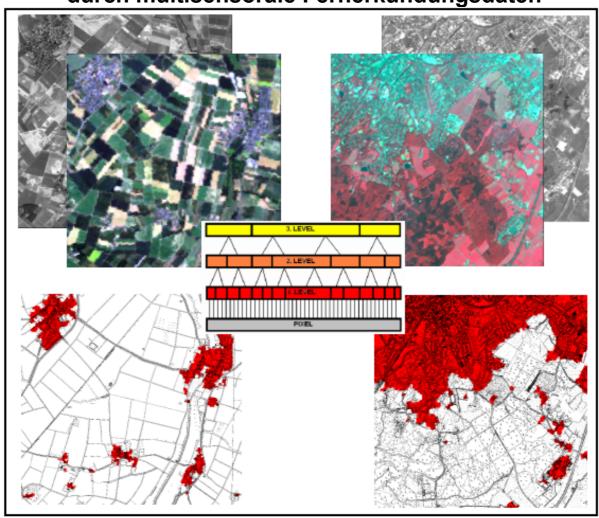
gi-reports@igf



Band 3

Institut für Geoinformatik und Fernerkundung

Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten



Daniel Tomowski, Manfred Ehlers, Ulrich Michel und Guido Bohmann

Herausgeber:

Institut für Geoinformatik und Fernerkundung (IGF)

<u>Autoren:</u> Daniel Tomowski, Manfred Ehlers, Ulrich Michel

und Guido Bohmann

Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten

Anschrift:

Institut für Geoinformatik und Fernerkundung

Seminarstr. 19 a/b

49069 Osnabrück

Telefon: 0541/969-4591

Telefax: 0541/969-4561

Email: sekretariat@igf.uni-osnabrueck.de

Internet: http://www.igf.uni-osnabrueck.de

ISSN 1863-0103

Auflage 1, Osnabrück 2006

Vorwort

Obwohl die vorgelegte Ausgabe der *gi-reports* bereits den dritten Band der Forschungsreihe darstellt, kann man ihn gleichzeitig als ersten Band einer neuen Serie ansehen. Der bisherige Herausgeber, das Forschungszentrum für Geoinformatik und Fernerkundung (FZG) der Hochschule Vechta, existiert nicht mehr. Mit der Versetzung der Geoinformatik an die Universität Osnabrück ist das FZG nach einer Zwischenlösung in das im November 2005 gegründete Institut für Geoinformatik und Fernerkundung (IGF) aufgegangen. Damit musste auch der Name der Reihe an die neuen Gegebenheiten angepasst werden: dies ist quasi der erste Band der *gi-reports@igf*. Trotz neuer ISSN-Nummer, setzen wir damit die Tradition der *gi-reports@fzg* nahtlos fort.

Wie schon das FZG begreift das IGF die Geoinformatik als neue wissenschaftliche Disziplin, die in Zukunft an Hochschulen und Universitäten den innovativen und integrativen Ansatz aus Geowissenschaften, Geodäsie und Informatik in Forschung und Lehre immer stärker vertreten sein wird. Das IGF widmet sich dabei jetzt auch der Lehre in Geoinformatik und wird im Wintersemester dieses Jahres mit einem Bachelor- und Master-Angebot an der Universität Osnabrück beginnen.

Noch eine weitere Neuigkeit bietet dieser Band: er erscheint erstmalig nur als digitale Ausgabe. Im Zuge der zunehmenden Digitalisierung unserer Gesellschaft findet es das IGF an der Zeit, wissenschaftliche Publikationen nicht mehr in gedruckter Form anzubieten. Vorteile sind nicht nur niedrigere Kosten und schnellere Veröffentlichung sondern auch die Möglichkeit, Farbabbildungen großzügig in den Text einbinden zu können.

Mit der vorgelegten Arbeit berichten wir über ein Projekt, welches noch zu 'FZG-Zeiten' begonnen wurde. In Zusammenarbeit mit dem Ministerium für Verkehr, Energie und Landesplanung des Landes Nordrhein-Westfalen wurde die Einsatzmöglichkeit multisensoraler Satellitendaten zur automatischen Detektion von Siedlungsgebieten untersucht und erfolgreich abgeschlossen. Das Projekt führte nicht nur zu einer Anzahl von Veröffentlichungen und Vorträgen sondern auch zu einer Diplomarbeit (D. Tomowski), die in wesentlichen Zügen in diesen Forschungsbericht eingeflossen ist.

Wir sind froh, dass wir mit den *gi-reports* die Publikationsmöglichkeiten in der Geoinformatik verbessert haben. Über ein Feedback von interessierten Lesern und der *Scientific Community* würden wir uns sehr freuen. Weitere Informationen zum IGF entnehmen Sie bitte der folgenden Internet-Adresse: www.igf.uni-osnabrueck.de.

Osnabrück, im Mai 2006

Prof. Dr. Manfred Ehlers

Direktor, IGF

A Inhaltsverzeichnis

А	Inhaltsverzeichnis	l		
В	Abbildungsverzeichnis	IV		
С	Tabellenverzeichnis	VII		
D	Formelverzeichnis			
1	Einführung	1		
1.1	Anlass	1		
1.2	Ziele und Aufbau der Arbeit	1		
2	Siedlungsflächenentwicklung	4		
2.1	Situation in Deutschland	4		
2.2	Ursachen des Flächenverbrauchs	6		
2.3	Auswirkungen des Flächenverbrauchs	8		
2.4	Herkömmliche Erfassungsmethoden und Fernerkundung	12		
3	Theoretische Grundlagen	16		
3.1	Fernerkundung	16		
3.1.1	Physikalische Grundlagen	16		
3.1.2	Verwendete Aufnahmesysteme	18		
3.1.3	Klassifikationsstrategien	22		
3.2	Segmentierungsverfahren	25		
3.2.1	Punkt-basierte Segmentierungsverfahren	26		
3.2.2	Regionen-basierte Segmentierungsverfahren	28		
3.2.3	Kanten-basierte Segmentierungsverfahren	31		
3.2.4	Segmentierungsverfahren in eCognition	33		

3.3	Texturorientierte Verfahren	38
3.3.1	Übersicht über texturorientierte Verfahren	39
3.3.2	GLC-Matrizen	40
3.4	Verfahren zur Genauigkeitsabschätzung	43
3.4.1	Konfusionsmatrizen	43
3.4.2	Kappa-Koeffizient	45
3.5	Bildanalysesoftware eCognition	46
3.5.1	Grundlegende Möglichkeiten	46
3.5.2	Objektorientierte Klassifikation	49
3.5.3	Verwendete Klassifikationsmerkmale	52
4	Methode	55
4.1	Ablaufschema und Datengrundlage	55
4.2	Fallbeispiel 1: SPOT und LANDSAT	57
4.2.1	Vorüberlegungen	57
4.2.2	Segmentierung	59
4.2.3	Generelle Vorgehensweise bei der Klassifikation	61
4.2.4	Klassifikation der dritten Segmentierungsebene	62
4.2.5	Klassifikation der zweiten Segmentierungsebene	69
4.2.6	Klassifikation der ersten Segmentierungsebene	76
4.2.7	Letzte Arbeitschritte zur Erzeugung der Siedlungsmaske	80
4.3	Fallbeispiel 2: KOMPSAT und ASTER	86
4.3.1	Vorüberlegungen	87
4.3.2	Anpassungen der Verfahrens	89
5	Auswertung der Ergebnisse	94
5.1	Auswertung des ersten Fallbeispiels	94
5.1.1	Visuelle Interpretation	95
5.1.2	Statistische Auswertung	96

5.2	Auswertung des zweiten Fallbeispiels	97
5.2.1	Visuelle Interpretation	99
5.2.2	Statistische Auswertung	99
O.L.L	Cialibricano nacionalig	00
5.3	Vergleich und Zusammenfassung	100
6	Diskussion der Ergebnisse	102
6.1	Probleme	102
6.1.1	Vergleichsdaten	102
6.1.2	Unterschiedliche Aufnahmezeitpunkte	103
6.1.3	Siedlungsflächen geringer Größe und Vegetation	104
6.1.4	Verfahrens- und softwarebedingte Einschränkungen	106
6.2	Vorteile	107
6.2.1	Verbesserungen im Vergleich zu pixelbasierten Verfahren	107
6.2.2	Grundlage für Landnutzungsklassifizierungen	107
6.2.3	Erkennen von zusammenhängenden Siedlungsstrukturen	108
6.2.4	Übertragbarkeit auf KOMPSAT- und ASTER-Daten	108
6.2.5	Kostenersparnis	109
6.3	Resümee	110
7	Zusammenfassung und Ausblick	111
8	Literaturverzeichnis	113

B Abbildungsverzeichnis

Abbildung 2.1:	Entwicklung der Siedlungsfläche, Bevölkerung und	
	Erwerbstätigen von 1960 bis 1996	5
Abbildung 2.2:	Bodenpreise und Bauklassen einer kontinental-	
	europäischen Großstadt	7
Abbildung 2.3:	Schematische Darstellung der Wasserhaushalts-	
	komponenten urbaner Böden	10
Abbildung 3.1:	Strahlungsenergie der Sonne, atmosphärische	
	Durchlässigkeit und elektromagnetisches Spektrum	17
Abbildung 3.2:	Schematische Darstellung der Funktionsweise eines	
	LANDSAT-Scanners	18
Abbildung 3.3:	Schematische Darstellung der Funktionsweise	
	eines optoelektronischen Scanners	20
Abbildung 3.4:	"Salz und Pfeffer" – Klassifizierung und Ergebnis einer	
	Segmentierung	25
Abbildung 3.5:	Bimodale Verteilung in einem Histogramm und	
	Segmentierungsschwelle	26
Abbildung 3.6:	Beispiel für eine Äquidensitendarstellung	27
Abbildung 3.7:	Prinzip des "region growing"	29
Abbildung 3.8:	Rekursive Aufteilung beim "region splitting"	30
Abbildung 3.9:	Prinzip des "split and merge"	31
Abbildung 3.10:	Segmentierung mit dem Watershed-Algorithmus	32
Abbildung 3.11:	Hierarchisches Netzwerk von Bildobjekten	33
Abbildung 3.12:	Bildausschnitte einer SPOT-Szene mit starker Textur	
	und mit schwacher Textur	39
Abbildung 3.13:	Rastermatrix und mögliche Kombinationen von	
	Grauwertpaaren	41
Abbildung 3.14:	Symmetrische GLC-Matrizen für vier Richtungen	41
Abbildung 3.15:	Dialogfeld multiskalige Segmentierung	47
Abbildung 3.16:	Vierfache und achtfache Nachbarschaft	48
Abbildung 3.17:	Zugehörigkeitsfunktion in eCognition	50
Abbildung 4.1:	Ablaufschema einer regionen-basierten Analyse von	
	Fernerkundungsdaten	55
Abbildung 4.2:	SPOT- und LANDSAT-Aufnahme des ersten Test-	

	gebietes	57
Abbildung 4.3:	Erste Probeklassifikation von Siedlungsflächen	58
Abbildung 4.4:	Segmentierung mit unterschiedlichen Einstellungen	60
Abbildung 4.5:	Klassenhierarchie in eCognition	62
Abbildung 4.6:	Merkmale der Klasse "Mögliche Siedlung (3)"	63
Abbildung 4.7:	Zugehörigkeitsfunktion des Merkmals "GLCM	
	Homogeneity, all dir"	63
Abbildung 4.8:	Benutzerdefiniertes Merkmal "LD-RD"	65
Abbildung 4.9:	Benutzerdefiniertes Merkmal "H-V"	66
Abbildung 4.10:	Zugehörigkeitsfunktionen der Merkmale "H-V" und	
	"LD-RD"	66
Abbildung 4.11:	Zugehörigkeitsfunktion des Merkmals "Length/width"	67
Abbildung 4.12:	Benutzerdefiniertes Merkmal "NDVI je Segment"	68
Abbildung 4.13:	Zugehörigkeitsfunktion des Merkmals "NDVI je	
	Segment"	68
Abbildung 4.14:	Merkmale der Klasse "Nicht Siedlung (3)"	68
Abbildung 4.15:	Klassifikationsergebnis der dritten Ebene	69
Abbildung 4.16:	Merkmale der Klasse "Mögliche Siedlung (2)"	70
Abbildung 4.17:	Zugehörigkeitsfunktion zum Merkmal "not Existence	
	of Nicht Siedlung (3) super-objects (1)"	71
Abbildung 4.18:	Zugehörigkeitsfunktion zum Merkmal "Compactness"	71
Abbildung 4.19:	Eliminierte Siedlungsbereiche (Splitterpolygone)	
	innerhalb von Siedlungen	72
Abbildung 4.20:	Merkmale der Klasse "Mögliche Siedlung	
	eingeschlossene Segmente (2)"	73
Abbildung 4.21:	Zusätzliche Zugehörigkeitsfunktion des Merkmals	
	"GLCM Homogeneity, all dir"	73
Abbildung 4.22:	Zugehörigkeitsfunktion des Merkmals "Relative border	
	to Mögliche Siedlung (2) neighbor objects"	74
Abbildung 4.23:	Structure group zur Fusion von Segmenten	75
Abbildung 4.24:	Segmentierung des zweiten Level vor und nach einer	
	Fusion	75
Abbildung 4.25:	Klassifikationsergebnis der zweiten Ebene.	76
Abbildung 4.26:	Merkmale der Klasse "Mögliche Siedlung einge-	
	schlossene Segmente aus Level 1 (1)"	77

Abbildung 4.27:	Merkmale der Klasse "Mögliche Siedlung einge-	
	schlossene Segmente aus Level 2 (1)"	78
Abbildung 4.28:	Klassifikationsergebnis der ersten Ebene	79
Abbildung 4.29:	Automatisierung der Arbeitschritte im Protokolleditor	79
Abbildung 4.30:	Beispiele für Fehlklassifizierungen	80
Abbildung 4.31:	Benutzerdefiniertes Merkmal "Varianz DN je Segment"	81
Abbildung 4.32:	Modifizierte Klassenhierarchie	82
Abbildung 4.33:	Merkmale der Klasse "Siedlung" im neu erzeugten	
	"Level Merge"	82
Abbildung 4.34:	Zugehörigkeitsfunktion des benutzerdefinierten	
	Merkmals "Varianz DN je Segment"	83
Abbildung 4.35:	Merkmal der Klasse "Siedlung" im Endlevel.	84
Abbildung 4.36:	Merkmal der Klasse "Eingeschlossene Siedlungs-	
	flächen" im Endlevel	84
Abbildung 4.37:	Binäre Siedlungsmaske für das erste Testgebiet	85
Abbildung 4.38:	Verfahrenschritte zur Generierung einer binären	
	Maske	86
Abbildung 4.39:	KOMPSAT- und ASTER-Aufnahme des zweiten Test-	
	gebietes	86
Abbildung 4.40:	Anwendung der Einstellungen aus dem ersten Fall-	
	beispiel (Level 1)	87
Abbildung 4.41:	Räumliche Auflösungen von SPOT und KOMPSAT	
	im Vergleich	88
Abbildung 4.42:	Veränderte Zugehörigkeitsfunktion des Merkmals	
	"GLCM Homogeneity, all dir" im dritten Level	89
Abbildung 4.43:	Klassifikationsergebnis der dritten Ebene für das	
	zweite Fallbeispiel	90
Abbildung 4.44:	Veränderte Zugehörigkeitsfunktion des Merkmals	
	"GLCM Homogeneity, all dir" im zweiten Level	90
Abbildung 4.45:	Klassifikationsergebnis der zweiten Ebene für das	
	zweite Fallbeispiel	91
Abbildung 4.46:	Klassifikationsergebnis der ersten Ebene für das	
ALLEID A 47	zweite Fallbeispiel	92
Abbildung 4.47:	Veränderte Zugehörigkeitsfunktion des Merkmals	00
	"Varianz DN je Segment" im Endlevel	92

Abbildung 4.48:	Binäre Siedlungsmaske für das zweite Testgebiet	93
Abbildung 5.1:	Erste Referenzmaske mit TK 25	94
Abbildung 5.2:	Erste binäre Siedlungsmaske mit TK 25	95
Abbildung 5.3:	Zweite Referenzmaske mit TK 25	98
Abbildung 5.4:	Zweite binäre Siedlungsmaske mit TK 25	98
Abbildung 6.1:	KOMPSAT-Bild und veraltete topographische Karte	102
Abbildung 6.2:	Beispiel für eine Generalisierung im dritten Level	104
Abbildung 6.3:	Siedlungsrandbereich mit hohem NDVI-Wert im ersten	
	Level	105
C Tabellenve	erzeichnis	
Tabelle 2.1:	Erhebungsmethoden im Vergleich	15
Tabelle 3.1:	Technische Daten der verwendeten Satelliten-	
	plattformen und Sensoren	22
Tabelle 3.2:	Konfusionsmatrix mit vier Klassen	43
Tabelle 4.1:	Segmentierungseinstellungen in eCognition	60
Tabelle 4.2:	Texturparameter im Vergleich	65
Tabelle 5.1:	Konfusionsmatrix für das erste Testgebiet	96
Tabelle 5.2:	Konfusionsmatrix für das zweite Testgebiet	99
Tabelle 5.3:	Bewertung des Kappa-Koeffizienten	101
D Formelver	zeichnis	
Formel 2.1:	Wasserhaushaltsgleichung	10
Formel 3.1:	Berechnung der Wellenlänge	16
Formel 3.2:	Berechnung der Farbhomogenität	36
Formel 3.3:	Berechnung des Compactnesskriteriums	36
Formel 3.4:	Berechnung des Kantenkriteriums	36
Formel 3.5:	Berechnung der Formhomogenität	37
Formel 3.6:	Homogenität eines Bildobjektes	37
Formel 3.7:	Verschmelzungskostengleichung	37
Formel 3.8:	Verbesserte Verschmelzungskostengleichung	38
Formel 3.9:	Wahrscheinlichkeit eines Grauwertübergangs	42
Formel 3.10:	Inverse Difference Moment (IDM)	42
Formel 3.11:	Berechnung der Gesamtgenauigkeit	44

gi-reports@igf VII

Formel 3.12:	Berechnung der Herstellergenauigkeit	44
Formel 3.13:	Berechnung der Nutzergenauigkeit	45
Formel 3.14:	Kappa-Koeffizient	46
Formel 3.15:	Mittelwert der Grauwerte	52
Formel 3.16:	Standardabweichung der Grauwerte	53
Formel 3.17:	Kompaktheitsgrad	53
Formel 3.18:	Berechnung des Längen-Breitenverhältnisses	53
Formel 4.1:	Benutzerdefiniertes Merkmal "LD-RD"	65
Formel 4.2:	Benutzerdefiniertes Merkmal "H-V"	65
Formel 4.3:	Berechnung des NDVI	67
Formel 4.4:	Grauwertvarianz je Segment	81

gi-reports@igf VIII

1 EINFÜHRUNG

1.1 Anlass

"Hervorgerufen durch die zunehmende Siedlungstätigkeit der Menschen geht immer mehr an natürlichen Bodenressourcen verloren, so daß der Boden zu einem bedrohten und schützenswerten Gut geworden ist." (NETZBAND 1998, S.1). Somit ist es erforderlich, aktuelle Daten über den anthropogenen Flächenverbrauch zu erfassen, um den Ist-Zustand zu dokumentieren und mögliche Strategien zum Schutz des Bodens auf Ihre Wirksamkeit hin zu überprüfen.

"Da sich, - proportional zu der Größe des zu kartierenden Gesamtgebiets -, eine operationelle Registrierung dieser Flächen entsprechend arbeits- und damit auch zeitund kostenintensiv gestaltet, besteht ein dringender Bedarf nach einem automatisierten Erhebungsverfahren." (FORSCHUNGSZENTRUM FÜR GEOINFORMATIK UND
FERNERKUNDUNG 2005, S.4). Dieser Auszug aus dem Tätigkeitsbericht des Forschungszentrums für Geoinformatik und Fernerkundung der Universität Osnabrück
beschreibt die Kernaufgabenstellung des Pilotforschungsprojektes "Landesweite Erfassung der Siedlungsflächen in Nordrhein-Westfalen", aus dem die vorliegende Arbeit entstanden ist. Das Thema der Arbeit "Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten" beschäftigt sich mit der
Frage, inwieweit eine Klassifikation von Siedlungsflächen durch eine objektorientierte
Methode möglich ist.

1.2 Ziele und Aufbau der Arbeit

Da nach Angaben des STATISTISCHEN BUNDESAMTES (2004, S. 2) "Siedlungsund Verkehrsfläche" und "versiegelte Fläche" nicht gleichgesetzt werden dürfen,
muss vor einer weiteren Konkretisierung der Ziele dieser Arbeit eine genaue
Definition des Begriffs "Siedlungsfläche" gegeben werden. Siedlungsfläche wird nach
APEL & HENCKEL (1995, S. 29) als "die für Siedlungs- und Verkehrsfläche
insgesamt in Anspruch genommene Bodenfläche" verstanden, die "neben den
bebauten Grundstücken und den Verkehrsflächen" auch "Betriebsflächen, Sport- und
Spielflächen, Stadtparkanlagen und Friedhöfe" enthält.

Für eine großflächige Erfassung von Siedlungsflächen auf der Grundlage von räumlich hochauflösenden panchromatischen SPOT-Daten (5 m räumliche Auflösung) und geringer auflösenden LANDSAT-Daten (30 m räumliche Auflösung) stellte sich vor Beginn der Arbeiten die Frage, ob die Verwendung pixelbasierter Klassifikationsansätze (siehe dazu auch Kapitel 3.1.3) Erfolg versprechend ist. Nach BLASCHKE et al. (2002, S. 4) erfordern hohe räumliche Auflösungen "eine neue Art der Verarbeitung, die die Betrachtung von einzelnen Pixeln überwindet [...] Anstatt einzelne Pixel aufgrund ihrer spektralen Eigenschaften zu klassifizieren, setzen neue Verfahren auf die Abgrenzung homogener Objekte als Basis für die weitere Bearbeitung".

