>NIR</i>	300/305/310	

Accuracy April 2001 Level 4

User \ Reference Class (pixel)	grassland (pasture/meadow)	potential open moor areas	potential wetlands	harvested fields	water	channels
Confusion Matrix						
grassland (pasture/meadow)	25553	198	0	1132	0	0
potential open moor areas	8	21691	0	0	0	5
potential wetlands	391	0	12184	233	69	0
harvested fields	2262	250	158	1115	0	0
water	0	0	432	0	71808	9
channels	0	0	0	0	0	50
Accuracy						
User	95,053%	99,940%	94,618%	29,458%	99,390%	100,000%
Producer	82,124%	68,795%	84,091%	35,151%	99,903%	75,758%
Totals						
Overall Accuracy	86,963%					
KIA	81,423%					

Accuracy April 2001 Level 3

User \ Reference Class (pixel)	external forest	wetland corr.	external grassland	potential moor areas from I4
Confusion Matrix				
external forest	92471	237	0	2305
wetland corr,	0	15837	0	0
external grassland	0	462	25488	1700
potential moor areas from I4	0	0	0	20924
Accuracy				
User	97,325%	100,000%	92,181%	100,000%
Producer	100,000%	94,969%	96,443%	83,934%
Totals				
Overall Accuracy	96,396%			
KIA	93,995%			

Accuracy April 2001 Level 2

User \ Reference Class (pixel)	deep water	shallow water	water corr
Confusion Matrix			
deep water	17863	21	0
shallow water	344	5304	65
water corr	0	0	0
Accuracy			
User	99,883%	92,841%	undefined
Producer	98,111%	99,363%	0,000%
Totals			
Overall Accuracy	98,078%		
KIA	94,687%		

Accuracy April 2001 Level

User \ Reference Class (pixel)	water	sedge dominated lowland moor	reed dense crop	reed/sedge mosaic close to water	moor shrub encroachment	open moor	forested wetland/bushland
Confusion Matrix							
water	23775	0	97	137	0	0	0
sedge dominated lowland moor	0	4100	411	2599	0	0	151
reed dense crop	0	142	349	78	0	0	0
reed/sedge mosaic close to water	1	255	209	1710	0	0	4
moor shrub encroachment	0	101	0	0	1360	299	0
open moor	0	6	0	0	772	8230	0
forested wetland/bushland	0	0	0	4	0	0	15
Accuracy							
User	99,025%	56,466%	61,336%	78,476%	77,273%	91,363%	78,947%
Producer	99,899%	75,340%	29,377%	36,430%	32,661%	94,630%	4,373%
Totals							
Overall Accuracy	81,816%						
KIA	73,913%						

Accuracy August 2001 Level 4

User \ Reference Class (pixel)	grassland (pasture/meadow)	harvested fields	potential wetlands	potential open moor areas	channels	water	submersed vegetation
Confusion Matrix							
grassland (pasture/meadow)	26681	0	116	0	0	0	0
harvested fields	1318	759	0	141	0	0	0
potential wetlands	0	0	11894	0	0	0	520
potential open moor areas	0	0	1236	25341	35	0	0
channels	0	0	0	0	162	764	0
water	0	0	0	0	0	71101	0
submersed vegetation	0	0	0	0	0	0	29
Accuracy							
User	99,567%	34,220%	95,811%	95,224%	17,495%	100,000%	100,000%
Totals							
Overall Accuracy	88,869%						
KIA	84,149%						

Accuracy August 2001 Level 3

User \ Reference Class (pixel)	external forest	external grassland	wetland corr, from I4	potential moor areas from I4
Confusion Matrix				
external forest	92471	0	237	1883
external grassland	0	25053	400	0
wetland corr, from I4	0	435	13645	0
potential moor areas from I4	0	0	2131	23046
Accuracy				
User	97,759%	98,429%	96,911%	91,536%
Producer	100,000%	94,797%	81,824%	92,447%
Totals				
Overall Accuracy	96,082%			
KIA	93,479%			

Accuracy August 2001 Level 2

User \ Reference Class (pixel)	deep water	shallow water	shallow water/submersed vegetation
Confusion Matrix			
deep water	17960	6	91
shallow water	247	5338	239
shallow water/submersed vegetation	0	22	281
Accuracy			
Producer	99,463%	91,655%	92,739%
User	98,643%	98,596%	30,280%
Totals			
Overall Accuracy	96,049%		
KIA	90,163%		

Accuracy August 2001 Level 1

User \ Reference Class (pixel)	water	sedge dominated lowland moor	reed dense crop	reed/sedge mosaic close to water	moor shrub encroachment	open moor	forested wetland/bushland
Confusion Matrix							
water	23799	0	5	0	0	0	0
sedge dominated lowland moor	0	5017	142	1706	0	0	69
reed dense crop	0	0	752	0	0	0	0
reed/sedge mosaic close to water	0	170	109	2904	0	0	20
moor shrub encroachment	0	0	0	0	3069	260	0
open moor	0	113	0	0	37	8437	0
forested wetland/bushland	0	0	0	0	0	0	59
Accuracy							
User	99,979%	72,354%	100,000%	90,665%	92,190%	98,253%	100,000%
Producer	100,000%	92,190%	63,300%	61,866%	73,703%	97,011%	17,201%
Totals							
Overall Accuracy	91,123%						
KIA	87,256%						

