Bewertung, Verarbeitung und segmentbasierte Auswertung sehr hoch auflösender Satellitenbilddaten vor dem Hintergrund landschaftsplanerischer und landschaftsökologischer Anwendungen

Von der Fakultät Forst-, Geo- und Hydrowissenschaften der
Technischen Universität Dresden zur Erlangung des akademischen Grades
Doktor der Naturwissenschaften (Dr. rer. nat.) genehmigte

Dissertation

Vorgelegt von Diplom-Geograph Marco Neubert,
geboren am 22. November 1974 in Dresden,
am 14. Februar 2005

Verteidigt am 14. Oktober 2005

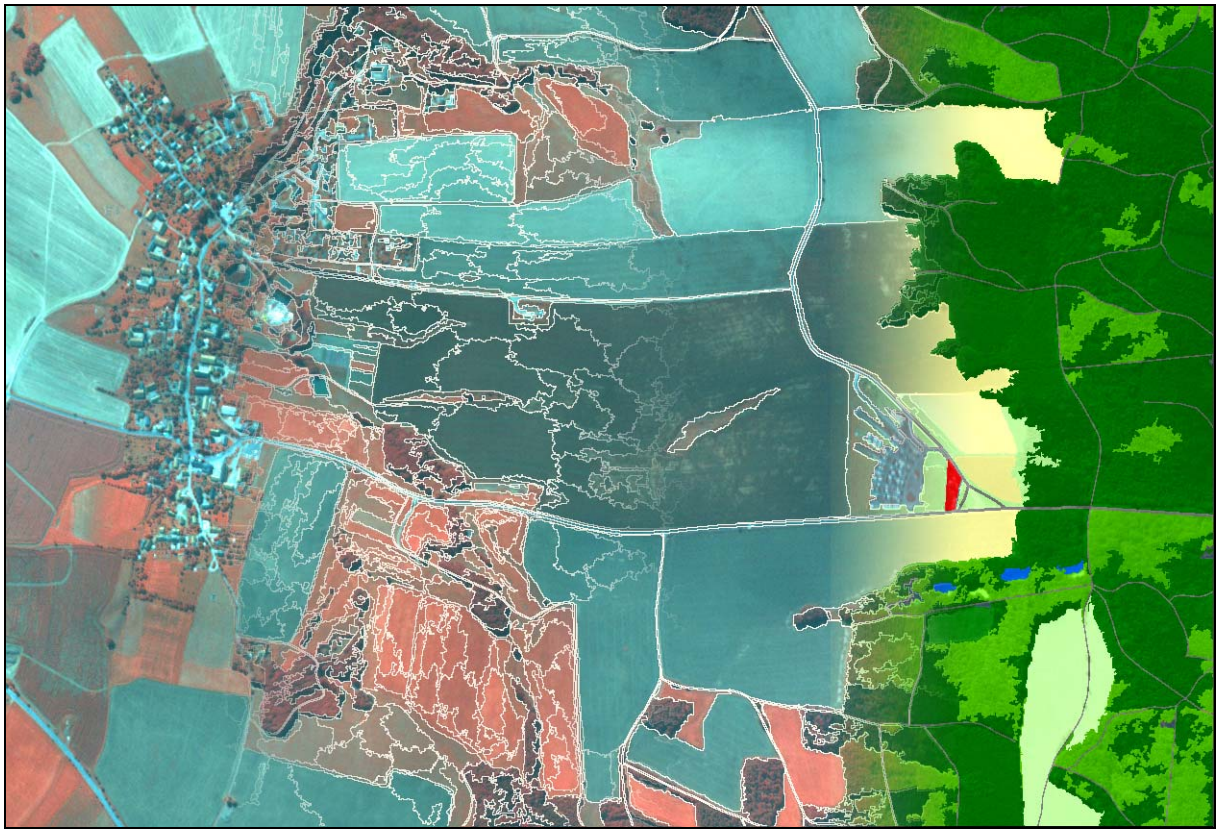

Gutachter:

Prof. Dr. habil. Elmar Csaplovics, Institut für Photogrammetrie und Fernerkundung, Technische Universität Dresden

ao. Univ.-Prof. Mag. Dr. Thomas Blaschke, Zentrum für Geoinformatik, Universität Salzburg

Dr.-Ing. Gotthard Meinel, Leibniz-Institut für ökologische Raumentwicklung e. V., Dresden

Inhaltsverzeichnis

Abbildungsverzeichnis		V
Tabellenverzeichnis		VII
Abkürzungsverzeichnis		IX
Urheberrechtlich geschützte Bezeichnungen		XIII
Zusammenfassung		XV
Abstract		XVII
Teil I:	***Einführung, Grundlagen und Stand der Wissenschaft***	***1***
1	**Einführung und Problemstellung**	**3**
1.1	Einleitung – Fernerkundung als Zukunftstechnologie	3
1.2	Hintergrund und Zielstellung der Arbeit	5
1.3	Aufbau der Arbeit	5
2	**Grundlagen und Stand der Forschung: Vom Pixel zum Vektor oder von der Fernerkundung zum GIS-Datensatz**	**7**
2.1	Sehr hoch auflösende Fernerkundungssysteme	7
2.1.1	Einordnung in Systematiken von Fernerkundungsdaten	8
2.1.2	Entwicklung und Eigenschaften sehr hoch auflösender Fernerkundungssensoren	8
2.1.3	Auswirkungen der sehr hohen geometrischen Auflösung auf die Bildklassifikation	13
2.2	Auswertungsverfahren von Fernerkundungsdaten	16
2.2.1	Visuelle Interpretation	17
2.2.2	Pixelbasierte Auswertung	18
2.2.2.1	Schwellwertverfahren	19
2.2.2.2	Überwachte spektrale Klassifikationsverfahren	20
2.2.2.3	Unüberwachte spektrale Klassifikationsverfahren	21
2.2.2.4	Per-parcel-Klassifikation	22
2.2.2.5	Neuronale Netze	23
2.2.2.6	Weitere pixelbasierte Verfahren, Kombinationen und Variationen	24
2.2.3	Segmentbasierte Auswertung	25
2.2.3.1	Kantenbasierte Segmentierungsverfahren	28
2.2.3.2	Regionenbasierte Segmentierungsverfahren	29
2.2.3.3	Hybride Segmentierungsverfahren	30
2.2.3.4	Weitere Segmentierungsverfahren	31
2.2.4	Wissensbasierte bzw. Expertensysteme	31
2.2.5	Objekterkennung und -extraktion	32
2.2.6	Vergleichende Methodenbewertung	32
2.3	Probleme der Fernerkundung	34
2.3.1	Umbrüche in der Fernerkundung	34
2.3.2	Mangelnde Anwenderorientierung	36
2.3.3	Integration von GIS und Fernerkundung	37
2.4	Zum Einsatz der Fernerkundung in Landschaftsplanung und Landschaftsökologie	39

Teil II:	***Datengrundlagen und Methodik***	***43***
3	**Datengrundlagen und Vorverarbeitung**	**45**
3.1	IKONOS-Satellitenbilddaten	45
3.1.1	Allgemeine Charakterisierung	45
3.1.2	Beurteilung der Bildqualität	49
3.1.3	Vergleich Luftbild versus IKONOS-Satellitenbild	52
3.2	Vorverarbeitung der IKONOS-Daten	54
3.2.1	Geometrische Entzerrung	55
3.2.2	Atmosphärische und topographische Korrektur	58
3.2.3	Bildfusion	64
3.3	Weitere Datengrundlagen	68
3.3.1	Laserscanner-Höhenmodell	68
3.3.2	Aus IKONOS-Daten abgeleitete Indizes	69
3.3.3	Verwendete Geobasisdaten	69
4	**Segmentbasierte Auswertungsmethoden**	**71**
4.1	Der segmentbasierte Klassifikationsansatz eCognition	71
4.1.1	eCognition-Segmentierungsverfahren	72
4.1.2	eCognition-Klassifikationsverfahren	75
4.1.3	Bewertung von eCognition	76
4.2	Vergleich segmentbasierter und pixelbasierter Klassifikation	77
4.3	Vergleich aktuell verfügbarer Segmentierungsprogramme und deren Segmentierungsqualität	83
4.3.1	Grundlagen und Methodik des Segmentierungsvergleiches	83
4.3.2	Visuelle Bewertung der Gesamtsegmentierungen	86
4.3.3	Quantitative Bewertung anhand von Testflächen	90
4.3.4	Vergleich mit ähnlichen Untersuchungen	92
4.3.5	Schlussfolgerungen aus dem Segmentierungsvergleich	92
Teil III:	***Anwendung segmentbasierter Klassifikationsverfahren auf IKONOS-Daten***	***95***
5	**Landschaftsanalyse durch die segmentbasierte Auswertung von IKONOS-Daten**	**97**
5.1	Segmentbasierte Klassifikation unterschiedlicher Testgebiete	97
5.1.1	Segmentierungs- und Klassifikationsstrategie	98
5.1.2	Klassifikationsergebnisse	99
5.1.3	Diskussion der Ergebnisse	102
5.2	Segmentgeometrien als Berechnungsgrundlage von Landschafts strukturmaßen	102
6	**Automatisierte Aktualisierung digitaler Datensätze – Beispiel Biotop- und Nutzungstypenkartierung**	**107**
6.1	Einführung	107
6.2	Automatisierte Aktualisierung von GIS-Daten – Stand der Forschung	108
6.3	Die Biotop- und Nutzungstypenkartierung	110
6.3.1	Erstellung und Eigenschaften der BNTK-Daten	110

6.3.2	Bewertung des Interpretationsverfahrens sowie der Datengrundlage	110
6.3.3	Beurteilung der Datenqualität	111
6.4	Segmentbasierte Biotop- und Nutzungstypenklassifikation anhand von IKONOS-Daten	112
6.4.1	Vorüberlegungen	113
6.4.2	Methodisches Vorgehen	114
6.4.2.1	Eignungsbewertung der IKONOS-Daten	114
6.4.2.2	Verwendung von Zusatzdaten	117
6.4.2.3	Segmentierungsstrategie	117
6.4.2.4	Klassifikationsstrategie	118
6.4.3	Bewertung der Ergebnisse	121
6.4.4	Automatisierung und Übertragbarkeit der Bearbeitung	127
6.5	Segmentierung gescannter CIR-Luftbilder	128
6.6	Schlussfolgerungen und Ausblick zur Automatisierung der Biotop- und Nutzungstypenkartierung	130
7	**Schlussfolgerungen und Ausblick**	**133**
Literaturverzeichnis		137
Danksagung		151

Abbildungsverzeichnis

Abb. 2.1: Einteilung ausgewählter aktueller Fernerkundungssysteme nach den in Tabelle 2.2 genannten Kriterien Aufnahmemodus, -medium und -plattform 9

Abb. 2.2: Entwicklung der Bodenauflösung ausgewählter Fernerkundungs sensoren 11

Abb. 2.3: Entwicklungstrend (Trendlinie) der Bodenauflösung ziviler Erdbeobachtungssatelliten 11

Abb. 2.4: Spektrale Auflösung derzeit verfügbarer sehr hoch auflösender Satellitensensoren im Vergleich zu Landsat-7 ETM+ 12

Abb. 2.5: Beispiele aus IKONOS-Daten für mangelhafte spektrale Unterscheid barkeit, spektrale Variabilität sowie die Bildauswertung störende Details 15

Abb. 2.6: Verallgemeinerte Prozesskette der fernerkundlichen Bilddatenverar beitung in Form einer Informationspyramide 16

Abb. 3.1: Grauwertsensitivität der IKONOS-Spektralkanäle 46

Abb. 3.2: Illustration abwechselnder Aufnahmemodi benachbarter Bildszenen durch IKONOS. 47

Abb. 3.3: Lage der verwendeten IKONOS-Bildszenen in Sachsen 49

Abb. 3.4: Darstellung der verwendeten IKONOS-Bildszenen 49

Abb. 3.5: Beispiele für Bildstörungen durch Reflexionseffekte in den IKONOS-Bilddaten 51

Abb. 3.6: Histogramme der einzelnen Kanäle der IKONOS-Szene Dresden 51

Abb. 3.7: Abfolge der durchgeführten Vorverarbeitungsschritte für IKONOS-Daten 54

Abb. 3.8: Die Überlagerung der orthorektifizierten IKONOS-Daten mit ATKIS-Daten verdeutlicht die hohe Lagetreue. Die Daten der Biotopkartierung zeigen dagegen teils erhebliche Abweichungen 57

Abb. 3.9: Streckung bzw. Stauchung einiger Bildbereiche infolge der Ortho rektifikation. Die Infrarotdarstellung zeigt den Lilienstein vor und nach der Orthorektifikation 57

Abb. 3.10: Verfahrensablauf zur atmosphärischen und topographischen Korrektur mit ATCOR3 58

Abb. 3.11: Aus dem DHM abgeleitetes Hangneigungsmodell. In der Elbe sowie auf ebenen Hochflächen sind störende Artefakte deutlich erkennbar 59

Abb. 3.12: Dialogfenster ATCOR3 60

Abb. 3.13: Gute Übereinstimmung der Testspektren gegenüber des Referenz spektrums zur Überprüfung der Kalibrierungsdatei für die Multi spektraldaten 61

Abb. 3.14: Dialogfenster des Moduls ATCON und Originalbilddaten überlagert mit der berechneten Dunstmaske 62

Abb. 3.15: Gegenüberstellung eines Ausschnittes des originalen IKONOS-Bildes mit dem atmosphärisch und topographisch korrigierten Ergebnis sowie dem Ergebnis ohne Dunstkorrektur 63

Abb. 3.16: Stark dunstbeeinflusstes multispektrales IKONOS-Satellitenbild der Stadt Dresden und dessen dunstbereinigtes Korrekturergebnis 64

Abb. 3.17: Für den Bildfusionsvergleich verwendete panchromatische und multi spektrale IKONOS-Originaldaten von San Diego, USA 65

Abb. 3.18: Fusionsergebnisse der PC-Bildfusion mit unterschiedlichen Resampling-Verfahren: cubic convolution, bilinear interpolation sowie nearest neighbour interpolation 66
Abb. 3.19: Fusionsergebnisse IHS-Transformation, multiplikative Bildfusion, Brovey-Transformation, AIF-Verfahren, Fusion nach Zhang 2002 sowie von Space Imaging panchromatisch geschärfte IKONOS-Daten 67
Abb. 3.20: 3D-Abbildung des Laserscanner-DGM für einen Ausschnitt der Sächsischen Schweiz 68
Abb. 4.1: Komponenten der eCognition-Software: Ebenenweise aufeinander aufbauende Segmentgeometrie, Hierarchie und Semantik der Segmente sowie die Wissensbasis zur Klassifikation 71
Abb. 4.2: Dialogfenster zur Eingabe der Segmentierungsparameter in eCognition 3 72
Abb. 4.3: Segmentierungsergebnisse bei unterschiedlicher Parameterwahl 73
Abb. 4.4: Zusammenhang zwischen Scale-Faktor und Anzahl der segmentierten Bildobjekte sowie durchschnittlicher Objektgröße 74
Abb. 4.5: Lage des Untersuchungsgebietes Dresden-West in den Stadtgrenzen Dresdens und innerhalb der IKONOS-Gesamtszene sowie multispek traler Bildausschnitt 78
Abb. 4.6: Klassifikationsergebnisse mit Expert Classifier und eCognition 79
Abb. 4.7: Ausschnitte des Untersuchungsgebietes 80
Abb. 4.8: Grundlagen des Segmentierungsvergleichs: IKONOS-Fusionsbild eines urbanen und eines ruralen Gebietes 85
Abb. 4.9: Vektor-Konvertierungsprobleme beim Minimum Entropy Approach 86
Abb. 4.10: Darstellung der 20 genutzten, visuell kartierten Referenzflächen 87
Abb. 4.11: Segmentierungsergebnisse von CAESAR 3.1 und von den Data Dissection Tools 88
Abb. 4.12: Segmentierungsergebnisse von eCognition 2.1 und 3.0 88
Abb. 4.13: Segmentierungsergebnisse der ERDAS-IMAGINE-Erweiterung Image Segmentation und von InfoPACK 1.0 89
Abb. 4.14: Segmentierungsergebnisse des Minimum Entropy Approach und von SPRING 4.0 90
Abb. 5.1: Ländliches Testgebiet (Vordere Sächsische Schweiz) 98
Abb. 5.2: Klassifikationsergebnis des urbanen Testgebietes mittels eCognition, Klassifikationsebene 3 101
Abb. 5.3: Klassifikationsergebnis des ländlichen Testgebietes mittels eCognition, Klassifikationsebene 2 101
Abb. 6.1: Ablaufschema zur Erfassung von Biotop- und Nutzungstypen aus IKONOS-Daten mittels eCognition 114
Abb. 6.2: Erstellter Entscheidungsbaum für die Ebene 3 und Möglichkeit der automatischen Erstellung von Zugehörigkeitsfunktionen anhand ausgewählter Testflächen mit dem Sample Editor 119
Abb. 6.3: Beispiele für unerwünschte Segmentierungseffekte 121
Abb. 6.4: Satellitenbild und Klassifikationsergebnis auf Ebene der Hauptgruppen im Vergleich zur originalen BNTK 123
Abb. 6.5: Satellitenbild und Klassifikationsergebnis auf Ebene der Untergruppen im Vergleich zur originalen BNTK 125
Abb. 6.6: Dialogfenster des Protocol Editors 127
Abb. 6.7: Typische Fehler bei der Segmentierung der CIR-Luftbilder: Verschmel zung von spektral ähnlichen Wiesen- und Laubwaldflächen sowie Entstehung fraktaler Segmente in Waldgebieten 129

Tabellenverzeichnis

Tab. 2.1: Einteilung von Fernerkundungsdaten nach ihrer räumlichen Boden auflösung 8
Tab. 2.2: Taxonomien von Fernerkundungsdaten 8
Tab. 2.3: Existierende und in naher Zukunft geplante, zivile, hoch bzw. sehr hoch auflösende optische Satellitensysteme in chronologischer Reihenfolge nach deren Starttermin 10
Tab. 2.4: Gegenüberstellung von Auswertungsverfahren 33
Tab. 2.5: Anwendungsmöglichkeiten sehr hoch auflösender Fernerkundungs daten in der Landschaftsplanung und Landschaftsökologie sowie deren Nachbardisziplinen 41
Tab. 3.1: Eigenschaften des IKONOS2-Sensors OSA 45
Tab. 3.2: Qualitätsstufen der IKONOS-Bildprodukte 48
Tab. 3.3: Aufnahmeparameter der verwendeten IKONOS-Szenen Dresden und Vordere Sächsische Schweiz 50
Tab. 3.4: Vergleichende Bewertung von analogem Luftbild und sehr hoch auflösendem digitalen Satellitenbild 53
Tab. 3.5: Übersicht derzeit verfügbarer digitaler Luftbildkameras 54
Tab. 3.6: Entzerrungsfehler der orbitentzerrten IKONOS-Szenen (Produktlevel Geo) sowie Fehler der daraus abgeleiteten passpunkt- bzw. orthorek tifizierten Szenen 56
Tab. 3.7: Wetterdaten der Station Lichtenhain-Mittelndorf, 01.08.2000, 9.50 Uhr 60
Tab. 3.8: Erstellte Kalibrierungsdatei für die multispektralen IKONOS-Daten der Sächsischen Schweiz 61
Tab. 3.9: Genutzte Parameter im ATCOR-Modul ATCON 61
Tab. 4.1: Verwendete Eingangsdaten zum Methodenvergleich zwischen Expert Classifier und eCognition 78
Tab. 4.2: Erkennungs- und Klassifikationsgüte im Vergleich 81
Tab. 4.3: Vergleichende Gegenüberstellung der getesteten Segmentierungs softwares 84
Tab. 4.4: Vergleichende Gegenüberstellung der Segmentierungsergebnisse für Referenzfläche 9 90
Tab. 4.5: Ergebnisse des Segmentierungsvergleichs für 20 Testflächen 91
Tab. 5.1: Zur Segmentierung mit eCognition verwendete Parameter für das urbane und das rurale Testgebiet 99
Tab. 5.2: Klassifikationsgüte des urbanen und ruralen Testgebietes 100
Tab. 5.3: Vergleich von Berechnungsergebnissen auf Basis eines BNTK-Objektes sowie jeweils eines ungeglätteten und geglätteten segmentierten Objektes 105
Tab. 6.1: Struktur des achtstelligen BNTK-Zahlencodes anhand eines Beispiels 110
Tab. 6.2: Bewertung der IKONOS-Daten bezüglich der visuellen Erkennbarkeit der sächsischen Biotoptypen und ihrer Segmentier- sowie Klassifizier barkeit 115
Tab. 6.3: Verwendete Eingangsdaten, Parametereinstellungen sowie ange strebtes Klassifikationsziel für die einzelnen Segmentierungsebenen 118
Tab. 6.4: Zur Objektfusion ausgewählte Klassen sowie Objektzahl (gerundet) vor und nach ihrer Fusion 120
Tab. 6.5: Ergebnisse der Güteprüfung auf Ebene der BNTK-Hauptgruppen 122

Tab. 6.6: Statistischer Vergleich der Ergebnisse auf Hauptgruppenebene mit der BNTK 122
Tab. 6.7: Statistischer Vergleich der Ergebnisse auf Untergruppenebene mit der BNTK 126
Tab. 6.8: Vor- und Nachteile der visuellen Interpretation analoger CIR-Luftbilder und der segmentbasierten Klassifikation von IKONOS-Satellitenbild daten 129

Abkürzungsverzeichnis

3D	Dreidimensional
ADEOS	*Advanced Earth Observing Satellite*, japanischer Satellitensensor
ADS 40	*Airborne Digital Sensor*, Flugzeugscanner
AIF	*Adaptive Image Fusion*, Bildfusionsverfahren
ALK	Automatisierte Liegenschaftskarte
ALOS	*Advanced Land Observing Satellite*, japanischer Satellitensensor
ATCON	Modul der Software ATCOR
ATCOR	Atmosphärische und topographische Korrektur, Software entwickelt vom DLR
ATKIS	Amtliches Topographisch-Kartographisches Informationssystem
BfN	Bundesamt für Naturschutz
BNTK	Biotop- und Nutzungstypenkartierung
BRDF	*Bidirectional reflectance distribution function*, bidirektionale Reflexionsverteilungsfunktion, Korrekturverfahren zur Beseitigung von Reliefeinflüssen in Fernerkundungsdaten
CAD	*Computer Aided Design*, rechnergestütztes Zeichnen und Entwerfen
CASI	*Compact Airborne Spectrographic Imager*, hyperspektraler Flugzeugscanner
CCD	*Charged Coupled Device*, Sensor für digitale Aufnahmesysteme
CE90	*Circular Error 90*, mittlerer Lagefehler für 90 % der Punkte
CIR	*Colour Infrared*, Farbinfrarot
CLC	*CORINE Land Cover*, europaweite Datenbank zur Landnutzung
CORINE	*Coordination of information on the environment*, Programm der Europäischen Union zur Erstellung einer europaweiten Datenbank zur Landnutzung
DAIS	*Digital Airborne Imaging Spectrometer,* multispektraler Flugzeugscanner
DGK	Deutsche Grundkarte
DGM	Digitales Geländemodell
DGPS	*Differential Global Positioning System,* Differential-GPS
DHM	Digitales Höhenmodell
DLM	Digitales Landschaftsmodell
DLR	Deutsches Zentrum für Luft- und Raumfahrt
DMC	*Digital Mapping Camera*, Flugzeugscanner
DOM	Digitales Oberflächenmodell
DRA	*Dynamic Range Adjust*, Grauwertstreckung
DVD	*Digital Versatile Disc*, Speichermedium
DWD	Deutscher Wetterdienst
ECHO	*Extraction and Classification of Homogenous Objects*, Segmentierungs-software

EO-1	*Earth Observing-1*, amerikanischer Satellitensensor
ERS	*Earth Remote Sensing Satellite*, erster europäischer Radarsatellit
ERTS	*Earth Ressource Technology Satellite*, erster ziviler Fernerkundungssatellit gestartet 1972, 1995 umbenannt in Landsat-1
ETM+	*Enhanced Thematic Mapper Plus*, Sensor des Landsat-7-Satelliten
GeoTIFF	Georeferenziertes *Tagged Image File Format*, Rasterdatenformat
GIS	Geographische Informationssysteme
GIFOV	*Ground instantaneous field of view*, Bodenauflösung von Fernerkundungsdaten
GPS	Globales Positionierungssystem
GSD	*Ground sampling distance*
HRSC-A	*High Resolution Stereo Camera-Airborne*, Flugzeugscanner
HRSC-AX	*High Resolution Stereo Camera-Airborne Extended*, Flugzeugscanner
HS	Hyperspektral
FFH-RL	Flora-Fauna-Habitat-Richtlinie der Europäischen Union
IfSAR/InSAR	Interferometrisches *Synthetic Aperrure Radar*, Radar-Sensoren
IGM	*Image Geometry Model*, Geometriemodell zur Entzerrung von IKONOS-Daten
IHS	*Intensity, Hue, Saturation* (Intensität, Farbton, Sättigung), Farbsystem
IKONOS	Kommerzieller segr hoch auflösender Satellit des Betreibers Space Imaging (USA), griech. Bild
IMG	*Image*-Format, Rasterdatenformat von ERDAS IMAGINE
IMU	*Inertial Measurement Units,* Inertiale Messsysteme, zur Bestimmung von Geschwindigkeits- und Neigungsinformationen von Sensoren
InVeKoS	Integriertes Verwaltungs- und Kontrollsystem für Europäische Landwirtschaftsbeihilfen
IRS	*Indian Remote Sensing Satellite*, indischer Satellitensensor
ISODATA	*Iterative Self-Organizing Data Analysis Technique*, auf Clusterbildung basierendes Klassifikationsverfahren
JERS	*Japanese Earth Resources Satellite*, japanischer Satellitensensor
KH	*Keyhole*, amerikanische Spionagesatellitenserie
LAN	Abgeleitet von Landsat, ehemaliges Rasterdatenformat von ERDAS IMAGINE
LIDAR	*Light Detection and Ranging*, Radaraufnahmeverfahren
MD	*Minimum Distance*, pixelbasiertes Klassifikationsverfahren
ML	*Maximum Likelihood*, pixelbasiertes Klassifikationsverfahren
MOMS	*Modular Optoelectronic Multispectral Scanner*, Shuttle-getragener Sensor
MS	Multispektral
MTFC	*Modulation Transfer Function Compensation*, radiometrisches Korrekturverfahren für IKONOS-Daten
NDVI	*Normalized Difference Vegetation Index*, Vegetationsindex

NMAS	*National Map Accuracy Standard*, Genauigkeitsstandard für Karten
NIR	Nahes Infrarot
OK	Objektartenkatalog
OSA	*Optical Sensor Assembly*, Name des IKONOS-Sensors
Pan	Panchromatisch
PC	*Principal components*, Hauptkomponeten
PCI	PCI Geomatics, kanadischer Softwarehersteller (PCI Geomatica)
Pixel	Kurzwort aus *picture element*, Bildelement
RC 30	Reihenmesscamera, analoge Flugzeugkamera
RGB	Rot, Grün, Blau, additives Farbsystem
RMK	Reihenmesskamera, analoge Flugzeugkamera
RMSE	*Root Mean Square Error,* mittlerer Lagefehler für 66,6 % der Punkte
RPC	Rationale Polynomkoeffizienten, nötig zur Entzerrung von IKONOS-Daten
SAR	*Synthetic Aperture Radar*, aktive, radarbasierte Aufnahmesysteme
SPOT	*System Probatoire d'Observation de la Terre*, französischer Satelliten-sensor
SQL	*Structured Query Language*, strukturierte Abfragesprache für Datenbanken
SSE	*Sum of squared errors*
SRTM	*Shuttle Radar Topography Mission*, Shuttlemission zur Erfassung eines weltweiten Höhenmodells
S/W	Schwarz/Weiß- bzw. Grauwertbild
SWIR	*Short wave infrared*, kurzwelliges Infrarot
TDI	*Time Delay and Integration*, radiometrisches Korrekturverfahren von IKONOS-Daten
TK	Topographische Karte (TK10: Maßstab 1 : 10 000, TK25: 1 : 25 000)
TM	*Thematic Mapper*, Sensorsystem von Landsat-4
UNIX	Kurzwort aus *universal* und *exchange*, Betriebssystem
UTM	*Universal Transverse Mercator*, geographische Projektion
WGS84	World Geodetic System 1984, Referenzellipsoid
VHR	*Very high resolution*, Bezeichnung für sehr hoch auflösende Fernerkundungsdaten
VIS	*Visible*, sichtbares Lichtspektrum (führt zu Naturfarbabbildung)

Urheberrechtlich geschützte Bezeichnungen

Folgende im Text verwendeten Bezeichnungen von Firmen oder Produkten sind urheberrechtlich geschützt:

- *Definiens Imaging* und *eCognition* sind eingetragene Warenzeichen der Firma Definiens Imaging GmbH
- *DigitalGlobe* ist ein eingetragenes Warenzeichen der Firma DigitalGlobe, Inc.
- *ENVI* ist ein eingetragenes Warenzeichen der Firma Research Systems, Inc.
- *ERDAS, ERDAS IMAGINE* und *IMAGINE Expert Classifier* sind eingetragene Warenzeichen der Firma ERDAS, Inc.
- *ESRI, ArcView* und *ArcGIS* sind eingetragene Warenzeichen der Firma Environmental Systems Research Institute, Inc. (ESRI)
- *Feature Analyst* ist ein eingetragenes Warenzeichen der Firma Visual Learning Systems, Inc.
- *PCI Geomatics* und *Geomatica* sind eingetragene Warenzeichen der Firma PCI Geomatics
- *Microsoft Windows* ist ein eingetragenes Warenzeichen der Firma Microsoft Corporation
- *Space Imaging* ist ein eingetragenes Warenzeichen der Firma Space Imaging, Inc.

Weitere im Text verwendete Bezeichnungen können Warenzeichen anderer Firmen sein.

Zusammenfassung

Die Fernerkundung war in den vergangenen Jahren von einschneidenden Umbrüchen gekennzeichnet, die sich besonders in der stark gestiegenen geometrischen Bodenauflösung der Sensoren und den damit einhergehenden Veränderungen der Verarbeitungs- und Auswertungsverfahren widerspiegeln. Sehr hoch auflösende Satellitenbilddaten – definiert durch eine Auflösung zwischen einem halben und einem Meter – existieren seit dem Start von IKONOS Ende 1999. Etwa im selben Zeitraum wurden extrem hoch auflösende digitale Flugzeugkameras (0,1 bis 0,5 m) entwickelt. Dieser Arbeit liegen IKONOS-Daten mit einer Auflösung von einem (panchromatischer Kanal) bzw. vier Metern (Multispektraldaten) zugrunde.

Bedingt durch die Eigenschaften sehr hoch aufgelöster Bilddaten (z. B. Detailgehalt, starke spektrale Variabilität, Datenmenge) lassen sich bisher verfügbare Standardverfahren der Bildverarbeitung nur eingeschränkt anwenden. Die Ergebnisse der in dieser Arbeit getesteten Verfahren verdeutlichen, dass die Methoden- bzw. Softwareentwicklung mit den technischen Neuerungen nicht Schritt halten konnte. Einige Verfahren werden erst allmählich für sehr hoch auflösende Daten nutzbar (z. B. atmosphärisch-topographische Korrektur).

Die vorliegende Arbeit zeigt, dass Daten dieses Auflösungsbereiches mit bisher verwendeten pixelbasierten, statistischen Klassifikationsverfahren nur unzulänglich ausgewertet werden können. Die hier untersuchte Anwendung von Bildsegmentierungsmethoden hilft, die Nachteile pixelbasierter Verfahren zu überwinden. Dies wurde durch einen Vergleich pixel- und segmentbasierter Klassifikationsverfahren belegt. Im Rahmen einer Segmentierung werden homogene Bildbereiche zu Regionen verschmolzen, welche die Grundlage für die anschließende Klassifikation bilden. Hierzu stehen über die spektralen Eigenschaften hinaus Form-, Textur- und Kontextmerkmale zur Verfügung. In der verwendeten Software eCognition lassen sich diese Klassifikationsmerkmale zudem auf Grundlage des *fuzzy-logic*-Konzeptes in einer Wissensbasis (Entscheidungsbaum) umsetzen. Ein Vergleich verschiedener, derzeit verfügbarer Segmentierungsverfahren zeigt darüber hinaus, dass sich mit der genutzten Software eine hohe Segmentierungsqualität erzielen lässt.

Der wachsende Bedarf an aktuellen Geobasisdaten stellt für sehr hoch auflösende Fernerkundungsdaten eine wichtige Einsatzmöglichkeit dar. Durch eine gezielte Klassifikation der Bilddaten lassen sich Arbeitsgrundlagen für die hier betrachteten Anwendungsfelder Landschaftsplanung und Landschaftsökologie schaffen. Die dargestellten Beispiele von Landschaftsanalysen durch die segmentbasierte Auswertung von IKONOS-Daten zeigen, dass sich eine Klassifikationsgüte von 90 % und höher erreichen lässt. Zudem können die infolge der Segmentierung abgegrenzten Landschaftseinheiten eine Grundlage für die Berechnung von Landschaftsstrukturmaßen bilden.

Nationale Naturschutzziele sowie internationale Vereinbarungen zwingen darüber hinaus zur kontinuierlichen Erfassung des Landschaftsinventars und dessen Veränderungen. Fernerkundungsdaten können in diesem Bereich zur Etablierung automatisierter und operationell einsatzfähiger Verfahren beitragen. Das Beispiel Biotop- und Landnutzungskartierung zeigt, dass eine Erfassung von Landnutzungseinheiten mit hoher Qualität möglich ist. Bedingt durch das Auswertungsverfahren sowie die Dateneigenschaften entspricht die Güte der Ergebnisse noch nicht vollständig den Ansprüchen der Anwender, insbesondere hinsichtlich der erreichbaren Klassifikationstiefe. Die Qualität der Ergebnisse lässt sich durch die Nutzung von Zusatzdaten (z. B. GIS-Daten, Objekthöhenmodelle) künftig weiter steigern.

Insgesamt verdeutlicht die Arbeit den Trend zur sehr hoch auflösenden digitalen Erderkundung. Für eine breite Nutzung dieser Datenquellen ist die weitere Entwicklung automatisierter und operationell anwendbarer Verarbeitungs- und Analysemethoden unerlässlich.

Abstract

Evaluation, processing and segment-based analysis of very high resolution satellite imagery against the background of applications in landscape planning and landscape ecology

In recent years remote sensing has been characterised by dramatic changes. This is reflected especially by the highly increased geometrical resolution of imaging sensors and as a consequence thereof by the developments in processing and analysis methods. Very high resolution satellite imagery (VHR) – defined by a resolution between 0.5 and 1 m – exists since the start of IKONOS at the end of 1999. At about the same time extreme high resolution digital airborne sensors (0.1 till 0.5 m) have been developed. The basis of investigation for this dissertation is IKONOS imagery with a resolution of one meter (panchromatic) respectively four meters (multispectral).

Due to the characteristics of such high resolution data (e.g. level of detail, high spectral variability, amount of data) the use of previously available standard methods of image processing is limited. The results of the procedures tested within this work demonstrate that the development of methods and software was not able to keep up with the technical innovations. Some procedures are only gradually becoming suitable for VHR data (e.g. atmospheric-topographic correction).

Additionally, this work shows that VHR imagery can be analysed only inadequately using traditional pixel-based statistical classifiers. The herein researched application of image segmentation methods helps to overcome drawbacks of pixel-wise procedures. This is demonstrated by a comparison of pixel and segment-based classification. Within a segmentaion, homogeneous image areas are merged into regions which are the basis for the subsequent classification. For this purpose, in addition to spectral features also formal, textural and contextual properties are available. Furthermore, the applied software eCognition allows the definition of the features for classification based on fuzzy logic in a knowledge base (decision tree). An evaluation of different, currently available segmentation approaches illustrates that a high segmentation quality is achievable with the used software.

The increasing demand for geospatial base data offers an important field of application for VHR remote sensing data. With a targeted classification of the imagery the creation of working bases for the herein considered usage for landscape planning and landscape ecology is possible. The given examples of landscape analyses using a segment-based processsing of IKONOS data show an achievable classification accuracy of 90 % and more. The landscape units delineated by image segmentation could be used for the calculation of landscape metrics.

National aims of nature conservation as well as international agreements constrain a continuous survey of the landscape inventory and the monitoring of its changes. Remote sensing imagery can support the establishment of automated and operational methods in this field. The example of biotope and land use type mapping illustrates the possibility to detect land use units with a high precision. Depending on the analysis method and the data characteristics the quality of the results is not fully equivalent to the user's demands at the moment, especially concerning the achievable depth of classification. The quality of the results can be enhanced by using additional thematic data (e.g. GIS data, object elevation models).

To summarize this dissertation underlines the trend towards very high resolution digital earth observation. Thus, for a wide use of this kind of data it is essentially to further develop automated and operationally useable processing and analysis methods.

Teil I:
Einführung, Grundlagen und Stand der Wissenschaft

„Despite mapping being one of the most common applications of remote sensing, with a history expanding over several decades, we have not yet reached the stage at which accurate land cover maps can be derived from remotely sensed data on an operational basis.“

GILES M. FOODY (1997)

1 Einführung und Problemstellung

1.1 Einleitung – Fernerkundung als Zukunftstechnologie

Unter Fernerkundung versteht man die Gesamtheit der Methoden, die das kontaktlose wissenschaftliche Beobachten und Erkunden eines Gebietes aus der Ferne erlauben. Daneben sind das Kartieren und Interpretieren von Erscheinungen auf der Erdoberfläche oder auf der Oberfläche anderer Himmelskörper Hauptgegenstand dieser Wissenschaft. Sie ist ein modernes und komplexes Hilfsmittel, das eine multidisziplinäre Arbeitsweise erfordert (vgl. LÖFFLER 1994, LILLESAND & KIEFER 2000).

Mit den Methoden der Fernerkundung lassen sich vielfältige aktuelle Informationen über die Erdoberfläche sowie der Erdatmosphäre erfassen. Für etliche Bereiche ist diese Form der Datenerfassung heute schon ein wichtiges Instrument, wie zum Beispiel die Meteorologie, die Umweltforschung oder die Kartographie. Darüber hinaus liefert die Fernerkundung einen bedeutenden Beitrag zur Raumbeobachtung (Monitoring). Um das Informationspotenzial von Fernerkundungsdaten voll auszuschöpfen, müssen sie systematisch weiterverarbeitet und ausgewertet werden. Hierzu sind Kenntnisse über ihre Entstehung, ihrer geometrischen und physikalischen Eigenschaften sowie über Verarbeitungs- und Auswertungsmethoden unerlässlich (vgl. ALBERTZ 2001).

Die Erdbeobachtung ist aufgrund der Intensität, mit der der Mensch das Gesicht der Erde verändert, dringend erforderlich. Eine hohe geometrische Auflösung ist nötig, um großmaßstäbliche, räumlich genaue Daten zur Verfügung zu stellen, die den wachsenden Informationsbedarf der Wissensgesellschaft stillen (vgl. NEER 1999).

Raumbezogene Informationen sind die Grundlage für vielfältige Planungsaufgaben. Die dazu notwendigen aktuellen Informationen können oftmals durch die Auswertung von Fernerkundungsdaten bereitgestellt werden. Zur Reduktion des Zeit- und Kostenaufwandes sowie zur objektiveren Datenauswertung sind leistungsfähige, weitgehend automatisierte Verfahren nötig. Die Anwendung derartiger Verfahren auf sehr hoch auflösende Satellitenbilddaten – im Auflösungsbereich zwischen einem halben und einem Meter – wird in der vorliegenden Arbeit untersucht.

Fernerkundungsdaten sind heute schnell und operationell verfügbar. Sie besitzen somit eine hohe Aktualität. Die Erfassung erfolgt flächendeckend und grenzüberschreitend. Sie ist weitestgehend automatisiert und standardisiert, wodurch eine global vergleichbare Erfassung von Informationen gewährleistet ist (vgl. ALBERTZ 1991). Herkömmliche Verfahren zur Erhebung räumlicher Daten, wie die Vor-Ort-Vermessung, sind dagegen selbst im Zeitalter Globaler Positionierungssysteme (GPS) nur bestimmten, eher lokalen Arbeitsfeldern vorbehalten, da sie sehr zeitaufwändig und kostenintensiv sind. Dies trifft auch für die heute noch oft angewendete manuelle Kartierung anhand analoger Luftbilder zu – wobei immer der Anwendungszweck für die Wahl der Mittel ausschlaggebend ist.

Die Entwicklung der letzten Jahre im Bereich der Fernerkundung verlief äußerst dynamisch. So haben sich die verfügbaren Daten durch die Entwicklung der Sensortechnik qualitativ stark verbessert, und sehr hoch auflösende digitale Daten entsprechen gegenwärtig dem Stand der Technik. Aber auch die Methoden der Auswertung wurden – nicht zuletzt bedingt durch den technischen Fortschritt – enorm weiterentwickelt. Die Tendenzen hin zur automatisierten Auswertung werden immer deutlicher. Die digitale Bildverarbeitung ist im Begriff, die visuelle Bildinterpretation zu verdrängen, um die entstehenden Datenmengen zeitnah und im Rahmen einer digitalen Prozesskette verarbeiten zu können. Zudem wachsen verschiedene, bisher weitgehend getrennte Fach- und Arbeitsgebiete – die Fernerkundung, Geographische Informationssysteme (GIS) und die Photogrammetrie, aber auch Unterdisziplinen der Informatik, wie die Bildverarbeitung, die Bilderkennung und die künstliche Intelligenz – zunehmend zusammen und werden unter der Bezeichnung Geoinformatik integriert. So sind z. B. Fernerkundungsdaten inzwischen zu einem wichtigen Bestandteil von GIS geworden und Bildverarbeitungsmethoden werden über Fachgebietsgrenzen hinweg angewandt. Die einzelnen Bereiche ergänzen sich gegenseitig und nutzen vorhandene Daten sowie Methoden gemeinsam, wodurch vielfältige Synergien entstehen.

Insbesondere der Datenauswertung, d. h. der Inwertsetzung von Rohdaten auf Basis von Satellitenbildern, wird in der gegenwärtigen Forschung große Aufmerksamkeit geschenkt. Der Grund hierfür ist, dass die Entwicklung und Anwendung neuer, effektiverer und genauerer Technologien zur computergestützten Informationsgewinnung aus Fernerkundungsdaten erst begonnen hat. Immer öfter werden innovative Ansätze den bisher üblichen Standardverfahren der Fernerkundung vorgezogen. SCHNEIDER et al. (2000) und andere Autoren sprechen sogar von einem Paradigmenwechsel.

Ziel der Bilddatenauswertung ist die Ableitung von Informationen, zumeist zur Landbedeckung und -nutzung. Dazu wird die Komplexität der Fernerkundungsdaten reduziert und abstrahiert, indem der Bildinhalt durch eine Klassifikation thematisch eingeteilt wird. Diese aktuellen Landnutzungsinformationen finden häufig in GIS weitere Verwendung und können dort mit beliebigen raumbezogenen Daten kombiniert werden.

Ein großes Potenzial besitzen Fernerkundungsdaten für die Aktualisierung bestehender digitaler Datensätze, wie z. B. des Amtlichen Topographisch-Kartographischen Informationssystems (ATKIS) oder der Biotop- und Nutzungstypenkartierung (BNTK). Deren Aktualität ist aufgrund langer Fortschreibungsintervalle meist mangelhaft. Es müssen daher operationelle Auswertungs- und Aktualisierungsverfahren entwickelt werden, die schnell umsetzbar sind – die Erstellung der europaweiten Landnutzungsdatenbank CORINE Land Cover (CLC) Anfang der 90er Jahre dauerte beispielsweise sieben Jahre. Daneben sollen die Methoden preiswert und weitestgehend automatisiert sein. Eine Lösung dieses Problemkreises könnte die Fernerkundung bieten. Bisher wurde die geringe Auflösung von Fernerkundungsdaten immer als hinderlich angesehen, da Kleinstrukturen nicht erkennbar waren. Mit der neuen Generation sehr hoch auflösender Fernerkundungsdaten, wie den des IKONOS-Satelliten (IKONOS – griech. Bild), stehen Daten mit 1 m Bodenauflösung und geringer zur Verfügung. Damit können Maßstabsbereiche bis 1 : 10 000 erreicht werden. Weitere Datengrundlagen wie Flugzeug- oder Laserscanner bieten verbesserte Möglichkeiten. Aufgrund der hohen Auflösung und insbesondere den damit verbundenen Datenmengen sind neue Verfahren zur Auswertung dieser Daten erforderlich.

1.2 Hintergrund und Zielstellung der Arbeit

Die vorliegende Arbeit entstand zwischen Oktober 2000 und Februar 2005 am Leibniz-Institut für ökologische Raumentwicklung e. V. Dresden, Abteilung Zentrale Aufgaben und Geoinformation, Projektbereich GIS und Fernerkundung. Im Rahmen des von der Deutschen Forschungsgemeinschaft (DFG) geförderten Projektes „Nutzungsmöglichkeiten neuester, hoch auflösender Satellitenbilddaten für die Raumplanung“ (Me 1592/1-2) wurde ein Großteil der beschriebenen Ergebnisse gewonnen. Ziel dieses Projektes war es, Verarbeitungs- und Auswertungsverfahren zu erarbeiten und Nutzungsmöglichkeiten für die seit dem Jahr 2000 erhältlichen Fernerkundungsdaten der 1m-Generation in verschiedenen Planungsbereichen zu analysieren.

Vor diesem Hintergrund sollen in dieser Arbeit die Eigenschaften, Potenziale und Probleme neuer, sehr hoch auflösender Fernerkundungsdaten dargestellt und bewertet werden. Ein Schwerpunkt liegt in der Ermittlung, Anwendung und Bewertung geeigneter Methoden zur Vorverarbeitung von Satellitenbilddaten dieser Auflösungsstufe. Aufgrund der Dateneigenschaften ist die Anwendung herkömmlicher Verfahren hierbei oft nicht mehr zielführend.

Einen weiteren Fokus der Arbeit stellt die Anwendung von innovativen Methoden zur automatisierten Datenauswertung dar. Hierbei kommen neue Verfahren zum Einsatz – insbesondere die Bildsegmentierung und die *fuzzy-logic*-basierte Klassifikation –, die sich für sehr hoch auflösende Daten in besonderem Maße eignen. Ein Vergleich mit konventionellen, pixelbasierten Verfahren gibt Aufschluss über die Vorzüge der segmentbasierten Auswertung. Verschiedenartige derzeit verfügbare Programme zur Bildsegmentierung werden vorgestellt und deren Leistungsfähigkeit evaluiert.

Aufbauend auf den Erkenntnissen zur Vorverarbeitung und Auswertung sehr hoch auflösender Fernerkundungsdaten erfolgt die Darstellung der Anwendung von IKONOS-Daten und segmentbasierter Klassifikation für Zwecke der Landschaftsplanung und Landschaftsökologie. Der Schwerpunkt liegt hierbei auf der Erstellung von Landbedeckungs- bzw. -nutzungsklassifikationen sowie der Aktualisierung von Geobasisdaten. Durch die anwendungsorientierte Bearbeitung soll ein breiterer Einsatz der verwendeten Verfahren angeregt und ein Beitrag zur Operationalisierung von Fernerkundungsmethoden geleistet werden.

1.3 Aufbau der Arbeit

Die Arbeit gliedert sich in drei Teile. Teil I „Einführung, Grundlagen und Stand der Wissenschaft“ behandelt die zum Verständnis nötigen Grundlagen der Fernerkundung entsprechend dem aktuellen Stand der Forschung. In diesem Zusammenhang werden zunächst die gängigen sehr hoch auflösenden Fernerkundungssensoren in Systematiken eingeordnet, charakterisiert und deren zukünftige Entwicklung umrissen. Eine Beschreibung des Abbildungsverhaltens sehr hoch auflösender Fernerkundungsdaten und deren Auswirkungen auf die Bildklassifikation leiten zu einer ausführlichen Darstellung und Bewertung bestehender Auswertetechniken für Fernerkundungsdaten über. Dabei werden visuelle Interpretation, pixelbasierte und segmentbasierte Klassifikation sowie sonstige Verfahren betrachtet. Eine kurze Zusammenfassung derzeit bestehender grundsätzlicher Probleme der Fernerkundung leitet über zu Anwendungsaspekten sehr hoch auflösender Fernerkundungsdaten in der Landschaftsplanung und der Landschaftsökologie.

In Teil II „Datengrundlagen und Methodik“ erfolgt zunächst die ausführliche Beschreibung der verwendeten IKONOS-Daten. Dabei werden grundlegende Sensorinformationen gegeben, die Bildqualität bewertet sowie ein Vergleich zum klassischen Luftbild gezogen. Anschlie-

ßend werden die angewendeten Methoden der einzelnen Vorverarbeitungsschritte – geometrische Entzerrung (Orthorektifikation), atmosphärisch-topographische Korrektur sowie Bildfusion – dargestellt. Zumeist findet dabei eine Gegenüberstellung verfügbarer Verfahren statt. Darauf folgt eine umfassende Betrachtung segmentbasierter Auswertungsmethoden, wobei die verwendete Software eCognition charakterisiert und bewertet wird. In Ergänzung werden die Ergebnisse einer pixel- und einer segmentbasierten Klassifikation gegenübergestellt. Außerdem werden acht Segmentierungsprogramme anhand ihrer Abgrenzungsgüte auf Basis sehr hoch auflösender Bilddaten verglichen.

Die „Anwendung segmentbasierter Klassifikationsverfahren auf IKONOS-Daten“ wird im dritten Teil betrachtet. Dabei werden Anwendungserfahrungen der Landbedeckungs- bzw. -nutzungsklassifikation zum Zweck der Landschaftsanalyse unterschiedlicher Testgebiete mit der Software eCognition dargestellt. Daneben werden die Möglichkeiten zur Berechnung von Landschaftsstrukturmaßen anhand aus der Segmentierung resultierender Polygongeometrien diskutiert. Anschließend erfolgt die Darstellung der speziellen Anwendung zur Biotop- und Nutzungstypenklassifikation. Die Arbeit endet mit zusammenfassenden Schlussfolgerungen und der Formulierung offener Forschungsfragen.

„Die Komplexität der Wirklichkeit wird zu einem Problem."

ANDREA HOFFMANN, JAN WILHELM VAN DER VEGT, FRANK LEHMANN (2000)

2 Grundlagen und Stand der Forschung: Vom Pixel zum Vektor oder von der Fernerkundung zum GIS-Datensatz

Waren noch vor wenigen Jahren gedruckte topographische Karten und analoge Luftbilder Grundlage verschiedener Planungen, so sind dies heute in zunehmendem Umfang digitale Geobasisdaten. Automatisierte Liegenschaftskarten (ALK), ATKIS-Daten sowie Biotop- und Nutzungstypenkartierungen stehen bereits nahezu flächendeckend landes- bzw. bundesweit digital zur Verfügung. Weitere digitale Datengrundlagen befinden sich im Aufbau, wie die Digitale Topographische Karte (DTK) als Fortführung der bisherigen Deutschen Grundkarte (DGK), und werden somit den vielgestaltigen Einsatz digitaler Daten in GIS oder CAD-Systemen *(Computer Aided Design)* intensivieren.

Fernerkundungsdaten werden immer mehr zu einer wichtigen Grundlage von Geoinformationssystemen. Infolge der fortschreitenden Verschmelzung von Fernerkundung und GIS ist eine integrative Nutzung zunehmend möglich. Die Bilddaten können in georeferenzierter Form als Hintergrund für beliebige Überlagerungen dienen oder in Kombination mit Höhenmodellen zur 3D-Visualisierung genutzt werden. Wichtiger ist jedoch die Nutzung von GIS-Informationen, welche sich aus Fernerkundungsdaten ableiten lassen, wie z. B. aktuelle Landbedeckungs- und Landnutzungsklassifikationen.

Die heute verfügbaren sehr hoch auflösenden Fernerkundungsdaten besitzen ein erhebliches Potenzial zur vereinfachten Erfassung von Geobasisdaten sowie zu deren Aktualisierung. Allerdings bestehen in diesem Zusammenhang noch beträchtliche methodische Probleme, um derartige Verfahren für die Praxisreife zu operationalisieren. Schwierigkeiten bereiten besonders die Auswertungsverfahren von Fernerkundungsdaten. Hier sind effiziente automatisierte Verfahren notwendig, um den Informationsgehalt der Bilddaten mit hoher Genauigkeit extrahieren zu können. Andererseits müssen die Interpretations- bzw. Klassifikationsergebnisse der Rasterdaten in ein Vektordatenformat umgewandelt werden, damit sie eine große Akzeptanz auf GIS-Nutzerseite erlangen. Trotz integrativer Systeme bestehen hierbei grundsätzliche Mängel.

2.1 Sehr hoch auflösende Fernerkundungssysteme

Namensgebend für derartige Systeme ist die erzielbare Bodenauflösung der Bilddaten, gemessen als GIFOV *(ground instantaneous field of view)*. Als sehr hoch auflösend *(very high resolution,* VHR) wurden bisher solche mit einer Bodenauflösung von unter 10 m aufgefasst (vgl. z. B. WILKINSON 1999). Mit der fortschreitenden Entwicklung ist diese Einteilung nicht mehr zeitgemäß. Vielfältige weitere Einteilungen sind in der Literatur beschrieben, aber entsprechen nicht dem derzeitigen Sprachgebrauch. Deshalb wird im Rahmen dieser Arbeit eine durch NEER (1999) aufgestellte Einteilung verwendet (vgl. auch MÖLLER 2002; BLASCHKE 2002), wonach geometrische Auflösungen zwischen einem halben und einem Meter als sehr hoch auflösend zu verstehen sind. Gröbere Auflösungen (ein bis vier Meter) werden als hoch auflösend bezeichnet, feiner aufgelöste Daten (0,1 bis 0,5 m) als extrem hoch auflösend (vgl. Tabelle 2.1). EHLERS (2002) verwendet eine ähnliche, jedoch leicht modifizierte Einteilung.

Tab. 2.1: Einteilung von Fernerkundungsdaten nach ihrer räumlichen Bodenauflösung. (Quellen: NEER 1999; MÖLLER 2002, verändert)

Räumliche Bodenauflösung [m]	Bezeichnung	Beispiele für Datenquellen
0,1 - 0,5	Extrem hoch auflösend	HRSC-A, ADS 40
0,5 - 1	Sehr hoch auflösend	IKONOS (Pan), QuickBird (Pan)
1 - 4	Hoch auflösend	IKONOS (MS), QuickBird (MS)
4 - 12	Mittel auflösend	IRS (Pan)
12 - 50	Gering auflösend	IRS (MS), Landsat-7 ETM
50 - 250	Sehr gering auflösend	Landsat MSS
> 250	Extrem gering auflösend	NOAH, Meteosat

2.1.1 Einordnung in Systematiken von Fernerkundungsdaten

Die Einordnung und damit die Systematisierung von Fernerkundungsdaten kann nach verschiedenen Merkmalen erfolgen. Einzelne Taxonomien werden selbst in einigen Lehrbüchern unterschiedlich gehandhabt. Eine Übersicht der verschiedenen Einteilungsmöglichkeiten neben der räumlichen Bodenauflösung gibt Tabelle 2.2.

Gegenstand dieser Arbeit sind passiv-optische Systeme. Diese messen Reflektionswerte der elektromagnetischen Strahlung der Erdoberfläche. Entsprechend den Spektralbereichen (Kanälen, Bändern) kann so z. B. die Rückstrahlung des sichtbaren Lichtes (RGB-Farbraum – Rot, Grün, Blau bzw. *VIS, visible)* aufgezeichnet werden. Im Gegensatz dazu messen aktive Systeme Laufzeiten oder die Phase und Polarisation des gesendeten Laser- oder Radarsignals. Die Datenaufnahme erfolgt heute zumeist digital. Der Vorteil digitaler Aufnahmemedien liegt in ihrem maschinenlesbaren Datenformat. Analoge Systeme hingegen sind ungünstig für eine nachfolgende computergestützte Auswertung.

Abbildung 2.1 zeigt die Einordnung sehr hoch auflösender Fernerkundungssysteme als optische, digitale Systeme, welche auf Basis von CCD-Scannern *(Charged Coupled Device)* arbeiten. Diese Scanner wandeln Licht in elektrische Ladung um und werden z. B. in Digitalkameras oder digitalen Camcordern eingesetzt. Neben den sehr hoch auflösenden Satellitensensoren nutzen die hier nicht näher betrachteten flugzeugbasierten Systeme häufig diese Technologie in Form von Zeilen- oder Matrix-CCD's.

2.1.2 Entwicklung und Eigenschaften sehr hoch auflösender Fernerkundungssensoren

Die Entwicklung von sehr hoch auflösenden Satellitensensoren war maßgeblich eine Folge von US-amerikanischen Regierungsbeschlüssen zur Freigabe der Satellitenfernerkundung

Tab. 2.2: Taxonomien von Fernerkundungsdaten. (Quelle: EHLERS 2002, verändert)

Aufnahmeplattform	Satellit/Shuttle		Flugzeug/Ballon (bemannt/unbemannt)	Stationär
Aufnahmemodus	Passiv (Elektrooptisch, Thermales Infrarot, Thermale Mikrowellenstrahlung)		Aktiv (Laser, Radar)	
Aufnahmemedium	Analog (Camera, Video)		Digital (Whiskbroom, Pushbroom (CCD Line Array bzw. Frame Camera))	
Spektralbereiche	Sichtbar/Ultraviolett	Reflektiertes Infrarot	Thermales Infrarot	Mikrowellenstrahlung
Spektrale Auflösung	Panchromatisch, Pan (1 Band)	Multispektral, MS (2 - 20 Bänder)	Hyperspektral (20 - 250 Bänder)	Ultraspektral (> 250 Bänder)
Radiometrische Auflösung	Sehr hoch (> 12 Bit)	Hoch (8 - 12 Bit)	Mittel (6 - 8 Bit)	Gering (< 6 Bit)

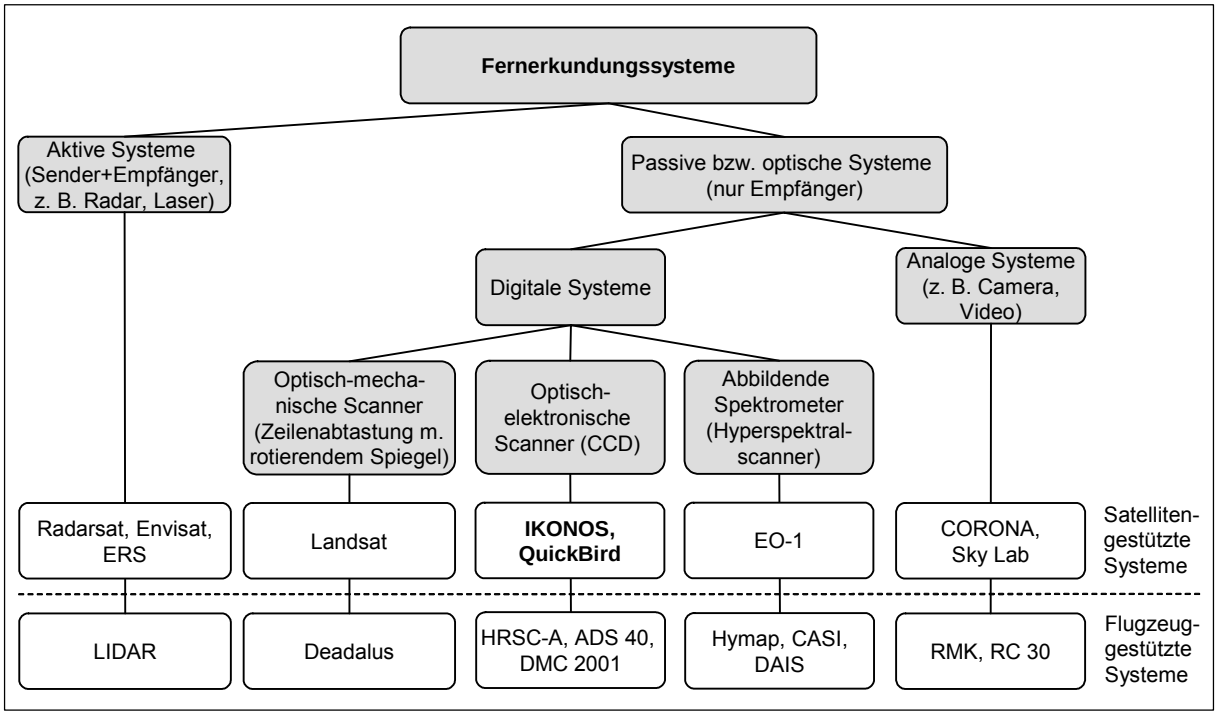

Abb. 2.1: Einteilung ausgewählter aktueller Fernerkundungssysteme nach den in Tabelle 2.2 genannten Kriterien Aufnahmemodus, -medium und -plattform.
(Quelle: Eigene Darstellung)

für private Firmen im Jahr 1992 (vgl. TRIPP 1995). Bis zu diesem Zeitpunkt war die Aufnahme solcher Daten Regierungsorganisationen – insbesondere dem Militär – vorbehalten. Den ersten kommerziellen Satelliten OrbView-1 beförderte Orbimage (USA) 1995 ins All. Durch die Freigabe von Bilddaten mit 1 m (1994) sowie 0,5 m Auflösung (2000) gab die US-Regierung der Entwicklung weiteren Anstoß (vgl. FRITZ 1999; PETRIE 2002).

Sehr hoch auflösende Satellitensensoren wurden bereits für Mitte der 90er Jahre angekündigt. Die Verfügbarkeit verzögerte sich jedoch aufgrund erheblicher technischer Schwierigkeiten und des Verlustes mehrerer Satelliten (z. B. EarlyBird1, IKONOS1, QuickBird1). Ende 1999 fand mit IKONOS2 (Space Imaging, USA, maximale Bodenauflösung 0,82 m) der erste erfolgreiche Start statt, Ende 2002 folgte QuickBird2 (DigitalGlobe, USA, 0,61 m). Der im Dezember 2000 erfolgreich gestartete Satellit EROS A (ImageSat International, Israel) kann lediglich hoch auflösende panchromatische Daten aufzeichnen (1,8 m). Die Auflösung von 2,5 m des SPOT-5-Sensors (Spot Image, Frankreich) wird nur durch die Überlagerung zweier panchromatischer Sensoren mit jeweils 5 m erreicht *(Supermode)*.

Weitere Satelliten setzen diese Aufzählung fort. Tabelle 2.3 zeigt eine Übersicht derzeitig existierender und in naher Zukunft geplanter Satelliten, welche hoch bzw. sehr hoch aufgelöste Daten liefern. Dadurch wird die zunehmende Relevanz dieser Daten für vielfältige Anwendungsgebiete deutlich. Für 2007 kündigte ORBIMAGE (2004) den Start von OrbView-5 mit einer Bodenauflösung von 0,41 m an, weitere Anbieter entwickeln mit IKONOS3 (Space Imaging) oder WorldView II (DigitalGlobe) vergleichbare Sensoren.

Die Auflösung optischer Sensoren wurde seit dem Start von ERTS 1 (79 m) im Jahr 1972 (1995 in Landsat-1 umbenannt) bis heute mit QuickBird2 (0,61 m) um mehr als den Faktor 100 verbessert (vgl. Abbildung 2.2). Die Entwicklung der letzten Jahrzehnte lässt einen deut lichen Trend zu einer verbesserten Auflösung erkennen (vgl. Abb. 2.3). Die Verbesserung der Auflösung war dabei ein fortwährender Wunsch der Datennutzer. Die Auswirkungen dieser Entwicklung auf die Datenauswertung werden im Abschnitt 2.1.3 diskutiert.

Tab. 2.3: Existierende und in naher Zukunft geplante, zivile, hoch bzw. sehr hoch auflösende optische Satellitensysteme in chronologischer Reihenfolge nach deren Starttermin (Informationen zu geplanten Satellitenmissionen sind vorläufige Angaben).
(Quellen: Eigene Darstellung, Internetseiten der Betreiber)

Satellit – Betreiber	Starttermin (geplant)	Sensoren	Bodenauflösung (Nadir) [m]	Schwenkbar quer zur / in Flugrichtung	Radiometrische Auflösung [Bit]	Streifenbreite [km]
IKONOS2 – Space Imaging (USA)	24.09.1999	Pan MS (RGB, NIR)	0,82 3,2	Ja / Ja	11	11,3
EROS A1 – ImageSat International (Israel)	05.12.2000	Pan	1,8	Ja / Nein	11	13,5
QuickBird2 – DigitalGlobe (USA)	18.10.2001	Pan MS (RGB, NIR)	0,61 2,44	Ja / Ja	11	16,5
SPOT 5 – Spot Image (Frankreich)	04.05.2002	Pan MS (R, G, NIR) SWIR	2,5/5,0 10,0 20,0	Ja / Ja	8	60
OrbView-3 – ORBIMAGE (USA)	26.06.2003	Pan MS (RGB, NIR)	1,0 4,0	Ja / Ja	11	8
FORMOSAT-2 – National Space Program Office (Taiwan)	21.05.2004	Pan MS (RGB, NIR)	2,0 8,0	K. A.	12	24
ALOS – National Space Development Agency (Japan)	24.01.2006	Pan MS (RGB, NIR)[1]	2,5 10,0	Ja (MS) / Ja (Pan)	8	70
CARTOSAT1 – Indian Space Research Organization	05.05.2005	2 x Pan	2,5	Ja / Nein	10	30
TopSat – British National Space Centre (UK)	27.10.2005	Pan MS	2,8 5,6	K. A.	K. A.	25
CARTOSAT2 – Indian Space Research Organization	(2006)	Pan MS	1,0 2,5	Ja / Ja	K. A.	10
EROS B1 - B6 – ImageSat International (Israel)	(2006)	Pan MS (RGB, NIR)	0,87 3,48	K. A.	10	13
IKONOS3 – Space Imaging (USA)	(2006)	Pan MS (RGB, NIR)	0,5 2,0	K. A.	K. A.	20
KOMPSAT-2 – Korea Aerospace Research Institute	(2006)	Pan MS	1,0 4,0	Ja / Nein	8	15
RazakSat – Astronautic Technology (Malaysia)	(2006)	Pan MS (RGB, NIR)	2,5 5,0	K. A.	> 8	20
RESURS-DK – Sovinformsputnik (RUS)	(2006)	Pan MS (RGB)	1,0 2,0 - 3,0	Ja / Nein	K. A.	28,3
WorldView I – DigitalGlobe (USA)	(2006)	Pan	0,45	Ja / K. A.	11	16
COSMO Skymed – Italian Space Agency	(2007)	Pan, MS, HS[1]	K. A.	K. A.	K. A.	K. A.
OrbView-5 – ORBIMAGE (USA)	(2007)	Pan MS (RGB, NIR)	0,41 1,64	Ja / K. A.	11	15,2
Pleiades – Centre National d'Etudes Spatiales (Frankreich)	(2008)	Pan MS (RGB, NIR)	0,7 2,8	Ja / Ja	10	20
WorldView II – DigitalGlobe (USA)	(2008)	Pan MS (RGB, NIR)[2]	0,46 1,8	Ja / K. A.	11	16,4

[1] Zusätzlich Radarsensoren. [2] Zusätzlich vier weitere Spektralkanäle.

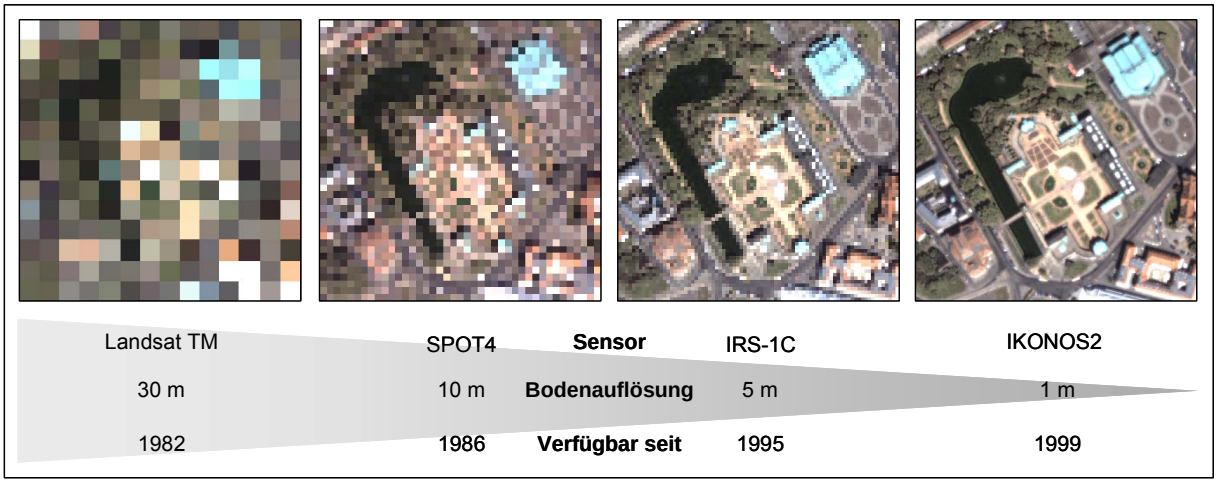

Abb. 2.2: Entwicklung der Bodenauflösung ausgewählter Fernerkundungssensoren.
(Quelle: Eigene Darstellung, IKONOS-Daten: © Space Imaging, weitere Daten simuliert)

Dennoch herrscht eine große Diskrepanz zwischen militärischen Systemen (z. B. amerikanische Spionagesatelliten; sog. *spy satellites)*, die durch Steuergelder finanziert werden und deren Daten Endverbrauchern unzugänglich bleiben, sowie dem hohen Preis für Daten kommerzieller Erderkundungssysteme. Nach Angaben der FEDERATION OF AMERICAN SCIENTISTS (2002) besitzen das US-Militär bzw. die US-Geheimdienste Satellitensensoren mit bis zu 10 cm Bodenauflösung (sog. *Keyhole-Serie,* KH) sowie digitale Flugzeugkameras (bzw. Drohnen) mit bis zu 3 cm Bodenauflösung. Infolge fehlender Investitionsmöglichkeiten und des Alters der bestehenden Sensoren – die Starts der aktuellen KH 11/12 erfolgten 1995, 1996 und 2000 –, werden zunehmend kommerziell verfügbare Bildprodukte genutzt und finanzintensive Förderverträge mit den Betreibern geschlossen.

Hoch auflösende Fernerkundungssysteme zeichnen sich neben ihrer hohen Bodenauflösung durch eine hohe radiometrische Auflösung (Farbtiefe) aus. Die höhere Zahl der Grauwerte (derzeit meist 11 Bit) ist wertvoll für eine genauere Auswertung. Nachteilig wirkt sich der Zusammenhang zwischen steigender Auflösung und sinkender Streifenbreite *(Swath)* aus. So hat z. B. Landsat-7 bei einer Auflösung von 15 m eine Streifenbreite von 185 km, IKONOS2 (0,82 m) lediglich 11,3 km. Durch die steigende Bodenauflösung infolge einer

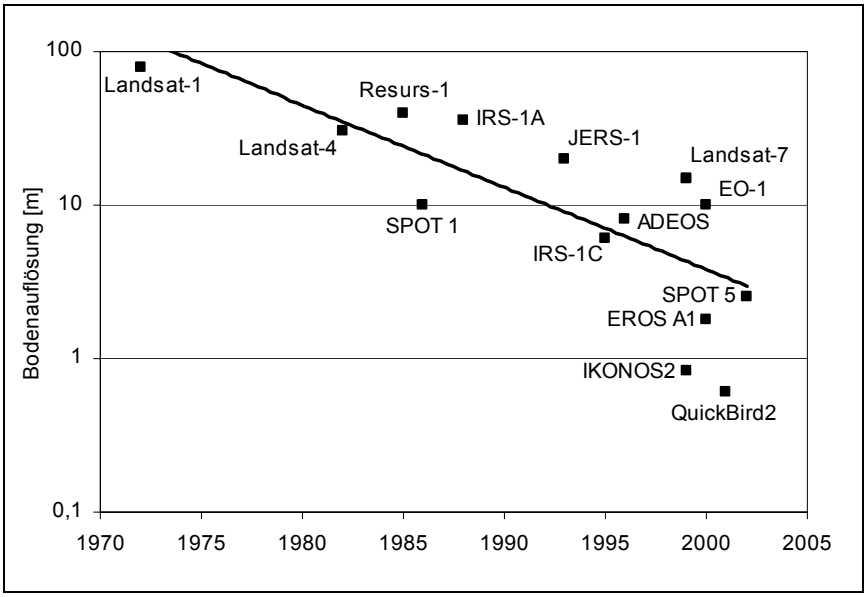

Abb. 2.3: Entwicklungstrend (Trendlinie) der Bodenauflösung ziviler Erdbeobachtungssatelliten.
(Quelle: Eigene Darstellung)

besseren Optik oder eines erdnäheren Orbits können bei begrenzter Anzahl von CCD-Zeilen (derzeit max. ca. 13 000, vgl. PETIRE 2002) nur Daten immer kleinerer Gebiete aufgezeichnet werden. Eine großflächigere Aufnahme wird zudem durch die derzeit mögliche Datenübertragungskapazität limitiert. Damit besteht der bisherige Vorteil der Fernerkundung – eine große Flächendeckung zu bieten – nur noch eingeschränkt.

Daneben geht die bessere räumliche Auflösung zulasten einer geringeren zeitlichen Auflösung (Wiederholrate). Dieser Effekt wird zumeist durch schwenkbare Sensoren kompensiert, die wiederum die Auflösung negativ beeinflussen und zu Aufnahmen mit Schrägblick führen. Dennoch sind dadurch Wiederholraten von ein bis zwei Tagen möglich. Ein erheblicher Zusatznutzen entsteht durch die Möglichkeit, Stereo-Bilddaten aufzunehmen, um z. B. gleichzeitig Höhenmodelle abzuleiten. Viele der neuen Satelliten bieten diese Funktionalität durch schwenkbare Sensoren quer zur oder in Flugrichtung *(across* bzw. *along track)*.

Zwischen der räumlichen Auflösung und den Kosten für VHR-Satellitenbilddaten besteht ein deutlicher proportionaler Zusammenhang. So betragen die Kosten für IKONOS-Daten derzeit 27,50 US$/km², für QuickBird-Daten 29,75 US$/km² (jeweils preiswerteste Produktstufe, Pan- und MS-Daten; vgl. EUROPEAN SPACE IMAGING 2004; EURIMAGE 2004). Für Aufnahmen von Landsat-7 ETM fallen dagegen lediglich Kosten von ca. 0,06 US$/km² an (vgl. ebd.). Interessant sind daher die Entwicklungen unter zunehmender Konkurrenz auf Anbieterseite sowie das Auftreten nichtkommerzieller Betreiber, wie etwa des geplanten koreanischen Satelliten KOMPSAT-2. Enttäuschend ist indes, dass bei den kommerziellen Aufnahmen trotz des hohen Preises eine Bewölkung von bis zu 20 % akzeptiert werden muss, für geringere Bewölkungsanteile fallen Mehrkosten an.

Wie Abbildung 2.4 zeigt, besitzen die VHR-Daten eine ähnliche spektrale Auflösung wie die seit langem verfügbaren Landsat-Daten. Dies ist eine Folge des sinnvoll nutzbaren Spektrums, aber auch im Sinne der Vergleichbarkeit zweckmäßig.

Um die Transport- und damit die Missionskosten künftiger Satelliten zu senken, werden zunehmend Mikro- (bis 100 kg), Mini- (bis 500 kg) und Kleinsatelliten (bis 1 t) eingesetzt. Sie besitzen nur eine kurze Lebensdauer, da sie nur sehr wenig oder keinen Treibstoff an Bord haben, um sich in der Umlaufbahn zu halten. Ein Beispiel hierfür ist der 2005 gestartete britische Satellit TopSat mit einem Gewicht von 120 kg.

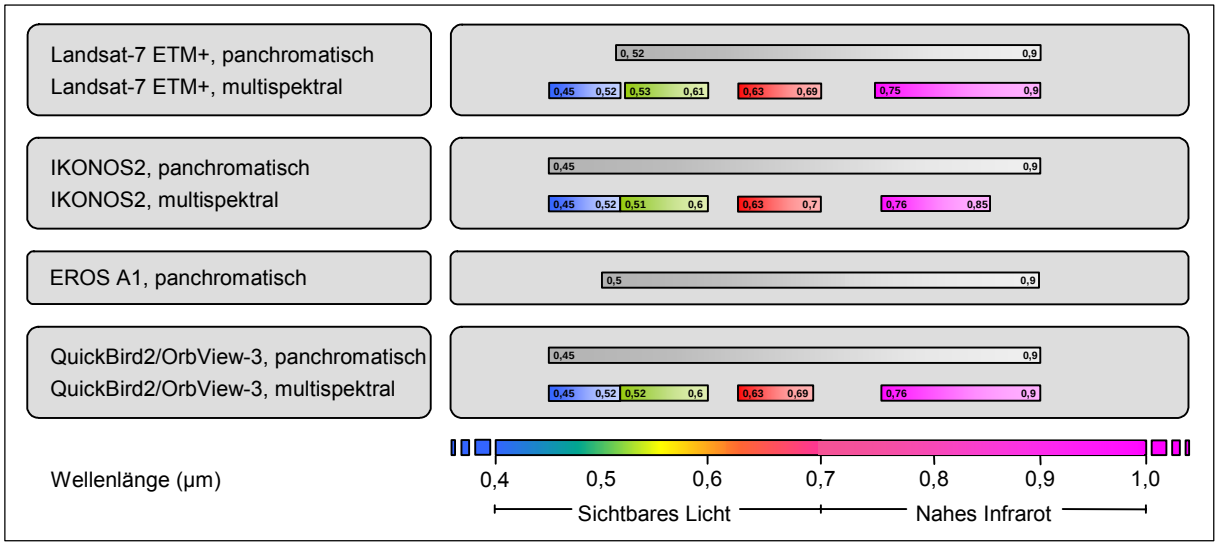

Abb. 2.4: Spektrale Auflösung derzeit verfügbarer sehr hoch auflösender Satellitensensoren im Vergleich zu Landsat-7 ETM+ (besitzt drei weitere Spektralkanäle; spektrale Eigenschaften von OrbView-3 identisch mit QuickBird).
(Quelle: Eigene Darstellung)

Auch Radarsatelliten zeichnen immer höher auflösende Daten auf. Für 2006 (TerraSAR) bzw. 2007 (Cosmo Skymed) geplante Sensoren sollen eine Auflösung von 1 m haben. Ähnliche Entwicklungen sind für hyperspektrale Sensoren zu erwarten. Die erste Mission eines sehr hoch auflösenden Hyperspektralsatelliten (OrbView-4) scheiterte jedoch 2002.