Vorteile von objektorientierten Klassifikationsverfahren bestehen darin, neben den spektralen Merkmalen weitere Objektmerkmale wie Textur, Form oder Nachbarschaftsbeziehungen während der Klassifikation nutzen zu können. Außerdem wird der sogenannte "Salz und Pfeffer-Effekt" (vgl. Kapitel 3.1.3), der bei pixelbasierten Ansätzen auftreten kann, bei objektorientierten Klassifikationsmethoden vermieden. Unter Berücksichtigung der zu Verfügung stehenden Daten wurde somit als Oberziel dieser Arbeit die Entwicklung eines objektorientierten Klassifikationsverfahrens zur Bestimmung von Siedlungsflächen unter der Verwendung von panchromatischen

Des Weiteren sollen bei der Entwicklung des Klassifikationsverfahrens folgende Teilziele beachtet werden:

SPOT-Daten und multispektralen LANDSAT-Daten festgelegt.

- Es soll durch die Darstellung von Ursachen und Auswirkungen des Siedlungsflächenzuwachses verdeutlicht werden, warum ein fernerkundliches Verfahren zur Erfassung von Siedlungsflächen nötig ist.
- 2. Das Klassifikationsergebnis soll in Form einer binären Siedlungsmaske (Siedlung/Nicht-Siedlung) vorliegen.
- 3. Das Verfahren soll so weit wie möglich automatisiert werden.
- 4. Zur Beurteilung der Qualität sollen die Klassifikationsgenauigkeiten bestimmt werden.

- 5. Es soll überprüft werden, ob das zu entwickelnde Verfahren auch auf panchromatische KOMPSAT-Daten (6,6 m räumliche Auflösung) in Kombination mit multispektralen ASTER-Daten (15 m räumliche Auflösung) übertragbar ist.
- 6. In einer abschließenden Diskussion sollen Vor- und Nachteile des Verfahrens diskutiert und eine Bewertung der definierten Zeile vorgenommen werden.

Zur Entwicklung des objektorientierten Klassifikationsverfahrens wurde in der Arbeit die objektorientierte Bildanalysesoftware eCognition[©] der Firma DEFINIENS in der Version 3.0 eingesetzt. Für Nachbearbeitungen und Georeferenzierungen wurde das Softwarepaket Erdas Imagine[©] 8.7 der Firma LEICA GEOSYSTEMS genutzt. Die Erstellung der Referenzdaten erfolgte mit der Software ArcView 3.2 der Firma ESRI, die statistische Auswertung mit MICROSOFT Excel.

Aufbauend auf der Zielsetzung folgen dieser Einführung (Kapitel 1) sechs weitere Kapitel. Kapitel 2 behandelt die Frage der Ursachen und Auswirkungen des Flächenverbrauchs und beleuchtet die Möglichkeiten, die ein fernerkundliches Erhebungsverfahren im Vergleich zu herkömmlichen Erfassungsmethoden bietet. Das Kapitel 3 geht auf die theoretischen Grundlagen ein, die in der Methode zur Bestimmung von Siedlungsflächen (Kapitel 4) angewandt werden. Kapitel 5 widmet sich der statistischen Auswertung der Klassifikationsresultate und Kapitel 6 dient dem Diskurs der erzielten Ergebnisse. Abschließend werden in Kapitel 7 die Leistungen und Ergebnisse zusammenfassend dargestellt und Ansätze zur Optimierung der Ergebnisse in einem Ausblick angesprochen.

2 SIEDLUNGSFLÄCHENENTWICKLUNG

Ziel dieses Kapitels ist es, in Anlehnung an das erste Teilziel in kurzer Form die Problematik der Siedlungsflächenentwicklung in Deutschland aufzuzeigen, Ursachen und Auswirkungen des Flächenverbrauchs zu ergründen und im Anschluss die Möglichkeiten der Fernerkundung zum Monitoring von Siedlungsflächen im Vergleich zu herkömmlichen Erfassungsmethoden vergleichend darzustellen.

2.1 Situation in Deutschland

Im Jahre 1992 hat sich die internationale Staatengemeinschaft, auf der von den Vereinten Nationen in Rio de Janeiro abgehaltenen Konferenz für Umwelt und Entwicklung, zum Leitbild einer nachhaltigen Entwicklung der Erde bekannt.

Unter "nachhaltiger Entwicklung" wird eine Entwicklung verstanden, "welche den Bedürfnissen der heutigen Generation entspricht, ohne die Möglichkeiten künftiger Generationen zu gefährden, ihre eigenen Bedürfnisse zu befriedigen." (http://de.wikipedia.org/wiki/Nachhaltige_Entwicklung).

Das Ergebnis der Konferenz von Rio de Janeiro, die Agenda 21, ist eine "Verpflichtungserklärung von mehr als 120 Ländern" (GRUPPE VON LISSABON 1997, S. 40), die "sämtliche nur denkbare Umweltprobleme [...] von der Überwindung Armut über Wasser- und Luftprobleme bis zur Biotechnologie und allgemeinem Technologietransfer." (VON WEIZSÄCKER 1997, S. 122) behandelt.

Basierend auf der Konferenz von Rio de Janeiro und des Weltgipfels für Umwelt und Entwicklung im Jahre 2002 in Johannesburg stellte die deutsche Bundesregierung im Frühjahr 2002 die nationale Nachhaltigkeitsstrategie zur umweltgerechten Entwicklung in Deutschland vor.

Eines der sieben prioritären Handlungsfelder in der deutschen Nachhaltigkeitsstrategie ist die Minderung der Flächeninanspruchnahme für Siedlungen und Verkehr. Die Zielsetzung der Bundesregierung sagt aus, dass das Flächenwachstum für die für von Wohnen, Verkehr und Gewerbe in Anspruch genommene Fläche von "129 ha pro Tag im Jahr 2000 auf eine tägliche Zunahme von 30 ha pro Tag im Jahre 2020" (DOSCH & EINIG 2005, S. I) reduziert werden soll.

Zur Verdeutlichung der Problematik soll die bisherige Siedlungsflächenentwicklung in Deutschland einer genaueren Betrachtung unterzogen werden. Abbildung 2.1 zeigt die Entwicklung der Siedlungs- und Verkehrsfläche im Vergleich zur Entwicklung der Bevölkerung und Erwerbstätigen in Deutschland (alte Bundesländer).

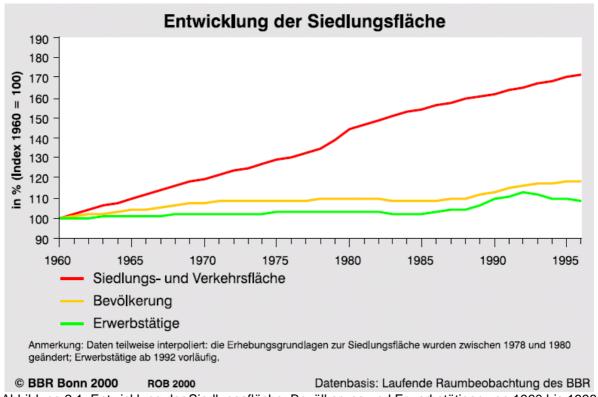


Abbildung 2.1: Entwicklung der Siedlungsfläche, Bevölkerung und Erwerbstätigen von 1960 bis 1996 (BUNDESAMT FÜR BAUWESEN UND RAUMORDNUNG 2000, S. 37).

Die auf der Abszisse dargestellten Zeitintervalle beginnen im Jahr 1960 und werden in Einjahresabständen bis 1996 fortgeführt, die Ordinate zeigt die relative Entwicklung von Siedlungs- und Verkehrsfläche, Bevölkerung und Erwerbstätigen seit 1960 in Prozent an. Festzustellen ist, dass es im Zeitraum von 37 Jahren zu einer Zunahme der Siedlungs- und Verkehrsfläche um ca. 70 Prozent gekommen ist, während dessen der relative Bevölkerungszuwachs ca. 20 Prozent betrug und die Anzahl der Erwerbstätigen lediglich um ca. 10 Prozent stieg. Insgesamt werden nach Angaben des STATISTISCHEN BUNDESAMTES (2004, S. 2) am 31.12.2003 (alte und neue Bundesländer) "45090 km² oder 12,6 % der Bodenfläche Deutschlands (357041 km²) [...] für Siedlungs- und Verkehrzwecke in Anspruch genommen." Wird das Verhältnis von Bevölkerungs- und Erwerbstätigenentwicklung über den gesamten Zeitraum miteinander verglichen, zeigt "die längerfristige Entwicklung einen konstanten, von der Einwohnerentwicklung weitgehend abgekoppelten Trend der Siedlungsflächenzu-

nahme." (BUNDESAMT FÜR BAUWESEN UND RAUMORDNUNG 2000, S. 37). Im folgenden Kapitel sollen die Ursachen für die Zunahme der Siedlungs- und Verkehrsfläche genauer untersucht werden.

2.2 Ursachen des Flächenverbrauchs

Zum einem werden in diesem Kapitel die generellen Ursachen des Flächenverbrauchs in der zweiten Hälfte des letzten Jahrhunderts in Deutschland erläutert und zum anderem wird auf spezielle Entwicklungen in den neunziger Jahren des 20. Jahrhunderts eingegangen.

Nach der Gründung der Bundesrepublik Deutschland im Jahr 1949 und der wirtschaftlichen Erholung in der Folgezeit wuchs der materielle Wohlstand der Gesellschaft. Betrug das Bruttoinlandsprodukt¹ im Jahr 1950 für Westdeutschland 49,69 Milliarden Euro, hatte es im Jahr 1991 die Summe von 1387,1 Milliarden Euro erreicht (http://www.destatis.de/download/d/vgr/biplangereihe.xls).

Das BUNDESAMT FÜR BAUWESEN UND RAUMORDNUNG (2000, S. 38) nennt den "gewachsenen materiellen Wohlstand mit stark gestiegenen individuellen Raumnutzungsansprüchen" als einen Grund für die Siedlungsflächenzunahme, da ein Teil des finanziellen Wohlstandes in den Ausbau von Verkehrs-, Wohnbau- und Gewerbeflächen geflossen ist.

Als weiteren Einflussfaktor für den Flächenverbrauch ist der Boden- bzw. Baulandpreis anzusehen. Nach Angaben des BUNDESAMTES FÜR BAUWESEN UND
RAUMORDNUNG (2000, S. 40) ist "der hohe Bodenpreis mit ein Hauptgrund für die
starke Zunahme und Ausweitung der Siedlungsfläche, vor allem in die regionalplanerisch unerwünschten Zwischenräume der Siedlungsachsen im Umland der Kernstädte.". Abbildung 2.2 stellt die Beziehung des mittleren Bodenpreises einer Stadt und
der Stockwerkszahl (Ordinate) zur räumlichen Entfernung vom Stadtzentrum (Abszisse) für verschiedene Nutzungen (Innenstadtbereich (engl.: CBD²), Wohngebiete
und gewerbliche Nutzung) dar. Es wird deutlich, dass ein Preisgefälle zwischen den
Zentren urbaner Räume und den Vororten bzw. dem ländlichen Raum besteht.
Herrscht im Bereich der City ein hohes Bodenpreisniveau vor, fällt der mittlere Bodenpreis mit der Entfernung vom Stadtzentrum. Dies führt auf Grund des Preisvor-

_

¹ "Wert aller Güter und Dienstleistungen, die innerhalb eines Jahres in einer Volkswirtschaft" (ADAM 1995, S. 65) von deutschen Staatsbürgern erzeugt worden sind.

² City Business District.

teils in den Gebieten zum Flächenverbrauch, in denen ausreichend billiges Bauland vorhanden ist.

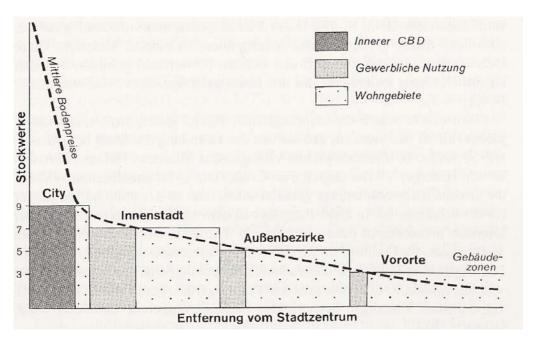


Abbildung 2.2: Bodenpreise und Bauklassen einer kontinentaleuropäischen Großstadt (HOFMEISTER 1999, S. 136).

Ein dritter Grund für den steigenden Flächenverbrauch ist die Suburbanisierung, bei der es sich nach WAGNER (1998, S. 78) um einen Dezentralisierungsprozess handelt, bei der "räumliche Standortverlagerungen von innen nach außen" vonstatten gehen, d. h. Arbeitsplätze, Wohnfunktion und Bevölkerung wandern von den alten Kernstädten in das Umland.

Gründe für diesen Suburbanisierungsprozess sind unter anderem ein Zuwanderungsdruck in die Stadtrandgebiete durch Inländer (Arbeitplatzsuche), ein starker Siedlungs- und Flächendruck aus den Kernstätten (Flächenknappheit), steigende individuelle Flächenansprüche und eine erhöhte individuelle Mobilität, die es ermöglicht längere Strecken zum Arbeitplatz zurückzulegen.

Neben diesen generellen Trends (Wohlstand, Bodenpreis und Suburbanisierung) sind insbesondere in den neunziger Jahren weitere Faktoren hinzugekommen, die das Flächenwachstum forciert haben.

So schließt das UMWELTBUNDESAMT (2004, S. 93) für die neuen Bundesländer und strukturschwache Gebiete nicht aus, dass die "massive Wirtschafts- und Infrastrukturförderung mit Fördermitteln [...] zum überproportionalen Zuwachs- der Siedlungs- und Verkehrsflächen beigetragen" haben.

Des Weiteren ist es nach Angaben des UMWELTBUNDESAMTES (2004, S. 94) in den neunziger Jahren insbesondere bei reinen Wohnbauflächen zu einer deutlichen Steigerung "um mehr als 70 %" gekommen. Die Ursachen hierfür sind ein stetiges Bevölkerungswachstum bei gleichzeitiger Binnenwanderung von Ost nach West, ein Nachholbedarf der neuen Bundesländer in Bezug auf die Wohnform (Wunsch nach Ein- und Zweifamilienhäusern) und letztendlich demographische Gründe, d. h. der Einfluss geburtenstarker Jahrgänge mit dem Wunsch des Eigenheimbaus.

2.3 Auswirkungen des Flächenverbrauchs

Nachdem im vorherigen Kapitel die Ursachen für den Siedlungsflächenzuwachs benannt wurden, sollen in diesem Kapitel die ökonomischen, sozialen und ökologischen Auswirkungen des zunehmenden Flächenverbrauchs skizziert werden.

Die zunehmende Bautätigkeit durch die Ausweisung von Bau- und Gewerbegebieten, sowie der dazugehörige Ausbau von Verkehrsflächen führt nach Auffassung des UMWELTBUNDESAMTES (2004, S. III) zu "ständig wachsenden Fixkosten für die Instandhaltung und den Betrieb dieser Infrastruktur [...], die immer schlechter ausgenutzt" wird. Öffentliche Haushalte, Wirtschaft und private Haushalte müssen immer mehr Geld Instandhaltung ausgeben: So weist B. das zur Z. BUNDESMINESTERIUM FÜR VERKEHR, BAU- UND WOHNUNGSWESEN (2003, S. 2) im Bundesverkehrswegeplan 2003 eine Steigerung der Bestandsinvestition für Schienenwege, Bundesfernstraßen und Bundeswasserstraßen von "46 % (Bundesverkehrswegeplan 92) auf nahezu 56 %" der Gesamtinvestitionen (82,7 Milliarden Euro) aus. Dies bedeutet, dass mehr Geld in die Instandhaltung von Infrastruktur als in deren Ausbau investiert wird. Die Fixkosten steigen.

Die sozialen Auswirkungen des Flächenverbrauchs hängen eng mit dem Suburbanisierungsprozess (vgl. Kapitel 2.2) zusammen. Die beschriebene Verlagerung der Wohnfunktion in das Umland führt zu sozialer Entmischung in den Städten und der Entstehung von Problemquartieren (siehe dazu auch TRAPPMANN 2004, S. 24). Des Weiteren müssen bei "deutlich verringerter Bevölkerungsdichte [...] die Infrastrukturen von immer weniger Menschen getragen werden" (UMWELTBUND-ESAMT 2004, S. III). Resultat sind Wohnungsleerstände und der Verfall von Bausubstanz (Beispiel: neue Bundesländer), wodurch der von TRAPPMAN beschriebene Effekt wiederum verstärkt wird.

Weiterhin hat der Flächenverbrauch und die damit einhergehende Flächenversieglung unmittelbare Auswirkungen auf den Lebensraum des Menschen. So steht eine hohe Versieglung meist in einem Missverhältnis zwischen Einwohnerzahl und Freiflächen. "Die Aneinanderreihung von Gebäuden, häufig nur durch Asphaltoder Betonflächen unterbrochen, kann auf die Bewohner eine bedrückende, monotone Wirkung haben. Natur, wie z. B. der Wechsel der Jahreszeiten, kann in der direkten Wohnumgebung nicht mehr erlebt werden." (http://www.stadtentwicklung.berlin.de/umwelt/umweltatlas/e_text/ka102.pdf).

Neben den beschriebenen ökonomischen und sozialen Auswirkungen des Flächenverbrauchs führt die zunehmende Versieglung von Böden zu Beeinträchtigungen der Bodenfunktion, zum Verlust von Flora und Fauna, zu Veränderungen im Bodenwasserhaushalt sowie zu klimatischen Veränderungen.

Durch Versiegelung und Verdichtung werden die Funktionen des Bodens stark beeinträchtigt. Nach SCHRÖDER (1992, S. 145) können den Böden "6 wichtige ökologische, technisch-industrielle, sozio-ökonomische und kulturelle Funktionen zugeordnet werden", wobei in diesem Kapitel die Beeinträchtigungen der ökologischen Bodenfunktionen behandelt werden.

Zum einen wird die landwirtschaftliche Produktionsfunktion eingeschränkt, d. h. der Verlust fruchtbarer Böden durch den Verbrauch als Siedlungs- und Verkehrsfläche vermindert die potenzielle Anbaufläche von Nahrungs- und Futtermitteln sowie erneuerbaren Rohstoffen.

Des Weiteren wird die Genschutz- und Genreservefunktion des Bodens gefährdet, d. h. die Artenvielfalt von Fauna und Flora im Boden als auch auf dem Boden wird durch die Bodenversieglung selbst und durch die zunehmende Ausweisung und Nutzung von Verkehrsinfrastruktur mit den resultierenden Schadstoffeinträgen dezimiert. Letztendlich wird durch die Bodenversieglung die Funktion des Bodens als "Filter-, Puffer und Transformator zwischen Atmosphäre und Grundwasser einerseits sowie zwischen Atmosphäre, Grundwasser und Pflanze andererseits" (SCHRÖDER 1992, S. 146) beeinträchtigt. Die Fähigkeiten des Bodens zur Bindung von Schadstoffen (Fällung und Adsorption), der mikrobiellen Zersetzung von organischen Schadstoffen und zur Speicherung von Wasser ist eingeschränkt oder gar nicht möglich.

Insbesondere wirkt sich die Bodenversiegelung negativ auf den Bodenwasserhaushalt aus. Der Bodenwasserhaushalt wird über die Wasserhaushaltsgleichung charakterisiert (Formel 2.1):

 $N = T + I + E + V - kA + \Delta S + A_0$ (Formel 2.1)

mit

N = Niederschlag, T = Transpiration,

I = Interzeption, E = Evaporation,

V = Versickerung, kA = kapillarer Aufstieg,

 ΔS = Wassergehaltsänderung, A_0 = Oberflächenabfluss.

Abbildung 2.3 verdeutlicht die Funktionszusammenhänge der schematisch dargestellten Komponenten der Wasserhaushaltsgleichung im Wasserhaushalt urbaner Böden.

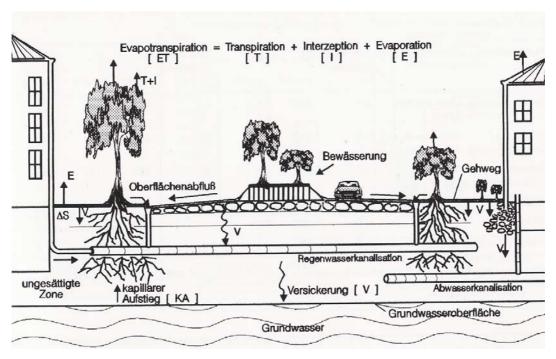


Abbildung 2.3: Schematische Darstellung der Wasserhaushaltskomponenten urbaner Böden (RENGER 1993, S. 175).

STREIT (1992, S. 99) definiert Evapotranspiration (ET) als "die Gesamtmenge der Transpiration durch Pflanzen und der Evaporation von Boden und Wasserfläche in einem Pflanzenbestand.". Nach NETZBAND (1998, S. 17) ist die Evapotranspiration durch die Reduzierung der Flora "in städtischen Gebieten aufgrund der vermehrten Bodenversieglung sehr viel geringer als im Umland.". Demnach kann bei stark versiegelten Flächen (90 % Versiegelung) die Evapotranspiration "bis unter ein Drittel der Menge des Umlandes sinken." NETZBAND (1998, S. 17). Damit hat die Eva-

potranspiration ebenfalls Einfluss auf die Luftfeuchtigkeit, die das lokale Klima beeinflussen kann.

Des Weiteren kommt es auf Grund der Versiegelung in urbanen Räumen zu einer Erhöhung des Oberflächenabflusses (A₀). Da das Regenwasser über Kanalsysteme zu Vermeidung von Überflutungen abgeleitet wird, kann es nicht mehr durch den Boden dem natürlichen Vorfluter zugeführt werden.

In Kombination mit dem Bevölkerungsdruck wird die Grundwasserneubildung reduziert, d. h. durch die verminderte Regenwasserversickerung (V) im Boden kann es in hochversiegelten Gebieten zu negativen Bilanzen bei der Trinkwasserentnahme kommen. Folge ist ein Absinken des Grundwasserspiegels. "Im Extremfall fallen Gewässerabschnitte urbaner Ökosysteme in niederschlagsarmen Perioden trocken." (RENGER 1993, S. 175).