Danke

Vielen Dank an alle, die zur Entstehung dieser Arbeit beigetragen haben. An erster Stelle möchte ich mich bei meinem Doktorvater Prof. Dr. Arnulf Melzer und bei Prof. Dr. Ulrich Ammer bedanken, die mir die Bearbeitung dieses Themas ermöglichten und für Fragen jederzeit ein offenes Ohr hatten.

Ganz besonders Danken möchte ich meinen Kollegen im Projekt AQUATIC, insbesondere Claudius Mott und Ralf Schüpferling für die schöne Zeit, konstruktive Anregungen, kritische Anmerkungen und die intensiven fachlichen und privaten Diskussionen.

Natürlich dürfen meine Chefs Thomas Schneider und Stefan Zimmermann nicht unerwähnt bleiben. Ein herzliches Dankeschön an Euch für die fachliche Betreuung und die konstruktiven Beiträge.

An dieser Stelle möchte ich auch meinen Diplomanden Katharina Drexel, Karin Schneider v. Deimling, Cero Rogg und Florian Löschenbrand für ihre Mitarbeit im Projekt, mehr oder weniger ausgedehnte Geländekampagnen und anregende Diskussionen danken. Die Zusammenarbeit mit Euch hat mir viel Spaß gemacht.

Für unermüdliches Korrekturlesen und intensive Diskussionen über den Sinn und Unsinn meiner Formulierungen möchte ich besonders Andrea Vogel, Susi Schneider, Nicole Pinnel und Gunilla Kaiser danken.

Allen Mitarbeitern der Limnologischen Station danke ich für drei Jahre des intensiven, abwechslungs- und lehrreichen Zusammenlebens, Zusammenarbeitens und Zusammenfeierns. In dieser besonderen Atmosphäre sind Freundschaften entstanden, die hoffentlich ein Leben halten. Ich werde mich bemühen.

Ein besonderer Dank gilt meinen Eltern, ohne deren Unterstützung mein Studium und auch diese Arbeit nicht möglich gewesen wären.

Iffeldorf im Januar 2004

Thorsten Andresen

LEBENS LAUF

ANGABEN ZUR PERSON

Name Thorsten Andresen
Geburtsdatum / -ort 27.12.1970, in Neumünster
Staatsangehörigkeit deutsch



ARBEITSERFAHRUNG

11.2000 bis 10.2003 **Wissenschaftlicher Angestellter an der Limnologischen Station der TU-München in Iffeldorf**
Projekt AQUATIC

5.1995 bis 4.2000 **Mitarbeiter am Geographischen Institut der Christian-Albrechts-Universität zu Kiel**
Systemverwaltung und Administration des Institutsnetzwerkes, Betreuung des PC-Labors, Erstellung und Pflege der Web-Seiten des Geographischen Instituts

UNIVERSITÄRE AUSBILDUNG

11.2000 bis 10.2003 **Promotionsstudium an der Technischen Universität München**
Promotion zum Thema: "Strategien zur Wissensbasierten Bildanalyse hoch auflösender Fernerkundungsdatensätze für das Monitoring gewässernaher Feuchtgebiete"

9.6.2000 **Diplom**
Diplomarbeit zum Thema: „Visualisierung von Geodaten mit 3D-Animationen - Analyse des Informationsgewinnes anhand einer Animation der Morphodynamik des Elbe-Ästuars“

17.7.1996 **Vordiplom**

10.1994 bis 5.2000 **Studium der Geographie an der Christian-Albrechts-Universität zu Kiel mit den Nebenfächern:**
Ozeanographie und Wasserwirtschaft

SCHUL- UND BERUFS AUSBILDUNG

8.1991 bis 1.1994 **Technologie-Büro Georg Theinert, Neumünster**
Abschluß: Datenverarbeitungskaufmann

7.1990 bis 6.1991 **Grundwehrdienst, Clausthal-Zellerfeld und Neumünster**

8.1981 bis 6.1990 **Gymnasium: Integrierte Gesamtschule Neumünster**

8.1977 bis 6.1981 **Grundschule: Wippendorfschule Neumünster**

PRAKTIKA

7.1997 bis 9.1997 **Praktikum beim Deutschen Fernerkundungs Datenzentrum (DFD) der Deutschen Forschungsanstalt für Luft- und Raumfahrt (DLR) in Oberpfaffenhofen, Abteilung VAV (Value Adding & Visualization)**

10.1998 bis 11.1998 **Praktikum beim CIFOT (Centro de Investigación y Formación para el Ordenamiento Territorial), Mendoza/Argentinien**