Die in dieser Arbeit verwendeten IKONOS-Satellitenbilddaten werden in Abschnitt 3.1.1 ausführlich charakterisiert. Die beachtlichen Entwicklungen flugzeuggetragener Systeme werden nur am Rande betrachtet (siehe Abschnitt 3.1.3). EHLERS, SCHIEWE & MÖLLER (2003) geben einen Überblick über diese Gruppe von Sensoren, die Bilddaten ebenfalls digital aufzeichnet.

2.1.3 Auswirkungen der sehr hohen geometrischen Auflösung auf die Bildklassifikation

Sehr hoch auflösende Satellitenbilddaten sind ideal für vielfältige Aufgaben der Fernerkundung. Sie sind detailliert genug, um die Flächenbedeckung bzw. -nutzung bis hin zu einzelnen Gebäuden abzubilden. Im Gegensatz zu Luftbildern sind sie gleichzeitig grob genug, um nicht zu viele, sich störend auf den Analyseprozess auswirkende Details zu beinhalten. Mit der Entwicklung der geometrisch sehr hoch auflösenden Satellitenbilddaten haben sich jedoch einige Umgebungsvariablen verändert, die sich insbesondere auf die digitale Bildverarbeitung bzw. -auswertung auswirken. Einige Punkte werden im Folgenden dargestellt.

WILKINSON (1999) nennt folgende Voraussetzungen, um Techniken des maschinellen Sehens erfolgreich anwenden zu können:

- ein eng umgrenztes Anwendungsgebiet,
- konsistente Aufnahmebedingungen,
- eine limitierte Anzahl der zu erkennenden Objekte,
- keine signifikanten Variationen der Objekte,
- eine relativ einfache Modellierbarkeit der Objekte.

Die in sehr hoch auflösenden Fernerkundungsdaten abgebildeten Objekte erfüllen diese Voraussetzungen nur eingeschränkt. Es handelt sich zumeist um großräumige Untersuchungen (gesamte Szene). Zudem sind die spektralen Objekteigenschaften für die Gesamtszene (z. B. infolge Sonneneinstrahlung) häufig variabel. Objekte erscheinen durch den abgebildeten Detailreichtum (z. B. Wachstums-, Vitalitäts- bzw. Feuchtigkeitsunterschiede innerhalb von Äckern) sowie die nicht relevanten Objektabbildungen (z. B. Fahrzeuge auf Straßen, Vieh auf der Weide) nicht homogen. Die Objekte weisen oft komplexe Grenzen auf und sind infolgedessen nicht einfach modellierbar. Hinzu kommen Probleme durch das Auftreten von Unschärfe, geringem Kontrast zwischen den Bildobjekten sowie Schattierung *(Shading)*. Zudem ist aufgrund der Datenmenge derzeit keine Echtzeitverarbeitung möglich. Der Anwendung maschineller Erkennungsverfahren stehen somit – insbesondere bei der Auswertung sehr hoch auflösender Fernerkundungsdaten – einige Probleme gegenüber.

Das Abbildungsverhalten der neuen 1m-Sensoren gegenüber den bisher gebräuchlichen Bilddaten (z. B. Landsat) hat sich grundlegend gewandelt. Mischpixel (sog. *Mixel)* waren bisher ein allgegenwärtiges Auswertungsproblem, da bei geringer Auflösung ein Pixel häufig mehrere Klassen repräsentiert. Um diesen Nachteil auszugleichen, wurden eigens komplexe Subpixelklassifizierungsalgorithmen entwickelt.

Das Mischpixelproblem tritt auch bei hohen Auflösungen auf, nur sind die Dimensionen dieses Problems andere: *„Einzelne Pixel stellen nicht mehr eine Mischung unterschiedlicher Objekte dar, sondern bilden vielmehr Teile eines einzigen Objektes“* ab (HESE 2001: 2). WOODCOCK & STRAHLER (1987) stellten in diesem Zusammenhang dar, dass konventionelle pixelbasierte Ansätze zur Landnutzungsklassifizierung räumlich hoch auflösender Daten

unbrauchbar sind, wenn der beobachtete und aufgezeichnete Maßstab der Daten größer ist, als der Maßstab der zu erfassenden Landnutzung (vgl. HOFFMANN 2001). So könnte beispielsweise bei einer Auflösung von 30 m innerhalb eines Pixels eine Wiesenfläche mit Baumbestand, Schatten und angrenzender Straße abgebildet werden. Bei einer Auflösung von 1 m bildet ein Pixel dagegen evtl. eine Grasfläche mit gelben Blumen und einem Maulwurfshügel ab. Dieses Beispiel verdeutlicht die geringere Relevanz des Mischpixelproblems bei hoher Auflösung.

Eine ähnliche Darstellung gibt DE KOK (2001). Demnach wird ein Waldbestand mit einer Größe von zwei Hektar in einer Landsat-Aufnahme mit 30 m Bodenauflösung durch 22 Pixel abgebildet. Im Falle eines IKONOS-Datensatzes mit 1 m Auflösung wird dieser Waldbestand durch 20 000 Pixel dargestellt. DE KOK (2001) argumentiert weiter, dass eine pixelweise Klassifizierung nicht mehr anwendbar ist, um den interessierenden Waldbestand aus den sehr hoch auflösenden Bilddaten abzuleiten. Das Interessensobjekt wurde in seine Strukturelemente aufgelöst und ist allein aufgrund spektraler Merkmale nicht mehr identifizierbar. „*Dieser Sachverhalt wurde von FEHLERT (1985) theoretisch und von KENNEWEG et al. (1991) praktisch anhand von Daedalus-ATM-Datensätzen nachgewiesen*“ (DE KOK 2001: 21). Zur Klassifikation sehr hoch auflösender Luftbilddaten plädierte GOUGEON (1995) daher für eine stärker objektbasierte Auswertung anstelle einer Verarbeitung der Spektralwerte einzelner Pixel unabhängig von deren Lage im Bild. Er schlägt ein wissensbasiertes System auf Basis mehrerer Merkmale (neben der Spektralsignatur Textur, Struktur, Kontext) zur Klassifikation vor. Auch BLASCHKE (2003) argumentierte, dass einzelne Pixel kaum wichtige Informationen zur Interpretation von Bilddaten enthalten. Erst die Betrachtung von Pixelgruppen (sog. *meaningful objects)* und ihrer Eigenschaften sowie wechselseitigen Relationen ermöglicht eine genaue Bildinterpretation.

Der oben genannte Auflösungsvergleich (vgl. auch Abb. 2.2) belegt darüber hinaus das stark gestiegene Datenvolumen, welches durch die Auswertungsprogramme bewältigt werden muss. Zwischen dem Landsat-Aufnahmesystem und IKONOS hat sich die Pixelzahl zur Abbildung derselben Fläche um den Faktor 900 erhöht. Zusätzlich wird die Datenmenge durch die höhere radiometrische Auflösung gesteigert, wodurch aber Grauwertunterschiede deutlicher differenziert werden können.

Dennoch existieren häufig spektrale Übereinstimmungen zwischen verschiedenen Objekten *(spectral confusion* – Mehrdeutigkeit spektraler Informationen). So lassen sich Straßen teilweise nicht spektral von Gebäuden trennen (siehe Abb. 2.5a). Hierzu sind zusätzliche Merkmale, wie Form oder Nachbarschaft notwendig, die herkömmliche Auswertungsverfahren nicht bieten.

Die vom Datenanbieter als *ground sampling distance* (GSD) angegebene Auflösung von z. B. einem Meter verleitet dazu anzunehmen, dass Objekte mit einem Durchmesser von einem Meter erkennbar sind. Im Unterschied zur *ground resolved distance* (GRD), die bei analogen Luftbildern die tatsächlich erfassbare Mindestgröße von Objekten angibt, ist die GSD etwa um den Faktor zwei größer (THEOBALD 1998). Demnach wären Objekte erst ab einer Ausdehnung von zwei Metern auf einem 1m-Bild sicher erkennbar. Als Grund wird die Einteilung der Realität in ein Raster angegeben. KRAUS & SCHNEIDER (1988) beschreiben das geometrische Auflösungsvermögen dagegen mit der Kontrastübertragungsfunktion *(modulation transfer function,* MTF).

Jedoch können auch andere Effekte auftreten, wie z. B. Überstrahlung, wenn sich Objekte gut von ihrer Umgebung abheben. Die in einem Bild mit einem Meter Bodenauflösung erkennbaren weißen Linien eines Fußballfeldes verdeutlichen diesen Umstand. Sie haben lediglich eine Breite von 12 cm, füllen jedoch ganze Pixel. Derartige Phänomene können ebenfalls mit der MTF beschrieben werden: Innerhalb eines Pixels wird die reflektierte

Abb. 2.5: Beispiele aus IKONOS-Daten für mangelhafte spektrale Unterscheidbarkeit (a – Ähnlichkeit zwischen Gebäuden und Straßen), spektrale Variabilität (b – Getreidefeld mit unterschiedlichen Reifestadien) sowie die Bildauswertung störende Details (c – Fahrzeuge auf der Autobahn).
(Quelle: Eigene Darstellung, © Space Imaging)

Strahlung gemittelt, was infolge der Veränderung der Wellenlänge auch zu einer Kontraständerung und damit zur Dämpfung, Erhöhung oder Auslöschung eines Signals führen kann (KRAUS & SCHNEIDER 1988). Auch TOWNSHEND et al. (2000) legen dar, dass ein substanzieller Anteil des Grauwertes, den ein Pixel repräsentiert, von dessen Umgebung beeinflusst wird. Die Gründe dafür sind multifaktoriell und liegen unter anderem in der Optik des Sensors, im Objektkontrast sowie in atmosphärischen Effekten (Streulicht). Aus diesen Gründen plädieren die Autoren gegen eine Anwendung pixelbasierter Auswertungsverfahren.

Der bedeutendste Grund für die eingeschränkte Nutzbarkeit pixelbasierter Verfahren liegt jedoch in der starken spektralen Variabilität (spektrale Dekorrelation benachbarter Pixel) innerhalb von Objekten bzw. Objektklassen (siehe Abb. 2.5b; vgl. z. B. WOODCOCK & STRAHLER 1987; CUSHNIE 1987; APLIN et al. 1999; SCHIEWE & TUFTE 2002). Spektrale Signaturen einzelner Pixel sind demnach nur begrenzt aussagefähig bezüglich der Klassenzugehörigkeit eines Bildelementes. HAY et al. (1996) bezeichnen diesen Problemkreis als *high-resolution problem: „One of the challenges in using high-spatial resolution remotely sensed imagery for classification is termed the H-resolution problem, and implies that as the spatial resolution of a sensor increases, so does the inter-class spectral variability of surface features, resulting in a reduction of statistical separability with traditional classifiers and a consequent reduction in classification accuracy"* (HAY et al. 1996: 109). Die Autoren schlagen daher eine Auswertung auf Basis von Bildobjekten *(image objects)* vor.

Weiterhin beeinflussen störende Objekte (z. B. Autos auf Straßen, Schatten zwischen Baumkronen, kleinräumige Feuchtigkeitsunterschiede auf Ackerflächen oder Vieh auf der Weide; siehe Abb. 2.5c) die Auswertung. Eine allein statistische Auswertung sehr hoch auflösender Daten auf Pixelbasis erscheint aus den genannten Gründen nicht sinnvoll, da somit eine Klassentrennbarkeit kaum noch gegeben ist.

Durch Fernerkundungsdaten, deren geometrische Auflösung bereits heute im Dezimeterbereich liegt, bestehen sehr hohe Anforderungen an die Hard- und Softwareperformance. Viele Musteranwendungen sind nicht zuletzt aus diesem Grund sehr kleinräumig (meist handelt es sich zudem um idealisierte Ausschnitte) und können daher ihre Anwendbarkeit – in Hinsicht auf Operationalität – nur in begrenztem Umfang zeigen.

Die genannten Effekte erfordern neue Auswertungsverfahren. Zunächst sollen jedoch die gängigen Auswertungsverfahren dargestellt und anschließend methodisch-qualitativ bewertet werden. Dabei werden aktuelle Ergebnisse der Anwendung auf sehr hoch auflösende Fernerkundungsdaten einbezogen.

2.2 Auswertungsverfahren von Fernerkundungsdaten

Die Fernerkundung liefert zunächst nur Daten und keine Informationen (KAPPAS 1994). Ziel der Auswertung von Fernerkundungsdaten ist zumeist deren Klassifikation, d. h. die Ableitung thematischer (GIS-)Informationen aus den Bilddaten. Mithilfe von Dateninterpretation oder -analyse können die gewünschten Informationen extrahiert werden. Eine verallgemeinerte Prozesskette in Form einer Informationspyramide ist in Abbildung 2.6 dargestellt.

Die Grundlage fernerkundungsbasierter Auswertungsmethoden ist die Bildverarbeitung. Darunter werden alle Verfahren verstanden, mit denen Bilder bearbeitet und verändert, d. h. aufbereitet und analysiert werden können. Mit Methoden der digitalen Bildverarbeitung werden digitale Bild- oder Rasterdaten computergestützt erstellt, analysiert, verbessert, interpretiert oder dargestellt (BILL & ZEHNER 2001). Dabei kann in verschiedene Verfahrensschritte untergliedert werden, wie Datenaufnahme, Datenaufbereitung bzw. Vorverarbeitung und Auswertung.

Datenaufnahme und Datenaufbereitung, wie radiometrische Korrekturen, geometrische Entzerrung oder digitale Bildverbesserung, sollen an dieser Stelle nicht näher dargestellt werden. Sie sind Teil der Beschreibung konkret durchgeführter Verarbeitungsschritte in Abschnitt 3.2. Im Folgenden stehen Auswertungsverfahren im Vordergrund, insbesondere die Bildanalyse. Darunter ist die *„automatische Ableitung einer expliziten und bedeutungsvollen Beschreibung von Objekten der realen Welt mit Hilfe von Bildern“* zu verstehen (ROSENFELD 1982; zit. in HEIPKE 2003: 170).

Mit digitalen Bildern wird versucht, reale Bilder zu modellieren, indem Sie in eine Rasterstruktur umgewandelt werden. Infolge der historischen Entwicklung bestehen Bilddaten aus quadratischen Bildelementen (Pixel). Dabei repräsentiert jedes Pixel einen Grauwert an einer bestimmten Stelle des Bildes (Bildkoordinaten). Die wichtigsten Vorteile digitaler gegenüber photographisch-analogen Aufnahmen sind (nach HEIPKE 2003):

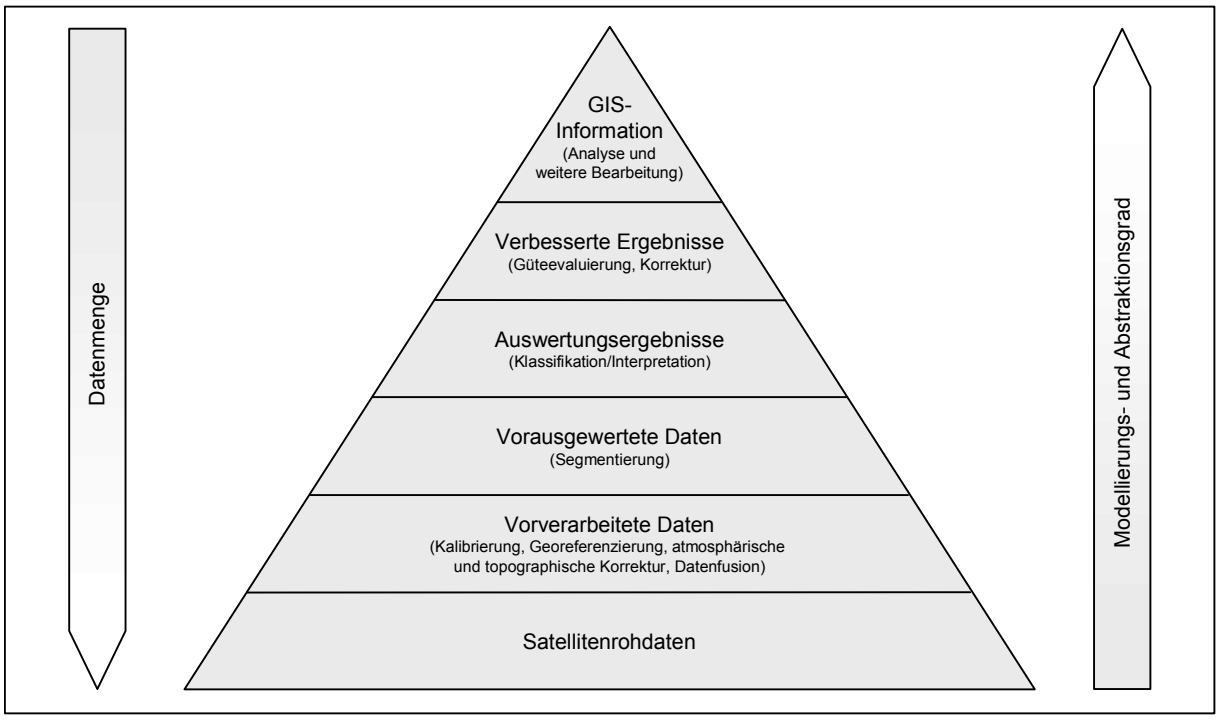

Abb. 2.6: Verallgemeinerte Prozesskette der fernerkundlichen Bilddatenverarbeitung in Form einer Informationspyramide.
(Quelle: Eigene Darstellung)

- die quantitative Erfassung und damit auch die Möglichkeit der quantitativen Datenauswertung,
- die Erweiterung des erfassbaren elektromagnetischen Spektrums,
- die höhere spektrale Auflösung,
- die Möglichkeit zur simultanen Erfassung verschiedener Eigenschaften der elektromagnetischen Strahlung (z. B. Strahlungsenergie, Phase, Laufzeit, Polarisation),
- die Möglichkeit der Erstellung verlustfreier Bildkopien,
- die Möglichkeit der digitalen Datenübertragbarkeit sowie
- das Potenzial zur Echtzeitverarbeitung durch Automation der Auswertung.

Dem stehen nur geringfügige Nachteile gegenüber, wie Probleme bei der Langzeitarchivierung großer Datensätze sowie die nur indirekt mögliche Wahrnehmbarkeit durch den Menschen (Ausgabegeräte notwendig). Damit erklärt sich die hohe Akzeptanz und Verbreitung digitaler Daten (vgl. HEIPKE 2003).

Der Mensch ist durch sein visuelles Wahrnehmungsvermögen in der Lage, enorm schnell und flexibel Objekte innerhalb von Bildern zu erkennen, indem er erlernte Assoziationen nutzt (vgl. ALBERTZ 1999). Das Ziel der Bildverarbeitung sowie der Nachbardisziplinen Robotik, Künstliche Intelligenz, Maschinelles Sehen *(Computer Vision)*, Bildverstehen (z. B. Objekt- und Mustererkennung) etc. ist es, diesen Prozess maschinell zu ermöglichen. Mit komplexen Bildverarbeitungssystemen und -methoden wird versucht, die visuellen und semantischen Fähigkeiten des Menschen computergestützt zu implementieren, um somit an die humane Interpretationsleistung heranzureichen. Die Komplexität dieser Aufgabe zeigen beispielsweise sog. *perceptual lines* (gedachte Verbindungslinien), die mathematisch nur schwer zu formalisieren sind. Die wenigen bisher erzielten Erfolge der digitalen Bildauswertung insbesondere im Fernerkundungsbereich (etwa Gebäude- oder Straßenextraktion) verdeutlichen darüber hinaus in eindrucksvoller Weise die immense Flexibilität und Leistungsfähigkeit des menschlichen Wahrnehmungssystems. Das menschliche ‚Bildverarbeitungssystem' ist somit stets Messlatte computergestützter Verfahren.

Die derzeit zur Verfügung stehenden Methoden werden im Folgenden dargestellt und der Stand der Forschung sowie Anwendungsbeispiele präsentiert.

2.2.1 Visuelle Interpretation

Unter visueller Interpretation ist die manuelle Auswertung von Fernerkundungsdaten zu verstehen, wobei die dargestellten Objekte durch einen Interpreten intuitiv erkannt, identifiziert und abgegrenzt werden. Von größter Bedeutung ist neben der Qualität des Bildmaterials und der verwendeten Auswertegeräte insbesondere das Fachwissen des Interpreten. Je nach Erfahrung lösen die Abbildungen Assoziationen aus und der Betrachter filtert die benötigten Informationen subjektiv. Dieses klassische Auswertungsverfahren – es geht auf den Landschaftsökologen TROLL (1939) zurück und wurde seitdem nicht wesentlich modifiziert – ist arbeits- und zeitintensiv, woraus hohe Kosten resultieren. Dennoch stellt diese simple Form der Auswertung momentan den leistungsfähigsten Ansatz in Bezug auf die inhaltliche Qualität dar, da der Interpret sein umfangreiches, auf Erfahrung basierendes Wissen über die Beschaffenheit der im Bild enthaltenen Objekte nutzen kann.

Vier unterschiedliche Verfahren stehen grundsätzlich zur Verfügung, wobei das Bildmaterial und das Interpretationsergebnis analog oder digital (gescannte Luftbilder, Digitalaufnahmen, digitale Orthophotos) vorliegen können. Die genannten rein analogen Verfahren finden heute nur noch selten Anwendung:

- analoge Interpretation analoger Luftbilder, wobei das Ergebnis auf Interpretationsfolien gezeichnet wird, die später digitalisiert werden können:
  - Monoskopisch oder
  - Stereoskopisch (unter Nutzung von Stereoluftbildern, wobei sich der entstehende räumliche Eindruck und die ableitbaren Höheninformationen positiv auf die Interpretationsgüte auswirken) und
- digitale Interpretation digitaler Luftbilddaten *(On-Screen-Digitizing):*
  - Monoskopisch oder
  - Stereoskopisch.

Der Interpret nutzt zur Erkennung der Bildbestandteile folgende Merkmale (ALBERTZ 2001: 126 ff.; HILDEBRANDT 1996: S. 291 ff.):

- Farbton und Farbsättigung (bzw. Helligkeit und Helligkeitsunterschiede im Falle von panchromatischen Bildern),
- Textur und Muster,
- Form und Größe der Objekte,
- Absolute und relative Lage,
- Schattenwurf,
- Assoziation (in Verbindung mit Kontextinformationen, z. B. Nähe zu anderen Objekten, Nachbarschaftsbeziehungen),
- Nutzungs- und Bewirtschaftungsspuren.

Das menschliche visuelle Wahrnehmungsvermögen ist enorm flexibel und leistungsfähig. So werden bestimmte Sachverhalte des Bildes auch erkannt, wenn Beleuchtung, Bildmaßstab, Qualität der Abbildung, Kontrast, Aufnahmezeitpunkt etc. stark variieren. Diese Einflüsse stören die Erkennungsqualität nur in geringem Maße (vgl. ALBERTZ 1999), da sich der Mensch an stabilen räumlichen Strukturen, wie Textur, Form, Orientierung, Lage, Kontext oder räumlicher Zusammenhang orientiert (vgl. STEINNOCHER 1997).

Entscheidend ist jedoch, dass nicht eine isolierte Stelle im Bild betrachtet wird, sondern dass Kontextinformationen genutzt werden. Im Zusammenhang mit der simultanen Erfassung verschiedener Objekteigenschaften wird selbst die Erkennung sehr komplexer Sachverhalte ermöglicht und somit eine sehr gute und umfangreiche Extraktion des Informationsgehaltes der Bilddaten erreicht. Darüber hinaus ist zur visuellen Interpretation keine kostenintensive Spezialsoftware erforderlich.

Die Nachteile der visuellen Interpretation sind insbesondere im hohen zeitlichen Aufwand und den damit verbundenen Kosten zu sehen. Zwar benötigt dieses Verfahren nur ca. ein Viertel bis ein Fünftel des Zeitaufwandes einer terrestrischen Kartierung (vgl. BUDER 1998). Im Vergleich zu computergestützten Verfahren erfordert es jedoch deutlich mehr Zeit. Ein weiterer wesentlicher Nachteil ist der im hohen Maße subjektive Einfluss des Interpreten auf das Ergebnis, sowohl bei der Abgrenzung als auch bei der Klassenzuweisung. Das unterschiedliche Expertenwissen, visuelle Empfinden bzw. Urteilsvermögen verschiedener Interpreten hat nicht-identische Ergebnisse zur Folge. Zudem können durch eine manuelle Bearbeitung vielfältige Fehler auftreten.

2.2.2 Pixelbasierte Auswertung

Die computergestützte Auswertung von Bilddaten wird auch als quantitative Bildanalyse bezeichnet, da Bildelemente (Pixel) anhand ihrer numerischen Eigenschaften (Messwerte)

bewertet werden. Schwerpunkt dieser Auswertung ist die Klassifikation, womit der Prozess der Zuordnung einzelner Pixel oder Pixelgruppen zu Merkmalsklassen bezeichnet wird. Derartige Klassifikationsmethoden – auch Standardklassifikationsverfahren genannt – werden seit etwa 1970, also seit Verfügbarkeit digitaler Daten, angewandt. Sie basieren auf der Auswertung einzelner Pixel. In der Fachliteratur werden diese Verfahren zum Teil auch als Segmentierungsverfahren bezeichnet, da im Ergebnis geclusterte Bildelemente entstehen. Die Clusteranalyse findet dabei im Gegensatz zu eigentlichen Segmentierungsverfahren (vgl. Abschnitt 2.2.3) nicht im Ortsraum der Bilddaten – also ohne Berücksichtigung des räumlichen Lagezusammenhanges – statt. Vielmehr beschränkt sie sich auf eine Clusterbildung im Merkmalsraum auf Basis spektraler Ähnlichkeit.

Verschiedenartige mathematisch-statistische Verfahren können zur pixelbasierten Auswertung genutzt werden (siehe ALBERTZ 1991; RICHARDS & JIA 1999; LÖFFLER 1994; HILDEBRANDT 1996; LILLESAND & KIEFER 1999; MARTHER 1999). Sie sind Bestandteil der meisten kommerziellen Programmpakete zur fernerkundlichen Bildverarbeitung. Die digitale Klassifikation einzelner Pixel kann aufgrund deren spektraler Eigenschaften (spektrale Klassifikation) oder Texturmerkmale (Texturanalyse) erfolgen.

Die Spektralsignatur der Einzelpixel entspricht der reflektierten Strahlungsenergie des abgebildeten Abschnitts der Erdoberfläche. Die Abbildung des Strahlungsspektrums kann in mehreren Kanälen erfolgen. Kombiniert man die einzelnen Spektralkanäle, so spannen sie einen n-dimensionalen Merkmalsraum auf, in dem jeder Pixel entsprechend seinen Spektralwerten dargestellt werden kann. Ähnliche Pixel, die gleichen thematischen Klassen entsprechen, ergeben dabei Punktwolken. Die Abgrenzung dieser Punktwolken im Merkmalsraum ist Ziel der multispektralen Klassifikatoren.

Eine spektrale Klassifikation ist im Wesentlichen durch zwei Verfahren möglich: der überwachten *(supervised)* oder der unüberwachten *(unsupervised)* Klassifikation (vgl. Abschnitt 2.2.2.2 bzw. 2.2.2.3). Beide Verfahren beruhen auf der Annahme, dass die unterschiedlichen spektralen Klassen im n-dimensionalen Merkmalsraum des Bildes *(feature space*, n = Anzahl der Spektralkanäle) verteilt sind.

Texturen werden dagegen durch Filterverfahren unter Berücksichtigung benachbarter Pixel innerhalb eines gleitenden Fensters *(moving window;* auch als Kernel, Filtermatrix oder Maske bezeichnet; z. B. 3 x 3; 5 x 5 etc.) aus den Abweichungen der räumlich benachbarten Spektralwerte ermittelt und dem jeweiligen Zentralpixel zugewiesen. Da ein Einzelpixel keine Textur besitzt, sind die berechneten Werte keine objektbezogenen Texturen, wie sie bei einer visuellen Interpretation nutzbar sind. Es handelt sich vielmehr um lokale Grauwertabweichungen, welche als spektrale Texturen bezeichnet werden können. Dieser Sachverhalt schränkt die Aussagekraft dieser Texturen ein. Ein weit verbreitetes Beispiel der Texturanalyse ist die Berechnung von *Cooccurrence* Matrizen, die auf HARALICK (1979) zurückgehen.

Texturen lassen sich neben den spektralen Bilddaten als Zusatzdaten in den Klassifikationsprozess einbeziehen. Weitere mögliche Zusatzdaten sind Ratios, Höhendaten, Indizes, GIS-Daten etc., die wie Spektralkanäle gehandhabt werden. Auch die Verwendung multitemporaler Bilddaten zur Klassifikation oder zur Erkennung von Veränderungen *(Change Detection)* ist möglich.

2.2.2.1 Schwellwertverfahren

Schwellwertverfahren *(thresholding)* sind die wohl einfachsten Verfahren der Zuordnung von Grauwertbereichen zu thematischen Klassen. Sie können nur auf ein Merkmal angewandt werden und sind daher keine multispektralen Verfahren. Das Abbildungsverhalten einer Klasse wird durch die Auswahl von Intervallen innerhalb des Wertebereichs eines Merkmals

beschrieben, wobei die Wertspannen sowohl zwischen zwei als auch über bzw. unter einem Schwellwert liegen können. Auf dieser Grundlage wird ein Binärbild erzeugt, wobei die Pixel des ausgewählten Intervalls den Wert 1 zugeordnet bekommen, alle anderen den Wert 0 *(bilevel thresholding*, vgl. HILDEBRAND 1996; JÄHNE 2002).

Weiterentwickelte Formen des Schwellwertverfahrens, wie die Äquidensitentechnik *(multi-thresholding)*, die histogrammbasierte Schwellwertbildung, die Semischwellwertbildung, die dynamische Schwellwertbestimmung oder Hysterese-Schwellwertverfahren werden in der Bildverarbeitungsliteratur beschrieben (vgl. HABERÄCKER 1995). Derartige Verfahren sind jedoch nur für einfache Fragestellungen anwendbar. Weiterhin müssen sich die zu erfassenden Objekte deutlich von ihrem Hintergrund abheben. Schwellwertverfahren haben heute kaum noch Bedeutung im Praxiseinsatz in der Fernerkundung. Lediglich zur Erstellung von Masken oder im Rahmen einer hierarchischen Klassifikation (siehe Abschnitt 2.2.2.6) werden sie noch angewendet.

2.2.2.2 Überwachte spektrale Klassifikationsverfahren

Im Falle des überwachten Verfahrens werden durch die Auswahl von repräsentativen Trainingsflächen und deren spektraler Eigenschaften (Signaturanalyse) zunächst Klassen vordefiniert. Durch die Klassifikation werden alle weiteren Pixel auf ihre Klassenübereinstimmung überprüft und der passenden Klasse zugewiesen. Dieser Prozess ist durch verschiedene statistische Algorithmen möglich, die im Folgenden kurz charakterisiert werden.

Die einfachste Methode ist der *Minimum-Distance*-Klassifikator. Dabei wird für die einzelnen Klassen jeweils ein Mittelwertvektor *(mean vector)* im n-dimensionalen Merkmalsraum berechnet. Für jedes betrachtete Pixel erfolgt im Rahmen der Klassifikation die Bestimmung der Abstände zu den Mittelwertvektoren aller Klassen. Im Ergebnis wird es der Klasse mit dem geringsten Abstand (euklidische Distanz) zugewiesen. Liegen Punkte im Merkmalsraum zu weit von den Klassenmittelwertvektoren entfernt – womit die Wahrscheinlichkeit einer Fehlklassifikation wächst –, kann das Verfahren um einen Abstandsschwellwert erweitert werden. Derart ausgeschlossene Pixel bleiben unklassifiziert. Der Schwellwert kann für alle Klassen gleich oder klassenspezifisch in Abhängigkeit von der Streuung der Grauwerte einer Klasse gewählt werden. Vorteilhaft ist die geringe Berechnungszeit, allerdings hat das Verfahren Grenzen bei spektral ähnlichen Klassen mit hoher Varianz (vgl. LILLESAND & KIEFER 2000; ALBERTZ 2001).

Ein ebenfalls einfaches Verfahren mit geringem Rechenaufwand stellt die Box-Klassifikation *(parallelepiped classifier,* Quader-Verfahren) dar. Hier dienen lediglich der minimale und der maximale Grauwert der Trainingsgebiete einer Klasse als Abgrenzungskriterien. Im Merkmalsbild ergibt sich eine boxförmige Abgrenzung der klassenbeschreibenden Grauwerte, wodurch viele Überschneidungen und damit häufig keine genaue Klassenzuweisung möglich sind. Außerhalb liegende Punkte bleiben unklassifiziert. Durch spektrale Ähnlichkeiten ergeben sich häufig Überschneidungen der Klassenabgrenzungen. Verbesserungen können in eingeschränktem Maße durch eine gestufte Klassenabgrenzung erreicht werden (vgl. HILDEBRAND 1996).

Das am häufigsten verwendete pixelbasierte Auswertungsverfahren ist die MAHALANOBIS-Distanz- bzw. *Maximum-Likelihood*-Klassifikation (vgl. RICHARDS & JIA 1999; ALBERTZ 2001; HILDEBRAND 1996). Bei diesen Verfahren wird angenommen, dass die Grauwerte einer Klasse der GAUß'schen Normalverteilung um den jeweiligen Mittelwertvektor folgen. Daneben fließt zur Berechnung der Klassenzugehörigkeit die Kovarianzmatrix der Punktwolke als zusätzlicher statistischer Parameter ein. Die daraus berechneten Wahrscheinlichkeiten, mit der die einzelnen Pixel den Klassen angehören, lassen sich durch elliptische Linien gleicher Wahrscheinlichkeit um den Mittelwertvektor beschreiben. Die Zuweisung erfolgt zur Klasse

mit der größten statistischen Wahrscheinlichkeit. Unklassifiziert bleiben Bildelemente, deren MAHALANOBISabstand (Verknüpfung von euklidischer Distanz mit der Kovarianzmatrix) größer ist, als ein vorgegebener Schwellenwert in Abhängigkeit von der gewünschten Wahrscheinlichkeit (Umhüllende der Wahrscheinlichkeitsellipsen). Eine Optimierung des Ansatzes stellt der BAYES'sche Klassifikator dar, wobei zusätzlich die a-priori-Wahrscheinlichkeiten des Vorkommens einer Klasse (z. B. mit großen Flächenanteilen) sowie die Schätzung des Verlustes durch Fehlklassifizierungen als Gewichte verwendet werden (vgl. HILDEBRAND 1996; LILLESAND & KIEFER 2000). Nachteilig ist der hohe Zeitbedarf für die Trainingsphase. Dafür erbringt das Verfahren in der Regel bessere Klassifizierungsergebnisse (Klassifikationsgüte meist zwischen 85 und 90 %, vgl. BLASCHKE 2000a).

2.2.2.3 Unüberwachte spektrale Klassifikationsverfahren

Eine Variante pixelbasierter Verfahren stellen die sog. Cluster-, *Clump- bzw. ISODATA*-Verfahren *(Iterative Self-Organizing Data Analysis Technique)* dar. Dabei erfolgt vor oder im Rahmen der Klassifikation, zumeist auf Grundlage einer vom Bearbeiter wählbaren Klassenanzahl, eine automatische Gruppierung aller Bildelemente anhand deren spektraler Ähnlichkeit. Zur Klassenbildung wird der Merkmalsraum nach verschiedenen Verfahren aufgeteilt. Da eine Zuordnung der so entstandenen Spektralklassen zu sinnvollen thematischen Klassen zunächst nicht bekannt ist und erst im Nachhinein durch den Bearbeiter erfolgt, werden derartige Verfahren als unüberwachte Verfahren bezeichnet. In der Klassenzuweisung liegt auch der Hauptnachteil, denn nicht alle der generierten Klassen lassen sich sinnvollen Objektklassen zuordnen.

Die Vorarbeiten der überwachten Klassifikation (Klassendefinition, Auswahl von Trainingsgebieten, Signaturanalyse) entfallen, dafür ist der Aufwand für die genaue Klassenzuordnung erheblich (vgl. HILDEBRAND 1996). Der Rechenaufwand dieser Verfahren ist hoch, stellt unter heutigen Bedingungen jedoch kein Hindernis mehr dar. Clusterverfahren werden häufig während der Vorarbeiten einer überwachten Klassifikation zur Untersuchung der Trennbarkeit thematischer Klassen eingesetzt. Von den zahlreichen Ansätzen werden wiederum die gebräuchlichsten dargestellt.

Zwei Cluster-Verfahren können prinzipiell unterschieden werden:

- Sequenzielle Verfahren – bestimmen für jeden Pixel den Abstand zum Clustermittelwert und
- Statistische Verfahren – nutzen ein Kernel und beziehen die Pixelumgebung mit in die Analyse ein.

Beim einfachen Verfahren des *RGB-Clustering* wird der dreidimensionale RGB-Farbraum entsprechend der gewählten Klassenanzahl in gleiche Grauwertintervalle aufgeteilt. Diesen Merkmalsraum-Clustern werden die entsprechenden Pixel zugeordnet, die diese spektralen Ähnlichkeitsbedingungen erfüllen.

Beim *K-means*-Algorithmus werden für eine vorgegebene Anzahl von Clustern *(K)* Mittelwertvektoren willkürlich im Merkmalsraum verteilt. Alle Pixel werden anschließend dem nächstliegenden Cluster zugeordnet. Daraufhin werden für alle Cluster die Mittelwertvektoren anhand der Abstände der zugeordneten Pixel neu berechnet. Ziel ist die Minimierung der Abweichungsquadrate, d. h. der Summe der quadrierten euklidischen Distanzen der einem Cluster zugewiesenen Pixel *(SSE, sum of squared errors)*. Der Vorgang wird iterativ wiederholt, bis sich die Lage der Mittelwertvektoren im Merkmalsraum nicht mehr verändert (vgl. LILLESAND & KIEFER 2000; MATHER 1999).

Ein ähnliches, weiterentwickeltes Verfahren stellt die *ISODATA*-Clusteranalyse dar. Über die Funktionalität des *K-means*-Algorithmus hinaus erlaubt das Verfahren eine Verschmelzung von Clustern, deren Entfernung unter einem Schwellwert liegt, sowie eine Teilung zu großer Cluster. Als Abbruchkriterien gelten die vom Nutzer festzulegende Anzahl der Iterationen sowie ein Konvergenzschwellwert (minimaler prozentualer Anteil an Bildelementen, deren Clusterzuweisung zwischen zwei Iterationen nicht mehr verändert wird). Diese Möglichkeiten erfordern jedoch gleichzeitig weitere Parameter (vgl. SCHOWENGERDT 1997; MATHER 1999).

Auch für die Cluster-Analyse gibt es einen *Minimum-Distance*-Ansatz. Dessen Vorteil ist, dass er ohne Vorgabe einer Klassenanzahl arbeitet. Zunächst wird willkürlich der Mittelwertvektor eines ersten, vorläufigen Clusters gesetzt. Die Distanzen aller Bildelemente werden anhand eines Zu- bzw. Zurückweisungskriteriums (z. B. einer *Minimum-Distance*-Schwelle) geprüft. Ist deren Entfernung größer als der angegebene Schwellwert, so wird ein neues Cluster eröffnet. Dies setzt sich fort, bis jeder Pixel einer Spektralklasse zugewiesen ist. Iterativ werden auch die Mittelwertvektoren optimiert. Durch eine Veränderung des Schwellwerts werden sowohl die räumliche Anordnung als auch die Größe der einzelnen Cluster verändert (vgl. HILDEBRAND 1996).

Beim *Agglomerative Hierarchical Clustering* wird ebenfalls keine Klassenanzahl benötigt. Jeder Pixel wird zunächst als eigenständiges Cluster aufgefasst. Benachbarte Cluster werden anschließend iterativ anhand von Mittelwertabständen zusammengefasst, bis alle Pixel zu einem einzigen Cluster gehören. Die Etappen der Zusammenfassung der Cluster werden in einem so genannten Dendrogramm dargestellt, welches dem Bearbeiter erlaubt, die Anzahl zusammengefasster Cluster zu bestimmen (vgl. RICHARDS & JIA 1999).

Die Anwendung der Clusteranalyse ist nicht zuletzt eine Ansichtssache. Selbst in einigen Lehrbüchern werden diese Verfahren geringschätzig als *„Stochern im Nebel“* bezeichnet (HILDEBRAND 1996: 542). Die mathematisch exakt durchgeführte Bildaufteilung hat aufgrund in den Bilddaten enthaltener Spektralvariationen und Schatten nur begrenzt realen Charakter. In der wissenschaftlichen Anwendung dagegen wurden verschiedene unüberwachte Klassifikationsverfahren häufig erfolgreicher als eine *Maximum-Likelihood*-Klassifikation eingesetzt, wie KENNEWEG et al. (2000) zusammenfassen. Die Clusteranalyse scheint demnach insbesondere für hoch auflösende Daten (z. B. IRS-1C) geeignet zu sein.

2.2.2.4 Per-parcel-Klassifikation

Bei *per-parcel-* bzw. *per-field*-Verfahren erfolgt eine Unterstützung der Klassifikation durch Geometriedaten. Durch diese Daten, die zumeist vorhandene Geodaten, aber auch Segmentierungsergebnisse oder manuelle Abgrenzungen sein können, werden die Bilddaten in Einheiten *(parcel, fields)* vorstrukturiert. Diese Technik wird vor allem genutzt, um dem Rauschen innerhalb von Landbedeckungseinheiten zu begegnen.

Zunächst werden die Bilddaten pixelbasiert klassifiziert. Dies kann wiederum durch unüberwachte (vgl. HOFFMANN 2001) oder überwachte (vgl. APLIN et al. 1999) Verfahren geschehen. Anschließend werden die Ergebnisse mit den Geometriedaten verschnitten und durch eine GIS-Operation die anteilig am stärksten vertretene Klasse der Einheiten ermittelt und zugewiesen. Darüber hinaus sind qualitative Aussagen möglich, z. B. die Einteilung in dicht oder locker bebaute Gebiete anhand des klassifizierten Bebauungsanteils oder durch die Nutzung von Mischungsverhältnissen.

Mit *per-parcel*-Verfahren konnten zumeist genauere Ergebnisse gegenüber einer pixelbasierten Klassifikation sehr hoch auflösender Daten erreicht werden. Anhand von aus CASI-Daten *(Compact Airborne Spectrographic Imager*, 2 m Bodenauflösung) simulierten IKONOS-Multispektraldaten (4 m) ermittelte APLIN (2003) eine Klassifikationsgüte von 82,5 %. Mit der

gleichen Datengrundlage und ebenfalls vier zu extrahierenden Klassen konnten per *Maximum-Likelihood*-Klassifikation lediglich 51,75 % erreicht werden. HOFFMANN (2001) klassifizierte HRSC-A-Daten *(High Resolution Stereo Camera-Airborne*, 15 bzw. 25 cm) mit einer Güte von 76 % (unüberwacht, vier Forstklassen) bzw. 85 % (überwacht, fünf Forstklassen).

Für die erfolgreiche Anwendung einer *per-parcel*-Klassifikation ist ein geometrisch und inhaltlich genauer Vektordatensatz mit übereinstimmender Aktualität erforderlich. Sollte dieser Datensatz erst durch visuelle Interpretation oder manuelle Anpassung vorhandener Geometriedaten erzeugt werden müssen, steigt der Zeitaufwand erheblich und das Verfahren verliert damit seine Vorteile. Insbesondere für die in sehr hoch auflösenden Fernerkundungsdaten abgebildeten Objekte existieren derartige Referenzdatensätze meist nicht, womit die Anwendung dieser Methode nicht sinnvoll erscheint (vgl. HOFFMANN 2001). Eine Aktualisierung bestehender GIS-Datensätze ist durch dieses Verfahren nicht möglich.

2.2.2.5 Neuronale Netze

In den letzten Jahren werden zunehmend sehr komplexe Klassifikationsverfahren basierend auf neuronalen Netzen für Fernerkundungsdaten eingesetzt (vgl. FOODY 1999; KLAUS et al. 1999; CANTY 1999). Dieser Ansatz aus der künstlichen Intelligenz imitiert die Struktur sowie einige Funktionen des menschlichen Gehirns.

Die Grundbausteine eines neuronalen Netzes sind künstliche Neuronen (Zellen, *Units)*. Diese sind in Schichten (Ebenen, *Layer)* angeordnet und untereinander gewichtet verbunden. Die einzelnen Schichten werden durch einen Eingabelayer (auf Werte zwischen 0 und 1 normalisierte Bilddaten), zumindest einer verdeckten Schicht *(hidden layer)* sowie einer Ausgabeebene (Klassifikationsergebnis, Anzahl der Neuronen entspricht in der Regel der Klassenanzahl) gebildet. Bei der Informationsverarbeitung erhält jedes Neuron mehrere gewichtete Eingabewerte und summiert sie. Anhand dieser Summe erfolgen eine einfache Berechnung (zumeist S-förmige Schwellwertfunktion) und eine Weitergabe des Ausgabewertes an die nächste Neuronenschicht.

Es existiert eine große Vielfalt an neuronalen Netzen (und hybriden Kombinationen), deren einzelne Eigenschaften hier nicht ausführlich erläutert werden können. Im Fernerkundungsbereich finden insbesondere *KOHONEN Self-Organising Map* Netzwerke aufgrund ihrer Fähigkeit der Selbstorganisation für unüberwachte Klassifikationen Anwendung. Eine verbreitete Form sind darüber hinaus *Multi-layered feedforward* Netze (auch *multilayer perceptron)*, die im Folgenden beispielhaft dargestellt werden. Sie werden besonders für überwachte Klassifikationen angewendet, da sie anhand von Beispielen lernen und generalisieren können (vgl. FOODY 1999). Ihr Prinzip ähnelt dem Klassifikationsablauf einer überwachten Klassifikation: In einer Trainingsphase werden die Bildelemente der Trainingsgebiete mit ihren bekannten Objektklassen verwendet. In der nachfolgenden Klassifikationsphase wird jedes Bildelement einer Objektklasse zugewiesen.

Zu Beginn der Bearbeitung steht eine Trainingsphase, wobei verschiedene Algorithmen benutzt werden können. In Fernerkundungsanwendungen sind das vor allem *backpropagation-, back impedance-* oder *quickprop*-Algorithmen. Der am häufigsten genutzte *backpropagation*-Trainingsprozess erfolgt durch den Vergleich der Spektralwerte der Trainingsflächen mit denen der berechneten Ergebnisklassen. Liegt keine Übereinstimmung vor, werden die zunächst zufällig gewählten Verbindungsgewichte iterativ anhand einer gewählten Lernrate korrigiert, bis eine vorgegebene Abweichung oder eine maximale Anzahl von Iterationen erreicht ist. Die Ergebniswerte liegen zwischen 0 (keine) und 1 (hohe Korrelation mit korrespondierender Klasse).

Während der Klassifikationsphase wird für jedes Eingabeneuron anhand der aus der Trainingsphase resultierenden Gewichte ein Ergebniswert berechnet. Die Zuordnung der Bildelemente erfolgt zu derjenigen Klasse, deren Outputwert am höchsten ist. Ein Bildelement kann zurückgewiesen werden und unklassifiziert bleiben, falls ein Schwellwert unterschritten wurde.

Neuronale Netzwerke setzen keine statistischen Verteilungen der Grauwerte innerhalb der Trainingsgebiete voraus, was ihre Einsatzfähigkeit gegenüber anderen Verfahren deutlich erhöht. Neben Spektraldaten ist die Verwendung zusätzlicher Daten vergleichsweise einfach möglich. Neuronale Netze haben die Fähigkeit, in gewissem Maße zu generalisieren. Sie sind dadurch mehr oder minder tolerant gegenüber Rauschen. Das Verfahren ist insgesamt sehr zeitaufwändig, und aufgrund der zunächst zufällig gewählten Gewichte ist das Ergebnis im Gegensatz zu statistischen Verfahren nicht reproduzierbar (vgl. SCHOWENGERDT 1997).

Die Berechnungsroutine von neuronalen Netzen ist derzeit noch nicht genau erforscht, sie entspricht nahezu einer Blackbox. Der Nutzer benötigt daher viel Wissen zum theoretischen Hintergrund, um eine optimale Parametereinstellung zu erreichen. So gibt es für die nötige Anzahl an verdeckten Schichten sowie die darin enthaltene Anzahl Neuronen keinerlei Vorgaben. Diese wichtige Angabe muss durch die *trial-and-error*-Methode gefunden werden. Je höher die Anzahl der *hidden layer*, desto flexibler ist die Klassifikation. Eine zu hohe Flexibilität führt leicht zum übermäßig angepassten Netz *(overfitting)*, sodass die Klassifikation nur für die Trainingsdaten optimal ist. Da ebenso die Fähigkeit des Generalisierens mit wachsender Zahl der Neuronen abnimmt, ist eine optimale Wahl erforderlich.

Der Trainingsaufwand ist relativ hoch, um etwa vergleichbare Ergebnisse eines *Maximum-Likelihood*-Verfahrens zu erreichen. Aber einmal trainiert, führt dieser Ansatz schnell zu Klassifikationsergebnissen (vgl. LILLESAND & KIEFER 2000; FOODY 1999). Durch verschiedene Untersuchungen konnte gezeigt werden, dass neuronale Netze gleichwertige oder bessere Ergebnisse als *Maximum-Likelihood*-Klassifikationen erbringen (vgl. MATHER 1999). KLAUS et al. (1999) verglichen drei neuronale Netzwerktypen (darunter ein *feedforward* Netz mit drei unterschiedlichen Lernverfahren) mit einem überwachten *Minimum-Distance*-, einem *Maximum-Likelihood*-Verfahren sowie einem integrierten Verfahren anhand zweier Landsat5-TM-Szenen. Die neuronalen Netze erbrachten dabei zumeist eine höhere Klassifikationsgüte als die überwachten Verfahren. Die besten Ergebnisse konnten mit dem integrierten Verfahren erzielt werden. Die oben beschriebenen *backpropagation*-Lernverfahren erreichten die niedrigste Klassifikationsgüte unter den neuronalen Netzen. TATEM et al. (2001) verwendeten ein HOPFIELD-Netz erfolgreich zur Subpixelklassifikation.

Neuronale Netze sind ein junges Forschungsfeld. EGMONT-PETERSEN et al. (2002) geben einen umfassenden Überblick über aktuelle Anwendungen von neuronalen Netzwerken in der Bildverarbeitung. Die breit gefächerte Einsatzpalette reicht dabei von Verfahren zur Bildvorverarbeitung, Datenkomprimierung, Segmentierung, Objekterkennung, Bildverstehen bis hin zu Optimierungsverfahren wie Graphen- oder Bildzuordnung *(graph matching).* Die Anwendung auf sehr hoch auflösende Bilddaten wurde bisher kaum untersucht und publiziert. MEHNER et al. (2004) beschreiben die Anwendung eines *multilayer perceptron* Netzes auf IKONOS-Daten, wobei lediglich eine Klassifikationsgüte von 80 % erreicht wurde. Bei Versuchen, die bereits angelernten Netze auf andere Szenen zu übertragen, sank die Güte auf unter 50 %.

2.2.2.6 Weitere pixelbasierte Verfahren, Kombinationen und Variationen

Verschiedene Verfahren lassen sich im Rahmen einer hybriden Klassifikation kombiniert anwenden, um Synergien zu nutzen. HILDEBRAND (1996) versteht unter hybrider Klassifikation lediglich die Ergänzung digitaler Verfahren durch manuelle. Zumeist werden heute jedoch

digitale Verfahren kombiniert. Ein häufiger Fall ist die Anwendung einer Clusteranalyse mit anschließender *Maximum-Likelihood*-Klassifikation, wobei durch das *Clustering* zunächst spektral ähnliche Klassen ermittelt werden, die im Anschluss überwacht klassifiziert werden (vgl. RICHARDS & JIA 1999). Ein solches Vorgehen kann zusätzlich durch visuelle Interpretation und die Einbeziehung von GIS-Daten erweitert werden.

Verfahren, welche nicht in einem einmaligen Prozess realisiert werden, sondern in einer Folge iterativer Einzelentscheidungen, werden als hierarchische Klassifikationsverfahren bezeichnet. Dieses Verfahren wird zumeist in Kombination mit anderen hier vorgestellten Klassifikatoren angewandt. Dabei werden wenige Hauptklassen anhand von Entscheidungsbäumen *(decision trees)* immer weiter aufgeteilt, wobei der Bearbeiter interaktiv die genutzten Datengrundlagen, die Klassifikationskriterien und selbst den Klassifikationsalgorithmus festlegen kann (vgl. RICHARDS & JIA 1999). Durch diese Wahlmöglichkeiten gestaltet sich das Verfahren sehr flexibel, besitzt aber durch den hohen Grad an Interaktivität einen erheblichen Arbeitsaufwand (vgl. ALBERTZ 2001). Weiterentwickelte hierarchische Verfahren werden als wissensbasierte oder Experten-Systeme bezeichnet (vgl. Abschnitt 2.2.4)

Eine Klassendefinition enthält stets Unsicherheiten und kann nie absolut sein. Daher werden ‚harte' bzw. scharfe *(crisp)* und ‚weiche' bzw. unscharfe *(fuzzy)* Klassifikationsverfahren unterschieden. Unscharfe Aussagen lassen sich durch Wahrscheinlichkeiten ausdrücken, wie sie *fuzzy-logic*-basierte Algorithmen *(fuzzy classification)* nutzen. Diese Verfahren wurden unter anderem zum besseren Umgang mit Mischpixeln entwickelt. Sie erlauben einem Bildelement eine Zugehörigkeit zu mehr als einer Klasse (z. B. könnte ein Pixel am Waldrand zu 73 % Wald, zu 21 % Acker und zu 6 % Straße repräsentieren). Unschärfe lässt eine gewisse Heterogenität zu und ermöglicht somit eine realitätsnähere Abbildung der natürlichen Variabilität der Landbedeckung (vgl. FOODY 1999).

Umsetzung fanden *fuzzy-logic*-Verfahren zumeist als Erweiterung bereits bestehender Ansätze, z. B. im überwachten *fuzzy Maximum-Likelihood*- oder unüberwachten *fuzzy K-means*-Ansatz. Dabei wurden die ‚harten' Grenzen im Merkmalsraum durch unscharfe ersetzt. Einem Pixel wird anstelle einer Klasse ein Zugehörigkeitsgrad *(membership value)* für jede Klasse zugewiesen. Auch Neuronale Netze sowie Segmentierungsansätze können mit *fuzzy-logic*-Verfahren kombiniert werden.

2.2.3 Segmentbasierte Auswertung

Unter Bildsegmentierung versteht man in der digitalen Bildverarbeitung die Gruppierung benachbarter Bildelemente (Pixel) zu Pixelgruppen (Regionen, Segmenten, Bildprimitiven, Bildobjekten) aufgrund von Ähnlichkeitskriterien (Spektralsignatur, Textur, Form). Dabei wird das gesamte Bild in sich nicht überlappende Segmente zerlegt (vgl. HARALICK & SHAPIRO 1985; HABERÄCKER 1991; HARALICK & SHAPIRO 1992). Teilweise wird unter Segmentierung lediglich die Trennung von Objekten und deren Hintergrund (Binärisierung) verstanden (vgl. JÄHNE 2002). Häufig werden auch pixelbasierte Verfahren (sog. punktorientierte Segmentierungsverfahren), wie Schwellwertverfahren (vgl. Abschnitt 2.2.2.1) oder das *Clustering* (vgl. Abschnitt 2.2.2.3) zu den Segmentierungsverfahren gezählt. Derartige Verfahren fassen Pixel jedoch allein aufgrund ihrer spektralen Merkmale zusammen (Merkmalsraum-basiert). Im Gegensatz dazu werden durch eine Segmentierung im Sinne dieser Arbeit spektral ähnliche, räumlich benachbarte Pixel verschmolzen (Ortsraum-basiert). Segmentierungsansätze integrieren damit eine wichtige Eigenschaft zum Bildverstehen, die auch bei der visuellen Interpretation von großer Bedeutung ist und von TOBLER als *„first law of geography"* formuliert wurde: *„Everything is related to everything else, but near things are more related than distant things"* (TOBLER 1970: 236; vgl. BLASCHKE 2000a).

Segmentierungsverfahren existieren seit etwa 1970. Sie wurden zunächst im Bereich der Bildverarbeitung für spezielle Anwendungen in der Medizin, Mustererkennung, Neuroinformatik (Szenenanalyse), Computerunterstütztes Sehen *(Computer vision)* und Nachrichtentechnik entwickelt. Die speziell konzipierten Programme sind auf die Aufgaben dieser Anwendungsbereiche abgestimmt und können die komplexen Anforderungen im Bereich der Fernerkundung kaum erfüllen. Insbesondere da hier

- multispektrale, teils multiskalige Datengrundlagen verwendet werden,
- Zusatzdaten genutzt werden sollen,
- die zu erkennenden Objekte häufig heterogene Eigenschaften hinsichtlich Form, Größe, spektralem Verhalten oder Texturierung aufweisen, weshalb nur sehr schwer modellbasiert klassifiziert werden kann und
- keine Echtzeit- oder dynamischen Auswertungen notwendig sind, wodurch sub-optimale Ansätze nicht notwendig sind (vgl. SCHIEWE & TUFTE 2002).

Die Darstellung von Segmentierungsverfahren fehlt in der Grundlagenliteratur der Fernerkundung nahezu vollständig. Lediglich bei KRAUS (1990) sowie SCHOWENGERDT (1997) finden sich kurze Einleitungen. Dieser Fakt zeigt, dass die Bildsegmentierung im Bereich der Fernerkundung erst spät Anwendung fand, obwohl bereits frühzeitig Forschungsarbeiten zu dieser Thematik existierten. Als ein erstes Verfahren für den Fernerkundungsbereich wird von SCHOWENGERDT (1997) das von KETTIG & LANDGREBE (1976) entwickelte System ECHO *(Extraction and Classification of Homogenous Objects)* angegeben. Der Grund für den späten Einzug der Segmentierung wird darin gesehen, dass die Anwendung dieser Verfahren auf gering aufgelöste Satellitendaten keine wesentlichen Vorteile brachte und bei Luftbildern aufgrund der Komplexität der Bildobjekte scheiterte (vgl. MÜLLER 2001). Daneben war der damalige Entwicklungsstand der Methoden sowie der Rechentechnik ein bedeutender Hinderungsgrund.

Erst in jüngster Vergangenheit und insbesondere mit der Verfügbarkeit sehr hoch auflösender Fernerkundungsdaten, also etwa seit dem Jahr 2000, werden Segmentierungsverfahren verstärkt entwickelt und angewandt. Seit dieser Zeit existieren auch erste kommerzielle Softwarepakete (z. B. eCognition, Definiens Imaging GmbH, welches im Rahmen dieser Arbeit angewendet wurde, vgl. Abschnitt 4.1). Inzwischen liegt eine Vielzahl implementierter Segmentierungsalgorithmen vor, mit teils sehr unterschiedlichem Charakter, wie ein Vergleich derzeit verfügbarer Programme zeigt (vgl. Abschnitt 4.3).

Die Segmentierung stellt einen Bearbeitungsschritt zwischen Vorverarbeitung und Klassifikation dar, da somit lediglich die Geometrie der später zu klassifizierenden Objekte geschaffen wird. Hierbei wirkt sich eine minderwertige Segmentierungsqualität nachteilig auf die Klassifikationsgüte aus, da die Klassifikation anhand der Segmenteigenschaften (spektraler Mittelwert, Form etc.) erfolgt. Der Evaluierung der Segmentierungsqualität kommt somit eine große Bedeutung zu (vgl. Abschnitt 4.3).

Die Bildsegmentierung gehört – im Gegensatz zur Objekterkennung – zu den unüberwachten Verfahren, da hier kein a priori Wissen über die im Bild enthaltenen Objekte eingebracht wird bzw. keine zu extrahierenden Klassen anhand von Trainingsflächen definiert werden. Das Bild wird vielmehr nur auf Grundlage der Pixelwerte zusammengefasst. Die gebildeten Bildprimitive *(image object primitives)* haben daher zunächst nur eine Topologie (Fläche, Umfang, weitere Formparameter) und eine geometrische Lagebeziehung zu ihren Nachbarobjekten (Anzahl der Nachbarobjekte, längste gemeinsame Grenze etc.). Thematische Bezüge (z. B. Nachbarschaft zu einer Klasse X) existieren noch nicht, diese können erst im Verlauf der Klassifikation genutzt werden.

Die Segmentierung soll je nach Untersuchungszweck relevante Bildelemente erzeugen, die auch in der realen Welt eine Bedeutung haben (bedeutungsvolle Objekte, *meaningful objects*; z. B. Gebäude, Straßen). Das Hauptanliegen der Segmentierung besteht in der lagerichtigen Abbildung von Regionsgrenzen und in der Schaffung homogener Segmente, um einerseits das Pixelrauschen zu eliminieren und andererseits eine Klassifikation zu ermöglichen. Als Anforderungen für eine erfolgreiche Segmentierung formulierte GORTE (1999) folgende Bedingungen:

- eine hohe geometrische Bildauflösung, sodass Objekte durch eine gewisse Pixelanzahl repräsentiert werden,
- leistungsfähige Hardware mit umfangreichem Arbeitsspeicher sowie
- eine effiziente Implementierung aufgrund der hohen Datenmengen.

HALLE (1999) forderte – unter dem Fokus einer Echtzeit-Segmentierung großer Bilddatenmengen – darüber hinaus eine

- starke Parallelisierbarkeit des Berechnungsprozesses,
- vollständige Zerlegung der Bildszene,
- Unabhängigkeit des Ergebnisses von den gewählten Startpunkten,
- Robustheit gegenüber Störungen (Rauschen),
- Unempfindlichkeit gegenüber geringfügigen Merkmalsänderungen,
- Eindeutigkeit bzw. exakte Reproduzierbarkeit,
- weitestgehende Vermeidung empirischer Schwellen und Faktoren sowie
- keine Beschränkung auf Segmentzahl oder -form.

Nicht alle heute existierenden Segmentierungsprogramme erfüllen diese Anforderungen, weshalb deren Anwendung zu teils suboptimalen Ergebnissen führt (vgl. Abschnitt 4.3).

Die in Fernerkundungsdaten abgebildeten Objekte – insbesondere Vegetationsflächen – besitzen häufig eine hohe interne Heterogenität und sind schwierig gegeneinander abzugrenzen. Dies macht die Segmentierung zu einer komplexen Aufgabe. Die vom Nutzer gewünschten Nutzungs- bzw. Bedeckungseinheiten *(objects of interest)* werden durch die Segmentierung komplexer Fernerkundungsdaten häufig nicht korrekt wiedergegeben. Die Ursachen hierfür liegen einerseits im Bildmaterial, welches die vielgestaltige Situation der Erdoberfläche abbildet (z. B. Grenzen des Auflösungsvermögens, Unschärfe, Kontrastmangel, atmosphärische Einflüsse, Schatten, Schrägblick, Überdeckungen – vgl. Abschnitt 2.1.3), andererseits liegen sie im Segmentierungsansatz selbst. Von Bedeutung sind vor allem das angewendete Segmentierungsverfahren sowie das verwendete Homogenitätsmaß und dessen Parametrisierung. Als Homogenitätskriterium wird derzeit häufig nur die infolge des Rauschens teils inhomogene spektrale Ähnlichkeit herangezogen, selten dagegen die häufig stabilere Textur.

Die vorgenannten Bedingungen führen oftmals zu nicht optimalen Ergebnissen. Unter- oder Übersegmentierung sind die Folge. Im ersten Fall werden zu wenige Regionen gebildet, sodass die Segmente oft mehr als nur eine vom Anwender gewünschte Objektklasse enthalten. Eine Übersegmentierung bedingt dementsprechend das gegenteilige Resultat, also die übermäßige Unterteilung in mehr Regionen, als vom Anwender gewünscht. Selbst homogene Bildbereiche können dabei durch mehrere Regionen repräsentiert werden. In diesem Fall müssen mehrere Regionen zunächst sinnvoll verschmolzen werden, um ein Objekt zu bilden. Dagegen bedarf ein untersegmentiertes Ergebnis des Hinzufügens weiterer Regions-

grenzen. Unter- und Übersegmentierung können nebeneinander in einem Ergebnis auftreten. Deshalb sind Verfahren sinnvoll, die nach einer initialen Segmentierung das Ergebnis optimieren.

Je nach Segmentierungsansatz können verschiedene, die Segmentierung steuernde Parameter gewählt werden. Durch die nötige Reduktion der Komplexität der Segmentierungsalgorithmen auf wenige Parameter zugunsten einer hohen Bedienfreundlichkeit sind Segmentierungsfehler vorprogrammiert. In einigen Segmentierungsprogrammen wirken einzelne Parameter sogar konträr und können daher nicht in vollem Umfang berücksichtigt werden. Ein Beispiel hierfür sind die Parameter Farb- vs. Formhomogenität der Software eCognition, da sich die Forderung nach spektraler Homogenität und Kompaktheit oder Glattrandigkeit der Segmente oftmals widerspricht (vgl. Abschnitt 4.1.1).

Die Vorteile einer segmentbasierten Klassifikation sind hauptsächlich in den zusätzlich zu den Spektralinformationen nutzbaren nicht-spektralen Segmentmerkmalen zu sehen. Dadurch können im Vergleich zur pixelbasierten Auswertung z. B. nicht nur Landbedeckungsklassen *(land cover),* sondern vielfach auch Informationen zur Landnutzung *(land use)* abgeleitet werden. Dies geschieht – wie bei einer visuellen Interpretation – häufig durch die Nutzung von Formeigenschaften eines Objektes (z. B. Größe, Längen-Breiten-Verhältnis) und Kontextinformationen (z. B. Nachbarschaften, Hierarchie bei der Segmentierung mehrerer Ebenen). So lässt sich eine rechteckige Wiesenfläche einer bestimmten Größe nahezu zweifelsfrei als Sportplatz (Fußballfeld) oder ein Baumbestand innerhalb einer Siedlung als Park klassifizieren.

Häufig wird der Begriff objektorientierte Bildverarbeitung verwendet, obwohl diese, aus der Programmierung entlehnte Bezeichnung nicht zutreffend ist. Denn im Falle einer Segmentierung entstehen Bildobjekte bzw. -primitive. Diese besitzen zwar eine Geometrie und können ein Objekt abbilden, ihnen fehlen jedoch Eigenschaften im Sinne von Attributinformationen sowie die Zugehörigkeit zu einer Objektklasse. Diese Zuordnung der Segmente findet erst im Rahmen der Klassifikation statt. Zutreffender wäre demnach die Bezeichnung ‚bildobjektorientiert'.

Man unterscheidet prinzipiell kantenbasierte *(edge based)* und regionenbasierte *(region based)* Segmentierungsverfahren. Erstere finden Bildkanten, die als Regionsgrenzen aufgefasst werden. Die zweite Gruppe aggregiert die einem Homogenitätskriterium genügenden Pixel. In beiden Verfahren können Informationen über objektspezifische Eigenschaften implementiert sein, die im Verlauf der Segmentierung genutzt werden (modellbasierte Verfahren). Hierfür können einerseits strukturelle Modelle Anwendung finden. Diese verwenden z. B. Schablonen *(templates)*, welche die Form von Objekten vorgeben. Andererseits können numerische Modelle integriert werden. Diese vergleichen objektspezifische Merkmale einzelner Pixel oder Regionen mit bekannten, vorgegebenen Merkmalen (z. B. Spektralwerte, Textur, Form). HARALICK & SHAPIRO (1985), PAL & PAL (1993), MOREL & SOLIMINI (1995) sowie SCHOWENGERDT (1997) geben einen guten Überblick über die in der Vergangenheit entwickelten Ansätze. Dabei werden insbesondere die mathematischen Grundlagen einzelner Verfahren diskutiert. Ein anwendungsorientierter Vergleich verschiedenartiger, aktuell verfügbarer Segmentierungsverfahren für Fernerkundungsanwendungen ist Bestandteil dieser Arbeit (siehe Abschnitt 4.3).

2.2.3.1 Kantenbasierte Segmentierungsverfahren

Kantenbasierte Verfahren suchen nach Grauwertgradienten im Bild, wobei angenommen wird, dass diese Diskontinuitäten Segmentgrenzen darstellen. Verschiedene Kantendetektoren (Gradientenoperatoren, Kantenfilter) werden hierzu eingesetzt, z. B. ein LAPLACE- oder ein SOBEL-Operator. Flächen, die von den so extrahierten Kanten vollständig umgrenzt

werden, stellen Segmente dar. Formale Aspekte (z. B. Geradlinigkeit) können bei der Grenzziehung berücksichtigt werden. Eine innere Homogenität der Segmente ist jedoch bei kantenbasierten Verfahren nicht immer gegeben. Vor Anwendung von Kantenfiltern sollten die Bilddaten daher zumindest geglättet werden, um diesen Effekt zu minimieren. Aufgrund geringer Pixelkontraste und Bildstörungen wird zudem ein Teil der visuell erkennbaren Grenzen nicht abgebildet oder Linien sind vielfach unterbrochen (vgl. JÄHNE 1997). Nicht verbundene Linienfragmente werden durch ein anschließendes *closing*-Verfahren zu Polygonen zusammengeschlossen. Einen Überblick über bestehende Kantendetektoren sowie die Weiterverarbeitung der extrahierten Kanten gibt MÜLLER (2001: 15 ff.)

Ein verbreitetes kantenbasiertes Verfahren ist die *Watershed*-Segmentierung: Das erzeugte Kantenbild wird dabei als Geländerelief aufgefasst, wobei die hohen Werte der Kanten Erhebungen (Bergrücken, -kämme) repräsentieren und niedrige Werte Niederungen. Um die lokalen Minima des Bildes wird entlang der maximalen Erhebungen – wie bei Wassereinzugsgebieten – eine Grenze gezogen, wodurch die Bildung des Segments erfolgt.

KARANTZALOS & ARGIALAS (2003) evaluierten drei Kantenextraktionsverfahren anhand unterschiedlicher Bilddatensätze, darunter panchromatische IKONOS-Daten. Diese *edge-detection*-Verfahren können Grundlage einer Segmentierung sein. Verglichen wurden ein *CANNY,* ein *LAPLACian morphological* sowie ein *Prewitt gradient edge detector.* Alle drei Verfahren wurden visuell als gut bewertet. Eine detaillierte Qualitätsanalyse wurde jedoch nicht durchgeführt.

2.2.3.2 Regionenbasierte Segmentierungsverfahren

Regionenbasierte Verfahren sind toleranter gegenüber Bildstörungen, die eine Kantensuche erschweren. Es gibt mehrere Varianten, die in *bottom-up- (data driven)*, z. B. Regionenwachstum *(region growing)*, oder *top-down*-Verfahren *(knowledge driven)*, z. B. *split-and-merge*, eingeteilt werden können.

Region-growing-Verfahren werden am häufigsten im Fernerkundungsbereich eingesetzt. Dabei werden zunächst Saatzellen *(seed pixel)* statistisch oder regelmäßig über das Bild verteilt. Ausgehend von diesen Wachstumskernen werden benachbarte Pixel in allen Richtungen (4er oder 8er Nachbarschaft) auf Ähnlichkeit geprüft und entweder mit dem Saatpixel verschmolzen oder zurückgewiesen (d. h. eine Segmentgrenze gezogen). Nicht zuordenbare Pixel dienen wiederum als Saatzelle. Die Segmentierung endet, wenn alle Pixel einem Segment zugeordnet wurden. Sowohl das Verfahren, nach dem die Saatzellen ausgewählt werden als auch das verwendete Ähnlichkeitskriterium haben einen erheblichen Einfluss auf die Qualität der Segmentierung.

Benachbarte Regionen können wiederum anhand eines Homogenitätskriteriums miteinander verglichen werden und durch deren schrittweise Fusionierung immer größere Segmente entstehen *(region merging)*. Werden dabei die in den einzelnen Schritten erzeugten Geometrien bewahrt, spricht man von einer hierarchischen Segmentierung (vgl. WOODCOCK & HARWARD 1992) oder Segmentierungspyramiden (vgl. SCHIEWE 2002a, 2002b). Ein hierarchisches *region-merging*-Verfahren wird in der im Rahmen dieser Arbeit genutzten Software eCognition eingesetzt (vgl. Abschnitt 4.1).

Das Berechnungsverfahren des *region growing* ist aufwändig, da meist mehrere Iterationen stattfinden. Dennoch handelt es sich um grundsätzlich einfache Verfahren, die insbesondere dort gute Ergebnisse liefern, wo kantenbasierte Verfahren an ihre Grenzen stoßen (z. B. schwacher Kontrast, Bildstörungen; vgl. MÜLLER 2001). Als nachteilig wird erachtet, dass teilweise Segmente mit irregulären (zerfransten) Außengrenzen und unerwünschten Löchern (inliegenden Segmenten) entstehen.

Um ein Pixel zu einem Segment hinzuzufügen, wird es auf Ähnlichkeit überprüft. Dazu dienen verschiedene Algorithmen, die sich hinsichtlich der Berechnungsgeschwindigkeit, der Toleranz gegenüber Rauschen und dem Umgang mit kontrastarmen Kanten unterscheiden. Folgende Verfahren sind möglich (vgl. HARALICK & SHAPIRO 1985):

- *single linkage* – die Differenz zum Startpunkt *(seed pixel)* ist entscheidend;
- *hybrid linkage* – die Differenz der benachbarten (max. acht) Pixel, die bereits zum Segment gehören, wird geprüft;
- *centroid linkage* – die Differenz zum nach jeder Fusion neu berechneten Mittelwert des Segmentes wird berechnet;
- *hybrid linkage combination* – Kombinationen der drei vorgenannten Algorithmen.

Bei *split-and-merge*-Verfahren wird zunächst das gesamte Bild auf ein Homogenitätskriterium hin überprüft. Bei Nichterfüllung wird das Bild in Quadranten aufgeteilt. Prüfung und weitere Unterteilung erfolgen, bis die geforderte Homogenität gegeben ist, wenn nötig bis auf Pixelebene. Dieses Vorgehen führt häufig zu einer Übersegmentierung, daher werden nach jeder Unterteilung die benachbarten Segmente zunächst auf Ähnlichkeit geprüft und ggf. verschmolzen. Durch die Quadranteneinteilung bildet sich oft eine unerwünschte Blockstruktur heraus, welche die Grenzen der Regionen ungenau wiedergibt (vgl. HARALICK & SHAPIRO 1985; MÜLLER 2001).

LUCIEER (2004) segmentierte einen kleinen Ausschnitt (512 x 512 Pixel) eines multispektralen IKONOS-Datensatzes (4 m Bodenauflösung) mittels eines *split-and-merge*-Algorithmus. Dabei wurden visuell ansprechende Ergebnisse erzielt, insbesondere bei relativ homogenen Landbedeckungsklassen. Bewaldete und urbane Gebiete werden jedoch aufgrund der großen Grauwertvarianzen stark übersegmentiert. Die bei *split-and-merge*-Verfahren üblichen rauhen Abgrenzungen sowie ein Auftreten von Blockstrukturen konnte durch die Wahl kleiner Parameter für die *split*-Phase vermieden werden.

2.2.3.3 Hybride Segmentierungsverfahren

MÜLLER (2001) kombinierte ein kanten- und regionenbasiertes Segmentierungsverfahren zur Extraktion landwirtschaftlicher Flächen aus hoch auflösenden panchromatischen Satelliten- und Luftbilddaten der Sensoren MOMS-02 *(Modular Optoelectronic Multispectral Scanner,* Bodenauflösung 4,5 m) und IRS-1C (5,8 m) sowie Luftbildern mit 25 cm Auflösung. Durch die sinnvolle Verknüpfung beider Verfahren konnten Nachteile der einzelnen Ansätze ausgeglichen werden. Eine Übersicht weiterer Arbeiten zur Kombination kanten- und regionenbasierter Verfahren findet sich ebenfalls in MÜLLER (2001).

Das von ZHU & YUILLE (1996) entwickelte *region-competition*-Verfahren nutzt in einer iterativen Prozessfolge verschiedene Algorithmen. Zunächst erfolgt eine initiale regionenbasierte Segmentierung, deren Segmentgrenzen anschließend durch aktive Konturen *(active contours)* optimiert werden. Aktive Konturen (bzw. *Snakes)* versuchen die Fläche zu maximieren, während gleichzeitig die Außengrenze geglättet und der Intensitätsgradient entlang der Grenze maximiert wird. In einem anschließenden Prozess wird basierend auf der BAYES-Statistik ein globales Kriterium zur Energieminimierung genutzt *(Minimum Description Length)*. Eine Anwendung in der Fernerkundung wurde von KERSCHNER (2003) dargestellt.