Ferner kann durch die Absenkung des Grundwasserspiegels der Bestand solcher Pflanzen gefährdet werden, die nicht in der Lage zur Bildung von ausreichend langen Pfahlwurzeln sind.

Neben den Auswirkungen auf den Wasserhaushalt wirkt sich die zunehmende Siedlungstätigkeit auf das lokale Klima in urbanen Räumen aus. Eine spezielle Ausprägung eines lokalen Klimas ist das Stadtklima, unter dem KUTTLER (1993, S. 113) "ein auf der Wechselwirkung mit der Bebauung und deren Auswirkungen beruhendes Klima" versteht, "das zusätzlich durch Abwärme und Schadstoffemissionen modifiziert wird.".

Ein wesentliches Merkmal des Stadtklimas ist die so genannte Wärmeinsel, "d. h. die im Vergleich zum Umland durchschnittlich erhöhte Temperatur der Stadt." (NETZBAND 1998, S. 12). Grund hierfür ist eine dichte Bebauung (große Oberfläche), bei der die Sonneneinstrahlung stärker absorbiert³ wird, da Baustoffe wie Beton, Asphalt oder Stein ein größeres Wärmespeichervermögen besitzen als natürliche Oberflächen. In Folge kommt es über bebauten Flächen zu einer Energieübertragung an die umgebende Luft, die bis in die Nacht andauert und durch Partikelkonzentrationen (Schadstoffe) in der städtischen Luft noch verstärkt wird. Durch die starke Aufwärmung tagsüber und die eingeschränkte Abkühlung in der Nacht herrschen in Siedlungsgebieten im Vergleich zum Umland höhere Temperaturen. Weitere Besonderheiten des Stadtklimas sind verminderte Windgeschwindigkeiten durch erhöh-

gi-reports@igf 11

_

³ "Bei der Absorption handelt es sich um eine Energieumwandlung, bei der ein Teil der elektromagnetischen Strahlung in Wärme oder andere Energieformen umgesetzt wird" (ALBERTZ 2001, S.14).

te Bodenrauhigkeit und Windbremsen, sowie eine vermehrte Dunst- und Nebelbildung durch eine erhöhtes Aerosolaufkommen (Schadstoffemissionen).

Alle "genannten Faktoren beeinflussen die Zusammensetzung der Stadtatmosphäre sowie den Strahlungs- und Energiehaushalt. Als Folge daraus resultieren mikro- und mesoklimatische Besonderheiten der Städte gegenüber ihrem Umland." (KUTTLER 1993, S. 115).

2.4 Herkömmliche Erfassungsmethoden und Fernerkundung

Wie im letzten Kapitel geschildert, hat der Zuwachs von Siedlungs- und Verkehrsfläche negative Auswirkungen für Volkswirtschaft, Mensch und insbesondere die Ökologie. Es ist daher eine kontinuierliche Überwachung der Siedlungsflächenentwicklung nötig, um mögliche Strategien (vgl. Nachhaltigkeitsstrategie der Bundesregierung, Kapitel 2.1) zur Steuerung des Flächenverbrauchs zu entwickeln und anzupassen. Dazu sind verlässliche Erfassungsmethoden erforderlich. Deshalb sollen in diesem Kapitel die Möglichkeiten der Fernerkundung im Vergleich zu herkömmlichen Erfassungsmethoden untersucht werden.

Nach MEINEL & HENNERSDORF (2002, S. 273) gibt es prinzipiell vier Möglichkeiten, Flächenbedeckungs- und Nutzungsinformation⁴ zu erheben: "Informationssysteme zur Flurstücksnutzung (Register, Kataster), Befragungen, Feldbegehung einschließlich Bewertung oder eine Auswertung fernerkundlicher Aufnahmen.".

In Deutschland wird auf der Grundlage von Katasterdaten die "Flächenerhebung nach Art der tatsächlichen Nutzung" durchgeführt, die nach Angaben des STATISTISCHEN BUNDESAMTES (2002, S. 3) eine dezentrale Statistik ist, bei der "die nach Landesrecht für die Führung des Liegenschaftskatasters zuständigen Stellen (in der Regel Liegenschafts- bzw. Katasterämter oder Vermessungsverwaltungen) [...] die geforderten Angaben zur Bodennutzung auf Gemeindebasis an das jeweilige Statistische Landesamt" liefern, welches wiederum die zusammengestellten Daten dem Statistischen Bundesamt bereitstellt. Dargestellt wird die Nutzung entsprechend dem Nutzungsartenverzeichnis der "Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland" (AdV), das sowohl Siedlungs- als auch Verkehrsfläche als Kategorie ausweist. Grundlegende Eigen-

gi-reports@igf 12

.

⁴ Unter Flächenbedeckung versteht man die (bio-)physische Beschreibung der Erdoberfläche. Flächennutzung beschreibt die funktionale Dimension, d.h. den Zweck der sozioökonomischen Nutzung (vgl. MEINEL & HENNERSDORF 2002, S. 272).

schaft der Katasterinformation ist die Verbindung von Flächeninformation (Nutzungsart) mit der konkreten örtlichen Lageinformation (Katasternummer, Adresse). Vorteile dieser registergestützten Daten sind somit die direkte Verknüpfung von Lage und Flächen sowie der geringe Erhebungsaufwand. Die Nachteile bestehen nach Auffassung von MEINEL et al. (2002, S. 274) darin, "dass die in den Registern gespeicherten Informationen im Hinblick auf Vollständigkeit, Qualität und Aktualität nicht immer die erforderliche Güte aufweisen.". Des Weiteren ist das STATISTISCHE BUNDESAMT (2002, S. 4) der Meinung, dass der "erreichte Stand der Automatisierung [...] zwischen den einzelnen Bundesländern und zum Teil auch innerhalb einzelner Bundesländer" in Bezug auf das "Automatisierte Liegenschaftsbuch" (ALB) unterschiedlich ist, wodurch vergleichende Analysen nicht möglich sind.

Ein weitere Möglichkeit für die Ermittlung von Flächennutzungen- bzw. Bedeckungen ist das Flächenstichproben-Verfahren, das als "statistischer Ansatz auf der Auswahl Beobachtung von repräsentativen Gebietsstichproben" (MEINEL HENNERSDORF 2002, S. 274) durch Feldbegehungen, Befragungen oder Fernerkundungsdaten basiert. Die Untersuchungsfläche wird dabei in Teile (primäre Stichprobeneinheiten) untergliedert, von denen ein Anteil repräsentativer Proben bestimmt wird. Die gewählten Stichproben werden im nächsten Schritt einer Flächennutzung zugeordnet und für die gesamte Bezugseinheit interpoliert. Vorteile des Flächenstichproben-Verfahrens liegen in der Sammlung detaillierter und spezifischer Information und der einfachen Wiederholbarkeit. Nachteilig sind die fehlende ortskonkrete So B. Information. wird Z. in Baulandumfragen (siehe auch http://www.bbr.bund.de/raumordnung/siedlung/methoden.htm) der Baulandverbrauch ausgewählter Gemeinden und Städte in Abhängigkeit vom Preis betrachtet, nicht jedoch die gesamte Fläche vorhandener Siedlungs- und Verkehrsfläche für die Bundesrepublik Deutschland.

Weitere statistische Datenquellen wie Bautätigkeitsstatistiken liefern nur Informationen zu der Anzahl von Baugenehmigungen und Baufertigstellungen, aber keine flächenbezogenen Daten. STEINNOCHER & TÖTZER (2001, S. 39) resümieren zurecht, dass statistische Analysen "letztendlich nur eine Annäherung an die Qualität und Aussagekraft von flächenbezogenen Daten" haben können. Ferner stellt nach REDER (2002, S. 169) "die Aktualisierung dieser Daten durch laufende Erhebungen [...] einen nicht unerheblichen Zeit- und Kostenaufwand" dar, da die Personalkosten und der Zeitaufwand mit zunehmender Größe des Untersuchungsgebietes steigen.

Fernerkundungsdaten (vgl. Kapitel 3.1) dagegen erlauben nach MEINEL & HENNERSDORF (2002, S. 274) "in vielen Fällen eine Bestimmung der Flächenbedeckung und die Einschätzung der Lage, Verteilung und räumlichen Beziehungen von Objekten auf der Erdoberfläche", d. h. sie geben "eine große Geländefläche unter praktisch einheitlichen Aufnahmebedingungen wieder" ALBERTZ (2001, S. 227). Des Weiteren können bei der Auswertung fernerkundlicher Aufnahmen zusätzliche Informationen des elektromagnetischen Spektrums genutzt werden, die das menschliche Auge nicht erfassen kann. So können Multispektralscanner "denselben Geländebereich, die gleichen Geländeobjekte gleichzeitig in mehreren, eng begrenzten (wählbaren) Teilspektren (Kanälen, engl. bands) aufnehmen" (KRONSBERG 1985, S. 1), die vom kurzwelligen Ultraviolett bis zum Mikrowellenbereich (Radar) reichen. Außerdem sind Satellitenbilder sehr gut dazu geeignet, die Dynamik einer Landschaftsentwicklung zu erfassen, da nach ALBERTZ (2001, S. 183) "die zeitliche Dimension" erfasst wird und so "das Beobachten von dynamischen Phänomenen mit Hilfe multitemporaler Bilder oder Datensätze" (LÖFFLER 1994, S. 224) ermöglicht wird.

Ein weiterer Vorteil der fernerkundlichen Datenerhebung ist nach MEINEL & HENNERSDORF (2002, S. 274) "die schnelle Durchführbarkeit und die damit verbundene Aktualität" der Flächendaten.

Als nachteilig bei dem Einsatz der Fernerkundung erweist sich der Preis für die Beschaffung der Daten: "Satellitenbilddaten sind teuer, und zur optimalen Nutzung kann auf die Mittel der digitalen Bildverarbeitung nicht verzichtet werden" ALBERTZ (2001, S. 227). Dementsprechend ist im Gegensatz zu Katasterinformationen bei Fernerkundungsdaten zusätzlich eine Auswertemethode und ein Bearbeiter erforderlich, der aus den Bilddaten Flächenbedeckungsinformationen ableitet bzw. die Methode zur Ableitung der Information entwickelt.

Des Weiteren sind nach MEINEL & HENNERSDORF (2002, S.274) "Bedeckungsaber nicht immer Nutzungsinformationen ableitbar" und "verdeckte Flächen sind ohne Zusatzinformationen überhaupt nicht kartierbar", d. h. die Zuweisung von Flächennutzungen und die inhaltliche Genauigkeit sind im Vergleich zum Kataster und
zur Flächenstichprobe in der Regel als schlechter einzustufen.

Tabelle 2.1 stellt die Vor- und Nachteile der vorgestellten Erhebungsmethoden auf einer Bewertungsskala von "sehr gut" bis "schlecht" in einem Vergleich zusammenfassend dar.

Katastergestützt Stichprobe FE-gestützte Kartierung Erhebungsbasis Sat.-/Luftbild Kataster, Register Sat.-/Luftbild, Begehung, Befragung Auswertungsmethodik Statistik, GIS Statistik, GIS Klassifikation/ Kartierung, GIS Raumbezug Flurstück Stichprobe Pixel Flächennutzungserhebung ++ + (bei Begehung) Flächenbedeckungserhebung Inhaltliche Genauigkeit ++ (bei Begehung) Flächendeckung Aktualität ++ Erhebungskosten hoch hoch gering

(bei Begehung)

Tabelle 2.1: Erhebungsmethoden im Vergleich (verändert nach MEINEL & HENNERSDORF 2002, S. 275).

Da diese Einschränkungen zum einem durch den Einsatz günstiger Fernerkundungsdaten (ASTER- und KOMPSAT-Daten, siehe dazu auch Tabelle 3.1) und zum anderen durch die zentrale Zielsetzung dieser Arbeit (Entwicklung einer objektorientierten (fernerkundlichen) Erhebungsmethode, vgl. Kapitel 1.2) nicht zum Tragen kommen, sowie der Einsatz des objektorientierten Bildanalysesystems eCognition bessere Ergebnisse bei einer Flächennutzungserhebung verspricht (siehe dazu auch MEINEL et al. 2001), überwiegen die Vorteile des Einsatzes einer fernerkundlichen Auswertung. Im Hinblick auf die zentrale Zielsetzung der Arbeit (vgl. Kapitel 1.2), behandelt das folgende dritte Kapitel die theoretischen Grundlagen, die zur Entwicklung der fernerkundlichen Auswertemethode notwendig sind.

⁺⁺ sehr gut, + gut, - weniger gut, -- schlecht

3 THEORETISCHE GRUNDLAGEN

Zweck dieses Kapitels ist die inhaltliche Erläuterung der Grundlagen, auf denen die in Kapitel 4 vorgestellte Methode zur Klassifikation von Siedlungsflächen beruht. Dazu wird zuerst auf die Grundlagen der Fernerkundung eingegangen, dann werden die theoretischen Grundlagen der in der Methode eingesetzten Verfahren und Klassifikationsmerkmale erläutert und zum Schluss wird auf die Funktionsweise des objektorientierten Bildanalysesystems eCognition eingegangen.

3.1 Fernerkundung

3.1.1 Physikalische Grundlagen

"Remote sensing is the science and art of obtaining information about an object, area, or phenomenon through the analysis of data acquired by a device that is not in contact with the object, area, or phenomenon under investigation" LILLESAND et al. (2004, S. 1). Die Gewinnung von Informationen erfolgt bei passiven Ferner-kundungssystemen über das elektromagnetische Spektrum mit der Sonne als natürlicher Strahlungsquelle. Die elektromagnetische Strahlung kann als ein sich mit Lichtgeschwindigkeit ausbreitendes periodisch änderndes elektromagnetisches Feld verstanden werden. In der Fernerkundung ist es weitgehend üblich, die elektromagnetische Strahlung über die Wellenlänge zu definieren (Formel 3.1).

$$\lambda = c/v \tag{Formel 3.1}$$
 mit
$$\lambda = \text{Wellenlänge in m,}$$

$$c = \text{Lichtgeschwindigkeit in m/s,}$$

$$v = \text{Frequenz in Hz.}$$

Abbildung 3.1 stellt die Wellenlängenbereiche des elektromagnetischen Spektrums (für unterschiedliche Aufnahmesysteme) der atmosphärischen Durchlässigkeit und der Strahlungsenergie der Sonne und Erde gegenüber.

Festzustellen ist, dass die Strahlungsenergie der Sonne nicht in allen Wellenlängenbereichen von der Erdatmosphäre durchgelassen wird: Es gibt Wellenlängenbereiche, in denen Strahlung durch Gase (Wasserdampf, Ozon und Kohlendioxid)

absorbiert wird und es gibt "Bereiche, für die die Atmosphäre durchlässig ist" (LÖFFLER 1994, S. 19). Diese Bereiche werden "Atmosphärische Fenster" genannt. Die Fernerkundung kann somit nicht das gesamte elektromagnetische Spektrum nutzen, sondern nur den Teil "des Spektrums zwischen dem nahen Ultraviolett und dem mittleren Infrarot" und außerdem den "Mikrowellenbereich" (ALBERTZ 2001, S. 11).

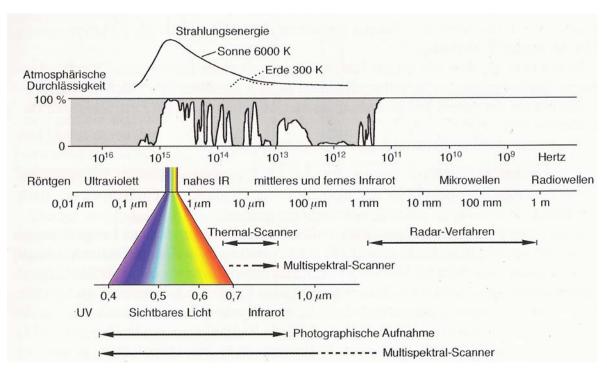


Abbildung 3.1: Strahlungsenergie der Sonne, atmosphärische Durchlässigkeit und elektromagnetisches Spektrum (ALBERTZ 2001, S. 11).

Strahlungswerte können grundsätzlich durch aktive oder passive Aufnahmesysteme gemessen werden. Aktive Sensoren (z. B. Radar) senden selbst Strahlung aus und registrieren den zum Sensor reflektierenden Anteil, passive Sensoren dagegen messen die reflektierte Sonnenstrahlung bzw. die vom beobachteten Körper selbst emittierte Strahlung (z. B. Thermalstrahlung). Die Differenzierung von beobachteten Objekten geschieht auf Grundlage des spektralen Reflexionsverhaltens der verschiedenen Oberflächen, die in Abhängigkeit von der Beschaffenheit des Materials unterschiedlich sind.

Da in diesem Kapitel nur die Grundlageninformationen zu den verwendeten Satellitenbilddaten bzw. deren Entstehung skizziert werden, wird für weiterführende Informationen an dieser Stelle auf die verwendete Grundlagenliteratur (LILLE-SAND et al. 2004, ALBERTZ 2001 und LÖFFLER 1994) hingewiesen.

3.1.2 Verwendete Aufnahmesysteme

In der vorliegenden Arbeit werden Bilddaten der Satelliten SPOT, LANDSAT, KOMPSAT und TERRA verwendet. Alle vier Satellitensysteme bedienen sich passiver Aufnahmensysteme, d. h. sie messen die von der Erdoberfläche (r)emittierte elektromagnetische Strahlung.

Diese passiven Abtastsysteme (engl.: scanner) können in optomechanische und optoelektronische Scanner differenziert werden.

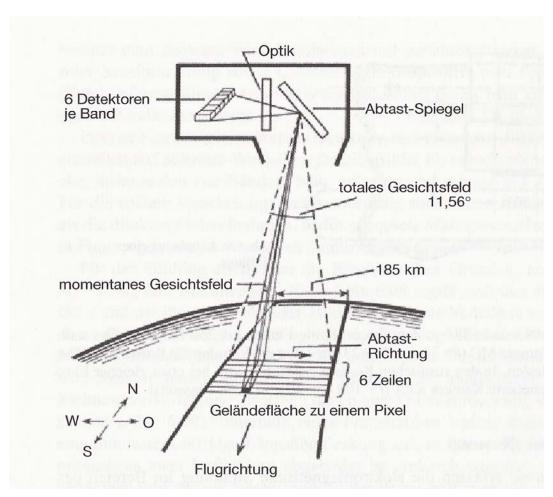


Abbildung 3.2: Schematische Darstellung der Funktionsweise des LANDSAT-Scanners (HAKE et al. 2002, S. 320).

Optomechanische Scanner, wie sie auf der LANDSAT-Satellitenplattform eingesetzt werden, tasten die Oberfläche der Erde mit Hilfe eines quer zur Flugrichtung schwingenden Spiegels (z. B. von links nach rechts) ab. Der rotierende "Spiegel lenkt die Strahlung für jeden Kanal (Band) gleichzeitig auf [...] Detektoren" (HAKE et al. 2002, S. 319), wodurch in Abhängigkeit von der Detektorenanzahl die Erdoberfläche zeilenweise abgetastet wird. Die von den Detektoren registrierte Strah-

lung wird über einen Verstärker (Analog/Digital-Wandlung⁵) in elektrische Signale (Photostrom) transformiert, so dass die aufgezeichneten Daten in digitaler Form weiterverarbeitet werden können. Abbildung 3.2 verdeutlicht das beschriebene Aufnahmeprinzip am Beispiel des Multispektralscanner-Aufnahmesystems der LANDSAT-Satelliten.

Optoelektronische Scanner dagegen basieren auf ladungsgekoppelten Halbleiter-Bildsensoren. Dabei handelt es sich um hochintegrierte Schaltungen auf Siliziumchips, die jeden Bildpunkt durch einen Photosensor erfassen. Mit Hilfe von "CCDs" (engl.: charge coupled devices), die aus Ketten von Kondensatoren bestehen, wird die von der Erdoberfläche empfangene Strahlung direkt in elektrische Ladung umgewandelt und als Videosignal gespeichert.

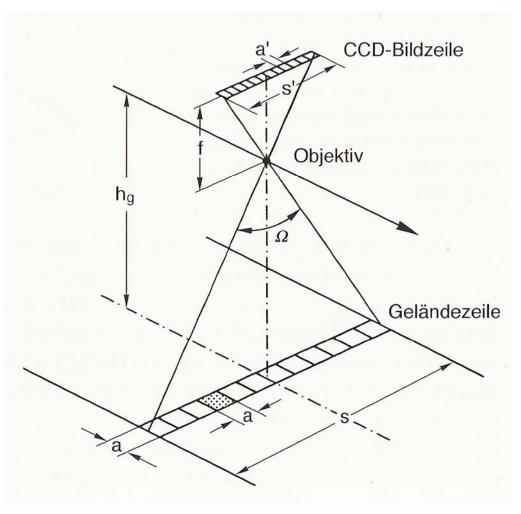


Abbildung 3.3: Schematische Darstellung der Funktionsweise eines optoelektronischen Scanners (ALBERTZ 2001, S. 51).

-

⁵ Umwandlung eines physikalisch sicht- oder unsichtbaren Bildes "*in eine zweidimensionale diskrete mathematische Funktion*" (EHLERS 1984, S. 5).

Des Weiteren wird es durch die feste zeilenweise Anordnung der CCDs möglich, alle Pixel einer quer zur Flugrichtung ausgerichteten Bildzeile gleichzeitig zu erfassen. Abbildung 3.3 verdeutlicht schematisch das geschilderte Aufnahmeprinzip eines optoelektronischen Scanners.

Vorteile der optoelektrischen Scanner sind der fehlende mechanische Verschleiß, da keine Bewegungen von Spiegeln nötig sind. Ferner führt nach ALBERTZ (2001, S. 52) "die Tatsache, daß eine ganze Zeile simultan aufgenommen wird, zu im Vergleich mit optisch-mechanischen Scannern – günstigeren geometrischen Eigenschaften der Bilddaten". Dies liegt an der Tatsache, dass beim Abtastvorgang eines optisch-mechanischen Scanners durch die Bewegung des Abtastspiegels zu den Außenrändern des Bildes hin eine spezielle Verzerrung auftritt, die so genannte Panorama-Verzerrung: Da die Entfernung von Scanner und Gelände zum Rand hin zunimmt (vgl. Abbildung 3.2), wächst mit dem Abstand auch die Größe der beobachteten Flächenelemente (IFOV⁶). Bei optoelektrischen Scannern hingegen tritt keine Panoramaverzerrung auf, da alle Bildelemente einer Zeile gleichzeitig in gleich großen Streckeninkrementen erfasst werden. Weitere Vorteile von optoelektischen Aufnahmesystemen liegen in der Möglichkeit, Stereodaten durch die Anordnung von mehreren CCD-Zeilen in einer Bildebene zu gewinnen und die räumliche Auflösung durch Variation der Brennweite (f) verbessern zu können.

Die Qualität der von den Aufnahmesystemen gelieferten Daten lässt sich anhand des radiometrischen, spektralen, räumlichen und zeitlichen Auflösungsvermögens differenzieren.

Die radiometrische Auflösung ist die messtechnische Fähigkeit eines Sensors, Strahlungsunterschiede zu erfassen. Die Anzahl der Strahlungsunterschiede wird in "bit" gemessen, wobei n bit = 2^n Strahlungsunterschiede (Grauwerte) sind.

Die spektrale Auflösung kennzeichnet die Lage der Kanäle im elektromagnetischen Wellenlängenspektrum und "wird durch die Anzahl der Spektralkanäle und deren jeweilige Bandbreite bestimmt." ALBERTZ (2001, S. 83).

Die räumliche Auflösung eines Sensors (engl.: spatial resolution) "is an indication of how well a sensor can record spatial detail" (LILLESAND et al. 2004, S. 38) und ist gekennzeichnet als Maß der kleinsten identifizierbaren Fläche in einem Bild. Bei Rasterdaten wird sie gewöhnlich durch die Größe der aufgenommen Raster-

.

⁶ Instantaneous Field of View.

zelle charakterisiert. Die räumliche Auflösung ist abhängig von der Bauart des Sensors und der Aufnahmehöhe der Sensorplatform.

Die zeitliche Auflösung (Wiederholrate) kennzeichnet den zeitlichen Abstand zwischen zwei Aufnahmen eines Gebietes durch einen Sensor und ist bei einer satellitengestützten Plattform abhängig von der Umlaufbahn eines Satellitensystems, d. h. wie oft ein Geländeausschnitt überflogen wird.

Nach der Klärung dieser Grundbegriffe, stellt Tabelle 3.1 die Eigenschaften der in dieser Arbeit verwendeten Fernerkundungssysteme zusammenfassend dar. Dabei ist der angegebene Preis für die KOMPSAT-Daten nicht entgültig und kann noch variieren (BOHMANN & MICHEL, pers. Mittl.).

Tabelle 3.1: Technische Daten der verwendeten Satellitenplattformen und Sensoren (LILLESAND et al. 2004. ALBERTZ 2001. KANG et al. 2002 und Internetquellen⁷).

(LILLESAND et al. 20	OT, ALDERTZ 200	1, 10-1110 Ct al. 2002	. una internetquenci	1 <i>)</i> .
Satellit:	SPOT 5	LANDSAT 7	KOMPSAT 1	TERRA
Sensor:	HRG	ETM+	EOC	ASTER (VNIR)
Тур:	optoelektronisch	optomechanisch	optoelektronisch	optoelektronisch
Betrieb:	seid 3.5.2002	seid 15.4.1999	Seid 21.12.1999	seid 18.12.1999
Aufnahmebreite (Schwad) in km:	60 - 80	185	17	60
Szenengröße in km²:	60*60	185*185	17*17	60*60
Spektralkanäle (Angaben in µm):	Pan: 0,48-0,71 B1: 0,50-0,59 B2: 0,61-0,68 B3: 0,78-0,89 B4:1,58-1,75	Pan: 0,52-0,90 B1: 0,45-0,52 B2: 0,52-0,60 B3: 0,63-0,69 B4: 0,76-0,90 B5: 1,55-1,73 B6: 10,4-12,5 B7: 2,08-2,35	Pan: 0,51-0,73	B1: 0,52-0,60 B2: 0,63-0,69 B3: 0,76-0,86 B4: 0,76-0,86 (backward look- ing)
Räumliche Auf- lösung in m:	2,5-20	15-60	6,6	15
Radiometrische Auflösung in bit:	8	8	8	8
Wiederholrate in Tagen:	26	16	28	16
Kosten je Szene in Euro:	ca. 2.750	ca. 600	ca. 110	ca. 45

http://www.eurimage.com/products/docs/eurimage_price_list.pdf http://www.ipi.uni-hannover.de/html/aktuelles/earsel_symposium/BuySymp.pdf http://www.isprs.org/commission3/proceedings/papers/paper129.pdf

3.1.3 Klassifikationsstrategien

Da als Klassifikationsmethode bei der Definition des Oberziels dieser Arbeit (vgl. Kapitel 1.2) bereits die Verwendung eines objektorientierten Klassifikationsansatzes festgelegt wurde, soll in diesem Unterkapitel dargelegt werden, worin der Mehrwert eines solchen Ansatzes im Vergleich zu herkömmlichen pixelbasierten Methoden liegt. Zuerst ein Überblick über pixelbasierte Methoden gegeben.

Bei der rechnergestützten Klassifizierung von Fernerkundungsdaten macht man sich das in Kapitel 3.1.1 erwähnte unterschiedliche Reflexionsverhalten der beobachteten Objekte zu nutze, indem Objekte (bzw. Pixel) mit ähnlichem Strahlungsverhalten einer "Reflexionsklasse" in einem Merkmalsraum zugeordnet werden. Der Merkmalsraum wird von der Anzahl der verwendeten Spektralbänder bestimmt. "Um jeden Punkthaufen bzw. jedes einzelne Pixel im Merkmalsraum einer Objektklasse zuzuweisen, besteht die Notwendigkeit einer Entscheidungsfunktion. Die Methoden der Klassifikation werden dabei generell in überwachte und unüberwachte Verfahren unterschieden" (MICHEL 2004, S. 61).

Bei der unüberwachten Klassifikation bzw. einer Cluster-Analyse werden Pixel durch eine Vorgabe der Klassenanzahl in spektrale Klassen unterteilt. "Because they are based solely on the natural groupings or clusters in the image value, the identity of the spectral classes will not be initially known." (LILLESAND et al. 2004, S.573). Die generierten Klassen müssen im Anschluss vom Interpreten unter Einbeziehung von thematischen Zusatzinformationen identifiziert werden. Da zur Ermittlung der Klassen oft mehrere Versuche mit unterschiedlichen Klassenvorgaben nötig sind, wird diese Art der Datenanalyse oft "zur Vorbereitung einer Überwachten Klassifizierung eingesetzt" (ALBERTZ 2001, S. 164), weil dieses Verfahren schnell Informationen zur spektralen Trennbarkeit von Klassen liefert.

Die überwachte Klassifizierung dagegen nutzt bekannte spektrale Eigenschaften einer gesuchten Klasse. Dabei gibt der Interpret über so genannte Trainingsgebiete die repräsentativen spektralen Charakteristiken der gesuchten Klasse vor und kann über verschiedene Klassifikationsalgorithmen eine Zuweisung der Bildelemente vornehmen. Die Güte des Klassifikationsergebnisses ist dabei immer abhängig von der Wahl der Trainingsgebiete. Für den überwachten Klassifikationsprozess werden überwiegend drei Klassifikationsmethoden genutzt: Die Methode der geringsten Distanz (engl:: minimum distance classifier), die Quader-Methode

(engl.: parallelepiped classifier) und die Methode der größten Wahrscheinlichkeit (engl.: maxiumum likelihood classifier).

Die Methode der geringsten Distanz "uses the information about the location of each class int the p-dimensional Cartesian space defined by the p bands (features) to be used as the basis of the classification. The location of each class is given by the class mean or centroid" (MATHER 1999, S. 179). Ein Bildelement wird derjenigen definierten Klasse zugeordnet, deren Mittelpunkt am nächsten ist. Beim Quader-Verfahren werden in den Spektralkanälen für die gesuchten Klassen obere und untere Grenzen definiert, die im zweidimensionalen Fall zu rechteckigen Entscheidungsgrenzen führen. Eine Zuweisung eines Bildelements zu einer Klasse geschieht nur, wenn die spektralen Messwerte innerhalb des definierten Rechtecks liegen, andernfalls bleibt das Bildelement unklassifiziert.

Die Methode der größten Wahrscheinlichkeit berechnet auf Grundlage der Trainingsgebiete einer Objektklasse mittels statistischer Kenngrößen (Mittelwert und Kovarianz⁸) die Zugehörigkeitswahrscheinlichkeit eines Bildelementes zu einer Objektklasse, wobei davon ausgegangen wird, "dass die Reflexionswerte eines bestimmten Objektes eine Normalverteilung um den jeweiligen Mittelwert der Musterklasse aufweisen" (MICHEL 2004, S. 67). Eine Zuweisung eines Bildelementes zu einer definierten Klasse geschieht dann, wenn die Zugehörigkeitswahrscheinlichkeit zur Klasse bezüglich der Grauwertverteilung am höchsten ist. Über einen Zugehörigkeitsschwellwert, in der aus den Trainingsgebieten abgeleiteten Wahrscheinlichkeitsfunktion, wird die Zuweisung der Bildelemente gesteuert. Datenkorrelationen der Spektralkanäle führen zu elliptischer Form der Linien gleicher Wahrscheinlichkeit. Das Maximum-Likelihood-Verfahren ist rechenintensiv, führt beim Vergleich der drei vorgestellten pixelbasierten Ansätze in der Regel zu den besten Klassifikationsergebnissen.

Da die fortschreitende technische Entwicklung führt zu immer besseren radiometrischen, spektralen, räumlichen und temporalen Auflösungen, d. h. insbesondere die immer besser werdenden räumlichen Auflösungen (z. B. IKONOS mit 1 m Bodenauflösung) ermöglichen eine immer genauere visuelle Interpretation und eine bessere Objektabgrenzung. Mit der Verbesserung der Bodenauflösung stoßen die erläuterten pixelbasierten Klassifikationsansätze an ihre Grenzen: Zwar sind die registrierten Reflexionswerte auf Grund der reduzierten Mischpixelproblematik

_

⁸ Maßzahl für den Zusammenhang zweier statistischer Merkmale (vgl. SCHWARZE 1997, S.73).

eindeutiger, aber die spektrale Heterogenität innerhalb einzelner Objekte nimmt zu. Dies führt bei einer pixelbasierten Klassifizierung zu sehr vielen unterschiedlichen und zu wenig zusammenhängenden Klassen. Man erhält eine so genannte "Salz und Pfeffer"-Klassifizierung. Abbildung 3.4 zeigt diesen Effekt bei einer Maximum-Likelihood-Klassifizierung (links) im Vergleich zu einem objektorientierten Ansatz (rechts).



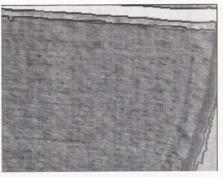


Abbildung 3.4: "Salz und Pfeffer" – Klassifizierung (links) und Ergebnis einer Segmentierung (rechts) (SCHIEWE & TUFTE 2002, S. 43).

Ein weiterer Nachteil pixelbasierter Ansätze ist nach GORTE (1998, S. 30) "a further use of the obtained unknown class [...] a 'reminder class'". Eine Zuordnung nicht klassifizierter Pixel kann seiner Auffassung nach durch eine nachherige Analyse mit Hilfe einer unüberwachten Klassifizierung oder durch "region-based segmentation techniques" geschehen. Letztere Technik geht von der Annahme aus, "dass ein Pixel mit einer hohen Wahrscheinlichkeit die gleiche Klassenzugehörigkeit hat wie sein Nachbarpixel. Das heißt, der Bildraum wird zuerst in homogene Regionen, bestehend aus ähnlichen Pixel, segmentiert" (KOCH et al. 2003, S. 195), um im Anschluss die erzeugten Segmente (Objekte) zu klassifizieren. Eine Übersicht über die Verfahren der Bildsegmentierung wird im folgendem Abschnitt gegeben.

3.2 Segmentierungsverfahren

Segmentierungsverfahren sind einem Teilgebiet der Informatik zuzuordnen, das sich mit der Extraktion von Informationen aus einem Bild oder einer Videosequenz beschäftigt, dem so genannten Bildverstehen bzw. Bilderkennen (engl.: computer vision). HARALICK & SHAPIRO (1992, S. 509), definieren Bildsegmentierung wie folgt: "Image segmentation is the partition of an image into a set of nonoverlapping

regions whose union is the entire image.". Das Grundprinzip der Segmentierung besteht in der Zusammenfassung von Bildelementen, die auf Grundlage von Nachbarschaftsbeziehungen und Wertähnlichkeiten gebildet werden. Nach JÄH-NE (1989, S. 163) gibt es prinzipiell drei Vorgehensweisen bei einer Segmentierung: "nämlich punktorientiert, regionenorientiert oder kantenorientiert zu arbeiten.".

In den folgenden Abschnitten werden diese drei Ansätze erläutert, um im Anschluss in Abschnitt 3.2.4 den in der Arbeit verwendeten Segmentierungsalgorithmus von eCognition einzuordnen und im Detail zu erläutern.

3.2.1 Punkt-basierte Segmentierungsverfahren

Das punktorientierte bzw. schwellwertorientierte Verfahren zur Bildsegmentierung wird in der Regel angewandt, um aus einem Grauwertbild ein binäres Bild oder ein Bild mit reduzierten Graustufen zu erzeugen. Dies ist insbesondere bei Bildern von Interesse, deren Bildinhalt sinnvoll in "Hintergrund" und "gesuchtes Objekt" differenziert werden kann, wie es z. B. bei Texten oder Strichzeichnungen der Fall ist. Bei einer Segmentierung wird dabei zuerst die Grauwertverteilung betrachtet, d. h. es wird untersucht, ob sich Grauwerte ähnlich sind oder nicht. Dabei wird über eine Histogrammanalyse⁹ versucht, optimale Schwellwerte zur Trennung von Objekten zu ermitteln. Diese Schwellwerte liegen im Idealfall an den lokalen Minima des Histogramms. Hat das Bild einen binären Charakter, so besitzt das "Histogramm eine bimodale Verteilung mit zwei klar getrennten Maxima. Idealerweise gibt es zwischen diesen einen Bereich, in dem keine Merkmale vorliegen. Dann kann die Schwelle [...] in diesem Bereich gesetzt werden." (JÄHNE 1989, S. 163). Abbildung 3.5 visualisiert den beschriebenen Fall.

-

⁹ Ein Histogramm ist eine graphische Darstellung einer Häufigkeitsverteilung von Elementen (vgl. MITTENECKER 1968, S. 7).

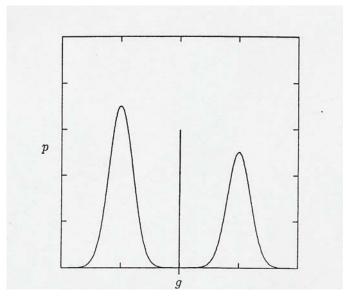


Abbildung 3.5: Bimodale Verteilung in einem Histogramm und Segmentierungsschwelle (g) (JÄHNE 1989, S.164).

Sind mehrere lokale Minima bzw. Segmentierungsschwellen im Histogramm vorhanden und korrespondieren diese mit Regionen von Interesse, kann der Merkmalsraum über einer Äquidensitendarstellung in mehrere Teile zerlegt werden (vgl. Abbildung 3.6).

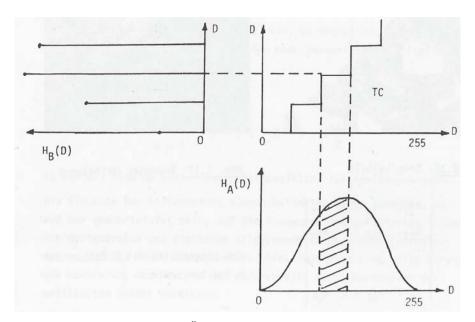


Abbildung 3.6: Beispiel für eine Äquidensitendarstellung (EHLERS 1984, S. 28).

Dies geschieht über "eine Zusammenfassung eines Grauwertintervalls mittels einer treppenförmigen Transfercharakteristik zu einem Grauwert" (EHLERS 1984, S. 28).

Zur genaueren Bestimmung der lokalen Minima ist vor einer Äquidensitenbildung eine "Glättung des erstellten Histogramms durch Mittelwertbildung [...] oder Berechnung des Medians von benachbarten Histogrammwerten günstig" (STEIN-BRECHER 2002, S. 204), da im geglätteten Histogramm (weniger Ausreißer) das Setzen von Schwellwerten erleichtert wird. Andere Möglichkeiten zum Bestimmen von Segmentierungsschwellen bei Bildern mit ungleichmäßiger Ausleuchtung bestehen in der adaptiven Suche nach lokalen Schwellwerten in zuvor abgegrenzten Bildbereichen (siehe dazu auch JAIN et al. 1995, S. 81) oder in der Verbesserung der Ausleuchtung (z. B. durch eine Histogrammlinearisierung 10) im gesamten Bild selbst. Weist das Histogramm dann immer noch keine eindeutigen Minima zur Schwellwertsetzung auf, "kann auch keine Entscheidung über das Setzen einer Schwelle gefällt werden." (JÄHNE 1989, S. 164).

Punktbasierte Segmentierungsverfahren werden in der Regel bei der Auswertung von Satellitenbilddaten wenig genutzt, da diese im Regelfall viele unterschiedliche Grauwerte mit unterschiedlicher Verortung für ein und dasselbe Objekt aufweisen.

3.2.2 Regionen-basierte Segmentierungsverfahren

Im Gegensatz zu punkt-basierten Segmentierungsverfahren beginnen regionenbasierte Ansätze zuerst im Bildraum, wo die vorhandenen Elemente (Pixel oder bereits existierende Regionen) auf Grundlage von Wertähnlichkeiten (Homogenität) neuen Segmenten zugeordnet werden. Nach SCHIEWE (2005, Internet¹¹) kann dabei prinzipiell zwischen drei Vorgehensweisen differenziert werden: Segmentierung mit dem Regionenwachstumsverfahren (engl.: region growing), Segmentierung mit dem Regionenteilungsverfahren (engl.: region splitting) oder Segmentierung mit kombinierten Verfahren (engl.: split and merge).

Das Regionenwachstumsverfahren ist ein "bottom-up-Verfahren", bei dem zu Beginn eine Startregion durch zufällige Vorgabe eines so genannten Saatpixel (engl.: seed pixel) definiert wird. Diesem Saatpixel werden sukzessive neue Pixel aus der unmittelbaren Nachbarschaft hinzugefügt, wenn sie den definierten Homogenitätskriterien (Grauwert, Form oder Textur) genügen. Sobald die Schwellwerte der Homogenitätskriterien überschritten wurden, wird an anderer Stelle ein neues

-

¹⁰ "Mit der Histogrammlinearisierung soll erreicht werden, daß jeder Grauwert mit der gleichen Häufigkeit auftritt" (EHLERS 1984, S.23).

http://www.fzg.uni-osnabrueck.de/mitarbeiter/schiewe/segm/ls_intro_frame.htm

Saatpixel gesetzt. Dieser Prozess wird solange fortgesetzt, bis keine Änderungen mehr auftreten und das gesamte Bild in Segmente aufgeteilt wurde. Abbildung 3.7 visualisiert den skizzierten Algorithmus für ein einzelnes Saatpixel. Nachteilig bei der Segmentierung mit einer zufällig ausgewählten Startregion ist das Entstehen von unterschiedlich großen und unterschiedlich positionierten Segmenten. Abhilfe kann das Setzen von mehreren gleichzeitig wachsenden Saatpunkten im Bild bringen.

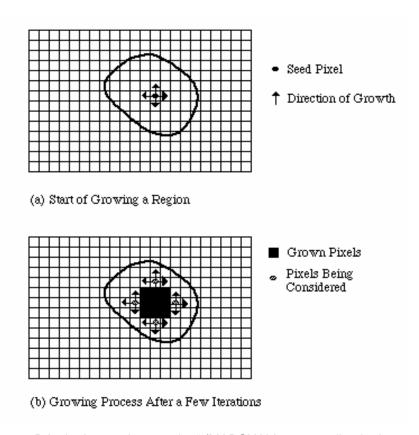


Abbildung 3.7: Prinzip des "region growing" (MARSHALL 2005, online im Internet unter: http://www.cs.cf.ac.uk/Dave/Vision_lecture).

Das Regionenteilungsverfahren ist ein "top-down-Verfahren" bei dem zu Beginn das gesamte Bild als potenzielles Segment angesehen wird. Im ersten Schritt wird getestet, ob das definierte Homogenitätskriterium erfüllt ist oder nicht. Ist dies nicht so, wird die gesamte Fläche in Teilflächen zerlegt und die Überprüfung auf Homogenität für jede dieser Teilflächen wiederholt. Dies wird rekursiv mit jedem zerlegten Teilbereich solange fortgesetzt, bis keine Flächenaufteilung mehr möglich ist. Beispiel für so einen Algorithmus ist der Quadtree, der eine Rastermatrix solange rekursiv in vier jeweils gleich große Viertel unterteilt, bis alle Quadranten homogen bezüglich des definierten Merkmals sind oder bis die Grundauflösung der Raster-

matrix erreicht ist. "An image obtained using the recursive splitting is represented in a tree stucture." JAIN et al. (1995, S. 89). Abbildung 3.8 zeigt die rekursive Zerlegung einer Rastermatrix (nach Himmelsrichtungen) mit zwei Grauwerten und die dazugehörige baumartige hierarchische Datenstruktur des Quadtrees.