Auf Basis von Luftbildern wurde von MEIDOW (2000) die BAYES-Statistik genutzt, um die mittels eines *region-growing*-Verfahrens segmentierten Bilddaten unter Anwendung einer Wissensbasis zu interpretieren. Durch dieses Vorgehen konnten ähnlich wie beim *fuzzy-logic*-Ansatz Unsicherheiten der Interpretation berücksichtigt werden. Allerdings konnte mit diesem Verfahren nur eine mangelhafte Abgrenzung der Bildobjekte erreicht werden.

2.2.3.4 Weitere Segmentierungsverfahren

Es existieren zahlreiche weitere Verfahren im Bereich der Fernerkundung, von denen hier einige beispielhaft genannt, jedoch nicht näher erläutert werden sollen, da sie nur in geringem Umfang Anwendung finden. KLONOWSKI (1999) verwendete MARKOFF-Zufallsfelder *(MARKOFF Random Fields)* in Kombination mit der BAYES-Statistik zur texturbasierten Segmentierung von Luftbildern. Ein ebenfalls auf MARKOFF-Zufallsfeldern basierendes Verfahren zur multiskaligen Segmentierung und Klassifikation von Multispektralbildern schufen KATARTZIS, VANHAMEL & SAHLI (2003). Mit der *Muliscale Region Adjacency Tree* genannten Methode wurde anhand digitaler Luftbilddaten eine Klassifikationsgüte von 95 % erreicht. STEWART et al. (2000) entwickelten ein Verfahren zur Segmentierung von Radar-Daten (*Synthetic Aperture Radar*, SAR) auf Basis eines *simulated-annealing*-Algorithmus. HERMES & BUHMANN (2001) verwendeten zur Segmentierung ein Triangulationsverfahren *(entropy-based polygonization)*. Dieses Verfahren fand seine Weiterentwicklung im *boundary-constrained agglomerative segmentation* (vgl. HERMES & BUHMANN 2004).

2.2.4 Wissensbasierte bzw. Expertensysteme

Grundlagen und Anwendungen wissensbasierter bzw. Expertensysteme werden im Fachgebiet der Künstlichen Intelligenz entwickelt. Diese Verfahren nutzen formalisiertes Vorwissen zur Lösung von komplexen Problemen und ahmen das Verhalten menschlicher Experten nach. Zumeist wird das Wissen anhand von Regeln in eine maschinell auswertbare Form transformiert (regelbasiertes System). Daneben erfolgt die Repräsentation des Wissens häufig in Form semantischer Netze. Sie ermöglichen eine einfache Abbildung hierarchischer und stark vernetzter Wissensstrukturen (z. B. durch Entscheidungsbäume). Insgesamt bestehen Ähnlichkeiten zwischen Expertensystemen und Neuronalen Netzen.

Die einzelnen Regeln folgen dem aus der Programmierung bekannten Wenn-Dann-Sonst-Muster *(if-then-else)*, gleichbedeutend mit einer aus einer Bedingung folgenden Konsequenz. Eine einzelne Bedingung kann aus mehreren logisch verknüpften Bedingungen bestehen. Die Menge aller festgelegten Regeln bildet die Wissensbasis. Kern eines Expertensystems ist ein Inferenzsystem (Inferenz – lat. Schlussfolgerung), welches das Wissen analysiert und verknüpft sowie das Ziehen von Schlussfolgerungen aufgrund gegebener Zusammenhänge erlaubt (vgl. BILL 1999; OPENSHAW & OPENSHAW 1997).

Wissensbasierte Systeme für Fernerkundungsaufgaben bleiben bisher meist der Nutzung durch Experten vorbehalten. Sie dienen häufig der Lösung komplexer Sachverhalte im Rahmen spezieller Forschungsprojekte. Nur wenige Systeme stehen der Allgemeinheit zur Verfügung. Beispiele für verfügbare Expertensysteme im Fernerkundungsbereich sind:

- der pixelbasierte Expert Classifier für ERDAS IMAGINE (vgl. z. B. LECHTENBÖRGER 2001);
- das *per-parcel*-basierte geoAIDA (vgl. z. B. BÜCKNER et al. (2002) sowie
- das segmentbasierte eCognition (vgl. Abschnitt 4.1).

Diese Zusammenstellung zeigt, dass Expertensysteme auf anderen Klassifikationssystemen aufbauen. Die zugrunde liegende Auswertestrategie baut auf unterschiedlichen Grundeinheiten auf (hier Pixel, *parcel* oder Segmente). Im Allgemeinen lassen sich die Vor- und Nachteile der verwendeten Auswerteverfahren auf die kombinierte Nutzung im Rahmen von Expertensystemen übertragen.

So verwenden BÜCKNER et al. (2002) im System geoAIDA ein *per-parcel*-Verfahren zur initialen Bildeinteilung. Kombiniert wird dieser Ansatz mit einem semantischen Netz, welches als Wissensbasis fungiert. Es enthält die Beschreibung der in der Szene vorkommenden Klassen entsprechend dem vorhandenen Vorwissen. MÜLLER et al. (2003) zeigen ein An-

wendungsbeispiel dieses noch in Entwicklung befindlichen Verfahrens anhand von SPOT-3-Daten (20 m Bodenauflösung). Die geringe Klassifikationsgüte von 70 % wird dabei maßgeblich auf die einfließende pixelbasierte Klassifikation zurückgeführt.

2.2.5 Objekterkennung und -extraktion

Unter Verfahren der Objekterkennung und -extraktion *(object recognition, feature extraction*) werden Methoden zusammengefasst, welche das Identifizieren und Extrahieren ausgewählter Objekte *(objects, features)* aus Bilddaten mittels Methoden der Digitalen Bildverarbeitung ermöglichen (BILL & ZEHNER 2001). Diese Verfahren werden auch als bildverstehende Expertensysteme bezeichnet. Wie der Name schon sagt, handelt es sich nicht um Verfahren zur flächendeckenden Klassifikation, sondern vielmehr um die Extraktion einzelner, zumeist gut definierbarer Objekte. Für deren Identifikation sind teilweise äußerst komplexe Erkennungskriterien nötig. Diese Verfahren sollen daher nicht vertiefend betrachtet werden, zumal sich dieser Bereich noch in einer intensiven Entwicklungsphase befindet. Sie finden derzeit vorwiegend im militärischen Bereich zur Erfassung strategisch wichtiger Objekte Anwendung. Beispiele aktueller Softwares sind APEX (PCI Geomatics), FeatureXTR (Hitachi Software Global Technology), Feature Analyst (Visual Learning Systems) und Smart Digitizer (York University).

Einen umfassenden Überblick über die derzeitigen Potenziale der Objekterkennung bieten BALTSAVIAS et al. (2002). Wie in dieser Publikation dargestellt, gibt es derzeit lediglich für künstliche Objekte (sog. *man-made features)*, wie Gebäude, Straßen, militärische Objekte, zweckmäßige Extraktionswerkzeuge. Die Erfassung natürlicher Objekte beschränkt sich momentan fast ausschließlich auf Einzelbäume anhand von Baumkronenmodellen. Die wenigsten dieser Methoden sind derzeit operabel anwendbar. LANG, SCHÖPFER & BLASCHKE (2003) verwenden zur Veränderungsdetektion von Siedlungsgebieten die Software Feature Analyst der Firma Visual Learning Systems. Der innovative Ansatz Smart Digitizer zur automatisierten Erfassung linearer Objekte in Fernerkundungsdaten wurde von HU & TAO (2004) präsentiert.

2.2.6 Vergleichende Methodenbewertung

Unter der Maßgabe der Auswertung sehr hoch auflösender Fernerkundungsdaten (vgl. Abschnitt 2.1.3) werden im Folgenden die oben beschriebenen Verfahren bezüglich ihrer Nutzbarkeit bewertet. Die Vor- und Nachteile der einzelnen Verfahrensgruppen werden kurz zusammengefasst. Anhand verschiedener Bewertungskriterien wird in Tabelle 2.4 eine Gegenüberstellung vorgenommen. Dabei bleiben Expertensysteme unberücksichtigt, da sie auf den anderen genannten Verfahren basieren (vgl. Abschnitt 2.2.4). Auch Verfahren der Objekterkennung werden ausgeklammert, da sie keine vollständige Bildklassifikation ermöglichen.

Da die Anwendung der Auswertungsverfahren auf sehr hoch auflösende Satellitenbilddaten erst seit Beginn ihrer Verfügbarkeit 1999 möglich ist, kann derzeit noch keine abschließende Bewertung erfolgen, welches Verfahren das tauglichste ist. Dies trifft insbesondere auf neue, teils noch in Entwicklung befindliche Auswertestrategien zu, wie z. B. Neuronale Netzwerke. Zudem sind zahlreiche Verfahrenskombinationen, z. B. im Rahmen von Expertensystemen möglich, die eine derartige Einschätzung erschweren. Die Auswahl eines geeigneten Verfahrens hängt darüber hinaus in erheblichem Maße von den zugrunde liegenden Bilddaten sowie der Aufgabenstellung ab. Der Auswertungsmaßstab spielt eine untergeordnete Rolle, da er durch die Auflösung der VHR-Daten vorgegeben wird.

Tab. 2.4: Gegenüberstellung von Auswertungsverfahren.
(Quelle: Eigene Darstellung)

Vergleichskriterien	Klassifikationsverfahren				
	Visuelle Interpretation	Pixelbasierte Klassifikation	*Per-parcel*-Klassifikation	Neuronale Netze	Segmentbasiert
Nötige Eingangsdaten	Bilddaten	Bilddaten	Bild- und Zusatzdaten	Bilddaten	Bilddaten
Haupteinflussfaktor auf die Qualität	Interpretenerfahrung	Training	Training, Qualität der Zusatzdaten	Training	Parameterwahl
Nutzung von Nachbarschaftsbeziehungen	ja	nein	nein	nein	ja
Nutzung von Texturen	ja	möglich	möglich	möglich	möglich
Nutzung von Objekteigenschaften (außer spektrale Signatur)	ja	nein	nein	nein	ja
Trainingsaufwand	sehr hoch	mittel	mittel	hoch	mittel
Automatisierungsgrad	gering	mittel	mittel	mittel	mittel
Eignung für VHR-Daten	gut	gering	gut	mittel	gut

Visuelle Interpretationsverfahren (vgl. Abschnitt 2.2.1) – als klassische Form der Bildauswertung – erbringen noch immer die qualitativ hochwertigsten Ergebnisse, insbesondere bei Kopplung mit modernen digitalen Methoden (z. B. digitale Stereo-Bildauswertung am Bildschirm). Jedoch ist diese Form der Auswertung sehr zeitaufwändig und damit kostenintensiv. Darüber hinaus beinhaltet sie ein hohes Maß an Subjektivität. Die Erkennungsgüte ist maßgeblich abhängig von der Erfahrung des Bildinterpreten. Neben inhaltlichen Fehlinterpretationen und Abgrenzungsungenauigkeiten, welche zum Teil bei großen Gebieten aus der Vielzahl der Interpreten resultieren, sind die Ergebnisse meist nicht vollständig nachvollziehbar und reproduzierbar. So erfolgt z. B. die Zuordnung zu verschiedenen Mischwaldklassen nur aufgrund geschätzter Laub- und Nadelwaldanteile.

Die Vorteile digitaler, pixelbasierter Verfahren (vgl. Abschnitt 2.2.2) sind die exakt messbare (quantitative), differenzierte und reproduzierbare Erfassung spektraler Eigenschaften. Aufgrund der Anwendung statistischer Verfahren ist das Ergebnis zumeist objektiver als eine visuelle Interpretation. Weitere Vorteile der computergestützten Auswertung sind die Robustheit, z. B. gegenüber optischen Täuschungen, die Verarbeitungsmöglichkeiten multispektraler Bildinformationen und die sichere Unterscheidung sehr ähnlicher Grauwerte. Dennoch besteht auch bei digitalen Klassifikationen ein subjektiver Einfluss des Bearbeiters durch die Auswahl von Klassenmerkmalen. Statistische Verfahren erlauben jedoch ohne den Einsatz künstlicher Intelligenz kaum Flexibilität und führen deshalb bei Störeinflüssen (z. B. Einflüsse durch Atmosphäre, Geländerelief etc.) zu Fehlern (vgl. HILDEBRAND 1996). Zwischen den von Trainingsgebieten repräsentierten Punktwolken treten bei steigender spektraler Inhomogenität häufig Überschneidungen auf. Nur teilweise kann dieses Problem durch eine Hauptkomponenten-Transformation behoben werden. Zudem werden die meisten Annahmen der Ansätze (z. B. GAUSS-Verteilung bei einer *Maximum-Likelihood*-Klassifikation) nur näherungsweise erfüllt, wodurch sich die Anwendung der Multispektral-Klassifikation in der Praxis schwierig gestaltet (vgl. ALBERTZ 2001).

Durch die Entwicklung vielfältiger pixelbasierter statistischer und nicht-statistischer Ansätze konnte eine Optimierung der merkmalsraumbasierten Klassifikationsverfahren erreicht werden. Bei einer mit steigender geometrischer Auflösung wachsenden spektralen Inhomogenität führen diese Ansätze jedoch zwangsläufig zu unerwünschten Effekten (vgl. Abschnitt 2.1.3). Das so genannte *Salt-and-Pepper*-Rauschen äußert sich durch unklassifizierte

Lücken und Fehlklassifikationen, da einzelne Pixel atypische, gemischte oder unbekannte (in den Trainingsdaten nicht enthaltene) Spektralsignaturen repräsentieren. Zudem nutzt diese Form der Auswertung lediglich die spektralen Bildeigenschaften der einzelnen Pixel. Damit bleibt ein großer Teil der Bildinformationen ungenutzt (z. B. Flächengröße und -form, Nachbarschaft, Kontext, Lage).

Die Nachteile der klassischen, pixelbasierten, rein statistischen Auswerteverfahren werden durch neuere Verfahrensentwicklungen teilweise behoben. Die weiterentwickelten Ansätze, wie Neuronale Netze (vgl. Abschnitt 2.2.2.5), Bildsegmentierung (vgl. 2.2.3), Expertensysteme (vgl. 2.2.4) oder Objekterkennung (vgl. 2.2.5), kommen dem menschlichen visuellen Auswertungsprozess näher. Sie werden in der Bildverarbeitung den *high-level*-Methoden zugeordnet und bilden den Übergang zur Künstlichen Intelligenz. Von diesen Methoden konnte sich bisher lediglich die Segmentierung im Bereich der Fernerkundung etablieren. Sowohl Neuronale Netze als auch die Objekterkennung befinden sich noch in einer Phase intensiver Entwicklung.

Nach Abwägung der Vor- und Nachteile sowie des Entwicklungsstandes der Verfahren wird im Rahmen dieser Arbeit schwerpunktmäßig die Auswertungsstrategie der Bildsegmentierung mit anschließender Klassifikation verfolgt. Eine detaillierte Gegenüberstellung von im Fernerkundungsbereich aktuell verfügbaren Segmentierungsprogrammen erfolgt in Abschnitt 4.3. Weiterhin sprechen die im Abschnitt 2.1.3 diskutierten Auswirkungen sehr hoch auflösender Fernerkundungsdaten für die Anwendung solcher Verfahren. Durch eine Segmentierung im Vorfeld der Klassifikation wird die spektrale Varianz nahezu beseitigt. Zudem stehen als klassenbeschreibende Merkmale Formeigenschaften sowie Kontextinformationen neben den Spektralinformationen zur Verfügung. Die Einbettung segmentbasierter Verfahren in Expertensysteme ermöglicht darüber hinaus die Nutzung von Entscheidungsbäumen oder *fuzzy logic* zur Optimierung der Klassifikation.

Zu einer ähnlichen Einschätzung bezüglich der Eignung verschiedener Ansätze zur Auswertung sehr hoch auflösender Fernerkundungsdaten kommt BOCK (2003). Eine segmentbasierte Klassifikation (Expertensystem eCognition) ist demnach für die Bearbeitungsmaßstäbe zwischen 1 : 5 000 und 1 : 25 000 am besten geeignet. Die neben einer Feldkartierung und einer Luftbildinterpretation verglichenen Ansätze – ERDAS IMAGINE Expert Classifier (pixelbasiertes Expertensystem), *kernel reclassification* und *case based reasoning* – sind nur für geringer aufgelöste Bilddaten geeignet oder befinden sich noch in Entwicklung.

2.3 Probleme der Fernerkundung

Die in der Forschung gut etablierte Anwendung von Methoden der Fernerkundung weist verschiedenartige Akzeptanzprobleme seitens der Endanwender auf. Einige der dazu beitragenden Faktoren werden im Folgenden dargestellt und diskutiert.

2.3.1 Umbrüche in der Fernerkundung

Die Entwicklung der Fernerkundung in jüngster Zeit war geprägt von einer enormen Dynamik. Sie wurde insbesondere durch den technologischen Fortschritt (z. B. Rechenkapazität von Computern) angetrieben. Darüber hinaus fanden aber in nahezu allen anderen Bereichen (z. B. Sensorentwicklung, Datenübertragung, Antriebstechnik etc.) vielfältige Innovationen statt.

Für die hier betrachteten Bereiche wird sogar von einem Paradigmenwechsel gesprochen – sowohl bezüglich heute verfügbarer Daten (vgl. FRITZ 1999; GRUBER et al. 2003) als auch

deren Auswerteverfahren (vgl. BLASCHKE 2000a; SCHNEIDER et al. 2000). Die Endanwender von Fernerkundungstechnologien warten jedoch auf operationell verfügbare Daten und Methoden, bevor sie mit der Nutzung beginnen. Daher gibt es derzeit wenige ökonomisch sinnvolle Anwendungen von Erdbeobachtungsdaten neben militärisch-geheimdienstlichen und meteorologischen Zwecken. Dieses Ungleichgewicht zwischen aufwändiger Weltraumtechnologie und Forschung einerseits sowie praxisorientierter Anwendung andererseits beschreibt auch LÖFFLER (1994). Lediglich Spezialanwendungen, wie das *Precision Farming*, konnten sich in den letzten Jahren etablieren. Auch die vorrangigen Anwender aus dem öffentlichen Sektor machen aus diesem Grund bisher nur wenig Gebrauch von der Fernerkundung. Als ein positives Beispiel ist hier das Integrierte Verwaltungs- und Kontrollsystem (InVeKoS) für Europäische Landwirtschaftsbeihilfen zu nennen, wobei Fernerkundungsdaten jedoch lediglich als Abgrenzungsgrundlage dienen.

Die Entwicklung der zur Verarbeitung und Auswertung verwendeten Methoden konnte bisher mit der Weiterentwicklung der Bilddaten nicht Schritt halten. Auf die Verfügbarkeit sehr hoch auflösender Fernerkundungsdaten und deren spezifische Probleme (vgl. 2.1.3) wurde seitens der Produzenten von Bildverarbeitungssoftware zu spät reagiert, obwohl VHR-Daten lange zuvor angekündigt waren und ihre Verfügbarkeit simuliert wurde. Sämtliche Programme hatten (und haben z. T.) trotz der starken und weiter wachsenden Rechnerleistung Verarbeitungsprobleme. Ein Beispiel hierfür ist das Adressierungsproblem durch 32-Bit-Software, wodurch die Bearbeitung großer Datenmengen (>2,1 Gigabyte, z. B. temporäre Dateien, Mosaikierung etc.) extrem behindert wird.

Im Fall der seit Anfang 2000 verfügbaren sehr hoch auflösenden Satellitendaten (vgl. Abschnitt 2.1.2) bestanden anfangs vielfältige Bearbeitungsschwierigkeiten. So war die Verarbeitung von 16-Bit-Daten mit einzelnen Fernerkundungs-Programmen nicht möglich. Zudem erwiesen sich viele herkömmliche Verarbeitungs- und Auswertungsmethoden aufgrund der Datenmenge, der Auflösung etc. als nicht mehr zweckmäßig. Alternativen stehen erst nach und nach zur Verfügung (vgl. Abschnitt 3.2).

Seit der Bereitstellung digitaler Sensoren mit photogrammetrischer Qualität erlebt die flugzeugbasierte Fernerkundung einen Entwicklungsschub. Mehrere derartige Systeme befinden sich in der Endphase der Testanwendung und stehen seit kurzer Zeit den Nutzern zur Verfügung (vgl. Abschnitt 3.1.3). Sie werden in den kommenden Jahren die analogen Kameras ablösen. Diese Systeme zeichnen sich neben ihrer hervorragenden geometrischen Auflösung (Dezimeterbereich) durch eine hohe spektrale Auflösung (VIS, NIR, Pan) aus. Zudem können die Daten mittels *in-flight*-Navigationssystemen sehr genau und kostengünstig entzerrt und orthorektifiziert werden (vgl. EHLERS 2002). Einige Aufnahmesysteme besitzen darüber hinaus die Möglichkeit, Stereodaten aufzuzeichnen. Diese Daten besitzen daher das weitaus größte Potenzial für großmaßstäbliche Anwendungen (z. B. Orthobilddaten für die Landesvermessung etc.). Verarbeitungsprobleme ergeben sich derzeit durch das immense Datenvolumen sowie die noch in Entwicklung befindlichen Vorprozessierungsmethoden der Daten.

Die großen Fortschritte der Bildverarbeitung und Mustererkennung im medizinischen und industriell-technischen Bereich lassen sich kaum auf die Aufgaben der Fernerkundung übertragen, da die Datengrundlagen sehr unterschiedlich sind. Die in sehr hoch auflösenden Fernerkundungsdaten abgebildeten Objekte und Muster sind meist komplexer Natur. Für deren Extraktion sind hoch entwickelte Algorithmen nötig (vgl. ALBERTZ 1999). Dennoch sind erste existierende Programme, wie z. B. aus den Bereichen Bildsegmentierung, Expertensysteme, Objekterkennung oder Neuronale Netze, herkömmlichen Auswertungsverfahren der Fernerkundung überlegen.

Um einen breiten Anwenderkreis zu erschließen, müssen Lösungen für die Bearbeitung deren komplexer Probleme bereitgestellt werden, die zugleich verständlich, nachvollziehbar, standardisiert und übertragbar sind. Insgesamt ist die derzeitige Entwicklung noch zu wenig nutzerorientiert.

2.3.2 Mangelnde Anwenderorientierung

Fernerkundungsanwendungen werden von Nutzern nur dauerhaft akzeptiert, wenn sich daraus Vorteile gegenüber den herkömmlichen Vorgehensweisen ergeben (Kosten, Qualität, Bearbeitungsgeschwindigkeit etc.). Zudem müssen derartige Anwendungen bzw. Lösungen praxisreif, d. h. operationell sein (vgl. KENNEWEG 2002) und die resultierenden Ergebnisse sollen gewisse Standards erfüllen. Die Umsetzung dieser Nutzeranforderungen ist aus verschiedenen Gründen oftmals nicht gegeben, z. B. durch nicht fernerkundungsgerechte Objektartenschlüssel, undurchsichtige Vorgehensweisen etc.

Die fehlende Operationalisierung zeigt sich auch bei den bisherigen experimentellen Anwendungen im Forschungsbereich. Zumeist erfolgt lediglich die Bearbeitung kleiner, häufig idealisierter Beispielgebiete mit wenigen, oft homogenen Nutzungsklassen, deren Auswertungsverfahren kaum übertragbar sein dürften.

In der Vergangenheit erfolgte auch seitens der Datenanbieter eine zu geringe Nutzerorientierung. Dies beginnt sich erst seit wenigen Jahren zu ändern. Ein positives Beispiel stellt hierbei der IKONOS-Satellit dar. Dessen Sensoren besitzen eine gute geometrische und spektrale Auflösung, um die Daten für vielfältige Zwecke einsetzen zu können. Die mangelnde Nutzerorientierung war eine maßgebliche Folge der staatlichen Satellitenprogramme sowie geheimdienstlich-militärischer Restriktionen. Mit der Marktöffnung für kommerzielle Anbieter von Fernerkundungsdaten verbessert sich die Situation zunehmend.

Darüber hinaus haben sich durch das verstärkte Angebot kommerzieller Betreiber die Bezugsmodalitäten und die Bereitstellung von zusätzlichen Sensorinformationen stark verändert. Erfreulich ist die in der Regel zügige Aufnahme und Lieferung der Daten nach eingegangener Bestellung. Allerdings sind gleichzeitig die Datenkosten stark gestiegen, da die Firmen im Gegensatz zu staatlichen Satellitenprogrammen profitorientiert arbeiten müssen. Damit einhergehend werden – gleichzeitig bedingt durch die Konkurrenzsituation – spezielle Informationen zum Teil nicht veröffentlicht. Beispielsweise zielt das Geheimhalten der vollständigen Sensorinformationen von IKONOS durch Space Imaging darauf ab, eine selbstständige Datenveredlung (insbesondere Georeferenzierung) durch die Nutzer zu behindern, um die firmeneigenen, hochpreisigen Produkte verkaufen zu können (vgl. Abschnitt 3.2.1).

Die hohen Kosten für Fernerkundungsdaten, Auswertungssoftware und optimale Hardware schrecken viele Nutzer ab. Hinzu kommen Aufwendungen für das nötige *Knowhow* der Mitarbeiter sowie der Zeitbedarf der Datenauswertung. Nur wenn Kosten und Nutzen in einem ausgeglichenen Verhältnis stehen, wird sich die Akzeptanz erhöhen.

Ein Mangel besteht ebenfalls auf dem Gebiet der Standardisierung, wobei das Ziel die Schaffung vergleichbarer Datengrundlagen ist. Allerdings kommen Einflüsse auf das spektrale Abbildungsverhalten bei sehr hoch auflösenden Fernerkundungsdaten häufig verstärkt zur Geltung. Diese Einflüsse resultieren aus unterschiedlichen Aufnahmezeitpunkten mit unterschiedlichen atmosphärischen und phänologischen Bedingungen, der Beschaffenheit der Geländeoberflächen (topographische Einflüsse) sowie unterschiedlichen Blickwinkeln und Sonnenständen. Erste Ansätze zur Beseitigung bzw. Verringerung dieser Einflüsse bietet das ERDAS IMAGINE Modul ATCOR (atmosphärische und topographische Korrektur, vgl. Abschnitt 3.2.2). Diese Auswirkungen führen u. a. zu Einschränkungen in der Vergleich-

barkeit multitemporaler Daten oder der Übertragbarkeit von Klassifikationsmerkmalen. Gleichzeitig sind robuste Algorithmen zur Datenfusion erforderlich, um das Informationspotenzial der VHR-Daten nutzen zu können (vgl. ZHANG 2002; vgl. Abschnitt 3.2.3).

Forschungsbedarf besteht ebenso in einer weiteren Automatisierung von Bearbeitungsschritten zur Etablierung operationeller Prozessketten. Hierdurch können subjektive Einflüsse weitestgehend minimiert und die Reproduzierbarkeit erhöht werden.

Insbesondere für den behördlichen Einsatz von Fernerkundungsdaten existieren zumeist deutliche Kostenrestriktionen. Kooperative Ansätze sind vermehrt erforderlich, da eine alleinige Datennutzung mit nur einer Zweckbestimmung heute meist nicht mehr finanzierbar ist. Die Nutzungsrechte sollten für mehrere Behörden gleichzeitig vorhanden sein, evtl. auch über administrative Einheiten hinweg (grenzübergreifend, regional und kommunal nutzbar etc.). Die hierfür nötigen Strukturen müssen erst noch geschaffen werden. Zudem ist eine größere Flexibilität seitens der Behörden erforderlich. Sinnvoll erscheint eine Datenaufnahme unter der Regie der mit der Landesvermessung beauftragten Behörden. Die unterschiedlichen Nutzeranforderungen (Aufnahmezeitpunkte etc.) müssten zuvor eruiert und wenn möglich homogenisiert werden. Die Beschaffung der Daten könnte weiterhin durch eine Freigabe für eine kommerzielle Mitnutzung oder für Forschungszwecke kofinanziert werden.

2.3.3 Integration von GIS und Fernerkundung

Die bisher weitgehend getrennten Disziplinen GIS und Fernerkundung (sowie weitere benachbarte Disziplinen, wie Photogrammetrie, Bildverarbeitung, Informatik etc.) verschmelzen zunehmend miteinander zur Geoinformatik (vgl. BLASCHKE & STROBL 2001; EHLERS 2002). Die Entwicklung verläuft in Richtung integrativer Systeme, wie sie bereits 1989 von EHLERS, EDWARDS & BEDARD angeregt wurde. Schon heute gibt es einen vielfältigen Austausch zwischen beiden Fachgebieten, sei es durch die Integration von Daten oder die Nutzung von Verarbeitungstechniken. Durch diese Integration entstehen mannigfaltige Synergien, welche die Nutzungsakzeptanz zukünftig erhöhen wird.

Die Fernerkundung liefert dabei zunehmend aktuelle Datengrundlagen für GIS-Aufgaben, denn konventionelle Verfahren, wie die Vor-Ort-Vermessung, können diese Aufgabe nicht mehr adäquat erfüllen. Eine Schlüsselrolle wird somit zukünftig der Informationsextraktion obliegen. Das Zusammenwachsen dieser Technologien hat durch die Kompatibilität von Datenformaten begonnen. Die Einbindung von Fernerkundungsdaten als bloße Bildebene aus einer anderen Datenquelle *(data fusion)* ist dabei nicht mit Integration gleichzusetzen. Hybride Systeme, wie ArcView, ArcGIS oder ERDAS IMAGINE, erlauben die Nutzung beider Daten-Formate (Datenintegration). Jedoch existiert derzeit noch kein zusammengeführtes System mit einer vollständigen Analyseintegration (vgl. EHLERS 2002), wodurch die breite Anwendung von Fernerkundungstechniken behindert wird. Rasterdaten werden nach wie vor auf Rasterbasis ausgewertet. Mithilfe erster existierender Softwarelösungen aus dem Bereich der Bildsegmentierung, die auch im Rahmen dieser Arbeit Anwendung finden, wird diese Integrationsstufe erstmals näherungsweise erreicht. Die Ursache der mangelnden Analyseintegration ist zumeist auf die unterschiedlichen Datenformate Raster vs. Vektoren zurückzuführen.

Der Sachverhalt der Raster-Vektor-Problematik soll hier noch etwas vertiefend betrachtet werden. Es handelt sich dabei zwar nicht um ein Problem der Fernerkundung als solches, es ist vielmehr ein Grundproblem der Geoinformatik. Darüber hinaus ist es ein Hauptgrund für die mangelnde GIS-Integration von Fernerkundungsverfahren: *"The integration of remote sensing an GIS is limited by the inability to fully understand and implement a transformation between these two representations of information […]"* (APLIN et al. 1999: 223).

Oft werden die Raster- bzw. Vektor-Datenmodelle als unterschiedliche ‚Welten' bezeichnet, da sie quasi unterschiedlichen Philosophien folgen. Räumliche Daten werden durch beide Datenmodelle in verschiedener Weise repräsentiert. Die Abbildung der Fernerkundungsdaten erfolgt in regelmäßigen Rasterzellen. Die Mehrheit der thematischen GIS-Daten wird durch Vektoren in Form von Punkten, Linien und Flächen repräsentiert. Die Aussage von TOMLIN (1990) verdeutlichte die Zwietracht der Nutzer der Datenmodelle: „*Yes, raster is faster, but raster is vaster, and vector just seems more corrector.*" Beide beanspruchten lange für sich, das Nonplusultra zu sein. Dabei haben beide Raumbezüge geographischer Daten in Abhängigkeit vom Anwendungszweck ihre spezifischen Vor- und Nachteile.

Durch Rasterdaten wird die reale Welt in Form von diskreten, zumeist quadratischen Einheiten abgebildet, die aufgrund ihrer Geometrie (in Abhängigkeit von deren Rasterweite bzw. Maschengröße) ungenau sind. So werden Punkte und Linien als Flächen dargestellt, gebogene Linien führen zu treppenförmigen Rasterstrukturen und die Objektmerkmale Form, Lage und Größe werden verfälscht. Die Einteilung in Rasterzellen erfolgt dabei willkürlich und orientiert sich nicht an Objektgrenzen. Vielmehr werden Teile von Objekten oder Mischungen verschiedenartiger Objekte abgebildet – die ihrerseits wiederum zu Problemen der inneren Varianz oder zu Mischpixeln führen (vgl. Abschnitt 2.1.3). Die einzelnen Rasterzellen repräsentieren einen mittleren Wert (Bildinformationen, Messwerte etc.), der für die gesamte Fläche der Rasterzelle gilt. Rasterdaten liegen in Matrixform (Zeilen und Spalten) vor und besitzen eine implizite räumliche Positionsangabe durch das Zeilen-Spaltensystem. Das Rasterdatenmodell erfordert einen höheren Speicherbedarf als Vektordaten.

Vektordaten stellen ein vereinfachtes und abstrahiertes Modell der realen Welt dar. Die Form geographischer Objekte wird dabei durch eine Reihe geordneter x,y-Koordinaten (Topologie) definiert. Mit jedem Objekt können beliebige Attributinformationen verknüpft werden. Durch Vektoren werden Grenzen zumeist akkurater und kartographisch ästhetischer wiedergegeben, da sie eher dem optischen Empfinden des Menschen entsprechen. Die Bildung der enthaltenen Objekte oder die Zuweisung von Objekteigenschaften ist ein Resultat vorheriger Interpretation und Identifikation. Während sich Vektordaten stufenlos vergrößern lassen, sind Rasterdaten gemäß ihrer Auflösung Grenzen gesetzt.

Rasterdaten erlauben im Vergleich zu Vektorgeometrien häufig umfassendere Berechnungen und Analysen. Die Kartierungsgenauigkeit beider Verfahren ist insbesondere abhängig von der räumlichen und thematischen Auflösung. Erstere meint im Falle der Raster deren Rasterweite, im Falle der Vektoren wird meist die Mindesterfassungsgröße betrachtet (kleinstes erfasstes Element in Abhängigkeit vom Aufnahmemaßstab). Die thematische Auflösung beschreibt die inhaltliche Tiefe, d. h. die Anzahl der Klassen.

Eine diskrete Abgrenzung räumlicher Sachverhalte, wie sie in Karten und digitalen Vektor-Daten vorgenommen wird, ist vielfach erwünscht oder erforderlich. Anders als bei anthropogen geprägten Objekten *(man-made features)* existieren in der Natur jedoch häufig keine scharfen Abgrenzungen, es handelt sich vielmehr um Übergänge. Das diese dennoch scharf abgegrenzt werden, ist Folge einer notwendigen Generalisierung. Karten und Vektor-Daten implizieren also eine Genauigkeit, die häufig nicht gegeben ist. Rasterdarstellungen sind in Abhängigkeit von ihrer Auflösung im begrenzten Maße in der Lage, kontinuierliche Übergänge abzubilden (z. B. Höhenlinienkarte vs. Höhenmodell).

Aufgrund der genannten Vorteile werden Flächennutzungskartierungen heute dominiert von Vektor-GIS-Informationen. Fernerkundungsdaten sind jedoch sehr komplex und heterogen, weshalb eine automatisiert daraus abgeleitete Kartierung nahezu immer irreguläre bzw. fraktale (ausgefranste) Grenzen aufweisen wird. Dies ist eine Folge der willkürlichen Einteilung der realen Welt in Pixel und deren ungeneralisierter Auswertung durch Bildanalyse-

systeme. Die Bilddaten widerspiegeln lediglich die natürlichen Gegebenheiten, wobei z. B. eine Waldgrenze (in Abhängigkeit vom Betrachtungsmaßstab) keine Linie darstellt.

Die Anforderungen der GIS-Nutzer erfordern zumeist die Abbildung der Landnutzung *(land use)*. Fernerkundungsdaten können dem nur in begrenztem Umfang gerecht werden. Sie bilden lediglich direkt die Landbedeckung *(land cover)* ab. Diese ist zudem stark abhängig von verschiedenen Aufnahmeparametern, wie Aufnahmezeitpunkt, Phänologie etc.. Im Rahmen einer Landnutzungskartierung werden häufig über eine Landbedeckungskartierung hinausgehend qualitative Merkmale von Objekten genutzt (zumeist unter Einbeziehung von Zusatzinformationen), die in diesem Maße bei der Auswertung von Fernerkundungsdaten nicht verfügbar sind. Lediglich die visuelle Interpretation erlaubt dies in vollem Umfang. Neuere Auswerteverfahren, wie etwa die segmentbasierte Klassifikation, ermöglichen die Nutzung von Zusatzinformationen sowie Objektmerkmalen zur Klassifikation, wodurch zum Teil eine Klassifikation der Landnutzung ermöglicht wird (vgl. Abschnitt 4.1.2). So können beispielsweise spektral gleiche Rasenflächen und Sportplätze unterschieden werden.

2.4 Zum Einsatz der Fernerkundung in Landschaftsplanung und Landschaftsökologie

Die Geschwindigkeit und Intensität, mit der das Gesicht der Erde verändert wird, hat in den letzten Jahren stark zugenommen. Damit steigt auch der Bedarf an aktuellen Zustandsinformationen und Planungsdaten. Die derzeitigen Veränderungen der Umwelt können mit herkömmlichen Aufnahmeverfahren (Vor-Ort-Vermessung) nicht mehr adäquat erhoben werden. Zudem ist diese Form der Aktualisierung äußerst arbeitsintensiv und kostspielig. Demgegenüber ist in der Erfassung und Aktualisierung von Geoinformationen eine wesentliche Aufgabe der Fernerkundung zu sehen (vgl. HEIPKE 2003). Neben der rasanten technischen Entwicklung wird die Nachfrage nach aktuellsten Daten in Zukunft noch stärker dazu führen, dass GIS-Anwender Fernerkundungsdaten nutzen. Unterstützt wird diese Entwicklung durch einen besseren Datenzugang, qualitativ höherwertige Daten sowie moderne Verfahren der Bildauswertung (vgl. BLASCHKE et al. 2002).

In den hier fokussierten Anwendungsbereichen Landschaftsplanung und Landschaftsökologie besitzt die Geoinformatik und speziell die Fernerkundung einen hohen Stellenwert (vgl. NAVEH & LIEBERMANN 1994; WALZ 2002). Die Fernerkundung wird immer häufiger zum Lieferanten aktueller Daten. Zudem hat die Nutzung von Fernerkundungsmethoden eine lange Tradition in der Landschaftsökologie, die auf TROLL (1939) zurückgeht. Nach BASTIAN & SCHREIBER (1999) ist insbesondere die Analyse der Flächennutzungsstruktur fundamentaler Bestandteil der Landschaftsanalyse. Sie bildet eine wichtige Voraussetzung für nachfolgende Untersuchungsschritte, wie der Landschaftsdiagnose oder dem Landschaftsmonitoring.

Bisher fanden Fernerkundungsdaten bereits rege Anwendung zur Auswertung aktueller Sachverhalte, sei es in der Landesvermessung, der Landes- und Regionalplanung oder zur Biotop- und Nutzungstypenkartierung (BNTK). Die Verfügbarkeit sehr hoch auflösender Bilddaten ermöglicht neue Anwendungen sowie eine Erweiterung des Nutzerkreises. Diese Entwicklung wird sich aber nur positiv vollziehen, wenn die in Abschnitt 2.3 diskutierten Anforderungen der Anwender in ausreichendem Maße berücksichtigt werden.

Unter Landschaftsökologie wird die Forschungsrichtung verstanden, die das komplexe räumliche, zeitliche sowie funktionale Wirkungsgefüge zwischen den lebenden Organismen und ihrer Umwelt innerhalb eines Ausschnittes der Landschaft untersucht (vgl. BASTIAN & SCHREIBER 1999). Wichtige Untersuchungsmethoden sind die Landschaftsanalyse, -diagnose,

-bewertung und -prognose, welche raumbezogene Grundlagen für die Landschaftsplanung darstellen können. Die Potenziale, Funktionen, Belastbarkeit und ökologische Stabilität von Landschaften stehen im Mittelpunkt des Forschungsinteresses.

Die Landschaftsplanung stellt das grundlegende Planungsinstrument des Naturschutzes und der Landschaftspflege dar. Rechtlich verankert ist dieses Instrumentarium im Bundesnaturschutzgesetz. Das Planungssystem ist ebenenübergreifend, wobei bundeslandweite Landschaftsprogramme sowie regionale Landschaftsrahmenpläne die Basis bilden. Darauf aufbauend werden auf örtlicher Ebene die Landschaftspläne für Gemeindegebiete erstellt. Ziel dieser Planungen ist der Schutz natürlicher Ressourcen, der nicht nur durch die Ausweisung von Schutzgebieten erfolgt, sondern auch durch flächendeckende Konzepte zum Erhalt und der langfristigen Entwicklung von Natur und Landschaft (vgl. BASTIAN & SCHREIBER 1999; BFN 2002a).

Für die Landschaftsplanung und die eng damit verbundene Landschaftsökologie ist die Fernerkundung ein Instrument zur Bestandsaufnahme sowie zur Beobachtung und Bewertung des Landschaftszustandes. Ein Vergleich von Daten unterschiedlicher Aufnahmezeitpunkte ermöglicht die Erfassung raum-zeitlicher Veränderungen der Landschaft. Daraus lassen sich Aussagen über die Dynamik der Landschaftsentwicklung ableiten. In der Landschaftsökologie gewinnt die fortlaufende Überwachung der Entwicklung (Monitoring) gegenüber der bloßen Beschreibung des Zustandes zu einem bestimmten Zeitpunkt (Inventarisierung, *Inventoring)* zunehmend an Bedeutung (vgl. ALBERTZ 2001). Zur Bewertung des Landschaftszustandes werden dabei häufig Landschaftsstrukturmaße herangezogen (siehe Abschnitt 5.2).

Landschaftsplanung und Landschaftsökologie sind darüber hinaus aufgrund ihres Flächenbezuges in besonderem Maße auf aktuelle raumbezogene Daten angewiesen. Fernerkundungsgestützte Verfahren können zur Erfassung oder Aktualisierung derartiger Geobasisdaten (z. B. ATKIS, BNTK) beitragen.

Einen weiteren wichtigen Beitrag leistet die Fernerkundung für Zwecke der Landschaftsvisualisierung und damit zur Beurteilung des Landschaftsbildes (vgl. HAEFNER 1999). Neben nationalen Naturschutzzielen (vgl. Bundesnaturschutzgesetz) erfordern internationale Vereinbarungen (z. B. Natura 2000) verstärkt die Überwachung von Lebensräumen. So brachte die Flora-Fauna-Habitat-Richtlinie (FFH-RL, 92/43/EWG) der Europäischen Union Aufwind für den Einsatz der Fernerkundung. Die darin vorgesehene Berichtspflicht über ausgewiesene FFH-Gebiete kann durch ein fernerkundungsbasiertes Monitoring maßgeblich unterstützt werden (vgl. BLASCHKE 2002; JANOTH et al. 2002; LANG et al. 2003; WEIERS et al. 2003).

Tabelle 2.5 stellt die Anwendungspotenziale sehr hoch auflösender, optischer Fernerkundungsdaten in Landschaftsplanung, Landschaftsökologie und begleitenden Fachplanungen überblicksartig dar. Dabei werden sowohl satelliten- als auch flugzeuggestützte Anwendungen einbezogen. Für eine ausführliche Diskussion der ausgewählten Anwendungsbeispiele – der fernerkundungsbasierten Landschaftsanalyse sowie der automatisierten Aktualisierung digitaler Geobasisdaten – wird auf Kapitel 5 und 6 verwiesen.

Die genannten Beispiele wurden im Rahmen von vielfältigen Gesprächen, Fachvorträgen und -publikationen eruiert, auf deren ausführliche Darstellung wenn möglich hingewiesen wird. Viele der Aufgaben sind nur in Kombination mit GIS lösbar (z. B. Modellierungen, Geometrieveränderungen von Vektordaten etc.), wobei Fernerkundungsdaten lediglich unterstützend zum Einsatz kommen. Zum Teil umfasst die Darstellung auch potenzielle Anwendungen, die derzeit noch nicht realisiert, jedoch von Nutzerseite erwünscht sind.

Tab. 2.5: Anwendungsmöglichkeiten sehr hoch auflösender Fernerkundungsdaten in der Landschaftsplanung und Landschaftsökologie sowie deren Nachbardisziplinen. (Quelle: Eigene Darstellung)

Anwendungen	Beispielhafte Publikationen
Landschaftsanalyse – Erfassung/Kartierung der aktuellen Landbedeckung/-nutzung	NEUBERT & MEINEL 2002a
Nutzung zur Veränderungsanalyse *(change detection)* multitemporaler Aufnahmen oder Vergleich mit GIS-Daten	LANG, SCHÖPFER & BLASCHKE 2003
Qualitätsanalyse bestehender Daten und Karten	HOFFMANN et al. 2000
Aktualisierung bzw. geometrische Anpassung von Geobasisdaten (ATKIS, BNTK, ALK, weitere Kataster, wie Baumkataster etc.)	NEUBERT & MEINEL 2002b; HOFFMANN 2001
Biotoptypenkartierung	NEUBERT & MEINEL 2002b; LESER 2002; GÄHLER et al. 2002, LANG et al. 2003, SEILER et al. 2004
Monitoring von Landschaftsveränderungen (Beweissicherung, Erfolgskontrolle von Naturschutzmaßnahmen, Veränderungsnachweise, FFH-Monitoring, Umwelt-, Biotop-, Schutzgebietsmonitoring)	BLASCHKE 2002; JANOTH et al. 2002; LANG et al. 2003; WEIERS et al. 2004; SELL, GRUBINGER & EISL 2004; LUFTBILD UND PLANUNG 2004
Pflege- und Entwicklungsplanung von Schutzgebieten	–
Umweltverträglichkeitsprüfung, Landschaftspflegerische Begleitpläne (Beurteilung von Eingriffs- und Ausgleichsmaßnahmen)	–
Ableitung homogener Landschaftseinheiten als Berechnungsgrundlagen von Landschaftsstrukturmaßen	BLASCHKE 2001; NEUBERT & BLASCHKE 2004
Bestimmung und Beurteilung der Biodiversität	IVITS & KOCH 2003
Erstellung von Satellitenbildkarten (ohne/mit überlagerten Vektorinformationen)	–
Stadtinformationssysteme, Stadtmodelle (in Kombination mit DOM), Stadtstrukturtypenkartierung	PETRINI-MONTEFERRI et al. 2001; MÖLLER 2003; BAUER & STEINNOCHER 2001
Versiegelungskataster	PILZ & STROBL 2002
3D-Visualisierungen, Höhenlinienkarten (Modellierungsaufgaben, z. B. Überflutungsbereiche) (in Kombination mit DOM)	MÖLLER 2003
Dokumentation landwirtschaftlicher Produktion	– (Anbaukontrollsystem InVeKos)
Landwirtschaftliche Entwicklungsplanung	–
Flurbereinigung	–
Desastermonitoring	VAN DER SANDE 2001
Forst- und Waldschadenskartierung	DE KOK 2001; HESE 2001; HOFFMANN 2001
Naturschutzfachliche Informationen (Biotopverbund- und Schutzgebietsplanung)	–
Straßenbau (Trassenoptimierung, Suche und Erfolgskontrolle von Ausgleichs- und Ersatzmaßnahmen)	–

Teil II:
Datengrundlagen und Methodik

„Wir müssen uns erheben über die Erde, hoch in die Atmosphäre und darüber hinaus – erst dann werden wir die Welt verstehen in der wir leben.“

SOKRATES (470-399 v. Chr.)

3 Datengrundlagen und Vorverarbeitung

3.1 IKONOS-Satellitenbilddaten

Die in Abschnitt 2.1.2 genannten generellen Eigenschaften sehr hoch auflösender Fernerkundungssensoren gelten gleichzeitig für den im Rahmen dieser Arbeit betrachteten IKONOS-Sensor. Sie werden im Folgenden ausführlich spezifiziert. Anschließend wird die Vorverarbeitung der IKONOS-Daten beschrieben.

3.1.1 Allgemeine Charakterisierung

Am 24. September 1999 wurde mit IKONOS2 der erste kommerzielle Sensor erfolgreich in den Orbit befördert, der seit März 2000 operationell Daten mit einer geometrischen Auflösung im Ein-Meter-Bereich liefert. Mit diesem Satelliten begann die Ära der sehr hoch auflösenden Fernerkundungsdaten (0,5 bis 1 m Bodenauflösung). Die wichtigsten Eigenschaften des IKONOS-Sensors OSA *(Optical Sensor Assemby)* sind in Tabelle 3.1 zusammengefasst.

Tab. 3.1: Eigenschaften des IKONOS2-Sensors OSA.
(Quelle: SPACE IMAGING 2003a; verändert)

Startdatum		24.09.99
Geplante Betriebsdauer		7 Jahre
Geometrische Auflösung	panchromatisch multispektral	1 m (0,82 m Nadir)[1] 4 m (3,28 m Nadir)[1]
Spektrale Auflösung	panchromatisch multispektral	0,45-0,90 µm 0,45-0,52 µm (blau) 0,51-0,60 µm (grün) 0,63-0,70 µm (rot) 0,76-0,85 µm (nahes Infrarot)
Radiometrische Auflösung		11 Bit
Streifenbreite	nominal	11,3 km (Nadir), 13,8 km (26° Off-Nadir)
Szenengröße	Bildgröße Streifenabbildungen	11*11 km 11 km Streifen bis zu 1 000 km Länge
Lagegenauigkeit		12 m horizontal, 10 m vertikal ohne Kontrollpunkte 2 m horizontal und 3 m vertikal mit Kontrollpunkten
Orbitinformationen	Flughöhe Inklination Geschwindigkeit Äquatorüberflug max. Schwenkwinkel[2] max. Schwenkzeit Repetitionszeit Umlaufzeit Umlaufbahn Umlaufbereich Erdumläufe	681 km 98,1° 7,5 km/s (Orbit), 6,8 km/s (über Grund) 10:30 UTM 27° (entspricht Aufnahmewinkel von 60°) <50 s 140 Tage (Nadir); 2,9 Tage bei 1m-Auflösung[1,3]; 1 Tag bei 2m-Auflösung[1,3] 98 Minuten sonnensynchron, polnah 85° nördliche Breite bis 85° südliche Breite 14,7 in 24 Stunden

[1] Bei NN. [2] Zum Erreichen einer Auflösung von 1 m, absolutes Max. 60°. [3] In Abhängigkeit von geographischer Breite (Angaben für 40° geographischer Breite, in Polnähe kürzere, in Äquatornähe längere Repetitionszeit).

Das digitale Kamerasystem besteht aus vier Komponenten. Die Aufnahmeoptik leitet die Rückstrahlung des betrachteten Ausschnitts der Erdoberfläche weiter zur Aufnahmeeinheit. Die CCD-Sensoren sind auf die Fluggeschwindigkeit des Satelliten abgestimmt, sodass kaum eine Bewegungsunschärfe auftritt. In der Bildverarbeitungseinheit werden die aufgenommenen Daten nahezu verlustfrei von 11 auf 2,6 Bit komprimiert und ggf. gespeichert. Der Datentransfer zu einer der Bodenstationen erfolgt mit Echtzeit-Geschwindigkeit (320 MBit/s).

Die Aufnahmeeinheit besteht aus zwei panchromatischen CCD-Zeilen, jeweils eine für den *forward* sowie für den *reverse* Aufnahmemodus. Beide sind mit 32 zusätzlichen Zeilen zur TDI-Korrektur (*Time Delay and Integration*) ausgestattet. Für multispektrale Aufnahmen sind vier weitere CCD-Zeilen vorhanden (RGB, NIR). Alle Zeilen bestehen aus je drei Teil-CCD's, die mechanisch miteinander verbunden sind und gemeinsam eine Gesamtzeile bilden. Derartige CCD-Anordnungen werden auch in anderen Sensoren verwendet – so bilden z. B. bei QuickBird sechs Teil-CCD's eine virtuelle Gesamtzeile (vgl. BALTSAVIAS et al. 2005).

Bei einer nominellen Flughöhe des Satelliten von 681 km wird eine Bodenauflösung von 0,82 m (panchromatischer Kanal, Pan) bzw. 3,2 m (Multispektralkanäle, MS) bei NN erreicht, die jedoch zum Vertrieb einheitlich auf 1 m bzw. 4 m umgerechnet wird. Aufgrund der hohen Auflösung ist gleichzeitig nur die Aufnahme von Streifen mit 11 km Breite (Nadir) durch die 13 816 (Pan) bzw. 3 454 (MS) CCD-Detektoren möglich. Für größere Gebiete ist die Aufnahme mehrerer Streifen und eine anschließende Mosaikierung nötig.

Einhergehend mit der hohen Auflösung der IKONOS-Daten ergibt sich eine immense, zu bearbeitende Datenmenge und damit hohe Anforderungen an die Auswertungshardware. Allein aufgrund der gestiegenen geometrischen Auflösung ist der Datenumfang gegenüber einer Landsat-Aufnahme (30 m Bodenauflösung) der gleichen Fläche um den Faktor 900 höher. Für eine Bildszene von 11 x 11 km mit einer Farbtiefe von 16 Bit ergeben sich Dateigrößen von rund 250 MB für den panchromatischen Kanal (1 m Auflösung), 55 MB für die vierkanaligen Multispektraldaten (4 m) bzw. 950 MB für die panchromatisch geschärften Multispektraldaten mit vier Kanälen (1 m).

Die durch IKONOS abgedeckten Spektralbereiche des sichtbaren Lichtes sind identisch mit denen von Landsat-7 ETM+, Kanal 1 bis 3 (vgl. Abb. 2.4). Die Grauwertsensitivität der einzelnen Kanäle wird in Abbildung 3.1 dargestellt. Die radiometrische Auflösung beträgt 11 Bit (2 048 mögliche Graustufen). Die Auslieferung der Bilddaten erfolgt mit 8 oder 16 Bit. Der Nutzer erhält bereits radiometrisch korrigierte Daten (zum Verfahren vgl. GERLACH 2000), womit dieser Vorverarbeitungsschritt entfällt.

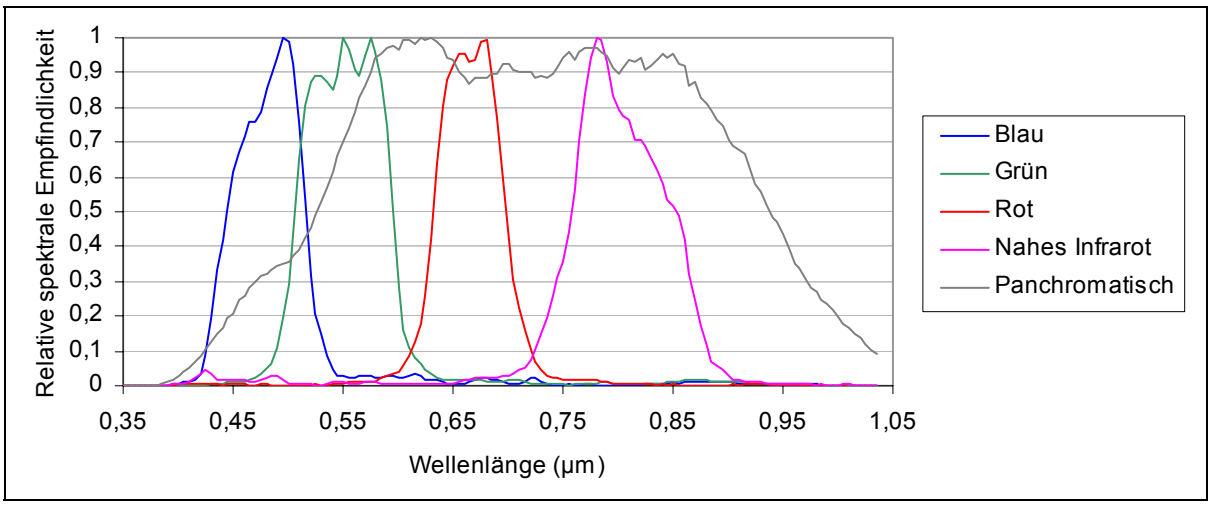

Abb. 3.1: Grauwertsensitivität der IKONOS-Spektralkanäle.
(Quelle: SPACE IMAGING 2003b, verändert)

Der Sensor des IKONOS-Satelliten zeichnet sich durch eine hohe Aufnahmeflexibilität aus. Er besitzt durch seine Schwenkmöglichkeiten eine hohe Beweglichkeit, wodurch die Bildwiederholfrequenz stark erhöht werden kann (zwei bis drei Tage statt 140 Tage ohne Schwenkung). Durch die Schwenkung des Sensors quer zur Flugrichtung (maximal 60°) verringert sich jedoch die Bodenauflösung und es kommt zu Kippeffekten höherer Objekte. Innerhalb eines Überflugstreifens von 350 km beiderseits der Flugspur ist eine Aufnahme mit einer Bodenauflösung von 1 m und weniger möglich (Schwenkwinkel max. 27°, Wiederholrate 3,2 Tage). Bei einem 700-km-Streifen beträgt die Auflösung noch 1,5 m (max. 44°; 1,6 Tage; BAUMGARTNER & ZEVENBERGEN 2003). Durch die Sensorbeweglichkeit sind Stereo-Aufnahmen in bzw. quer zur Flugrichtung *(along/across track)* möglich. Darüber hinaus sind auch nahezu simultane Aufnahmen benachbarter Gebiete durch abwechselnde Anwendung von vorwärts *(forward*, Normalmodus, in Nord-Süd-Richtung) und rückwärts *(reverse*, in Süd-Nord-Richtung) gerichtetem Aufnahmemodus möglich (siehe Abbildung 3.2). Der Vorteil solcher Aufnahmen ist – abgesehen vom unterschiedlichen Schwenkwinkel – deren nahezu gleiche Aufnahmebedingungen. Aufnahmen im *Reverse Mode* weisen allerdings eine geringere Lagegenauigkeit auf (vgl. FRASER et al. 2002). Durch die Drehung der gesamten Aufnahmeoptik sind selbst Aufnahmestreifen quer zur Flugrichtung möglich. Diese Option wird jedoch aufgrund der hierfür nötigen Energiemenge selten angewandt.

Der Originalmaßstab der IKONOS-Aufnahmen beträgt 1 : 68 000. Er ist damit drei bis fünf mal geringer als bei Luftbilddaten für einen Zielmaßstab von 1 : 20 000 und bis zu zehn mal kleiner für einen Maßstab von 1 : 10 000. Dennoch kann als Grenzmaßstab für IKONOS-Auswertungen 1 : 10 000 angegeben werden (vgl. JACOBSEN 2002). Mit IKONOS-Daten stehen somit erstmals Satellitenbilddaten für einen Maßstabsbereich bis 1 : 10 000 operationell zur Verfügung.

Die Daten werden vorwiegend nach Bestellung durch den Kunden aufgezeichnet. Zusätzlich werden bei Allgemeininteresse (z. B. im Desasterfall) oder im Interesse des Betreibers Daten akquiriert. Anfänglich auftretende Verfügbarkeitsprobleme insbesondere im europäischen Raum wurden inzwischen durch die Einrichtung neuer Empfangsstationen ausgeräumt. Es besteht die Möglichkeit, alle bisher aufgenommenen Szenen als Archivdaten zu beziehen. Ein umfangreiches, internetbasiertes Archivsystem erlaubt die Recherche nach geeigneten Aufnahmen und gibt Auskunft über die jeweiligen Aufnahmeparameter der Daten. Darüber hinaus sind im Archiv auch Vorschaubilder *(Quicklooks)* enthalten.

Die Daten sind in unterschiedlichen Qualitätsstufen erhältlich, deren aktuelle Beschreibung und Lizenzpreise sich von den Internetseiten des Anbieters abrufen lassen. Tabelle 3.2 zeigt eine Übersicht über die Eigenschaften der IKONOS-Bildprodukte. Einige bei der Bestellung der IKONOS-Bilddaten zu beachtende Angaben werden im Folgenden dargestellt.

Die Bestimmung des Aufnahmegebietes kann durch Angabe von Zentrums- oder Eckpunkten sowie durch einen Polygondatensatz jeweils mit *Latitude/Longitude*-Koordinaten erfolgen. In letzterem Falle sind unregelmäßige Gebietsabgrenzungen mit bis zu 300 Punkten zu

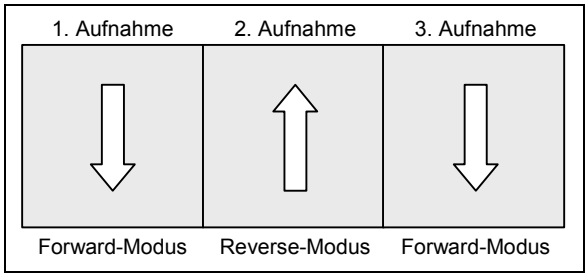

Abb. 3.2: Illustration abwechselnder Aufnahmemodi benachbarter Bildszenen durch IKONOS. (Quelle: Eigene Darstellung)

Tab. 3.2: Qualitätsstufen der IKONOS-Bildprodukte (in der Arbeit verwendete Qualitätsstufe: Geo). (Quelle: SPACE IMAGING 2003a; verändert)

Produkt-stufe	Lagegenauigkeit			Ortho-rektifiziert	Aufnahme winkel [°]	Bild-mosaike möglich	Stereo-aufnahmen möglich	DHM[4] nötig	Pass-punkte nötig
	CE90[1] [m]	RMSE[2] [m]	NMAS[3]						
Geo/Geo Ortho Kit[5]	15,0[6]	23,3	k. A.[7]	Nein	60-90	Nein	Nein	Nein	Nein
Standard Ortho	50,0[8]	25,0	1 : 100 000	Ja	60-90	Nein	Nein	Ja	Nein
Reference	25,4	11,8	1 : 50 000	Ja	60-90	Ja	Ja	Ja	Nein
Pro	10,2	4,8	1 : 12 000	Ja	66-90	Ja	Nein	Ja	Ja
Precision	4,1	1,9	1 : 4 800	Ja	72-90	Ja	Ja	Ja	Ja
Precision Plus	2,0	0,9	1 : 2 400	Ja	75-90	Ja	Nein	Ja	Ja

[1] *Circular Error* 90 – Mittlerer Lagefehler für 90 % der Punkte. [2] *Root Mean Square Error* – Mittlerer Lagefehler für 66,6 % der Punkte. [3] Angaben gemäß US-amerikanischem *National Map Accuracy Standard*. [4] Digitales Höhenmodell. [5] Enthält gegenüber Geo nötige Angaben zur eigenständigen Orthorektifikation. [6] Ohne Berücksichtigung von Höheneinflüssen. [7] Nach TOUTIN (2001) etwa 1 : 250 000. [8] In wenig entwickelten Gebieten mit starkem Relief bis 75,0 m (z. B. Anden, Himalaja).

lässig. Die Mindestbestellfläche für Neuaufnahmen beträgt 100 km², bei Archivdaten 49 km². Bei der Bestellung muss die Prozessierungsstufe gewählt werden, wobei die Kosten mit zunehmender Verarbeitung stark steigen. Zudem werden die benötigten Spektralkanäle bestimmt. Hierbei ist der Bezug panchromatischer sowie dreikanaliger (Naturfarb- oder Infrarotdarstellung) bzw. vierkanaliger multispektraler Daten einzeln oder in Kombination möglich. Ebenso ist die Bestellung panchromatisch geschärfter Multispektraldaten möglich (vgl. Abschnitt 3.2.3), wobei allerdings keine panchromatischen Daten mitgeliefert werden.

Als weitere Angabe ist der Aufnahmezeitpunkt erforderlich, der in Form eines Aufnahmefensters angegeben wird. Innerhalb dieser Zeitspanne wird ein Aufnahmetag gewählt, der die zu akzeptierende Wolkenbedeckung unterschreitet. Sie betrug anfangs 10 %, derzeit jedoch 20 % der Bildszene. Es kann lediglich eine Bildkoordinate angegeben werden, die unbedingt wolkenfrei sein soll. Gegen Zahlung eines Aufpreises ist eine Verringerung der enthaltenen Wolkenanteils möglich (z. B. 25 % Mehrkosten zur Reduktion auf 10 %).

Um die radiometrische Auflösung von 11 Bit besser auszunutzen, besteht die Option, eine Streckung des Grauwerthistogrammes *(Dynamic Range Adjust*, DRA) durch den Datenanbieter vornehmen zu lassen (vgl. OLESZCZUK 2000). Dabei werden allerdings die Originalgrauwerte unwiederbringlich verändert. Wird die ursprüngliche Radiometrie der Daten für die weitere Verarbeitung benötigt, z. B. im Rahmen einer atmosphärischen Korrektur, sollte diese Option keinesfalls gewählt werden.

Da selbst die geringste Qualitätsstufe Geo georeferenziert ausgeliefert wird, müssen eine Projektion (z. B. *Universal Transverse Mercator*, UTM) und ein Ellipsoid (z. B. *World Geodetic System* 1984, WGS84) vordefiniert werden. Damit sind die Daten nach Lieferung prinzipiell sofort in einem GIS nutzbar. Als weitere Bestellparameter sind das Datenformat (z. B. georeferenziertes *Tagged Image File Format*, GeoTIFF), der gewünschte Medientyp (z. B. *Digital Versatile Disc*, DVD) sowie die Art der Lizenz (Einzel-/Mehrfachnutzer) wählbar. Die Bildprodukte werden gemeinsam mit einer *Header*- und einer Metadatei sowie den Lizenzbestimmungen geliefert. Der Metadatei sind alle wichtigen Informationen, wie Szenenlage, Sonnen- und Aufnahmeposition sowie Aufnahmedatum und -uhrzeit, Bodenauflösung und Prozessierungsschritte (Kartenprojektion, Ellipsoid, Grauwertstreckung, Interpolationsmethode) zu entnehmen. Zu beachten ist, dass beim Kauf nur eine Nutzungslizenz erworben wird, nicht jedoch die Eigentumsrechte an den IKONOS-Daten.

Für die Bearbeitung im Rahmen dieser Dissertation wurden zwei IKONOS-Szenen – für das Stadtgebiet Dresden (Aufnahmedatum 04.06.2000) sowie die Vordere Sächsische Schweiz (01.08.2000) – der preiswertesten Prozessierungsstufe Geo genutzt. Abbildung 3.3 zeigt eine Lageeinordnung der Daten. Beide Datensätze sind in Abbildung 3.4 verkleinert als Naturfarbabbildung dargestellt. Tabelle 3.3 enthält die Aufnahmeparameter beider Szenen. Die panchromatischen Daten beider Bildszenen wurden einer zum Aufnahmezeitpunkt standardmäßigen durchgeführten Grauwertstreckung (DRA) unterzogen.

3.1.2 Beurteilung der Bildqualität

Die Bilddaten des IKONOS-Sensors bieten eine sehr präzise, qualitativ hochwertige Abbildung der Erdoberfläche. Die gute Detailerkennbarkeit widerspiegelt sich beispielsweise in den panchromatischen Bilddaten mit einem Meter Bodenauflösung, in denen bei ausreichendem Kontrast die weißen Linien von Sportplatz-, Parkflächen- und Straßenmarkierungen sichtbar sind. Darüber hinaus sind teilweise auch Schatten von Hochspannungsleitungen erkennbar (vgl. KERSTEN et al. 2000).

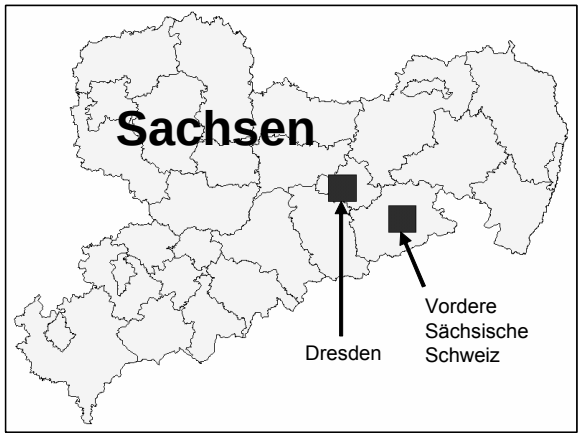

Abb. 3.3: Lage der verwendeten IKONOS-Bildszenen in Sachsen.
(Quelle: Eigene Darstellung)

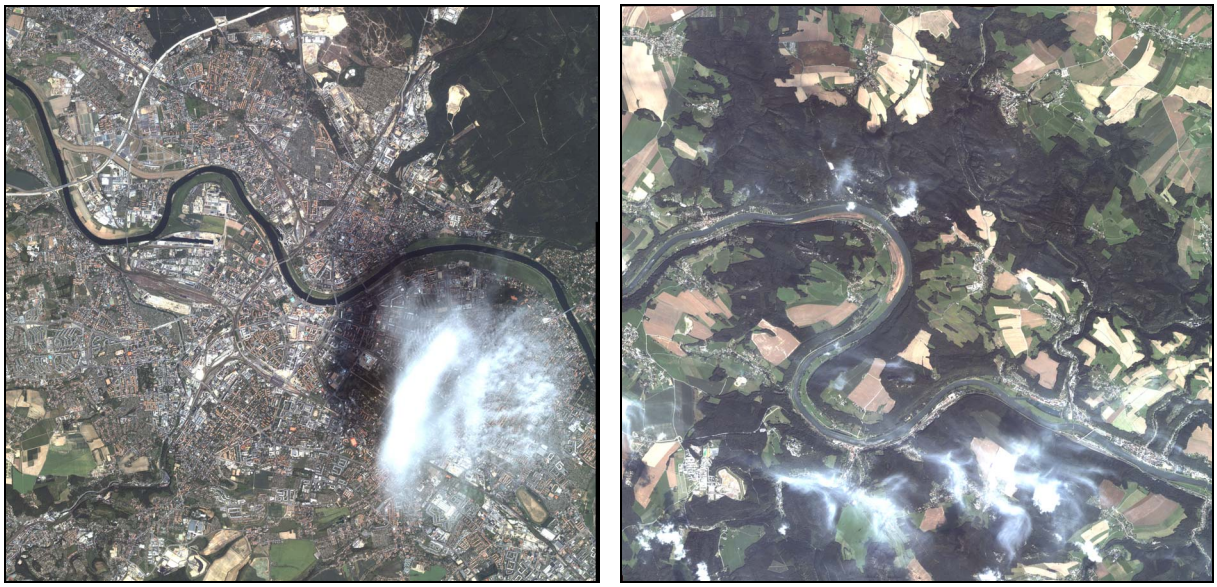

Abb. 3.4: Darstellung der verwendeten IKONOS-Bildszenen. Links: Aufnahme des Stadtgebietes Dresden, rechts: Vordere Sächsische Schweiz; Szenengröße je 11 x 11 km.
(Quelle: Eigene Darstellung, © Space Imaging)

Tab. 3.3: Aufnahmeparameter der verwendeten IKONOS-Szenen Dresden und Vordere Sächsische Schweiz. (Quelle: Eigene Darstellung auf Grundlage der Metadateninformationen)

Aufnahmeparameter	Dresden	Vordere Sächsische Schweiz
Aufnahmedatum	04.06.2000	01.08.2000
Aufnahmezeit	10:50	10:05
Aufnahmeazimut [°]	149,1	335,4
Aufnahmewinkel [°]	76,8	71,4
Sonnenazimut [°]	146,5	152,6
Sonnenwinkel [°]	58,2	54,7
Bodenauflösung [m] - quer zur Flugrichtung - in Flugrichtung	 0,85 0,86	 0,87 0,90

Im Vergleich zu einem Luftbild der gleichen Auflösung erreichen IKONOS-Daten nahezu dieselbe Qualität, weisen jedoch ein etwas schlechteres Kontrastverhältnis auf (vgl. MEINEL & REDER 2001). Auf einen schlechteren Bildkontrast gegenüber Luftbildern und einer daraus resultierenden verminderten Detailerkennbarkeit weisen auch JACOBSEN (2002) sowie BALT SAVIAS et al. (2004) hin. KERSTEN et al. (2000) sehen den Grund hierfür in der größeren Flughöhe und im Bildrauschen. Zudem zeigte ein Vergleich zwischen mehreren IKONOS-Szenen deutliche Qualitätsunterschiede, die insbesondere auf unterschiedliche atmosphärische Bedingungen (Bewölkung, Dunst, Rauch, Aerosol- und Partikelgehalt etc.) als die einflussreichsten Variablen zurückzuführen sind. Sie senken den effektiven Kontrast einer Szene, erhöhen das Rauschen und verschlechtern somit den Gesamteindruck. Daneben sind Aufnahmewinkel, Sonnenstand, Jahreszeit und Szenentyp entscheidend für hochqualitative Aufnahmen (vgl. KUDALA 2000). Das Signal-Rauschen-Verhältnis *(signal to noise ratio)* wird von Space Imaging mit vier Grauwerten für alle fünf Kanäle angegeben (vgl. GERLACH 2000). BALTSAVIAS et al. (2001) ermittelten dagegen ein Ratio bis zu 10,5 Grauwerten.

Die genannten Effekte treten auch in den vorliegenden Bildszenen zu Tage. Beide Datensätze sind deutlich atmosphärisch beeinflusst – ein häufiges Problem bei der Verwendung von IKONOS-Daten. Die Bildszene von Dresden besitzt eine Wolkenbedeckung von 11 % und weitere 7 % sind durch den starken Schatten nahezu unbrauchbar. Auch der Datensatz der Vorderen Sächsischen Schweiz weist besonders im Südteil ausgeprägte Wolkenschleier auf (vgl. Abbildung 3.4).

Als Bildfehler konnte in allen Kanälen der Dresdner IKONOS-Szene ein 64 m breiter Saum am westlichen Bildrand mit einer Länge von 6 872 m identifiziert werden, der nicht mit Bildinformationen belegt ist. Daneben wurde im blauen Kanal beider Datensätze ein schräg durchs Bild verlaufender, zwei Pixel breiter Streifen lokalisiert. BALTSAVIAS et al. (2001) berichten darüber hinaus über Bildfehler (Artefakte), die sich insbesondere durch geringfügige Grauwertsprünge äußern und erst nach einer Kontrastverbesserung sichtbar werden. Sie sind auf die hohe Kompression während der Datenübertragung sowie spezielle Bildverarbeitungsverfahren seitens Space Imaging zurückzuführen. GERLACH (2000) beschreibt diese zur Kalibrierung verwendeten Verfahren. Die Optik des Sensors führt infolge der hohen Satellitengeschwindigkeit zu einer sehr kurzen Belichtungszeit der CCD-Zeilen. Die Belichtungsdauer ist zu gering, um ein ausreichend starkes Signal aufzuzeichnen. Zudem wird das Signal in mehreren Zeilen abgebildet *(signal mixing)*. Mittels *Time Delay and Integration* (TDI) wird das panchromatische Signal verstärkt und akkumuliert, was gleichzeitig insbesondere in Flugrichtung zu einer Signalglättung führt. Durch eine optionale *Modulation Transfer Function Compensation* (MTFC) wird das Signal anschließend wieder geschärft, was zwar zu visuell schärferen Bildern, jedoch zu geringerem Kontrast und Artefakten *(ringing, overshoot)* führt (BALTSAVIAS et al. 2001).

Stark reflektierende Oberflächen, wie metallene Gebäudedächer, helle Hausfassaden oder Glasflächen, führten in Abhängigkeit der Sonneneinstrahlung zu Übersteuerungspunkten (sog. *spillings)* im panchromatischen Kanal (0,08 % der Fläche im Stadtgebiet Dresden). Allerdings kommt es in keinem Fall zu nachfolgenden Streifenausfällen, wie z. B. bei IRS-1C-Daten. Teilweise wurden in den panchromatischen Bilddaten um Übersteuerungspunkte auch Spots mit in Nord-Süd-Richtung lang gestreckter Form und schwarzem Saum festgestellt (siehe Abbildung 3.5; vgl. MEINEL & REDER 2001).

Wie anhand der Histogramme für die Dresdner IKONOS-Szene in Abbildung 3.6 beispielhaft erkennbar ist, wird in den drei Kanälen des sichtbaren Spektrums nur das erste Drittel und im nahen Infrarot ca. die Hälfte der zur Verfügung stehenden Bandbreite (2 048 mögliche Grauwerte bei 11 Bit) ausgenutzt. Im panchromatischen Kanal wird der verfügbare Grauwertbereich zu etwa zwei Dritteln ausgenutzt, was vermutlich durch dessen DRA-Streckung bewirkt wird. Ähnliches gilt für die Bildszene der Vorderen Sächsischen Schweiz. Auch andere Nutzer berichten von derartigen Erfahrungen (vgl. BALTSAVIAS et al. 2001; LHOMME et al. 2003). Demnach werden effektiv nur acht bis neun Bit der verfügbaren Radiometrie genutzt. Der große Anteil von Bildpunkten mit dem Grauwert Null im Multispektralbereich wird durch die fehlende Bildinformation am westlichen Bildrand hervorgerufen. Das Maximum im panchromatischen Histogramm beim Grauwert 2 048 ist Folge der Übersteuerungspunkte.