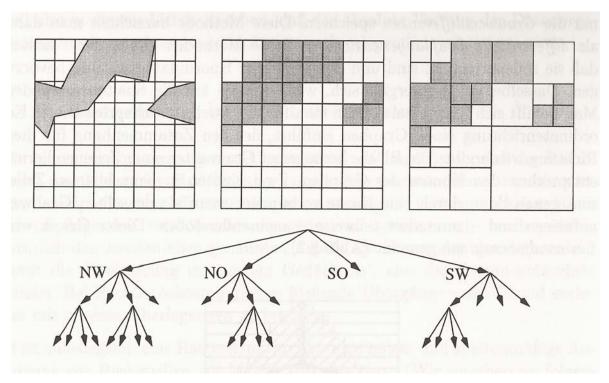


Abbildung 3.8: Rekursive Aufteilung beim "region splitting" (BARTELME 2000, S. 254).

Nachteil des Regionenteilungsverfahrens ist die Generierung zu vieler kleiner Regionen, die nicht die tatsächliche Verteilung im Raum repräsentieren: "the boundaries produced by the split technique tend to be squarish and slightly artificial" (HARALICK et al. 1992, S. 540).

Eine Lösung dieses Problems kann die Kombination von Regionenwachstumsund Regionenteilungsverfahren sein, die im "split-and-merge-Algorithmus" verwirklicht wurde. Dabei wird, wie Abbildung 3.9 dargestellt, nach einer rekursiven Aufteilung der Rastermatrix in Quadranten (Schritt a bis c) überprüft, ob benachbarte Teilflächen (in diesem Beispiel I₄₃ und I₄₄) doch so homogen sind, das sie wieder vereinigt werden (Schritt d). Zwar kommt es bei der Anwendung dieses Algorithmus zur Bildung von größeren Segmenten als beim Regionenteilungsverfahren, dennoch bleiben die erzeugten Objekte in der Form unnatürlich (eckige Kanten), womit eine Nachbearbeitung erforderlich ist.

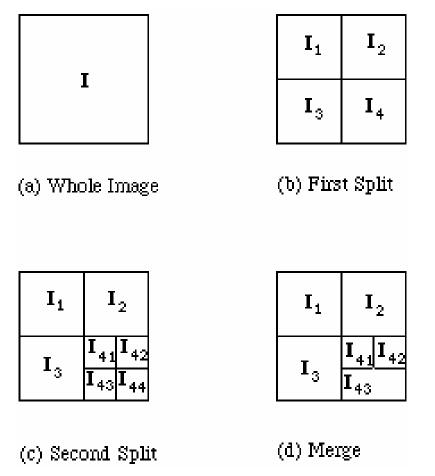


Abbildung 3.9: Prinzip des "split and merge" (MARSCHALL 2005, online im Internet unter: http://www.cs.cf.ac.uk/Dave/Vision_lecture).

3.2.3 Kanten-basierte Segmentierungsverfahren

"Während bei der Segmentierung über Schwellwerte oder durch Gebietswachstum die einzelnen Objekte als Flächen extrahiert werden, werden mit Hilfe der Kantendetektionsverfahren die Umrandungen der Objekte bestimmt" (STEINBRECHER 2002, S. 206). Sind diese Umrandungen nicht zusammenhängend, werden Filter zur Kantenhervorhebung (z. B. Gradientenfilter) genutzt, um zusammenhängende Konturen¹² herstellen zu können.

Nach der Bestimmung dieser Konturen können über einen "Füllalgorithmus" Segmente erzeugt werden. Beispiel ist das so genannte Wasserscheidenverfahren (engl.: watershed-algorithm), dessen Funktionsprinzip in Abbildung 3.10 dargestellt ist.

_

¹² Umrisslinie eine Objektes.

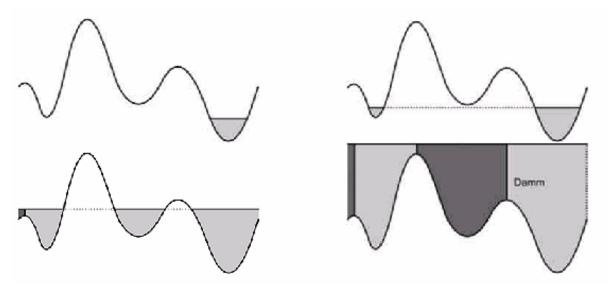


Abbildung 3.10: Segmentierung mit dem Watershed-Algorithmus (Online im Internet unter: http://www.bild-medizin/bild-medizin_4.html).

Wird ein Grauwertbild in drei Dimensionen betrachtet, so erhält man ein Graustufengebirge (vergleichbar mit einem Digitalen Höhenmodell). Im Profil dieses Graustufengebirges (Abbildung 3.10) repräsentieren die Konturen die Wasserscheiden und die dazwischenliegenden Regionen die Wassereinzugsgebiete. Der Algorithmus ermittelt auf Basis dieses Profils die Objektgrenzen, indem das Graustufengebirge schrittweise geflutet und an den Stellen ein Damm errichtet wird, wo das Wasser zweier Täler ineinander fließen würde. Die gesuchten Objektgrenzen werden dann von diesen Dämmen repräsentiert.

Ein Nachteil kanten-basierter Verfahren besteht darin, dass das Ergebnis (Umrandungs- bzw. Konturenbild) meist so stark verrauscht ist, das es zur Bildung von zu vielen Segmenten kommt (Übersegmentierung), die nachträglich manuell vereinigt werden müssen. Des Weiteren sind kanten-basierte Verfahren für Satellitenbilddaten nur bedingt von Nutzen, da diese nach starken Grauwert-Gradienten (Diskontinuitäten) suchen, jedoch viele Regionen (Beispiel: Gebiete mit vielen unterschiedlichen Grauwertübergängen, wie z. B. Siedlungen) nicht eindeutig durch globale Grauwert-Gradienten unterscheidbar sind.

3.2.4 Segmentierungsverfahren in eCognition

In der Bildanalysesoftware eCognition wird für die Segmentierung von Bilddaten ein multiskaliges Segmentierungsverfahren (engl.: multiresolution segmentation) auf Grundlage des Regionenwachstumsverfahrens (vgl. Kapitel 3.2.2) bereit ge-

stellt. Die multiskalige Segmentierung ist eine von der Münchener Firma DEFI-NIENS IMAGING neu entwickelte Segmentierungsprozedur, welche die Extraktion homogener Objekte in frei wählbaren Auflösungen erlaubt, d. h. es besteht die Möglichkeit von der Pixelebene ausgehend nacheinander eine Vielzahl von Segmentierungen zu generieren, die jeweils eine andere Segmentgröße (Auflösung) besitzen. Die erzeugten Segmentierungsebenen können über ein hierarchisches Netzwerk (siehe Abbildung 3.11) in Beziehung zueinander gesetzt werden.

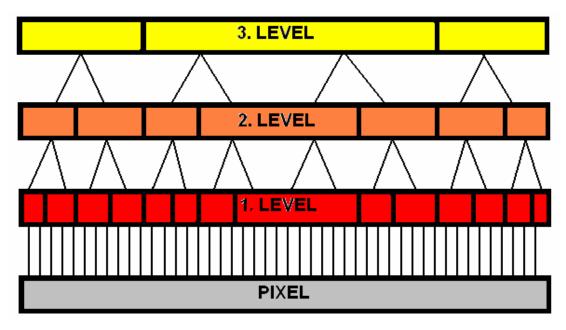


Abbildung 3.11: Hierarchisches Netzwerk von Bildobjekten (EHLERS et al. 2005, S. 211).

Die Vorteile dieses Netzwerkes liegen in der Möglichkeit, jedem Segment seine Nachbar-, Unter- und Oberobjekte zuzuordnen, wodurch bei einer späteren Klassifikation diese Beziehungen zur Abstraktion von neuen Objekten genutzt werden können. Dies ist insbesondere in heterogenen Räumen wie z. B. Städten nützlich, da Objekte (z. B. Gebäude und Parks) in der Realität unterschiedlich groß sind, die generierten Segmente innerhalb einer gewissen Toleranz aber ähnliche Ausmaße aufweisen. Mit Hilfe des hierarchischen Netzwerks können z. B. generierte Objekte einer niedrigen Segmentierungsebene (Level) in einer höheren Segmentierungsebene semantisch zusammengefasst werden, so dass eine korrekte Klassifikation erzielt wird. In eCognition wird dieses Zusammenfassen "classification based segmentation" (vgl. Kapitel 3.5.1) genannt.

Der eigentliche Segmentierungsalgorithmus zur multiskaligen Segmentierung sowie die nachfolgenden Ausführungen beruhen auf der Arbeit von BAATZ & SCHÄPE (2000).

Wie in Kapitel 3.2.2 erläutert, werden beim Regionenwachstum mehrere gleichzeitig anwachsende Saatpixel im Bild verteilt. Ist das Regionenwachstum für den "ersten Satz" der Saatpixel abgeschlossen, werden neue Saatpixel an den Stellen im Bild gesetzt, die die größte Entfernung zu allen vorher verschmolzenen Punkten haben. Zweck dieser iterativen Vorgehensweise ist das Bestreben, möglichst ähnlich große Segmente zu erzeugen.

Das Wachstum der Segmente geschieht dabei auf Basis lokaler Homogenitätskriterien, die die Unterschiede zwischen benachbarten Objekten beschreiben. "Wachstum" bedeutet dabei das paarweise Verschmelzen nach dem Prinzip eines Greedy-Algorithmus¹³: Jeder Verschmelzungsvorgang zweier benachbarter Objekte orientiert sich an den verursachten Kosten der Verschmelzung (als "degree of fitting" bezeichnet), d. h. eine Verschmelzung kann nur solange geschehen, bis die Kosten einen definierten Schwellwert (als "least degree of fitting" bezeichnet) erreicht haben. Die Wahl des "degree of fitting" beeinflusst dabei die Segmentgröße: Ein niedriger Wert erzeugt kleine Segmente und ein hoher Wert große Segmente. Wegen dieser Eigenschaft wird dieser Schwellwert in eCognition Skalierungsparameter (engl.: scale parameter) genannt.

Vorteile eines Greedy-Algorithmus liegen in der Tatsache, dass nicht für alle möglichen Kombinationen von Bildelementen die Verschmelzungskosten berechnet werden müssen: Es werden zuerst für alle Bildelemente die Homogenitätswerte berechnet, um im zweiten Schritt nur diejenigen Objekte A und B zu verschmelzen, deren Verschmelzungskosten im Vergleich zum Kostenaufwand anderer benachbarter Objekte am geringsten sind. Dies geschieht sukzessiv solange, bis der definierte Schwellwert erreicht wird. Der Zyklus aus "Berechnen von Homogenitätskriterien" und "Objektverschmelzung" wird bei jeder Segmentierung mehrmals durchgeführt. Bei den Auswahlkriterien für die Bestimmung des zu verschmelzenden Nachbarn B mit dem betrachteten Bildobjekt A kann zwischen mehreren Vorgehensweisen differenziert werden:

¹³ Greedy-Algorithmen bilden in der Informatik eine spezielle Klasse von Algorithmen, die sich dadurch auszeichnen, immer den Folgezustand zu wählen, der das beste Ergebnis verspricht (vgl. http://de.wikipedia.org/wiki/Greedy).

- 1. "Fitting": Objekt A akzeptiert Objekt B, wenn das Homogenitätsmaß unter dem vorgegeben Schwellwert liegt.
- "Best Fitting": Objekt A vereinigt sich in der vordefinierten Umgebung nur mit dem Objekt, dass die Homogenitätskriterien im Vergleich mit den anderen Objekten am Besten erfüllt.
- "Local Mutual Best Fitting": Sind die Objekte A und B bereits als homogen erkannt, dann wird das zu B passende Objekt C nur dann verschmolzen, wenn C auch zu A passt.
- 4. "Global Mutual Best Fitting:": Verschmelze dasjenige Paar von benachbarten Objekten in der gesamten Szene, dass die Homogenitätskriterien am besten erfüllt.

Bei der Multiresolution Segmentierung wird nach dem Prinzip des "Local Mutual Best Fitting" vorgegangen.

Die Berechnung der Homogenität wird von zwei Faktoren beeinflusst, die separat berechnet und vom Nutzer gewichtet werden können: Farbhomogenität und Formhomogenität.

Die Farbhomogenität eines Objektes ergibt sich aus der Summe der Standardabweichungen (σ_i) der Grauwerte in einem Kanal i multipliziert mit einem Gewichtungsfaktor ω_K , der für jeden Kanal frei gewählt werden kann:

$$h_c = \sum_{i=1}^{N} \omega_{Ki} \sigma_i$$
 (Formel 3.2)

mit

h_c = Farbhomogenität,

 ω_{Ki} = Gewichtungsfaktor eines Kanals,

 σ_i = Standardabweichung der Grauwerte eines Kanals,

N = Anzahl der Kanäle.

Die Formhomogenität wird, unter der Annahme, dass der Kreis die Idealform repräsentiert, als die relative Abweichung der Objektform definiert. Zur Berechnung wird ein Flächenkriterium C (engl.: compactness) als Verhältnis der Objektkanten-

länge I zur Objektfläche (Formel 3.3) und ein Kantenkriterium S (engl.: smothness) als Verhältnis Objektkantenlänge I und kürzester Kantenlänge b, die durch eine bounding box¹⁴ um das Objekt ermittelt wird, genutzt (Formel 3.4).

$$C = \frac{l}{\sqrt{n}}$$
 (Formel 3.3)

mit

C = Compactness,

I = Objektkantenlänge,

n = Pixelanzahl des Objektes.

$$S = \frac{l}{b}$$
 (Formel 3.4)

mit

S = Smothness,

I = Objektkantenlänge,

b = kürzeste Kantenlänge der bounding box.

Da eine Segmentierung mit einer ausschließlichen Gewichtung auf die Farbhomogenität in vielen Fällen zu der Generierung von weit verzweigten Objekten führt, ist es wichtig das Kriterium der spektralen Homogenität und der Formhomogenität zu mischen.

Das Flächenkriterium bewirkt dabei die Erzeugung von kompakten Objekten, d. h. von Objekten, die der Kreisform angenähert sind, während das Kantenkriterium die Bildung von länglichen Objekten, die eine relativ glatte Kante besitzen, fördert. Flächenkriterium C und Kantenkriterium S fließen wie folgt in die Berechnung der Formhomogenität ein (Formel 3.5):

$$h_f = (1 - \omega_f)S + \omega_f C \tag{Formel 3.5}$$

mit

h_f = Formhomogenität,

 ω_f = Gewicht für Formhomogenität.

-

¹⁴ Eine bounding box ist das kleinstmögliche Rechteck um ein Objekt, in dem das Objekt enthalten ist (siehe auch SCHIEWE 2003, S.116).

Aus der Farb- und Formhomogenität errechnet sich die Homogenität für jedes Bildobjekt (Formel 3.6):

$$h = (1 - \omega_c)h_c + \omega_c h_f \tag{Formel 3.6} \label{eq:formel 3.6}$$
 mit

 ω_c = Gewicht für die Farbhomogenität.

Die Gewichte ω_{f} und ω_{c} werden vom Nutzer interaktiv vergeben und richten sich nach der jeweiligen Fragestellung der Anwender.

Nach der Herleitung der Homogenitätskriterien, bleibt die Frage, wie der Algorithmus der Multiresolution-Segmentation Bildelemente für eine Verschmelzung auswählt: dies geschieht über eine Minimierung der Verschmelzungskosten (Formel 3.7). Die Änderung der Kosten h_{diff} für eine virtuelle Verschmelzung benachbarter Bildobjekte A und B lässt sich wie folgt beschrieben:

$$h_{diff} = h_m - \frac{h_a + h_b}{2}$$
 (Formel 3.7)

mit

 h_{m} = Homogenität nach dem Verschmelzen von Objekt A und B,

h_a = Homogenität des Objektes A,

h_b = Homogenität des Objektes B.

Ziel ist die Minimierung von h_{diff}, um die Bildung heterogener Segmente zu verhindern. Die Definition von h_{diff} kann durch die Einbeziehung der Objektgrößen der Objekte A und B bei der Berechnung der Kostenänderung verbessert werden:

$$h_{diff} = h_m - \frac{h_a \eta_A + h_b \eta_B}{\eta_A + \eta_B}$$
 (Formel 3.8)

mit

 $\eta_{A,B}$ = Objektgrößen.

Dies hat den Vorteil, dass nicht nur die absoluten Kosten, sondern auch die Veränderungen des Kostenaufwandes für den Fall berücksichtigt wurden, wenn die Objekte A und B verschmolzen werden. Zusammenfassend stellt die Multiresolution-Segmentierung ein Region Growing Verfahren dar, das in Abhängigkeit von Farbe und Form solche Bildpunkte zusammenfasst, die die globale Heterogenität (Kosten) des Gesamtbildes am wenigsten ansteigen lässt.

3.3 Texturorientierte Verfahren

Hochauflösende panchromatische Satellitenbilddaten ermöglichen die Interpretation von vielen unterschiedlichen Objekten. Das menschliche Sehvermögen registriert aber nicht nur die Intensität einzelner Grauwerte, sondern auch die Strukturierung der Grauwerte, die sich in Form, Textur, Lage, Orientierung und räumlichen Zusammenhängen unterscheiden. "Es ist schwierig zu definieren, was genau Textur ist. Allgemein beschreibt eine Textur die Oberflächenbeschaffenheit (Strukturierung) eines Gegenstandes. Im Bild resultiert dies in einer Strukturierung der Grauwerte" (STEINBRECHER 2002, S. 243). Abbildung 3.12 zeigt beispielhaft zwei Bildausschnitte einer SPOT-Szene, die das Aussehen einer Textur verdeutlichen.






Abbildung 3.12: Bildausschnitte einer SPOT-Szene mit starker Textur (links) und mit schwacher Textur (rechts).

Der linke Bildausschnitt zeigt einen Siedlungsbereich, der rechte Ausschnitt landwirtschaftlichtliche Flächen im Außenbereich. Auffällig beim linken Ausschnitt ist
das kleinteilige, teilweise regelmäßige Muster, das aus dem Wechsel von Gebäuden und Straßenzügen resultiert. Im Vergleich dazu wirkt das rechte Bild wenig
strukturiert, sondern in vielen Bereichen eher gleichförmig. Nach der allgemein
gehaltenen Definition von STEINBRECHER (2002) weist die im linken Bildausschnitt visualisierte Siedlungsfläche eine Textur auf. Ziel dieses Unterkapitels ist
es daher, den festgestellten Unterschied zwischen heterogen strukturierten Sied-

lungsbereichen und (teilweise) homogen strukturierten Außenflächen mathematisch so zu beschreiben, dass eine einfache Klassifikation von Siedlungsflächen möglich wird. Dazu wird in Kapitel 3.3.1 eine Übersicht mathematisch möglicher Charakteristika von Textur gegeben und in Kapitel 3.3.2 im Detail auf das in dieser Arbeit verwendete Texturmerkmal eingegangen.

3.3.1 Übersicht über texturorientierte Verfahren

Im Gegensatz zu einem Grauwert, der eindeutig über die Intensität bestimmt werden kann, "weist Textur eine mehrdimensionale Charakteristik auf. Diese beschränkt sich nicht nur auf die zwei Dimensionen der Bildmatrix, sondern bezieht auch die unterschiedlichen Ausprägungsformen der Textur mit ein" (STEINNO-CHER 1997, S. 145). Sprachlich können diese Ausprägungsformen z. B. durch unscharfe Wörter wie "körnig", "fein" oder "glatt" beschrieben werden. Für einen Klassifikationsprozess bedarf es aber eindeutiger mathematischer Definitionen. SALI & WOLFSON (1992, S. 3396) geben eine Übersicht statistischer Ansätze zur Beschreibung von Grauwertverteilungen in einem Bild, die Textur beschreiben. Die Wichtigesten seien im folgenden kurz aufgezählt:

- Statistische Parameter erster Ordnung, wie z. B. Mittelwerte oder Varianz können einfach berechnet und interpretiert werden, berücksichtigen aber nicht die räumliche Verteilung der Grauwerte im Bild.
- Statistische Parameter zweiter Ordnung, wie Grauwertübergangsmatrizen (engl.: grey-level co-occurence matrices) berücksichtigen die spektrale und die räumliche Verteilung von Grauwerten.
- **Fouriertransformationen** digitaler Bilder ermöglichen über die Analyse des Amplitudenspektrums das Erkennen regelmäßiger Strukturen im Bild.

Weitere Ansätze beruhen auf der Analyse von Histogrammen oder leiten Texturmerkmale mit Hilfe fraktaler Eigenschaften¹⁵ oder Filtertechniken her.

1

¹⁵ Ein Fraktal (lat. fractus: gebrochen) beschreibt natürliche oder künstliche Gebilde oder Muster mit einem hohen Grad von Selbstähnlichkeit (vgl. http://de.wikipedia.org/wiki/Fraktal).

Das folgende Kapitel widmet sich der Texturbeschreibung durch die "Grey-level co-occurence" (GLC) Matrizen, da sich nach STEINNOCHER (1997, S. 146) dieser statistische Parameter zweiter Ordnung für die Analyse von panchromatischen Fernerkundungsbildern bei der Detektion von Siedlungsgebieten als vorteilhaft erwiesen hat.

3.3.2 GLC-Matrizen

GLC-Matrizen dienen zur Ableitung von Statistiken zweiter Ordnung in digitalen Bildern und gehen auf HARALICK et al. (1973) zurück. Eine GLC-Matrix beschreibt die Wahrscheinlichkeit eines Übergangs vom Grauwertniveau i auf das Grauwertniveau j zweier benachbarter Bildelemente. Wie dies im Einzelnen berechnet wird, soll an einer Rastermatrix mit vier Grauwerten aufgezeigt werden:

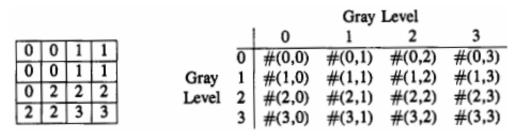


Abbildung 3.13: Rastermatrix (links) und mögliche Kombinationen von Grauwertpaaren (rechts) (HARALICK et al. 1973, S. 613).

Wie Abbildung 3.13 verdeutlicht, richtet sich die Größe einer GLC-Matrix nach der Anzahl der vorhandenen Grauwerte des untersuchten Bildes. Auf Grundlage der maximal möglichen Grauwertkombinationen (Abbildung 3.13, rechts) werden die Häufigkeiten zweier benachbarter Grauwerte i und j mit fest definiertem Abstand für die beiden Nachbarn einer bestimmten Richtungsgraden gezählt. Um alle möglichen Kombinationen von Grauwertpaarungen für eine Richtungsgrade zu erhalten, wird vor- und rückwärts gezählt. Das Ergebnis ist eine symmetrische Matrix (Abbildung 3.14).

$$0^{\circ} P_{H} = \begin{pmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 1 & 1 & 2 \end{pmatrix} \qquad 90^{\circ} P_{V} = \begin{pmatrix} 6 & 0 & 2 & 0 \\ 0 & 4 & 2 & 0 \\ 2 & 2 & 2 & 2 \\ 0 & 0 & 2 & 0 \end{pmatrix}$$
$$135^{\circ} P_{LD} = \begin{pmatrix} 2 & 1 & 3 & 0 \\ 1 & 2 & 1 & 0 \\ 3 & 1 & 0 & 2 \\ 0 & 0 & 2 & 0 \end{pmatrix} \qquad 45^{\circ} P_{SD} = \begin{pmatrix} 4 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 0 & 2 & 4 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

Abbildung 3.14: Symmetrische GLC-Matrizen für vier Richtungen (HARALICK et al. 1973, S. 613).

Wie Abbildung 3.14 verdeutlicht, können für alle vier möglichen Richtungen (horizontal, vertikal, linksdiagonal und rechtsdiagonal) GLC-Matrizen berechnet werden. Dies wird im späteren Teil dieser Arbeit (vgl. Kapitel 4.2.4) noch eine Rolle spielen. Um nun die Wahrscheinlichkeit eines Grauwertübergangs auszudrücken, muss jeder Wert in einer GLC-Matrix durch die maximale Anzahl tatsächlich möglicher Grauwertübergänge für eine Richtung dividiert werden:

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}}$$
 (Formel 3.9)

mit

i, j = Zeilen- und Spaltennummer,

V = Wert in einer symmetrischen GLC-Matrix,

N = Anzahl der Zeilen oder Spalten.

In unserem Beispiel ergeben sich 25 mögliche Übergänge, so dass sich z. B. bei der Berechnung einer Grauwertübergangswahrscheinlichkeit in horizontaler Richtung (0°) für die Grauwertkombination 0,0 ein Wert von 0,16 (4 dividiert durch 25) ergibt. Wird dies analog für alle Werte der symmetrischen GLC-Matrix durchgeführt, erhalten wir eine normalisierte GLC-Matrix.

Da die Erstellung einer GLC-Matrix für digitale Bilder mit hoher radiometrischer Auflösung sehr speicherplatzintensiv wäre, verwenden HARALICK et al. (1973) 14 Texturmerkmale, die die Charakteristik der Matrix durch einen einzigen Wert ausdrücken.

Eines dieser Merkmale ist das "Inverse Difference Moment" (IDM), das wie folgt definiert wird:

$$IDM = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i-j)^2}$$
 (Formel 3.10)

mit

N = Zeilen oder Spaltenanzahl,

P_{ii} = Auftrittswahrscheinlichkeit eines Grauwertpaars,

i,j = Grauwertkombination in der Spalte i und Zeile j der GLC-Matrix.

Dabei wird im Nenner über die Grauwertdifferenz der Grauwerte i und j ein Gewichtungsfaktor gebildet, im Zähler stehen die nominalen Häufigkeiten der Grauwertübergänge im Verhältnis zur Gesamtzahl der möglichen Grauwertübergänge für eine Richtung. Dies führt dazu, dass homogene Bereiche höher gewichtet werden als heterogene, da die homogenen Elemente näher an der Diagonale der GLC-Matrix liegen.

3.4 Verfahren zur Genauigkeitsabschätzung

Die Bestimmung der Klassifikationsgenauigkeit (Teilziel 4) ist zwingende Vorraussetzung, um die Übertragbarkeit der entwickelten Methode bei unterschiedlichen Satellitenbilddaten (Teilziel 5) auszutesten und die anschließende Diskussion der Ergebnisse (Teilziel 6) durchführen zu können. Dazu werden in diesem Kapitel die in dieser Arbeit angewandten gängigen Verfahren zur Bestimmung von Klassifikationsgenauigkeiten erläutert.

3.4.1 Konfusionsmatrizen

"An error matrix is a very effective way to represent map accuracy" (CONGALTON & GREEN 1999, S. 45). Warum Konfusionsmatrizen so effektiv sind, ist Gegenstand dieses Unterkapitels. Bei Konfusionsmatrizen handelt es sich um Tabellen, die für jede Klasse angeben, wie viele der betrachteten Pixel richtig oder falsch klassifiziert wurden. Dazu bedarf es eindeutiger Referenzdaten, die die Klassenzugehörigkeit in der Realität wiedergeben. Bei einer Genauigkeitsabschätzung werden diese Referenzdaten mit dem erzeugten Klassifikationsergebnis in der Konfusionsmatrix verglichen. Tabelle 3.2 zeigt den Aufbau einer Konfusionsmatrix.

Ergebnis Referenz	Klasse 1	Klasse 2	Klasse 3	Klasse 4	Summe
Klasse 1	65	4	22	24	115
Klasse 2	6	81	5	8	100
Klasse 3	0	11	85	19	115
Klasse 4	4	7	3	90	104
Summe	75	103	115	141	434

Tabelle 3.2: Konfusionsmatrix mit vier Klassen (verändert nach CONGALTON & GREEN 1999, S. 46).

Die Zeilen der Matrix repräsentieren die Aufteilung der Pixel nach der durchgeführten Klassifikation (blau hervorgehoben), die Spalten zeigen die Pixelzuordnung auf Basis der Referenzdaten an (rot hervorgehoben). Durch diese Darstellungsweise ist das einfache Feststellen von Genauigkeiten jeder Klasse und das Aufzeigen von so genannten Überlassungsfehlern (engl.: commission error) und Unterlassungsfehlern (engl.: omission error) je Klasse möglich (siehe dazu auch LILLE-SAND et al. 2004, S. 586). Der Überlassungsfehler (ablesbar in den Zeilen) beschreibt, wie viele Pixel anderer Klassen in der erzeugten Ergebnisklasse vorhanden sind; der Unterlassungsfehler (ablesbar in den Spalten) zeigt auf, wie viele Pixel der Referenzdaten falsch zugeordnet bzw. nicht erfasst worden sind.

In Tabelle 3.2 sind z. B. vier Pixel "Klasse 1" zugeordnet, obwohl sie auf Grundlage der Referenzdaten zur "Klasse 2" gehören (Überlassungsfehler). Wird die Hauptdiagonale der Matrix betrachtet, so werden die mit den Referenzdaten übereinstimmenden Pixel des Klassifikationsergebnisses angezeigt, was der individuellen Genauigkeit jeder Klasse entspricht (in der Tabelle fett hervorgehoben). Aus der Konfusionsmatrix lassen sich weitere Genauigkeitsmaße ableiten, wie die Gesamtgenauigkeit (engl.: overall accuracy), die Herstellergenauigkeit (engl.: producer's accuracy) und die Nutzergenauigkeit (engl.: user's accuracy).

Die Gesamtgenauigkeit O_A ergibt sich aus der Summe aller korrekt klassifizierten Pixel (Hauptdiagonale der Konfusionsmatrix), dividiert durch die Gesamtzahl aller Pixel:

$$O_A = \frac{\sum_{i=1}^k n_{ii}}{n}$$
 (Formel 3.11)

mit

n_{ii} = Pixelwert in Zeile i und Spalte i,

k = Anzahl der Klassen,

n = Gesamtpixelanzahl.

Individuelle Klassengenauigkeiten lassen sich über die Hersteller- und Nutzergenauigkeit beschreiben. Dabei gibt die Herstellergenauigkeit P_A das Verhältnis korrekt zugeordneter Pixel einer Klasse zur Gesamtpixelzahl der dazugehörigen Referenzklasse an:

$$P_{\scriptscriptstyle A} = \frac{n_{jj}}{n_{\scriptscriptstyle +j}} \tag{Formel 3.12}$$

mit

 n_{jj} = korrekt zur Klasse j zugeordnete Pixel, n_{+j} = Gesamtpixelzahl der Referenzklasse j.

Die Nutzergenauigkeit U_A beschreibt das Verhältnis der zur Klasse i korrekt zugeordneten Pixel und aller laut Klassifikation zugehöriger Pixel zur Klasse i.

$$U_A = \frac{n_{ii}}{n_{i+}}$$
 (Formel 3.13)

mit

n_{ii} = korrekt zur Klasse i zugeordnete Pixel,
 n_{i+}= Gesamtpixelzahl das Klassifikationsergebnisses der Klasse i.

In der Regel werden die Genauigkeiten nicht in Absolutwerten sondern unter Bezugnahme auf die Gesamtpixelzahl als proportionaler Anteil in Prozent dargestellt.

3.4.2 Kappa-Koeffizient

Mit Hilfe der Kappa-Analyse (zurückgehend auf COHEN 1960) steht eine weitere Maßzahl zu Beurteilung der Gesamtgenauigkeit zur Verfügung, die im Gegensatz zur Gesamtgenauigkeit O_A auch die Commission- und Omission-Fehler berücksichtigt.

Zwar wurde der Kappa-Koeffizient in der Vergangenheit in einer Vielzahl von Studien verwendet, dennoch ist er aber nicht unumstritten, da er Vielfach falsch zitiert wurde (vgl. HUDSON & RAMM 1987, S. 421) und andere Koeffizienten wie z.B. der Tau-Koeffizient (vgl. MA & REDMOND 1995) existieren, die einfacher zu berechnen und zu interpretieren sind.

Der Vorteil des Kappa-Koeffizienten (K) besteht nach LILLESAND et al. (2004, S. 592) in der Fähigkeit "to use this value as a basis for determining the statistical significance of [...] the differences among matrices.". Gebildet wird K aus der Differenz von tatsächlicher Übereinstimmung (der Klassifikationsergebnisse mit den Referenzdaten) und zufälliger Übereinstimmung der Referenzdaten bei einer zufälligen Klassifikation.

Diese Differenz ist der Anteil der über den Zufall hinausgehenden Übereinstimungen. Hierdurch wird berücksichtigt, dass auch bei einer willkürlichen, zufälligen Klassifikation einige Pixel mit den Referenzdaten übereinstimmen können. Zum Zwecke der Normierung wird die ermittelte Differenz durch den theoretischen möglichen Anteil der über den Zufall hinausgehenden Übereinstimmungen dividiert. Der Kappa-Wert ist wie folgt definiert:

$$K = \frac{n\sum_{i=1}^{k} n_{ii} - \sum_{i=1}^{k} (n_{i+}n_{+i})}{n^2 - \sum_{i=1}^{k} (n_{i+}n_{+i})}$$
 (Formel 3.14)

mit

n_{+i} = Gesamtpixelzahl der Referenzdaten der Klasse i.

Im Ergebnis sagt z.B. ein Wert von 0,5 aus, dass 50 Prozent der Fehler einer zufälligen Zuordnung vermieden wurden. Ein Kappa-Wert von 1 zeigt eine perfekte Übereinstimmung, ein Wert von 0 entspricht der Übereinstimmung, die bei einer Zufallsklassifikation erreicht worden wäre: "It is always satisfying to see that your classification is meaningful and significantly better than a random classification." (CONGALTON & GREEN 1999, S. 50).

3.5 Bildanalysesoftware eCognition

Ziel dieses Kapitels ist die Beschreibung der wesentlichen Grundfunktionen der Bildanalysesoftware eCognition, sowie die Erläuterung der in dieser Arbeit verwendeten Klassifikationsmerkmale. Da die Erläuterung aller Funktionalitäten den Rahmen dieser Arbeit überschreiten würde, sei auf die vertiefende Darstellung im Handbuch zu eCognition (DEFINIENS IMAGING 2003) verwiesen.

3.5.1 Grundlegende Möglichkeiten

Der Bearbeitungsablauf in eCognition kann grob in zwei Schritte differenziert werden. Im ersten Schritt wird das untersuchte Bild segmentiert (siehe hierzu Segmentierungsverfahren in Kapitel 3.2.4). In einem zweiten Schritt erfolgt die Klassifikation der segmentierten Flächen. Abbildung 3.15 zeigt das Dialogfeld zur multiskaligen Segmentierung in eCognition.

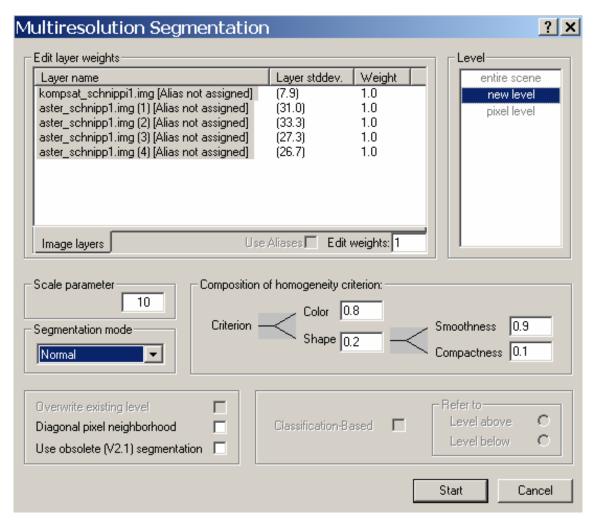


Abbildung 3.15: Dialogfeld multiskalige Segmentierung.

Im linken oberen Ausgabefeld sind alle zur Segmentierung zur Verfügung stehenden Datenlayer aufgelistet. Bei einer Segmentierung können diese Eingangslayer in Abhängigkeit von der Bedeutung unterschiedlich gewichtet werden (siehe dazu Formel 3.2). Im rechten Kasten "Level" wird definiert, an welcher Stelle des hierarchischen Segmentierungsnetzwerks die neue Segmentebene eingefügt werden soll. Des Weiteren können, wie bereits erläutert, über den "Scale parameter" die

Segmentgröße beeinflusst und über die Eingabefelder "Color" und "Shape" die Farb- bzw. Formhomogenität (nochmals differenziert nach "Compactness" und "Smoothness") gewichtet werden. Die Checkbox "Diagonal pixel neighborhood" kann nur vor Erzeugung der ersten Segmentierungsebene aktiviert werden. Hierbei wird festgelegt, welche Nachbarn für die Verschmelzung zu einem Segment in Frage kommen (Abbildung 3.16).

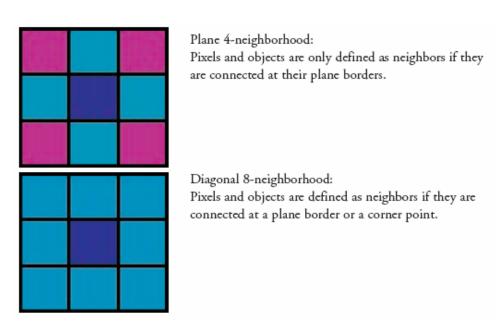


Abbildung 3.16: Vierfache und achtfache Nachbarschaft (DEFINIENS IMAGING 2003, S.61).

Bei einer vierfachen Nachbarschaft (N4) werden nur die Pixel bei der Segmentierung berücksichtigt, die eine ganze Pixelseite zum betroffenen Ausgangspixel (auf der Abbildung dunkelblau) aufweisen, eine achtfache Nachbarschaft (N8) bezieht zusätzlich auch die Pixel mit ein, die mit einer Ecke an den betrachteten Pixel anstoßen (diagonale Pixelnachbarschaft). Bei der Wahl einer diagonalen Pixelnachbarschaft können nach MITTELBERG (2001, S. 45f.) "leicht sehr verzweigte Objekte einstehen, deren Unterobjekte nur über einzelne Ecken aneinander stoßen". Ähnlich wie bei der Differenzierung der Formhomogenität nach "Compactness" und "Smoothness" hängt die Frage der Anwendung einer diagonalen Pixelnachbarschaft von der zu beantwortenden Aufgabenstellung ab, d. h. ob z. B. Flussläufe oder Straßen oder eher zusammenhängende kompakte Segmente generiert werden sollen.

Zusätzlich neben der multiskaligen Segemntierung bietet eCognition die Möglichkeit, eine sogenannte "Classification-based Segmentation" durchzuführen. Diese steht erst zu Verfügung, wenn mindestens eine Segmentierungsebene vorhanden ist, und ermöglicht eine wissensbasierte Segmentierung, d. h. der Nutzer kann in zuvor definierten Strukturgruppen (engl.: structure groups) definieren, welche Segmente in derselben oder einer höheren Segmentierungsebene zu einem Segment zusammengefasst werden sollen (mehr dazu in Kapitel 3.5.2).

3.5.2 Objektorientierte Klassifikation

Ist die Segmentierung abgeschlossen, so kann mit der Klassifikation begonnen werden. Das Bildanalysesystem eCognition verwendet bei der Klassifizierung von Segmenten einen objektorientierten Ansatz, bei dem das Wissen über ein so genanntes "semantisches Netz" dargestellt wird. "Semantische Netze sind markierte Graphen. Die Knoten stellen die Repräsentation von Objekten [...] dar. Die Kanten im Graph stellen die Beziehungen zwischen den Knoten dar." (BILL 1999, S. 404). Diese Vorgehensweise unterscheidet das objektorientierte Verfahren grundlegend von den pixelbasierten Klassifikationsverfahren (vgl. Kapitel 3.1.3), da erst nach der Generierung der Segmente eine Klassifizierung auf Grundlage von Texturmerkmalen, Grauwerten, Formmerkmalen oder Segmentrelationen vorgenommen wird. Im Gegensatz zu pixelbasierten Verfahren, die nur die spektralen Merkmale zur Klassifikation heranziehen, ist bei der objektorientierten Klassifikation eine Wissensbasis erforderlich, d. h. der Anwender muss entscheiden, welche Merkmale (innerhalb welcher Toleranzen) zu einer definierten Klasse gehören oder nicht.

In eCognition kann der Benutzer wahlweise die Objekte über zuvor definierte Trainingsgebiete automatisiert einer Klasse zuweisen lassen (Nearest Neighbour Klassifikator) oder über Fuzzy Logic-Funktionen selber Merkmale und Schwellwerte einer Klassenzugehörigkeit definieren. Nach Auffassung von TIZHOOSH (1998, S. 10) stellt die Klassifikation mit letzterem Ansatz "einen hervorragenden mathematischen Rahmen zur Modellierung von Expertenwissen und sprachlich formuliertem Wissen bereit", so dass im weiteren Verlauf der Arbeit der Fuzzy Logic-Ansatz weiterverfolgt wird.

Die Fuzzy Logic-Theorie¹⁶ entwickelte sich innerhalb der letzten vier Jahrzehnte und beruht auf dem Prinzip der Fuzzy Mengen. Das wesentliche Element ist, wie der Begriff im Englischen sagt, die "Unschärfe" bzw. die parzielle Zugehörigkeit

_

¹⁶ Fuzzy Set Theorie, im Jahr 1965 von Lofti Zadeh eingeführt.

(engl.: fuzzy memberships) einer Aussage oder einer Merkmalsausprägung. Dabei existierten im Gegensatz zur Booleschen Algebra nicht nur logische Zustände von 0 und 1, sondern der gesamte Bereich zwischen 0 und 1 wird als Kontinuum angesehen. Unschärfe bedeutet dabei aber nicht einen Mangel an Information, sondern drückt das Problem nicht eindeutig bestimmbarer Grenzen aus. So ist z. B. die Grenze zwischen Wald und Wiese in der Regel nicht immer geometrisch bestimmbar, ebenso wenig können bei geringen räumlichen Auflösungen immer eindeutige Objektzuordnungen erfolgen. Zur Lösung dieses Problems werden Funktionen gebildet, die eine mögliche Zugehörigkeit eines Objektes zu einer Klasse basierend auf dessen Ausprägung definieren. Dabei wird eine Fuzzy Menge A durch eine Zugehörigkeitsfunktion $\mu(A)$ charakterisiert, die jedem Element aus der Grundmenge eine reelle Zahl im abgeschlossenen Intervall [0,1] zuordnet. Abbildung 3.17 zeigt die Implementierung einer Zugehörigkeitsfunktion in eCognition.

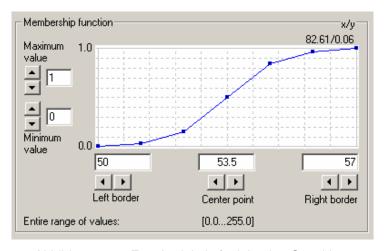


Abbildung 3.17: Zugehörigkeitsfunktion in eCognition.

Die Zugehörigkeit eines Objektes zu einer Klasse wird bei einem "Maximum value" von 1 als möglich und bei einem "Minimum value" von 0 als nicht möglich angesehen. Das Intervall zwischen "Left border" und "Right border" auf der Abszisse definiert den Toleranzbereich, indem eine Zuordnung auf Grundlage des Funktionsverlaufs teilweise möglich ist (in diesem Beispiel zwischen den Werten 50 und 57 der Merkmalausprägung). "The function slope describes how the membership value for the specific expression ist calculated for a certain value of an image object." (DEFINIENS IMAGING 2003, S. 216). In unserem Beispiel steht die Form der Zugehörigkeitsfunktion für ein "größer als", wodurch alle Objekte mit einer Merkmalsausprägung über dem Wert 57 eindeutig der gesuchten Klasse zuzuord-

nen sind; analog fallen Objekte mit einer Merkmalsausprägung unter dem Wert 50 nicht in die gesuchte Klasse. Die Zuordnung von Objekten zwischen beiden Merkmalsausprägungen geschieht erfolgt über den Funktionsverlauf. Neben weiteren vorgegebenen Funktionsformen wie z. B. "kleiner als", "exakt ein Wert" oder "gesamter Wertebereich" bietet eCognition die Möglichkeit jeden beliebigen Funktionsverlauf manuell zu editieren (siehe dazu auch DEFINIENS IMAGING 2003, S. 216f.).