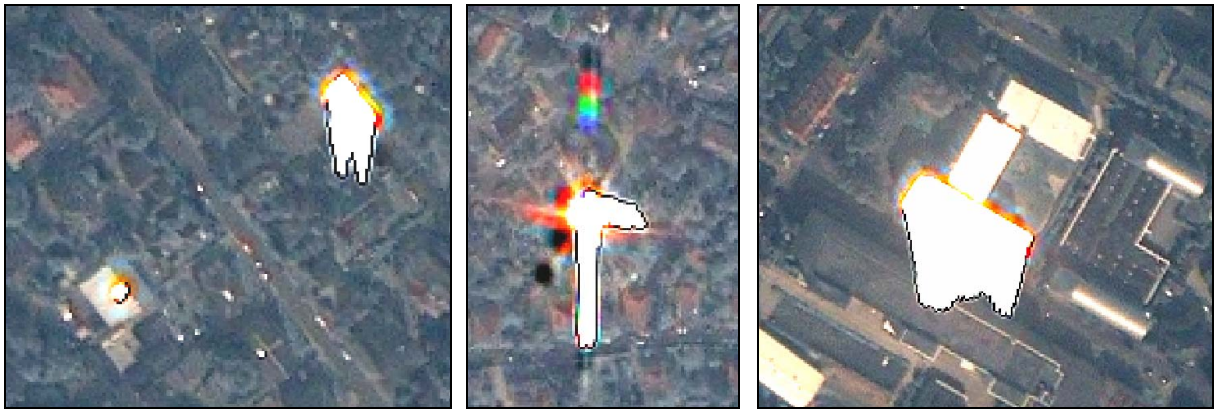

Abb. 3.5: Beispiele für Bildstörungen durch Reflexionseffekte in den IKONOS-Bilddaten.
(Quelle: Eigene Darstellung, © Space Imaging)

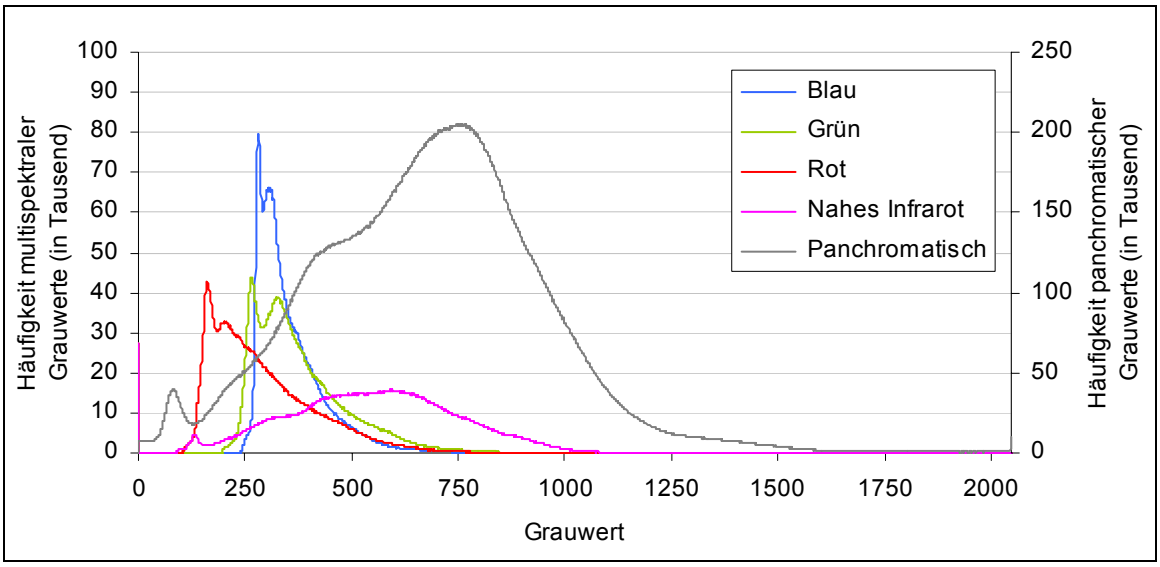

Abb. 3.6: Histogramme der einzelnen Kanäle der IKONOS-Szene Dresden.
(Quelle: Eigene Darstellung)

Beeinträchtigungen der Bildqualität können durch die in Abschnitt 3.1.1 erwähnte Teilung der CCD-Zeilen hervorgerufen werden (vgl. BALTSAVIAS et al. 2005). Darüber hinaus kann der Schrägblick des Sensors zu Problemen der Auswertbarkeit der Bilddaten führen. So ist bei der Dresdner Szene, die mit einem Blickwinkel von 76,8° aufgenommen wurde (dies entspricht einem Schwenkwinkel des Sensors von 14°), die Kippung von Gebäuden etc. deutlich sichtbar. Dies behindert infolge der Abbildung von Fassaden im Bild und durch Kantenverdeckung die Interpretation und Klassifikation. Besonders zu beachten ist der Aufnahmewinkel und gleichzeitig der Sonnenstand bei der Auswertung multitemporaler Bildszenen. Im Rahmen einer Veränderungsanalyse *(change detection)* können dadurch erhebliche Fehler auftreten.

Durch die zeitgleiche Aufnahme von panchromatischen und multispektralen Bilddaten sowie die identischen Szeneneckkoordinaten ist eine Lageidentität zwischen den Spektralkanälen gegeben, sodass die Berechnung einer Bildfusion problemlos möglich ist (vgl. Abschnitt 3.2.3).

3.1.3 Vergleich Luftbild versus IKONOS-Satellitenbild

Digitale, sehr hoch auflösende Satellitenbilddaten dringen zunehmend in den Anwendungsbereich klassischer Luftbilder vor. Sie haben gegenüber den herkömmlichen, analogen Luftaufnahmen deutliche Vorteile, die insbesondere in der größeren Flächendeckung, der besseren spektralen Auflösung und dem geringeren Vorprozessierungsaufwand liegen. Luftbilder besitzen dagegen zumeist eine bessere geometrische Auflösung. Die Kosten sind – unter Berücksichtigung des höheren Vorprozessierungsaufwandes der Luftbilder – vergleichbar. In Tabelle 3.4 werden verschiedene Aspekte beider Datenquellen gegenübergestellt. Die Tatsache, dass sehr hoch auflösende Satellitendaten häufig an Luftbildern gemessen werden, ist Anlass für diesen Vergleich.

Die seit Jahrzehnten etablierte Technologie der analogen Luftbildaufnahme bietet eine hohe geometrische Auflösung und damit eine detaillierte Objektwiedergabe. Die Luftbilder sind nutzbar bis zu sehr großen Maßstäben von >1 : 500. Häufig sind lange Zeitreihen verfügbar. Durch das photographische Verfahren sind lediglich einkanalige (S/W) oder dreikanalige Naturfarb- (Color-) bzw. Farbinfrarotaufnahmen (CIR) möglich. Luftbilder weisen daneben eine eingeschränkte radiometrische Auflösung auf, die von SCHENK (1999) mit 6 Bit angegeben wird. Zudem besteht aufgrund richtungsabhängiger Transmissionsgrade der Sensoroptik sowie variierender und nichtlinearer Detektorempfindlichkeit (KRAUS 1990) keine Möglichkeit einer radiometrischen Kalibrierung. Da nur die Aufnahme von Einzelbildern möglich ist, wird jeweils nur ein kleines Gebiet abgebildet. Infolge von Randabschattungen und Helligkeitsunterschieden innerhalb und zwischen den Bildern gestaltet sich ein Zusammenfügen benachbarter Bilder (Mosaikierung) schwierig. Grauwertsprünge an den Bildübergängen sind häufig die Folge. Durch die zentralperspektivische Aufnahme weisen Luftbilder starke geometrische Verzerrungen auf. Die niedrige Flughöhe führt zu starken Auswirkungen des Reliefs, wodurch ein radialer Versatz auftritt und das Bild keinen einheitlichen Maßstab besitzt. Diese Fakten erschweren eine digitale Verarbeitung und Auswertung in erheblichem Maße, zumal die analogen Luftbilder zunächst durch Scannen digitalisiert werden müssen.

Die Kosten für die analogen Luftbilder sind zunächst gering. Sollen die Daten jedoch digitalisiert werden, um sie in GIS verwenden zu können, steigen die Kosten erheblich an (insbesondere im Falle einer Orthophotoherstellung). Ein digitales Datenformat ermöglicht einen höheren Automatisierungsgrad bei der Vorverarbeitung und Auswertung (vollständig digitale Prozesskette) sowie eine problemlose Nutzung in einer bestehenden GIS-Umgebung.

Tab. 3.4: Vergleichende Bewertung von analogem Luftbild und sehr hoch auflösendem digitalen Satellitenbild (++ sehr positiv, + positiv, o neutral, - negativ).
(Quelle: Eigene Darstellung)

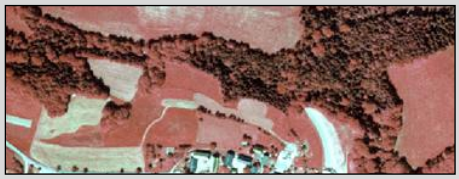 *CIR-Luftbild, 1992*	*IKONOS-Satellitenbild, 2000*
++ Extrem hohe geometrische Auflösung	+ Sehr hohe geometrische Auflösung
- Spektrale Auflösung (drei Farbkanäle)	+ Spektrale Auflösung (ein Pan-, vier MS-Kanäle)
o Geringe radiometrische Auflösung (6 Bit)	+ Hohe radiometrische Auflösung (11 Bit)
- Geringe Flächenabdeckung	+ Große Flächenabdeckung (Streifenbreite)
- Schlechte Bildgeometrie (zentralperspektivisch verzerrt)	+ Gute Bildgeometrie (aufgrund der Flughöhe quasi-parallelperspektivisch verzerrt)
- Analoges Datenformat (Film)	+ Digitales Datenformat (CCD)
- Hoher Vorprozessierungsaufwand (Scannen, Mosaikieren)	+ Geringer Vorprozessierungsaufwand
o Kosten (unter Berücksichtigung der Vorverarbeitung)	o Kosten
- Zeitliche Auflösung (Verfügbarkeit von Aufnahmen nur nach Bestellung)	+ Zeitliche Auflösung (nahezu permanente Verfügbarkeit von Aufnahmen)
- Eingeschränkte Wiederholbarkeit der Aufnahme unter gleichen äußeren Bedingungen	+ Wiederholbarkeit der Aufnahme unter annähernd gleichen äußeren Bedingungen

Aufgrund der genannten Vorteile einer digitalen Datenaufnahme vollzieht sich derzeit eine Umorientierung von der analogen hin zur digitalen Luftbildaufnahme. Die sehr hohe geometrische Auflösung sowie die Lagegenauigkeiten sind vergleichbar. Darüber hinaus stehen durch digitale Flugzeugscannerdaten (siehe Tabelle 3.5) häufig multispektrale Aufnahmen und teilweise mittels so genannter Multisensorsysteme parallel erfasste Höhenmodelle zur Verfügung, wodurch die Erstellung von *True Ortho-Photos* möglich ist. Ein geringerer Öffnungswinkel sowie die Aufnahme von Bildstreifen gegenüber Einzelbildern bewirken eine bessere Bildgeometrie. GRUBER et al. (2003) verglichen analoge und digitale Luftbilddaten (ULTRACAM). Sie zeigten, dass die vorteilhaftere Bildqualität der Digitalaufnahmen eine Folge der höheren radiometrischen Auflösung sowie des im Vergleich zu analogen Aufnahmen nicht auftretenden Kornrauschens ist. Ein Vergleich von analogen Luftbildern und HRSC-A-Daten findet sich bei HOFFMANN (2001). BALTSAVIAS et al. (2004) verglichen analoge Luftbilder, IKONOS-, QuickBird- und ADS-40-Daten hinsichtlich der Nutzbarkeit für eine automatische Straßenextraktion. Die Ergebnisse waren umso besser, je höher die Auflösung der Daten war. Die Daten der ADS 40 erbrachten dem Luftbild vergleichbare Ergebnisse.

Die Vorteile digitaler Luftbildaufnahmen sind denen sehr hoch auflösender Satellitendaten ähnlich. Zur genauen Bildregistrierung und Orthobildgenerierung kommen kombinierte Differenzial-GPS und inertiale Messsysteme (IMU) zum Einsatz. Problematisch wirkt sich bei digitalen Luftbilddaten die größere Datenmenge aus, womit der technische Aufwand sowie die benötigte Auswertungszeit wachsen. Zudem sind die Kosten dieser Aufnahmen höher als für Satellitenbilddaten. Es lässt sich insgesamt schlussfolgern, dass die Unterschiede zwischen digitalen satelliten- und flugzeuggestützten Bilddaten zunehmend verschwimmen. Tendenziell werden digitale Daten – gleich welcher Herkunft – analoge verdrängen.

Tab. 3.5: Übersicht derzeit verfügbarer digitaler Luftbildkameras.
(Quellen: Eigene Darstellung, Internetseiten und Informationen der Anbieter)

Kamera	HRSC-A (High Resolution Stereo Camera-Airborne)	HRSC-AX (High Resolution Stereo Camera-Airborne Extended)	ADS 40 (Airborne Digital Sensor)	FALCON II	DMC (Digital Mapping Camera)	ULTRACAM$_D$ (Large Format Digital Aerial Camera)
Anbieter	DLR	DLR	Leica Geosystems	TopoSys	Z/I Imaging	Vexcel Imaging
Verfügbar seit	1998	2000	2000	2000	2002	2003
Kanäle	5 Pan 4 MS	5 Pan 4 MS	3 Pan 4 MS	4 MS	4 Pan 4 MS	4 Pan 4 MS
Sensortyp	Triplet Stereo	Triplet Stereo	Triplet Stereo	CCD Line Arrays	Matrix CCD	Matrix CCD
Zeilenauflösung [Pixel]	5 272	12 172	12 000	682	13 800 (Pan) 3 000 (MS)	11 500 (Pan) 4 008 (MS)
Pixelgröße [µm]	7	6,5	6,5	14	12	9
Radiometrische Auflösung [Bit]	8	12	12	8	12	12
Bodenauflösung [m], Flughöhe 3 000 m	0,23 (Px) 0,12 (Py)	0,23 (Px) 0,13 (Py)	0,15[1]	1,00[2]	0,30	0,27
Streifenbreite [m], Flughöhe 3 000 m	622	1 572	3 600[1]	400[2]	4 140	3 105
Quelle des Höhenmodells	Stereobilddaten	Stereobilddaten	Stereobilddaten/LIDAR	LIDAR	-	-

[1] Bei 2 880 m Flughöhe. [2] Bei 1 600 m Flughöhe (max. Flughöhe aufgrund der Reichweite des LIDAR-Sensors).

Die Vorteile von Satellitenbilddaten liegen demnach hauptsächlich in der grundsätzlich digitalen Datenaufnahme, der nahezu permanenten Verfügbarkeit, der vorteilhaften Bildgeometrie aufgrund der großen Flughöhe sowie der größeren Flächendeckung.

3.2 Vorverarbeitung der IKONOS-Daten

Um die Daten sinnvoll auswerten zu können, bedarf es einiger Vorverarbeitungsschritte. Die Abfolge ist in Abbildung 3.7 dargestellt. Die bereits radiometrisch korrigierten IKONOS-Daten (vgl. Abschnitt 3.1.2) lagen als GeoTIFF in einzelnen Farbkanälen vor. Für eine weitere Verwendung im Bildverarbeitungssystem ERDAS IMAGINE wurden sie in das nötige *Image*-Format (IMG) konvertiert. Zudem wurde eine Bandkombination *(Layer Stack)* der Multispektralkanäle durchgeführt. Die weiteren Vorverarbeitungsschritte werden im Folgenden detailliert beschrieben.

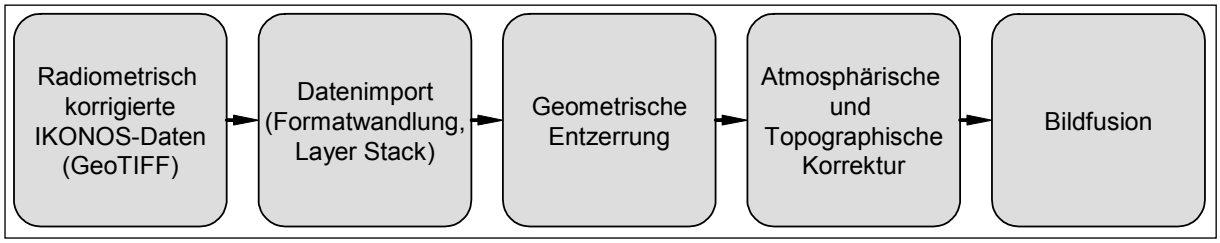

Abb. 3.7: Abfolge der durchgeführten Vorverarbeitungsschritte für IKONOS-Daten.
(Quelle: Eigene Darstellung)

3.2.1 Geometrische Entzerrung

Um Fernerkundungsdaten oder daraus abgeleitete Informationen in GIS nutzen zu können, bedarf es der vorherigen geometrischen Entzerrung (auch geometrischen Transformation, Georeferenzierung, Geokodierung). Bei dieser Einbindung in ein geodätisches Referenzsystem werden den unreferenzierten Bilddaten eine Projektion (z. B. Transverse Mercator) sowie ein Ellipsoid (z. B. Bessel) zugewiesen. Das Verfahren erfolgt zumeist unter Nutzung von im Ein- und Ausgabebild identischen Passpunkten.

Die Georeferenzierung kann nicht-parametrisch oder parametrisch erfolgen (vgl. ALBERTZ 2001). Erstere – auch als Interpolationsverfahren bezeichnet – verwenden standardisierte Entzerrungsfunktionen (z. B. Polynomfunktionen). Die Aufnahmegeometrie bleibt bei diesen Ansätzen unberücksichtigt. Bei unebenem Gelände hängt die Qualität einer nicht-parametrischen Entzerrung von der Dichte der Passpunkte ab, da zwischen den Passpunkten interpoliert wird. Mittels parametrischer Verfahren wird dagegen versucht, unter Nutzung der Sensorgeometrie sowie der Raumlage bzw. -bewegung (innere bzw. äußere Orientierung) die Aufnahmegeometrie mathematisch zu modellieren. Geländehöhenunterschiede können durch die Verwendung eines digitalen Höhenmodells (DHM) entsprechend dessen Genauigkeit vollständig korrigiert werden. Insbesondere bei hoch aufgelösten Bilddaten sollte eine solche Orthorektifikation durchgeführt werden, da Einflüsse des Reliefs die Lage der Bildpunkte stark beeinträchtigen (Punktversatz).

Die eigentliche Transformation der Bildpunkte wird als *Resampling* bezeichnet. Drei Verfahren werden hauptsächlich angewendet: nächste Nachbarschaft *(nearest neighbour)*, bilineare *(bilinear)* und bikubische Interpolation *(cubic convolution)*. Bei der Resamplingmethode *cubic convolution* wird der Grauwert des betrachteten Pixels gewichtet aus den Grauwerten der 16 umliegenden Pixel (4x4-Fenster) bestimmt. Die Genauigkeit des Verfahrens ist hoch, sodass Mittelwert und Standardabweichung des Eingangs- und Ausgangsbildes weitestgehend übereinstimmen. Das Ergebnis ist zumeist schärfer als bei einer bilinearen Interpolation und bietet ein besseres Erscheinungsbild als die *nearest-neighbour*-Interpolation, welches zu Treppeneffekten neigt (vgl. Abschnitt 3.2.3). Aus diesen Gründen wurde das *cubic-convolution*-Verfahren für alle in dieser Arbeit durchgeführten *Resampling*-Prozesse angewendet. Zwar werden somit die Original-Grauwerte verändert, was bei einer pixelbasierten Klassifikation zu Fehlern führen kann. Da die Daten jedoch segmentbasiert ausgewertet wurden, lag das Hauptaugenmerk auf einer hohen visuellen Qualität.

Die Orthorektifizierung von IKONOS-Daten wird durch das von Space Imaging bisher nicht veröffentlichte Sensormodell stark beeinträchtigt. Angaben zur inneren Orientierung der Aufnahmen als Voraussetzung für eine exakte Orthorektifikation und photogrammetrische Stereoauswertung sind somit nicht erhältlich. Dieses Vorgehen ist eine Folge der Firmenstrategie von Space Imaging. Die Firma hat ein wirtschaftliches Interesse, ihre hochpreisigen Ortho-Produkte zu verkaufen und daher das Sensormodell geheim zu halten. Sämtliche derzeit verfügbaren parametrischen Entzerrungsmodelle sind somit nur Näherungslösungen.

Bei Neuaufnahmen wird mittlerweile zu den Daten der Produktstufe Geo Ortho Kit ein *Image Geometry Model* (IGM) geliefert. Es enthält rationale Polynomkoeffizienten (RPCs), welche den funktional geometrischen Zusammenhang zwischen Bild- und Objektpunkten beschreiben. Die Entzerrungsgüte ist in hohem Maße abhängig von der Genauigkeit, mit der die RPCs bestimmt werden (vgl. BREUER 2002). Auch VOZIKIS et al. (2003) weisen auf fehlerbehaftete RPCs hin. Zudem ist eine Entzerrung unter Nutzung der RPCs nicht zwangsläufig genauer als ohne diese.

VOZIKIS et al. (2003) verglichen vier Verfahren zur Georeferenzierung für hoch auflösende Fernerkundungsdaten. Dabei wurden eine zentralperspektivische direkt lineare Transformation, ein parallelperspektivisches Modell, ein affines Modell sowie ein *Rational Function*

Model (zur Nutzung von RPCs) gegenübergestellt. Die besten Ergebnisse liefert demnach eine affine Transformation mit Genauigkeiten von unter einem halben bis zu einem Pixel. Zudem stellen die Autoren eine Methode vor, mit der sich RPCs zumeist genauer generieren lassen.

Demgegenüber stellte JACOBSEN (2002) ein einfaches Verfahren zur Generierung von Orthobildern aus IKONOS-Daten der Produktstufe Geo vor. Damit ist es möglich, mithilfe von drei bis vier Passpunkten eine Genauigkeit von ein bis drei Metern zu erreichen. Durch diese einfache Vorgehensweise lassen sich Genauigkeiten erzielen, die bisher nur mit dem teuren orthorektifizierten Produkt Precision Plus (bei Zusatzkosten von ca. 20 000 US$ pro Szene) möglich waren.

Für beide vorliegenden Szenen waren zum Zeitpunkt der Aufnahme diese RPC-Informationen noch nicht verfügbar. Auch die heute in den gängigen Bildverarbeitungsprogrammen enthaltenen Sensormodelle bestanden noch nicht. Daher wurde die Dresdner IKONOS-Szene nicht-parametrisch mittels eines Polynoms zweiter Ordnung entzerrt. Die IKONOS-Daten der Sächsischen Schweiz wurden im Rahmen einer Kooperation mit dem *Canada Centre for Remote Sensing* unter Nutzung des Modells von TOUTIN & CHENG (2000) entzerrt.

Die Daten wurden jeweils orbitentzerrt geliefert (UTM, WGS84). Ohne Berücksichtigung reliefbedingter Verzerrungen wurden seitens Space Imaging zum Zeitpunkt der Bestellung ein mittlerer Lagefehler von <50 m für 90 % der Punkte (*Circular Error 90*, CE90) bzw. 23,6 m für 66,6 % der Punkte (*Root Mean Square Error*, RMS) angegeben. Heute gelten andere CE90-Werte (vgl. Tabelle 3.2). In den beiden untersuchten Bildszenen wurden allerdings wesentlich größere mittlere Lagefehler ermittelt. Die Tabelle 3.6 zeigt diese Abweichungen für die Dresdner Szene. Demnach ist eine mittlere Lageverschiebung von 108 m in x- und 144 m in y-Richtung in der orbitentzerrten Dresdner Szene zu verzeichnen. Die IKONOS-Daten der Sächsischen Schweiz wiesen aufgrund des stärkeren Reliefs höhere Abweichungen auf. Auffallend ist der nur unwesentlich höhere maximale gegenüber dem mittleren Lagefehler, was auf eine gute innere Lagetreue hinweist (vgl. MEINEL & REDER 2001).

Um eine hohe Lagetreue zu erzielen, wurde die Dresdner Szene auf Basis eines Orthophotomosaiks aus dem Jahre 1999 mit einer Auflösung von 1 m und einer mittleren Lagegenauigkeit von 0,5 m entzerrt. Die Geländehöhen innerhalb der Bildszene liegen zwischen 100 und 290 m. Abrupte Höhenunterschiede treten nur im Süden des Untersuchungsgebietes auf. Zur Entzerrung wurden 31 gleichverteilte Passpunkte mit einer RMS-Abweichung von 0,49 m (Δx = 0,32 m, Δy = 0,37 m) ermittelt. Nach der Transformation wurde die entzerrte Szene hinsichtlich ihrer Lagetreue anhand von 20 gleichverteilten Messpunkten kontrolliert (vgl. Tabelle 3.6). Der mittlere Lagefehler wurde mit 2,9 m in x- und 4,7 m in y-Richtung bestimmt. Die maximale Abweichung, gemessen nahe eines cañonartigen Taleinschnittes am Südrand, lag hier jedoch mit 14,1 m in y-Richtung wesentlich höher als der mittlere RMS-Fehler, was auf die Nichtberücksichtigung des Reliefs zurückzuführen ist. Eine Orthorektifizierung könnte

Tab. 3.6: Entzerrungsfehler der orbitentzerrten IKONOS-Szenen (Produktlevel Geo) sowie Fehler der daraus abgeleiteten passpunkt- bzw. orthorektifizierten Szenen.
(Quellen: Eigene Darstellung nach MEINEL & REDER 2001, ergänzt)

Untersuchungsgebiet		Mittlerer Fehler [m]			Maximaler Fehler [m]		
		x	y	RMS	x_{Max}	y_{Max}	RMS_{Max}
Dresden	Orbitentzerrt	108,0	144,0	180,0	121,6	224,1	250,7
	Passpunktentzerrt	2,9	4,7	5,5	5,7	14,1	16,9
Sächsische Schweiz	Orbitentzerrt	121,3	165,2	227,7	256,4	252,0	257,6
	Orthorektifiziert	1,5	1,5	2,4	4,3	5,1	5,3

diesen Nachteil ausgleichen, konnte aber mangels eines genügend genauen Höhenmodells nicht realisiert werden (vgl. MEINEL & REDER 2001). Innerhalb des Stadtgebietes wiesen die Abweichung mit ein bis zwei Metern zufrieden stellende Werte auf. Ein für weitere Auswertungen im Rahmen dieser Arbeit verwendetes, nahezu ebenes Teilgebiet der Dresdner IKONOS-Szene (Dresden-West, 2,4 x 2,4 km) konnte mithilfe von 37 Passpunkten im Mittel auf 0,5 m genau entzerrt werden (vgl. NEUBERT & MEINEL 2002a).

Die Szene der Sächsischen Schweiz wurde unter Verwendung eines Laserscanner-DGM (1 m Rasterweite; 1 m Lagegenauigkeit; 0,5 m Höhengenauigkeit, vgl. Abschnitt 3.3.1) und eines Orthophotomosaiks (0,4 m Rasterweite; 0,5 m Lagegenauigkeit) orthorektifiziert. Mit 31 Passpunkten wurde ein mittlerer RMS-Fehler von 2,4 m (x, y = 1,5 m) erzielt. Die maximalen Abweichungen betragen ca. 5 m (vgl. Tabelle 3.2). Die hohe Lagetreue verdeutlicht ein kleinräumiger Ausschnitt in Abbildung 3.8. Eine vergleichsweise durchgeführte Entzerrung unter Nutzung von 122 Passpunkten auf Basis einer Topographischen Karte 1 : 10 000 (TK10) anstelle des Orthophotomosaiks ergab ungenauere Ergebnisse (vgl. TOUTIN 2001).

Die Nachteile einer Orthorektifikation sind die Streckung bzw. Stauchung einiger Bildbereiche, die sich negativ auf die Auswertung auswirken kann. Das Bildbeispiel in Abbildung 3.9 verdeutlicht diese Effekte.

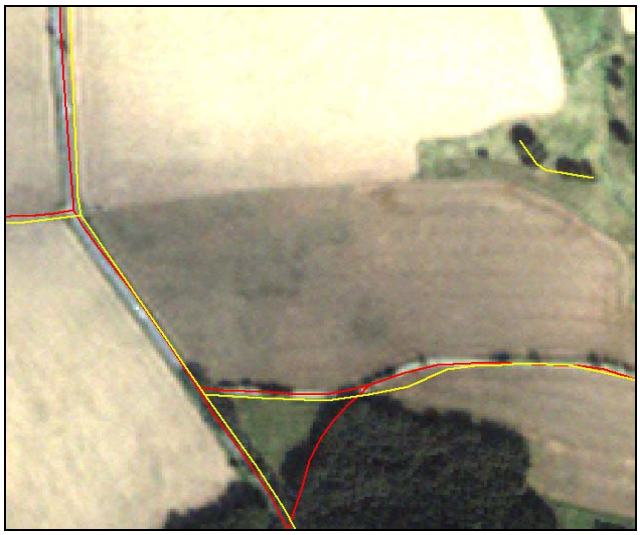

Abb. 3.8: Die Überlagerung der orthorektifizierten IKONOS-Daten mit ATKIS-Daten (rot) verdeutlicht die hohe Lagetreue. Die Daten der Biotopkartierung (gelb) zeigen dagegen teils erhebliche Abweichungen. (Quelle: Eigene Darstellung, © Space Imaging)

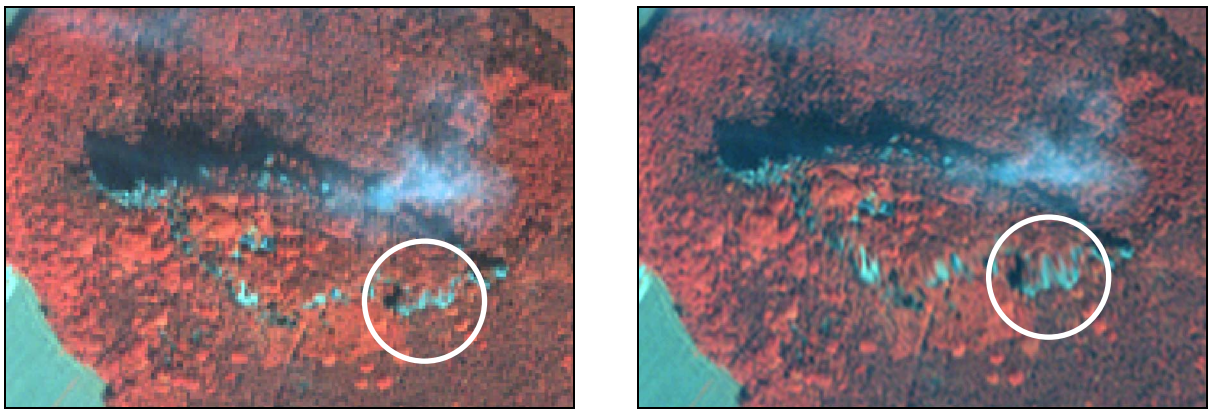

Abb. 3.9: Streckung bzw. Stauchung einiger Bildbereiche infolge der Orthorektifikation. Die Infrarotdarstellung zeigt den Lilienstein vor (links) und nach der Orthorektifikation (rechts). (Quelle: Eigene Darstellung, © Space Imaging)

3.2.2 Atmosphärische und topographische Korrektur

Atmosphärische und topographische Einflüsse wirken sich negativ auf die Radiometrie und damit auf die Auswertung optischer Fernerkundungsdaten aus. Sehr hoch auflösende Satellitenbilddaten weisen häufig atmosphärische Beeinträchtigungen auf, da man die Aufnahmebedingungen der auf Bestellung aufgenommenen Szenen kaum beeinflussen kann. So behindern oftmals unerwünschte Dunstschleier die Auswertung von Satellitenbildszenen. In Gebieten mit bewegtem Relief erschweren Beleuchtungsunterschiede in Hanglagen die Auswertung zusätzlich. Atmosphärische und topographische Korrekturverfahren besitzen daher für VHR-Daten eine große Bedeutung.

Die derzeit auf dem Markt befindlichen, in Fernerkundungssoftware implementierten Verfahren zur Korrektur atmosphärischer Einflüsse sind mit Ausnahme der Software ATCOR nicht für sehr hoch auflösende Sensoren geeignet. Erschwerend kommt hinzu, dass viele Korrekturprogramme ein umfangreiches Vorwissen des Bearbeiters, eine Vielzahl an Parametern sowie zahlreiche manuelle Optimierungsschritte erfordern. HOLZER-POPP et al. (2002) entwickelten mit „DurchBlick“ erstmals ein vollautomatisches Korrekturmodell unter Einbeziehung von aktuellen Zusatzdaten zum Aufnahmezeitpunkt (z. B. Wasserdampf- und Ozongehalt, Höhenmodell, Aerosolmenge und -typ, Wolken/Schatten, Bodentyp), um operationell und standardisiert Korrekturen vornehmen zu können. Leider ist dieses Modell derzeit nicht für IKONOS-Daten verfügbar.

Im Rahmen dieser Arbeit wurde daher auf die Software ATCOR zurückgegriffen. Sie wurde vom Deutschen Zentrum für Luft- und Raumfahrt (DLR) entwickelt (vgl. RICHTER 1996, 2003) und in ERDAS IMAGINE implementiert. Die seit 2002 verfügbare Software ist auch Bestandteil anderer Bildverarbeitungsprogramme (PCI, ENVI) oder als autonomes Programm verfügbar. Zwischen zwei Varianten kann gewählt werden: ATCOR2 ermöglicht eine Atmosphärenkorrektur, ATCOR3 erlaubt darüber hinaus eine topographische Berichtigung durch Verwendung eines Höhenmodells. Für die Korrektur der IKONOS-Daten wurde ATCOR3 in der Version 2.1 angewendet. Das Vorgehen wird im Folgenden ausführlich erläutert (siehe Abbildung 3.10).

Die vom Sensor aufzunehmende reflektierte Strahlung wird durch die Komponenten atmosphärisches Streulicht, Nachbarschaftseffekte *(adjacency effect)* und Terrainrückstrahlungen beeinflusst. Die ersten beiden Komponenten können durch eine radiometrische Kalibrierung herausgefiltert werden. Die letzte Komponente ist nur durch die Nutzung eines Höhenmodells zu extrahieren. Die verbleibende Rückstrahlung am Sensor wird in Reflexionsgrade

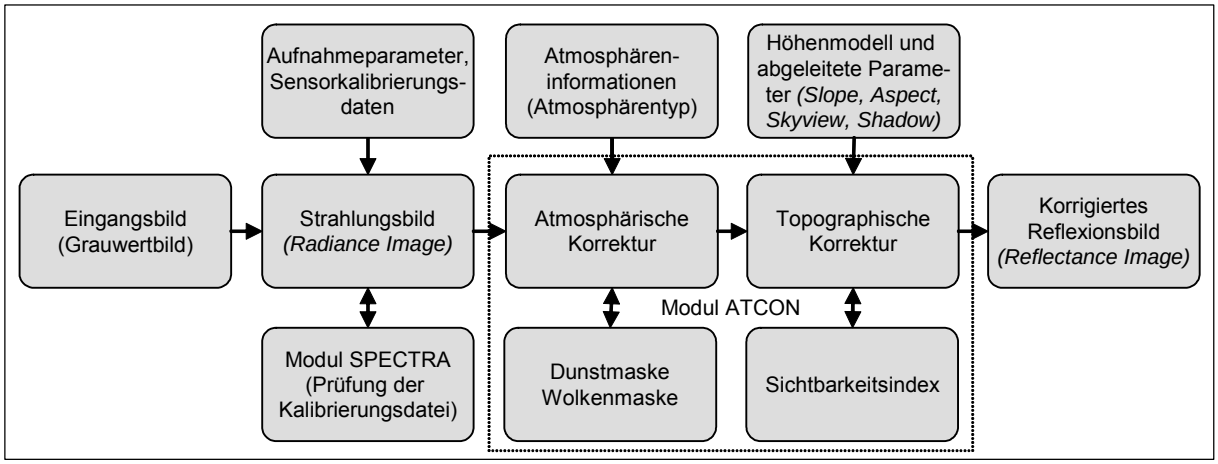

Abb. 3.10: Verfahrensablauf zur atmosphärischen und topographischen Korrektur mit ATCOR3. (Quelle: Eigene Darstellung)

der Oberfläche umgerechnet (vgl. GEOSYSTEMS 2002a: 8 ff.). Damit sollen die Grauwerte verschiedener Bildszenen vergleichbar gemacht werden. Orthorektifizierte Bilddaten sowie ein möglichst vierfach höher aufgelöstes Höhenmodell sind Voraussetzungen zur Anwendung von ATCOR3. Wird ein geringer aufgelöstes DHM genutzt, kann es zu Bildartefakten kommen. Bei der Verwendung von VHR-Daten ist die letzte Anforderung jedoch kaum erfüllbar. Alle Eingangsdaten müssen in einer einheitlichen Rasterung vorliegen.

Zunächst wird mittels des *Sun-position Calculators* in Abhängigkeit vom Aufnahmedatum (01.08.2000), der Überflugzeit (10:05) und des Szenenmittelpunktes *(Longitude* 14,05; *Latitude* 50,56) das solare Zenit (Sonnenhöhe) und das solare Azimut (Sonnenwinkel) berechnet. Dafür ergaben sich 35,2° bzw. 152,4°. Die nötigen Informationen sind der *Header*-Datei der Bilddaten zu entnehmen. Anschließend werden aus dem Höhenmodell die zusätzlichen Parameter *Slope* (Hangneigung), *Aspect* (Hangausrichtung), *Skyview* (Strahlverfolgungsverfahren zur Sichtbarkeitsanalyse des Himmels) und *Shadow* (Schattenflächen) berechnet. Diese Berechnungen sind sehr zeit- und ressourcenaufwändig. So betrug beispielsweise die Zeit dieses Berechnungsschritts für die Gesamtszene der Sächsischen Schweiz insgesamt 3,5 Stunden und ein Arbeitsspeicher von 2 GB war nötig. Das aus dem Laserscanner-DHM abgeleitete Hangneigungsmodell weist Artefakte auf (vgl. Abbildung 3.11), die insbesondere in der Elbe sowie auf den ebenen Hochflächen auffallen. Die Artefakte werden vermutlich durch die Eigenschaften sowie die Genese des DHM hervorgerufen (vgl. Abschnitt 3.3.1). Sie lassen sich jedoch selbst durch den Einsatz von Filterverfahren nicht gänzlich eliminieren und haben negative Auswirkungen auf das Korrekturergebnis.

Im weiteren Verlauf sichert ein Abfragedialog (siehe Abbildung 3.12) die Eingabe aller notwendigen Daten und Parameter. Der Parameter Schwenkwinkel der IKONOS-Aufnahme kann indirekt aus der zugehörigen *Header-Datei* entnommen werden. Demnach beträgt der Aufnahmewinkel 71.4°, womit sich ein Sensorschwenkwinkel (Nadirabweichung) von ca. 17° ergibt (vgl. MEINEL & REDER 2001). Da die Eingabe nur in 10°-Schritten möglich ist, wurde ein Schwenkwinkel von 20° in östliche Richtung gewählt. Als Atmosphärentyp wurde die Option „midlat_summer_rural“ genutzt. Dies entspricht der Strahlungsregion Mittlere Breiten, Jahreszeit: Sommer, Aerosoltyp: rural. Die Sichtweite wurde nach Angaben des Deutschen Wetterdienstes (DWD, vgl. Tabelle 3.7) mit 25 km gewählt.

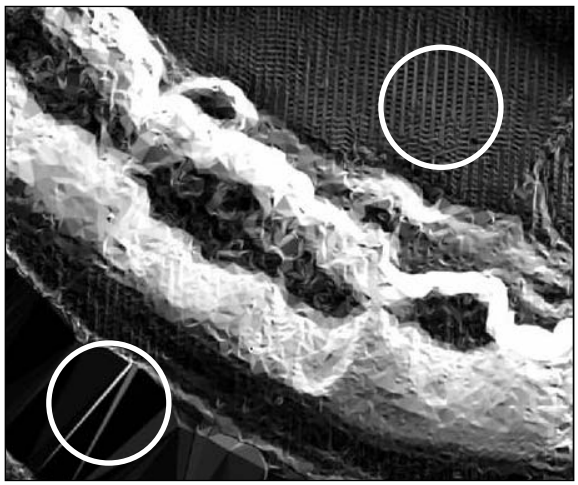

Abb. 3.11: Aus dem DHM abgeleitetes Hangneigungsmodell. In der Elbe (untere Markierung) sowie auf ebenen Hochflächen (obere Markierung) sind störende Artefakte deutlich erkennbar.
(Quelle: Eigene Darstellung)

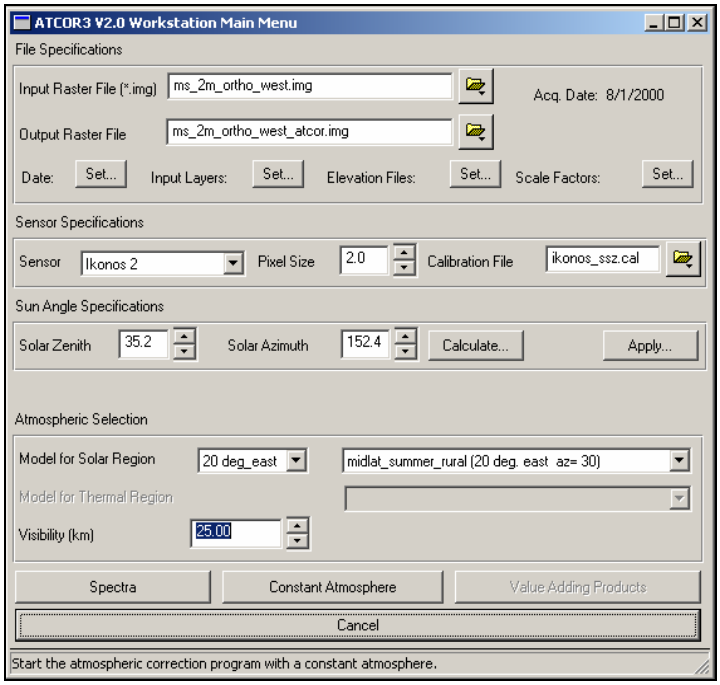

Abb. 3.12: Dialogfenster ATCOR3.
(Quelle: ATCOR3, eigene Darstellung)

Tab. 3.7: Wetterdaten der Station Lichtenhain-Mittelndorf, 01.08.2000, 9.50 Uhr.
(Quelle: DWD, eigene Darstellung)

Temperatur	21,1°C
Relative Luftfeuchte	50 %
Sichtweite	25 km
Luftdruck	983,5 hPa
Bedeckungsgrad	3 Okta
Sonnenhöhe	53,5°

Eine weitere wichtige Eingabe stellt das *sensor calibration file* dar, welches die Kalibrierungsdaten (Korrekturfaktoren *Bias* [c0] und *Gain* [c1]) jedes Kanals enthält. *Bias* beschreibt die spektrale Strahlenimmission am Sensor für einen Grauwert von Null. *Gain* repräsentiert den Kalibrierungsgradient. Die Angaben erfolgen in der Einheit elektromagnetischer Strahlung [mW cm^{-2} sr^{-1} μm^{-1}]. Mithilfe dieser Faktoren berechnet ATCOR3 die Rückstrahlung am Sensor.

Da das System sehr empfindlich auf diese Parameter reagiert, sollten sie sehr genau und aktuell für die jeweilige Szene vorliegen. IKONOS-Daten werden grundsätzlich vor Auslieferung radiometrisch kalibriert, wobei die vom Satelliten übertragenen Rohdaten umgerechnet werden (vgl. Abschnitt 3.1.2). Für die einzelnen Szenen sind keine spezifischen Kalibrierungswerte verfügbar. SPACE IMAGING (2003b) gibt lediglich Korrekturfaktoren für größere Zeitintervalle an, die jedoch ausreichend sind, da die Sensorkalibrierung langfristig erfolgt.

Von GEOSYSTEMS (2002a) wird ausdrücklich darauf hingewiesen, dass keine DRA-gestreckten IKONOS-Daten (vgl. Abschnitt 3.1.1) zur atmosphärischen Korrektur verwendet werden sollen, da dies zu Beeinträchtigungen führen kann. Laut *Header*-Datei der vorliegenden Szene ist entsprechend der Voreinstellungen eine DRA-Streckung der panchromatischen Daten durchgeführt worden, da dieser Punkt bei der Bestellung nicht beachtet wurde. Für DRA-gestreckte Daten muss die Kalibrierungsdatei selbst erstellt werden, da die in ATCOR vorhandenen Vorgaben hierfür nicht nutzbar sind. Für die Pan- und MS-Daten wurde mit

dem ATCOR-Modul SPECTRA eine vorhandene Kalibrierungsdatei, deren Relationen gute Übereinstimmungen zeigten, iterativ angepasst. Dabei wurden gemessene Spektren vorgegebenen Referenzspektren gegenübergestellt (siehe Abbildung 3.13, Tabelle 3.8). Die Abweichung sollte weniger als 10 % betragen (vgl. GEOSYSTEMS 2002b). Anschließend begann die eigentliche Atmosphärenkorrektur mit dem ATCOR-Modul ATCON. Sie erfolgte getrennt für panchromatische und multispektrale Bilddaten.

Für die multispektralen Bilddaten erfolgte eine Atmosphärenkorrektur mit Dunstkorrektur. Dabei wurde zuerst eine Maske generiert, welche die Dunst- und Wolkenverteilung der Szene enthält (siehe Abbildung 3.14). Um diese szenenspezifisch zu berechen, standen wiederum verschiedene Parameter zur Verfügung. Falls die Standardwerte nicht zu den gewünschten Ergebnissen führen, müssen sie iterativ an die jeweilige Szene angepasst werden (vgl. Tabelle 3.9).

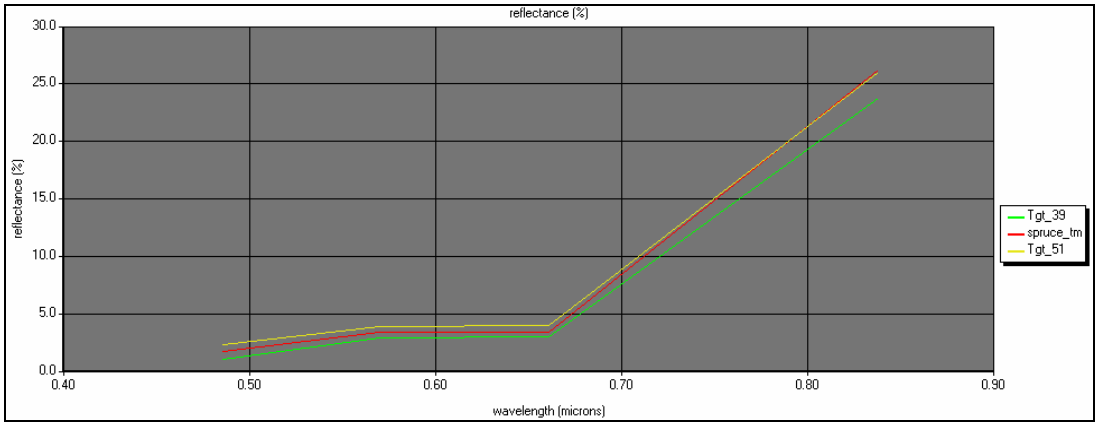

Abb. 3.13: Gute Übereinstimmung der Testspektren (tgt_39 und tgt_51) gegenüber des Referenzspektrums (Beispiel Fichte, spruce_tm) zur Überprüfung der Kalibrierungsdatei für die Multispektraldaten. (Quelle: ATCOR-Modul SPECTRA, eigene Darstellung)

Tab. 3.8: Erstellte Kalibrierungsdatei für die multispektralen IKONOS-Daten der Sächsischen Schweiz. (Quelle: Eigene Darstellung)

Kanal	c0 [mW cm^{-2} sr^{-1} μm^{-1}]	c1 [mW cm^{-2} sr^{-1} μm^{-1}]
1	0.0000	0.02500
2	0.0000	0.02013
3	0.0000	0.02075
4	0.0000	0.01200

Tab. 3.9: Genutzte Parameter im ATCOR-Modul ATCON. (Quelle: Eigene Darstellung)

Variante	*Haze Removal, incl. Visibility Index File*
Hazemask Thresholds	*Interactive*
Hazemask Properties: *Range for smoothing around haze* *Minimum size of island haze/cloud Polygons*	 500 m 250 Pixel
Haze Bound Algorithm	*Histogram Match*
Boundary Parameters: *Boundary width* *Thresholds for Estimation of optical Depth (Visibility)*	 2000 m T3 = 0,2 ; T4 = 1,0 ; T5 = 1,5
Additional Parameters: *Determine Terrain Reflectance* *BRDF Correction*	 *3 iterations for average terrain* *Empirical (Function 4 (für schwenkbare Sensoren); Threshold angle: 65; Lower boundary: 0,25)*

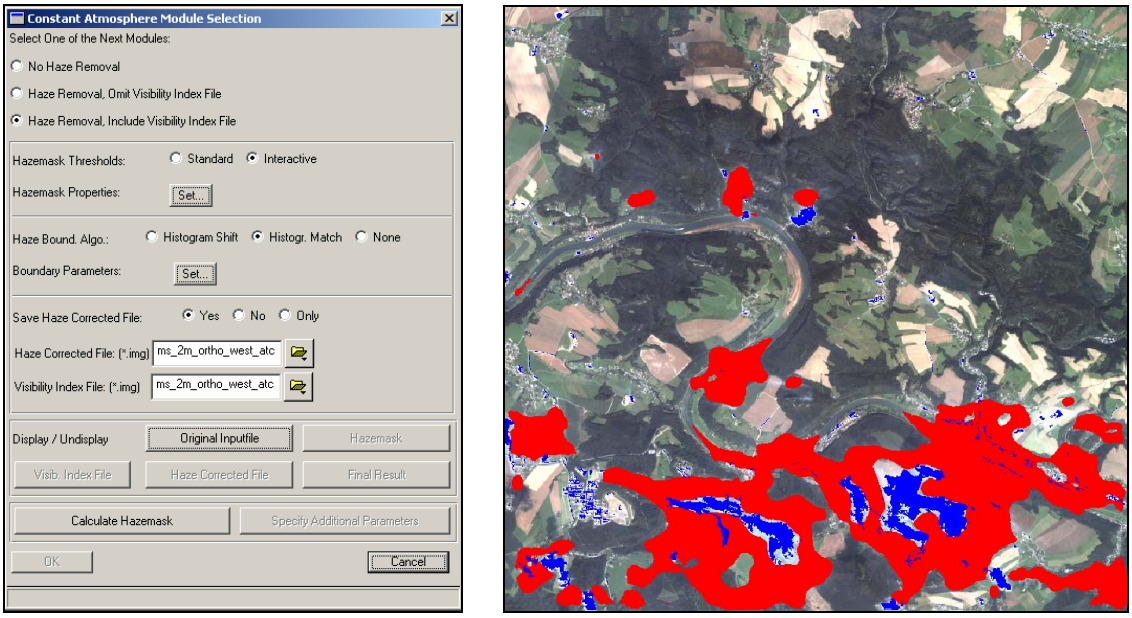

Abb. 3.14: Dialogfenster des Moduls ATCON (links) und Originalbilddaten überlagert mit der berechneten Dunstmaske (rechts; rot: Dunst, blau: Wolken).
(Quelle: ATCOR, eigene Darstellung, © Space Imaging)

Programm-intern erfolgt anschließend die Berechnung eines Sichtbarkeits-Index auf Grundlage des Höhenmodells, und die Bilddaten werden zunächst atmosphärisch korrigiert. In Kombination mit den anfangs aus dem DHM abgeleiteten Daten wird im weiteren Verlauf das Endergebnis generiert – eine atmosphärisch und topographisch berichtigte Szene.

Das Berechnungsergebnis war jedoch in vielerlei Hinsicht unbefriedigend und für eine weitere Nutzung unbrauchbar (siehe Abbildung 3.15b). Es enthielt falschfarbige Bereiche, wies Farbsprünge und Artefakte auf. Die Farbsprünge sind Folge der Dunstkorrektur und der ausgeprägten Abbildung des Dunstes in sehr hoch auflösenden Bilddaten. Infolgedessen schlägt die empirische Histogrammanpassung fehl. Die Artefakte treten an den im Gebiet häufig vorkommenden steilen, schattigen Hang- und Felsbereichen auf.

Hinweise der Entwicklerfirma Geosystems führten zu einer zweiten Berechnungsvariante ohne Dunstkorrektur. Darüber hinaus wurden einige Parameter verändert (keine Berücksichtigung des Aufnahmewinkels; *Bidirectional reflectance distribution function* (BRDF) = 1; *Threshold angle* = 50°). Das Ergebnis wies keine Farbsprünge auf und besaß ähnliche Histogramme wie das Original (siehe Abbildung 3.15c). Es zeigten sich nur geringe Korrekturen an Schatthängen und insgesamt „wärmere“ Farben. Bedingt durch das DGM enthielt es jedoch kleinere Artefakte. Der Dunst im Bild war unverändert vorhanden. Somit stellte auch diese Berechnungsvariante den gesamten aufwändigen Bearbeitungsprozess infrage.

Für die panchromatischen Bilddaten muss die Atmosphärenkorrektur gesondert erfolgen. Die Vorgehensweise sowie die Parametereinstellungen stimmen dabei mit dem oben beschriebenen Korrekturverfahren der Multispektraldaten überein. Mit dem Modul SPECTRA muss zunächst wieder eine Kalibrierungsdatei erstellt werden. Im Anschluss erfolgt die Berechnung mittels ATCON ohne Dunstkorrektur, da den panchromatischen Daten ein Kanal zur Bestimmung des Dunstes fehlt. In einer späteren Programmversion soll der Import von Dunstmasken, die z. B. aus den zugehörigen multispektralen Daten berechnet wurden, ermöglicht werden. Panchromatische Daten können demnach gegenwärtig nur topographisch berichtigt werden.

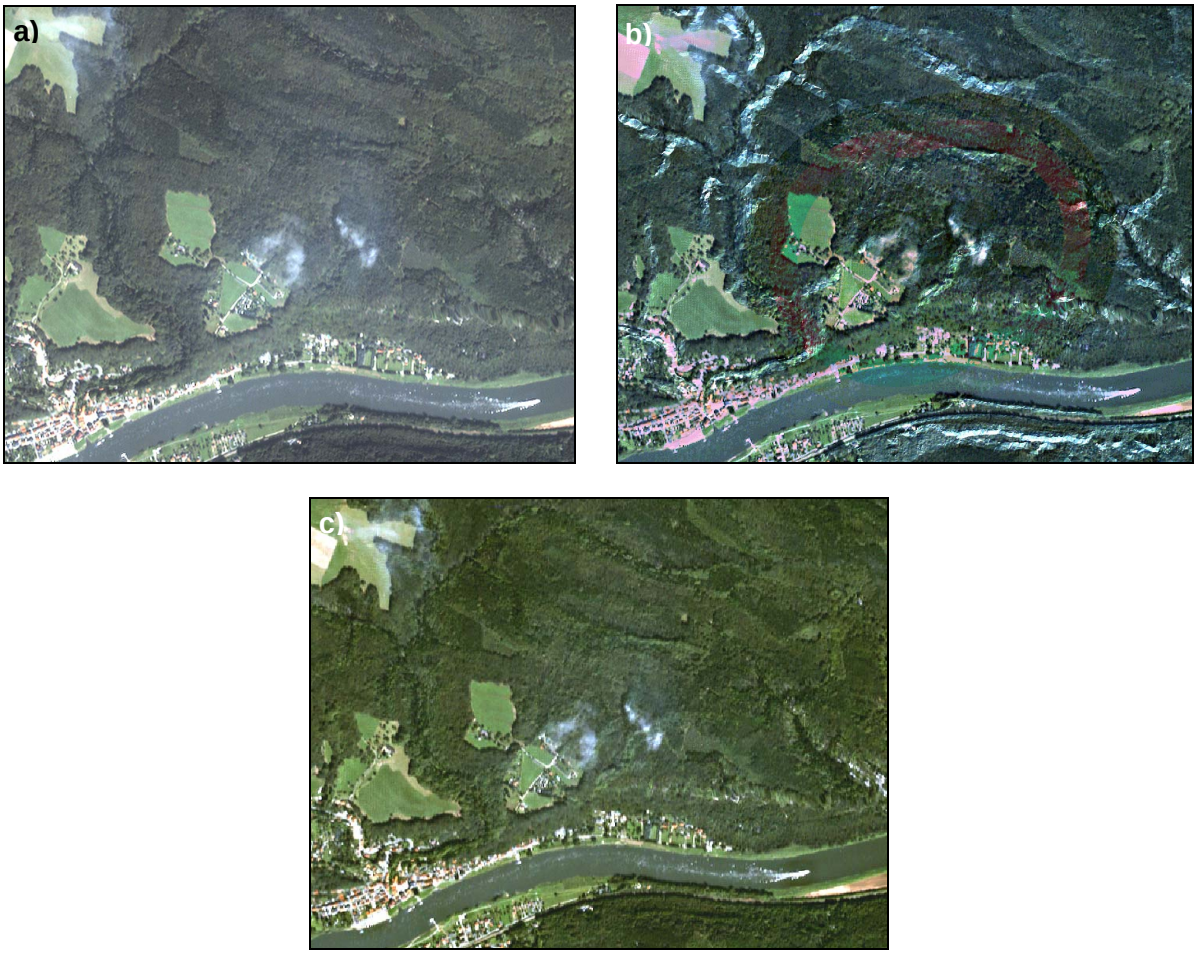

Abb. 3.15: Gegenüberstellung eines Ausschnittes des originalen IKONOS-Bildes (a) mit dem atmosphärisch und topographisch korrigierten Ergebnis (b) sowie dem Ergebnis ohne Dunstkorrektur (c).
(Quelle: Eigene Darstellung, © Space Imaging)

Das Ergebnis der Atmosphärenkorrektur der panchromatischen Bilddaten ist zufrieden stellend, wenngleich es durch die Kontrastverbesserung in den Schattenbereichen eher dunkler wirkt als zuvor. Der höhere Kontrast lässt das Bild etwas schärfer erscheinen. Das DHM führt lediglich zu kleineren Artefakten, die aber durch dessen Eigenschaften zustande kommen.

Schlussfolgernd kann festgehalten werden, dass die atmosphärische und topographische Korrektur sehr hoch aufgelöster Fernerkundungsdaten derzeit noch nicht ausgereift und operationell anwendbar ist. Insbesondere die großen Datenmengen stellen in Kombination mit den aufwändigen Berechnungen der Atmosphärenkorrektur ein Hindernis dar. Eine befriedigende Dunstkorrektur war mit der genutzten Software ATCOR3 (Version 2.1) nicht möglich. Für die weiteren Untersuchungen im Rahmen dieser Arbeit wurden daher atmosphärisch unkorrigierte Daten verwendet.

In einer weiterführenden Kooperation mit dem DLR und Geosystems wurden weitere Programmanpassungen vorgenommen, um die Ergebnisse zu optimieren. Abbildung 3.16 zeigt beispielhaft ein Korrekturergebnis, welches mit einer verbesserten Programmversion erzielt wurde und im Vergleich zur vorhergehenden Untersuchung eine bessere Qualität erbringt. Diese neue Version – ATCOR3 für ERADAS IMAGINE 8.7 – ist seit Mai 2004 verfügbar.

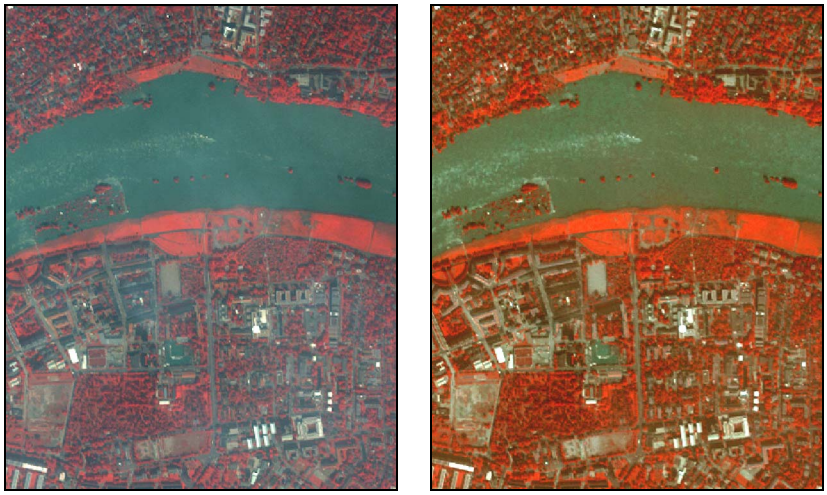

Abb. 3.16: Stark dunstbeeinflusstes multispektrales IKONOS-Satellitenbild der Stadt Dresden (Aufnahme vom 18.08.2002; links) und dessen dunstbereinigtes Korrekturergebnis (rechts). (Quelle: ATCOR, eigene Darstellung, © Space Imaging)

3.2.3 Bildfusion

Um die Abgrenzungsschärfe der panchromatischen IKONOS-Bilddaten mit den Spektralinformationen der Farbkanäle zu kombinieren, lassen sich Bildfusionsverfahren *(resolution merge)* nutzen. Das Ergebnis ist ein visuell ansprechendes, geschärftes Multispektralbild mit einem Meter Bodenauflösung, welches eine verbesserte Grundlage für nachfolgende Auswertungsschritte bieten soll. Folgende Fusionsverfahren wurden getestet:

Im Rahmen der IHS-Transformation werden die im RGB-Spektrum vorliegenden 8-Bit-Bilddaten in den IHS-Farbraum *(Intensity, Hue, Saturation* – Intensität, Farbton, Sättigung) transformiert. Nachteilig ist, dass dabei nur dreikanalige Farbbilder verwendet werden können. Nach der Transformation wird die *Intensity*-Komponente durch den panchromatischen Kanal ersetzt. Die Histogramme dieser beiden Kanäle sollten angepasst werden. Danach wird das Bild in den RGB-Farbraum rücktransformiert (vgl. ALBERTZ 2001).

Beim Hauptkomponentenverfahren *(Principal component transform,* PC) wird der hoch aufgelöste panchromatische Datensatz in den Datenbereich einer ersten Hauptkomponente umgewandelt, welche die erste Hauptkomponente des multispektralen Bildes unter Beachtung deren Spannbreite ersetzt. Anschließend erfolgt eine inverse Hauptkomponententransformation. Die thematischen Informationen werden durch die Berechnungen nicht verändert und die Szenenradiometrie wird bestmöglich erhalten. Das Verfahren gewichtet jeden Kanal gleich und bedarf eines hohen Rechenaufwandes (vgl. LILLESAND & KIEFER 2000). Die Ergebnissqualität des PC-Verfahrens ist abhängig vom jeweiligen Bildausschnitt.

Durch die Multiplikation der panchromatischen mit den Multispektraldaten erreicht man eine multiplikative Bildfusion. Vor dieser Kombination werden beide Eingangsdatensätze mit unterschiedlichen Faktoren gewichtet. Insgesamt handelt es sich hierbei um ein einfaches mathematisches Verfahren, welches häufig zu Farbverschiebungen führt.

Die Brovey-Transformation gehört zur Gruppe der arithmetischen bzw. Ratio-Fusionsverfahren. Die normierten multispektralen Grauwerte werden hierbei mit den panchromatischen Grauwerten multipliziert. Dieses Verfahren ist nur für dreikanalige Bilddaten anwendbar. Es dient zur Kontrastanhebung in hohen und niedrigen Grauwertbereichen.

Bei der Anwendung der von STEINNOCHER (1999) entwickelten *Adaptive Image Fusion* (AIF) bleiben die Original-Farbwerte weitestgehend erhalten. Die Anwendung der Software erfor-

dert zunächst die Umrechnung der Bilddaten auf eine einheitliche Auflösung (1 m) sowie die Konvertierung in das ERDAS LAN-Format. Beide Datensätze werden anschließend unter Nutzung eines Sigma-Varianzfilters iterativ kombiniert. Das Ergebnis bildet die in den panchromatischen Bilddaten sichtbaren Kanten ab. Kanten, die nur in den Multispektraldaten sichtbar sind, bleiben dagegen nicht erhalten. Auch die Texturinformation der Bilddaten wird nicht bewahrt. Insgesamt kommt es zu einer Glättung des Bildmaterials, wobei Unschärfen und Verwischungseffekte auftreten. Kleinobjekte gehen bei der Berechnung zum Teil verloren. Das AIF-Verfahren ist demnach weniger für eine visuell ansprechende Datenaufbereitung geeignet, es wurde vielmehr zur Vorverarbeitung für nachfolgende Klassifikationen, inbesondere von Hauptnutzungsklassen, entwickelt (vgl. STEINNOCHER 1999).

Ein neues standardisiertes Verfahren wurde von ZHANG (2002) entwickelt. Es basiert auf der Bildstatistik (Methode der kleinsten Quadrate) und kommt gänzlich ohne zusätzliche Parameter aus. Die Ergebnisse weisen einen hohen Detailliertheitsgrad sowie sehr geringe Farbunterschiede zum Original auf. Der Algorithmus ist in der Software PCI Geomatica implementiert.

Um optimale Vergleichsergebnisse zu erzielen, wurde ein von Space Imaging im Internet bereitgestellter IKONOS-Beispieldatensatz verwendet (San Diego, USA, 16 Bit, 1000 x 1000 Pixel; vgl. Abbildung 3.17). Die IKONOS-Szene weist sehr gute Aufnahmebedingungen auf und wurde keiner DRA-Streckung unterzogen. Ebenfalls war ein Fusionsprodukt verfügbar, welches mit einem nicht offen gelegten Algorithmus von Space Imaging berechnet wurde. Dieser Datensatz wurde zusätzlich in den Vergleich einbezogen.

Eine wichtige Rolle spielt im Rahmen der Bildfusion das gewählte *Resampling*-Verfahren. Die in Abschnitt 3.2.1 dargestellten Varianten werden in Abbildung 3.18 am Beispiel des PC-Fusionsverfahrens graphisch gegenübergestellt. Das beste Ergebnis wurde mit dem *cubic convolution*-Verfahren erreicht, da es das Resultat der *bilinear interpolation*-Methode an Schärfe und Kontrast übertrifft. Das Ergebnis der *nearest neighbour* Interpolation führt zu den für dieses Verfahren typischen Treppeneffekten. Für alle Berechnungen wurde demzufolge die *Resampling*-Methode *cubic convolution* gewählt, soweit diese Vorgabe wählbar war.

Abb. 3.17: Für den Bildfusionsvergleich verwendete panchromatische (1 m Bodenauflösung, links) und multispektrale (4 m, rechts) IKONOS-Originaldaten von San Diego, USA.
(Quelle: Eigene Darstellung, © Space Imaging)

Abb. 3.18: Fusionsergebnisse der PC-Bildfusion mit unterschiedlichen Resampling-Verfahren: *cubic convolution* (links), *bilinear interpolation* (Mitte) sowie *nearest neighbour interpolation* (rechts). (Quelle: Eigene Darstellung, © Space Imaging)

Die Ergebnisse der weiteren Fusionsverfahren zeigt Abbildung 3.19. Dabei erweisen sich die Resultate der Verfahren der IHS-, der multiplikativen sowie der Brovey-Fusion als wenig geeignet, da sie starke spektrale Abweichungen gegenüber dem Original aufweisen. Die erzielte Bildschärfe ist dagegen beim IHS- und Brovey-Verfahren sehr gut. Die Gründe für die Farbverschiebungen bei der Verwendung der IHS-Fusion für sehr hoch auflösende Bilddaten liegen in deren breitem panchromatischen Spektrum gegenüber früher verfügbaren Daten (z. B. IRS 0,50-0,75 µm; IKONOS 0,45-0,90 µm). Es wurde bei IKONOS (auch bei QuickBird und Landsat-7) bis in den nahen Infrarotbereich ausgedehnt. Dadurch ergibt sich ein deutlicher Unterschied zwischen den panchromatischen Daten und dem Intensitätskanal der IHS (vgl. ZHANG 2002).

Die AIF-Methode führt zu einem stark abweichenden Ergebnis. Die Berechnungsparameter müssen durch iterative Tests an das Bildmaterial angepasst werden. Die verwendeten Parameter (Filtergröße 9x9, 0,01 Varianz, 3 Iterationen) führen zu einer deutlichen Glättung der Bilddaten. Deutlich sichtbare Kanten, die durch andere Fusionsverfahren erhalten bleiben, werden aufgelöst. Diese Effekte können sich negativ auf eine Segmentierung auswirken (vgl. FISTRIC 2002), können aber durch die Verminderung von Details auch vorteilhaft sein.

Die Abhängigkeit der Fusionsergebnisse von den jeweiligen Sensoreigenschaften (z. B. Eigenschaften der Spektralkanäle) sowie von den Bilddaten (z. B. evtl. Vorverarbeitungsschritte) zeigt auch der Vergleich mit anderen Publikationen. So ermittelte MÖLLER (2003) die Brovey- bzw. die IHS-Transformation als geeignete Verfahren für die höchstauflösenden Flugzeugscannerdaten des HRSC-A-Sensors.

Die Ergebnisse der PC-Methode (siehe Abbildung 3.18), des Verfahrens von ZHANG (2002) und des Space-Imaging-eigenen Fusionsalgorithmus weisen eine ähnlich hohe Qualität auf. Diese drei Methoden führen zu sehr geringen Farbabweichungen gegenüber den originalen Multispektraldaten sowie zu einer hohen Bildschärfe. Zudem ermöglichen diese drei Verfahren die Fusion aller vier Spektralkanäle mit der vollen radiometrischen Auflösung von 16 Bit. Nachteilig bei der Nutzung des Space-Imaging-Produktes *(pan-sharpened)* ist, dass nur die Fusionsprodukte und nicht die Originaldaten geliefert werden. Bei Bestellungen von geschärften QuickBird-Daten beim Konkurrenten DigitalGlobe stehen vier Fusionsverfahren zur Auswahl: IHS-, PC-, ZHANG- oder ein ebenfalls geheim gehaltenes, firmeninternes Verfahren. Aufgrund der frühen Verfügbarkeit sowie der guten Ergebnisse wurde im Rahmen dieser Arbeit das Fusionsergebnis des PC-Verfahrens verwendet.

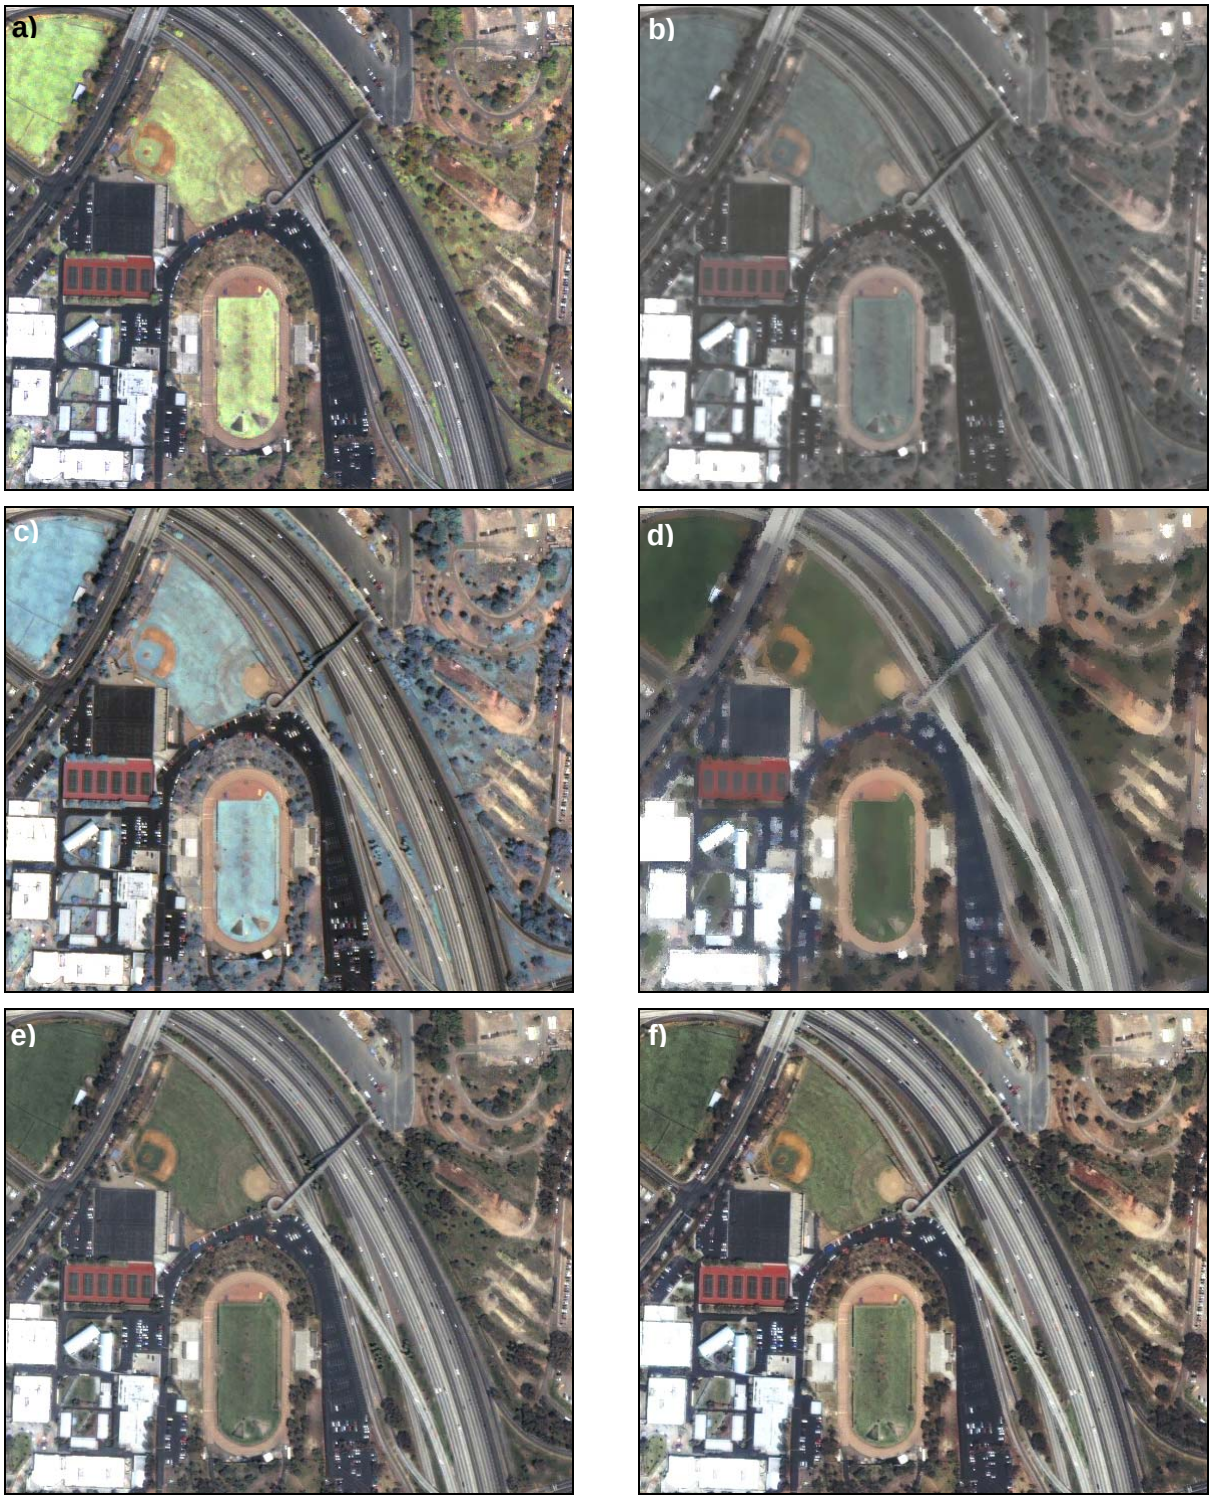

Abb. 3.19: Fusionsergebnisse IHS-Transformation (a), multiplikative Bildfusion (b), Brovey-Transformation (c), AIF-Verfahren (d), Fusion nach ZHANG 2002 (e) sowie von Space Imaging panchromatisch geschärfte IKONOS-Daten (f).
(Quelle: Eigene Darstellung, © Space Imaging)

3.3 Weitere Datengrundlagen

Neben den Bilddaten können zur Klassifikation zahlreiche Zusatzdaten verwendet werden. Viele verschiedene Kombinationen wurden im Rahmen der Arbeit getestet. Im Folgenden werden die letztlich genutzten Zusatzdaten charakterisiert.

3.3.1 Laserscanner-Höhenmodell

Flugzeuggetragene Laserscanner messen die Laufzeit eines ausgesendeten Laserimpulses zwischen Sender und reflektierender Oberfläche. Aus diesen Informationen lassen sich digitale Höhenmodelle bestimmen. Dabei wird mithilfe der durch DGPS und IMU exakt ermittelten Sensorposition sowie dem Winkel des ausgesandten Laserpulses aus der Laufzeit des Signals die Entfernung zur Oberfläche berechnet. Heute werden zumeist das erste (z. B. durch die Vegetationsoberfläche) und das letzte (durch die Bodenoberfläche) reflektierte Signal simultan aufgezeichnet *(first* bzw. *last pulse)*. Erstgenannte Messungen eignen sich zur Erstellung von digitalen Oberflächenmodellen (DOM), letztere zur Generierung von digitalen Geländemodellen (DGM). Neue Sensorkombinationen erlauben die simultane Aufzeichnung von DHMs und optischen Bilddaten (z. B. HRSC-Kamera). Künftig wird daneben die Erstellung von hoch aufgelösten DHMs mithilfe interferometrischer *Synthetic Aperture Radar*-Sensoren (InSAR bzw. IfSAR) an Bedeutung gewinnen (z. B. *Shuttle Radar Topography Mission* – SRTM). Einen Vergleich verschiedener Erfassungsmethoden zeigen REICH & THIEL (2002).

Zur Entzerrung der IKONOS-Daten der Sächsischen Schweiz sowie teilweise zu deren Klassifikation wurde ein Laserscanner-DGM verwendet (siehe Abbildung 3.20). Die Befliegung wurde von der Firma TopScan durchgeführt. Die Daten wurden vom Institut für Photogrammetrie und Fernerkundung der Technischen Universität Dresden zur Verfügung gestellt. CSAPLOVICS & WAGENKNECHT (1999) beschreiben die Aufnahmeparameter und -technik sowie die Vorverarbeitungsverfahren des DGM umfassend. Aus den 1997 aufgenommenen Laserdaten wurden mittels Filterverfahren Vegetations- und andere Streusignale eliminiert. Der mittlere Punktabstand beträgt 3 m, die mittlere Lagegenauigkeit 1 m und die mittlere Höhengenauigkeit 0,5 m. Die in einer unregelmäßigen Verteilung vorliegenden Messpunkte wurden auf eine einheitliche Rasterweite von 1 m umgerechnet. Dieses Vorgehen kann zu geringfügigen Interpolationsfehlern führen. Ebenso werden Fehler durch die nahezu vollständige Absorption des Lasersignals in Gewässern und Feuchtgebieten hervorgerufen.

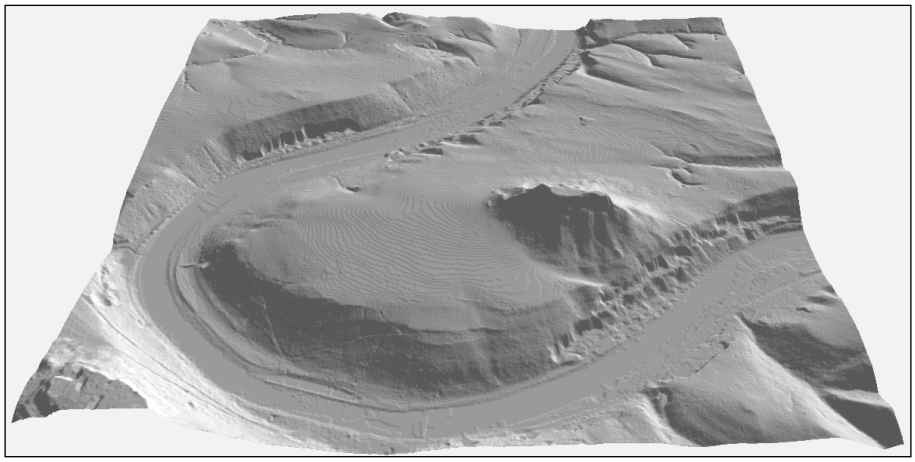

Abb. 3.20: 3D-Abbildung des Laserscanner-DGM für einen Ausschnitt der Sächsischen Schweiz. Dargestellt sind die Elbschleife bei Königstein sowie der Lilienstein.
(Quelle: Eigene Darstellung)

3.3.2 Aus IKONOS-Daten abgeleitete Indizes

Verschiedene spektrale und Texturindizes wurden getestet, um sie unterstützend zur Klassifikation der IKONOS-Daten einzusetzen. Verwendet wurde letztlich nur der Vegetationsindex NDVI *(Normalized Difference Vegetation Index)*. Der NDVI wird berechnet, indem die Differenz zwischen nahem Infrarot- und rotem Kanal durch die Summe der zwei Kanäle dividiert wird. Das Ergebnis dient der besseren Differenzierung von unterschiedlichen Vegetationsarten sowie zur eindeutigen Identifizierung vegetationsloser Flächen.

3.3.3 Verwendete Geobasisdaten

Als Zusatzdaten im Rahmen einer Bildklassifikation lassen sich die Geometrie und/oder die Attribute von Geobasisdaten im Vektorformat nutzen. Im Rahmen dieser Arbeit wurden folgende drei Datensätze verwendet:

- Daten des Amtlichen Topographisch-Kartographischen Informationssystems (ATKIS) (Landesvermessungsamt Sachsen, Stand 1992 (Vordere Sächsische Schweiz) bzw. 1993 (Dresden)),
- die Biotop- und Nutzungstypenkartierung (Sächsisches Landesamt für Umwelt und Geologie, Stand 1992/93) sowie
- eine Digitale Blockkarte der Stadt Dresden (Städtisches Vermessungsamt, Stand 1999).

Die ATKIS-Daten werden von den Landesvermessungsverwaltungen bereitgestellt. Sie werden nach einem bundesweit einheitlichen Objektartenkatalog (OK) erfasst (vgl. ADV 2000). Die ATKIS-Daten wurden unter anderem mit dem Ziel bereitgestellt, als Basisgeometrie für aufbauende Fachdaten zu dienen. Die restriktive Datenpolitik der Vermessungsämter sowie die hohen Datenpreise selbst für eine behördeninterne Nutzung führten jedoch nicht zu einer derartigen Verwendung. Die Daten des Basis-DLM (Digitales Landschaftsmodell, früher DLM 25) sind meist lagegenauer als der angegebene Maßstab von 1 : 25 000 erwarten lässt, da sie je nach Vorhandensein auf Basis der DGK 1 : 5 000, Orthophotos, der TK10 bzw. oder TK25 sowie unter Nutzung des ALK digitalisiert wurden. Die Lagegenauigkeit der Daten liegt bei ±3 m. Auf Fehler und Probleme bei der Nutzung von ATKIS-Daten weist ZÖLITZ-MÖLLER (2000, 2002) hin. Für die Klassifikation des Gebietes der Sächsischen Schweiz wurde das ATKIS-Basis-DLM (Realisierungsstufe 1, früher DLM 25/1) verwendet, um das Verkehrswegenetz sowie die Siedlungsgrenzen zu definieren.

Die in einigen Bundesländern flächendeckend vorliegenden Biotop- und Nutzungstypenkartierungen (BNTK) der Umweltverwaltungen wurden durch visuelle Interpretation von Farbinfrarot-Luftbildern (CIR-Luftbildern) im Maßstab 1 : 10 000 erstellt (vgl. z. B. für Sachsen: FRIETSCH 2001). Sie weisen jeweils nur landesweit gültige Interpretationsschlüssel auf, obwohl Bestrebungen zu einer Homogenisierung existieren (vgl. BFN 1995, 2002b). Weitere Eigenschaften dieses Datensatzes werden in Abschnitt 6.3 erläutert. Die BNTK-Daten dienten hauptsächlich zum Vergleich mit den Ergebnissen der aus IKONOS-Daten erstellten Biotop- und Nutzungstypenklassifikation.

Für die Auswertung des Untersuchungsgebietes Dresden wurde die digitale Blockkarte der Stadt Dresden verwendet. Die Blockrestfläche kann dazu dienen, Straßenflächen sicher abzugrenzen und zu klassifizieren. Insbesondere durch Baumkronen wird die Erkennbarkeit von Straßen in Fernerkundungsdaten und damit deren Klassifikation stark beeinträchtigt.

„Segmentation is one of the deepest problems in pattern recognition.“

RICHARD O. DUDA, PETER E. HART & DAVID G. STORK (2001)

4 Segmentbasierte Auswertungsmethoden

Die Grundlagen der Bildsegmentierung wurden bereits in Abschnitt 2.2.3 ausführlich dargestellt. Im Folgenden werden die angewendeten Methoden der segmentbasierten Klassifikation und speziell die Software eCognition näher erläutert. Zudem werden ein Vergleich mit pixelbasierten Klassifikationsverfahren sowie eine Gegenüberstellung aktuell verfügbarer Segmentierungsprogramme beschrieben.

4.1 Der segmentbasierte Klassifikationsansatz eCognition

eCognition ist ein Softwarepaket für die Auswertung von Fernerkundungsdaten und eines der ersten kommerziell verfügbaren Programme, welches dafür einen Segmentierungsalgorithmus nutzt. Aufbauend auf einer initialen Segmentierung lässt sich das Zwischenergebnis mit umfangreichen Werkzeugen klassifizieren. Die Klassenbeschreibung erfolgt durch ein komplexes System von Klassifikationsregeln in Form einer Wissensbasis. Damit ist eCognition der Gruppe von Expertensystemen (vgl. Abschnitt 2.2.4) zuzuordnen. Vergleichbare Segmentierungsalgorithmen sind derzeit noch nicht in den Standardprogrammen zur Bildverarbeitung von Fernerkundungsdaten, wie ERDAS IMAGINE, ENVI oder PCI Geomatica, integriert.

Die einzelnen Komponenten der Software – die hierarchische Segmentierung mit aufeinander aufbauenden Segmentierungsebenen, das dadurch generierte semantische Netz von Bildsegmenten sowie die wissensbasierte Klassifikation (siehe Abbildung 4.1) – werden im Folgenden näher erläutert und bewertet.

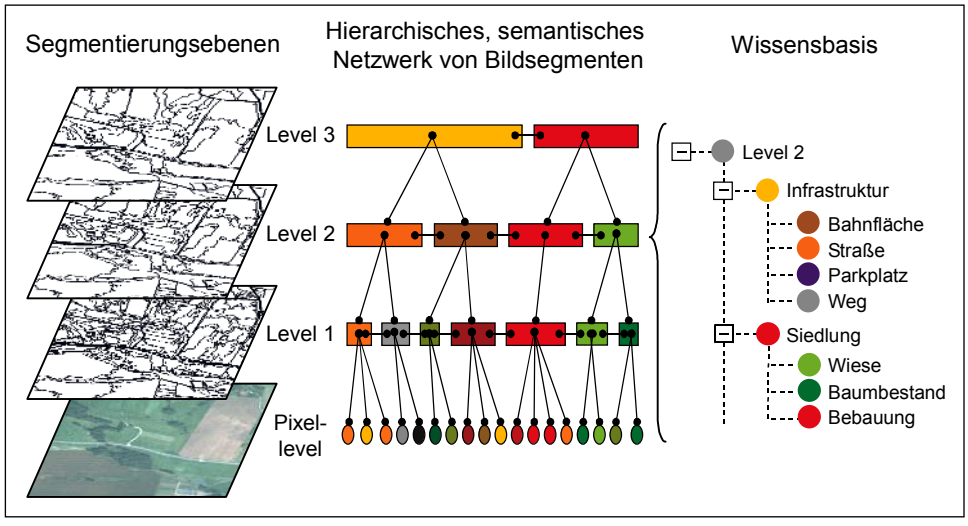

Abb. 4.1: Komponenten der eCognition-Software: Ebenenweise aufeinander aufbauende Segmentgeometrie, Hierarchie und Semantik der Segmente sowie die Wissensbasis zur Klassifikation. (Quelle: Eigene Darstellung)

4.1.1 eCognition-Segmentierungsverfahren

Als Datengrundlage für eine Segmentierung mit eCognition lassen sich verschiedene Rasterdatenformate über eine umfangreiche Datenschnittstelle importieren. Die Bilddaten können von unterschiedlicher Auflösung sein, intern werden sie auf die kleinste Auflösung gerastert. Darüber hinaus ist auch die Verwendung thematischer Raster- oder Vektordaten (ArcView-Shapeformat) möglich.

Zur Zusammenfassung der einzelnen Pixel zu Segmenten wird in eCognition der regionenbasierte Ansatz *fractal net evolution approach* genutzt (vgl. BAATZ & SCHÄPE 2000). Zu Beginn des Verfahrens werden alle Einzelpixel als Segmente aufgefasst. Sie werden mit benachbarten Segmenten aufgrund ihrer lokalen Homogenität zunehmend verschmolzen *(bottom-up region-merging technique)*. Das zugrunde liegende Homogenitätskriterium – die so genannten *merging costs* – wird bei jeder Verschmelzung überprüft *(degree of fitting)*. Zwei benachbarte Segmente werden verschmolzen, wenn der Anstieg der Heterogenität minimal im Vergleich zu den anderen Vereinigungsmöglichkeiten ist. Übersteigt das Homogenitätskriterium einen vorgegebenen Schwellwert, kann das untersuchte Segment nicht verschmolzen werden *(least degree of fitting)*. Der Prozess wird beendet, wenn keine Verschmelzungen mehr möglich sind. Der Schwellwert führt je nach Wahl zu unterschiedlich großen Objekten mit verschiedenen Homogenitätseigenschaften und wird daher als *Scale*-Parameter bezeichnet (vgl. ebd.).

Neben dem *Scale*-Parameter wird die Segmentierung durch weitere Parameter gesteuert, welche die farbliche *(color)* und formale Homogenität *(shape)* gewichten. Der Formparameter *shape* unterteilt sich weiter in Kompaktheit *(compactness)* und Linienglätte *(smoothness)*. Der *Scale*-Faktor wird durch eine gewichtete Standardabweichung der spektralen Kanäle bestimmt. Die einzelnen Bildkanäle können dabei unterschiedlich gewichtet werden. Der Wert des *Scale*-Parameters ist frei wählbar. Da die Wirkungsweise der weiteren Parameterpaare *color* und *shape* sowie *compactness* und *smoothness* gegenläufig ist, werden sie durch eine Gewichtung festgelegt, deren Summe jeweils Eins ergibt. Im Falle der Formparameter wird die Homogenität wie folgt berechnet: Das Verhältnis der Grenzlänge des Objektes zur Anzahl der Pixel bestimmt den Parameter *compactness.* Dabei ist das kompakteste Element ein Quadrat. *Smoothness* wird durch den Quotienten von Grenzlänge des Objektes zur Hüllgeometrie *(bounding box)* berechnet. Ein glattrandiges Segment besitzt möglichst keine ausgefransten bzw. fraktalen Grenzen (vgl. DEFINIENS IMAGING 2003). Der in Abbildung 4.2 dargestellte Segmentierungsdialog verdeutlicht die Parametereingabe.

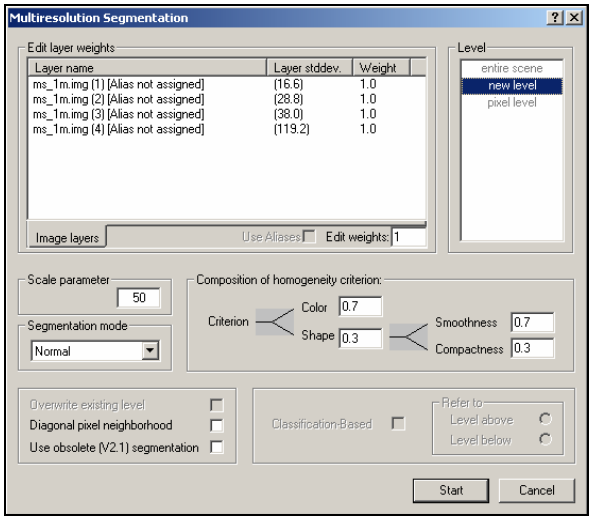

Abb. 4.2: Dialogfenster zur Eingabe der Segmentierungsparameter in eCognition 3 (Erläuterung im Text). (Quelle: Eigene Darstellung, eCognition 3)

Die Wirkung der einzelnen Parameter verdeutlicht Abbildung 4.3. Die alleinige Nutzung des Farbparameters führt zu farblich homogenen, aber stark übersegmentierten Flächen (a). Die maximale Gewichtung des Formparameters *shape* (0,9) und die alleinige Gewichtung des Parameters *compactness* führt dagegen zu einer für Klassifikationszwecke unbrauchbaren Untersegmentierung (b), da die Farbeigenschaften der Objekte weitestgehend vernachlässigt werden. Durch die extreme Wahl des Parameters *smoothness* werden dagegen kleine Flächen ungenügend berücksichtigt (c). Beispiel (d) zeigt eine gute Parameterkombination. Der noch enthaltenen Übersegmentierung lässt sich durch die Wahl eines höheren *Scale*-Parameters und der gleichzeitigen Anpassung der weiteren Parameter in einer übergeordneten Segmentierungsebene begegnen (e). Das Segmentierungsergebnis ist somit immer eine Kombination aus *Scale*-, Farb- und Formparameter angepasst an die jeweiligen Bilddaten.

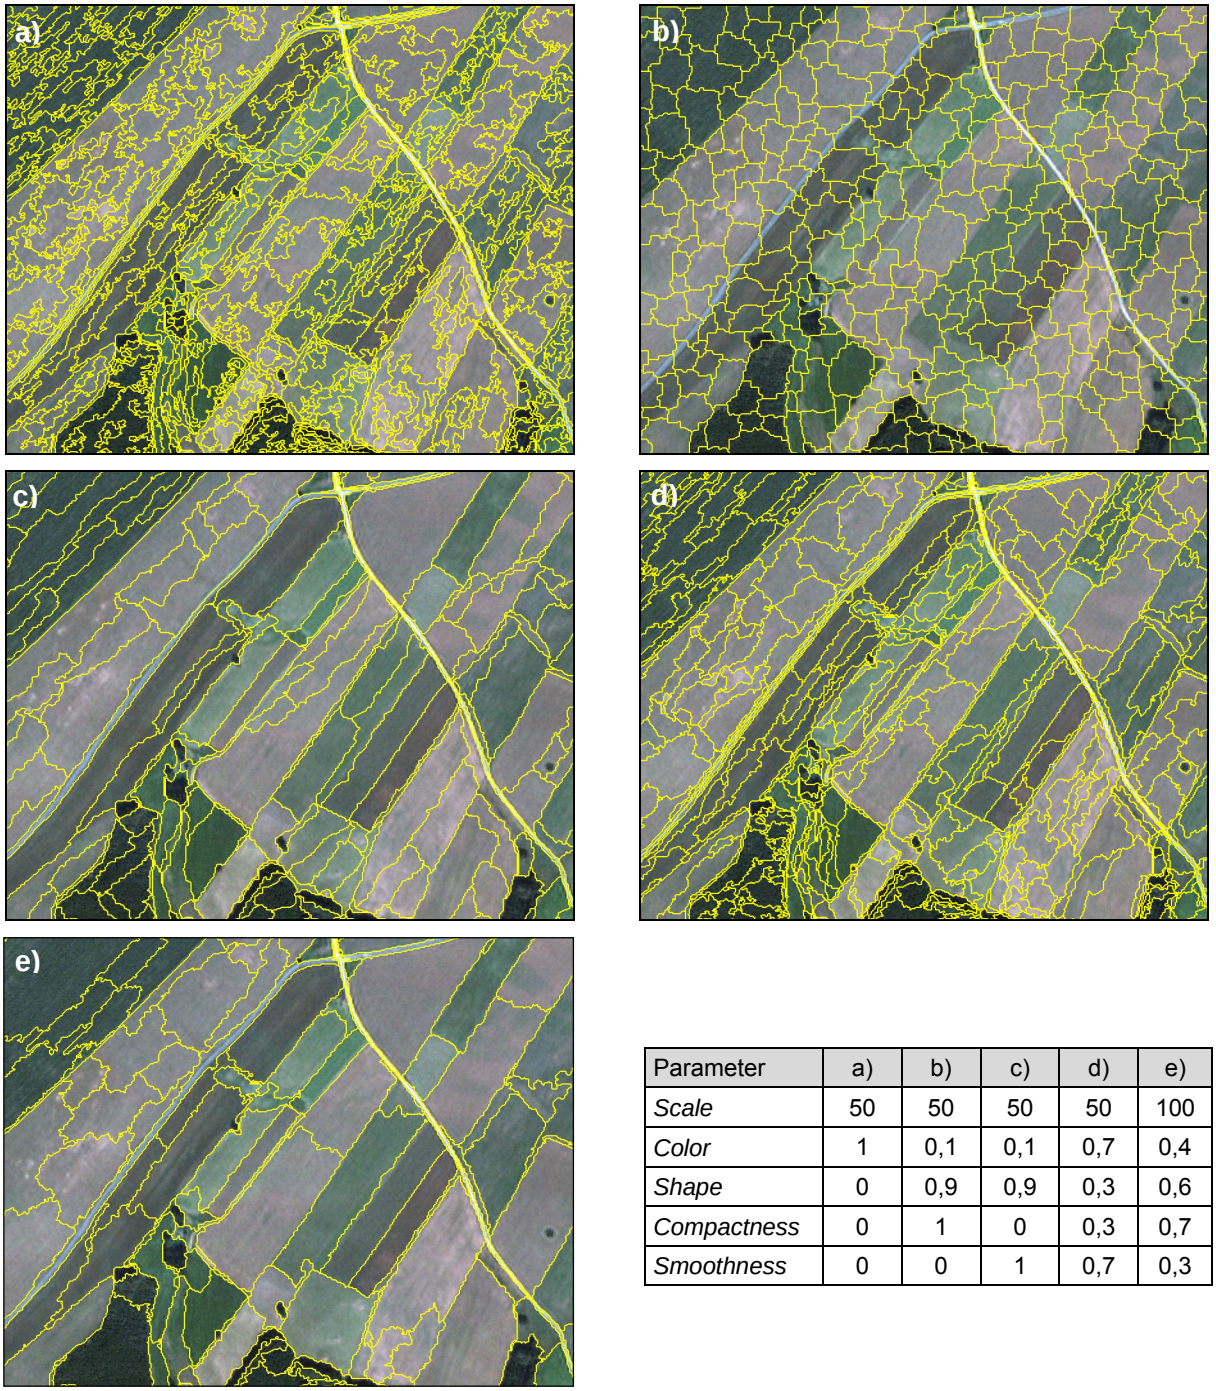

Parameter	a)	b)	c)	d)	e)
Scale	50	50	50	50	100
Color	1	0,1	0,1	0,7	0,4
Shape	0	0,9	0,9	0,3	0,6
Compactness	0	1	0	0,3	0,7
Smoothness	0	0	1	0,7	0,3

Abb. 4.3: Segmentierungsergebnisse bei unterschiedlicher Parameterwahl (Erläuterung im Text). (Quelle: Eigene Darstellung, © Space Imaging)

Um den Einfluss des *Scale*-Parameters auf die Anzahl der segmentierten Bildobjekte sowie die durchschnittliche Segmentgröße zu ermitteln, wurde anhand einer Testfläche (840 x 700 Pixel) die Segmentierung mit verschiedenen *Scale*-Faktoren durchgeführt. Die anderen Parameter blieben unverändert. Es ergab sich ein polynomialer Zusammenhang zwischen dem *Scale*-Parameter und der durchschnittlichen Objektgröße (siehe Abbildung 4.4). Daneben besteht ein negativ-exponentieller Zusammenhang zwischen dem *Scale*-Faktor und der Anzahl der Segmente.

Zusätzlich lassen sich im Abfragedialog der Segmentierung (siehe Abbildung 4.2) weitere Parameter auswählen, wie die Gewichtung der verwendeten Kanäle, die Nutzung der Geometrie thematischer Zusatzdaten, der Segmentierungs-Modus (Normal oder *Sub-Line-Analysis)* sowie die Berücksichtigung einer 8er Nachbarschaft *(Diagonal Pixel Neighborhood)*.

Optimale Parameter lassen sich nur durch langwieriges iteratives Testen nach der *trial-and-error*-Methode finden. Für ganze Bildszenen ist die Festlegung idealer Parameter aufgrund ihrer Heterogenität zum Teil unmöglich. Die Parametereinstellungen hängen grundsätzlich in starkem Maße von verschiedenen Faktoren der Bilddaten ab, wie der geometrischen Auflösung, der Anzahl der Bildkanäle, der Farbtiefe, den spektralen Eigenschaften des Bildes sowie den abzugenzenden Objekten. Eine allgemeingültige Aussage zur Parameterwahl ist aus diesem Grund nicht möglich. Verfahren zur Ermittlung optimaler Segmentierungsparameter wurden von DELPHI IMM (2003), HAUBROCK & LESSING (2002) sowie TUFTE (2003) vorgestellt. Die Praxistauglichkeit dieser Verfahren konnte jedoch noch nicht belegt werden.

Wie bereits in Abschnitt 2.2.3 erläutert, entstehen durch die Segmentierung zunächst Bildobjektprimitive *(image object primitives)*. Sie entsprechen selten den tatsächlich zu extrahierenden Objekten *(objects of interest)*. Die interessierenden Objekte müssen oft aus mehreren Objektprimitiven aggregiert werden. Daher sollten die initialen Objektprimitive nur einer Klasse zuordenbar sein und keinesfalls Klassengrenzen überschreiten. Eine Untersegmentierung ist demnach zu vermeiden, um den manuellen Aufwand – etwa für Geometriekorrekturen (z. B. Segmentteilungen) – zu minimieren. Wesentlich häufiger tritt eine Übersegmentierung ein, die aber durch eine Zusammenfassung von Segmenten einfach behoben werden kann. Das parallele Auftreten einer Unter- oder Übersegmentierung ist infolge des genutzten, relativ allgemeinen Homogenitätskriteriums unumgänglich (vgl. BAATZ & MIMLER

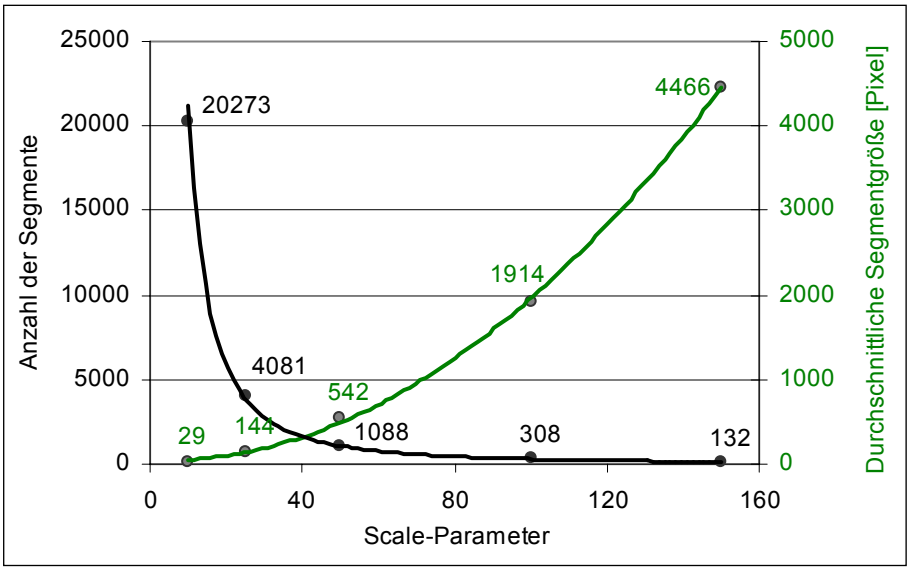

Abb. 4.4: Zusammenhang zwischen *Scale*-Faktor und Anzahl der segmentierten Bildobjekte sowie durchschnittlicher Objektgröße (Trendlinien).
(Quelle: Eigene Darstellung)

2002). Aus diesem Grund ist ein optimales Ergebnis insbesondere bei umfangreichen Bilddaten nur für einzelne Bildbereiche möglich.

Die Qualität der Segmentierung bleibt bisher häufig unbeachtet und wird – wenn überhaupt – lediglich subjektiv-visuell überprüft. Gerade durch den bestehenden subjektiven Einfluss infolge der Parameterwahl übt der Bearbeiter jedoch einen erheblichen Einfluss aus, zumal die Segmentierung die Grundlage für die weiteren Klassifikationsschritte darstellt und somit entscheidende Auswirkungen auf das Ergebnis besitzt. Dieser Aspekt wird daher in Abschnitt 4.3 näher untersucht.

Durch die Möglichkeit einer hierarchischen bzw. multiskalaren Segmentierung entstehen mehrere Ebenen (bzw. Level, Segmentierungsniveaus oder Segmentpyramiden), die den Bildinhalt repräsentieren. Sie bieten die Möglichkeit – ähnlich der menschlichen Erkennungsfähigkeiten – verschiedene Objektgrößen parallel zu erfassen. Die erste Segmentierung liefert dem Homogenitätskriterium entsprechend homogene Objektprimitive, die durch weitere Segmentierungsschritte zu größeren Einheiten verschmolzen werden können *(buttom-up*-Variante). Auch eine *top-down*-Segmentierung ist möglich, die jedoch zu einer deutlich längeren Berechnungszeit führt, da die Segmentierung jeder Ebene anhand der Pixelwerte berechnet wird. Die Segmentgeometrien der einzelnen Ebenen bauen stets aufeinander auf.

Die Wahl des Startpunktes für das *region growing* entscheidet über die Reproduzierbarkeit des Segmentierungsverfahrens in Abhängigkeit vom gewählten Bildausschnitt. Eine solche Reproduzierbarkeit ist aus Nutzersicht von größter Bedeutung, da die nötigen Parameter zumeist anhand kleinerer Bildausschnitte getestet werden, um sie dann auf ein großes Gebiet zu übertragen. Zufällig oder regelmäßig verteilte Startpunkte führen zu nicht reproduzierbaren Ergebnissen. Das in eCognition ab der Version 3 verwendete Verfahren erlaubt eine zuverlässige, ausschnittunabhängige Reproduktion der Segmentierung.

Während der Segmentierung, die eine Informationsreduktion darstellt, werden die extrahierten Segmente in einer GIS-vergleichbaren Datenbankstruktur abgelegt, welche für jedes Segment verschiedene, für die Klassifikation nutzbare Segmentmerkmale enthält. Zwischen den einzelnen Bildobjekten bestehen semantische Verbindungen, d. h. jedes Bildobjekt ist mit seinen Nachbarn, seinen untergeordneten Segmenten (Subobjekte) sowie seinem übergeordneten Segment (Superobjekt) verknüpft (siehe Abbildung 4.1). Diese Objektrelationen bzw. Kontextinformationen sind in der Klassifikation explizit nutzbar.

4.1.2 eCognition-Klassifikationsverfahren

Im Anschluss an die initiale Bildsegmentierung erfolgt die Klassifikation. Sie erfolgt auf Grundlage von *fuzzy logic* (vgl. Abschnitt 2.2.2.6). Vor der Klassifikation wird eine Wissensbasis erstellt, welche die Klassendefinitionen enthält. Der Aufbau der Wissensbasis kann regelbasiert anhand von Zugehörigkeitsfunktionen oder durch die Auswahl von Trainingsflächen erfolgen. Die eigentliche Klassifikation erfolgt durch Datenbankabfragen – im ersten Fall auf Basis der *Structured Query Language* (SQL), im zweiten Fall anhand eines statistischen Verfahrens *(nearest neighbour)*.

Das *fuzzy*-Prinzip erlaubt die Festlegung unscharfer Klassenmerkmale sowie die gleichzeitige Zuordnung zu mehreren Klassen, wobei dem Objekt die Klasse mit der höchsten Wahrscheinlichkeit (genauer: dem Erfüllungsgrad einer Regel) zugewiesen wird. Neben den spektralen Eigenschaften der Bildobjekte und daraus erzeugbaren Ratios können Formkriterien (z. B. Fläche, Umfang, *Shape*-Index), Texturmerkmale *(Co-occurrence* Matrizen) sowie Objektrelationen (Nachbarschaft, z. B. ‚grenzt an', ‚ist umgeben von', ‚liegt in der Nähe von'; Hierarchie, z. B. ‚ist Element von', ‚besteht aus' etc.) genutzt werden. Einige dieser Merkmale sind typische GIS-Analysefunktionen, wie z. B. die Grenzlänge zu einem Objekt

einer bestimmten Klasse, die Entfernung zum nächsten Element der gleichen oder bestimmten anderen Klasse. Mit Ausnahme der klassenbezogenen Eigenschaften werden die Merkmale unmittelbar bei der Segmentierung berechnet. Weitere Berechnungen sind einfach durch nutzerdefinierbare Merkmale integrierbar (vgl. DEFINIENS IMAGING 2003).

Infolge der hierarchischen Segmentierung können Objekte, die sich aus mehreren Teilobjekten zusammensetzen, besser erfasst werden. So kann z. B. eine Fläche als Streuobstwiese klassifiziert werden, die in einer untergeordneten Ebene aus Wiese und regelmäßig stehenden Bäumen besteht.

Innerhalb der Klassenhierarchie können Informationen zur Übertragung von Klassifikationsregeln *(inheritance)*, zur Klassensemantik *(groups)* sowie zur Klassenstrukturierung *(structure)* verwaltet werden. Klassifikationsregeln lassen sich in der Klassenhierarchie vererben, wobei Merkmale der übergeordneten Klasse *(parent class)* auf Unterklassen *(child classes)* übertragen werden. So kann z. B. die Oberklasse Gewässer – beschrieben durch einen bestimmten Wertebereich des NDVI – durch die Nutzung von Formmerkmalen in die Unterklassen Fließ- und Stillgewässer untergliedert werden. Zur Vereinfachung von Klassenbeschreibungen lassen sich darüber hinaus unabhängige Klassen zu semantischen Gruppen zusammenfassen (z. B. können Bebauung, Straßen etc. als versiegelte Flächen gruppiert werden). Zur Verbesserung des Klassifikationsergebnisses lässt sich eine wissensbasierte Segmentierung nutzen, wodurch benachbarte, gleich klassifizierte Segmente ähnlich dem GIS-Befehl *Dissolve* zusammengefasst werden. Hierzu können auch mehrere Klassen zusammengefasst werden, denen vorher eine gemeinsame Strukturgruppe zugewiesen wurde.

Zur Überprüfung der Klassifikationsgüte stehen statistische Analyseverfahren zur Verfügung, die allerdings auf Basis von Segmenten – und nicht wie bei der Bewertung pixelbasierter Klassifikationsergebnisse üblich punktbasiert – ablaufen. Im Anschluss an die Klassifikation ist der Export der Ergebnisse in GI-Systeme (ArcView-Shapeformat) zur Weiterbearbeitung möglich.

Alle Bearbeitungsschritte lassen sich in einem Protokoll aufzeichnen. Dadurch ist die Übertragung der Vorgehensweise auf andere Gebiete möglich. Veränderungen der Klassenhierarchie, die während des Klassifikationsprozesses oftmals nötig sind, werden jedoch nicht aufgezeichnet. Darüber hinaus lässt sich die zur Klassifikation erstellte Wissensbasis exportieren und in weiteren Projekten anwenden. Um diese Funktion nutzen zu können ist zu beachten, dass einige Merkmale, wie Spektralwerte oder Ratios, hochgradig variabel sind und die Übertragbarkeit nur nach einer aufwändigen Anpassung erfolgreich ist. Es sollten demnach weitestgehend stabile Merkmale, wie Nachbarschaft, Form, Relationen oder Textur verwendet werden.

4.1.3 Bewertung von eCognition

Nach der Markteinführung von eCognition im Jahr 2000 erfuhr die Software ein überwiegend positives Echo. Als Vorteile gegenüber konventionellen, pixelbasierten Verfahren lassen sich folgende Punkte nennen:

- größere Ähnlichkeit zum menschlichen Erkennungsprozess;
- großer Umfang der zur Klassifikation nutzbaren Merkmale (insbesondere Kontext- und Formmerkmale);
- hierarchische Segmentierung ermöglicht die Betrachtung verschiedener Dimensionsstufen;
- *fuzzy-logic*-basierte Klassifikation zum Umgang mit Unschärfe;

- Wissensbasis zur Formalisierung des zur Klassifikation genutzten Wissens;
- Unterdrückung eingestreuter falsch oder nicht klassifizierter Pixel *(salt-and-pepper*-Effekt);
- funktionale Verschmelzung von GIS-Operatoren und spektralen Klassifikationsmethoden zeigen einen hohen Integrationsgrad von GIS und Fernerkundung;
- hoher Automatisierungsgrad (halbautomatische Bildauswertung, Objektextraktion voll automatisiert);
- umfangreiche Import- und Exportfunktionen.

Folgende Nachteile lassen sich erkennen:

- eCognition dient lediglich zur Bildanalyse, Bildverarbeitungskapazitäten sind nicht vorhanden, womit immer eine zusätzliche Software erforderlich ist;
- fehlende Transparenz des Segmentierungsprozesses (*Scale*-Parameter abstrakt, subjektive Parameterwahl nach der *trial-and-error*-Methode);
- aufwändiges Erstellen von Klassifikationsregeln mit hohem manuellen Arbeitsanteil;
- eingeschränkte Übertragbarkeit der Klassifikationsregeln (spektrale Signaturen variieren z. B. durch unterschiedliche atmosphärische Bedingungen);
- schlechtes Handling großer Datenmengen;
- mangelnde Qualitätskontrolle der Segmentierung.

Die weitere Entwicklung der Software lässt einige Verbesserungen erkennen, beispielsweise hinsichtlich der Verarbeitung großer Datenmengen mit der Version 4 oder die noch umzusetzende Unterstützung bei der Extraktion einfacher geometrischer Formen anthropogener Objekte (z. B. Gebäude, Ackerschläge, Straßen; vgl. BAATZ & MIMLER 2002). Insgesamt wird die zukünftige Entwicklung durch die Fachwelt mit großem Interesse verfolgt.

4.2 Vergleich segmentbasierter und pixelbasierter Klassifikation

Um die segmentbasierte Klassifikation mit eCognition (Version 1.0) den klassischen pixelbasierten Verfahren gegenüberzustellen, wurde zu Beginn der Projektbearbeitung ein Vergleich zum ERDAS IMAGINE Expert Classifier (Version 8.4.1) – ebenfalls ein Expertensystem – durchgeführt (vgl. MEINEL, NEUBERT & REDER 2001).

Die Untersuchung erfolgte anhand einer Teilfläche der IKONOS-Szene von Dresden. Das urbane Testgebiet Dresden-West mit einer Größe von 2,4 x 2,4 km weist viele verschiedene Bodenbedeckungs- und Flächennutzungsarten auf (siehe Abbildung 4.5). Im nördlichen Bereich liegen Areale mit überwiegender Industrie- und Gewerbenutzung. Südlich der Elbe sind neben landwirtschaftlichen Flächen auch Wohngebiete in Form von Einzelhaus- und Blockbebauung, Industrie-, Gewerbeflächen, Bahnflächen und -trassen, Kleingarten-, Sport- und Parkanlagen, Friedhofsareale, Obstplantagen, Waldgebiete sowie ausgedehnte Wiesen- und Grünlandareale zu finden (siehe Abbildung 4.5). Daneben treten Flächen auf, die erst in jüngster Vergangenheit verändert wurden bzw. sich noch in Bebauung befinden (offener Boden).

Da sich beide Klassifikationsverfahren deutlich unterscheiden (zum Vorgehen siehe MEINEL, NEUBERT & REDER 2001), wurden die Eingangsdaten jeweils optimiert und weichen dadurch voneinander ab (vgl. Tabelle 4.1). Die digitale Blockkarte der Stadt Dresden (vgl. Abschnitt

Abb. 4.5: Lage des Untersuchungsgebietes Dresden-West (links, grau dargestellt) in den Stadtgrenzen Dresdens (strichpunktiert) und innerhalb der IKONOS-Gesamtszene (gestrichelt) sowie multispektraler Bildausschnitt (rechts).
(Quelle: Eigene Darstellung, © Space Imaging)

3.3.3) ermöglichte die Abgrenzung von Straßenflächen (Blockrestfläche), die sich aus Fernerkundungsdaten aufgrund von Baumkronenverdeckung und der Vielzahl unterschiedlicher Straßenbeläge nur unzulänglich klassifizieren lassen. Die ATKIS-Daten sowie das -Höhenmodell dienten im Rahmen der pixelbezogenen Klassifikation zur Sicherung von unklaren Hypothesen bei speziellen Nutzungsklassen (z. B. Bahnfläche, Klärbecken). Bei Verwendung des ATKIS-Datensatzes wurde darauf geachtet, dass nur nahezu unveränderliche Flächennutzungen (z. B. Friedhöfe, Gleisanlagen und Flussläufe) in die Klassifikation Eingang fanden. Andere Flächen könnten sich, wenn man den Fortschreibungsstand der ATKIS-Daten bedenkt (im vorliegenden Fall 1993), in ihrer Nutzung bzw. Bodenbedeckung geändert haben.

Ursprüngliches Ziel im Rahmen des Klassifikationsvergleichs war die Verwendung eines einheitlichen Klassifikationsschlüssels. Dieser musste im Laufe der Arbeiten teilweise modifiziert werden, da bei der Klassifikation mittels eCognition durch die Einbeziehung von Nachbarschaftsbeziehungen und Formfaktoren eine differenziertere Klassenbildung möglich war

Tab. 4.1: Verwendete Eingangsdaten zum Methodenvergleich zwischen Expert Classifier und eCognition.
(Quelle: Eigene Darstellung)

Eingangsdaten	Expert Classifier	eCognition
Bilddaten	• vier Multispektralkanäle (4 m Bodenauflösung)	• vier Multispektralkanäle (PC-Fusionsbild, 1 m Bodenauflösung), • panchromatische Bilddaten (1 m Bodenauflösung)
Abgeleitete Bilddaten	• Vegetationsindex (NDVI), • Zweite Hauptkomponente, • Texturkanal (aus den panchromatischen Bilddaten berechnet), • Ergebnis einer unüberwachten Klassifikation	• Vegetationsindex (NDVI)
GIS-Daten	• Digitale Blockkarte der Stadt Dresden • ATKIS Basis-DLM • ATKIS DGM25	• Digitale Blockkarte der Stadt Dresden

und über die Bodenbedeckung hinaus teilweise die Flächennutzung klassifizierbar war (z. B. Sport-, Parkplätze, Obstanbau).

Beim visuellen Vergleich der beiden Klassifikationsergebnisse zeigen sich signifikante Unterschiede (vgl. Abbildung 4.6). Während eCognition durch die vorgeschaltete Segmentierung sehr homogene Flächen ausbildet, bedingt die Klassifikation mit dem Expert Classifier das bekannte kleinteilige Pixelklassifikationsmuster *(salt-and-pepper*-Rauschen). Abbildung 4.7 stellt verschiedene Ausschnitte der Klassifikationen im Bildvergleich dar. Die oberste Reihe zeigt, wie mittels eCognition ein Straßenneubau richtig klassifiziert wurde (durch Auswertung von Form und Nachbarschaft), während dieser durch den Expert Classifier nur teilweise und als versiegelte Freifläche ausgewiesen werden konnte. Die mittlere Reihe verdeutlicht, dass sich IKONOS-Daten generell zur Klassifikation von Einzelhäusern nutzen lassen, obwohl eine korrekte Klassifikation durch die detaillierte Darstellung der vielfältigen Dachmaterialien sowie verschiedener Besonnungssituationen erschwert wird. Die untere Reihe zeigt, dass ein Fluss und zwei Sportplätze mit eCognition richtig klassifiziert werden konnten.

Unterschiede ergaben sich im Anteil der unklassifizierten Flächen, welcher bei der pixelbasierten Klassifikation mit 0,42 % der Gesamtfläche größer ausfiel als beim segmentbasier-

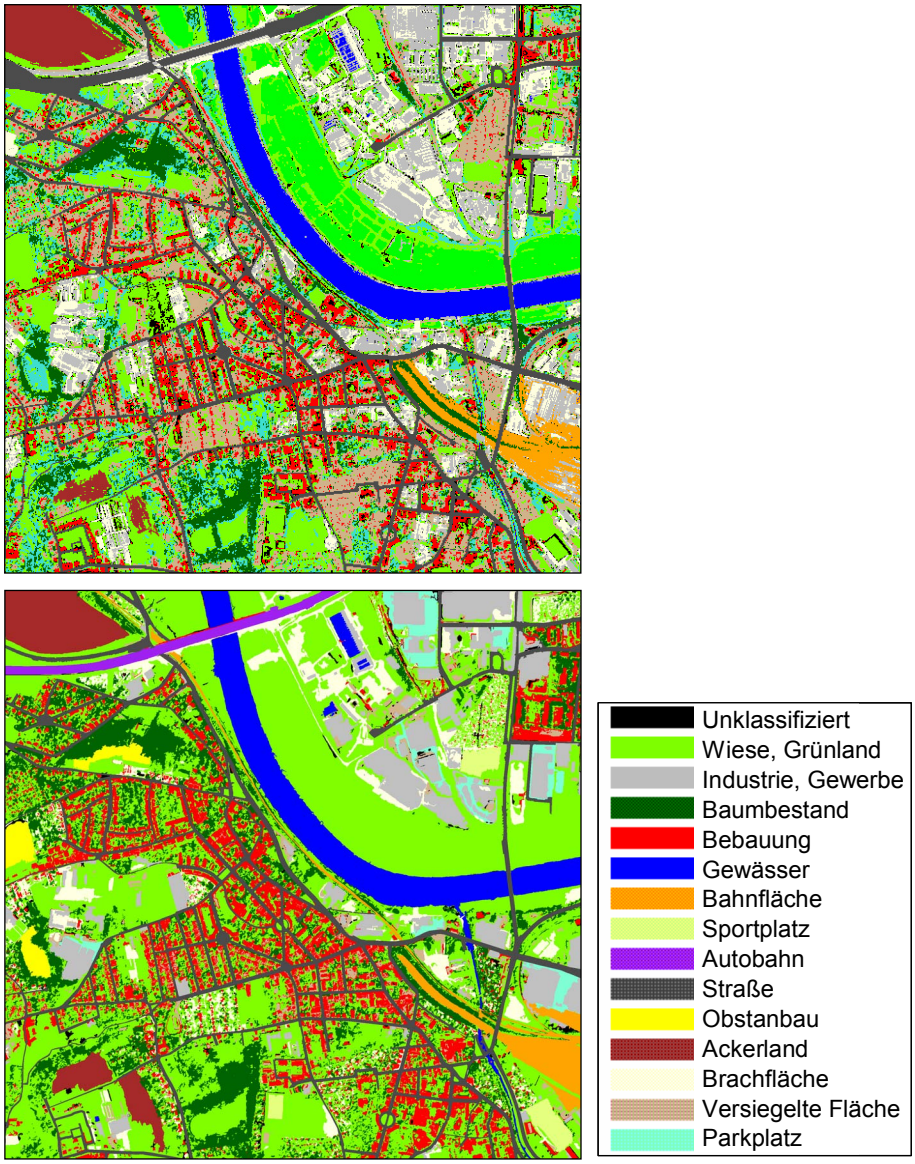

Abb. 4.6: Klassifikationsergebnisse mit Expert Classifier (oben) und eCognition (Klassifikationsebene 1, unten). (Quelle: Eigene Darstellung)

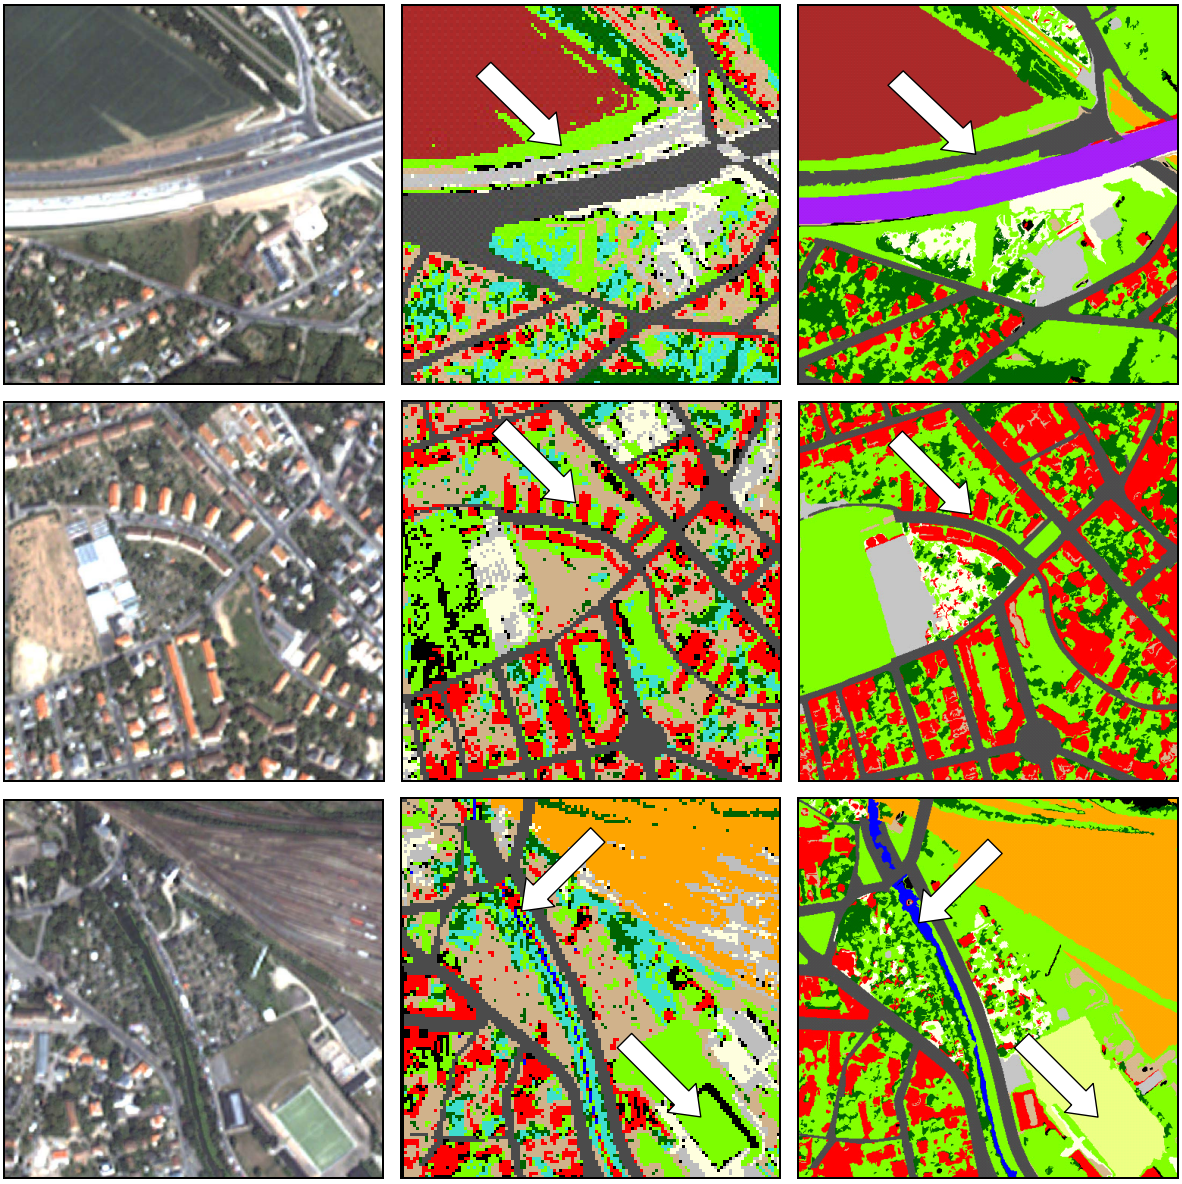

Abb. 4.7: Ausschnitte des Untersuchungsgebietes (links: IKONOS-Bild, Mitte: Klassifikationsergebnis Expert Classifier, rechts: eCognition), Erläuterung im Text.
(Quelle: Eigene Darstellung, © Space Imaging)

ten Verfahren (0,07 %). Bei der pixelbasierten Klassifikation verbleiben immer einzelne nicht zusammenhängende Pixel, die nicht eindeutig einer Klasse zugeordnet werden können.

Durch die Einbeziehung von Nachbarschaftsbeziehungen und Flächenform werden in eCognition differenziertere Klassenschlüssel möglich. So konnten Sportplätze durch eine Form- und Größenanalyse sowie bestimmte Gebäude durch ihre Nachbarschaft zu Straßen klassifiziert werden. Im Allgemeinen lässt sich feststellen, dass sich mit eCognition große, homogene Flächen sicherer und mit geringerem Zeitaufwand klassifizieren lassen als stark heterogene Flächen.

Für die Berechnung der Klassifikations- und Erkennungsgüte wurde das *Accuracy Assessment Tool* von ERDAS IMAGINE benutzt. Für jede Klasse wurden unabhängig von ihrem Flächenanteil je 20 Testpunkte durch einen Zufallsgenerator erzeugt. Um Testpunkte auf Nutzungsgrenzen zu verhindern (die sich letztlich auch im Rahmen einer visuellen Interpretation nicht eindeutig zuordnen lassen), sollten die Testpunkte innerhalb homogener Flächen liegen.

Grundlage der visuellen Bedeckungs-/Nutzungsbestimmung für diese Testpunkte war in erster Linie das Bildfusionsprodukt der IKONOS-Daten. In Zweifelsfällen wurde eine Luftbildaufnahme des Jahres 1999 verwendet, in einigen Fällen erfolgte die Sicherung durch Vorortbegehung. Die Ergebnisse der Klassifikationskontrolle sind in Tabelle 4.2 dargestellt.

Beide Klassifizierungen weisen eine identische Gesamtklassifikationsgüte von 89,6 % auf. Allerdings wurde die Klassifikation mit dem Expert Classifier anhand von 4-m-Daten und mit nur elf Klassen erstellt. Demgegenüber erfolgte die Klassifikation mit eCognition mit 1-m-Daten und 13 Klassen. In den einzelnen Klassen treten keine erheblichen Unterschiede auf.

Es lässt sich schlussfolgern, dass ein segmentbasiertes Vorgehen selbst in heterogenen urbanen Gebieten zu besseren Ergebnissen führt. Mit eCognition war eine größere Klassifikationstiefe (13 gegenüber elf Klassen) möglich. Durch die Nutzung von Kontext- und Formmerkmalen gelang es zudem, über Bodenbedeckungen hinaus Flächennutzungen zu klassifizieren. Weiterhin enthält das eCognition-Ergebnis einen geringeren Anteil unklassifizierter Flächen und weist kein *salt-and-pepper*-Rauschen auf.

Zahlreiche weitere Studien belegen mittlerweile die Überlegenheit des segmentbasierten Klassifikationsansatzes eCognition gegenüber traditionellen, pixelbasierten Verfahren. Eine Auswahl aktueller Untersuchungen wird im Folgenden dargestellt.

Tab. 4.2: Erkennungs- und Klassifikationsgüte im Vergleich.
(Quelle: Eigene Darstellung)

Klasse	Expert Classifier		eCognition	
	Erkennungs-güte [%]	Klassifikations-güte [%]	Erkennungs-güte [%]	Klassifikations-güte [%]
Ackerland	100,0	100,0	100,0	100,0
Wiese/Rasen	78,3	90,0	80,9	85,0
Elbwiese	94,7	90,0	-	-
Sportplatz	-	-	100,0	95,0
Wald/Baumbestand	95,2	100,0	100,0	95,0
Laubgehölz, verbuschtes Gelände	85,7	90,0	-	-
Obstanbau	-	-	100,0	95,0
Garten/Kleingarten[1]	94,1	80,0	-	-
Gewässer	100,0	100,0	100,0	100,0
Industrie-/Gewerbefläche[2]	-	-	62,5	75,0
Bebauung	90,9	100,0	94,7	90,0
Bahnfläche	100,0	90,0	100,0	100,0
Autobahn	-	-	100,0	100,0
Straßenflächen[3]	-	-	-	-
Vegetationslose Flächen, unversiegelt	85,7	60,0	83,3	75,0
Versiegelte Flächen	68,0	85,0	69,6	80,0
Parkplätze	-	-	83,3	75,0
Gesamtklassifikationsgüte	89,6		89,6	

[1] Die Klasse Garten/Kleingarten wurde bei der Klassifikation mit eCognition in der hier geprüften feinsten Klassifikationsebene in ihre Bodenbedeckungsbestandteile zerlegt.
[2] Versiegelte Industrie-/Gewerbeflächen sind bei der Klassifikation mittels Expert Classifier in der Klasse versiegelte Flächen enthalten.
[3] Straßenflächen wurden von der Gütebestimmung ausgeschlossen, da sie nicht klassifiziert, sondern unmittelbar aus der Blockrestfläche abgeleitet wurden.

DARWISH et al. (2003) erstellten eine Klassifikation mittels eCognition auf Basis von Landsat- sowie IRS-Daten und verglichen sie mit einer *Minimum-Distance*- (MD) sowie einer *Maximum-Likelihood*-Klassifikation (ML). Dabei schnitten die ML-Ergebnisse deutlich besser ab, als die des MD-Verfahrens. eCognition erbrachte bei steigender Klassenzahl sowie höherer Auflösung die besten Ergebnisse. So hatten die Klassifikationsergebnisse bei elf gegenüber sechs Klassen mit eCognition eine bessere Güte, als bei den anderen Methoden. Auf Basis der besser aufgelösten IRS-Daten waren ebenfalls genauere Resultate möglich, als bei Landsat-Daten.

KOCH et al. (2003) führten einen ähnlichen Vergleich durch, wobei eCognition im Vergleich mit einem ML-, einem MD-, einem Box-Klassifikator sowie dem ERDAS IMAGINE Expert Classifier verwendet wurde. Ziel dieser Untersuchung war die Unterscheidung und Abgrenzung von vier Waldklassen. Die Datengrundlage war eine mit panchromatischen IRS-1D-Daten (5,6 m Bodenauflösung) geschärfte Landsat-ETM-Szene (30 m, Fusionsverfahren: *Adaptive Image Fusion)*. In beiden getesteten Gebietsausschnitten erzielte die segmentbasierte Klassifikation mittels eCognition mit einer Klassifikationsgüte von 92 bzw. 82 % die besseren Ergebnisse. Als zweitbestes Verfahren schnitt der Expert Classifier mit 78 bzw. 76 % ab. Alle weiteren pixelbasierten Verfahren blieben dahinter zurück. In Abhängigkeit von den gewählten Segmentierungsparametern werden von eCognition die Waldflächen jedoch generalisiert, was aus Nutzersicht zum Teil nicht erwünscht ist. So ließen sich im Test keine Anteile der einzelnen Bestände bestimmen. Zur Umgehung dieses Nachteils kombinierten die Autoren die Segmentierungsergebnisse mit einer pixelbasierten Klassifikation, um die Mischanteile innerhalb der Segmente zu ermitteln. Ein ähnliches Resultat lässt sich ebenfalls durch die Nutzung einer feinen, zugrunde liegenden Segmentierungsebene erreichen (vgl. Abschnitt 6.4.2.4).

Die Untersuchung von SCHWARZ et al. (2002) zeigt ein ähnliches Ergebnis. Verglichen wurden die Klassifikationsergebnisse von eCognition und dem ERDAS IMAGINE Expert Classifier anhand von SPOT- sowie IKONOS-Daten. Bei der Klassifikation von fünf Klassen auf Basis der SPOT-Daten wurden vergleichbare Ergebnisse erzielt. Deutlich besser schnitt eCognition jedoch bei der Klassifikation der IKONOS-Daten ab.

Auch ESCH et al. (2003) verglichen Klassifikationsergebnisse des segmentbasierten Verfahrens eCognition mit einer pixelbasierten ML-Klassifikation. Grundlage war hier eine panchromatisch geschärfte Landsat-ETM-Szene (15 m, Fusionsverfahren: Hauptkomponentenverfahren mit bilinearer Interpolation) eines ländlichen Gebietes. Für das Ergebnis wurde eine Gesamtgüte von 90 % für eCognition gegenüber 82 % mit dem ML-Verfahren ermittelt. Begründet werden die guten Ergebnisse von eCognition mit den Vorteilen, die die Klassifikation bietet (z. B. Vielzahl der nutzbaren Merkmale zur Klassenbeschreibung, Klassifikation in mehreren Ebenen).

Für höchstauflösende HRSC-Daten findet sich eine Gegenüberstellung z. B. bei LESER (2002). Die Autorin verglich pixelbasierte Auswertemethoden (ISODATA und ML) mit dem segmentbasierten Verfahren eCognition. Durch den infolge der hohen spektralen Variabilität auftretenden *salt-and-pepper*-Effekt, die fehlende Nutzbarkeit von Kontextmerkmalen sowie vielfältige Fehlklassifikationen waren die pixelbasierten Verfahren zur Auswertung der HRSC-Daten wenig geeignet.

Die Anwendung von eCognition scheint demnach besonders für Daten mit sehr hoher Auflösung zweckmäßig. Bedingt durch die Eigenschaften dieser Bilddaten (vgl. Abschnitt 2.1.3) schneiden pixelbasierte gegenüber segmentbasierten Verfahren meist schlechter ab. Die Ursachen hierfür sind in der Homogenisierung der Daten infolge der Segmentierung sowie den zahlreichen, über spektrale Eigenschaften hinaus zur Verfügung stehenden Klassifikationsmerkmalen zu sehen.

4.3 Vergleich aktuell verfügbarer Segmentierungsprogramme und deren Segmentierungsqualität

4.3.1 Grundlagen und Methodik des Segmentierungsvergleiches

Um zu ermitteln, welche Segmentierungsprogramme sich für die Auswertung sehr hoch auflösender Fernerkundungsdaten eignen, wurde ein Vergleich von aktuell verfügbarer Software durchgeführt. Ziel dieser Untersuchung war zugleich eine Evaluierung der Segmentierungsqualität, da die Segmentierung einen erheblichen Einfluss auf die Klassifikationsgüte ausübt.

Eine Evaluierung verschiedener Segmentierungen ist dabei analytisch oder empirisch möglich (vgl. ZHANG 1996). Eine analytische Untersuchung bewertet die qualitativen Eigenschaften und Prinzipien der Algorithmen. Beispiele hierfür sind die Untersuchungen von HARALICK & SHAPIRO (1985) oder PAL & PAL (1993). Hinderlich ist dabei das Fehlen einer allgemeinen Theorie der Bildsegmentierung (vgl. HARALICK & SHAPIRO 1992). Empirische Verfahren nutzen dagegen originale oder nachbearbeitete Segmentierungsergebnisse von Testbildern zur Qualitätsbestimmung. Eine empirische Gütekontrolle bewertet die Gesamtsegmentierung anhand der Uniformität innerhalb der Segmente, dem Kontrast gegenüber angrenzenden Segmenten oder der Segmentform (vgl. ZHANG 1996). Diese Verfahren wurden jedoch für Segmentierungen basierend auf dem Schwellwertverfahren (vgl. Abschnitt 2.2.2.1) entwickelt und scheinen wenig geeignet zur Anwendung auf heute übliche Verfahren. Bei einer empirischen Diskrepanzanalyse wird das Segmentierungsergebnis flächenhaft oder anhand von Testgebieten einem Vergleichsdatensatz gegenübergestellt. Empirische Diskrepanzverfahren finden aktuell häufiger Anwendung zur Evaluierung der Segmentierungsqualität (vgl. z. B. ZHANG & GERBRANDS 1994; SCHOUTEN & KLEIN GEBBINCK 1995; YANG et al. 1995; EVERINGHAM et al. 2001; HIRSCHMUGL 2002; CARLEER et al. 2003; DELPHI IMM 2003; TUFTE 2003; LUCIEER 2004). Bei der Nutzung von Testgebieten besteht die Möglichkeit, Kenngrößen wie Fläche oder Umfang zu vergleichen.

Der hier durchgeführte Vergleich bewertet die Algorithmen nicht in analytischer Hinsicht. Dennoch werden Aussagen zu den Eigenschaften der untersuchten Segmentierungsprogramme getroffen. Der gewählte Ergebnisvergleich entspricht einer empirischen Diskrepanzanalyse anhand von visuell kartierten Testflächen. Es handelt sich um eine anwendungsorientierte Untersuchung, die auf realen Fernerkundungsdaten basiert (vgl. NEUBERT & MEINEL 2003a, 2003b; MEINEL & NEUBERT 2003, 2004).

Einen Überblick über die untersuchten Programme, die anhand verschiedener Vergleichskriterien gegenübergestellt werden, zeigt Tabelle 4.3. Die Auswahl der Softwares erfolgte aufgrund der Eignung zur Segmentierung von Fernerkundungsdaten (z. B. für Multispektraldaten). Zudem war die Bereitschaft der Entwickler zur Zusammenarbeit Voraussetzung für den Vergleich.

Anhand eines urban sowie eines rural geprägten Testgebietes (2 400 x 2 400 bzw. 2 000 x 2 000 Pixel) wurden mit den acht genutzten Programmen Segmentierungen erstellt. Als Segmentierungsgrundlage standen panchromatisch geschärfte IKONOS-Multispektraldaten mit 1 m Bodenauflösung zur Verfügung (siehe Abbildung 4.8). Ziel war die Extraktion relevanter Objektgrenzen der Flächenbedeckung bzw. -nutzung. Die Segmentierungen erfolgten mit Ausnahme von eCognition, SPRING und der ERDAS-IMAGINE-Erweiterung *Image Segmentation* seitens der Entwickler, wodurch eine optimale Segmentierung durch Experten gesichert war (z. B. Parameterwahl). Die Programmentwickler sollten die Testdatensätze gemäß den Zielvorgaben (z. B. Referenzsegmentierung) mithilfe ihres Expertenwissens segmentieren und einen umfangreichen Fragebogen beantworten. Segmentierungsergebnisse der Software CAESAR lagen nur für das rurale Testgebiet vor. Mit dem *Minimum*

Tab. 4.3: Vergleichende Gegenüberstellung der getesteten Segmentierungssoftwares. (Quelle: Eigene Darstellung)

Segmentierungsprogramm		CAESAR 3.1	*Data Dissection Tools*	eCognition 2.1 bzw. 3.0	*Image Segmentation* (für Erdas)	InfoPACK 1.0	*Minimum Entropy Approach*	SPRING 4.0
Grundlagen	Entwickler	N.A.Software Ltd.	INCITE, Stirling University	Definiens Imaging GmbH	Remote Sensing Applications Center	InfoSAR Ltd.	Universität Bonn, Institut für Informatik	National Institute for Space Research
	Internetseite	www.nasoftware.co.uk	www.incite.org.uk/projects	www.definiens-imaging.com	www2.erdas.com/SupportSite	www.infosar.co.uk	www-dbv.informatik.uni-bonn.de/polyDemo	www.dpi.inpe.br/spring
	Algorithmus	Simulated annealing	Superparamagnetic clustering	Region growing	Region growing	Simulated annealing	Triangulation	Region growing/ Watershed
	Anwendungsbereich	Fernerkundung, insb. Radar	Bildanalyse, statistische Physik	Fernerkundung	Fernerkundung	Fernerkundung, insb. Radar	Polygonalisierung verrauschter Bilddaten	Fernerkundung
	Grundlegende Referenz	COOK et al. 1996	VON FERBER & WÖRGÖTTER 2000	BAATZ & SCHÄPE 2000	RUEFENACHT et al. 2002	COOK et al. 1996	HERMES & BUHMANN 2001	BINS et al. 1996
Implementierung	Stand der Software	09/1998	10/2002	04/2002 / 11/2002	09/2002	03/2003	08/2002	08/2003
	Betriebssystem	Linux, Solaris	Win, Linux, Unix, SGI	Win	Win (nicht XP)	Linux, Win	Linux	Win, Unix
	Systemschale	Standalone	K. A. (evtl. MatLab)	Standalone	Erdas	Standalone	Standalone	Standalone
	Parameter	6	3	3	2	2	2	2
	Ca. Laufzeit[1,2]	K. A. (hoch)	10 min	10 min	30 min	5 min	mehrere Stunden	30 min
	Reproduzierbarkeit[3]	Nein	Nein	Nein/ Ja (ab 3.0)	Nein	Nein	Nein	Nein
	Unterstützung einer Klassifikation	Ja	Nein	Ja (Fuzzy Logic, wissensbasiert)	Nein	Ja (Maximum Likelihood)	Nein	Ja
Ein- und Ausgabe	Max. Bildgröße [ca. Pixel][1]	2 000 x 2 000	4 000 x 4 000	10 000 x 10 000	2 000 x 2 000	Keine Beschränkung	2 000 x 1 500	2 000 x 2 000
	Max. Farbtiefe	16 Bit	16 Bit	32 Bit	8 Bit	64 Bit	8 Bit	8 Bit
	Eingabeformate	IMG	Raster (TIFF)	Raster, Shape	IMG	NetCDF[4]	Raster	GRIB[4]
	Vektorausgabe / Format	Nein (extern)	Nein (extern)	Shape	Arc-Coverage	Nein (extern)	Nein (extern)[5]	Nein (extern)[6]
	Zusatzdaten nutzbar	Ja	Nein	Ja	Nein	Ja	Nein	Ja
Vertrieb	Verfügbarkeit	Nicht mehr verfügbar	Kommerziell	Kommerziell	Freeware	Kommerziell	Auf Anfrage	Freeware
	Ca. Preis[7] (Kommerziell/ Forschung)	-	K.A./Kostenlos (non-profit)	14000 €/ 9000 € (non-profit) /2900 €	kostenlos	8300 € / 5800 €	-	kostenlos

[1] Angabe stark abhängig von Systemressourcen, insb. Arbeitsspeicher. [2] Bei Nutzung der hier verwendeten Bilddaten (2 000 x 2 000 Pixel). [3] Bei verändertem Bildausschnitt. [4] Konvertierbar aus diversen Rasterformaten, z. B. GeoTIFF, IMG. [5] Proprietäres Vektorformat. [6] Programminterne Vektorausgabe funktionierte nicht. [7] Stand 04/2003.

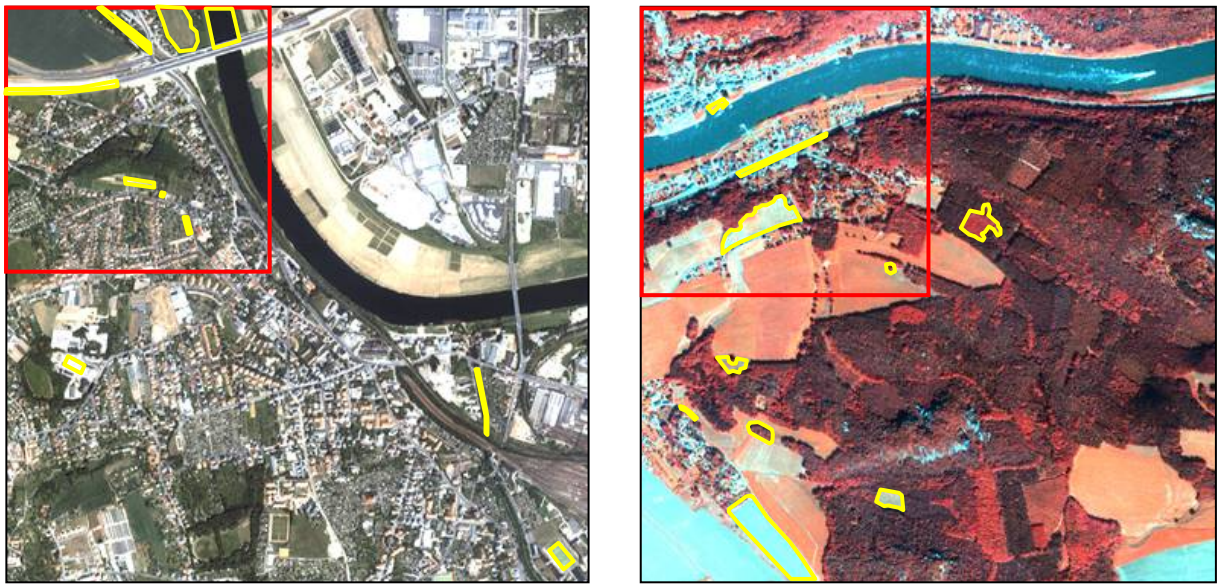

Abb. 4.8: Grundlagen des Segmentierungsvergleichs: IKONOS-Fusionsbild eines urbanen (Naturfarbdarstellung, links) und eines ruralen (Infrarotdarstellung, rechts) Gebietes. Dargestellt sind weiterhin die Lage der 20 Testflächen (gelb) sowie das durch den *Minimum Entropy Approach* berechnete Gebiet (1 000 x 1 000 Pixel, rot).
(Quelle: Eigene Darstellung, © Space Imaging)

Entropy Approach wurde für beide Testgebiete aufgrund mangelnder Performance nur ein Viertel der Bildfläche berechnet (jeweils 1 000 x 1 000 Pixel). Außer für InfoPACK lagen für alle Ansätze Segmentierungen mit unterschiedlichen, die Segmentgröße beeinflussenden Parametern vor. Im Fall einer schlechten Objektabgrenzung konnte so auf feinere oder gröbere Segmentierungsniveaus zurückgegriffen werden.

Alle Segmentierungsergebnisse wurden für den anschließenden Geometrievergleich vektorisiert. Da nur eCognition und die ERDAS-IMAGINE-Erweiterung *Image Segmentation* ein GIS-lesbares Vektorformat exportieren, wurden alle anderen Segmentierungen als Rasterdaten (TIFF) mit eineindeutigem Attribut ausgegeben. Den Rasterdaten wurde durch Hinzufügen des Worldfiles (TFW) der Testdaten ihre Geocodierung wieder zugewiesen. Anschließend wurden diese GeoTIFF-Dateien einer Raster-Vektor-Konvertierung durch ein externes Programm (ERDAS IMAGINE) unterzogen.

Zu negativen Effekten führte die Vektorisierung lediglich im Falle des *Minimum Entropy Approach*, da sich dieses Verfahren nicht wie andere Segmentierungsprogramme an den Rastergrenzen orientiert (vgl. Abbildung 4.9). Durch den dort implementierten Triangulationsalgorithmus wird das Bild vielmehr über Rastergrenzen hinweg zerlegt. Die Vektorkonvertierung zog eine höhere Anzahl von Teilsegmenten sowie Fehlsegmentierungen nach sich, da infolge der Umwandlung Polygone nicht geschlossen sind. Diese Effekte beeinflussen die Qualitätsprüfung negativ, waren jedoch aufgrund einer fehlenden Vektorausgabe nicht vermeidbar.

Die unterschiedlichen Resultate wurden zunächst einer überblicksartigen, visuellen Bewertung der Gesamtsegmentierungsgüte unterzogen. Dabei standen allgemeine Aspekte, wie die Güte der Trennung unterschiedlicher Flächenbedeckungen (z. B. Wiese/Wald, Feld/Wiese), die Abbildung linearer Objekte oder das Auftreten von Fehlsegmentierungen im Mittelpunkt.

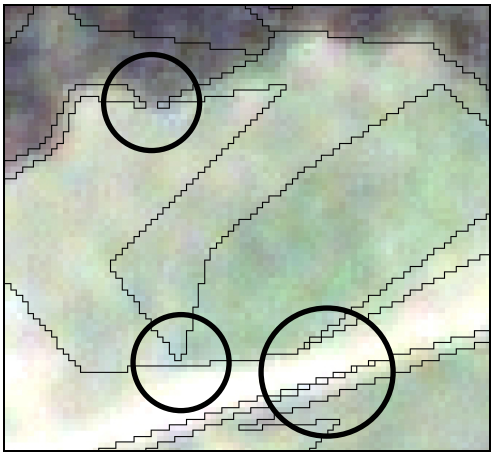

Abb. 4.9: Vektor-Konvertierungsprobleme beim *Minimum Entropy Approach.* Die Folge: ungeschlossene Polygone (linke Markierungen) sowie Bildung von Kleinstpolygonen (rechte Markierung). (Quelle: Eigene Darstellung, © Space Imaging)

Anschließend erfolgte ein detaillierter Vergleich anhand ausgewählter, visuell kartierter Referenzflächen. Bei deren Auswahl wurde insbesondere die visuell relativ sichere Abgrenzbarkeit berücksichtigt. Zunächst wurden 20 Referenzflächen – die sich in Lage, Form, Größe, Bedeckung/Nutzung, Kontrast, Textur etc. unterscheiden (siehe Abbildung 4.10) – sowie deren segmentierte Pendants visuell gegenübergestellt und beschrieben. Im nächsten Schritt erfolgte ein quantitativer Vergleich der Ergebnisse. Dabei wurden die Kriterien Anzahl von Teilsegmenten, die Segmentgröße, der Umfang, der Shape-Index (Umfang-Flächen-Verhältnis) sowie der Abweichung dieser Werte im Vergleich zur Referenzfläche bestimmt. Als Teilsegmente wurden alle zu mindestens 50 % im Referenzobjekt liegenden Segmente gezählt. Der Shape-Index stammt aus der Landschaftsökologie und beschreibt die Flächenform (Shape-Index = Umfang/4*Wurzel des Flächeninhaltes). Zusätzlich wurde die Qualität der Ergebnisse visuell bewertet (0 schlecht, 1 mittel, 2 gut; vgl. Abschnitt 4.3.3).

Die geplante Ergänzung dieser Resultate durch qualitative Kriterien konnte nicht umgesetzt werden, da sich die Software SEQ-Tool (vgl. DELPHI IMM 2003) zur Bewertung der Grenzlinienübereinstimmung noch in Entwicklung befindet. Diese Software vergleicht Segmentierungen mit Referenzobjekten, wobei der Nutzer in Abhängigkeit des Zielmaßstabes bzw. der geforderten Genauigkeit eine tolerierbare Abweichung in Form eines Puffers wählt. Der mit dem SEQ-Tool berechnete Index bewertet die geometrische Grenzlinienübereinstimmung in einem Wertebereich zwischen 0 (keine Deckungsgleichheit) und 100 (maximale Übereinstimmung). Derzeit liegen nur vorläufige Ergebnisse vor, die hier nicht dargestellt werden.

Eine gute Segmentierungsqualität wird erreicht, wenn möglichst alle verschiedenartigen Flächenbedeckungen/-nutzungen korrekt abgegrenzt werden und andererseits homogene Flächen nicht übermäßig in Teilsegmente zerlegt werden (Übersegmentierung). Zudem sollten die ermittelten Formkriterien möglichst gut mit den Maßen der Referenzflächen übereinstimmen.