Wurden vom Benutzer alle relevanten Merkmalsausprägungen durch Fuzzy-Funktionen auf Basis von Expertenwissen oder iterativen Versuchsreihen bestimmt, können die gefundenen Regeln unter Verwendung logischer Operatoren in Klassen miteinander verknüpft werden. Folgende logische Operatoren stehen zur Verfügung:

- and(min) = Und-Operator, der den kleinsten Zugehörigkeitswert der verknüpften Merkmale wiedergibt.
- and(*) = Und-Operator, der das Produkt der Zugehörigkeitswerte der verknüpften Merkmale liefert.
- or(max) = Oder-Operator, der den größten Zugehörigkeitswert der verknüpften Merkmale wiedergibt.
- mean(geo) = Gibt das geometrische Mittel der Zugehörigkeitswerte aus.
- mean(arithm)= Gibt das arithmetische Mittel der Zugehörigkeitswerte aus.
- not = Inversion des Zugehörigkeitswertes.

Ferner können einzelne Klassen in einer so genannten Klassenhierarchie miteinander verknüpft werden, womit eine Vererbung eines Regelwerkes von hierarchisch höher stehenden Klassen an darunter liegende Klassen möglich ist. Des Weiteren bietet eCognition die Möglichkeit, thematisch zusammengehörende Klassen in so genannten Groups zusammenzufassen. Weiterhin können, wie in Kapitel 3.5.1 erwähnt, in Strukturgruppen die Klassen definiert werden, deren Segmente bei einer "Classification based Segmentation" (bzw. "Classification based fusion") miteinander verschmolzen werden sollen.

Wird nach der Festlegung des entgültigen Klassifikationsbaumes die Klassifikation gestartet, muss neben der Wahl der zu klassifizierenden Segmentierungsebene bestimmt werden, ob die klassenbezogenen Merkmale (mehr dazu in Kapitel 3.5.3) in die Klassifikation miteinbezogen werden sollen oder nicht. Ist dies der Fall, muss die Anzahl der Klassifikationszyklen determiniert werden, da sich die Klassenzugehörigkeiten auf Grund der klassenbezogenen Merkmale mit jedem Zyklus verändern können.

Nach einer erfolgten Klassifikation kann jedes Objekt über das Dialogfeld "Image Objekt Information" evaluiert und ggf. eine Anpassung des Regelwerks bzw. der Schwellwerte vorgenommen werden.

Ist mit dem erstellten Klassifikationsbaum letztendlich ein zufriedenstellendes Ergebnis erreicht worden, können über den so genannten "Protocol Editor" sowohl die Segmentierung als auch eine Klassifikation mit einem bestehenden Klassifikationsbaum automatisiert werden.

3.5.3 Verwendete Klassifikationsmerkmale

Bei den in eCognition verwendeten Merkmalen handelt es sich zum einem um Objektmerkmale und zum anderem um klassenbezogene Merkmale. Im nachfolgenden Abschnitt werden die verwendeten Merkmale auf Grundlage der soeben gegebenen Unterteilung erläutert.

Die zur Verfügung stehenden Objektmerkmale in eCognition sind spektrale Merkmale, Formmerkmale, Texturmerkmale und Merkmale zur Charakterisierung der Objekthierarchie. Folgende Merkmale wurden verwendet:

 Mittelwert der Grauwerte (engl.: layer mean): Wird für jedes Segment einzeln berechnet und ist abhängig von der radiometrischen Auflösung des segmentierten Bildes:

$$c_m = \frac{\sum_{i=1}^{n} c_i}{n}$$
 (Formel 3.15)

mit

c_m= Mittelwert der Grauwerte,

c_i= Grauwert des i-ten Pixels,

n = Pixelanzahl eines Segments.

 Standardabweichung der Grauwerte (engl.: standard deviation): Berechnet sich aus den Grauwerten aller in einem Objekt enthaltenden Pixel und ist abhängig von der radiometrischen Auflösung:

$$s = \sqrt{\frac{\sum_{i=1}^{n} (c_i - c_m)^2}{n-1}}$$
 (Formel 3.16) mit

s = Standardabweichung.

 Kompaktheitsgrad (engl.: compactness): Wird in eCognition als Produkt von Objektlänge und Objektbreite geteilt durch die Pixelanzahl des Objektes berechnet (Wertebereich: [0; ∞]):

$$c = \frac{l*b}{n}$$
 (Formel 3.17) mit
$$c = \text{Kompaktheitsgrad},$$

$$l = \text{Objektlänge},$$

$$b = \text{Objektbreite},$$

$$n = \text{Anzahl der Objektpixel}.$$

Längen-Breitenverhältnis (engl.: length/width): Wird für ein Objekt entweder über das Verhältnis zweier Kovarianzmatrizen oder über eine so genannte "bounding box" berechnet (siehe dazu auch DEFINIENS IMAGING 2003, S. 95 f.), wobei eCognition als Ergebnis den kleineren Zahlenwert auswählt (Wertebereich: [0; 1]):

$$\gamma = \frac{l}{b} \tag{Formel 3.18}$$
 mit
$$\gamma = \text{Längen-Breitenverhältnis}.$$

 Segmentierungsebene (engl.: level): Gibt die Nummer der Segmentierungsebene an, in dem sich ein Objekt befindet. Dieses Merkmal dient beim Aufbau einer Klassenhierarchie dazu, jeder Klasse eine gültige Segmentierungsebene zuzuweisen.

 Benutzerdefinierte Merkmale (engl.: costumized features): eCognition bietet die Möglichkeit beliebige Objektmerkmale durch arithmetische Operatoren miteinander zu kombinieren. Somit können z. B. nachträglich Vegetationsindices oder neue Texturmerkmale generiert werden (mehr dazu in Kapitel 4.2.3).

Die in eCognition zur Verfügung stehenden klassenbezogenen Merkmale (engl.: class related features) drücken die Beziehungen der Klassen zueinander aus, d. h. sie beschreiben die Beziehungen von Nachbar-, Unter- oder Oberobjekten. Die nachfolgend beschriebenen Merkmale wurden in dieser Arbeit verwendet:

- Existenz einer Klasse X in einer übergeordneten oder untergeordneten Segmentierungsebene (engl.: existence of class): Stellt fest, ob mindestens ein Super- oder Sub-Objekt des betrachteten Objektes in einer definierten Segmentierungsebene vorhanden ist (Wertebereich: {1=true, 0=false}).
- Relative Grenze zu Objekten der Klasse X in der Nachbarschaft (engl.: relative border to class): Beschreibt das Längenverhältnis zwischen übereinstimmender Objektgrenze des betrachteten Objektes zu den Objektgrenzen der Klasse X (Wertebereich: [0;1]).
- Ähnlichkeit zur Klasse X (engl.: similarity to class): Vererbungskriterium, das bei den betrachteten Objekten die Klassenbeschreibungen der Klasse X überträgt. Ähnlichkeiten sind flexibler als die Vererbung in einer Klassenhierarchie, da sie auch in Teilbereichen der Klassenbeschreibung eingesetzt werden können. Wichtige Anwendung ist die Nutzung der invertierten Ähnlichkeiten durch den logischen Operator "not", um die Zugehörigkeit zu einer Klasse zu negieren.

4 METHODE

Inhalt dieses Kapitels ist die Erläuterung des objektorientierten Klassifikationsverfahrens zur Bestimmung von Siedlungsflächen am Beispiel zweier Testgebiete. Dazu wird das Verfahren zuerst gemäß des Oberziels dieser Arbeit an SPOT- und LAND-SAT-Daten erläutert (Fallbeispiel 1). An einem zweiten Fallbeispiel wird die Übertragbarkeit des Verfahrens bei Verwendung von KOMPSAT- und ASTER-Daten (Teilziel 5) demonstriert.

4.1 Ablaufschema und Datengrundlage

Um die nötigen Arbeitsschritte bei einer regionen-basierten Analyse von Fernerkundungsdaten zu verdeutlichen, wird die in dieser Arbeit angewendete Vorgehensweise anhand eines Ablaufschemas dargestellt (Abbildung 4.1).

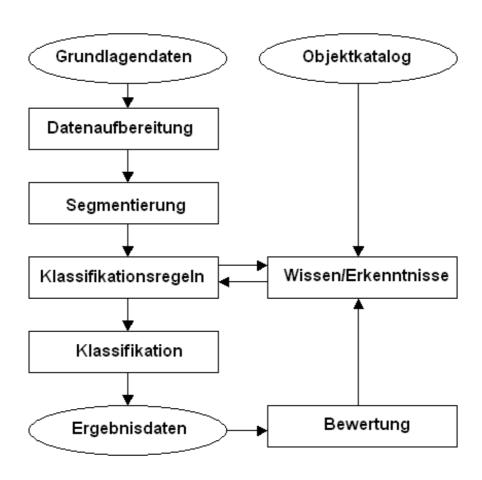


Abbildung 4.1: Ablaufschema einer regionen-basierten Analyse von Fernerkundungsdaten (Quelle: Eigene Darstellung).

Im ersten Arbeitschritt müssen die Satellitenbilddaten geometrisch entzerrt bzw. geokodiert¹⁷ werden, um im zweiten Schritt die eigentliche Segmentierung vorzunehmen
zu können. Danach werden über eine Klassenhierarchie die Klassifikationsregeln auf
Basis von Zielvorgaben (z. B. durch Objektkataloge) und Expertenwissen aufgestellt
(vgl. Kapitel 3.5.2). Nach der Definition von Klassen erfolgt die Klassifikation. Da im
Regelfall das erste Klassifikationsergebnis noch verbesserungswürdig ist, wird eine
Bewertung (Interpretation) vorgenommen, um die gewonnenen Erkenntnisse solange
in die Verbesserung des Regelwerkes einfließen zu lassen, bis ein optimales Ergebnis erzielt wurde.

Als Datengrundlage für das erste Fallbeispiel wurden panchromatische Bilddaten des SPOT-Satelliten (Aufnahmedatum: 16.3.2003) mit 5 m räumlicher Auflösung genutzt. Die zudem verwendeten multispektralen Daten des LANDSAT-Sensors (Aufnahmedatum: 26.6.2001) wurden unter Einbeziehung des panchromatischen LANDSAT-Kanals in ERDAS IMAGINE auf 15 m formatiert (vgl. Tabelle 3.1). Die multispektralen ASTER-Daten (Aufnahmedatum: 03.08.2003) des zweiten Fallbeispiels mussten auf 6,6 m Bodenauflösung formatiert werden: Zwar gibt DEFINIENS IMAGING (2003, S. 153) an, dass mit eCognition Daten unterschiedlicher räumlicher Auflösung verarbeitet werden können, indem die niedriger auflösenden Daten automatisch auf die Größe der höher auflösenden Daten formatiert werden, dennoch war beim zweiten Fallbeispiel eine manuelle Formatierung der ASTER-Daten in der Software Erdas Imagine notwendig, um beide Layer (KOMPSAT und ASTER) ohne Fehlermeldung in eCognition einbinden zu können. Die panchromatischen KOMPSAT-Daten (Aufnahmedatum: 20.5.2004) wurden mit einer räumlichen Auflösung (vgl. Tabelle 3.1) von 6,6 m unverändert genutzt.

Die Daten wurden im Rahmen der Vorarbeiten zum Pilotforschungsprojekt bereits durch andere Projektmitarbeiter geokodiert und geometrisch korrigiert. Somit setzen die folgenden Fallbeispiele, nach der Beschreibung der Ausgangssituation, bei der Frage der Segmentierungseinstellungen für die Bilddaten an.

¹⁷ Geometrische Operation, bei der eine Transformation der Bildelemente des Eingabebildes (Bildkoordinatensystem) in ein Zielbild (Referenzkoordinatensystem) vorgenommen wird (siehe auch MICHEL 2004, S. 34f.).

4.2 Fallbeispiel 1: SPOT und LANDSAT



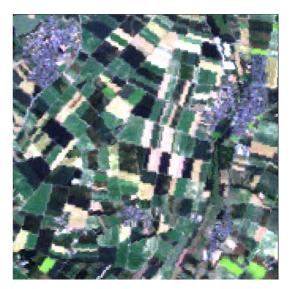


Abbildung 4.2: SPOT- (links) und LANDSAT-Aufnahme (rechts) des ersten Testgebietes.

Abbildung 4.2 zeigt eine SPOT- und LANDSAT-Aufnahme des ersten Untersuchungsgebietes, bei dem es sich um einen Ausschnitt des Stadtgebietes von Erftstadt, ca. 25 km süd-westlich von Köln gelegen, handelt. Nord-westlich und östlich befinden sich eindeutig größere Siedlungsagglomerationen sowie im Süden einige Splittersiedlungen. Die übrige Nutzung ist überwiegend landwirtschaftlicher Art. Insgesamt weist das Gebiet eine Fläche von 25 km² auf.

4.2.1 Vorüberlegungen

Vor Beginn der Arbeiten stellte sich die Frage, mit welcher Klassifikationsstrategie die Erzeugung einer binären Siedlungsmaske (Teilziel 2) am besten gelingt. Grund- überlegung dabei war, auf Basis der panchromatischen SPOT-Daten eine Segmentierung zu generieren, bei der die Identifikation von Siedlungsflächen auf Grundlage statistischer Texturparameter (GLC-Matrizen) zweiter Ordnung erfolgt (vgl. Kapitel 3.3). Die ersten Versuche der Klassifizierung von Segmenten über dieses Merkmal zeigten zwar Erfolge, dennoch war der Anteil der Nicht-Siedlungsflächen zu hoch. In Abbildung 4.3 sind die potenziellen Siedlungsflächen, nach einer Segmentierung (Segmentierungseinstellungen in Tabelle 4.1, Level 3) und einer Probeklassifizierung mittels des IDM-Merkmals (vgl. Kapitel 3.3.2), rot dargestellt.

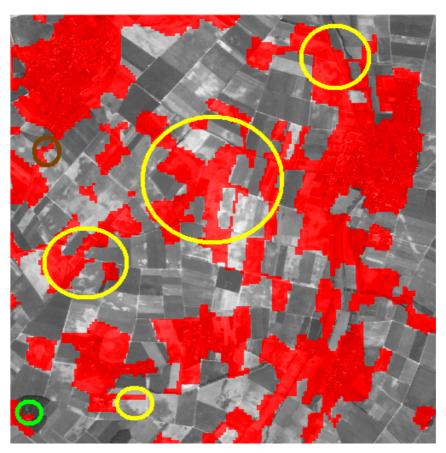


Abbildung 4.3: Erste Probeklassifikation von Siedlungsflächen (rot).

Bei einem Vergleich mit Abbildung 4.2 wird deutlich, dass nicht nur Siedlungsflächen erfasst wurden, sondern auch landwirtschaftliche Flächen (gelb umrandet), Wald (grün umrandet) und Strassen (braun umrandet). Weiterhin wird sichtbar, dass die Siedlungsrandbereiche nicht eindeutig abgegrenzt werden, sondern zu weit gefasst sind. Um die Güte der Klassifizierung signifikant zu verbessern, mussten bei der weiteren Verfahrensentwicklung insbesondere folgende Punkte beachtet werden:

- Die Siedlungsflächen bzw. Siedlungsrandbereiche müssen durch Optimierung der Segmentierungsparameter genauer abgebildet und
- 2. die Nicht-Siedlungsflächen (z. B. landwirtschaftliche Flächen, Wald und Straßen) müssen durch geeignete zusätzliche Klassifikationsmerkmale eliminiert werden.

Da eine Klassifizierung erst nach einer Segmentierung erfolgen kann, wird in Kapitel 4.2.2 zuerst der Frage der optimalen Segmentierungseinstellungen nachgegangen.

4.2.2 Segmentierung

Nach SCHIEWE et al. (2001, S. 38) "has to be pointed out that important steps of the region-based method imply time-comsuming manual interactions. Firstly, [...] the choice of scale parameters [...] has to be done by the user.".

Zur Verminderung des Zeitaufwandes wurden die ersten Segmentierungen auf Grundlage der Empfehlungen der Herstellerfirma durchgeführt, die dazu rät, die einzelnen segmentierten Objekte so groß wie möglich und so detailliert wie nötig ausfallen zu lassen: "1. Rule of thumb: Always produce image objects of the biggest possible scale which still distinguishes different image regions (as large as possible and as fine as necessary)" (DEFINIENS IMAGING 2003, S. 181).

Des Weiteren musste eine sinnvolle Gewichtung der spektralen Eigenschaft "Color" und des Formkriteriums "Shape" gefunden werden. Auch wenn prinzipiell eine stärkere Gewichtung des Formkriteriums "Shape" möglich ist, sollte das spektrale Kriterium so hoch wie möglich gehalten werden: "2. Rule of thumb: Use as much color criterion as possible while keeping the shape criterion as high as necessary [...] The reason for this rule is that a high degree of shape criterion works at the cost of spectral homogeneity. However, the spectral information is, at the end, the primary information contained in image data. Using too much shape criterion can therefore reduce the quality of segmentation results" (DEFINIENS IMAGING 2003, S. 182).

Ausgehend von diesen Empfehlungen wurden mehrere Versuchsreihen durchgeführt mit dem Ziel, für die gesuchten Siedlungsflächen Segmente adäquater Größe zu erzeugen.

Basierend auf der "1. Rule of thumb" wurde mit der Generierung von großen Segmenten (Scale = 48) begonnen. Da, wie es Abbildung 4.3 verdeutlicht, die Grenzen der Siedlungsflächen zum Außenbereich bei einer Segmentierung mit einem Scale von 48 und anschließender Klassifikation zu weit gefasst sind, wurde im weiteren Verfahren die Strategie verfolgt, durch eine sukzessive Verringerung des Scale die Siedlungsgrenzen besser abzubilden. Um bei der späteren Entwicklung eines Klassifizierungsverfahrens die gewonnenen Informationen der zuvor erstellten Segmentierungsebene jedoch weiter nutzen zu können, wird von den Vorteilen der "Multiresolution Segmentation" (vgl. Kapitel 3.2.4) Gebrauch gemacht:

Es wird eine neue Segmentierungsebene (Level 2) generiert, wodurch "die bestehenden Segmente ihrerseits in kleinere Subsegmente (sog. Filialsegmente) zerlegt" (EHLERS et al. 2005, S.213) werden. Analog dazu wird ein zusätzliches erstes Level generiert, so "dass letztendlich kleine Segmente (sog. Nepotalsegmente verbleiben" (EHLERS et al. 2005, S.214). Dabei beträgt der Scale jedes neuen Levels die Hälfte des Wertes des jeweiligen darrüberliegenden Levels (vgl. Tabelle 4.1).

	Scale	Color	Shape	Compactness	Smoothness
Level 3	48	0,7	0,3	1,0	0,0
Level 2	24	0,7	0,3	1,0	0,0
Level 1	12	0,7	0,3	1,0	0,0
Endlevel	12	0,999	0,001	1,0	0,0

Tabelle 4.1: Segmentierungseinstellungen in eCognition.

Da die Generierung der Segmente ausschließlich auf Grundlage der höher auflösenden panchromatischen SPOT-Daten erfolgte, wurde die "2. Rule of thumb" zwar berücksichtigt, dennoch wurde nach ersten Versuchsreihen deutlich, dass eine sinnvolle Segmentierung panchromatischer Daten (insbesondere bei der Wahl des Color-Werts, der nur aus den panchromatischen Intensitätswerten resultiert) nur bei einer stärkeren Gewichtung des Formkriteriums Sinn macht, da sonst der in Kapitel 3.2.4 erwähnte Effekt, weit verzweigte Segmente zu generieren (siehe Abbildung 4.4, links), eintritt.

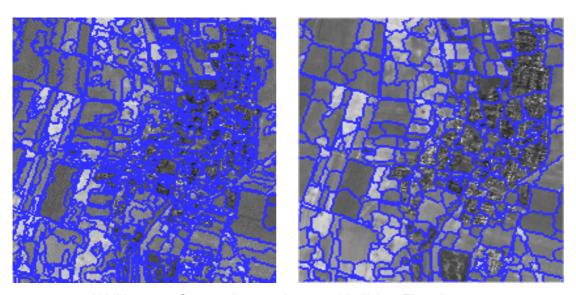


Abbildung 4.4: Segmentierung mit unterschiedlichen Einstellungen.

Das linke Bild in Abbildung 4.4 wurde, mit der Ausnahme den Wert für Color auf 1 zu setzen, auf Grundlage der Einstellungen für die zweite Ebene (vgl. Tabelle 4.1) segmentiert.

Es bestätigt sich, dass eine rein spektrale Segmentierung zu einer Vielzahl von wenig kompakten und verzweigten Segmenten, die insbesondere im Siedlungsflächenbereich zahlreich vorhanden sind, führt. Grund für diesen Effekt ist neben der Gewichtung des Color-Kriteriums, die heterogene Beschaffenheit der Siedlungsflächen, die sich in unterschiedlichen Grauwerten manifestiert. Da die spätere Klassifizierung aber nur zwei eindeutig definierte Klassen (Siedlung/Nicht-Siedlung) beinhalten soll, würde eine Vielzahl von Segmenten auch eine Vielzahl von möglichen Fehlerquellen bedeuten.

Wird hingegen der Shape-Wert auf 0,3 und das Kompaktheitskriterium auf den Wert 1 gesetzt (Abbildung 4.4, rechts), werden die Siedlungsflächen durch wesentlich größere und kompaktere Segmente abgebildet. Wird weiterhin von der Prämisse ausgegangen, dass anthropogen geprägte Strukturen in der Regel kompaktere Formen (Beispiel: Häuser) aufweisen als naturbelassene Flächen, stellt die Segmentierung im rechten Bild im Hinblick auf die Zielvorgabe die bessere Grundlage für eine Klassifizierung dar. Nach weiteren empirischen Versuchsreihen und manuellen Vergleichen wurden die Segmentierungseinstellungen gemäß Tabelle 4.1 als weitere Grundlage für die Klassifikation genutzt. Des Weiteren wurden, um die Entstehung möglichst kompakter Segmente zu forcieren, alle Segmentierungen mit einer N4-Nachbarschaft (vgl. Kapitel 3.5.1) durchgeführt.