4.3.2 Visuelle Bewertung der Gesamtsegmentierungen

Das für die Segmentierung von Radar-Daten entwickelte Programm CEASAR 3.1 erbringt wenig nützliche Resultate (siehe Abbildung 4.11). Es führt zumeist zu kompakten Segmenten ähnlicher Größe. Selbst bei unterschiedlichen Segmentierungsparametern kommt dieser Effekt zum Tragen, wobei lediglich die durchschnittliche Segmentgröße variiert. Dadurch bleiben kleinere Strukturen, insbesondere linienhafte Elemente, häufig unrepräsentiert und

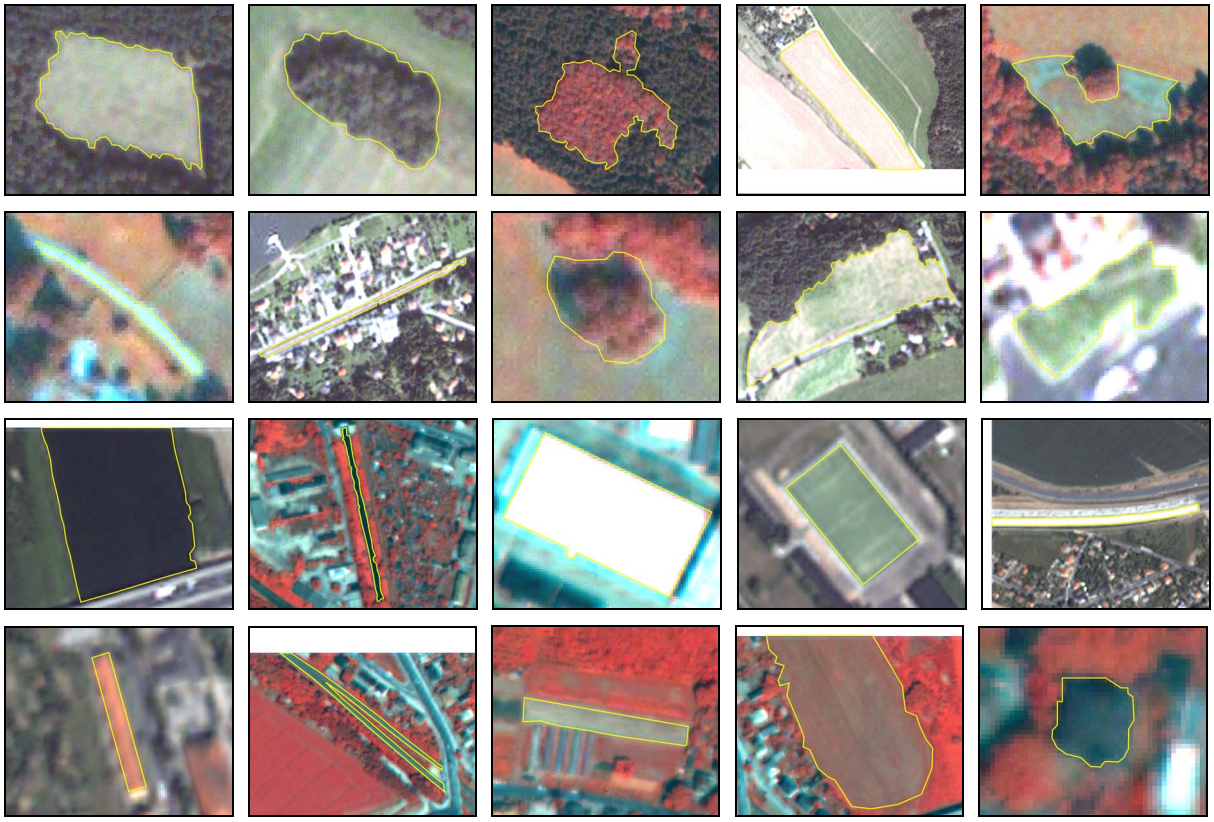

Abb. 4.10: Darstellung der 20 genutzten, visuell kartierten Referenzflächen (gelb markiert). (Quelle: Eigene Darstellung, © Space Imaging)

es kommt insgesamt zu einer Übersegmentierung. Kontrastarme Flächenübergänge werden schlecht wiedergegeben, teilweise auch Grenzen mit ausreichendem Kontrast (z. B. Wald vs. Wiese).

Die Segmentierungen der *Data Dissection Tools* (siehe Abbildung 4.11) weisen nur teilweise befriedigende Ergebnisse auf. Die Software neigt zu einer sehr starken Übersegmentierung sehr heller Bildbereiche, wodurch eine Vielzahl von Kleinstsegmenten entsteht. Homogene Flächen (z. B. Acker, Wiesen, Gewässer) werden zumeist korrekt segmentiert. Sehr große Areale werden zuweilen willkürlich geteilt. In kontrastarmen Bildbereichen kommt es zu deutlichen Abgrenzungsfehlern. Fehler treten auch in Waldgebieten auf. Hier werden zum Teil einzelne Pixel abgegrenzt (ähnlich dem *salt-and-pepper*-Effekt). Das nahe Infrarot wird durch die *Data Dissection Tools* aufgrund einer ungünstigen Gewichtung nur geringfügig berücksichtigt, was insbesondere bei der Trennung von Laub- vs. Nadelwald deutlich wird. Die befehlszeilenorientierte Programmsteuerung wird als nicht mehr zeitgemäß angesehen.

Die Ergebnisse von eCognition 2.1 und 3.0 (siehe Abbildung 4.12) sind – trotz ihrer teils deutlichen Unterschiede bei Verwendung gleicher Parameter – zumeist von guter Qualität. Allerdings enthalten die Ergebnisse bisweilen irregulär abgegrenzte Segmente, insbesondere an saumartigen Übergängen und in Waldgebieten. In kontrastarmen Arealen können Fehlsegmentierungen auftreten. Große, homogene Flächen werden mitunter willkürlich geteilt.

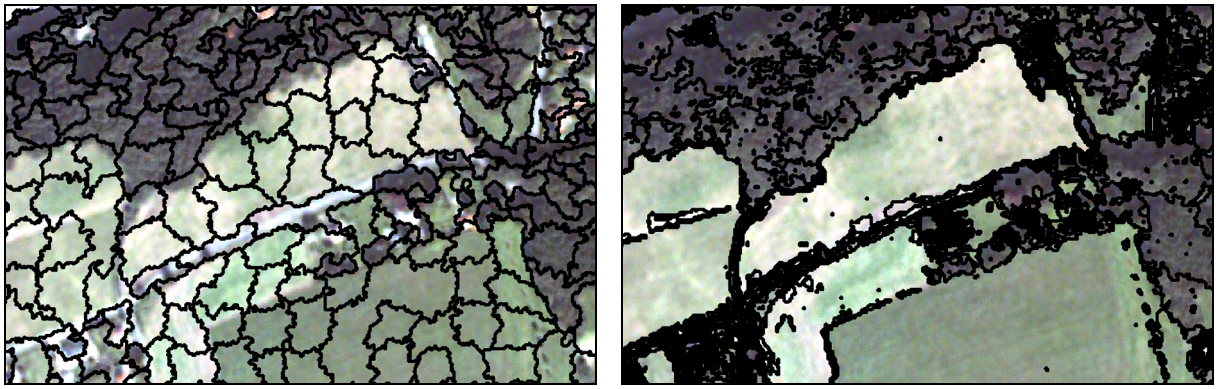

Abb. 4.11: Segmentierungsergebnisse von CAESAR 3.1 (links) und von den *Data Dissection Tools* (rechts). (Quelle: Eigene Darstellung, © Space Imaging)

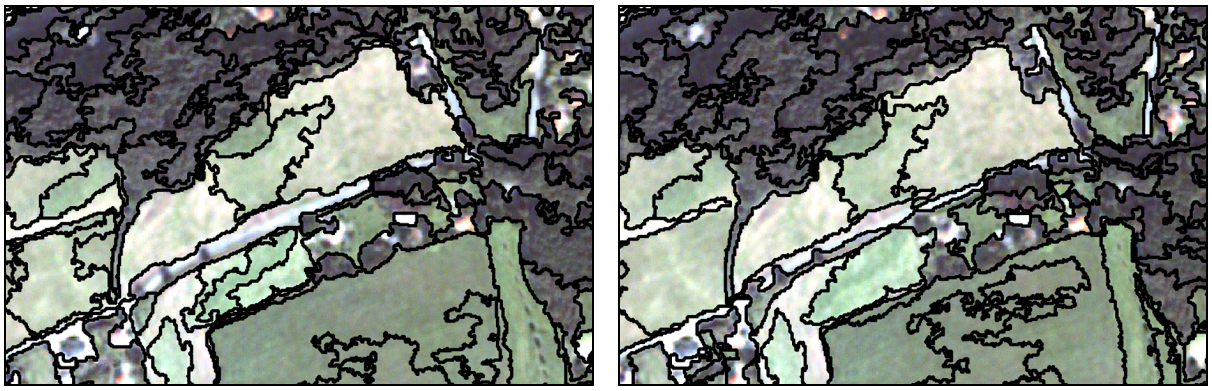

Abb. 4.12: Segmentierungsergebnisse von eCognition 2.1 (links) und 3.0 (rechts). (Quelle: Eigene Darstellung, © Space Imaging)

Seit der eCognition-Version 3.0 wird ein Segmentierungsalgorithmus eingesetzt, der eine Unabhängigkeit des Segmentierungsergebnisses vom Bildausschnitt gewährleistet. Der Algorithmus der Version 2.1 kann auch in der aktuellen Version 4.0 alternativ verwendet werden. Insgesamt bietet eCognition durch seine multiskalige Segmentierung sowie durch eine *fuzzy-logic*-basierte Bildklassifikation viele Potenziale. Durch die vielfältigen Schnittstellen zu anderen GIS- und Fernerkundungssystemen werden wichtige Anwenderforderungen erfüllt.

Die Anwendung der ERDAS-IMAGINE-Erweiterung *Image Segmentation* (siehe Abbildung 4.13) führt zu Über- und Untersegmentierung innerhalb eines Segmentierungsergebnisses. Kontrastreiche Grenzen zwischen Hauptnutzungen (z. B. Acker vs. Wald) werden gut wiedergegeben. Flächen mit geringem Kontrastunterschied werden häufig nicht segmentiert. Probleme bereitet die Abgrenzung von Acker gegen Wiese. Waldgebiete werden zu großen Konglomeraten zusammengefasst, innerhalb derer häufig sehr kleine Inselsegmente entstehen, die wenig größer als der gewählte Parameter Mindestsegmentgröße sind *(salt-and-pepper*-Effekt). Die Abbildung linearer Strukturen ist häufig mangelhaft. Homogene Flächen werden oftmals geteilt.

Das Ergebnis enthält Segmentierungsfehler in Form horizontaler oder vertikaler Grenzen. Das Ausmaß dieser Fehlsegmentierungen hat sich mit einer neuen Version, veröffentlicht im September 2002, etwas verringert. Sie waren hauptsächlich eine Folge der vom Programm genutzten Blockgröße, die nun entsprechend der verfügbaren Systemressourcen bzw. Bilddaten frei gewählt werden kann. Dennoch treten weiterhin vereinzelt Segmentierungsfehler auf. Mit der neuen Programmversion hat sich auch die Berechnungszeit deutlich verbessert. Die Segmentierungsqualität ist jedoch insgesamt nahezu unverändert gering.

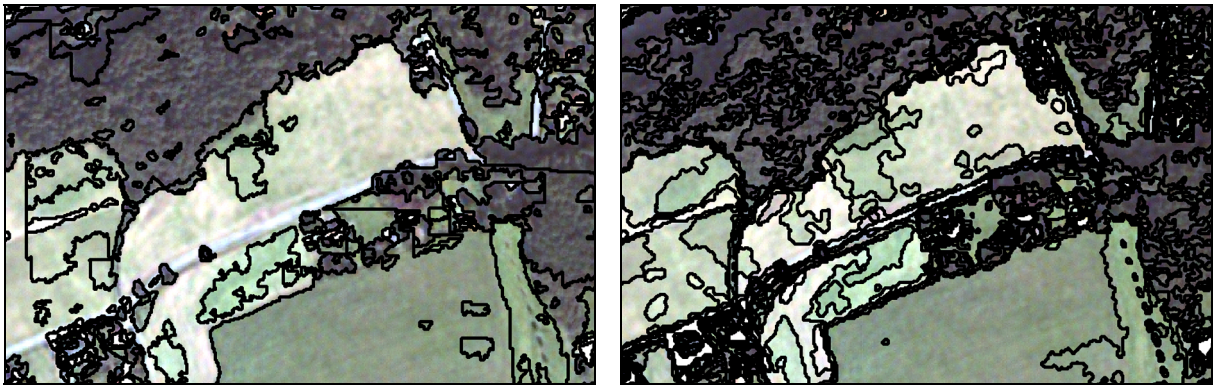

Abb. 4.13: Segmentierungsergebnisse der ERDAS-IMAGINE-Erweiterung *Image Segmentation* (links) und von InfoPACK 1.0 (rechts).
(Quelle: Eigene Darstellung, © Space Imaging)

Das Ergebnis von InfoPACK (siehe Abbildung 4.13), der Weiterentwicklung von CAESAR, bietet eine gute Abgrenzung der meisten Objekte, neigt dabei jedoch stark zur Übersegmentierung. Homogenere Objekte (Wiesen, Acker) sind davon weniger betroffen und werden zumeist gut abgebildet. Vor allem Waldflächen und Bebauung werden stark untergliedert. An Bedeckungs-/Nutzungsübergängen werden oftmals störende, schlauchförmige Segmente gebildet. Kontrastarme Grenzen werden häufig korrekt gefunden. Kompakte, nahezu gleichgroße Segmente wie bei CAESAR treten nicht mehr auf.

Hervorzuheben ist der implementierte *Tiling*-Algorithmus (Bildkachelung), um Bildszenen jeglicher Größe verarbeiten zu können. Allerdings entstehen an den Kachelübergängen zusätzliche Segmentgrenzen. Zudem sind Randeffekte möglich, die zu unterschiedlichen Ergebnissen beiderseits der Kachelgrenze führen können. Der Ansatz erlaubt darüber hinaus eine klassifikationsbasierte Zusammenfassung gleich klassifizierter und benachbarter Segmente (ähnlich wie eCognition), wodurch die Anzahl der Segmente deutlich reduziert werden kann. Zu beachten ist, dass die Software für stark verrauschte SAR-Daten entwickelt wurde und dies zu suboptimalen Ergebnissen bei der Segmentierung optischer Daten führen kann.

Der *Minimum Entropy Approach* (siehe Abbildung 4.14) bildet geradlinig verlaufende Grenzen so genannter *man-made features* (wie Feldgrenzen, Straßen) gut ab. Komplexe natürliche Grenzverläufe (z. B. Waldränder) werden durch das verwendete Triangulationsverfahren ungenau abgeleitet. Große homogene Flächen werden häufig zerteilt. Insgesamt zeigen sich als Folge der Triangulation vielfach geradlinige Segmentgrenzen oder -abschnitte bzw. typische Segmentformen, womit das Verfahren einer visuellen Abgrenzung ähnlicher ist. Gleichzeitig werden die o. g. Effekte der Raster-Vektor-Konvertierung deutlich. Das Verfahren liegt inzwischen als Weiterentwicklung vor *(boundary-constrained agglomerative segmentation* (vgl. HERMES & BUHMANN 2004).

Die Ergebnisse des in der Bildverarbeitungssoftware SPRING implementierten *region-growing*-Segmentierungsverfahrens bieten einen guten Gesamteindruck (siehe Abbildung 4.14). Homogene Flächen werden sehr gut abgegrenzt. Häufig kommt es jedoch zur Übersegmentierung dieser Flächen. Stark texturierte Gebiete, wie Waldflächen, werden dagegen meist untersegmentiert. Stellenweise treten Segmentierungsfehler auf. Mangelhaft sind die Bedienfreundlichkeit und das Datenhandling der Software. Der ebenfalls integrierte kantenbasierte *Watershed*-Algorithmus wurde zusätzlich getestet, führte aber zu weit schlechteren Ergebnissen (sehr starke Übersegmentierung) und wurde deshalb nicht in den Vergleich einbezogen.

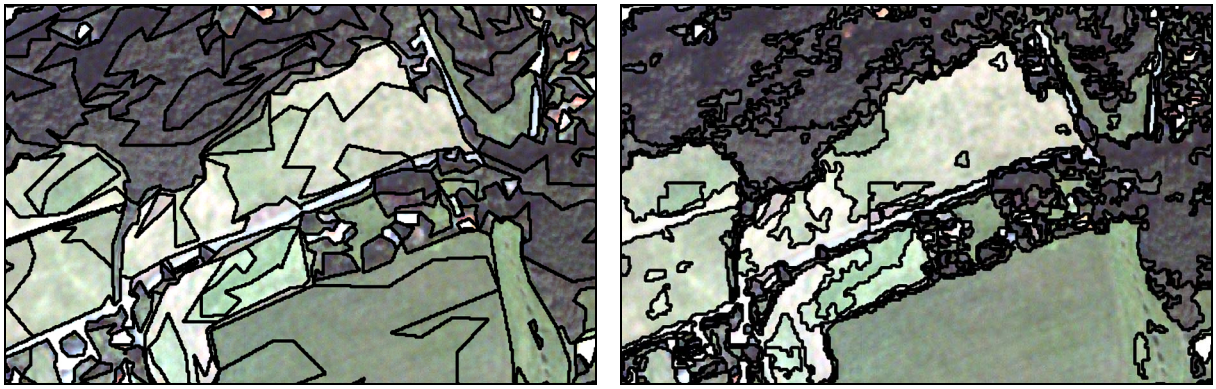

Abb. 4.14: Segmentierungsergebnisse des *Minimum Entropy Approach* (links) und von SPRING 4.0 (rechts). (Quelle: Eigene Darstellung, © Space Imaging)

4.3.3 Quantitative Bewertung anhand von Testflächen

Ein Beispiel für die detaillierte Auswertung einer einzelnen Referenzfläche wird in Tabelle 4.4 gegeben. Die anhand der Einzelflächen ermittelten Werte liefern die Voraussetzung für ein über alle 20 Testflächen gemitteltes Ergebnis (siehe Tabelle 4.5). Wie diese Übersicht zeigt, erreichen SPRING, eCogniton 2.1 bzw. 3.0 sowie InfoPACK und der *Minimum Entropy Approach* die besten durchschnittlichen Größenübereinstimmungen. Auch bei der mittleren

Tab. 4.4: Vergleichende Gegenüberstellung der Segmentierungsergebnisse für Referenzfläche 9. (Quelle: Eigene Darstellung)

Segmentierungsprogramm	Referenzfläche 9	CAESAR 3.1	*Data Dissection Tools*	eCognition 2.1	eCognition 3.0	*Image Segmentation*	InfoPACK 1.0	*Minimum Entropy Approach*	SPRING 4.0
Graphische Darstellung	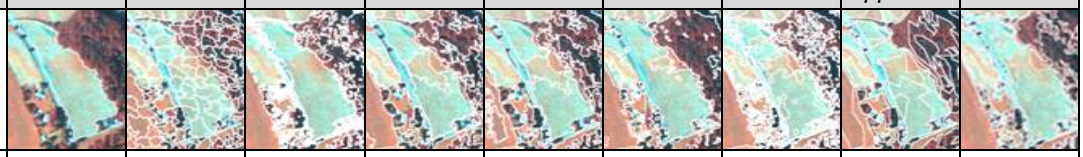								
Beschreibung/ Bemerkungen	*Grünland visuell segmentiert*	Stark übersegmentiert, Fehlsegmentierung	Ränder stark übersegmentiert, Kleinstsegmente	Leichte Fehlsegmentierungen	Leichte Fehlsegmentierungen	Sehr starke Fehlsegmentierung	Stark übersegmentiert, schlauchförmige Randsegmente	Übersegmentiert, Geradlinigkeit der Grenzen	Leichte Fehlsegmentierungen, übersegmentiert
Teilsegmente[1]	*1*	34	216	4	4	6	37	15	30
Größe [m²][2]	*19 776*	20 738	20 146	19 250	18 636	72 474	20 223	21 549	19 637
Differenz [%][3]	-	5	2	-3	-6	266	2	9	-1
Umfang [m][2]	*1 054*	1 550	1 110	1 470	1 194	6 628	1 134	1 324	1 290
Differenz [%][3]	-	47	5	39	13	529	8	26	22
Shape-Index[2]	*1,87*	2,69	1,96	2,65	2,19	6,16	1,99	2,25	2,30
Differenz [%][3]	-	44	4	41	17	228	6	20	23
Visuelle Bewertung[4]	-	0	1	1	1	0	1	0	0

[1] Mindestens 50 % Flächenübereinstimmung mit dem Referenzobjekt. [2] Werte ermittelt anhand entsprechend zusammengefasster Teilsegmente. [3] Zu den Werten des Referenzobjektes. [4] Wertebereich 0 (schlecht) bis 2 (gut).

Tab. 4.5: Ergebnisse des Segmentierungsvergleichs für 20 Testflächen. (Quelle: Eigene Darstellung)

Segmentierungs-programm	CAESAR 3.1	eCogni-tion 2.1	eCogni-tion 3.0	*Data Dis-section Tools*	*Image Segmen-tation*	InfoPACK 1.0	*Minimum Entropy Approach*	SPRING 4.0
Testflächen	10[1]	20	20	20	20	20	11[1]	20
Durchschnittliche Größenab-weichung [%]	75,1	12,5	15,9	2 100,3	107,0	11,1	13,6	8,2
Durchschnittliche Umfangsab-weichung [%]	35,1	15,9	17,2	475,6	177,3	30,9	10,0	10,8
Durchschnittliche Shape-Index-Abweichung [%]	25,5	16,7	16,2	38,9	87,1	25,5	10,0	11,7
Durchschnittliche Anzahl Teilseg-mente	10,4	1,9	1,8	134,6	5,9	17,1	9,0	6,2
Durchschnittliche visuelle Bewertung	0,0	1,0	0,9	0,2	0,2	0,6	0,8	0,9

[1] Abweichende Anzahl durch nicht vollständig vorliegende Segmentierungsergebnisse.

Abweichung von Umfang und *Shape*-Index ergibt sich das gleiche Bild, jedoch schneidet InfoPACK hier etwas schlechter ab. Die guten *Shape*-Index-Werte des *Minimum Entropy Approach* werden durch das der visuellen Abgrenzung ähnliche Triangulationsverfahren hervorgerufen.

Besonders in der Anzahl der gebildeten Teilsegmente zeigen beide eCognition-Versionen ihre Stärken. Sie weisen demnach die geringste Übersegmentierung auf. Die Ergebnisse der ERDAS-IMAGINE-Erweiterung *Image Segmentation* erreichen zwar hierbei ebenfalls einen guten Wert, sind aber aufgrund der starken Abweichungen der anderen Werte problematisch. Die Ergebnisse von SPRING können in Hinsicht auf die Anzahl der Teilsegmente ebenfalls als gut bewertet werden.

Damit untermauern die Ergebnisse die visuell bewerteten Qualitäten der einzelnen Segmentierungsprogramme. So erreichen derzeit nur die Segmentierungen von SPRING 4.0 und eCognition 2.1 bzw. 3.0 gute Gesamtergebnisse. Diese Programme führen meist zu den geringsten Abweichungen von den Referenzflächen bei allen untersuchten Faktoren. InfoPACK und der *Minimum Entropy Approach* liefern ebenfalls akzeptable Resultate. Erstere Software neigt jedoch zur Übersegmentierung und der zweite Ansatz besitzt noch erhebliche Mängel bezüglich seiner Leistungsfähigkeit.

Die Ergebnisse der weiteren drei Ansätze bleiben dahinter zurück, sie scheitern vermutlich an der hohen Komplexität der hoch auflösenden Satellitenbilddaten. Eine starke Fehl- oder Übersegmentierung ist häufig die Folge. Zudem ist der Grad an Übereinstimmungen zu den Referenzobjekten gering. Allerdings muss hier betont werden, dass diese Ansätze teilweise nicht primär für die Fernerkundung entwickelt wurden.

Von der Implementierung sowie vom Handling her sind die kommerziellen Programme eCognition und InfoPACK den anderen, zumeist aus dem Forschungsbereich stammenden Entwicklungen deutlich überlegen. Nur diese Programme bieten vielfältige Schnittstellen zum Im- und Export anderer Datenformate, ermöglichen die Verarbeitung größerer Datenmengen und besitzen eine bedienerfreundliche graphische Benutzeroberfläche.

4.3.4 Vergleich mit ähnlichen Untersuchungen

Einen weiteren empirischen Vergleich von Segmentierungsverfahren führten CARLEER et al. (2003) durch. Segmentierungsergebnisse folgender vier Algorithmen auf Basis panchromatischer IKONOS-Daten wurden dabei gegenübergestellt:

Zwei kantenbasierte Verfahren

- *Optimal edge detector* (COCQUEREZ & PHILIPP 1995) und
- *Watershed segmentation* (DEBEIR 2001),

sowie zwei regionenbasierte Verfahren

- *Multilevel tresholding* (DERAVI & PAL 1983) und
- eCognition (DEFINIENS IMAGING 2003).

Die Ergebnisse dieser Untersuchung zeigen ebenfalls, dass die Güte von Segmentierungen in hohem Maße von den gewählten Parametereinstellungen abhängig ist. Weiterhin wurde geschlussfolgert, dass kantenbasierte Verfahren nur für homogene, stark kontrastreiche Flächen geeignet sind, wie sie in ländlichen Gegenden vorkommen. In urbanen Gebieten scheitern diese Ansätze zumeist, da sie sehr sensitiv gegenüber Rauschen und Texturen sind. Zudem ist bei der Anwendung kantenbasierter Segmentierungen eine zusätzliche Vorverarbeitung (Filterung) nötig. Die beiden regionenbasierten Ansätze schnitten besser ab, neigen jedoch teilweise zur Ausbildung saumförmiger Segmente an Flächenübergängen. Das *Multilevel-tresholding*-Verfahren führte darüber hinaus zu einer starken Übersegmentierung, die dem *salt-and-pepper*-Effekt gleichkommt (vgl. CARLEER et al. 2003).

Die Segmentierungsverfahren von eCognition und IMPACT wurden von HIRSCHMUGL (2002) gegenübergestellt. Dabei kam ein abweichendes Verfahren zum Einsatz, wobei sowohl die Referenzkartierung als auch die Segmentierungsergebnisse beider Programme als Rasterdatensatz verglichen wurden. Alle Pixel, die eine Grenzlinie darstellen, wurden dabei gezählt und mit der aus dem Referenzdatensatz ermittelten Zahl verglichen. Daraus wurde das Verhältnis von richtig zu falsch erkannten Objektgrenzen ermittelt. Der durchschnittliche Anteil korrekter Objektgrenzen ist bei eCognition (71 %) geringfügig höher als bei IMPACT (67 %). Beide Verfahren erzielen also grundsätzlich gute Ergebnisse. Jedoch ist der Anteil falsch erkannter Grenzen bei IMPACT mit 27 % deutlich geringer als bei eCognition infolge einer Übersegmentierung mit 45 %. Unter Berücksichtigung einer Lagetoleranz von zwei Pixeln werden die Resultate von IMPACT als qualitativ besser gegenüber denen von eCognition eingestuft.

4.3.5 Schlussfolgerungen aus dem Segmentierungsvergleich

Die Segmentierung von Bilddaten ist für hoch auflösende Bilddaten unverzichtbar geworden. Die weitere Entwicklung erster, Erfolg versprechender Segmentierungsansätze bietet viele Potenziale, um die Abgrenzung von Landschaftseinheiten und damit gleichzeitig Klassifikation im Bereich der Fernerkundung genauer und effizienter zu gestalten. So könnte z. B. die Nutzung von Texturinformationen die Segmentierungsergebnisse weiter verbessern, allerdings bietet derzeit nur InfoPACK diese Option, die aber in diesem Test nicht genutzt werden konnte. Auch eine Kombination mit Programmen zur Objektextraktion bzw. modellbasierte Segmentierungsverfahren wären erstrebenswert zur Verbesserung der Segmentierungsqualität.

Die Segmentierungsansätze reagieren häufig sehr sensibel auf geringfügige Variationen, wie z. B. leichte Parameterveränderungen, der Reihenfolge der Segmentierung bei hierarchischen Verfahren und der Bilddaten selbst (Bildgröße, Farbtiefe), wodurch der Anwender mit

einer großen Zahl von Freiheitsgraden konfrontiert wird. Bei den meisten Programmen wird zum Teil auf komplexe Parameter zurückgegriffen, deren Einstellung nur von Experten mit dem nötigen Hintergrundwissen des Ansatzes sowie einer gewissen Nutzererfahrung möglich ist. Die Wirklichkeit ist jedoch all zu oft durch eine zeitaufwändige empirische Parametersuche nach dem *trial-and-error*-Prinzip gekennzeichnet, wodurch subjektiv beeinflusste Resultate entstehen. Eine Minimierung dieser Einflussmöglichkeiten sollte daher im Rahmen der Weiterentwicklung der Programme angestrebt werden. Die Integration von Instrumentarien zur Beurteilung der Segmentierungsgüte in den Segmentierungsprogrammen erscheint dabei für die Evaluierung wünschenswert.

Die Weiterführung dieser Untersuchung ist durch die Integration weiterer Segmentierungsprogramme vorgesehen, z. B. IMPACT (Johanneum Research, vgl. HIRSCHMUGL 2002), HALCON 7.0 (MVTEC SOFTWARE 2004), Parbat 0.32 (vgl. LUCIEER 2004), SegSAR (National Institute for Space Research, Brasilien), RHSEG-AED (NASA's Goddard Space Flight Center, USA) sowie InfoPACK 2.0 (InfoSAR Ltd.).

Teil III:
Anwendung segmentbasierter Klassifikationsverfahren auf IKONOS-Daten

„An important consequence of the distinction between reality and data is that operations performed on data, such as the data analysis tools of remote sensing and GIS, relate to this data and not to the reality they represent."

PETER M. ATKINSON & NICHOLAS J. TATE (1999)

5 Landschaftsanalyse durch die segmentbasierte Auswertung von IKONOS-Daten

Mit der Verfügbarkeit neuer, sehr hoch auflösender Fernerkundungsdaten ergeben sich neue oder verbesserte Anwendungsmöglichkeiten. Ein klassisches Einsatzgebiet der Fernerkundung ist die Landschaftsanalyse, d. h. die Ableitung von Informationen zur Landbedeckung bzw. Landnutzung durch die Klassifikation von Bilddaten. Es konnte gezeigt werden, dass sich segmentbasierte Klassifikationsansätze sehr gut eignen, um die Potenziale dieser heute nutzbaren Datengrundlagen weitestgehend auszuschöpfen.

Vor diesem Hintergrund wird im vorliegenden Kapitel die Anwendung der Software eCognition auf zwei verschiedenartige Untersuchungsgebiete beschrieben – einem städtisch und einem ländlich geprägten Raum. Diese Untersuchungen basieren auf der zum Bearbeitungszeitpunkt erhältlichen Programmversion 1.0 (vgl. NEUBERT & MEINEL 2002). Die zwischenzeitlich erfolgten Programmverbesserungen infolge der intensiven Weiterentwicklung der Software werden im Text dargestellt.

Daneben ist die Analyse der Landschaftsstruktur ein bedeutendes Teilgebiet der landschaftsökologischen Forschung. Die Verwendung von Landschaftsstrukturmaßen zur segmentbasierten Klassifikation sowie die Schaffung geeigneter Basisgeometrien für die Berechnung dieser Indizes sind ebenfalls Gegenstand dieses Kapitels.

5.1 Segmentbasierte Klassifikation unterschiedlicher Testgebiete

Durch die vergleichende Anwendung der Bildanalysesoftware eCognition auf zwei unterschiedliche Testgebiete sollten Gemeinsamkeiten und Unterschiede in der Bearbeitung aufgezeigt werden. Insbesondere die Wahl der Segmentierungs- bzw. Klassifikationsstrategie und die erzielbare Klassifikationsgüte standen im Mittelpunkt dieser Untersuchung.

Die zugrunde liegenden Bilddaten sind Teile der vorhandenen IKONOS-Szenen. Die Lage der Gebiete wurde bereits in Abschnitt 3.1.1, Abbildung 3.4, dargestellt. Für eine beispielhafte Anwendung in einem urbanen bis suburbanen Raum wurde ein Ausschnitt von 2,4 x 2,4 km aus der Szene des Stadtgebietes Dresden vom 04.06.2000 gewählt. Bei diesem Testgebiet handelt es sich um die gleiche Fläche, die bereits im Abschnitt 4.2 beschrieben wurde (siehe Abbildung 4.5).

Für die Betrachtung eines ländlichen Raumes wurde ein Ausschnitt aus der Szene der Vorderen Sächsischen Schweiz gewählt (siehe Abbildung 5.1). Das 3,5 x 3,5 km umfassende Untersuchungsgebiet ist Teil der IKONOS-Szene vom 01.08.2000. Das Gebiet ist sehr reliefreich und wird durch Ebenheiten und Tafelberge, Felsgebiete sowie das Elbtal geprägt. Das teilweise zum Nationalpark Sächsische Schweiz gehörende Gebiet besitzt eine naturnahe, homogene Flächennutzung mit einem charakteristischen Wechsel von Wald- und Offenland

Abb. 5.1: Ländliches Testgebiet (Vordere Sächsische Schweiz).
(Quelle: Eigene Darstellung, © Space Imaging)

bereichen. Die Wälder bestehen aus Laub- und Nadelbaumbeständen, die jedoch in der Klassifikation nicht unterschieden wurden. Die landwirtschaftlich genutzten Flächen weisen unterschiedliche Fruchtarten auf (Getreide, Ölfrüchte und Feldfutter). Neben dörflichen Siedlungsstrukturen treten im Elbtal auch Industriestandorte auf.

Die Eingangsdaten wurden nach der in den Abschnitten 3.2.1 und 3.2.3 beschriebenen Weise vorverarbeitet. Grundlagen der Auswertungen waren somit passpunktentzerrte (Dresden) bzw. orthorektifizierte IKONOS-Daten (Sächsische Schweiz). Vorhergehende Tests hatten gezeigt, dass die Segmentierung auf Basis eines Fusionsbildes (PC-Verfahren) die besten Ergebnisse ergab. Für beide Gebiete wurden deshalb die zur Verfügung stehenden IKONOS-Daten fusioniert, um den Detailgehalt der panchromatischen 1-m-Daten mit den multispektralen 4-m-Daten zu kombinieren. Dadurch wurde die Auflösung für alle Kanäle auf 1 m berechnet. Ohnehin waren in eCognition 1.0 nur Daten gleicher Rasterung verwendbar. Genutzt wurden jeweils die vier multispektralen Kanäle sowie der panchromatische Kanal. Zusätzlich wurde ein Vegetationsindex (NDVI) einbezogen.

Als Zusatzdaten zur Segmentierung kam im urbanen Untersuchungsraum ein gerasterter Ausschnitt der digitalen Blockkarte der Stadt Dresden (zur Straßengenerierung) zum Einsatz. Die Rasterung war nötig, da die erste Programmversion von eCognition noch keine Vektordaten importieren konnte. Im ländlichen Gebiet wurde das hoch aufgelöste Laser-Scanner-DGM mit einer Auflösung von 1 m einbezogen. Es wurde jedoch nicht zur Segmentierung, sondern nur zur Unterstützung der Klassifikation genutzt.

5.1.1 Segmentierungs- und Klassifikationsstrategie

Infolge der Unterschiedlichkeit der Testgebiete war ein differenziertes Vorgehen nötig. Im Fall des urbanen Gebietes tritt eine sehr kleinräumige und heterogene Flächennutzung auf. Die zu extrahierenden *objects of interest* sind daher von geringerer Größe als im ländlichen Untersuchungsraum. Diesem Faktum muss durch geeignete Parametereinstellungen Rechnung getragen werden. Die angewendete Segmentierungsstrategie ist entsprechend zu

Tab. 5.1: Zur Segmentierung mit eCognition verwendete Parameter für das urbane und das rurale Testgebiet. (Quelle: Eigene Darstellung)

Parameter	Urbanes Testgebiet			Rurales Testgebiet		
	Ebene 1	Ebene 2	Ebene 3	Ebene 1	Ebene 2	Ebene 3
Scale	10	50	165	10	50	150
Color	0,8	0,7	0,5	0,8	0,6	0,4
Shape	0,2	0,3	0,5	0,2	0,4	0,6
Compactness	0,8	0,7	0,5	0,9	0,7	0,5
Smoothness	0,2	0,3	0,5	0,1	0,3	0,5

wählen. Die unterschiedlichen Anforderungen widerspiegeln sich in den in Tabelle 5.1 dargestellten Segmentierungsparametern. Die genannten Parameter mussten dabei durch iterative Tests gefunden werden.

Die Segmentierung der urbanen Testdaten erfolgte in drei Segmentierungsebenen. Alle Ebenen waren Bestandteil der anschließenden Klassifikation, wobei auf den beiden übergeordneten (gröberen) Segmentierungsebenen 2 und 3 ausschließlich Zugehörigkeitsfunktionen zur Klassenbeschreibung genutzt wurden. Auf der untersten (feinsten) Ebene 1 wurde das Ergebnis mittels Beispielflächen weiter differenziert.

Die Bilddaten des ruralen Untersuchungsgebietes wurden ebenfalls in drei Ebenen segmentiert. Die Segmentierungsebene 1 war aufgrund der größeren Objektausmaße zur Klassifikation nicht nötig. Die Klassenzuweisung wurde nur unter Verwendung von Zugehörigkeitsfunktionen durchgeführt. Bei auftretender atmosphärischer Beeinflussung durch Bewölkung, wie sie im Süden des Testgebietes deutlich erkennbar ist, erfolgte eine manuelle Klassenzuweisung.

5.1.2 Klassifikationsergebnisse

Das Klassifikationsergebnis des urbanen Untersuchungsgebietes zeigt ein homogenes Bild (kein *Salt-and-Pepper*-Effekt, siehe Abbildung 4.5). Insgesamt konnten (in der dort dargestellten, zusammengefassten Ebene 1) 13 Klassen gebildet werden, zwei mehr als bei dem im gleichen Gebiet angewandten pixelbasierten Verfahren (vgl. Abschnitt 4.2). Trotz der starken Nutzungsheterogenität und des hohen Detailliertheitsgrades der Daten wurde eine Klassifikationsgüte von 89,6 % erreicht (siehe Tabelle 5.2), wobei für jede Klasse 20 zufällig generierte Testpunkte ausgewertet wurden.

Die Nutzung der digitalen Blockkarte ermöglichte eine Ableitung der Straßenflächen (Blockrestfläche) und wirkte sich positiv auf die Segmentierung aus. Nahe den vorgegebenen Grenzen war die Segmentierung durch eine geringere Segmentzahl sowie weniger ausgefranste Segmente gekennzeichnet.

Im Rahmen der Klassifikation ließen sich größere, homogene Flächen einfacher und präziser zuordnen, als heterogene Kleinobjekte. Schwierigkeiten ergaben sich insbesondere bei der Klassifikation bzw. Unterscheidung von Industrie- und Gewerbeflächen, Brachflächen, Parkplätzen sowie sonstigen versiegelten Arealen. Dies erklärt die geringere Klassifikationsgüte dieser Klassen infolge von Verwechslungen. Die Klassifikationsmöglichkeiten von nicht im Straßenlayer enthaltenen Straßenneubauten, linienhaften Gewässern und Sportplätzen sowie der sehr geringe Anteil unklassifizierter Flächen (0,07 %) sind als positive Resultate zu nennen.

Tab. 5.2: Klassifikationsgüte des urbanen und ruralen Testgebietes.
(Quelle: Eigene Darstellung)

Klasse	Urbanes Testgebiet		Rurales Testgebiet	
	Erkennungs-güte [%]	Klassifikations-güte [%]	Erkennungs-güte [%]	Klassifikations-güte [%]
Ackerland	100,0	100,0	-	-
Feldfutter	-	-	100,0	100,0
Getreide	-	-	100,0	100,0
Ölfrucht	-	-	100,0	100,0
Grünland, Wiese	80,9	85,0	90,0	90,0
Sportplatz	100,0	95,0	-	-
Wald/Baumbestand	100,0	95,0	87,0	100,0
Obstanbau	100,0	95,0	-	-
Gewässer	100,0	100,0	100,0	100,0
Industrie, Gewerbe	62,5	75,0	-	-
Bebauung	94,7	90,0	86,4	95,0
Bahnfläche	100,0	100,0	100,0	100,0
Autobahn	100,0	100,0	-	-
Straße	-[1]	-[1]	70,4	95,0
Weg	-	-	100,0	60,0
Brachfläche	83,3	75,0	94,1	80,0
Versiegelte Fläche	69,6	80,0	-	-
Parkplatz	83,3	75,0	-	-
Felsen	-	-	100,0	95,0
Gesamt-klassifikationsgüte	89,6		92,9	

[1] Straßenflächen wurden von der Gütebestimmung ausgeschlossen, da sie nicht klassifiziert, sondern unmittelbar aus der Blockrestfläche abgeleitet wurden.

Über eine Klassifikation der reinen Bodenbedeckung hinaus war teilweise eine Extraktion der Flächennutzungen möglich. Diese höhere Informationsebene kann durch die vielfältigen, zusätzlich nutzbaren Segmentmerkmale erreicht werden. Auf diese Weise konnten über die bereits genannten Klassen Park- bzw. Sportplätze auch weitere Klassen gebildet werden. Das in Abbildung 5.2 dargestellte Klassifikationsergebnis der Ebene 3 weist z. B. Verkehrsbegleitgrün aus. Dies sind Grünflächen einer bestimmten Größe, die von Straßenflächen eingeschlossen sind. Diese Regeln lassen sich mit eCognition eindeutig formulieren. Zur Gütekontrolle wurden die wenigen vorkommenden Flächen jedoch zu Grünland/Wiese zusammengefasst. Weitere Beispiele für Landnutzungsklassifikationen in der dritten Ebene sind beispielsweise Kleingartenareale oder Bebauungsblöcke. Die in Abbildung 4.5 und Tabelle 5.2 dargestellte, zur Gütekontrolle verwendete Klassifikationsebene 1 zeigt dagegen Kleingärten und Baublöcke aufgeteilt in deren Bodenbedeckungsbestandteile.

Das in Abbildung 5.3 dargestellte Bearbeitungsergebnis des ländlichen Testgebietes weist häufig fraktale Grenzen auf (insbesondere in Waldgebieten), welche die Klassifikation erschwerten. In diesem Fall wurden keine Zusatzdaten zur Verbesserung der Segmentierung verwendet. Ungünstig wirkten sich die vorhandene Bewölkung sowie Dunstschleier aus, die keine Unterscheidung von Laub- und Nadelwald zuließen. Eine vorhergehende Atmosphärenkorrektur war mangels Software zu diesem Zeitpunkt nicht möglich. Die Nutzung des DGM's verbesserte das Ergebnis und ermöglichte u. a. die Klassifikation von Felsgebieten

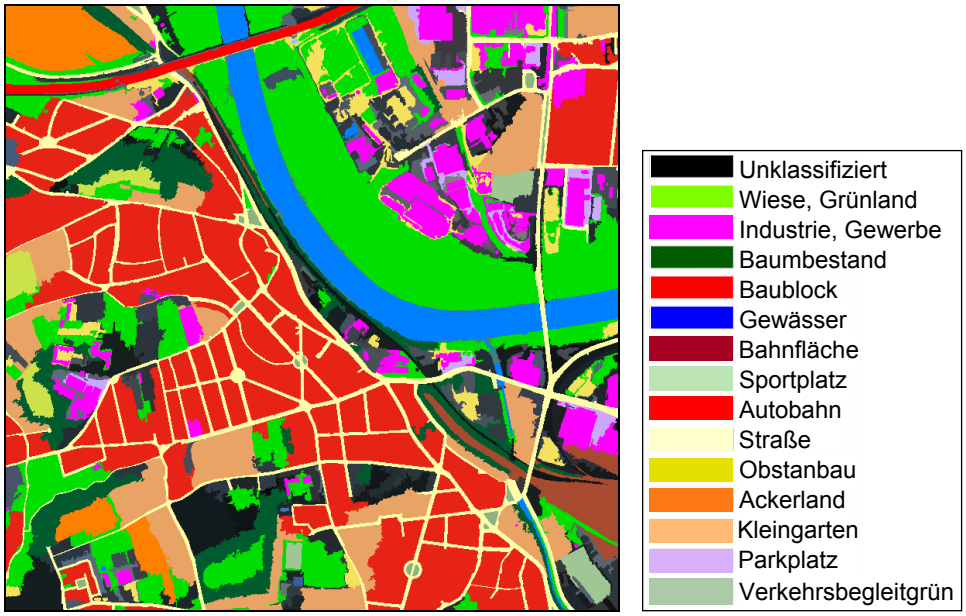

Abb. 5.2: Klassifikationsergebnis des urbanen Testgebietes mittels eCognition, Klassifikationsebene 3. (Quelle: Eigene Darstellung)

bzw. den Ausschluss bestimmter Nutzungen (z. B. Eisenbahn nur im Tal). Darüber hinaus ließe sich zusätzlich ein Oberflächenmodell für die Klassifikation von Gebäuden u. ä. einsetzen (vgl. HOFFMANN & VAN DER VEGT 2001; HOFMANN 2001). Im Ergebnis der Klassifikation konnten zwölf Bodenbedeckungsklassen mit einer Gesamtklassifikationsgüte von 92,9 % unterschieden werden (siehe Tabelle 5.2). Gut differenzierbar waren die unterschiedlichen Ackerkulturen. Problematisch hingegen war die Unterscheidung von Bebauung gegenüber Brachfläche sowie von Straßen gegenüber Wegen.

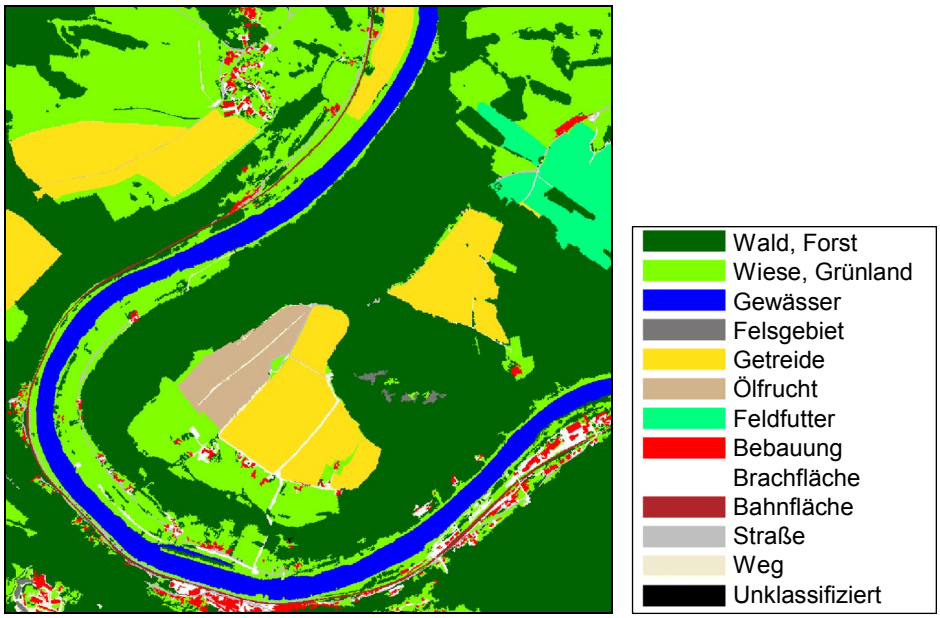

Abb. 5.3: Klassifikationsergebnis des ländlichen Testgebietes mittels eCognition, Klassifikationsebene 2. (Quelle: Eigene Darstellung)

5.1.3 Diskussion der Ergebnisse

Mit der vorliegenden Untersuchung konnte gezeigt werden, dass eCognition mit der segmentbasierten Klassifikation eine geeignete Methodik bietet, um sehr hoch auflösende Satellitendaten auszuwerten. Sowohl im städtischen als auch im ländlichen Untersuchungsgebiet wurde mit einer Klassifikationsgüte von etwa 90 % ein gutes Ergebnis erreicht.

Kritisch anzumerken ist die mangelnde Transparenz im Segmentierungsprozess. Das Finden optimaler Segmentierungsparameter muss durch aufwändige iterative Tests nach dem *trail-and-error*-Prinzip erfolgen. Hier fehlen helfende oder steuernde Werkzeuge (evtl. durch die Abgrenzung von Trainingsobjekten). Auch die Qualität der Abgrenzung ist zum Teil nicht optimal. So werden insbesondere innerhalb von Waldgebieten häufig stark zergliederte (ausgefranste) Segmente gebildet, auf deren Grundlage eine Klassifikation kaum möglich ist.

Als vorteilhaft sind die vielfältigen Segmentmerkmale zu nennen, die eine umfassendere Klassifikation gestatten. Es konnte gezeigt werden, dass dadurch teilweise eine Klassifikation der Flächennutzung gegenüber einer bloßen Bodenbedeckungskartierung möglich ist.

Der Aufbau einer umfangreichen Wissensbasis als Klassifikationsgrundlage kann ein zeitaufwändiger Prozess sein. Wichtig ist hierbei die Verwendung möglichst weniger, einfacher und stabiler Regeln, da der Klassifikationsbaum sonst leicht unübersichtlich wird und zu große Überschneidungen auftreten. Die Nutzung *fuzzy-logic*-basierter Zugehörigkeitsfunktionen bietet zusätzliche Vorzüge gegenüber harten Klassifikationsregeln. Diese Regeln können zudem aus einer Auswahl an Trainingsflächen automatisch generiert und bei Bedarf weiter angepasst werden.

eCognition erlaubt durch seine fortschrittliche Implementierung ein gutes Handling sehr hoch auflösender Bilddaten. Durch die graphische und menügesteuerte Benutzeroberfläche ist ein einfacher Umgang mit der Software gewährleistet. Die vielfältigen Importmöglichkeiten erlauben die sinnvolle Nutzung zusätzlicher Daten, welche den Segmentierungs- und Klassifikationsprozess unterstützen können. Der einfache Export der Daten in GIS-lesbare Formate ermöglicht die Weiterverarbeitung und Analyse der Ergebnisse.

5.2 Segmentgeometrien als Berechnungsgrundlage von Landschaftsstrukturmaßen

Zur Bewertung der Landschaft wird in der Landschaftsökologie das Konzept der Landschaftsstrukturmaße *(landscape metrics)* angewendet. Unter dem Untersuchungsgegenstand Landschaft verstehen die Begründer dieser Forschungsrichtung FORMAN & GODRON (1986) ein Mosaik interagierender Ökosysteme, wobei die Analyse von strukturellen, funktionalen sowie dynamischen Beziehungen und Prozessen zwischen den Landschaftseinheiten im Mittelpunkt stehen. Die Grundlage hierfür stellt das *Patch-Corridor-Matrix*-Konzept dar, wonach sich Landschaften aus kleinsten Einheiten (Ökotopen, so genannten *patches)* und linearen Elementen *(corridors)* in der umgebenden Grundstruktur des Landschaftsausschnittes *(matrix)* zusammensetzen (vgl. ebd.; FORMAN 1995). Landschaftsstrukturmaße quantifizieren die räumliche Konfiguration dieser kleinsten Landschaftselemente, d. h. deren Anordnung, Struktur bzw. Verteilungsmuster *(landscape pattern)*. Dabei werden meist mehrere Indizes benötigt, um Form, Größe, Kompaktheit, Isoliertheit oder Verbund der *patches* zu beschreiben.

Als Gründe für eine Analyse der landschaftlichen Muster und Strukturen nennen TURNER et al. (2001):

- die Erfassung des Landschaftswandels über die Zeit;
- die Vergleichbarkeit von Entwicklungen verschiedener Landschaften;
- die Analyse von Planungsvarianten oder Szenarios sowie
- die Wirkungsanalyse des Landschaftswandels auf die Umwelt (z. B. Nährstoffverlagerungen, Migrationsprozesse).

Als Anwendungsmöglichkeiten der quantitativ-räumlichen Landschaftsanalyse mittels Landschaftsstrukturmaßen ergeben sich z. B. die Untersuchung von:

- Fragmentierung, Isolation und Konnektivität, z. B. zur Untersuchung von Biotopverbünden;
- Anordnung bestimmter Flächen, Ausprägung von Mustern (Diversität, Heterogenität, Homogenität);
- Abstände zwischen zwei bestimmten Flächentypen oder zwischen den einzelnen Flächen einer Klasse oder
- Kombinationen solcher Analysen mit Informationen über einzelne Landschaftskomponenten (z. B. Bodenarten, Geologie, Hangneigung), Landschaftsfunktionen oder sozioökonomischen Daten.

Derartige Untersuchungen können unterstützend in die Landschaftsplanung, die Landschaftsbeobachtung (Monitoring), den Naturschutz oder den Artenschutz einfließen (vgl. BLASCHKE 2000b; WALZ 2001).

Die den Analysen zugrunde liegenden *patches* sollen je nach Erfassungs- und Betrachtungsmaßstab weitgehend homogen sein (vgl. FORMAN & GODRON 1986; FORMAN 1995; TURNER & GARDNER 1991). Die Abgrenzung homogener Landschaftseinheiten (in Bezug auf Landbedeckung bzw. -nutzung) ist gleichzeitig Ziel der Bildsegmentierung. Vor diesem Hintergrund wurde untersucht, inwiefern sich segmentbasierte Auswertungsverfahren zur diskreten, konsistenten und nachvollziehbaren Abgrenzung landschaftsökologisch bedeutsamer Einheiten anhand sehr hoch auflösender Satellitenbilddaten nutzen lassen (vgl. BLASCHKE 2001; NEUBERT & BLASCHKE 2004). Hierzu wurde wiederum die Software eCognition verwendet. Der Vorteil dieser Vorgehensweise liegt in einer weitgehenden Automatisierung des Prozesses gegenüber einer visuellen Interpretation.

Als Merkmale zur Klassifikation der abgegrenzten Landschaftseinheiten (Segmente) stehen in eCognition programmintern vielfältige Merkmale zur Verfügung, unter denen sich auch Landschaftsstrukturmaße (z. B. *Shape*-Index) oder verwandte Indizes befinden. Zusätzliche Berechnungen (z. B. komplexere Landschaftsstrukturmaße) sind einfach durch nutzerdefinierbare Merkmale integrierbar. Die einzelnen Segmentmerkmale werden unmittelbar bei der Segmentierung berechnet. Von großem Vorteil ist das Prinzip mehrerer Ebenen (multiskalige Segmentierung), da auch in der Landschaftsökologie mehrere Skalen betrachtet werden. Die semantischen Beziehungen zwischen den Segmenten in unterschiedlichen Ebenen (Relationen zu übergeordneten Super- bzw. untergeordneten Subsegmenten) lassen sich zur Klassifikation nutzen.

NEUBERT & BLASCHKE (2004) erläuterten den Einsatz von Landschaftsstrukturanalysen basierend auf einer segmentbasierten Auswertung von Fernerkundungsdaten anhand mehrerer Beispiele.

Für ein Monitoring der Verbuschung von Weidelandschaften – wobei unterschiedliche Verbuschungssgrade im Mittelpunkt des Interesses standen – wurden Luftbilder auf zwei Ebenen segmentiert. Die feiner abgegrenzte Ebene repräsentierte Einzelelemente der Landschaft bis hin zu Einzelbüschen, soweit sie auf dem Luftbild abgrenzbar waren. Auf diese Weise wurde für die übergeordneten, generalisierten Einheiten (Wiesen, Weiden oder relativ homogene Teile davon – entsprechend ihrer Textur und Farbgebung im CIR-Orthophoto) eine *„within-patch diversity"* auf Basis der Heterogenität der Unterobjekte ermittelt (vgl. BLASCHKE 2001). Statt einer bloßen statistischen Betrachtung der Farbwerte konnte so die Differenzierung der Unterobjekte (Wiesen- oder Weidenstücke sowie Büsche, Gehölzgruppen, Einzelbäume etc.) analysiert werden.

Eine ähnlich gelagerte Verbuschungs- und Austrocknungsproblematik war Gegenstand von Untersuchungen in Moorgebieten und führte zu weitergehenden Monitoringansätzen basierend auf Objektveränderungen (vgl. LANG & LANGANKE 2004). Identifizierte Einzelelemente stehen über Vererbungs- und Nachbarschaftsregeln sowohl ‚horizontal' („grenzt an", „ist umgeben von", „ist in der Nähe von" etc.) als auch ‚vertikal' („ist Element von", „besteht aus") in räumlicher Beziehung. Auf diese Weise kann ‚Textur' operationalisiert werden, nicht nur über die Varianz der Farbwerte innerhalb einer Fläche, sondern zusätzlich über eine Analyse der Superobjekt-Subobjekt-Beziehungen. Die qualitative Unterscheidung der *matrix* (in diesem Falle das intakte Moor) und der *patches* (die eindringenden Gehölzgruppen) konnte erfolgreich nicht nur kartographisch dargestellt, sondern auch quantifiziert werden.

In beiden vorgestellten Fallstudien werden Merkmale zur Klassifikation verwendet, die einfache Landschaftsstrukturmaße widerspiegeln. Über die spektralen Eigenschaften hinaus werden Informationen über Formen, Größen und Verteilungen von Objekten genutzt, um größere Flächen zu charakterisieren. Dies ist derzeit technisch nur auf Basis einer Segmentierung von Bilddaten möglich. Versuche mit *moving-window*-Verfahren, die bestimmte Arten von Textur gut charakterisieren, waren sowohl im Falle der verbuschenden Weideflächen als auch zur Charakterisierung der Moorgebiete nicht zielführend (BLASCHKE et al. 2001; BURNETT et al. 2003).

Über gute Erfahrungen mit der Berechnung von Landschaftsstrukturmaßen auf Basis der Segmentgeometrien vor dem Hintergrund der Erfassung der Landschaftsdiversität wurden von IVITS & KOCH (2003) berichtet. Hervorgehoben wurde dabei die reproduzierbare Abgrenzung von Landschaftseinheiten im Rahmen einer Segmentierung im Vergleich zu stark subjektiven Grenzen durch eine visuelle Interpretation. Damit bietet die Segmentierung eine stabilere Grundlage für die Objektabgrenzung. Die durch die Autorinnen präsentierten Klassifikationsergebnisse von QuickBird- und Luftbilddaten besitzen eine Güte von 97,5 % und 99,4 % (bei einer groben Klassifikation mit vier Klassen) bzw. 90 % und 96,3 % (bei einer detaillierten Klassifikation mit sieben Klassen). Eine Diskriminanzanalyse lieferte zuvor die zur Klassifikation geeigneten Merkmalskombinationen. Insbesondere die Nutzung der durch eCognition bereitgestellten *Cooccurrence*-Texturwerte hat sich als sehr nützlich erwiesen.

Im Rahmen dieser Dissertation war eine gegenüberstellende Berechnung von Landschaftsstrukturmaßen auf Basis der Klassifikationsergebnisse (vgl. Abschnitt 6.4) und der originalen Biotop- und Nutzungstypenkartierung vorgesehen, um eventuelle zeitliche Entwicklungen zu zeigen. Aufgrund der unterschiedlichen zugrunde liegenden Geometrien (Lagefehler der BNTK; Klassifikationsunterschiede, wie nicht- bzw. flächenhaft kartierte Straßen; visuelle Generalisierung durch Bearbeiter der BNTK etc.) sind die Ergebnisse jedoch kaum vergleichbar. Tabelle 5.3 verdeutlicht diese Problematik, indem die Ergebnisse verschiedener Landschaftsmaßberechnungen beispielhaft anhand eines Objektes verglichen werden. Zwei Segmentierungsergebnisse – eine ungeglättete (rasterbasierte) sowie eine geglättete Abgrenzung – und das aus der BNTK entnommene Pendant wurden dabei verwendet.

Tab. 5.3: Vergleich von Berechnungsergebnissen auf Basis eines BNTK-Objektes sowie jeweils eines ungeglätteten und geglätteten segmentierten Objektes.
(Quelle: Eigene Darstellung)

	Objekt aus BNTK	Segmentiertes Objekt auf Rasterbasis (1 m Rasterweite)	Segmentiertes Objekt, geglättet mit eCognition-Exportoption[1]
Graphische Darstellung		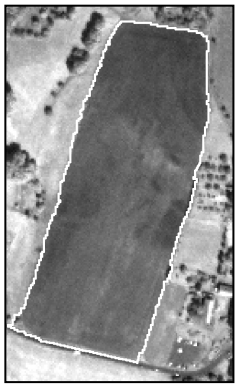	
Größe [m²]	64 070	59 606	59 597
Umfang [m]	1 078	1 360	1 188
Anzahl Stützpunkte	22	397	209
Shape-Index	1,201	1,571	1,373
Perimeter-Area-Ratio	0,017	0,023	0,020
Fraktale Dimension	1,262	1,312	1,288

[1] Gewählte Polygonisierungsoptionen: Base und Shape Polygon Schwellwert = 5.

Die Ergebnisse der Berechnungen unterscheiden sich aufgrund der vielfältigen Einflüsse signifikant voneinander. Die graphische Darstellung zeigt die teils deutlichen Lageabweichungen der Objekte in der BNTK. Die Erfassungsgüte dieser Einheiten ist insbesondere vom Aufnahmemaßstab abhängig. Ebenso kann die Segmentierung Fehler aufweisen. Da sie sich an den Rastergrenzen orientiert, wird sie zudem durch die Pixelgröße beeinflusst. Die digitalisierten BNTK-Objekte haben wesentlich weniger Stützpunkte, als die segmentierten Objekte. Sie sind dadurch deutlich ‚glatter' und dies beeinflusst auch die Ergebnisse der Landschaftsmaßberechnungen erheblich. Das derzeit in eCognition implementierte Glättungsverfahren führt zwar zu einer besseren, aber noch nicht zu einer idealen Berechnungsgrundlage für Landschaftsmaße. Insgesamt stellt sich die Frage, durch welche Form der Abgrenzung sich „realistischere" Objekte erzielen lassen.

Die existierende Vielzahl an Landschaftsstrukturmaßen kann zum Problem werden. Nach wie vor gibt es wenige Beispiele direkter Übertragbarkeit und Vergleichbarkeit. Zudem befindet sich die Anwendung strukturbeschreibender Indizes methodisch noch in einem Entwicklungsstadium (vgl. BLASCHKE 2000b). Auf methodische Interpretationsprobleme von Landschaftsstrukturmaßen soll an dieser Stelle nicht vertiefend eingegangen werden. Darüber hinaus existieren Probleme der Datenabhängigkeit (z. B. Raster vs. Vektor) oder Korrelation der einzelnen Maße und Berechnungsunterschiede in unterschiedlichen Softwareprogrammen (HARGIS et al. 1998; BLASCHKE 2000b).

„The expected proliferation of highly detailed and ‚realistic' maps of cities from high spatial resolution satellite imagery has not as yet materialized. The reasons may be more methological, alluding to conceptual, rather than technical factors."

VICTOR MESSEV (2003)

6 Automatisierte Aktualisierung digitaler Datensätze – Beispiel Biotop- und Nutzungstypenkartierung

6.1 Einführung

Der Bedarf an aktuellen Bestandsdaten zur Landnutzung für verschiedenste Planungs- und -evaluierungsaufgaben wächst stetig. Neben den Daten des Amtlichen Topographisch-Kartographischen Informationssystems (ATKIS) stellt die Biotop- und Nutzungstypenkartierung (BNTK) eine insbesondere im Bereich Naturschutz und Landschaftsplanung wichtige und häufig genutzte Datenbasis dar (vgl. KENNEWEG et al. 2000), die für einige Bundesländer flächendeckend existiert. Sie wurde im vergleichsweise großen Maßstab von 1 : 10 000 durch visuelle Interpretation analoger CIR-Luftbilder erstellt. Vor-Ort-Kartierungen wurden nur in Einzelfällen herangezogen, ansonsten nur zur selektiven Biotopkartierung angewandt. Die Erfassung und Überwachung von Biotopen ist unter anderem bedeutsam für nationale Naturschutzziele (§ 24a Bundesnaturschutzgesetz) sowie internationale Vereinbarungen (z. B. FFH-Monitoring im Rahmen von Natura 2000, Richtlinie 92/43/EWG).

Die BNTK kann aufgrund ihres Alters und den aus der Erhebungsmethodik resultierenden Fehlern häufig nicht mehr als zuverlässige Datengrundlage gelten. Für das untersuchte Gebiet in der Vorderen Sächsischen Schweiz, welches Teil des Nationalparks „Sächsische Schweiz" ist, hatten die BNTK-Daten einen Stand von 1992/93. Die Fortführung dieser Daten ist dringend erforderlich, steht jedoch für die hierfür zuständigen Umweltbehörden (in Sachsen: Sächsisches Landesamt für Umwelt und Geologie) bei Finanzknappheit infrage. Zudem enthält die Biotop- und Nutzungstypenkartierung geometrische und inhaltliche Fehler (nicht, ungenau oder falsch klassifizierte Elemente; vgl. SLFUG 2001). Insbesondere zeigt sich der subjektive Einfluss unterschiedlicher Bearbeiter. Ziel muss es daher sein, die Genauigkeit zu erhöhen und die Subjektivität zu minimieren. Eine weitestgehend automatisierte Fortschreibung ist anzustreben, um eine kosteneffiziente Operationalisierung sowie eine Vereinfachung der bisherigen Erhebungsmethodik zu erreichen.

Die rasant fortschreitende Entwicklung im Bereich der Fernerkundung (insbesondere der Sensorkonstruktion) sowie der Bildverarbeitung eröffnet neue Möglichkeiten zum Einsatz von effizienten und automatisierten Methoden zur Kartierung bzw. Aktualisierung von Biotop- und Nutzungstypen. Durch neue, sehr hoch auflösende Satellitensensoren mit 0,5 bis 1 m Bodenauflösung stehen digitale Bilddaten zur Verfügung, die den Maßstabsbereich der ursprünglich zur Kartierung der BNTK verwendeten analogen Luftbilder annähernd erreichen und damit für eine Aktualisierung herangezogen werden können. Daneben kommt höchstauflösenden digitalen Luftbildkameras mit einer Auflösung unter 0,5 m ein großes Potenzial für diese Aufgabe zu. In diesem Kapitel wird daher eine Methode der segmentbasierten Klassifikation von IKONOS-Satellitenbilddaten zur Erstellung bzw. Aktualisierung der BNTK erläutert und über die dabei gewonnenen Erkenntnisse berichtet (vgl. NEUBERT & MEINEL 2002; SEILER 2003; SEILER, NEUBERT & MEINEL 2004). Darüber hinaus wurde die Übertragung des Verfahrens auf gescannte Farbinfrarot-Luftbilder (CIR-Luftbilder) untersucht.

6.2 Automatisierte Aktualisierung von GIS-Daten – Stand der Forschung

Die Automatisierung zeit-, personal- und kostenaufwändiger Aktualisierungsprozesse digitaler Daten wird in den letzten Jahren verstärkt untersucht, bisher allerdings ohne operationelle Methoden zur Verfügung zu stellen. Im Folgenden werden einige aktuelle Arbeiten genannt.

Eine Methode zur Aktualisierung von Gebäuden in Karten oder GIS-Daten basierend auf einem *change-detection*-Verfahren stellten MATIKAINEN, HYYPPÄ & KAARTINEN (2004) vor. Dabei wurden Laserscannerdaten und Luftbilddaten segmentbasiert ausgewertet, 88 % aller Gebäude wurden auf diese Weise korrekt detektiert.

HOLLAND & MARSHALL (2004) gaben an, das IKONOS-Daten für eine topographische Kartierung im Maßstab 1 : 10 000 bis 1 : 50 000 geeignet sind. Mit QuickBird-Daten ist eine Aufnahme bis zu 1 : 6 000 möglich. Die Daten sind jedoch ungeeignet für die von der Britischen Vermessungsverwaltung bearbeiteten Maßstäbe von 1 : 2 500 bis 1 : 1 250. Viele in diesem Maßstabsbereich wichtige Objekte lassen sich aus den Bilddaten nicht erkennen. Daher können z. B. QuickBird-Daten nur als Zusatzinformation bei der Kartenaktualisierung dienen.

Ein *per-parcel*-Verfahren zur Aktualisierung von ATKIS-Daten wurde von WALTER (2004) vorgestellt. Basierend auf digitalen Luftbilddaten (DMC), daraus abgeleiteten Textur- (GLCM) und Spektralparametern (NDVI) sowie einem Laserscanner-Höhenmodell wurde überprüft, ob die in den ATKIS-Daten enthaltenen Objekte der Klassen Wohngebiete und Industrieflächen korrekt klassifiziert sind. Durch das verwendete *change-detection*-Verfahren wurden 7 % der Objekte als potenzielle Veränderungsflächen markiert. Lediglich diese Flächen müssen durch einen Bearbeiter nun manuell überprüft werden.

WALTER (2004) plädiert darüber hinaus für die Nutzung von *per-parcel*-Verfahren zur Aktualisierung von GIS-Datensätzen. Segmentbasierte Techniken sind nach Meinung des Autors insbesondere zur Ersterfassung von GIS-Daten geeignet, da die Bildsegmentierung keine Objekte existierender GIS-Daten einbezieht. Entgegen dieser Darstellung können vorhandene GIS-Daten zur Strukturierung von Bilddaten im Rahmen der Segmentierung eingesetzt werden (vgl. Abschnitte 4.1.1 und 5.1 ff.). Unabdingbare Voraussetzung ist jedoch generell das Vorhandensein eines lageidentischen Datensatzes. Bei der Anwendung von *per-parcel*-Verfahren ist zu beachten, dass sich dabei die Nachteile pixelbasierter Auswertungsverfahren auswirken können (vgl. Abschnitt 2.2.2.4). Insbesondere lassen sich durch dieses Vorgehen keine Veränderungen an der Geometrie der vorhandenen Objekte durchführen.

Ein ähnliches Verfahren zur Aktualisierung von ATKIS-Daten auf Basis von Ortholuftbildern wird von BUSCH et al. (2004) dargestellt. Dabei wird das bereits in Abschnitt 2.2.4 beschriebene *per-parcel*-basierte Expertensystem geoAIDA genutzt (vgl. BÜCKNER et al. 2002). Das Verfahren wird ergänzt um ein Linienerkennungsverfahren zur Klassifikation von Straßen.

Auch die Aktualisierung der BNTK ist bereits Untersuchungensgegenstand. Anforderungen hierfür wurden teilweise durch verschiedene zuständige Landesbehörden geäußert. Die Zukunft der BNTK liegt demnach in der Nutzung digitaler Luftbilddaten. Begründet wird dies mit der benötigten sehr hohen Bodenauflösung von 20 cm (CIR) und dem mit einem klassischen Luftbild vergleichbaren Handling. Vorreiter ist das Bundesland Sachsen-Anhalt, wo 2004 bereits die Auftragsausschreibung für eine flächendeckende Befliegung im Jahr 2005 erfolgte. Diese Entscheidung verdeutlicht den Trend zur Verwendung digitaler Datengrundlagen. Eine weitere Aktualisierung ist alle fünf bis zehn Jahre geplant. Die Auswertung soll visuell geschehen, da zum jetzigen Zeitpunkt noch keine Methodik zur automatischen Bildauswer-

tung existiert, die den Ansprüchen an die Ergebnisse der BNTK-Auswertungen gerecht wird (vgl. LANGE 2004).

Gute Erfahrungen bei der Erstellung bzw. Aktualisierung der Biotoptypenkartierung wurden mit HRSC-Flugzeugscannerdaten gemacht. Diese Daten haben eine flughöhenabhängige Bodenauflösung von bis zu 10 cm, was für Anwendungen im Maßstab 1 : 10 000 bereits zu detailliert ist. Die Nutzung von HRSC-A-Daten ist nicht problemfrei, da sich unterschiedliche Blickwinkel der einzelnen Kanäle negativ auf die Bildqualität auswirken – dieser Nachteil wurde beim weiterentwickelten Kameranachfolger HRSC-AX verringert. Zudem entstehen infolge der hohen Auflösung immense Datenmengen. Aufgrund der sehr hohen Datenkosten und der nicht operationellen Beschaffungsmöglichkeiten ist die Verwendung dieses Bildmaterials mit Einschränkungen verbunden.

Ein pixelbasiertes Verfahren zur Biotoptypenklassifikation auf Basis von HRSC-A- bzw. -AX-Daten wurde von GÄHLER et al. (2002) bzw. GÄHLER & JANOWSKI (2003) entwickelt. In einem mehrstufigen Prozess aus Schwellwertverfahren, Maskenbildung, überwachter und unüberwachter Klassifikation erfolgte die Differenzierung der einzelnen Biotoptypen. Wichtige Datengrundlage war das aus den Sterreobildkanälen berechnete Höhenmodell. Mit dem Verfahren wurde eine hohe Übereinstimmung gegenüber einer manuellen Auswertung erreicht.

Mit verschiedenen automatisierten Auswerteverfahren untersuchte LESER (2002) die Erstellung von Biotoptypenkartierungen basierend auf HRSC-A-Daten. Die Überprüfung der Klassifikationsgüte ergab 71 % für eine pixelbasierte ML-Klassifizierung (zehn thematische Klassen) bzw. 79 % für eine ISODATA-Clusteranalyse (neun Klassen). Eine Güteprüfung der segmentbasierten Auswertung (eCognition, zwölf Klassen) fehlt zwar, wird aber visuell als gut bewertet. Daneben wurden die Bilddaten auch visuell ausgewertet und das Resultat als gut eingeschätzt. Zu bemerken ist allerdings, dass im Rahmen dieser Arbeit nur eine frühe Beta-Version eingesetzt wurde, die viele der heute realisierten Programmfunktionen noch nicht enthielt.

Daneben wird derzeit in mehreren Projekten untersucht, inwiefern sich sehr hoch auflösende Satellitenbilddaten für die Kartierung von Biotopen oder FFH-Lebensraumtypen eignen (vgl. z. B. SELL, GRUBINGER & EISL 2004; LUFTBILD UND PLANUNG 2004).

Für die Aktualisierung von BNTK-Daten für einen Teil der südkoreanischen Stadt Seoul nutzten KLEINSCHMIT & KIM (2004) panchromatisch geschärfte IKONOS-Daten. Zunächst wurden die Geometrie sowie Attributierungsfehler durch eine visuelle Interpretation korrigiert. Daneben wurde eine gefilterte, pixelbasierte ML-Klassifikation zur Trennung von Vegetation, Nicht-Vegetation und Schattenflächen durchgeführt, die jedoch Fehlklassifikationen (z. B. durch Kippeffekte von Hochhäusern) enthält. Die so entstandenen Datensätze waren Grundlage einer segmentbasierten Auswertung, wobei lediglich der Grünflächenanteil innerhalb der durch die BNTK-Daten vorgegebenen Objektgrenzen ermittelt wurde. Darüber hinaus wäre die Bestimmung von Lage und Verteilung der Vegetationsflächen für Planungszwecke möglich gewesen. Das Ergebnis wird gegenüber der durch Vermessung erstellten Originalkartierung als objektiver angesehen und erlaubt eine genauere Bestimmung der Grünflächenanteile.

Frühere Untersuchungen unter Verwendung geringer aufgelöster Satellitendaten stellten sich dagegen als nicht zielführend heraus, wie z. B. KENNEWEG et al. (2000) für die BNTK oder SCHLÜTER (2000) für ATKIS-Daten am Beispiel von IRS-Daten zeigten.

6.3 Die Biotop- und Nutzungstypenkartierung

6.3.1 Erstellung und Eigenschaften der BNTK-Daten

In Sachsen erfolgte 1992/1993 eine flächendeckende CIR-Luftbildbefliegung mit dem Ziel, die Naturraumausstattung (Biotoptypen) und die reale Landnutzung zu erfassen. In den Folgejahren wurden die ca. 16 000 Luftbilder interpretiert und liegen seit Ende 2000 als kompletter digitaler Vektordatensatz vor (vgl. FRIETSCH 2001). Eine vergleichbare Kartierung existiert in allen neuen Bundesländern sowie in Schleswig-Holstein, Niedersachsen und Baden-Württemberg.

Etwa 240 unterschiedliche Biotop- und Landnutzungstypen wurden im Rahmen der Interpretation unterschieden. Sie wurden in acht Hauptgruppen und etwa 40 Untergruppen gegliedert. Jeder Kartiereinheit wurde ein achtstelliger Zahlencode zugewiesen, wobei die ersten fünf Stellen den Biotoptyp (Haupt- und Untergruppe) bzw. Bestand und die weiteren drei Ziffern die Ausprägung, Nutzung und Sekundärnutzung bezeichnen, sofern diese Merkmale interpretierbar waren (siehe Tabelle 6.1).

Zur Erstellung der Biotop- und Nutzungstypenkartierung wurden die analogen CIR-Luftbilder visuell interpretiert (vgl. z. B. FRIETSCH 2001). Die manuelle Abgrenzung und Klassifikation der Kartiereinheiten erfolgte basierend auf einer stereoskopischen Erfassung von Objekthöhen, Farbunterschieden, Strukturen und Texturen, dem Erkennen von räumlichen Zusammenhängen und insbesondere der Erfahrung des Bildinterpreten. Die Einordnung in die entsprechenden Objektklassen erfolgte nach einem für Sachsen entwickelten Interpretationsschlüssel (vgl. SLFUG 1994).

6.3.2 Bewertung des Interpretationsverfahrens sowie der Datengrundlage

Die gewählte Form der Auswertung ist sehr aufwändig und birgt ein hohes Maß an Subjektivität. Neben inhaltlichen Fehlinterpretationen und Ungenauigkeiten, welche infolge des großen zu bearbeitenden Gebietes teilweise aus der Vielzahl der Interpreten resultieren, sind die Ergebnisse nicht vollständig nachvollziehbar und reproduzierbar. Die zahlreichen manuellen Bearbeitungsschritte (Abgrenzung der Biotop- und Nutzungstypen, mehrmaliges Übertragen auf Folien, anschließende Digitalisierung usw.) stellen potenzielle Fehlerquellen dar.

Die der Originalkartierung zugrunde liegenden photographischen Filmaufnahmen erfolgten in Zentralprojektion. Neben den dadurch bedingten Verzerrungen an den Bildrändern führen unterschiedliche Geländehöhen zu teils erheblichen geometrischen Lageungenauigkeiten.

Tab. 6.1: Struktur des achtstelligen BNTK-Zahlencodes anhand eines Beispiels. (Quelle: Eigene Darstellung in Anlehnung an SCHERFKE 2001)

Hauptgruppe	Untergruppe	Bestand/ Biotoptyp	Ausprägung	Sekundär-nutzung	Sonder-nutzung	
2	1	2 0 0	4	1	7	Beispielcode
2						Gewässer
	1					Fließgewässer
		2 0 0				Bach
			4			Mit Gehölzsaum
				1		naturnah
					7	trockengefallen

Als Referenzkarte wurde in Sachsen die Topographische Karte 1 : 10 000, DDR-Ausgabe Volkswirtschaft, verwendet (vgl. SCHERFKE 2001), die gegenüber der Normalausgabe teilweise geometrisch verzerrt und inhaltlich verändert ist. Durch die Verwendung derartiger, veralteter oder fehlerhafter Referenzkarten, aus denen im Luftbild nicht erkennbare Informationen zum Teil übernommen wurden (z. B. administrative Grenzen; im Wald liegende Quellbereiche, Straßen oder Gewässerläufe), wurden Abweichungen teilweise verstärkt.

Durch eine Entzerrung gescannter Originalluftbilder unter Berücksichtigung der Reliefform (Orthorektifizierung) können lagegenaue digitale Orthophotos mit einheitlichem Abbildungsmaßstab hergestellt werden. Eine Orthorektifizierung wurde jedoch im Rahmen der Biotop- und Nutzungstypenkartierung in den 90er Jahren aus technischen bzw. Kostengründen nicht durchgeführt, wodurch Lageungenauigkeiten des Bildmaterials in die Kartierung einflossen. Auch erfolgte damals keine unmittelbare Bildschirm-Digitalisierung, wodurch weitere Genauigkeitsverluste hinzunehmen waren.

Die Verwendung von orthorektifizierten, digitalen Bilddaten zur visuellen Interpretation direkt am Bildschirm *(on-screen)* reduziert die zahlreichen manuellen Bearbeitungsschritte und die daraus resultierenden Fehlerquellen (insbesondere die Lagegenauigkeit; vgl. LESER 2002). Die Geometrien der interpretierten Biotop- und Nutzungstypen können direkt auf den Bilddaten digitalisiert und die dazugehörigen Attribute in entsprechenden Tabellen abgelegt werden. Selbst eine computergestützte stereoskopische Auswertung ist bei einer üblichen Befliegung mit 60 % Längs- und 30 % Querüberdeckung möglich. Das hohe Maß an Subjektivität bleibt jedoch auch bei diesem Verfahren bestehen.

Der Vorteil heute üblicher digitaler Luftbildkameras liegt in der gleichzeitigen Aufnahme panchromatischer und multispektraler Datensätze (RGB, NIR). Einige Kamerasysteme ermöglichen die Aufnahme von Stereobilddaten zur Berechnung eines digitalen Höhenmodells oder zeichnen diese durch zusätzlich vorhandene Laserscanner simultan auf. Dies führt zu einer zusätzlichen informativen Datenebene und zu einer Steigerung der Lagegenauigkeit der verarbeiteten Daten. Der Anwendungsmaßstab derartiger Bilddaten liegt zwischen 1 : 500 bis 1 : 2 000. Sie verbinden damit die hohe geometrische Auflösung analoger Luftbilder mit der hohen radiometrischen und spektralen Auflösung digitaler Aufnahmesysteme (vgl. Abschnitt 3.1.3) und eignen sich somit als Datengrundlage für die Erstellung einer BNTK.

Im Gegensatz zu flugzeuggestützten Aufnahmen liefern Erdbeobachtungssatelliten kontinuierlich Bilddaten. Satellitenbilder besitzen darüber hinaus den Vorteil der größeren Gebietsabdeckung, sodass häufig geringere Kosten pro Fläche anfallen. Das Bildprodukt liegt von vornherein digital vor und ermöglicht eine rasche Weiterverarbeitung. Die neue Generation sehr hoch auflösender Satellitensensoren liefert Bilddaten, deren Anwendungsmaßstab von 1 : 5 000 bis 1 : 25 000 bisher dem Luftbild vorbehalten war. Sie vereinen die Vorteile der Satellitenfernerkundung (rasche Verfügbarkeit, hohe Wiederholrate, Vergleichbarkeit der Daten) mit denen von Ortholuftbildern (geringe geometrische Verzerrungen im Falle einer Orthorektifizierung). Außerdem ermöglichen sie die parallele Erstellung von digitalen Oberflächenmodellen bei vorliegenden Stereoaufnahmen. Heute stehen mehrere Systeme zur Verfügung, deren Bilddaten sich zur Erstellung der BNTK grundsätzlich eignen.

6.3.3 Beurteilung der Datenqualität

Als Fehlerarten innerhalb der BNTK nennen KENNEWEG et al. (2000) im Rahmen einer Untersuchung eines Gebietes im Harz folgende Varianten:

- Interpretationsfehler (falsche Klassenzuweisung), die insbesondere in Grünlandbereichen auftreten können (Intensivgrünlandflächen, welche großblättrige Ampferarten oder Brennnesseln aufweisen, werden häufig fälschlicherweise als Feuchtgrünland interpretiert);

- Digitalisierungsfehler (ungenaue Grenzlinien/Ränder, falsche Lage, falsche Flächengröße), die z. B. im Vergleich zur Topographischen Karte oder zum Ortholuftbild auffallen (siehe Abbildung 3.8);
- Generalisierung, besonders von Waldflächen (fehlende Unterscheidung von Beständen) oder Siedlungsflächen (unterschiedliche Siedlungstypen werden nicht ausreichend voneinander abgegrenzt);
- Labelfehler (falsche Codierung), die teilweise bei der Baumartenbestimmung in Waldgebieten auftreten (z. B. Klassifizierung von Erle statt Eiche; vgl. KENNEWEG et al. 2000).

BASTIAN & SCHREIBER (1999) gehen aufgrund der unmöglichen oder schweren Erkennbarkeit einiger Biotoptypen von einer Fehlerquote von 3-10 % der Gesamtfläche aus. Die Zuordnung aufgrund von physiognomischen Eigenschaften und nicht nach biologischen bzw. ökologischen Aspekten birgt zusätzliche Interpretationsunsicherheit. Daneben weisen die Autoren darauf hin, dass infolge von anthropogenen – und in weitaus geringerem Maße auch natürlichen – Landschaftsveränderungen die Kartierung rasch veraltet. Bei der Verwendung der BNTK-Daten ist daher eine Überprüfung zum heutigen Ist-Zustand notwendig.

Das Sächsische Landesamt für Umwelt und Geologie als Urheber der Daten hat die Genauigkeit anhand repräsentativer Beispielgebiete (1,5 % der Landesfläche) evaluiert. Demnach führen die unterschiedlichen Fehlerquellen auf der Ebene der Hauptgruppen zu einer Gesamtfehlerquote von unter 5 %. Eine Ausnahme bildet die Hauptgruppe Moore und Sümpfe, bei der ein Fehler von 14,1 % ermittelt wurde. Da diese Objektarten nur einen geringen Flächenanteil aufweisen, ist dieser Fehler weniger relevant. Auf der Ebene der Untergruppen treten Abweichungen von bis zu 20 % auf, die in Einzelfällen, wie z. B. bei Einzelbäumen in einigen Gebieten bis zu 50 % betragen. Die Ergebnisse bieten somit nur im Bereich der Hauptgruppen eine zuverlässige Informationsgrundlage. Bei differenzierteren Analysen sind die entsprechenden Fehlerquoten zu berücksichtigen und besonders bei Bearbeitungsmaßstäben größer 1 : 25 000 sollten die Angaben im Gelände überprüft werden (SCHERFKE 2001).

6.4 Segmentbasierte Biotop- und Nutzungstypenklassifikation anhand von IKONOS-Daten

Im Rahmen dieser Untersuchung wurde die von NEUBERT & MEINEL (2002a) entwickelte Methodik zur Erfassung der BNTK auf Basis von IKONOS-Satellitendaten praktisch erprobt. Das Verfahren wurde bereits durch SEILER (2003) angewendet und nun mit der eCognition-Programmversion 3.0 umgesetzt. Der verwendete Bildausschnitt umfasst die östliche Hälfte der IKONOS-Szene der Vorderen Sächsischen Schweiz unter Ausschluss der stark atmosphärisch beeinflussten Bereiche im Süden (vgl. Abschnitt 3.1.2). Das Gebiet ist Bestandteil des Nationalparks Sächsische Schweiz und ist gekennzeichnet durch eine Vielzahl natürlicher und naturnaher Biotop- und Nutzungstypen. Die Größe des Untersuchungsgebietes (37,1 km²) entspricht etwa der Fläche einer Topographischen Karte 1 : 10 000. Im Mittelpunkt stand die Ermittlung der erreichbaren thematischen Tiefe einer segmentbasierten Klassifikationsmethodik. Darüber hinaus wurden die Ergebnisse mit der originalen BNTK verglichen und qualitativ bewertet. Die Übertragbarkeit der erarbeiteten Methodik auf einen benachbarten Bildausschnitt und die damit verbundene Automatisierbarkeit der Bearbeitungsschritte sind ebenfalls betrachtet worden.

6.4.1 Vorüberlegungen

Im Rahmen der Untersuchung musste zunächst entschieden werden, ob eine Aktualisierung der vorhandenen Daten oder eine Neuerfassung des BNTK-Inventars durchgeführt werden soll. Gegen eine Aktualisierung sprachen einerseits geometrische Abweichungen. Andererseits führen eine visuelle Interpretation und eine automatisierte Bildauswertung zu deutlichen inhaltlichen Unterschieden. Die Originalkartierung unterlag der Subjektivität der Bearbeiter und ist trotz eines vorgegebenen Interpretationschlüssels nicht durchweg nachvollziehbar und reproduzierbar. Zudem wurden Inhalte der BNTK aus Zusatzdaten (Topographische Karte) übernommen. Diese zumeist funktional definierten Landnutzungsklassen lassen sich in Fernerkundungs-Bildmaterial nicht erkennen. Aufgrund dieser inhaltlichen Differenzen fiel die Entscheidung für eine Neuerfassung.

Ein Methodenvergleich von manuell-stereoskopischer und automatisiert-segmentbasierter Luftbildauswertung von CIR-Luftbilddaten wurde von LANGANKE et al. (2004) durchgeführt. Durch die visuelle Interpretation können die Biotoptypen auf hohem Aggregationsniveau mit sehr guter Qualität erfasst werden. Der Arbeitsaufwand wächst signifikant an, wenn es sich um kleinräumige oder sehr detaillierte Zielklassen handelt. Ebenso wird die Subjektivität bei der Abgrenzung der Kartiereinheiten deutlich. Das segmentbasierte Verfahren zeigt seine Stärken bei der Bearbeitung kleinteiliger Einheiten sowie in der objektiven Klassendefinition auf Basis physikalisch erfasster Merkmale. Von Vorteil ist darüber hinaus die Arbeit auf mehreren Segmentierungsstufen, ergo Aggregationsebenen. Problematisch ist hingegen die Abgrenzung stark aggregierter, spektral inhomogener Klassen (z. B. Gärten, Obstplantagen). Einen Ausweg sehen die Autoren in einer Kombination beider Verfahren: Der Abgrenzung durch eine Segmentierung und der anschließenden manuellen Attributierung. Sehr komplex ist die Implementierung von Expertenwissen in Klassifikationsregeln und deren Feinabstimmung. Zu vergleichbaren Ergebnissen kommen auch BRÖCKER (2003) sowie LANG et al. (2003; siehe Abschnitt 6.5).

Speziell mit der automatisierten Fortführung von Biotop- und Nutzungstypenkartierungen beschäftige sich LESER (2002). Als Anforderungen an eine operationelle Methodik zur fernerkundlichen Biotopkartierung werden darin folgende Punkte genannt:

- zuverlässige Abgrenzung und Klassifikation der Kartiereinheiten;
- weitgehende Übertragbarkeit der Klassifikationsabläufe auf Folgekartierungen;
- weitgehende Automatisierbarkeit des Verfahrens und damit Verringerung der Subjektivität der Bearbeiter;
- weitgehender Verzicht auf Expertenwissen (vgl. LESER 2002).

Problematisch ist insbesondere die fehlende Standardisierung der Kartiereinheiten. In den betreffenden Bundesländern existieren eigene Erfassungsvorschriften, obwohl es eine bundeseinheitliche Vorgabe gibt (vgl. BFN 1995, 2002b), die jedoch erschien, nachdem einzelne Kartierungen bereits im Gange oder abgeschlossen waren.

Daneben ist die Standardisierung des Bildmaterials von großer Wichtigkeit, also weitestgehend gleichartige spektrale Eigenschaften sowie eine einheitliche Bodenauflösung. Die ursprünglich verwendeten CIR-Luftbilder enthielten vielfältige radiometrische Verzerrungen durch unterschiedliche Aufnahmezeitpunkte (wechselnde Sonnenstände), Einflüsse durch Geländeunebenheiten, atmosphärische Einflüsse, richtungsabhängige Transmissionsgrade der Sensoroptik sowie variierende und nichtlineare Detektorempfindlichkeit (vgl. KRAUS 1990; LESER 2002). Diese Einflüsse sollten weitestmöglich ausgeschlossen werden, sind in der Praxis jedoch nur näherungsweise durch radiometrische Rektifizierung zu eliminieren. Die Konstanz der Grauwerte ist jedoch Grundvoraussetzung zur Übertragbarkeit und Ver-

gleichbarkeit und damit zur Automatisierung. Da insgesamt keine Vergleichbarkeit möglich ist, wird die Anpassung grauwertabhängiger Größen nötig (vgl. Abschnitt 3.2.2).

6.4.2 Methodisches Vorgehen

Zur Auswertung mittels der Bildanalysesoftware eCognition 3.0 wurden orthorektifizierte IKONOS-Daten der Vorderen Sächsischen Schweiz verwendet. Die Vorverarbeitungsschritte wurden bereits in den Abschnitten 3.2.1 und 3.2.3 erläutert. Es ist zu beachten, dass das Aufnahmedatum 01.08.2000 nicht ideal für eine Biotopkartierung ist. Normalerweise werden Bilddaten hierfür zu Begin der Vegetationsperiode (Mai/Juni) aufgenommen.

Um den Detailgehalt der panchromatischen Daten sowie die Farbinformationen der Multispektraldaten (Fusionsprodukt) nutzen zu können, wurden beide Datenquellen verwendet. Vorhergehende Untersuchungen bezüglich der Segmentierung mit eCognition zeigten darüber hinaus, dass mit dieser Datenkombination die besten Ergebnisse erzielt werden. Zusätzlich wurden ein Vegetationsindex (NDVI) einbezogen, der wertvolle Informationen zur Klassifikation unterschiedlicher Vegetationstypen lieferte. Das integrierte Laserscanner-Höhenmodell wurde zum Ausschluss bestimmter Merkmalskombinationen benutzt (z. B. Eisenbahn nur unter bestimmter Höhenlage). Die passgenauen ATKIS-Daten wurden zur Unterstützung der Segmentierung eingesetzt. Die Vorgehensweise ist in Abbildung 6.1 schematisch dargestellt. Die einzelnen Schritte werden im Folgenden näher erläutert.

6.4.2.1 Eignungsbewertung der IKONOS-Daten

Vor Bearbeitungsbeginn war zunächst eine Bewertung des IKONOS-Bildmaterials bezüglich visueller Erkennbarkeit (Identifizierbarkeit), Segmentierbarkeit (automatisierte Abgrenzbarkeit) sowie Klassifizierbarkeit (hinreichend genaue Merkmalsunterscheidung gegenüber anderen Klassen) der zu extrahierenden Biotop- und Nutzungstypen nötig (siehe Tabelle 6.2).

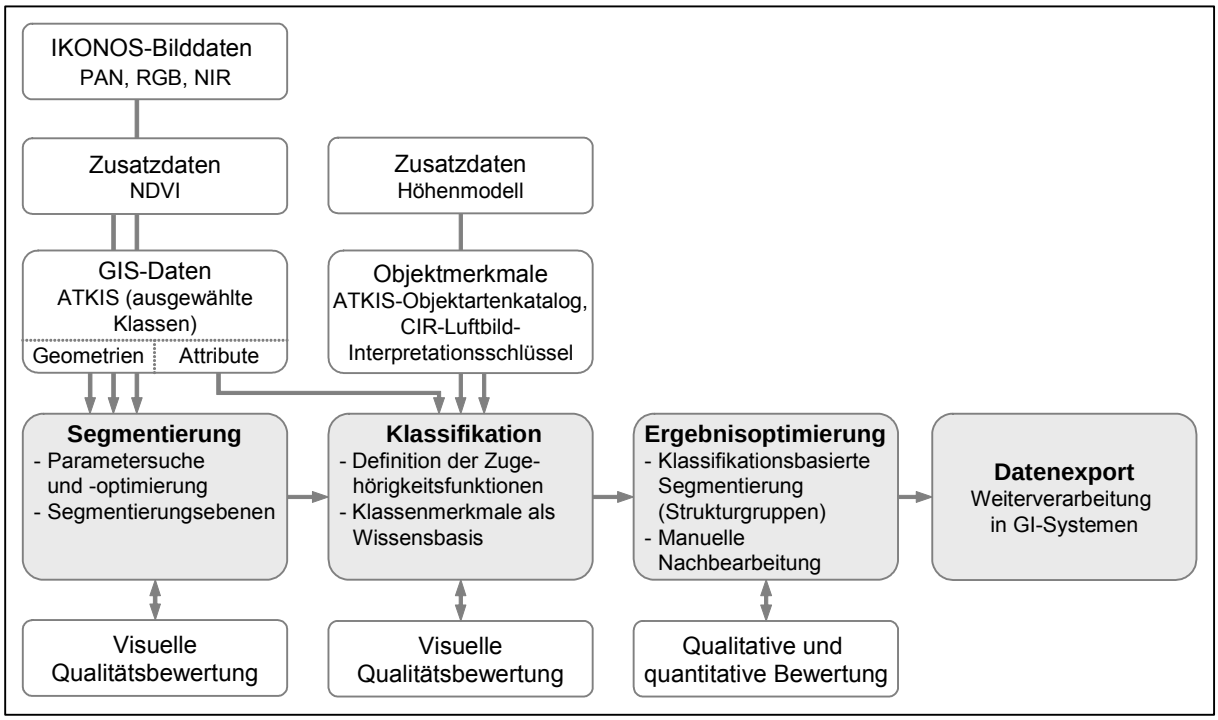

Abb. 6.1: Ablaufschema zur Erfassung von Biotop- und Nutzungstypen aus IKONOS-Daten mittels eCognition. (Quelle: Eigene Bearbeitung)

Tab. 6.2: Bewertung der IKONOS-Daten bezüglich der visuellen Erkennbarkeit der sächsischen Biotoptypen und ihrer Segmentier- sowie Klassifizierbarkeit (+ gut; o bedingt; - nicht eindeutig). (Quelle: Eigene Bearbeitung)

HG	UG	Bestand/ Biotoptyp	Bezeichnung	Merkmale, *Probleme*	Visuelle Erkennbarkeit	Segmentierbarkeit	Klassifizierbarkeit
2 Gewässer	21 Fließgewässer	100	Quellbereich	In BNTK aus Zusatzdaten übernommen	-	-	-
		200	Bach	Breite 5 bis 10 m, *Überdeckung*	o	o	-
		300	Graben	Breite 5 bis 10 m, Geradlinigkeit, *Überdeckung, Unterscheidung zu Bächen*	o	-	-
		400	Fluss	Breite > 5 bis 10 m	+	+	+
		500	Kanal	Breite > 5 bis 10 m, Geradlinigkeit, *Unterscheidung zu Flüssen*	+	+	o
	23 Stillgewässer	100	Tümpel	Temporäres, naturnahes Kleingewässer, wenige m² groß, *Überdeckung*	o	o	-
		200	Kleingewässer	Größe < 1 ha, *Überdeckung*	o	o	-
		300	Teich	Anthropogen entstanden, Verlandungsvegetation, *Unterscheidung zu Seen*	+	+	o
		400	Staugewässer	*Nur wenn Stauwerk erkennbar von See zu unterscheiden*	o	o	-
		600	Altwasser	Stehendes, meist mäanderförmiges Gewässer in der Nähe von Flüssen, *Unterscheidung zu anderen Stillgewässern*	+	o	-
		700	See	Natürlich entstanden, *Unterscheidung zu Teich*	+	+	o
	24		Gewässerbegleitende Vegetation	Undifferenzierte Erfassung möglich, Nähe zum Gewässer, *Artenunterscheidung nicht möglich*	+	+	o
3 Moore, Sümpfe	31		Hochmoor, Übergangsmoor	*Keine Angaben möglich, da nicht im Gebiet vorkommend*			
	32		Niedermoor, Sumpf	*Keine Angaben möglich, da nicht im Gebiet vorkommend*			
4 Grünland, Ruderalflur	41		Wirtschaftsgrünland	Flächengröße, homogene Textur (Mahdstreifen), *Artendifferenzierung (z. B. in mesophiles Grünland, Saatgrasland, Feuchtgrünland) nicht möglich*	+	+	+
	42		Ruderalflur, Staudenflur	Z. T. erkennbar als Wiese oder Gehölze, krautige Vegetation auf anthropogen beeinflussten Standorten (Bahndamm, Schuttplatz), Saumgesellschaften an Waldrändern und Gebüschen, büschelartige Textur, *meist nicht unterscheidbar von anderen Grünlandbereichen*	o	o	-
5 Magerrasen, Felsfluren, Zwergstrauchheiden	51		Anstehender Fels	*Verwechslung mit Blockschutthalden möglich, Überdeckung*	o	o	o
	52		Blockschutthalde	*Verwechslung mit Fels möglich, Überdeckung*	o	o	o
	53		größere Lesesteinhaufen und Steinrücken	*Keine Angaben möglich, da nicht im Gebiet vorkommend*			
	54		Offene Flächen	Vegetationslos, nicht versiegelt	+	+	o
	55		Zwergstrauchheiden und Borstgrasrasen	Trockene Grasfluren, saure Standorte, einzelne Bäume, *Verwechslung mit Heiden und Magerrasen möglich*	o	o	o
	56		Magerrasen trockener Standorte	Grasfluren auf trockenen, basenreichen Standorten (Vitalität gering)	o	o	o
6	61		Feldgehölz / Baumgruppe	Umgeben von Acker/Wiese, *Artenunterscheidung nicht möglich*	+	+	+
	62		Baumreihe	Linearität, *Artenunterscheidung nicht möglich*	+	+	+

(Fortsetzung auf der nächsten Seite)

6 Baumgruppen, Hecken, Gebüsche	63		Allee	Linearität, Nähe zur Strasse/ Weg, *Artenunterscheidung nicht möglich*	+	+	+
	64		Einzelbaum, Solitär	*Artenunterscheidung nicht möglich, Verwechslung mit Baumgruppen möglich*	+	o	o
	65		Hecke	Linearität, *Verwechslung mit Baumreihen möglich*	+	o	o
	66		Gebüsch	A*rtenunterscheidung nicht möglich, Verwechslung mit Baumgruppen*	+	o	o
7 Wälder und Forsten	71		Laubbaumart	A*rtenunterscheidung nicht möglich*	+	+	+
	72		Nadelbaumart	A*rtenunterscheidung nicht möglich*	+	+	+
	73		Laub-Nadel-Mischwald	Max. 90% Laubholz, *Mischbestandteile nicht direkt erkennbar,* A*rtenunterscheidung nicht möglich*	o	o	+
	74		Nadel-Laub-Mischwald	Max. 90% Nadelholz, *Mischbestandteile nicht direkt erkennbar, Artenunterscheidung nicht möglich*	o	o	+
	75		Laubmischwald	Min. 90% Laubholz, *Mischbestandteile nicht direkt erkennbar, Artenunterscheidung nicht möglich*	o	o	+
	76		Nadelmischwald	Min. 90% Nadelholz, *Mischbestandteile nicht direkt erkennbar, Artenunterscheidung nicht möglich*	o	o	+
	77		Feuchtwald	Nicht unterscheidbar	o	-	-
	78		Waldrandbereich/Vorwald	Z. T. erkennbar, junges Sukzessionsstadium, keine Pflanzreihenstruktur, A*rtenunterscheidung nicht möglich*	o	o	-
	79		Wiederaufforstung	Erkennbar an Struktur und Schlagschatten, A*rtenunterscheidung nicht möglich*	+	o	-
8 Acker[1]	81		Acker	Unterscheidung von Arten z. T. möglich	+	+	+
	82		Sonderkulturen	*Keine Angaben möglich, da nicht im Gebiet vorkommend*			
9 Siedlung, Infrastruktur, Grünflächen	91		Wohngebiet	Erkennbar als Bebauung, *Funktion nicht ableitbar*	+	o	o
	92		Mischgebiet	Erkennbar als Bebauung, *Funktion nicht ableitbar*	+	o	o
	93		Gewerbegebiet/ technische Infrastruktur	Erkennbar als Bebauung, *Funktion nicht ableitbar*	+	o	o
	94 Grün-/Freiflächen	100	Parkanlage	Urbane Grünfläche	+	+	o
		200	Sport- und Freizeitanlagen	Vielfältig, *Funktion nicht ableitbar (Bad, Sportplatz, Tennisanlage, etc.)*	+	+	o
		400	Kleingartenanlage	Regelmäßige Struktur von Wegen und kleinen Gebäuden	+	+	o
		500	Friedhof	*Verwechslung mit Parkanlage, Kleingärten*	o	o	o
	95 Verkehrsflächen	100	Straße	*Überdeckung, Beschattung*	+	o	o
		130	Wirtschaftsweg	*Überdeckung, Beschattung*	+	o	o
		200	Platz	*Überdeckung, Verwechslung mit Straße möglich*	+	+	o
		300	Bahnanlage	*Beschattung*	+	+	+
		500	Hafenanlage/ Hafenbecken	*Funktion nicht direkt ableitbar*	+	+	o
		600	Verkehrsbegleitgrün	Nähe zu Straße/Weg, *Unterscheidung zwischen Bäumen, Sträuchern und Wiese schwierig*	+	+	o
	96 Sonderflächen[2]	100-200	Bauflächen, Lagerflächen	*I. d. R. nur kurzfristig vorhanden, Erfassung daher fraglich*	+	+	o
		300-340	Aufschüttungen/ Altablagerungen, Halde	Nicht direkt erkennbar, z. T. bewachsen	o	o	o
		410-440	Abgrabung, Tagebau	Detailliert erkennbar mit Halde, Gebäuden und Ablassbecken	+	+	-

[1] Acker und Sonderstandorte. [2] Sonderflächen anthropogen genutzt.

Diese Untersuchung ist jedoch unvollständig, da mit dem vorhandenen Bildmaterial das Spektrum der Biotope nicht komplett abgedeckt werden konnte. Insgesamt lassen sich nahezu alle Biotop- und Nutzungstypen visuell in den Bilddaten identifizieren, viele davon auch segmentieren und klassifizieren. Probleme treten lediglich bei Klassen mit fließenden Übergängen auf.

6.4.2.2 Verwendung von Zusatzdaten

Die Verwendung topographischer und thematischer Zusatzdaten im Rahmen einer spektralen Klassifikation ist sinnvoll und wird von vielen Autoren befürwortet (vgl. ALBERTZ 2001; HILDEBRANDT 1996). Aus den ATKIS-Daten wurden daher die Geometrien einiger Klassen übernommen. Die Nutzung derartiger Zusatzdaten zur Segmentierung ist nur zweckmäßig, wenn diese hinreichend lagegenau sind und sich die Kartiereinheiten auch in den Bilddaten identifizieren lassen, was im vorliegenden Fall gegeben war.

Da auch ATKIS-Daten nicht fehlerfrei sind, sollten sie nicht ungeprüft verwendet werden. Zu beachten ist in jedem Fall die Aktualität der Daten. Zudem sollten nur Geometrien langzeitstabiler Nutzungen übertragen werden. Die Nutzung der ATKIS-Daten geschah unter anderem vor dem Hintergrund, dass die ATKIS-Daten ursprünglich als Basisgeometrie für aufbauende Fachdaten – also auch der BNTK – geplant waren.

Gemäß den in den ATKIS-Daten enthaltenen Angaben (Breite der Fahrbahn/des Verkehrsweges) wurden die Flächen für Straßen (3101), Wege (3102) und Bahnflächen (3201) durch Pufferung erstellt. Das Straßen- und Wegenetz ist insbesondere durch unterschiedliche Fahrbahnbeläge sowie Baumüberdeckung nur unter Verwendung aktueller und geometrisch genauer thematischer Zusatzdaten zuverlässig erfassbar. Das Gleiche trifft für die Siedlungsgrenzen zu, da sie funktionaler Natur und somit nicht in den Bilddaten erkennbar sind. Die Siedlungsgrenzen wurden durch die Zusammenfassung der ATKIS-Klassen Fläche besonderer funktionaler Prägung (2114), Fläche gemischter Nutzung (2113), Industrie und Gewerbe (2112), Wohnbaufläche (2111), Sportanlagen (2201), Friedhof (2213) sowie Gartenland (4103) erreicht. Auch in der Original-BNTK wurden einige Informationen aus topographischen Karten übernommen und nicht visuell aus den Luftbilddaten ermittelt.

Die Geometrien der originalen BNTK wurden dagegen aufgrund der geometrischen Ungenauigkeiten nicht verwendet. Dennoch besteht zwischen den ATKIS- und den BNTK-Daten eine gewisse Ähnlichkeit der Geometrien, was mit einer ähnlichen Aktualität sowie den teilweise aus der TK10 übernommenen Informationen der Biotopkartierung erklärt werden kann. In den Flächengeometrien der BNTK sind jedoch deutlich weniger Wege und Straßen enthalten, die in natura aber häufig grenzbildend sind (insb. in Waldgebieten). Somit sind in dieser Kartierung viele der klassifizierten Flächen nicht nachvollziehbar, da die Wege etc. als grenzbildende Objekte fehlen oder nicht konsequent als Grenze berücksichtigt wurden. Dies ist wahrscheinlich eine Folge der getrennten Haltung von Linien- und Flächengeometrien. Dagegen bilden Linienelemente in ATKIS zwingend Polygongrenzen (einheitliche Geometrie).

6.4.2.3 Segmentierungsstrategie

Zur Auswahl geeigneter Segmentierungsparameter sowie zweckmäßiger Kombinationen der Eingangsdaten wurden verschiedene Tests durchgeführt, um optimale Ergebnisse zu erreichen (vgl. SEILER 2003). Segmentiert wurde daraufhin auf fünf Ebenen, beginnend mit kleinen Segmenten, die durch das implementierte *Region-Merge*-Verfahren zu größeren Segmenten verschmolzen wurden. Während bei der Parameterwahl der Schwerpunkt anfangs auf den Spektralinformationen lag (starke Farbgewichtung), wurde in den höheren

Ebenen dem Formparameter mehr Gewicht zugemessen, um glattrandigere Segmentgrenzen zu erhalten. Tabelle 6.3 zeigt für die einzelnen Segmentierungsebenen die jeweils verwendeten Eingangsdaten, die genutzten Parameter und das angestrebte Klassifikationsziel.

Bedingt durch die Vielfalt der Einflussfaktoren auf die Segmentierung (z. B. Bildinhalt, Kontrast und Größe der zu extrahierenden Objekte) lassen sich keine allgemeingültigen Parameter festlegen, sodass diese iterativ für jedes Gebiet neu zu ermitteln und vor einer Klassifikation visuell zu überprüfen sind. Damit bleiben die Segmentierung und Klassifikation von Bilddaten mit eCognition Aufgaben mit hohen Anforderungen an den Bearbeiter.

Die lagerichtigen ATKIS-Geometrien der o. g. Klassen wurden zur Segmentierung genutzt. Zu beachten ist, dass die Grenzen thematischer Daten in eCognition als zwingende Segmentgrenzen übernommen werden. Um die ATKIS-Grenzen generell zu bewahren, wurden diese in allen Segmentierungsebenen übernommen. So konnten z. B. Wege und Straßen, die in Waldgebieten häufig schlecht extrahierbar sind, als vordefinierte Segmente genutzt werden.

6.4.2.4 Klassifikationsstrategie

Die Wissensbasis (Entscheidungsbaum), welche die Objektmerkmale zur Klassifikation enthält, wurde ausgehend von Ebene 5 bis Ebene 1 mittels Zugehörigkeitsfunktionen manuell erstellt. Dieses sehr aufwändige Verfahren wurde zur Verfeinerung der Ergebnisse um Zugehörigkeitsfunktionen ergänzt, die anhand ausgewählter Testflächen *(samples)* automatisch generiert werden und sich anschließend editieren lassen *(Sample Editor: Generate Membership funtions > Compute* bzw. *Edit/Insert;* siehe Abbildung 6.2).

Die Auswahl der Klassenbeschreibungen aus den umfangreich zur Verfügung stehenden Merkmalen ist frei wählbar. Über eine selbst definierte Verteilungskurve wird die Zugehörigkeit eines Objektmerkmales zu einem spezifischen Wertebereich formuliert (Zugehörigkeitsfunktion). Das *fuzzy-logic*-Prinzip erlaubt die Festlegung unscharfer Klassenmerkmale sowie die gleichzeitige Zuordnung zu mehreren Klassen, wobei jedem Objekt die Klasse mit der höchsten Wahrscheinlichkeit zugewiesen wird.

Tab. 6.3: Verwendete Eingangsdaten, Parametereinstellungen sowie angestrebtes Klassifikationsziel für die einzelnen Segmentierungsebenen.
(Quelle: SEILER 2003, verändert)

Ebene	Zur Segmentierung genutzte Daten[1]	Scale-Faktor	Gewichtung von Farbe vs. Form	Gewichtung von Kompaktheit vs. Linienglätte	Klassifikationsziel
1	RGB, NIR, NDVI, PAN, ATKIS	30	0,9 vs. 0,1	0,5 vs. 0,5	Erfassung von Kleinstrukturen wie Baumgruppen, Parkplätzen, Gebäuden; Unterscheidung von Laub- und Nadelwald etc.
2	RGB, NIR, NDVI, PAN, ATKIS	50	0,9 vs. 0,1	0,5 vs. 0,5	
3	RGB, NIR, NDVI, PAN, ATKIS	100	0,8 vs. 0,2	0,5 vs. 0,5	Fusionsebene, integriert Informationen der Ebene 1 und 2 in den Hauptnutzungsklassen
4	RGB, NIR, NDVI, PAN, ATKIS	150	0,8 vs. 0,2	0,5 vs. 0,5	Hauptnutzungsklassen (Grünland, Wald, Acker, Siedlung, Gewässer)
5	RGB, NIR, NDVI, PAN, ATKIS	200	0,8 vs. 0,2	0,5 vs. 0,5	Große, homogene Flächen wie Acker und Fluss

[1] RGB = Kanäle Rot, Grün, Blau; NIR = naher Infrarotkanal; NDVI = *Normalized Difference Vegetation Index*; PAN = panchromatischer Kanal; ATKIS = Straßen, Wege, Bahnflächen, Siedlungsgrenzen.

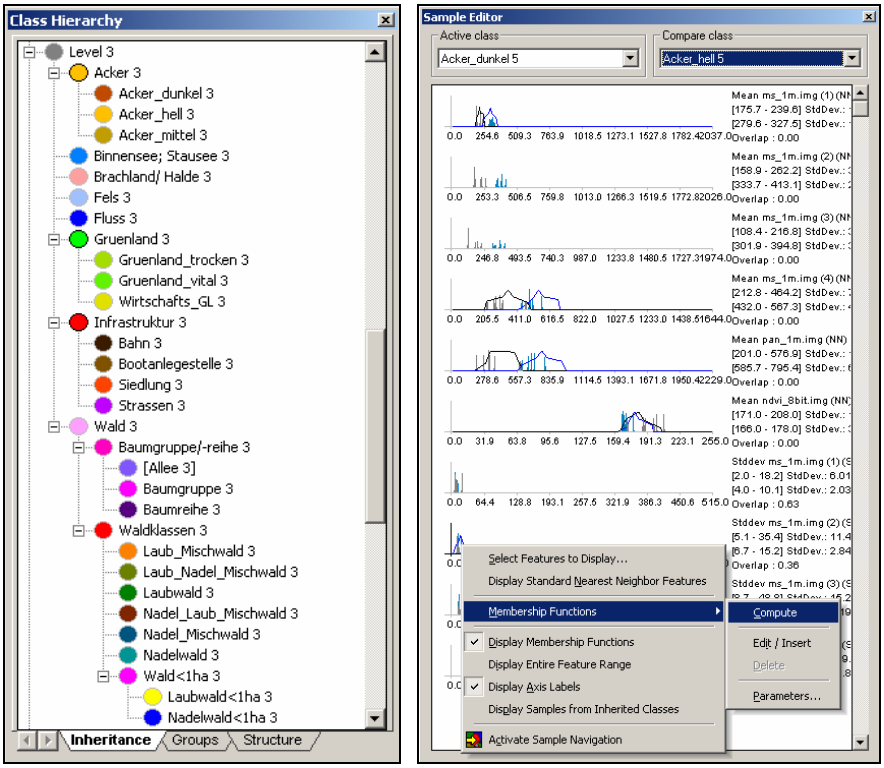

Abb. 6.2: Erstellter Entscheidungsbaum für die Ebene 3 (links) und Möglichkeit der automatischen Erstellung von Zugehörigkeitsfunktionen anhand ausgewählter Testflächen mit dem *Sample Editor* (rechts). (Quelle: Eigene Bearbeitung; Screenshots der eCognition Software)

Hilfreich bei der Erstellung des Entscheidungsbaumes waren die Angaben in den BNTK-Kartieranleitungen sowie im ATKIS-Objektartenkatalog (z. B. Flächengröße zur Unterscheidung Baumgruppe vs. Wald). Diese Hinweise können zum Teil als Merkmal der jeweiligen Klasse zusätzlich zu deren spektralen Eigenschaften formuliert werden.

Ausgehend von den großflächigen, homogenen Segmenten der Ebenen 5 und 4 wurden zunächst die Hauptnutzungsklassen Acker, Wald, Grünland, Gewässer, Siedlung und Verkehr entsprechend der CIR-Hauptgruppen klassifiziert. Darauf aufbauend wurden diese Klassen in den Ebenen 3, 2 und 1 weiter differenziert. Unter Verwendung des NDVI und des panchromatischen Kanals diente Ebene 2 zur Differenzierung von Laub- und Nadelwald. Beide Waldklassen wurden zur weiteren Klassifikation in die BNTK-Waldklassen auf Ebene 3 übertragen. In Ebene 1 erfolgte die Klassifikation der Siedlungsbereiche in Bebauung, Grünfläche und Bäume.

Die Klassifikation mittels Zugehörigkeitsfunktionen muss iterativ wiederholt werden. Nach jeder Änderung einer Zugehörigkeitsfunktion muss das Klassifikationsergebnis zunächst visuell überprüft und die Funktion gegebenenfalls erneut angepasst werden. Durch das Bilden neuer Klassen und das Verändern der Zuweisungsfunktionen werden allmählich alle Segmente eines Bildes verschiedenen Klassen zugeordnet.

Die aus ATKIS abgeleiteten thematischen Zusatzdaten wurden anhand ihrer Attribute klassifiziert. Die so importierten Geometrien wurden auf Veränderungen hin geprüft (z. B. Straßenneubauten, Verschiebungen der Siedlungsgrenzen). Neu gebaute Straßen können im Rahmen der Klassifikation erfasst werden. Eine derartige Prüfung sollte generell selbst bei quasistabilen Klassen stattfinden.

Die Hauptnutzungsklassen Acker und Grünland wurden wegen ihrer stark variierenden Spektraleigenschaften, die z. B. aus unterschiedlichen Artenzusammensetzungen oder Reifestadien resultieren, in Unterklassen, wie vitales und trockenes Grünland, differenziert. Eine

Oberklasse Grünland hätte einen sehr großen heterogenen Merkmalsraum beschrieben und z. B. Teile der Klasse Wald umfasst.

Als fehlerhaft bzw. nicht klassifizierbar erwiesen sich Bildbereiche, die von Wolken, Dunst und Wolkenschatten beeinflusst waren (ca. 3 % des Untersuchungsgebietes). In diesem Fall wurden die Flächen manuell den entsprechenden Klassen zugewiesen. Die Segmente umfassten aber mitunter mehrere Objektklassen, sodass eine manuelle Zuweisung nicht immer eindeutig erfolgen konnte.

Der Schwerpunkt der Bildanalyse lag gebietsbedingt in der Klassifikation der verschiedenen BNTK-Walduntergruppen (71 bis 79), deren Unterscheidung sich aus den Anteilen von Laub- und Nadelbaumbeständen ergibt. Die Hauptgruppe Wald wurde in der dritten Ebene entsprechend der in Ebene 2 ermittelten Laub- und Nadelbaumanteile in sechs Untergruppen differenziert. So besteht die Untergruppe Nadel-Laub-Mischwald beispielsweise aus maximal 90 % Nadelwald und weniger als 50 % Laubwald (vgl. BFN 2002: 120 ff.). Derart komplexe Klassifikationsregeln lassen sich mittels *fuzzy logic* gut umsetzen. Als Mindestflächengröße wurden die eindeutigen Angaben im ATKIS-Objektartenkatalog von 0,1 ha (vgl. ADV 2002, Objektart 4107) verwendet. Die nach der Klassifikation verbleibenden Restflächen mit einer Größe unter 0,1 ha wurden nach einer Zusammenfassung gleich klassifizierter, benachbarter Segmente *(classification based segmentation)* ihren angrenzenden Flächen schrittweise zugeordnet (z. B. Restfläche Laubwald mit der Klasse Laub-Nadel-Mischwald). So können zunächst übersegmentierte Flächen, wie sie in Waldgebieten häufig auftreten, durch deren Zusammenfassung optimiert werden. Neben den Walduntergruppen konnten weitere BNTK-Untergruppen, wie z. B. Baumgruppen und -reihen klassifiziert werden. Darüber hinaus war die Klassifikation von Aufforstungsflächen anhand deren Textur weitgehend möglich.

Die Fusion gleich klassifizierter, benachbarter Segmente wurde neben den Waldflächen auch für weitere Klassen angewendet. Dieses Vorgehen ist empfehlenswert, da die Objektanzahl verringert (z. B. Ebene 2 um fast 50 %), der Speicherbedarf gesenkt und gleichzeitig der visuelle Gesamteindruck verbessert werden kann (siehe Tabelle 6.4; vgl. Abschnitt 4.1.2). So war die Zerlegung großer Ackerflächen in mehrere kleine Segmente zunächst für die Klassifikation notwendig, um eingeschlossene Kleinstrukturen (z. B. Baumgruppen) erfassen zu können. Die Ackerflächen wurden dadurch jedoch aufgelöst und die visuelle Wahrnehmung der Gesamtfläche erschwert. Eine Objektfusion ist daher für die weitere Arbeit vorteilhaft. Zu beachten ist, dass sich infolge der Objektfusion neben der Objektgröße auch die Merkmalswerte ändern, wodurch sich auch die Klassenzugehörigkeit verschieben kann. Das Fusionsergebnis ist durch eine erneute Klassifikation sofort zu überprüfen und gegebenenfalls sind die Zugehörigkeitsfunktionen zu verändern. In den jeweiligen Ebenen wurden daher nur die Klassen zur Objektfusion verwendet, in denen eine nachträgliche Änderung der Zugehörigkeitsfunktion nicht nötig wurde.

Tab. 6.4: Zur Objektfusion ausgewählte Klassen sowie Objektzahl (gerundet) vor und nach ihrer Fusion. (Quelle: SEILER 2003, verändert)

Ebene	Zur Objektfusion verwendete Klassen	Objektanzahl vor Fusion	Objektanzahl nach Fusion
1	Bebauung, Grünfläche, Straßen	179 800	167 450
2	Acker mittel, Acker dunkel, Fluss, Siedlung, Straßen	73 300	36 890
3	Acker mittel, Acker dunkel, Fluss, Siedlung, Wald-Unterklassen (6 Klassen), Straßen	23 400	15 660
4	Acker mittel, Acker dunkel, Fluss, Siedlung, Wald, Straßen	14 350	11 100
5	Acker mittel, Acker dunkel, Fluss, Siedlung, Straßen	11 100	10 260

6.4.3 Bewertung der Ergebnisse

Das Klassifikationsergebnis zeigt die aus den aktuellen IKONOS-Bilddaten abgeleiteten Biotop- und Nutzungstypen. Dieser Datensatz muss manuell nachbearbeitet werden, um die Genauigkeit zu erhöhen (z. B. Zusammenfassung von Flächen, Generalisierung). Eine Veränderungsanalyse ist nach einem Export der Polygone ins Shape-Format einfach mit einem GIS möglich.

Die Qualität des Klassifikationsergebnisses wird im Wesentlichen von einer erfolgreichen Segmentierung bestimmt, d. h. wie gut die gebildeten Segmente die realen Objekte voneinander abgrenzen. Aus Mangel quantitativer Evaluierungsmöglichkeiten (vgl. Abschnitt 4.3) konnte die Segmentierung nur visuell überprüft werden.

Segmentierungsfehler sind hauptsächlich auf die breite Streuung der Reflexionswerte innerhalb eines Objekttyps zurückzuführen. Die Hauptgründe dafür liegen in der Geländemorphologie und den daraus resultierenden Sonnen- und Schattenbereichen sowie den atmosphärischen Einflüssen durch Wolkenbedeckung, -schatten und Dunst im Bildmaterial. Für Vegetationsflächen kommt die durch variierende Standortfaktoren hervorgerufene, natürliche Vielfalt ihrer Erscheinung hinzu (z. B. trockene und feuchte Wiesenbereiche). Die Qualität der Segmentierung war sehr gut, wenn kontrastreiche Übergänge oder farblich sehr homogene Objekte vorlagen. Daneben traten aber auch unerwünschte Segmentierungseffekte (Fehlsegmentierungen) auf, die sich zumeist in nicht sinnvoll abgegrenzten, stark ausgedehnten Segmenten äußerten (insb. Grenzsäume, Wald; siehe Abbildung 6.3).

Die qualitative Bewertung des Klassifikationsergebnisses erfolgte mittels des in ERDAS IMAGINE 8.6 verfügbaren Güte-Kontrollverfahrens *accuracy assessment*. Aus dem Originalsatellitenbild wurde dabei die tatsächliche Klassenzugehörigkeit für 50 zufällig gesetzte Kontrollpunkte je Klasse durch visuelle Interpretation ermittelt. Die durchschnittliche Klassifikationsgüte beträgt demnach 91,3 % auf Ebene der Hauptgruppen (sechs Klassen, siehe Tabelle 6.5), wobei das Ergebnis von atmosphärisch stark beeinträchtigten Bildbereichen (Dunst, Wolken) nachteilig beeinflusst wurde. Eine atmosphärische Korrektur des Bildmaterials sollte daher als Vorverarbeitungsschritt einer Bildauswertung zu einem wesentlichen Bestandteil künftiger Arbeiten werden. Zum Zeitpunkt der Bearbeitung waren entsprechende Programme jedoch noch nicht verfügbar (vgl. Abschnitt 3.2.2).

Abb. 6.3: Beispiele für unerwünschte Segmentierungseffekte (rot abgegrenzte Segmente). (Quelle: Eigene Bearbeitung)

Tab. 6.5: Ergebnisse der Güteprüfung auf Ebene der BNTK-Hauptgruppen. (Quelle: Eigene Bearbeitung)

Hauptgruppe	Flächen-anteil [%]	Erken-nungs-güte [%]	Klassifi-kations-güte [%]	Gründe für Abweichungen
2 Gewässer	2,3	98,0	96,0	Fehler an Gewässerrändern
4 Grünland, Ruderalflur	25,1	92,2	94,0	Verwechslung mit Acker
5 Magerrasen, Felsflur, Zwergstrauchheide	1,0	84,0	84,0	Kleinteilige offene Flächen im Acker (Errosionsflächen), Fehlklassifikation von Bewölkung als Brachfläche
6 Baumgruppe, Hecke, Gebüsch	0,5	87,8	86,0	Verwechslung mit Wald
7 Wald, Forst	43,4	90,2	92,0	Verwechslung mit Baumgruppen
8 Acker, Sonderstandort	15,8	94,1	96,0	Fehler an Ackerrändern
Andere Biotop- und Nutzungstypen[1]	11,7	-	-	
Gesamt	**100,0**	**91,3**		

[1] Nicht geprüft, da aus ATKIS übernommen (Straßen, Wege, Bahnflächen, Siedlungsgrenzen) bzw. unklassifiziert.

Insgesamt kann das Ergebnis auf Ebene der Hauptgruppen als gut bis sehr gut bewertet werden. Eine Klassifikationsgüte über 90 % erreichen die Klassen Gewässer, Grünland, Wälder sowie Acker. Etwas geringer ist die Güte von Magerrasen (84 %) und Baumgruppen (86 %). Diese Klassen nehmen allerdings nur einen sehr geringen Flächenanteil ein. Die Gründe der Abweichungen sind in Tabelle 6.5 enthalten. Eine statistische Gegenüberstellung mit den Flächen und -anteilen der BNTK wird in Tabelle 6.6 gegeben. Das Klassifikationsergebnis ist für einen Ausschnitt des Testgebietes in Abbildung 6.4 dargestellt.

Tab. 6.6: Statistischer Vergleich der Ergebnisse auf Hauptgruppenebene mit der BNTK. (Quelle: Eigene Bearbeitung)

Hauptgruppe	Segmentbasierte Klassifikation		BNTK		Differenz	
	Fläche [ha]	Flächen-anteil [%]	Fläche [ha]	Flächen-anteil [%]	Fläche [ha]	Flächen-anteil [%]
2 Gewässer	87,0	2,3	111,2	3,0	-24,2	-0,7
3 Moor, Sumpf	0,0	0,0	0,3	0,0	-0,3	0,0
4 Grünland, Ruderalflur	931,1	25,1	853,9	23,0	77,3	2,1
5 Magerrasen, Felsflur, Zwergstrauchheide	36,3	1,0	103,7	2,8	-67,4	-1,8
6 Baumgruppe, Hecke, Gebüsch	20,0	0,5	15,7	0,4	4,3	0,1
7 Wald, Forst	1 610,2	43,4	1 470,9	39,7	139,3	3,7
8 Acker, Sonderstandort	587,9	15,8	734,8	19,8	-146,9	-4,0
9 Siedlung, Infrastruktur, Grünfläche	342,2	9,2	414,0	11,2	-71,8	-1,9
Unklassifizierte Fläche	5,1	0,1	4,8	0,1	0,4	0,0
Straße, Weg[1]	77,6	2,1	-	-	77,6	2,1
Bahnfläche[1]	11,8	0,3	-	-	11,8	0,3
Summe	**3 709,3**	**100,0**	**3 709,3**	**100,0**	**-**	**-**

[1] Straßen, Wege und Bahnflächen wurden mit der segmentbasierten Methodik flächenhaft erfasst.

IKONOS-Satellitenbilddaten (c) Space Imaging

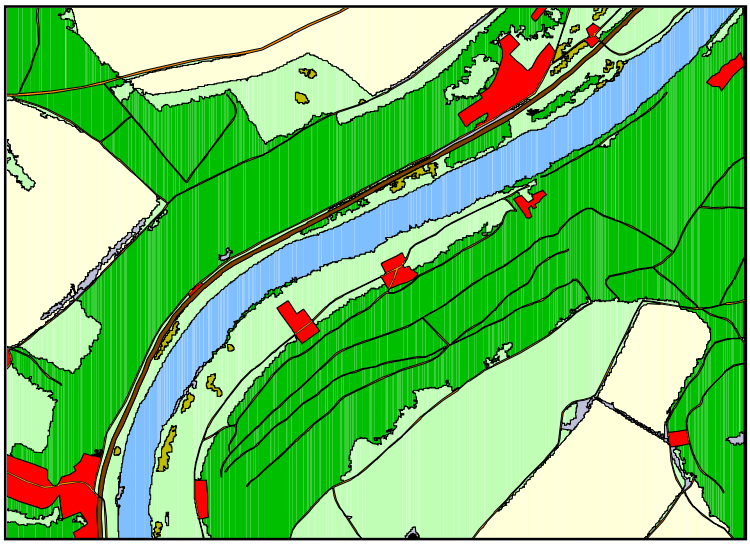

Klassifikationsergebnis nach Hauptgruppen (Ebene 4)

Hauptgruppen der Original-BNTK (Stand 1992/1993)

Legende

Flächenhafte Biotop- und Nutzungstypen:

- Gewässer
- Grünland, Ruderalflur
- Magerrasen, Felsflur, Zwergstrauchheide
- Baumgruppe, Hecke, Gebüsch
- Wald, Forst
- Acker, Sonderstandort
- Siedlung, Infrastruktur, Grünfläche
- Straße, Weg
- Bahnfläche
- Unklassifiziert

Linienhafte Biotop- und Nutzungstypen:

- Gewässer
- Baumgruppe, Hecke, Gebüsch
- Wald, Forst
- Straße, Weg

Klassifikationsgrundlage

IKONOS-Satellitenbild
Panchromatisch geschärfte Multispektraldaten,
Bodenauflösung: 1 m
Aufnahmedatum: 01. August 2000

Abb. 6.4: Satellitenbild und Klassifikationsergebnis auf Ebene der Hauptgruppen im Vergleich zur originalen BNTK (Ausschnittgröße 2 250 x 1800 m).
(Quelle: Eigene Bearbeitung)

Die Unterschiede gegenüber der BNTK sind generell bedingt durch Verfahrensunterschiede und tatsächlich auftretende Veränderungen. Aus diesem Grund sind die Unterschiede grundsätzlich plausibel. Erhebliche statistische Abweichungen ergeben sich in folgenden Klassen:

- Gewässer (wasserstandsabhängige Erfassung der Flussabgrenzung, Überdeckung kleiner Teiche durch Bäume),
- Grünland (Flächenumwidmungen, teilweise wurden Ackerflächen fälschlich als Grünland klassifiziert),
- Felsfläche (Felsflächen häufig durch Wald verdeckt),
- Wälder (waldbestandene Felsflächen, keine anthropogen genutzte Sonderflächen in Wäldern),
- Acker (Flächenumwidmungen, als Grünland klassifizierte Ackerflächen),
- Siedlung (Abweichungen ATKIS vs. BNTK, Straßenfächen in separater Klasse).

Für die Ebene der Untergruppen war keine Prüfung mittels *accuracy assessment* möglich, da sich die funktional definierten Klassen im Bildmaterial nicht visuell interpretieren lassen. Für eine flächenhafte Gegenüberstellung war keine zuverlässige Referenzgrundlage vorhanden. Die originale BNTK konnte aufgrund ihrer geometrischen und inhaltlichen Ungenauigkeiten nur zu einem visuellen Vergleich verwendet werden.

Insbesondere der Vergleich der Waldklassen gestaltete sich schwierig. So wurden die Anteile von Laub- und Nadelwald in der BNTK durch die Interpreten zumeist geschätzt, wodurch sich BNTK und Klassifikationsergebnis deutlich unterscheiden. Zudem lagen der automatisierten Auswertung andere Mindestflächengrößen zugrunde und Liniengeometrien (Straßen, Wege etc.) bilden zwingend Objektgrenzen (siehe Abschnitte 6.4.2.3 bzw. 6.4.2.4). Daher waren nur allgemeine Schlussfolgerungen bezüglich der Ergebnisqualität ableitbar.

Auch der Versuch, andere Referenzkartierungen zu verwenden, war nicht erfolgreich. Überprüft wurde die Vergleichbarkeit mit den Ergebnissen der Sächsischen Waldbiotopkartierung (1 : 10 000) sowie der Forstgrundkarte (1 : 5 000). Beide Datensätze wiesen gegenüber den IKONOS-Daten teils erhebliche Lagefehler auf, die einen geometrischen Vergleich einschränkten. Die Waldbiotopkartierung war Grundlage der BNTK und floss auf Ebene der Bestände ein. Sie enthält ergänzend zu den Biotoptypen differenzierte Waldgesellschaften. Der hohe Detailliertheitsgrad dieser Kartierung war durch die Klassifikation nicht erreichbar, daher bietet sie keine vergleichbare Grundlage. In der Forstgrundkarte werden die Bestände entsprechend der Besitzstruktur abgegrenzt. Derartige Abgrenzungen sind aus Fernerkundungsdaten nicht ableitbar.

Abbildung 6.5 zeigt einen Ausschnitt der Klassifikation auf Ebene der Untergruppen und stellt die Ergebnisse der BNTK gegenüber. Darüber hinaus werden die Unterschiede beider Kartierungen in Tabelle 6.7 statistisch gegenübergestellt. Da sich bei dieser Gegenüberstellung die gleichen Tendenzen wie auf Hauptgruppenebene ergaben, lag das Hauptaugenmerk auf den Walduntergruppen. Hier zeigten sich Abweichungen bis zu 6 %, die insbesondere auf Abgrenzungsunterschiede der Kartiereinheiten zurückzuführen sind. Aufforstungsflächen konnten selbst unter Nutzung texturieller Eigenschaften nicht klassifiziert werden. Die Untergliederung von Siedlungsflächen in ihre funktionalen Bestandteile war nur in eingeschränktem Maße möglich. Der Anteil unklassifizierter Flächen ist in beiden Kartierungen ähnlich.

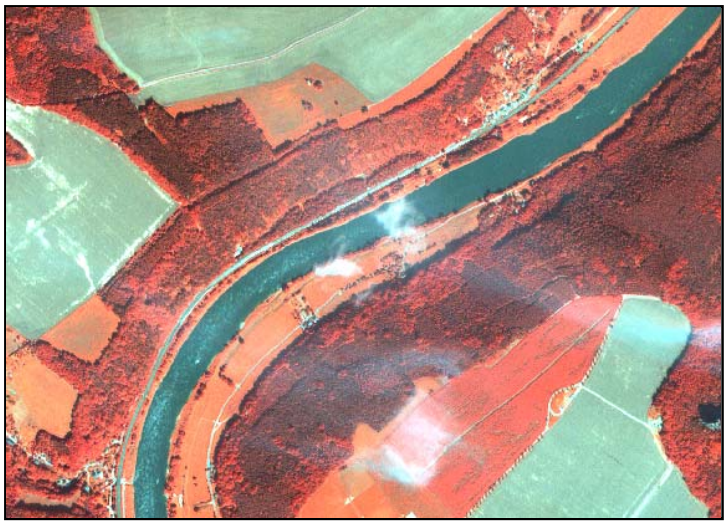

IKONOS-Satellitenbilddaten (c) Space Imaging

Klassifikationsergebnis nach Untergruppen (Ebene 3)

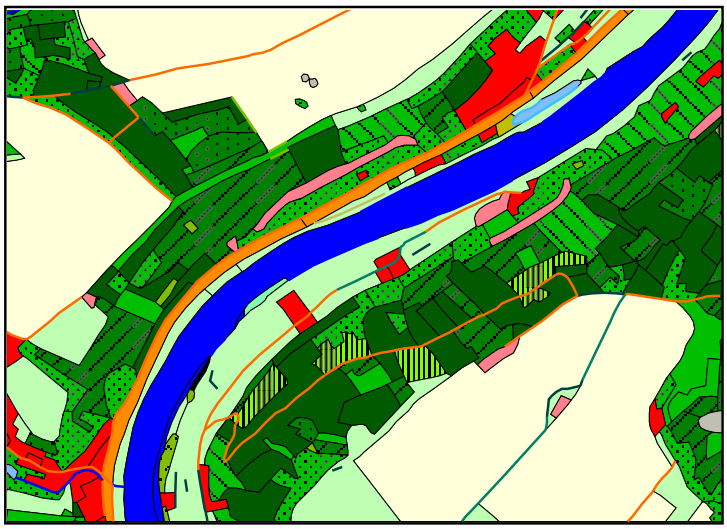

Untergruppen der Original-BNTK (Stand 1992/1993)

Legende

Flächenhafte Biotop- und Nutzungstypen:

- Fließgewässer
- Stillgewässer
- Gewässerbegleitende Vegetation
- Grünland, Ruderalflur (undifferenziert)
- Anstehender Fels
- Offene Fläche
- Feldgehölz, Baumgruppe
- Gebüsch
- Laubwald
- Nadelwald
- Laub-Nadel-Mischwald
- Nadel-Laub-Mischwald
- Laub-Mischwald
- Nadel-Mischwald
- Feuchtwald
- Waldrandbereich/Vorwald
- Wiederaufforstung
- Acker, Sonderkultur
- Siedlungsfläche (eCognition); Wohn-, Misch- bzw. Gewerbegebiet, Grün- und Freifläche (BNTK)
- Straße, Weg (eCognition); Verkehrsfläche (BNTK)
- Anthropogen genutzte Sonderfläche (BNTK)
- Bahnfläche (eCognition)
- Unklassifiziert

Linienhafte Biotop- und Nutzungstypen:

- Fließgewässer
- Stillgewässer
- Baumreihe
- Allee
- Waldrandbereich/Vorwald
- Straße, Weg

Klassifikationsgrundlage

IKONOS-Satellitenbild
Panchromatisch geschärfte Multispektraldaten,
Bodenauflösung: 1 m
Aufnahmedatum: 01. August 2000

Abb. 6.5: Satellitenbild und Klassifikationsergebnis auf Ebene der Untergruppen im Vergleich zur originalen BNTK (Ausschnittgröße 2 250 x 1800 m).
(Quelle: Eigene Bearbeitung)

Tab. 6.7: Statistischer Vergleich der Ergebnisse auf Untergruppenebene mit der BNTK. (Quelle: Eigene Bearbeitung)

Hauptgruppe	Segmentbasierte Klassifikation		BNTK		Differenz	
	Fläche [ha]	Flächen-anteil [%]	Fläche [ha]	Flächen-anteil [%]	Fläche [ha]	Flächen-anteil [%]
21 Fließgewässer	86,8	2,3	92,6	2,5	-5,8	-0,2
23 Stillgewässer	0,6	0,0	6,5	0,2	-5,9	-0,2
24 Gewässerbegleitende Vegetation	0,0	0,0	12,1	0,3	-12,1	-0,3
32 Niedermoor, Sumpf	0,0	0,0	0,3	0,0	-0,3	0,0
41 Wirtschaftsgrünland	931,5	25,1	839,2	22,6	92,3	2,5
42 Ruderalflur, Staudenflur	0,0	0,0	14,6	0,4	-14,6	-0,4
51 Anstehender Fels	28,4	0,8	99,9	2,7	-71,5	-1,9
54 Offene Fläche	8,8	0,2	3,8	0,1	5,0	0,1
61 Feldgehölz, Baumgruppe	20,0	0,5	15,4	0,4	4,6	0,1
62 Baumreihe	6,4	0,2	0,0	0,0	6,4	0,2
66 Gebüsch	0,0	0,0	0,4	0,0	-0,4	0,0
71 Laubbaumart	313,2	8,4	100,4	2,7	212,8	5,7
72 Nadelbaumart	197,0	5,3	360,8	9,7	-163,7	-4,4
73 Laub-Nadel-Mischwald	362,6	9,8	147,4	4,0	215,2	5,8
74 Nadel-Laub-Mischwald	324,9	8,8	312,1	8,4	12,8	0,3
75 Laubmischwald	175,6	4,7	262,4	7,1	-86,8	-2,3
76 Nadelmischwald	226,1	6,1	219,6	5,9	6,5	0,2
77 Feuchtwald	0,0	0,0	3,4	0,1	-3,4	-0,1
78 Waldrandbereich/Vorwald	0,0	0,0	10,9	0,3	-10,9	-0,3
79 Wiederaufforstung	0,0	0,0	51,7	1,4	-51,7	-1,4
81 Acker	587,7	15,8	731,9	19,7	-144,2	-3,9
82 Sonderkultur	0,0	0,0	2,9	0,1	-2,9	-0,1
9 Siedlung, Infrastruktur, Grünfläche	341,8	9,2	0,0	0,0	341,8	9,2
91 Wohngebiet	0,0	0,0	88,6	2,4	-88,6	-2,4
92 Mischgebiet	0,0	0,0	124,4	3,4	-124,4	-3,4
93 Gewerbegebiet/technische Infrastruktur	0,0	0,0	18,1	0,5	-18,1	-0,5
94 Grün- und Freifläche	0,0	0,0	127,5	3,4	-127,5	-3,4
95 Verkehrsfläche	0,0	0,0	22,0	0,6	-22,0	-0,6
96 Anthropogen genutzte Sonderfläche	0,0	0,0	33,5	0,9	-33,5	-0,9
Straße, Weg[1]	78,3	2,1	0,0	0,0	78,3	2,1
Bahnfläche[1]	11,8	0,3	0,0	0,0	11,8	0,3
Unklassifizierte Fläche	7,9	0,2	7,1	0,2	0,8	0,0
Summe	**3 709,3**	**100,0**	**3 709,3**	**100,0**	-	-

[1] Straßen, Wege und Bahnflächen wurden mit der segmentbasierten Methodik flächenhaft erfasst.

Die Untersuchung zeigte, dass die überwiegende Zahl der Untergruppen klassifiziert werden kann und in Einzelfällen nachgeordnete Bestände differenzierbar sind. Eine weiterführende Unterscheidung in Ausprägung, Nutzung und Sekundärnutzung ist in der BNTK unter Verwendung von thematischem Zusatzwissen erfolgt und kann nicht als Maßstab für eine digitale Bildauswertung dienen. Diese ist im Wesentlichen quantitativ-beschreibend. Die Erfassung von qualitativen Merkmalen ist dagegen nur indirekt über Indikatoren oder durch Nutzung von Zusatzwissen zu erreichen. In dieser Hinsicht ist eine thematisch detaillierte

Erfassung von Biotop- und Nutzungstypen auch in Zukunft nur über Teilergebnisse und unter Verwendung von umfangreichen Zusatzwissen bzw. -daten zu realisieren.

6.4.4 Automatisierung und Übertragbarkeit der Bearbeitung

Im Hinblick auf eine operationelle Bearbeitung sollten die Arbeitsschritte einer Aktualisierung der Biotop- und Nutzungstypenkartierung weitestmöglich automatisiert werden. Durch die angewendete Methodik konnten folgende Anforderungen erfüllt werden:

- zuverlässige, reproduzierbare Segmentierung und Klassifikation der Biotoptypen,
- Übertragbarkeit des Klassifikations- und Entscheidungsbaumes auf andere Bilddaten des gleichen Sensors sowie
- Automatisierung der Abläufe (Segmentierung, Klassifikation, Datenexport usw.).

Zum Test der Automatisierungsmöglichkeiten mit eCognition wurden während der Bearbeitung des Testgebietes alle Arbeitsschritte in einem Protokoll aufgezeichnet. Dieses wurde einschließlich des erstellten Entscheidungsbaums auf die westlich benachbarte Szenenhälfte übertragen. Beide Bildausschnitte entstammen also der gleichen Bildszene, d. h. sie sind in Aufnahmezeitpunkt und -technik identisch. Die Anwendung des Protokolls kann vollständig automatisiert (ohne Eingriffsmöglichkeiten) erfolgen. Weiterhin kann das Protokoll schrittweise bzw. durch markieren einer Position ausgeführt werden (siehe Abbildung 6.6). Einzelne im Protokoll enthaltene Operationen (z. B. Segmentierungsparameter) können so verändert werden.

Der innerhalb eines eCognition-Projektes erstellte Entscheidungsbaum kann in einer autonomen Datei abgelegt werden. So kann die einmal erstellte Klassenstruktur einfach auf ein anderes Gebiet übertragen werden. Voraussetzung für die Übertragbarkeit ist die Übereinstimmung hinsichtlich der Anzahl der verwendeten Eingangsdatensätze und deren Namen (Vergabe eines Alias-Namens möglich). Bei der Erstellung des Klassifikationsbaumes sollte darauf geachtet werden, möglichst universelle und stabile Klassenmerkmale zu nutzen. Die Komplexität der Klassenbeschreibungen sollte so gering wie möglich sein.

Die Anwendung des Protokolls sowie des Entscheidungsbaumes lieferte zunächst nur ein vorläufiges Ergebnis. Infolge der Merkmalskomplexität der Objekte und deren vielfältigem Erscheinungsbild war es notwendig, manuelle Anpassungen vorzunehmen. Des Weiteren sind die Segmentierungsparameter für jeden Bildausschnitt neu zu ermitteln bzw. zu optimieren,

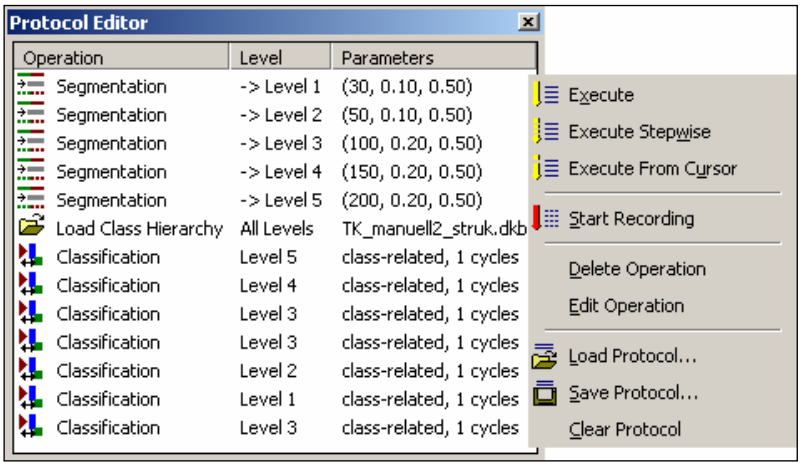

Abb. 6.6: Dialogfenster des *Protocol Editors*.
(Quelle: Eigene Bearbeitung; Screenshot der eCognition Software)

da sie stark vom jeweiligen Bildinhalt abhängen. So waren bei der Übertragung auf die benachbarte Szenenhälfte die Segmentierungsparameter nicht ideal, z. B. da dieses Gebiet größere und sehr homogene Waldflächen aufwies. Zu beachten ist außerdem, dass Änderungen von Klassenmerkmalen (z. B. Aktivierung/Deaktivierung von Klassen im Klassifikationsprozess) oder der Klassenhierarchie nicht im Protokoll aufgezeichnet werden. Eine einfache Übertragung ohne Anpassungen führt zu unvollständigen Ergebnissen, dennoch reduziert sich der Aufwand gegenüber einer Neuklassifikation deutlich (im Beispiel um ca. 75 %).

6.5 Segmentierung gescannter CIR-Luftbilder

Im weiteren Verlauf der Untersuchung wurde geprüft, inwiefern sich automatisierte Methoden der segmentbasierten Aktualisierung mit den im Rahmen der ursprünglichen BNTK-Kartierung verwendeten CIR-Luftbildern durchführen lassen. Diese Untersuchung erfolgte aufgrund von Bestrebungen der zuständigen Behörden, die Aktualisierung aus finanziellen Gründen anhand von analogen Luftbildern, jedoch mit automatisierten Verfahren, durchzuführen. Die mit einer Bodenauflösung von 0,2 m gescannten CIR-Luftbilder der Originalkartierung wurden mit einem Lagefehler von unter 0,6 m orthorektifiziert. Die Überlagerung der Bilddaten mit den Ergebnissen der BNTK zeigte zum Teil erhebliche Abweichungen, insbesondere da die Originalkartierung auf unrektifizierten Luftbildern basiert.

Die Ergebnisse wiesen gegenüber den mit IKONOS-Daten erzielten Resultaten eine wesentlich schlechtere Qualität auf. Dieser Sachverhalt hat vielfältige Ursachen, die hauptsächlich in der Datengrundlage zu suchen sind (vgl. Abschnitt 3.1.3). Die gescannten Luftbilder besitzen zwar eine sehr hohe geometrische Auflösung, verfügen aber nur über drei, zudem teilweise stark korrelierte Farbkanäle, gegenüber vier im Falle der verwendeten Satellitenbilddaten. Darüber hinaus ist ihre radiometrische Auflösung mit 8 Bit (256 Grauwerte) im Vergleich zu den 11-Bit-Daten des IKONOS-Sensors (2048 Grauwerte) erheblich geringer. Aus diesem Grund war eine Unterscheidung spektral ähnlicher Flächen teilweise unmöglich (z. B. Laubwald vs. Wiese).

Die Segmentierung der Luftbilder mit der Software eCognition war nur mit einer 100%igen Gewichtung des Parameters „Farbe“ sinnvoll durchführbar. Die Verwendung des zweiten Parameters „Form“ führte selbst bei geringer Gewichtung zu deutlichen Segmentierungsfehlern. Diese zeigten sich insbesondere durch die Vereinigung von benachbarten Acker- und Wiesenflächen, die jedoch visuell deutlich unterscheidbar waren, sowie eine schlechtere Abgrenzung von Waldflächen (Entstehung großer zusammenhängender und gleichzeitig stark zerlappter Flächen, siehe Abbildung 6.7). Durch die alleinige Verwendung des Farbparameters entstehen häufig stark gegliederte (fraktale) Segmentgeometrien, die für eine weitere Verwendung in GI-Systemen nicht zweckmäßig sind bzw. einer aufwändigen Nachbereitung bedürfen.

Im Ergebnis führten diese Beeinträchtigungen zu einer unbefriedigenden Segmentierung der CIR-Luftbilder, welche wiederum nur eine mangelhafte Klassifikation erlaubte. Die auf Grundlage von IKONOS-Daten erzielte Qualität des Fortschreibungsergebnisses kann nicht erreicht werden. Es ist lediglich eine automatisierte Erkennung der Hauptgruppen und geeigneter Untergruppen der BNTK möglich. Auch BRÖCKER (2003) erzielte bei der segmentbasierten Klassifikation von CIR-Ortholuftbildern mit 30 cm Bodenauflösung im Gebiet des Biosphärenreservates Oberlausitzer Heide- und Teichlandschaft vergleichbare, nicht zufrieden stellende Ergebnisse. Es lässt sich schlussfolgern, dass mit dieser Datengrundlage nur durch eine visuelle und insbesondere stereoskopische Auswertung gute Kartierergebnisse erreicht werden können.

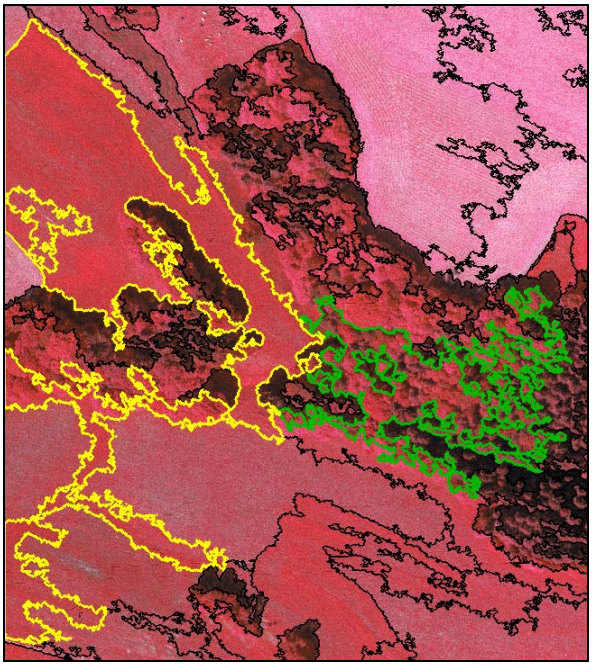

Abb. 6.7: Typische Fehler bei der Segmentierung der CIR-Luftbilder: Verschmelzung von spektral ähnlichen Wiesen- und Laubwaldflächen (gelbes Segment) sowie Entstehung fraktaler Segmente in Waldgebieten (grünes Segment).
(Quelle: Eigene Bearbeitung)

Einen Vergleich zwischen der visuellen Interpretation analoger CIR-Luftbilder sowie der segmentbasierten Klassifikation von IKONOS-Satellitenbilddaten zur Erstellung der BNTK stellten SEILER, NEUBERT & MEINEL (2004) dar (siehe Tabelle 6.8). Eine Vielzahl von Vor- und Nachteilen beider Verfahren wurde dabei aufgeführt.

Tab. 6.8: Vor- und Nachteile der visuellen Interpretation analoger CIR-Luftbilder und der segmentbasierten Klassifikation von IKONOS-Satellitenbilddaten.
(Quelle: SEILER, NEUBERT & MEINEL 2004, verändert)

Methode	Vorteile	Nachteile
Visuelle Interpretation analoger Luftbilder	• Niedrige Kosten für analoge Luftbilder mit hoher Bodenauflösung • Stereoskopische Auswertung erlaubt große thematische Klassifikationstiefe • Umfangreiches Wissen spezialisierter Interpreten • Qualitative Bewertung der Klassen möglich (z. B. Ausprägung, Zustand)	• Hoher zeitlicher und personeller Aufwand Bildinterpretation (Kosten) • Subjektivität der Auswertung und Einfluss verschiedener Bearbeiter • Geometrische Ungenauigkeiten nicht orthorektifizierter Luftbilder
Segmentbasierte Klassifikation von Satellitenbilddaten	• Geometrisch genaue, multispektrale Bilddaten mit großer Flächenabdeckung • Bessere Nutzung der Spektralinformation • Geringer zeitlicher Bearbeitungsaufwand (Kosten, Aktualität) • Segmentierung reduziert Datenkomplexität und ermöglicht die Nutzung von Kontextinformationen • Objektivere, bearbeiterunabhängigere Klassifikation (Nutzung quantitativer Merkmale) • Einfache Datenübertragbarkeit in GIS	• Hohe Kosten für Bilddaten und Softwareausrüstung • Mangelnde Verfügbarkeit von geometrisch genauen Zusatzdaten • Abhängigkeit der Segmentierung von den Bilddaten (problematische Übertragbarkeit, nötige Korrekturen) • Mangelnde Klassifikationsmöglichkeiten funktional definierter Flächen • Geringere thematische Klassifikationstiefe

LANG et al. (2003) erarbeiteten ebenfalls Vorstudien zur segmentbasierten Aktualisierung der BNTK im Nationalpark Berchtesgaden auf Basis digitalisierter und orthorektifizierter Luftbilder. Neben der auch in dieser Arbeit durchgeführten Klassifikation von Biotoptypen wird ein weiteres Verfahren vorgestellt. Dabei gibt eine Segmentierung lediglich die Grenzen der Objekte vor, welche durch eine aufwändige visuelle Interpretation bzw. Geländebegehung klassifiziert wurden. Eine qualitative Bewertung der Segmentierungs- und Klassifikationsergebnisse wurde nicht vorgenommen.

Die Nutzung für ein Natura-2000-Monitoring wurde von LANG & LANGANKE (2004) anhand der Verbuschungs- und Verwaldungsstadien eines Moores untersucht. Dabei kam ein segmentbasiertes Klassifikationsverfahren (eCognition) auf Basis multitemporaler Luftbilder zum Einsatz. Positiv wurden von den Autoren die vielfältigen Klassifikationsmöglichkeiten hervorgehoben. Dadurch konnten die spektralen Landbedeckungsklassen zu semantischen Einheiten (hier FFH-Lebensraumtypen) aggregiert werden, die allein spektral nicht klassifizierbar sind.

6.6 Schlussfolgerungen und Ausblick zur Automatisierung der Biotop- und Nutzungstypenkartierung

Wie am Beispiel von IKONOS-Daten gezeigt werden konnte, ist der komplexe Informationsgehalt sehr hoch auflösender Satellitendaten mittels segmentbasierter Auswertung gut extrahierbar und erscheint für die Fortschreibung der BNTK geeigneter, als beispielsweise gescannte CIR-Luftbilder. Die Klassifikationstiefe erreicht weitestgehend die Ebene der BNTK-Untergruppen und in Einzelfällen die Ebene der Bestände. Hierfür erweist sich die Möglichkeit, komplexe Klassenbeschreibungen definieren zu können, als sehr vorteilhaft. Für eine Automatisierung sind einfach strukturierte Entscheidungsbäume und Klassendefinitionen sowie die Nutzung möglichst stabiler Merkmale (z. B. Texturen, Nachbarschaften) allerdings geeigneter. Durch die Übertragbarkeit der Entscheidungsbäume sowie die Anwendung von in Protokollen gespeicherten Verarbeitungsschritten ist die Auswertung in starkem Maße automatisierbar. Allerdings sind einzelne Funktionen damit derzeit nicht steuerbar und Segmentierungsparameter sowie Klassenmerkmale bedürfen einer teils aufwändigen Anpassung.

Insgesamt bietet das Verfahren eine deutliche Hilfestellung bei der Fortführung von Geobasisdaten. Es kann jedoch derzeit keinen vollständigen Ersatz konventioneller Interpretationsmethoden darstellen, den Prozess jedoch sinnvoll unterstützen. Schätzungsweise 85 % der Flächen lassen sich automatisiert erfassen. Dennoch unterscheidet sich ein aus Fernerkundungsdaten abgeleiteter Datensatz zwangsläufig von einer manuellen Kartierung, da eine Generalisierung, wie sie ein Interpret vornimmt, nicht stattfindet. Zudem führt das segmentbasierte Verfahren zu rasterorientierten Objektgrenzen. Die Anwendung des in eCognition implementierten Glättungsverfahrens beim Datenexport ist nicht ausreichend für eine Korrektur und ist daher verbesserungswürdig. Eine Nachbearbeitung innerhalb eines GIS ist derzeit unerlässlich (Grenzkorrekturen, Generalisierung etc.). Eine Möglichkeit zur Optimierung der Ergebnisse rasterbasierter Polygongrenzen kann in der Anwendung aktiver Konturen (bzw. *Snakes)* gesehen werden (vgl. KERSCHNER 2003).

Um das vorgestellte Verfahren operationell nutzen zu können, sind weitere Untersuchungen nötig. So ist die Übertragbarkeit auf neue verfügbare Daten zu prüfen (z. B. QuickBird, Flugzeugscanneraufnahmen), die eine höhere geometrische Auflösung besitzen und deshalb das Erreichen einer besseren Klassifikationstiefe anzunehmen ist. Des Weiteren ist die zusätzliche Verwendung von Objekthöheninformationen, z. B. in Form von Vegetationshöhenmodellen, denkbar. Diese Datenebene kann weitere wichtige Merkmale zur Klassendifferen-

zierung liefern, wie sie auch bei der stereoskopischen Luftbildauswertung einfließen. Methodisch weitergehende Untersuchungen sind ebenfalls nötig, insbesondere bezüglich der Nutzung von Zusatzdaten, der Verwendung anderer Segmentierungsverfahren oder der Generalisierung der Ergebnisse. Neben der Fortschreibung der Biotop- und Nutzungstypenkartierung eröffnen sich für die beschriebene Methodik der segmentbasierten Bildauswertung weitere Anwendungsmöglichkeiten, beispielsweise bei der Aktualisierung von Geobasisdaten (ATKIS) oder im Landschaftsmonitoring (FFH-Richtlinie). Denn die Objektarten des ATKIS-Objektartenkataloges sind nahezu vollständig in den Bilddaten erkennbar.

Der wesentliche Vorteil einer automatisierten Klassifikation digitaler Satellitenbilddaten gegenüber herkömmlichen, visuellen Auswertungsmethoden analoger Bildmaterialien liegt in einer erheblichen Effizienzsteigerung. Neben der deutlichen Reduzierung des zeitlichen Bearbeitungsaufwandes führt die Methode bei Verwendung gleicher Parameter und Ausgangsdaten zu gleichen Ergebnissen – sie ist also reproduzierbar. Zumindest Teile der entwickelten Regelsätze zur Klassifikation sind (ggf. nach einer Anpassung) darüber hinaus auf andere Projekte übertragbar. Durch die Nutzung physikalischer Messwerte wird der Einfluss der Subjektivität gemindert und eine große Zahl von Fehlerquellen, die im Falle einer manuellen Bearbeitung auftreten können, ausgeschlossen. Damit sind die methodischen Voraussetzungen für eine laufende Erfassung im Sinne einer Aktualisierung der BNTK mit dem oben beschriebenen Verfahren gegeben.

Neben der Entscheidung für ein zweckmäßiges Verfahren ist die Auswahl einer geeigneten Datengrundlage zur Erfassung der Biotop- und Landnutzungstypen essenziell. Dabei gilt es, verschiedenartige Faktoren zu berücksichtigen (vgl. Abschnitt 3.1.3). Dazu zählen unter anderem die räumliche sowie die Farbauflösung der Daten, verfügbare Höheninformationen, Bildverzerrungen oder Bildfehler (bzw. der Aufwand/die Kosten für deren Beseitigung) sowie die Kosten für die Bilddaten (und evtl. benötigte Zusatzdaten). Die Auswahl sollte unter Berücksichtigung dieser Faktoren entsprechend den jeweiligen Anforderungen erfolgen.

„Es ist von großem Vorteil, die Fehler, aus denen man lernen kann, recht frühzeitig zu machen.“

WINSTON CHURCHILL (1874-1965)

7 Schlussfolgerungen und Ausblick

Ein Ziel der vorliegenden Arbeit war es, die Eigenschaften, Potenziale und Probleme sehr hoch auflösender Fernerkundungsdaten darzustellen und zu bewerten. Diesbezüglich wurde der Trend hin zur digitalen, sehr hoch auflösenden Erdbeobachtung verdeutlicht. Die Zahl geplanter Satellitenstarts in diesem Auflösungsbereich veranschaulicht diese Entwicklung eindrucksvoll.

Am Beispiel von IKONOS-Daten wurden die Eigenschaften sehr hoch auflösender Satellitenbilddaten analysiert und evaluiert. Neben der hohen geometrischen Auflösung sowie der sehr guten visuellen Bildqualität sind die günstige spektrale Auflösung (vier Multispektralkanäle) sowie die hohe Wiederholrate infolge der Schwenkbarkeit des Sensors als Vorteile zu nennen. Nachteilig sind die vergleichsweise geringe Flächendeckung der Aufnahmen, die restriktive Lizenzierung der Bilddaten sowie die hohen Datenkosten.

Durch die zunehmende Kommerzialisierung der Fernerkundung stehen der Zugänglichkeit spezifischer Informationen häufig wirtschaftliche Interessen entgegen. Als Folge wird beispielsweise das Sensormodell von IKONOS nach wie vor geheim gehalten, sodass eine Entzerrung der Bilddaten nur näherungsweise möglich ist.

Ein zweiter Schwerpunkt dieser Arbeit lag in der Ermittlung, Anwendung und Bewertung geeigneter Methoden zur Vorverarbeitung und Auswertung von sehr hoch auflösenden Satellitenbilddaten. Infolge der stark gestiegenen geometrischen Auflösung der Bilddaten sind die Ergebnisse bisher verwendeter Verfahren nicht vollständig befriedigend. Für künftige Anwendungen mussten und müssen daher geeignete Methoden entwickelt bzw. weiterentwickelt werden.

Die zur Vorverarbeitung von IKONOS-Daten nötigen Verfahren existierten nicht von Anbeginn der Datenverfügbarkeit. Dies ist sowohl auf o. g. Gründe der Geheimhaltung und eine mangelnde Flexibilität seitens der Anbieter von Fernerkundungssoftware als auch auf fehlende Verarbeitungsmethoden zurückzuführen. Bedingt durch das immense Datenvolumen zeigten sich zudem Schwächen von 32-Bit-Software. Infolgedessen wird die Bearbeitung großer Datenmengen stark behindert. Eine Umorientierung der Softwarehersteller auf 64-Bit-Systeme sowie die Unterstützung von Multiprozessorsystemen ist künftig unumgänglich.

Durch das Zurückhalten des Sensormodells war die Entwicklung geeigneter Verfahren zur Georeferenzierung bzw. Orthorektifikation erst nach und nach möglich. Unter anderem führte eine veränderte Distributionspolitik seitens Space Imaging zu einer Verbesserung der Situation (Lieferung eines *Image Geometry Model* mit den Bilddaten). Nach dem Start weiterer Satelliten (z. B. QuickBird, OrbView-3) reagieren die Softwarehersteller inzwischen schneller.

Versuche, die häufig durch Dunst und Besonnungseinflüsse beeinträchtigten IKONOS-Bilddaten atmosphärisch und topographisch zu korrigieren, schlugen anfänglich fehl. Mit der einzigen Software, die momentan zur Korrektur dieser Bilddaten erhältlich ist (ATCOR), konnte kein zielführendes Ergebnis erreicht werden. Allerdings konnten Verbesserungen der Software angeregt werden, die in einer neuen Version viel versprechende Korrekturergebnisse liefert. Die atmosphärische Korrektur und damit die Umrechnung der reflektierten Strahlung in Reflexionsgrade ist allerdings eine wichtige Voraussetzung zur Übertragbarkeit von Klassifikationsalgorithmen.

Von den bestehenden Vorverarbeitungsverfahren waren lediglich die Methoden zur Fusion panchromatischer und multispektraler Bilddaten ohne Weiteres für sehr hoch auflösende Bilddaten nutzbar.

Weiterhin konnte gezeigt werden, dass aufgrund der Eigenschaften sehr hoch auflösender Fernerkundungsdaten (z. B. Detailgehalt, starke spektrale Variabilität, Datenmenge) eine pixelbasierte Auswertung nicht mehr zielführend ist. Einzelne Pixel enthalten kaum wichtige Informationen zur Interpretation von Bilddaten. Erst die Betrachtung von Pixelgruppen (sog. *meaningful objects)* und ihrer Formeigenschaften sowie ihrer wechselseitigen Relationen (räumlicher Kontext) ermöglicht eine genaue Bildinterpretation. Daraus ergibt sich die Notwendigkeit zur Verwendung neuer Klassifikationsverfahren gegenüber herkömmlich genutzten, pixelbasierten statistischen Methoden.

Eine vergleichende Methodenbewertung bestehender Klassifikationsverfahren stellte heraus, dass die Nachteile pixelbasierter Auswerteverfahren durch neuere Methoden teilweise behoben werden können. Weiterentwickelte Ansätze, wie Neuronale Netze, Bildsegmentierung, Expertensysteme oder Objekterkennung, kommen dem menschlichen visuellen Auswertungsprozess näher. Sie bilden den Übergang zwischen Bildverarbeitung und künstlicher Intelligenz, der für die Entwicklung künftiger Verfahren noch intensiviert werden muss (z. B. modellbasierte Segmentierung, Verknüpfung von Segmentierungs- mit Objekterkennungsverfahren). Von den neuen Methoden konnte sich bisher lediglich die Bildsegmentierung im Bereich der Fernerkundung etablieren. Daher wurde in dieser Arbeit schwerpunktmäßig die Auswertungsstrategie der Bildsegmentierung mit anschließender Klassifikation verfolgt.

Durch eine Segmentierung im Vorfeld der Klassifikation wird die spektrale Varianz nahezu beseitigt. Zudem stehen als klassenbeschreibende Merkmale neben Spektral- und Texturinformationen auch Formeigenschaften sowie Kontextinformationen zur Verfügung. Die Nutzbarkeit derartiger Merkmale erlaubt eine Klassifikation der Flächennutzung gegenüber einer bloßen Bodenbedeckungskartierung, da Flächennutzungsklassen nicht allein durch spektrale Reflexionswerte beschrieben werden können. So können beispielsweise Sportplätze anhand ihrer Größe und Geometrie zweifelsfrei von Wiesenflächen unterschieden werden. Damit kann einer oft geäußerten Nutzeranforderung nach der Bereitstellung aktueller Flächennutzungsinformationen nachgekommen werden. Die Einbettung segmentbasierter Verfahren in Expertensysteme ermöglicht darüber hinaus die Nutzung von Entscheidungsbäumen oder *fuzzy logic* zur Optimierung der Klassifikation.

Die angewendete Software eCognition bietet hierzu eine umfangreiche Werkzeugpalette an. Mit den Möglichkeiten einer multiskaligen Vorgehensweise, einer reproduzierbaren Segmentierung, einer wissens- sowie *fuzzy-logic*-basierten Klassifikation, den umfassenden für eine Klassifikation nutzbaren Merkmalen, der Unterstützung zahlreicher Eingabeformate und einem Vektorexport stellt es ein *state-of-the-art*-Produkt dar. Als problematisch wird dagegen das Finden optimaler Segmentierungsparameter durch aufwändige iterative Tests nach dem *trail-and-error*-Prinzip bewertet. Hier fehlen helfende oder steuernde Werkzeuge (evtl. durch die Abgrenzung von Trainingsobjekten). Auch die Qualität der Abgrenzung ist zum Teil nicht optimal, wodurch mitunter stark zergliederte (ausgefranste bzw. fraktale) Segmente gebildet werden, auf deren Grundlage eine Klassifikation kaum möglich ist.

Aufgrund der genannten Vorzüge hat die Software mittlerweile eine weite Verbreitung gefunden. Bezüglich der weiteren Entwicklung der Software sind vielfältige Verbesserungen geplant (z. B. stärker modellbasierte Segmentierung durch die Vorgabe von *Master*-Objekten, Aufbau von Datenbanken mit Objekteigenschaften für unterschiedliche Bilddaten, Implementierung weiterer Segmentierungsverfahren).

Durch einen Methodenvergleich bezüglich der Anwendung eines pixel- sowie eines segmentbasierten Expertensystems (ERDAS Expert Classifier vs. eCognition) auf sehr hoch auflö-

sende IKONOS-Daten konnte die Überlegenheit des Segmentierungsverfahrens untermauert werden. Die Klassifikationsgüte betrug zwar in beiden Fällen 90 %, die pixelbasierte Klassifikation erfolgte jedoch auf 4-m-Daten, gegenüber einer komplexeren Auswertung von 1-m-Daten mit eCognition. Die segmentbasierte Klassifikation erlaubte eine differenziertere Klassifikation. Neben der Klassifikation der reinen Bodenbedeckung war die Erfassung von Flächennutzungsklassen möglich (z. B. Sportplatz, Fließgewässer, Autobahn). Das segmentbasierte Ergebnis ist homogener, es weist nicht das von der Pixelklassifikation bekannte *salt-and-pepper*-Rauschen auf. Darüber hinaus ist der Anteil unklassifizierter Flächen beim segmentbasierten Ergebnis deutlich geringer (0,07 % gegenüber 0,42 %). Zu vergleichbaren Ergebnissen mit dieser frühzeitig durchgeführten Untersuchung kommen inzwischen zahlreiche weitere Studien (vgl. Abschnitt 4.2).

Eine detaillierte Gegenüberstellung von im Fernerkundungsbereich aktuell verfügbaren Segmentierungsprogrammen und deren erzielbare Abgrenzungsqualität anhand realer sehr hoch auflösender Satellitenbilddaten erfolgte vor dem Hintergrund, das zweckmäßigste Verfahren zu finden. Die Segmentierungsgüte von eCognition zählte dabei zu den Besten. Die zusätzlich in der Software vorhandenen Klassifikationswerkzeuge machen es zu einem der derzeit gebräuchlichsten Programme. Allerdings existieren Möglichkeiten zur Bewertung der Segmentierungsqualität bisher nur in Ansätzen. Die in den Segmentierungsprogrammen heute übliche visuelle Bewertung muss um eine quantitative Evaluierung der Segmentierungsgüte ergänzt werden. Die Fortführung und Erweiterung dieser Untersuchung hinsichtlich zusätzlicher Segmentierungsansätze ist Gegenstand laufender Arbeiten. Darüber hinaus gab es Hinweise, eine derartige Gegenüberstellung z. B. durch internationale Fernerkundungs-Gremien durchführen zu lassen.

Aufbauend auf den Erkenntnissen zur Vorverarbeitung und Auswertung sehr hoch auflösender Fernerkundungsdaten verfolgte die Arbeit das Ziel, IKONOS-Daten und segmentbasierte Klassifikation für Zwecke der Landschaftsplanung und Landschaftsökologie anzuwenden. Der Schwerpunkt lag dabei auf der Erstellung von Landbedeckungs- bzw. -nutzungsklassifikationen sowie der Aktualisierung von Geobasisdaten.

Die Anwendung zur segmentbasierten Landschaftsanalyse ergab, dass eCognition eine geeignete Methodik zur Klassifikation von sehr hoch auflösenden IKONOS-Daten bietet. Sowohl im heterogenen urbanen als auch im homogenen ländlichen Testgebiet konnte eine Klassifikationsgüte von 90 % erreicht werden. Dadurch ist die Schaffung aktueller Arbeitsgrundlagen für die Landschaftsplanung und die Landschaftsökologie gegeben.

Da sich Auswertungsverfahren von Fernerkundungsdaten an den Grenzen der zugrunde liegenden Rasterzellen orientieren, ist für die weitere Nutzung der Ergebnisse eine Glättung der durch die Segmentierung entstehenden rasterbasierten Polygone sinnvoll. Hierdurch wird auch die Nutzung der Segmentgeometrien als Berechnungsgrundlage von Landschaftsstrukturmaßen hochgradig beeinträchtigt. Die derzeit beim Datenexport zur Verfügung stehenden Verfahren zur Glättung bzw. Generalisierung der Grenzlinien sind nicht ausreichend.

Die Potenziale zur Aktualisierung von Geobasisdaten wurden anhand der Erfassung von Biotoptypen- und Landnutzungsklassen verdeutlicht. Der komplexe Informationsgehalt sehr hoch auflösender Satellitendaten ist mittels automatisierter, segmentbasierter Auswertung gut extrahierbar und erscheint für eine Aktualisierung der BNTK geeigneter, als beispielsweise die visuelle Interpretation gescannter CIR-Luftbilder. Gegenüber einer manuellen Bearbeitung wird die Effizienz erheblich gesteigert, die Subjektivität durch Bearbeitereinflüsse minimiert sowie ein weitestgehend reproduzierbares Ergebnis erzielt. Damit sind die methodischen Voraussetzungen für eine laufende Erfassung im Sinne einer Aktualisierung der BNTK mit dem beschriebenen Verfahren gegeben.

Die Klassifikationstiefe erreicht die Ebene der BNTK-Untergruppen weitgehend und in Einzelfällen die Ebene der Bestände. Durch die Übertragbarkeit der Entscheidungsbäume sowie die Anwendung von in Protokollen gespeicherten Verarbeitungsschritten ist die Auswertung in starkem Maße automatisierbar. Die Segmentierungsparameter sowie einzelne Klassenmerkmale bedürfen allerdings einer teils aufwändigen Anpassung.

Um das vorgestellte Verfahren operationell nutzen zu können, sind weitere Untersuchungen hinsichtlich der Übertragbarkeit auf neue verfügbare Daten (z. B. QuickBird, Flugzeugscannerdaten) nötig. So ist zu prüfen, ob mit einer weiter gesteigerten geometrischen Auflösung das Erreichen einer besseren Klassifikationstiefe möglich ist. Des Weiteren ist die zusätzliche Verwendung von Objekthöheninformationen, z. B. in Form von Vegetationshöhenmodellen, zu untersuchen. Diese Datenebene kann weitere wichtige Merkmale zur Klassendifferenzierung liefern, wie sie auch im Rahmen einer stereoskopischen Luftbildauswertung einfließen. Methodisch weitergehende Untersuchungen sind ebenfalls nötig, insbesondere bezüglich der zusätzlichen Nutzung von GIS-Daten, der Verwendung anderer Segmentierungsverfahren oder der Generalisierung der Ergebnisse. Neben der Fortschreibung der Biotop- und Nutzungstypenkartierung eröffnen sich für die beschriebene Methodik der segmentbasierten Bildauswertung weitere Anwendungsmöglichkeiten, beispielsweise im Landschaftsmonitoring (Natura 2000) oder bei der Aktualisierung weiterer Geobasisdaten (ATKIS). Die Objektarten des ATKIS-Objektartenkataloges sind nahezu vollständig in den Bilddaten erkennbar.

Insgesamt ist eine stärkere Anwenderorientierung sowohl seitens der Daten- als auch der Softwareanbieter nötig. Die Operationalität und Automatisierung von standardisierten Methoden sollte bei künftigen Entwicklungen im Vordergrund stehen. Dabei muss die Integration von GIS und Fernerkundung weiter vorangetrieben werden. Nur dann werden die Nutzer bereit sein, neue Methoden und hohe Kosten zu akzeptieren und damit der Fernerkundung ein breites Anwendungsfeld eröffnen.

Literaturverzeichnis

ADV (Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder, 2000): ATKIS-Gesamtdokumentation, Teil D: ATKIS-Objektartenkatalog (ATKIS-OK). Stand 2000, Hannover. [http://www.atkis.de/dstinfo/dstinfo2.dst_gliederung2?dst_ver=dst00 – 17.08.2002]

Albertz, J. (1991): Grundlagen der Interpretation von Luft- und Satellitenbildern: Eine Einführung in die Fernerkundung. Wiss. Buchges., Darmstadt: 204 S.

Albertz, J. (1999): Methoden der Mustererkennung. In: Rundgespräche der Kommission für Ökologie 17 „Fernerkundung und Ökosystem-Analyse“, Pfeil, München: 37-51.

Albertz, J. (2001): Einführung in die Fernerkundung – Grundlagen der Interpretation von Luft- und Satellitenbildern. 2. Aufl., Wiss. Buchges., Darmstadt: 249 S.

Aplin, P. (2003): Comparision of simulated IKONOS and SPOT HRV imagery for classifying urban areas. In: Mesev, V. (Ed.): Remotely sensed cities. Taylor & Francis, London: 23-45.

Aplin, P.; Atkinson, P. M. & Curran P. J. (1999): Per-field Classification of Land Use Using the Forthcoming Very Fine Spatial Resolution Satellite Sensors: Problems and Potential Solutions. In: Atkinson, P. M. & Tate N. J. (Eds.): Advances in remote sensing and GIS analysis. Wiley, Chichester: 219-239.

Atkinson, P. M. & Tate, N. J. (Eds., 1999): Advances in remote sensing and GIS analysis. Wiley, Chichester, 273 S.

Avery, T. E. & Berlin, G. L. (Eds., 1992): Fundamentals of remote sensing and airphoto interpretation. 5th ed., Macmillan Publishing, New York: 472 S.

Baatz, M. & Mimler, M. (2002): Bildobjekt-Primitive als Bausteine – Extraktion von Objekten „of interest“ bzw. anthropogenen Objekten basierend auf der expliziten Kanteninformation von Bildobjekt-Primitiven. In: Blaschke, T. (Hrsg.): Fernerkundung und GIS. Wichmann, Heidelberg: 179-188.

Baatz, M. & Schäpe, A. (2000): Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation. In: Strobl, J.; Blaschke, T. & Griesebner, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung XII, Wichmann, Heidelberg: 12-23.

Bähr, H.-P. & Vögtle, T. (Hrsg., 1998): Digitale Bildverarbeitung – Anwendung in Photogrammetrie, Kartographie und Fernerkundung. 3. Aufl., Wichmann, Heidelberg: 360 S.

Baltsavias, E. P.; Gruen, A. & van Gool, L. (Eds, 2002): Automatic Extraction of Man-Made Objects from Aerial and Space Images (III). Balkema Publishers, Lisse: 415 S.

Baltsavias, E. P.; O’Sullivan, E. L. & Zhang , C. (2004): Automated Road Extraction and Updating Using the Atomi System – Performance Comparison Between Aerial Film, ADS40, IKONOS and Quickbird Orthoimagery. In: Proceedings XXth ISPRS Congress, Istanbul, 14.-23. July 2004, Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXV (CD), 6 S.

Baltsavias, E. P.; Pateraki, M. & Zhang, L. (2001): Radiometric and geometric evaluation of Ikonos GEO images and their use for 3D building modelling. In: Proceedings Joint ISPRS Workshop High Resolution Mapping from Space 2001, Hannover, 21 S.

Baltsavias, E. P.; Zhang, L. & Eisenbeiss, H. (2005). DSM Generation and Interior Orientation Determination of IKONOS Images Using a Testfield in Switzerland. ISPRS Workshop High-Resolution Earth Imaging for Geospatial Information, International Archives of Photogrammetry and Remote Sensing, Vol. XXXVI, Part I/W3 (CD), Hannover, 9 p.

Bastian, O. & Schreiber, K.-F. (Hrsg., 1999): Analyse und ökologische Bewertung der Landschaft. 2. Aufl., Spektrum, Heidelberg, Berlin: 564 S.

Bauer, T. & Steinnocher, K. (2001): Per parcel land use classification in urban areas applying a rule-based technique. GeoBIT/GIS (6): 24-27.

Baumgartner, M. F. & Zevenbergen, A. (2003): Zugriff auf höchstauflösende Satellitendaten – technische Aspekte. Geomatik Schweiz (8): 434-438.

BfN (Bundesamt für Naturschutz, Hrsg., 1995): Systematik der Biotoptypen- und Nutzungstypenkartierung (Kartieranleitung). Schriftenreihen für Landschaftspflege und Naturschutz, Heft 45, 153 S.

BfN (Bundesamt für Naturschutz, 2002a): Landschaftsplanung für eine nachhaltige Gemeindeentwicklung. Leipzig: 24 S. [http://www.bfn.de/03/0313_landsch_planung.pdf – 02.12.03]

BfN (Bundesamt für Naturschutz, Hrsg., 2002b): Systematik der Biotoptypen- und Nutzungstypenkartierung (Kartieranleitung). Schriftenreihen für Landschaftspflege und Naturschutz, Heft 73, 169 S.

Bill, R. (1999): Grundlagen der Geo-Informationssysteme. Band 1: Hardware, Software, Daten. 4. Aufl.; Band 2: Analysen, Anwendungen und neue Entwicklungen. 2. Aufl., Wichmann, Heidelberg: 959 S.

Bill, R. & Zehner, M. L. (2001): Lexikon der Geoinformatik. Wichmann, Heidelberg: 312 S.

Bins, L. S.; Fonseca, L. M. G.; Erthal, G. J. & Ii, F. A. M. (1996): Satellite imagery segmentation: a region growing approach. Proceedings of VIII Brazilian Remote Sensing Symposium, Salvador, Bahia: 4 S.

Blaschke, T. (Hrsg., 1999): Umweltmonitoring und Umweltmodellierung – GIS und Fernerkundung als Werkzeuge einer nachhaltigen Entwicklung. Wichmann, Heidelberg: 278 S.

Blaschke, T. (2000a): Objektextraktion und regelbasierte Klassifikation von Fernerkundungsdaten: Neue Möglichkeiten für GIS-Anwender und Planer. In: Schrenk, M. (Hrsg.): Computergestützte Raumplanung – Beiträge zum Symposion CORP 2000. Wien: 153-162.

Blaschke, T. (2000b): Landscape Metrics: Konzepte eines jungen Ansatzes der Landschaftsökologie und Anwendungen in Naturschutz und Landschaftsforschung. Arch. für Naturschutz und Landschaftsforschung (39): 267-299.

Blaschke, T. (2001): Multiskalare Bildanalyse zur Umsetzung des patch-matrix-Konzepts in der Landschaftsplanung. „Realistische“ Landschaftsobjekte aus Fernerkundungsdaten. In: Naturschutz und Landschaftsplanung 33 (2/3): 84-89.

Blaschke, T. (2002): GIS und Fernerkundung für Landschaftsmonitoring und Landschaftsplanung. Standort – Zeitschrift für Angewandte Geographie (3): 115-120.

Blaschke, T. (2003): Object-based contextual image classification built on image segmentation. IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data, CD-ROM, Washington DC: 7 S.

Blaschke, T.; Gläßer, C. & Lang, S. (2002): Bildverarbeitung in einer integrierten GIS/Fernerkundungsumgebung – Trends und Konsequenzen. In: Blaschke, T. (Hrsg.): Fernerkundung und GIS. Wichmann, Heidelberg: 1-8.

Blaschke, T.; Conradi, M. & Lang, S. (2001): Multi-scale image analysis for ecological monitoring of heterogeneous, small structured landscapes. Proceedings of SPIE, Toulouse: 35-44.

Blaschke, T.; Lang, S.; Lorup, E.; Strobl, J. & Zeil, P. (2000): Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: Cremers, A. & Greve, K. (Eds.): Environmental Information for Planning, Politics and the Public. Metropolis, Marburg, Vol. 2: 555-570.

Blaschke, T. & Strobl, J. (2001): What's wrong with pixels? Some recent developments interfacing emote sensing and GIS. In: GIS (6): 12-17.

Bock, M. (2003): SPIN Final Report: 86 S. [http://spin.space.noa.gr/service/SPIN-Final-Report.pdf – 07.07.2004]

Breuer, M. (2002): Die Verarbeitung von Stereo-Satellitenbilddaten mit Erdas am Beispiel von IKONOS- und ASTER-Daten. In: Seyfert, E. (Hrsg.): Zu neuen Märkten – auf neuen Wegen – mit neuer Technik. 22. Wissenschaftlich-Technische Jahrestagung der DGPF, 24.-26. September 2002 in Neubrandenburg. Publikat. d. Dt. Gesellschaft f. Photogrammetrie u. Fernerkundung; Band 11, Münster: 159-166.

Bröcker, J. (2003): Segmentbasierte Landnutzungsklassifikation von CIR-Orthophotos im Biosphärenreservat Oberlausitzer Heide- und Teichlandschaft. Technische Universität Dresden, Institut für Photogrammetrie und Fernerkundung, Diplomarbeit, unveröff.: 87 S.

Bückner, J.; Pahl, M.; Stahlhut, O. & Liedtke, C.-E. (2002): A Knowledge-Based System for Context Dependent Evaluation of Remote Sensing Data. In: Van Gool, L. J. (Ed.): Pattern Recognition. Proceedings of the 24th DAGM Symposium, Zurich, Switzerland, September 16.-18.: 58-65.

Buder, W. (1998): Zwei Strategien zur Landschaftsanalyse: CIR-Biotoptypen- und Landnutzungskartierung und selektive terrestrische Biotopkartierung. In: Sächsische Akademie für Natur und Umwelt (Hrsg.): Ergebnisse der CIR-Biotoptypen- und Landnutzungskartierung und ihre Anwendungsmöglichkeiten in der Naturschutzpraxis. Heft 3/97: 21-24.

Burnett, C.; Aaviksoo, K.; Lang, S.; Langanke, T. & Blaschke, T. (2003): An Object-based Methodology for Mapping Mires Using High Resolution Imagery. In: Järvet, A. & Lode, E. (eds.): Ecohydrological Processes in Northern Wetlands, Tallinn: 239-244.

Busch, A.; Gerke, M.; Grünreich, D.; Heipke, Ch.; Liedtke, C.-E. & Müller, S. (2004): Automated Verification of a Topographic Reference Dataset: System Design and Practical Results. In: Proceedings XXth ISPRS Congress, Istanbul, 14.-23. July 2004, Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXV (CD), 6 S.

Canty, J. M. (1999): Fernerkundung mit neuronalen Netzen: Theorie – Algorithmen – Programme. Edition expertsoft; Bd. 34, expert, Renningen-Malmsheim: 208 S.

Carleer, A. P.; Debeir, O. & Wolff, E. (2003): Comparison of very high spatial resolution satellite images segmentations. In: Bruzzone, L. (Ed.): Image and Signal Processing for Remote Sensing IX. Proceedings SPIE Vol. 5238: 532-542.

Cocquerez, J. P. & Philipp, S. (1995): Analyse d'images: filterage et segmentation. Masson, Paris: 457 S.

Cook, R.; McConnell, I.; Stewart, D. & Oliver, C. J. (1996): Segmentation and simulated annealing. In: Franceschetti, G.; Oliver, C. J.; Rubertone, F. S. & Tajbakhsh, S. (Eds.): Microwave Sensing and Synthetic Aperture Radar. Proceedings SPIE 2958: 30-35.

Csaplovics, E. & Wagenknecht, S. (1999): Airborne Laser Scanning zur topographischen Modellierung von Felsgebieten. In: Strobl, J. & Blaschke, T. (Hrsg.): Angewandte Geographische Informationsverarbeitung XI. Wichmann, Heidelberg: 108-119.

Cushnie, J. L. (1987): The interactive effect of spatial resolution and degree of internal variability within land-cover types on classification accuracies. Int. Journal of Remote Sensing 8 (1): 15-29.

Darwish, A.; Leukert, K. & Reinhardt, W. (2003): Urban Land-Cover Classifikation: An Object Based Perspective. In: Proceedings 2nd GRSS/ISPRS Joint Workshop on Data Fusion and Remote sensing over Urban Areas – URBAN 2003, Berlin: 278-282.

Debeir, O. (2001): Segmentation supervisée d'images. Ph.D., Faculté des Sciences Appliquées, Université de Bruxelles: 187 S.

Definiens Imaging (2003): eCognition User Guide 3. München: 480 S.

de Kok, R. (2001): Objektorientierte Bildanalyse. Ein Lösungsansatz für den automatisierten Einsatz sehr hoch auflösender Satellitendaten für forstliche Fragestellungen. Diss. TU München, Fakultät Wissenschaftszentrum Weihenstefan für Ernährung, Landnutzung und Umwelt.

Delphi IMM (2003): Bestimmung der Segmentierungsqualität bei objektorientierten Bildanalyseverfahren mit SEQ. [http://www.delphi-imm.de/neu/ > Fernerkundung > Software > SEQ – 07.12.2003]

Deravi, F. & Pal, S. K. (1983): Grey level thresholding using second-order statistics. Pattern Recognition Letters (1): 417-422.

Duda, R. O.; Hart, P. E. & Stork, D. G. (2001): Pattern Classification, 2nd Edition, John Wiley and Sons, New York: 654 S.

Egmont-Petersen, M.; de Ridder, D. & Handels, H. (2002): Image Processing with neural networks – a review. Pattern Recognition 35: 2279-2301.

Ehlers, M. (2002): Fernerkundung für GIS-Anwender – Sensoren und Methoden zwischen Anspruch und Wirklichkeit. In: Blaschke, T. (Hrsg.): GIS und Fernerkundung: Neue Sensoren – Innovative Methoden. Wichmann, Heidelberg: 10-23.

Ehlers, M.; Edwards, G. & Bedard, Y. (1989): Integration of remote sensing with geographic information systems: a necessary evolution. Photogrammetric Engineering and Remote Sensing 55: 1619-1627.

Ehlers, M.; Schiewe, J. & Möller, M. (2003): 3D City Modelling Using Ultra High Resolution and Multi-Sensoral Remote Sensing. GeoBIT/GIS (6): 30-37.

Esch, T.; Roth, A.; Strunz, G. & Dech, S. (2003): Object-oriented classification of Landsat-7 data for regional planning purposes. In: Jürgens, C. (Ed.): Proceedings of the ISPRS WG VII/4 Symposium Remote Sensing of Urban Areas. Int. Arch. of the Photogrammetry, Remote Sensing and Spatial Information Sciences (CD-ROM), VOL XXXIV-7/W9, Regensburg, Germany.

Eurimage (2004): Eurimage Price List, December 2004. [http://www.eurimage.com/products/docs/eurimage_price_list.pdf – 28.01.2005]

European Space Imaging (2004): IKONOS Price List, June 2004. [http://www.euspaceimaging.com/content/Products/price list/EUSpaceImaging-Pricelist.pdf – 28.01.2005]

Everingham, M.; Muller, H. & Thomas, B. (2001): Evaluating image segmentation algorithms using monotonic hulls in fitness/cost space. In: Cootes, T. & Taylor, C. (Eds.): Proceedings of the 12th British Machine Vision Conference (BMVC2001): 363-372.

Federation of American Scientists (2002): Imagery Intelligence Gallery. [http://www.fas.org/irp/imint – 27.02.2003]

Fehlert, G. P. (1985): Kalibrierung von MSS-Satellitenbilddaten zur Auswertung zeitlicher Reflexionsänderungen an Fichtenbeständen. Techn. Univ. Berlin, Diss.: 186 S.

Fistric, S. (2002): Operationalisierung von Fernerkundungsdaten für die Umweltverwaltung im Land Sachsen-Anhalt (OFULSA). Endbericht des Teilvorhabens „Auenlandschaften". [http://www.delphi-imm.de/ofulsa/download/endbericht_aue.pdf – 07.12.2003]

Foody, G. M. (1999): Image Classification with a Neural Network: From Completely-Crisp to Fully-Fuzzy Situations. In: Atkinson, P. M. & Tate, N. J. (Eds.): Advances in remote sensing and GIS analysis. Wiley, Chichester: 17-37.

Forman, R. T. T. (1995): Land mosaics. The ecology of landscapes and regions. Cambridge University Press, Cambridge: 632 S.

Forman, R. T. T. & Godron, M. (1986): Landscape ecology. Wiley and Sons, New York, Chichester: 619 S.

Fraser, C. S.; Baltsavias, E. & Gruen, A. (2002): Processing of IKONOS imagery for submetre 3D positioning and building extraction. ISPRS Journal of Photogrammetry & Remote Sensing 56: 177-194.

Frietsch, G. (2001): Die Color-Infrarot-(CIR-)Luftbildbefliegung im Freistaat Sachsen. Materialien zu Naturschutz und Landschaftspflege 23, Sächsisches Landesamt für Umwelt und Geologie, Dresden: 8-10.

Fritz, L. W. (1999): High Resolution Commercial Remote Sensing Satellites and Spatial Information Systems. In: ISPRS Highlights 4 (2): 19-30. [http://www.isprs.org/publications/highlights/highlights0402/fritz.html – 04.03.2003]

Gähler, M. & Janowski, R. (2003): Hierarchisches Klassifikationsverfahren zur automatisierten Ableitung von Biotoptypen aus HRSC-AX-Scannerdaten. In: Seyfert, E. (Hrsg.): Auf dem Weg zu operationellen Prozessketten in Photogrammetrie, Fernerkundung und Geoinformation. Vorträge 23. Wissenschaftlich-technische Jahrestagung der DGPF. Publikationen der DGPF, Band 12, Münster: 81-88.

Gähler, M.; Janowsky, R. & Schröder, U. (2002): Automatisierte Biotoptypenklassifizierung auf Basis höchstauflösender Flugzeugscannerdaten. In: Blaschke, T. (Hrsg.): GIS und Fernerkundung: Neue Sensoren – Innovative Methoden. Wichmann, Heidelberg: 233-240.

Geosystems (2002a): ATCOR for Erdas Imagine. ATCOR3 Ver. 2.0 User Manual. Germering: 86 S.

Geosystems (2002b): Calibration Files in ATCOR Ver. 2.0. 7 S. [http://www.geosystems.de/atcor/sensors/Calibration_Files_in_ATCOR_V20.pdf – 14.01.2004]

Gerlach, F. (2000): Characteristics of Space Imaging's One-Meter-Resolution Satellite Imagery Products. Int. Arch. of Photogrammetry and Remote Sensing 33 (B1): 128-135.

Gorte, B. (1999): Supervised Segmentation by Region Merging. In: Kanellopoulos, I.; Wilkinson, G. G. & Moons, T. (Eds., 1999): Machine Vision and Advanced Image Processing in Remote Sensing. Springer, Berlin: 329-335.

Gougeon, F. A. (1995): Comparison of possible multispectral classification schemes for tree crowns individually delineated on high spatial resolution MEIS Images. Can. J. Rem. Sens. 21 (1): 1-9.

Gruber, M.; Leberl, F. & Perko, R. (2003): Paradigmenwechsel in der Photogrammetrie durch digitale Luftbildaufnahme. Photogrammetrie – Fernerkundung – Geoinformation (4): 285-297.

Haberäcker, P. (1995): Praxis der digitalen Bildverarbeitung und Mustererkennung. Hanser, München: 350 S.

Haefner, H. (1999): Fernerkundung als Instrument der Landschaftsökologie. In: Schneider-Sliwa, R.; Schaub, D. & Gerold, G. (Hrsg.): Angewandte Landschaftsökologie – Grundlagen und Methoden. Springer, Berlin: 201-215.

Halle, W. (1999): Ausgewählte Algorithmen der Segmentierung und Klassifikation zur thematischen Bildverarbeitung in der Fernerkundung. Deutsches Zentrum für Luft- und Raumfahrt: Forschungsbericht, Band 99, 36, Köln, Zugl.: Berlin, Techn. Univ., Diss.: 113 S.

Haralick, R. M. (1979): Statistical and structural approaches to texture. Proc. IEEE 67 (5): 786-804.

Haralick, R. M. & Shapiro, L. G. (1985): Image segmentation techniques. Computer Vision, Graphics and Image Processing 29: 100-132.

Haralick, R. M. & Shapiro, L. G. (1992): Computer and robot vision. Vol. I, Addison-Weasley, Reading: 672 S.

Hargis, C.; Bisonette, J. & David, L. (1998): The behaviour of landscape metrics commonly used in the study of habitat fragmentation. Landscape ecology 13: 167-186.

Haubrock, S. & Lessing, R. (2002): ETIC – ein modulares Klassifikationsverfahren zur Nutzung von verteiltem Wissen. In: Strobl, J.; Blaschke, T. & Griesebner, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung XIV. Beiträge zum AGIT-Symposium Salzburg 2002, Wichmann, Heidelberg: 148-155.

Hay, G. J.; Niemann, K. O. & McLean, G. F. (1996): An Object-Specific Image-Texture Analysis of H-Resolution Forest Imagery. RSoE 55: 108-122.

Heipke, C. (2003): Photogrammetrie & Fernerkundung – vom Elektronenmikroskop bis zur Planetenbeobachtung. Photogrammetrie – Fernerkundung – Geoinformation (3): 165-180.

Hermes, L. & Buhmann, J. M. (2001): Contextual Classification by Entropy-Based Polygonization, Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR'01), Vol. 2: 442-447.

Hermes, L. & Buhmann, J. M. (2004): Boundary-Constrained Agglomerative Segmentation. IEEE Transactions on Geoscience and Remote Sensing 42 (9): 1984-1995.

Hese, S. M. (2001): Entwicklung und Anwendung geostatistischer Verfahren zur strukturellen Klassifizierung von Forstbeständen in hochauflösenden Daten der HRSC-A. Berlin Techn. Univ., Diss.: 237 S. [http://edocs.tu-berlin.de/diss/2001/hese_soeren.pdf – 02.08.2003]

Hildebrandt, G. (1996): Fernerkundung und Luftbildmessung für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie. Wichmann, Heidelberg: 676 S.

Hirschmugl, M. (2002): Automatisierte Bildsegmentierung von Nutzungsstrukturen in der Fernerkundung. Unveröff. Diplomarbeit, Institut für Geographie und Raumforschung, Karl-Franzens-Universität Graz, Graz: 115 S.

Hoffmann, A. (2001): Neue Ansätze zur Auswertung und Klassiffizierung von sehr hochauflösenden Daten – Methoden der Segmentierung, der hierarchischen Klassifizierung und der per-Parcel-Methode mit Daten der digitalen Kamera HRSC-A und ihre Anwendbarkeit für die Aktualisierung topographischer Karten, Diss. HU Berlin: 200 S.

Hoffmann, A.; Smith, G.; Hese, S. & Lehmann, F. (2000): Die Klassifizierung hochauflösender Daten: Ein per-parcel Ansatz mit Daten des digitalen Kamerasystems HRSC-A. In: Tagungsband der Wissenschaftlich-Technischen Jahrestagung 1999, Schriftenreihe der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung, Band 8, Essen. 17 S. [http://solarsystem.dlr.de/FE/abteilung/pdfs/ah-etal-dgpf1999.pdf – 14.01.2004]

Hoffmann, A. & Van der Vegt, J. W. (2001): New sensor systems and new classification methods: laser- and digital camera-data meet object-oriented strategies. GIS (6): 18-23.

Hoffmann, A.; Van der Vegt, J. W. & Lehmann, F. (2000): Die automatische Aktualisierung von Karten: Neue Methoden mit Daten der Kamera HRSC-A. Kartographische Nachrichten 50 (5): 211-217.

Hofmann, P. (2001): Detecting buildings and roads from IKONOS data using additional elevation information. GIS (6): 28-33.

Holzer-Popp, T.; Bittner, M.; Borg, E.; Dech, S.; Erbertseder, T.; Fichtelmann, B. & Schroedter, M. (2002): Das Automatische Atmosphärenkorrekturverfahren „DurchBlick“. In: Blaschke, T. (Hrsg.): GIS und Fernerkundung: Neue Sensoren – Innovative Methoden. Wichmann, Heidelberg: 78-87.

Hu, X. & Tao, C. V. (2004): Smart Digitizer – A Software Tool for Making Feature Extraction Smarter and Faster. Proceedings of ASPRS 2004 Annual Conference, 23-28 May, Denver: 5 S. [http://www.geoict.yorku.ca/Resources/ResearchProjects/SmartDigitizer/ASPRS2004SM.pdf – 12.11.2004]

Ivits, E. & Koch, B. (2003): Optimierung der Erfassung der Landschaftsdiversität auf der Basis von Satelliten- und Luftbildern: ein Europäisches Landschaftskonzept. In: Bastian, O.; Grunewald, K.; Schanze, J.; Syrbe, R.-U. & Walz, U. (Hrsg.): Bewertung und Entwicklung der Landschaft. IÖR-Schriften 40: 13-24.

Jacobsen, K. (2002): Auswertung von IKONOS-Aufnahmen. In: Seyfert, E. (Hrsg.): Zu neuen Märkten – auf neuen Wegen – mit neuer Technik. Publikat. d. Dt. Gesellschaft f. Photogrammetrie u. Fernerkundung; Band 11, Münster: 49-57.

Jähne, B. (1997): Digitale Bildverarbeitung. 4. Aufl., Springer, Berlin, Heidelberg, New York: 591 S.

Jähne, B. (2002): Digitale Bildverarbeitung. 5. Aufl., Springer, Berlin, Heidelberg, New York: 618 S.

Janoth, J.; Eisl, M.; Klaushofer, F. & Luckel, W. (2002): Segmentbasierte Verfahren zur Veränderungsanalyse und Waldklassifizierung mit hochauflösenden Satellitendaten. In: Blaschke, T. (Hrsg.): Fernerkundung und GIS: Neue Sensoren – Innovative Methoden. Wichmann, Heidelberg: 98-107.

Kanellopoulos, I.; Wilkinson, G. G. & Moons, T. (Eds, 1999): Machine Vision and Advanced Image Processing in Remote Sensing. Springer, Berlin: 335 S.

Kappas, M. (1994): Fernerkundung nah gebracht – Leitfaden für Geowissenschaftler. Dümmler, Bonn: 207 S.

Karantzalos, K. G. & Argialas, D. P. (2003): Evaluation of Selected Edge Detection Techniques in Remote Sensing. In: Serpico, S. B. (Ed.): Image and Signal Processing for Remote Sensing VIII, Proceedings SPIE Vol. 4885: 102-110.

Katartzis, A; Vanhamel, I. & Sahli,H. (2003): A Hierarchical Markovian Model for Multiscale Region-Based Classification of Multispectral Images. IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data, CD-ROM, Washington DC: 6 S.

Kenneweg, H. (2002): Neue methodische Ansätze zur Fernerkundung in den Bereichen Landschaft, Wald und räumliche Planung. In: Dech, S. (Hrsg.): Tagungsband 19. DFD-Nutzerseminar. 15.-16. Oktober 2002: 127-137.

Kenneweg, H.; Förster, B. & Runkel, M. (1991): Diagnose und Erfassung von Waldschäden auf der Basis von Spektralsignaturen. Abschlußbericht, Teil B 6 zum BMFT-geförderten Verbundprojekt „Untersuchung und Kartierung von Waldschäden mit Methoden der Fernerkundung“: 105 S.

Kenneweg, H.; Lehnert, S.; Michael, F.; Schönfeld, R. & C. Werner (2000): MOMSIS – Biotopüberwachung mit Satellitenbildfernerkundung. Arbeitsmaterialien zur Landschaftsplanung, Heft 18: 267 S. (CD-ROM).

Kerschner, M. (2003): Snakes für Aufgaben der digitalen Photogrammetrie und Topographie. Diss. TU Wien: 115 S. [http://www.ipf.tuwien.ac.at/phdtheses/mk/diss_mk.pdf - 07.08.2003]

Kersten, T.; Baltasavias, E.; Schwarz, M. & Leiss, I. (2000): IKONOS-2 CARTERRA GEO – Erste geometrische Genauigkeitsuntersuchungen in der Schweiz mit hochauflösenden Satellitendaten. Vermessung, Photogrammetrie, Kulturtechnik (8): 490-497.

Kettig, R. L. & Landgrebe, D. A. (1976): Classification of Multispectral Image Data by Extraction and Classification of Homogeneous Objects. IEEE. Trans. Geoscience Electronics, GE-14: 19-26.

Klaus, D.; Canty, M. J.; Poth, A.; Voß, M.; Niemeyer, I. & Stein, G. (1999): Satellitenbildauswertung mit künstlichen Neuronalen Netzen zur Umweltüberwachung – Vergleichende Bewertung konventioneller und Neuronaler Netzwerkalgorithmen und Entwicklung eines integrierten Verfahrens. Forschungszentrum Jülich (Hrsg.), Schriftenreihe Umwelt/Environment, Band 15: 163 S.

Kleinschmit, B. & Kim, H. O. (2004): Anwendung sehr hochauflösender Satellitendaten zur urbanen Biotop- und Nutzungstypenkartierung – dargestellt am Beispiel der südkoreanischen Megastadt Seoul. In: Seyfert, E. (Hrsg.): Instrumentarien zur nachhaltigen Entwicklung von Landschaften. Schriftenreihe der DGPF 13: 263-270.

Klonowski, J. (1999): Segmentierung und Interpretation digitaler Bilder mit Markoff-Zufallsfeldern. Deutsche Geodätische Kommission bei der Bayerischen Akademie der Wissenschaften, Reihe C, Heft 492, Verl. d. Bayer. Akad. d. Wiss., München, Zugl.: Diss. Univ. Bonn, 1997.

Koch, B.; Jochum, M.; Ivits, E. & Dees, M. (2003): Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren. Photogrammetrie – Fernerkundung – Geoinformation (3): 195-204.

Kraus, K. & Schneider, W. (1988): Fernerkundung, Band 1: Physikalische Grundlagen und Aufnahmetechnik. Dümmler, Bonn: 291 S.

Kraus, K. (1990): Fernerkundung. Band 2: Auswertung photographischer und digitaler Bilder. Dümmler, Bonn: 310 S.

Kudala, R. (2000): Eye on Quality: Setting Expectations Across the Range of Image Quality. Imaging Notes 15 (3). [http://www.imagingnotes.com/mayjun00/eyeonquality.htm – 14.01.2004]

Lang, S.; Blaschke, T.; Langanke, T.; Kias, U. & Demel, W. (2003): Objektbasierte Ansätze zur halbautomatisierten Fortschreibung von CIR-Luftbild Kartierungen – ein Verfahrensvergleich. GIS – Zeitschrift für Geoinformationssysteme (9): 17-25.

Lang, S. & Langanke, T. (2004): Monitoring von Verbuschungs- und Verwaldungsstadien im Natura 2000-Gebiet Wenger Moor: objektbasierte Bildanalyse und GIS. In: Walz, U.; Lutze, G.; Schultz, A. & Syrbe, R.-U. (Hrsg.): Landschaftsstruktur im Kontext von naturräumlicher Vorprägung und Nutzung – Datengrundlagen, Methoden und Anwendungen. IÖR-Schriften 43: 191-203.

Lang, S.; Schöpfer, E. & Blaschke, T. (2003): Object-specifc change detection based on assisted feature extraction: a case study of an expanding suburban area. Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol XXXIV-7/W9: 93-98.

Lange, U. (2004): Voraussetzungen und Chancen für den operationellen Fernerkundungseinsatz in den Naturschutzverwaltungen eines Landes – Erfahrungen und Erwartungen. [http://www.lup-umwelt.de/de/texte/sara04-ulrich-lange.pdf – 07.06.2004]

Lechtenbörger, C. (2001): Rechnergestützte Bilddatenanalyse im Umweltmonitoring: Zum Einsatz wissensbasierter Klassifikationen und Veränderungsanalysen mit handelsüblicher Fernerkundungssoftware. Univ. Bochum, Diss.: 338 S.

Leser, C. (2002): Operationelle Biotoptypenkartierung mit HRSC-Daten – Probleme und Lösungsansätze. In: Blaschke, T. (Hrsg.): GIS und Fernerkundung: Neue Sensoren – Innovative Methoden. Wichmann, Heidelberg: 88-97.

Leser, C. (2003): Entwicklung operationell einsatzfähiger Methoden zur Biotoptypen-Kartierung anhand hochauflösender HRSC-Daten. Berlin Techn. Univ., Diss.: 160 S. [http://edocs.tu-berlin.de/diss/2003/leser_cornelia.pdf – 18.05.2003]

Lhomme, S.; He, D.-C. & Morin, D. (2003): Errors analysis of IKONOS imagery over an urban environment. In: Jürgens, C. (Ed.): Remote Sensing of urban Areas zugl. Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXIV-7/W9 (CD), Regensburg: 245-247.

Lillesand, T. M. & Kiefer, R. W. (2000): Remote Sensing and Image Interpretation. 4th ed., Wiley & Sons, New York: 724 S.

Löffler, E. (1994): Geographie und Fernerkundung: Eine Einführung in die geographische Interpretation von Luftbildern und modernen Fernerkundungsdaten. 2. Aufl., Teubner, Stuttgart: 251 S.

Lucieer, A. (2004): Uncertainties in segmentation and their visualisation. PhD Thesis Utrecht University, ITC Dissertation 113, Enschede, 174 S. [http://www.itc.nl/library/Papers_2004/phd/lucieer.pdf – 25.11.2004]

Luftbild und Planung (2004): SARA'04 – Umweltbezogenes Raummonitoring mit höchstauflösenden Satellitendaten. [http://www.lup-umwelt.de/de/default_de.htm > Forschung + Entwicklung – 07.06.2004]

Mather, P. M. (1999): Computer processing of remotely-sensed images – an introduction. 2. ed., Wiley, Chichester: 292 S.

Matikainen, L.; Hyyppä, J. & Kaartinen, H. (2004): Automatic detection of changes from laser scanner and aerial image data for updating building maps. In: Proceedings XXth ISPRS Congress, Istanbul, 14.-23. July 2004, Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXV (CD), 6 S.

Mehner, H.; Fairbairn, D.; Csaplovics, E. & Cutler, M. (2004): Transferability of Artificial Neural Networks for Mapping Land Cover of Regional Areas with High Spatial Resolution Imagery. In: Proceedings XXth ISPRS Congress, Istanbul, 14.-23. July 2004, Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. 35 (CD), 6 S.

Meidow, J. (2000): Gemeinsame Segmentierung und Interpretation digitaler Luftbilder mit Hilfe der Bayes-Statistik. Shaker, Aachen: 92 S.

Meinel, G. & Neubert, M. (2003): Bildsegmentier – Ansätze, vergleichende Untersuchungsmethodik und erste Ergebnisse. In: Seyfert, E. (Hrsg.): Vorträge 23. Wissenschaftlich-technische Jahrestagung der DGPF. Publikationen der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation, Band 12, Münster: 187-194.

Meinel, G. & Neubert, M. (2004): A Comparision of segmentation programs for high resolution remote sensing data. Proceedings XXth ISPRS Congress, Istanbul, 14.-23. Juli 2004, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXV-B4: 1097-1102.

Meinel, G.; Neubert, M. & Reder, J. (2001): Pixelorientierte versus segmentorientierte Klassifikation von IKONOS-Satellitenbilddaten – ein Methodenvergleich. Zeitschrift für Photogrammetrie, Fernerkundung und Geoinformation (3): 157-170.

Meinel, G. & Reder, J. (2001): IKONOS-Satellitenbilddaten – ein erster Erfahrungsbericht. In: Kartographische Nachrichten 51 (1): 40-46.

Mesev, V. (2003): Remotely sensed cities – an indroduction. In: Mesev, V. (Ed.): Remotely sensed cities. Taylor & Francis, London: 1-19.

Möller, M. (2002): Untersuchungen zur Modellierung und Analyse höchstauflösender Scannerdaten. In: Blaschke, T. (Hrsg.): GIS und Fernerkundung: Neue Sensoren – Innovative Methoden. Wichmann, Heidelberg: 10-23.

Möller, M. (2003): Urbanes Umweltmonitoring mit digitalen Flugzeugscannerdaten. Wichman, Heidelberg: 126 S.

Morel, J.-M. & Solimini, S. (1995): Variational methods for image segmentation. Birkhäuser, Boston: 245 S.

Müller, M. (2001): Extraktion großflächiger Strukturen aus hochauflösenden panchromatischen Satellitendaten. Akad. Verl.-Ges. Aka, Berlin, zugl. Diss. Univ. Bielefeld: 158 S.

Müller, S.; Feitosa, R.; Mota, G.; da Costa, D.; da Silva, V. & Tanisaki, K. (2003): GEOAIDA Applied to SPOT Satellite Image Interpretation. Proc. URBAN 2003, 2nd GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, May 22-23, Berlin, Germany: 220-224.

MVTec Software (2004): HALCON. [http://www.mvtec.com/halcon – 30.01.2004]

Naveh, Z. & Liebermann, A. (1994): Landscape ecology – Theory and application. 2nd ed., Springer, Berlin, Heidelberg, New York: 360 S.

Neer, J. (1999): High Resolution Earth Imaging from Space. A Commercial Perspective on a Changing Landscape. ISPRS Highlights 4 (2): 20-27.

Neubert, M. (2001): Segment-based analysis of high resolution satellite and laser scanning data. In: Hilty, L. M. & Gilgen, P. W. (Eds.): Sustainability in the Information Society. Proceedings of the 15th International Symposium Informatics for Environmental Protection, Zurich, October 10-12, 2001. Metropolis, Marburg: 379-386.

Neubert, M. & Blaschke, T. (2004): Segmentierung von Fernerkundungsdaten als Grundlage zur Ableitung von Landschaftsstrukturmaßen. In: Walz, U.; Lutze, G.; Schultz, A. & Syrbe, R.-U. (Hrsg.): Landschaftsstruktur im Kontext von naturräumlicher Vorprägung und Nutzung – Datengrundlagen, Methoden und Anwendungen. IÖR-Schriften 43: 91-108.

Neubert, M. & Meinel, G. (2002a): Segmentbasierte Auswertung von IKONOS-Daten – Anwendung der Bildanalyse-Software eCognition auf unterschiedliche Testgebiete. In: Blaschke, T. (Hrsg.): Fernerkundung und GIS: Neue Sensoren – innovative Methoden. Wichmann, Heidelberg: 108-117.

Neubert, M. & Meinel, G. (2002b): Fortführung von Geobasisdaten durch die segmentbasierte Auswertung von IKONOS-Daten – erste Ergebnisse. In: Strobl, J.; Blaschke, T. & Griesebner, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung XIV. Beiträge zum AGIT-Symposium Salzburg 2002, Wichmann, Heidelberg: 403-408.

Neubert, M. & Meinel, G. (2003a): Vergleich von Segmentierungsprogrammen für Fernerkundungsdaten. In: Strobl, J.; Blaschke, T. & Griesebner, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung XV. Wichmann, Heidelberg: 323-329.

Neubert, M. & Meinel, G. (2003b): Evaluation of segmentation programs for high resolution remote sensing applications. In: Schroeder, M.; Jacobsen, K. & Heipke, C. (Eds.): Procedings of the Joint ISPRS/EARSeL Workshop „High Resolution Mapping from Space 2003“, Hannover, Germany, October 6-8, 2003 (CD): 8 S.

Oleszczuk, R. (2000): Eye on Quality: To DRA or not to DRA. Imaging Notes 15 (5). [http://www.imagingnotes.com/sepoct00/septeye.htm – 14.01.2004]

Openshaw, S. & Openshaw, C. (1997): Artificial intelligence in geography. Wiley, Chichester: 329 S.

ORBIMAGE (2004): ORBIMAGE Selected as NGA's Second NextView Provider. [http://www.orbimage.com/news/releases/09-30A-04.html – 29.11.2004]

Pal, N. R. & Pal, S. K. (1993): A review on image segmentation techniques. Pattern Recognition 26: 1277-1294.

Petire, G. (2002): Optical Imagery from Airborne & Spaceborne Platforms: Comparisons of Resolution, Coverage & Geometry for a Given Ground Pixel Size. GeoInformatics 5 (1): 28-35.

Petrini-Monteferri, F.; Steinnocher, K.; Hoffmann, C.; Engelhardt, K. & Koren, G. (2001): IKONOS-Satellitendaten für Stadtinformationssysteme – Fallbeispiel Klagenfurt. In: Strobl, J.; Blaschke, T. & Griesebner, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung XIII. Wichmann, Heidelberg: 356-361.

Pilz, H. & Strobl, J. (2002). Versiegelungsanalyse auf Basis digitaler Farborthofotos mittels objektorientierter Bildverarbeitung. In: Blaschke, T. (Hrsg., 2002): Fernerkundung und GIS. Wichmann, Heidelberg: 159-168.

Reich, M. & Thiel, K.-H. (2002): Vergleich von Digitalen Höhenmodellen. In: Seyfert, E. (Hrsg.): Zu neuen Märkten – auf neuen Wegen – mit neuer Technik. Vorträge 22. Wiss.-techn. Jahrestagung der DGPF 24.-26. September 2002 in Neubrandenburg.

Publikationen der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation, Band 11: 345-353.

Richards, J. A. (1993): Remote sensing digital image analysis – an introduction. 2nd ed. Springer, Berlin, Heidelberg, New York: 340 S.

Richards, J. A. & Jia, X. (1999): Remote sensing digital image analysis – an introduction. 3rd ed. Springer, Berlin, Heidelberg, New York: 363 S.

Richter, R. (1996): A spatially adaptive fast atmospheric correction algorithm. International Journal of Remote Sensing 17 (6): 1201-1214.

Richter, R. (2003): Atmospheric / Topographic Correction for Satellite Imagery. DLR report DLR-IB 564-01/03, Wessling, Germany.

Ruefenacht, B.; Vanderzanden, D.; Morrison, M. & Golden, M. (2002): New Technique for Segmenting Images. Softwaredokumentation: 14 S.

Schenk, T. (1999): Digital Photogrammetry. TerraScience, Laurelville: 428 S.

Scherfke, M. (2001): Die Nutzung der Biotoptypen- und Landnutzungskartierung aus CIR-Luftbildern. Materialien zu Naturschutz und Landschaftspflege 23, Sächsisches Landesamt für Umwelt und Geologie, Dresden: 17-19.

Schiewe, J. (2002a): Segmentation of high-resolution remotely sensed data – concepts, applications and problems. Int. Arch. of Photogrammetry and Remote Sensing 34(4): 380-385.

Schiewe, J. (2002b): Konzeption einer Vernetzung von Segmentierungs- und Klassifizierungsverfahren. In: Seyfert, E. (Hrsg.): Zu neuen Märkten – auf neuen Wegen – mit neuer Technik. Vorträge 22. Wiss.-techn. Jahrestagung der DGPF 24.-26. September 2002 in Neubrandenburg. Publikationen der DGPF 11: 405-412.

Schiewe, J. & Tufte, L. (2002): Potenzial regionen-basierter Verfahren für die integrative Auswertung von GIS- und Fernerkundungsdaten. In: Blaschke, T. (Hrsg.): GIS und Fernerkundung: Neue Sensoren – Innovative Methoden. Wichmann, Heidelberg: 42-52.

Schlüter, M. (2000): Fortführung von Geoinformationssystemen anhand direkt aufgezeichneter digitaler Bilddaten. Mittlungen des BA f. Kartographie u. Geodäsie 14, Verlag d. BA f. Kartographie u. Geodäsie, Frankfurt a. M.: 99 S.

Schneider, T.; de Kok, R.; Buck, A. & Manakos, I. (2000): Objektorientierte Bildanalyse – Paradigmenwechsel in der thematischen Auswertung von Erdbeobachtungsdaten? In: Lehrstuhl für Landnutzungsplanung und Naturschutz der TU München (Hrsg.): Aktuelle Forschungsberichte. Festschrift zur Emeritierung von Prof. Dr. U. Ammer, Freising: 234-258.

Schouten, T. E. & klein Gebbinck, M. S. (1995): Quality measures for image segmentation using generated images. Proceedings Image and Signal Processing for Remote Sensing II (Washington: SPIE): 411-422.

Schowengerdt, R. A. (1997): Remote sensing – models and methods for image processing. 2. Ed., Academic Press, San Diego: 522 S.

Schwarz, M.; Steinmeier, Ch. & Waser, L. (2002): Detection of storm losses in the Alpine forest areas by different methodical approaches using high-resolution satellite data. In: Bégni, G. (Ed.): Observing our environment from space: New solutions for a new millenium. Lisse, Balkema: 251-257.

Seiler, U. (2003): Aktualisierung und Fortführung der Biotop- und Nutzungstypenklassifikation durch segmentbasierte Auswertung (eCognition) von IKONOS-Daten. Diplomarbeit, Technische Universität Dresden, Institut für Geographie, unveröff.: 94 S.

Seiler, U.; Neubert, M. & Meinel, G. (2004): Automatisierte Erfassung von Biotop- und Nutzungstypen durch segmentbasierte Klassifikation von IKONOS-Satellitenbilddaten. Naturschutz und Landschaftsplanung 36 (4): 101-106.

Sell, E.; Grubinger, J. & Eisl, M. M. (2004): Earth Observation for Natura2000+ – Eine Bottom-up-Studie – Ergebnisse aus Deutschland und Österreich. In: Strobl, J.; Blaschke, T. & Griesebner, G. (Hrsg.): Angewandte Geoinformatik 2004. Beiträge zum 16. AGIT-Symposium Salzburg. Wichmann, Heidelberg: 626-631.

SLfUG (Sächsisches Landesamt für Umwelt und Geologie, 2001): Die Nutzung der Biotoptypen- und Landnutzungskartierung aus Color-Infrarot-(CIR-)Luftbildern. Materialien zu Naturschutz und Landschaftspflege Nr. 23. 78 S.

SLfUG (Sächsisches Landesamt für Umwelt und Geologie, 1994): Biotoptypen- und Landnutzungskartierung aus CIR-Luftbildern – Interpretationsschlüssel (unveröffentlicht).

SpaceImaging (2003a): IKONOS Product Guide. [http://www.spaceimaging.com/whitepapers_pdfs/IKONOS_Product_Guide.pdf – 01.12.2003]

SpaceImaging (2003b): IKONOS Relative Spectral Response and Radiometric Calibration Coefficients. [http://www.spaceimaging.com/products/ikonos/spectral.htm – 01.12.2003]

Steinnocher, K. (1997): Texturanalyse zur Detektion von Siedlungsgebieten in hochauflösenden panchromatischen Satellitenbilddaten. In: Dollinger, F. & Strobl, J. (Hrsg.): Angewandte geographische Informationsverarbeitung IX. Beiträge zum GIS-Symposium vom 2.-4. Juli 1997, Salzburger Geographische Materialien, Heft 26: 143-152.

Steinnocher, K. (1999): Adaptive Fusion of Multisource Raster Data Applying Filter Techniques. Int. Arch. of Photogrammetry and Remote Sensing 32, Part 7-4-3 W6: 108-115.

Stewart, D.; Blacknell, D.; Blake, A.; Cook, R. & Oliver, C. (2000): An optimal approach to SAR image segmentation and classification. IEEE Trans. on Radar, Sonar and Navigation 147, June 2000: 25 S. [http://www.infosar.co.uk/pub/PS-files/iee00.ps.gz – 23.07.2003]

Tatem, A. J.; Lewis, H. G.; Atkinson, P. M. & Nixon, M. S. (2001): Multiple-class land cover mapping at the sub-pixel scale using a Hopfield neural network. International Journal of Applied Earth Observation and Geoinformation 3 (2): 184-190.

Theobald, E. G. (1998): Eye on Quality: When is a Meter a Meter? Imaging Notes 13 (2): 5. [http://www.imagingnotes.com/sepoct98/9eyeon.html – 21.05.2003]

Tobler, W. R. (1970). A Computer Model Simulating Urban Growth in the Detroit Region. Economic Geography 46: 234-240.

Tomlin, D. (1990): Geographic Information Systems and Cartographic Modelling. Prentice-Hall, Englewood Cliffs, New Jersey: 249 S.

Toutin T. (2001): Geometric Processing of IKONOS Geo Images with DEM. In: Proceedings ISPRS Joint Workshop „High Resolution Mapping from Space“, Hannover: 264-272.

Toutin, T. & Cheng, P. (2000): Demystification of IKONOS. Earth Observation Magazine 9 (7): 17-21.

Townshend, J. R. G.; Huang, C.; Kalluri, S. N. V.; Defries, R.S.; Liang, S. & Yang, K. (2000): Beware of per-pixel characterization of land cover. Int. J. Remote Sensing 21 (4): 839-843.

Tripp, B. (1995): EarlyBird Satellite Expected to Sharpen Focus of Commercial Remote Sensing Industry. In: EOM 4 (10) [http://www.eomonline.com/Common/Archives/Oct95/tripp.htm – 27.02.2003]

Troll, C. (1939): Luftbildplan und ökologische Bodenforschung. Zeitschrift d. Ges. f. Erdkunde 74: 241-298.

Tufte, L. (2003): Automatisierte Bestimmung von Bearbeitungsskalen für die multiskalige Auswertung von hoch auflösenden Fernerkundungsdaten. Photogrammetrie – Fernerkundung – Geoinformation 5: 383-394.

Turner, M. G. & Gardner, R. H. (1991): Quantitative Methods in Landscape Ecology. Springer, Berlin, Heidelberg, New York: 536 S.

Turner, M. G.; Gardner, R. H. & O`Neill, R. V. (2001): Landscape Ecology in Theory and Practice – Pattern and Process. Springer, Berlin, Heidelberg, New York: 404 S.

van der Sande, C. J. (2001): River Flood Damage Assessment Using IKONOS Imagery. Natural Hazards Project-Floods. Space Applications Institute, Joint Research Centre, European Commission, Ispra: 86 S.

von Ferber, C. & Wörgötter, F. (2000): Cluster update algorithm and recognition. Phys. Rev. E 62, Nr. 2, Part A: 1461-1464.

Vozikis, G.; Fraser, C. & Jansa, J. (2003): Alternative Sensor Orientation Models for High Resolution Satellite Imagery. In: Seyfert, E. (Hrsg.): Auf dem Weg zu operationellen Prozessketten in Photogrammetrie, Fernerkundung und Geoinformation. Vorträge 23. Wissenschaftlich-technische Jahrestagung der DGPF. Publikationen der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation, Band 12, Münster: 179-186.

Walter, V. (2004): Object-based Evaluation of LIDAR and multispectral data for automatic change detection in GIS databases. In: Proceedings XXth ISPRS Congress, Istanbul, 14.-23. July 2004, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. 35 (CD), 6 S.

Walz, U. (2001): Charakterisierung der Landschaftsstruktur mit Methoden der Satelliten-Fernerkundung und der Geoinformatik. Logos, Berlin: 204 S.

Walz, U. (2002): Remote sensing and digital image processing. In: Bastian, O. & Steinhardt, U. (Eds.): Development and Perspectives of Landscape Ecology. Kluwer, Dordrecht, Boston, London: 282-294.

Weiers, S.; Bock, M.; Wissen, M.; Rossner, G. (2004): Mapping and indicator approaches for the assessment of habitats at different scales using remote sensing and GIS methods. Landscape and Urban Planning 67: 43-65.

Wilkinson, G. G. (1999): Recent Developments in Remote Sensing Technology and the Importance of Computer Vision Analysis Techniques. In: Kanellopoulos, I.; Wilkinson, G. G. & Moons, T. (Eds): Machine Vision and Advanced Image Processing in Remote Sensing. Springer, Berlin, Heidelberg, New York: 5-11.

Woodcock, C. E. & Strahler, A. H. (1987): The factor of scale in remote sensing. Remote Sensing of Environment 21: 311-332.

Woodcock, C. E. & Harward, V. J. (1992): Nested-hierarcical scene models and image segmentation. International Journal of Remote Sensing 13: 3167-3187:

Yang, L.; Albregtsen, F.; Lønnestad, T. & Grøttum, P. (1995): A Supervised Approach to the Evaluation of Image Segmentation Methods. In: Proceedings CAIP, Prague, Czech Republic: 759-765.

Zhang, Y. (2002). Problems in the Fusion of Commercial High-Resolution Satellite Images as well as Landsat 7 Images and Initial Solutions. Int. Arch. of Photogrammetry and Remote Sensing 34, Part 4 (CD): 6 S.

Zhang, Y. J. (1996): A survey on evaluation methods for image segmentation. Pattern Recognition 29 (8): 1335-1346.

Zhang, Y. J. & Gerbrands, J. J. (1994): Objective and quantitative segmentation evaluation and comparison. Signal Processing 39 (1-2): 43-54.

Zhu, S. C. & Yuille, A. (1996): Region Competition: Unifying Snakes, Region Growing and Bayes / MDL for Multiband Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence 18: 884-900.

Zölitz-Möller, R. (2000): Das ATKIS-DLM 25/1 aus Sicht der Nutzer im Umweltbereich. DVW-Schrifenreihe, Bd. 39/2000: 153-167.

Zölitz-Möller, R. (2002): Geobasisdaten für die Planung? Standort – Zeitschrift für angewandte Geographie 3/2002: 110-114.

„So eine Arbeit wird eigentlich nie fertig, man muss sie für fertig erklären, wenn man nach Zeit und Umständen das möglichste getan hat."

JOHANN WOLFGANG VON GOETHE (1749-1832)

Danksagung

Diese Forschungsarbeit wurde durch die Deutsche Forschungsgemeinschaft im Rahmen des Projektes „Nutzungsmöglichkeiten neuester, hoch auflösender Satellitenbilddaten für die Raumplanung" (Me 1592/1-2) gefördert.

Für seine Betreuung über den gesamten Zeitraum der Promotion sowie seine Funktion als Erstgutachter bedanke ich mich bei Herrn Prof. Elmar Csaplovics (Technische Universität Dresden).

Herrn Dr. Thomas Blaschke (Universität Salzburg) danke ich für die Übernahme des Zweitgutachtens sowie seine hilfreichen Tipps zum Inhalt dieser Arbeit.

Meinem Betreuer am Leibnitz-Institut für ökologische Raumentwicklung e. V. (IÖR), Dresden – Herrn Dr. Gotthard Meinel – bin ich zu besonderem Dank verpflichtet. Im Rahmen der intensiven Zusammenarbeit wurde eine Reihe innovativer Untersuchungen durchgeführt. Zudem entstanden zahlreiche gemeinsame Publikationen.

Danken möchte ich auch den zahlreichen weiteren Kollegen des IÖR, die während meiner Promotionszeit immer für eine angenehme Arbeitsatmosphäre sorgten und mit Rat und Tat zur Seite standen. Für ihre umfangreiche Mitarbeit in diesem Forschungsprojekt danke ich insbesondere Frau Ulrike Seiler sowie Herrn Thomas Schulz. Für die Durchsicht des Manuskripts danke ich Frau Gisela Richter.

Für die gute Zusammenarbeit und die Bereitstellung des Laserscanner-DGM's der Sächsischen Schweiz sei dem Institut für Photogrammetrie und Fernerkundung der Technischen Universität Dresden gedankt.

Für die fruchtbare Kooperation in Bezug auf die atmosphärische und topographische Korrektur von IKONOS-Daten danke ich Herrn Dr. Rudolf Richter (DLR) sowie Herrn Andreas Keutterling (Geosystems). Dank gebührt weiterhin Herrn Dr. Thierry Toutin *(Canada Centre of Remote Sensing)* für die Orthorektifizierung der IKONOS-Szene der Sächsischen Schweiz.

Für die Möglichkeit der Nutzung der PCI-Geomatica-Software im Rahmen der Bildfusion sei Frau Dr. Karin Engelhardt (CGISystems) gedankt. Herrn Dr. Klaus Steinnocher (Austrian Research Center) danke ich für die Bereitstellung der von ihm entwickelten Software zur *Adaptive Image Fusion*.

Für die Zusammenarbeit im Rahmen des Vergleiches verschiedener Segmentierungsprogramme bedanke ich mich bei Frau Dr. Corinna Prietzsch (Infoterra), Herrn Prof. Chris Oliver (InfoSAR), Herrn Dr. Christian von Ferber (Universität Freiburg) sowie Herrn Dr. Lothar Hermes (Universität Bonn). Für die Bereitstellung der Software SEQ-Tool sei Herrn Dr. Rolf Lessing und Herrn Sören Haubrock (DELPHI IMM) gedankt.

Viele Präsentationen und Gespräche auf wissenschaftliche Veranstaltungen haben diese Arbeit bereichert. Ich bin dankbar für all die erhaltenen Anregungen und Hinweise. Viele weitere, hier nicht namentlich genannte Personen und Unternehmen, die mir freundlicherweise Daten, Softwares oder Publikationen kostenfrei zur Verfügung gestellt haben, trugen auf diese Weise zum Gelingen dieser Arbeit bei.

Für den Rückhalt während der Anfertigung dieser Arbeit danke ich meiner Familie, meinen Eltern sowie meinen Freunden. Mein besonderer Dank gilt meiner Partnerin Manja Slodowski für ihre verständnisvolle Unterstützung sowie meinen Kindern Hannah und Julius.

Dresden, am 14. Oktober 2005 Marco Neubert