4.2.3 Generelle Vorgehensweise bei der Klassifikation

Zum besseren Verständnis der generellen Strategie des vorgestellten Verfahrens wird zu Anfang, bevor es zur Erläuterung des Klassifikationsverfahrens im Detail kommt, in diesem Abschnitt das Grundprinzip skizziert:

Aufbauend auf dem hierarchischen Netzwerk von Segmenten (vgl. Tabelle 4.1) werden im dritten Level zunächst potenzielle Siedlungsflächen und Nicht-Siedlungsflächen bestimmt. Damit ergibt sich im folgenden Schritt die Möglichkeit, bei der Klassifikation der zweiten Ebene die bestimmten Nicht-Siedlungsflächen des dritten Levels ausschließen zu können. Analoge Vorgehensweise wird auch im ersten Level angewandt, bei dem die Nicht-Siedlungsflächen des zweiten Levels als

Ausschlussflächen für die Klassifikation des ersten Levels dienen. Parallel dazu werden in jedem Segmentierungslevel die Schwellwerte der genutzten Klassifikationsmerkmale (Textur, Form, Nachbarschaftsbeziehungen und spektrale Merkmale) der Zielklasse "Siedlung" so verschärft, so dass mit jeder Klassifikation in einer tiefer liegenden Segmentierungsebene ein besseres Klassifikationsergebnis erreicht wird (vgl. EHLERS et al. 2005, S. 215). In einem letzten Arbeitschritt werden die generierten Siedlungssegmente fusioniert und bisher nicht erfasste innerstädtische Flächen (Grünflächen, Seen oder Friedhöfe) der Klasse "Siedlung" zugeordnet.

Somit besteht der erste Arbeitschritt vor einer Klassifikation in der Definition von Klassifikationsregeln. Grundlage dafür ist in eCognition die Klassenhierarchie (Abbildung 4.5), welche die Basis für die nächsten Verfahrenschritte in den Abschnitten 4.2.4 bis 4.2.6 bildet. Die in dieser Hierarchie definierten Klassen und Klassenmerkmale werden in den nun folgenden Abschnitten sukzessive für jede Segmentierungsebene erläutert.

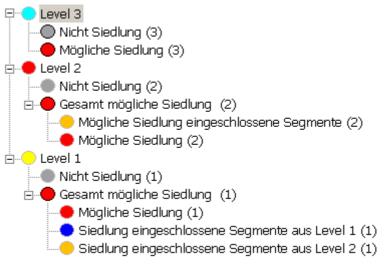


Abbildung 4.5: Klassenhierarchie in eCognition.

4.2.4 Klassifikation der dritten Segmentierungsebene

Der dritte Level besteht aus der Klasse "Nicht Siedlung (3)" und "Mögliche Siedlung (3)". Für jedes Segment der Klasse "Mögliche Siedlung (3)" werden die limitierenden Schwellwerte der Zugehörigkeitsfunktionen im ersten Schritt entsprechend niedrig angesetzt, da die (ggf. sehr) großen Segmente noch eine starke (spektrale) Hetero-

genität aufweisen. Konkret wurden für die Klasse "Mögliche Siedlung (3)" folgende Merkmale definiert (Abbildung 4.6).

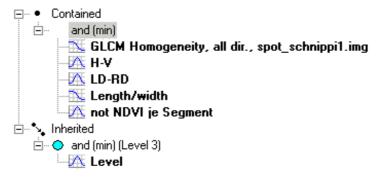


Abbildung 4.6: Merkmale der Klasse "Mögliche Siedlung (3)".

Alle nachfolgend beschrieben Merkmale wurden mit einem logischen "Und" verknüpft, so das eine Klassenzugehörigkeit eines Segmentes nur dann gegeben ist, wenn alle definierten Regeln bzw. Zugehörigkeitsfunktionen wahr sind. Bei dem Merkmal "GLCM Homogeneity, all dir" handelt es sich um das in Abschnitt 3.3.2 beschriebene Texturmerkmal Inverse Difference Moment (IDM). Die Auftrittswahrscheinlichkeit eines Grauwertpaars im SPOT-Bild (vgl. Formel 3.10) wird dabei als gemittelte Summe aller vier möglichen Richtungen der GLC-Matrix gebildet. Dabei ist die Zugehörigkeit eines Segments zur Klasse "Mögliche Siedlung (3)" nur bei entsprechender Heterogenität gegeben. Nach empirischen Versuchsreihen und manuellen Vergleichen wurde definiert, dass der IDM-Wert kleiner als 0,4 sein muss (Abbildung 4.7).

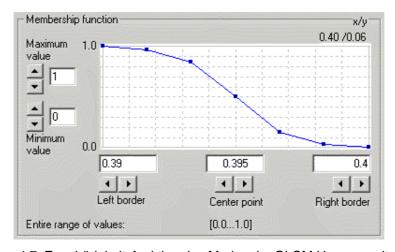


Abbildung 4.7: Zugehörigkeitsfunktion des Merkmals "GLCM Homogeneity, all dir".

Zwar lassen sich mit dem IDM-Merkmal bereits grobe Differenzierungen zwischen besiedelten (heterogenen) und unbesiedelten (teilweise homogenen) Bereichen ableiten, dennoch besteht die in Abbildung 4.3 aufgezeigte Problematik der Fehlzuordnung von landwirtschaftlichen Flächen (Äcker und Felder) zur Klasse "Siedlung". Grund hierfür ist, dass insbesondere Regionen mit Feld- und Ackerflächen ähnliche Texturmerkmale aufweisen können wie Siedlungsflächen. Einen Ansatz zur Lösung dieser Problematik zeigt STEINNOCHER (1997) auf, indem er bei der Flächenbeschreibung drei texturale Eigenschaften in Bildern unterscheidet:

- 1. richtungsabhängige inhomogene Flächen
- 2. richtungsunabhängige inhomogene Flächen
- 3. homogene Flächen

Demnach weisen GLC-Matrizen richtungsunabhängiger inhomogener Flächen und homogener Flächen untereinander ähnliche Formen auf, entweder stark streuend bei inhomogenen Gebieten (z. B. Siedlungen) oder mit geringer Streuung in homogenen Gebieten (z. B. Wald). Bei Feldern bzw. landwirtschaftlichen Flächen weisen die GLC-Matrizen durch das Vorhandensein von geradlinigen Außengrenzen (Kanten) jedoch kaum Streuung auf.

Dieser Unterschied lässt sich quantitativ in dem aus den GLC-Matrizen abgeleiteten Texturmerkmal IDM belegen (Tabelle 4.2). Bei einer Berechnung des IDM für alle vier möglichen Richtungen (horizontal, vertikal, rechtsdiagonal und linksdiagonal) zeigt sich, dass die Werte des IDM innerhalb von Siedlungs- und Waldbereichen annähernd identisch sind, sich bei landwirtschaftlichen Flächen (Feldern) die Hauptrichtung der Kanten (Außengrenzen) deutlich in den berechneten IDM-Werten widerspiegelt.

Null" (STEINNOCHER 1997, S. 147) bilden.

IDM	Feld	Siedlung	Wald
horizontal	0.146	0.113	0.227
vertikal	0.254	0.120	0.269
rechtsdiagonal	0.141	0.092	0.201
linksdiagonal	0.145	0.088	0.189

Tabelle 4.2: Texturparameter im Vergleich (verändert nach STEINNOCHER 1997, S. 147).

Das IDM von Äckern und Feldern zeigt für die vertikale Richtung (rot umrandet) einen deutlich höheren Wert als die übrigen Richtungswerte. Dies rührt daher, dass durch Differenzbildung "zweier normal aufeinander stehender Texturmerkmale [...] sich in Kantenumgebungen – und nur dort – Differenzen [...] signifikant größer

"
$$LD - RD$$
" = $\sqrt{(IDM_{45^{\circ}} - IDM_{135^{\circ}})^2}$ (Formel 4.1)

"
$$H - V$$
" = $\sqrt{(IDM_{0^{\circ}} - IDM_{90^{\circ}})^2}$ (Formel 4.2)

Da es pro Umgebung zwei Möglichkeiten der Differenzbildung gibt, wird zum einem der Betrag des Differenzwerts zwischen linksdiagonaler und rechtsdiagonaler Ausrichtung (Klassifikationsmerkmal "LD-RD") und zum anderem zwischen horizontaler und vertikaler Ausrichtung (Klassifikationsmerkmal "H-V") des IDM als benutzerdefiniertes Merkmal in eCognition (vgl. Kapitel 3.5.3) implementiert (Abbildung 4.8 und Abbildung 4.9).



Abbildung 4.8: Benutzerdefiniertes Merkmal "LD-RD".

H-V
Feature calculator ((<glcm 0°,="" dir.="" homogeneity,="" spot_schnippi1.img="">-<glcm 90°,="" dir.="" homogeneity,="" spot_schnippi1.img="">)^2)^0.5</glcm></glcm>

Abbildung 4.9: Benutzerdefiniertes Merkmal "H-V".

Nach der Durchführung iterativer Versuchsreihen wurde der Wertebereich für die Texturmerkmale "H-V" und "LD-RD" auf 0 bis 0,07 festgelegt (Abbildung 4.10).

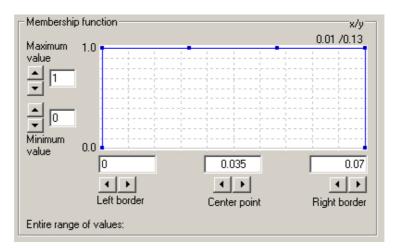


Abbildung 4.10: Zugehörigkeitsfunktionen der Merkmale "H-V" und "LD-RD".

Weiteres Klassifikationsmerkmal zur Elimination von Nicht-Siedlungsflächen ist das "Length/width"-Verhältnis (vgl. Kapitel 3.5.3). Da nach der Segmentierung insbesondere Straßen im Außenbereich (vgl. Abbildung 4.3) als längliche Objekte abgebildet wurden, diese aber ähnliche Texturwerte wie Siedlungsflächen aufweisen können, musste auf Grundlage der Definition von APEL & HENCKEL (1995) ein Weg zur Eliminierung dieser Objekte gefunden werden. Dazu wurden die Schwellwerte für das Längen-Breiten-Verhältnis so bestimmt, dass möglichst nur extrem lange Straßen im Außenbereich herausfallen. Nach der Durchführung mehrerer Versuchsreihen wurde für die Klasse "Mögliche Siedlung (3)" ein Längen-Breiten-Verhältnis von unter 3 determiniert (Abbildung 4.11), so dass alle Segmente mit einem Wert größer als 3 definitiv herausfallen.

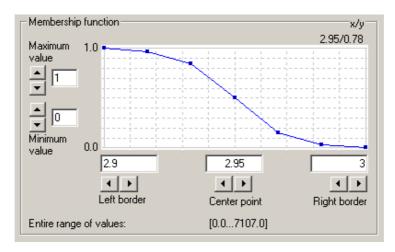


Abbildung 4.11: Zugehörigkeitsfunktion des Merkmals "Length/width".

Nach den in Kapitel 4.2.1 geschilderten Problematiken bei einer ausschließlichen Klassifikation von Siedlungsflächen mit dem IDM-Merkmal, musste für die Verbesserung des Ergebnisses noch ein Abgrenzungskriterium zur Elimination von Vegetation gefunden werden. Ein in der Fernerkundung gebräuchliches Merkmal ist der sogenannte NDVI (engl.: Normalized Difference Vegetation Index): "Er verknüpft Daten im Nahen Infrarot (NIR), auf die sich die Vitalität der Vegetation besonders auswirkt, mit Daten im roten Spektralbereich (ROT)" (ALBERTZ 2001, S. 219):

$$NDVI_{Seg} = \frac{IR_{c_m} - R_{c_m}}{IR_{c_m} + R_{c_m}}$$
 (Formel 4.3)

mit

c_m = Mittelwert der Grauwerte eines Segments,

IR = Reflexionswert im nahen Infrarotbereich,

R = Reflexionswert im sichtbaren Rot-Bereich.

Die spektralen Merkmale für jedes erzeugte Segment können in eCognition nur aus den gemittelten Durchschnitten der Grauwerte je Segment (vgl. Formel 3.15) gebildet werden, wodurch auch nur ein durchschnittlicher NDVI berechnet werden kann. Da der NDVI nicht standardmäßig implementiert ist, wurde ein benutzerdefiniertes Merkmal "NDVI je Segment" (Abbildung 4.12) auf Grundlage der LANDSAT-Daten gemäß Formel 4.3 eingefügt. Die Selektion der einzelnen Spektralbänder wurde über das Klassifikationsmerkmal "layer mean" (Kapitel 3.5.3) realisiert.

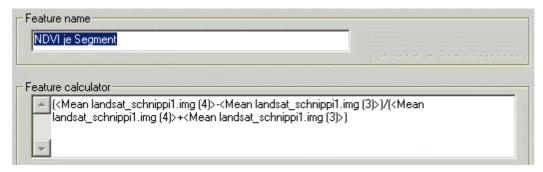


Abbildung 4.12: Benutzerdefiniertes Merkmal "NDVI je Segment".

Da wegen der Mittelwertbildung bei großen Segmenten die Gefahr besteht, kleine Siedlungsflächen in ländlichen Räumen fälschlicherweise zu eliminieren, mussten die Schwellwerte der Zughörigkeitsfunktion für die dritte Ebene sehr hoch angesetzt werden. Dementsprechend wurde definiert, dass der "NDVI je Segment" für die Klasse "Mögliche Siedlung (3)" nicht im Wertebereich von 0,5 bis 1 liegen darf (Abbildung 4.13).

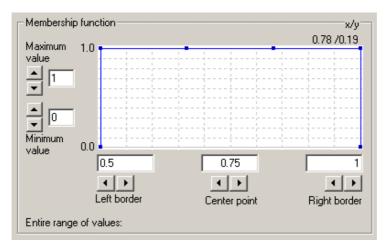


Abbildung 4.13: Zugehörigkeitsfunktion des Merkmals "NDVI je Segment".

Die Klasse "Nicht Siedlung (3)" wird über die Negation der Ähnlichkeit zur Klasse "Mögliche Siedlung (3)" (vgl. Kapitel 3.5.3) gebildet (Abbildung 4.14) und besitzt keine weiteren Merkmale.



Abbildung 4.14: Merkmale der Klasse "Nicht Siedlung (3)".

Die Klassifikation des dritten Levels erfolgt ohne Berücksichtigung klassenbezogener Merkmale (vgl. Kapitel 3.5.2), da noch keine Beziehungen zu anderen Hierarchie- ebenen oder Nachbarobjekten definiert wurden. Abbildung 4.15 zeigt das Klassifikationsergebnis für die dritte Ebene. Dabei wird die Klasse "Mögliche Siedlung (3)" durch ein transparentes Hellgrau dargestellt. Soweit im Text nicht anders zugewiesen, gilt diese Farbzuweisung für die Klassen "Siedlung" und "Nicht-Siedlung" für alle folgenden Abbildungen der Klassifikationsergebnisse.

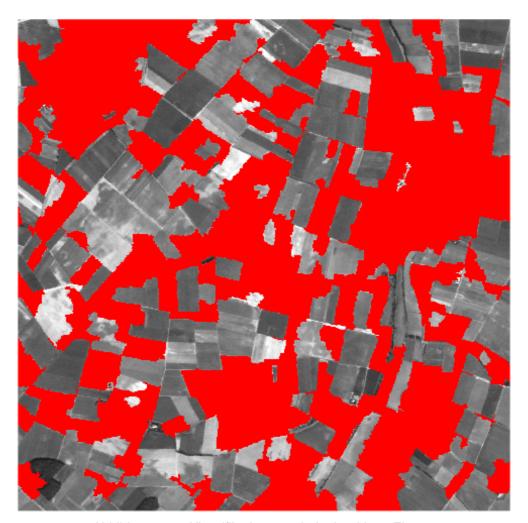


Abbildung 4.15: Klassifikationsergebnis der dritten Ebene.

4.2.5 Klassifikation der zweiten Segmentierungsebene

Bei der Klassifikation der zweiten Segmentierungsebene werden die Restriktionen von Textur-, Form- und NDVI-Merkmalen angehoben; zusätzlich zu den bereits be-

kannten Klassen und Klassifikationsmerkmalen werden weitere Neuerungen eingeführt. So wurden in der Klassenhierarchie (vgl. Abbildung 4.5) die Tochterklassen "Mögliche Siedlung (2)" und "Mögliche Siedlung eingeschlossene Segmente (2)" eingeführt, die in der Mutterklasse "Gesamt mögliche Siedlung (2)" zusammengefasst werden.

Bei der Klasse "Mögliche Siedlung (2)" handelt es sich im Wesentlichen um die bereits bekannte Klasse "Mögliche Siedlung (3)". Jedoch wurden die Restriktionen der vorgestellten Merkmale verschärft und neue Merkmale bzw. Regeln hinzugefügt (Abbildung 4.16).

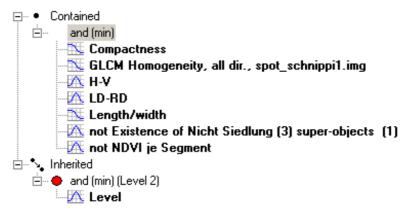


Abbildung 4.16: Merkmale der Klasse "Mögliche Siedlung (2)".

Die erste Neuerung besteht in der Anwendung der in Kapitel 3.5.3 angesprochenen "Existence of" Beziehung. Bei der Anwendung dieses Merkmals wird von den Vorteilen des hierarchischen Segmentierungsnetzwerks Gebrauch gemacht, indem die übrigen Klassifikationsmerkmale nur noch für die Segmente berechnet werden, die Teil eines Nicht-Ausschlussflächen-Segments sind. Dies geschieht, indem die Zugehörigkeitsfunktion des Merkmals "not Existence of Nicht Siedlung (3) super-objects (1)" auf den Wert 1 (wahr) gesetzt wird (Abbildung 4.17).

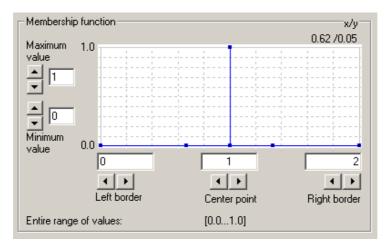


Abbildung 4.17: Zugehörigkeitsfunktion zum Merkmal "not Existence of Nicht Siedlung (3) super-objects (1)".

Die zweite Neuerung besteht in der Einführung eines weiteren Formparameters, dem Kompaktheitsgrad (vgl. Formel 3.17). Grundidee der Einführung dieses Merk-mals war, dass bei einem geringeren Scale (vgl. Tabelle 3.2) Strukturen in Siedlungen (Beispiel: Gebäude) in der Regel kompakter als Naturflächen im Außenbereich (Beispiel: Flüsse und Berge) abgebildet werden.

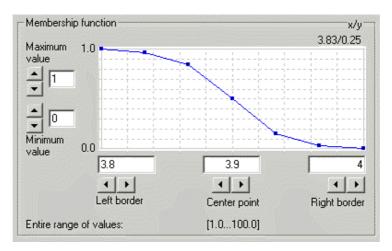


Abbildung 4.18: Zugehörigkeitsfunktion zum Merkmal "Compactness".

Nach Durchführung mehrerer Versuchsreihen bestätigte sich diese Annahme und es konnten weitere Nicht-Siedlungsflächen eliminiert werden. Dabei wurde die Zugehörigkeitsfunktion (Abbildung 4.18) so definiert, dass alle Segmente mit einem Kompaktheitsgrad von unter 4 in die Klasse "Mögliche Siedlung (2)" fallen können.

Wie bereits erwähnt, werden bei den zuvor vorgestellten Klassifikationsmerkmalen die Restriktionen verschärft, so dass an dieser Stelle auf weitere Abbildungen von

Zugehörigkeitsfunktionen dieser Merkmale verzichtet wird und nur die Wertveränderung im Text beschrieben wird.

So wurden für das IDM-Merkmal "GLCM Homogeneity, all dir" die Fuzzy-Grenzen (left border und right border) der Zugehörigkeitsfunktion auf 0,23 bis 0,24 erniedrigt, womit alle Segmente, die einen IDM-Wert von weniger als 0,24 aufweisen, in die Klasse "Mögliche Siedlung (2)" fallen können.

Ferner wurde der Wertebereich für die Texturmerkmale "H-V" und "LD-RD" auf 0 bis 0,065 erniedrigt und für das Längen-Breiten-Verhältnis der Fuzzy-Bereich der Zugehörigkeitsfunktion auf 2,8 bis 2,9 festgelegt.

Des Weiteren wurde auf Grund des geringeren Skalenniveaus das Merkmal "NDVI je Segment" für die Klasse "Mögliche Siedlung (2)" so verschärft, dass er nicht im Wertebereich von 0,4 bis 1 liegen darf.

Die Einführung der Tochterklasse "Mögliche Siedlung eingeschlossene Segmente (2)" wurde nötig, da durch die Verschärfung der Restriktionen in der Klasse "Mögliche Siedlung (2)" zwar eine erfolgreiche Eingrenzung von Siedlungsflächen bewirkt wurde, aber durch die Schwellwertanhebung ebenfalls eine Elimination von Siedlungsflächen innerhalb von Siedlungsgebieten auftrat. Nach SCHIEWE et al. (2001, S. 39) liegt dies am Klassifikationsansatz in eCognition, da der "hierachical approach can lead to undesired sliver ploygons or even missing segments". Beispiele für solche Splitterpolygone (gelb umrandet) sind in Abbildung 4.19 visualisiert.

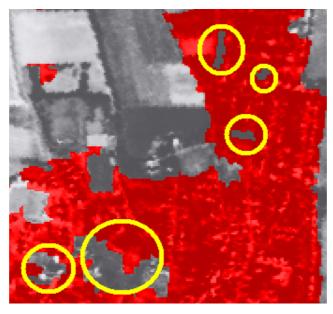


Abbildung 4.19: Eliminierte Siedlungsbereiche (Splitterpolygone) innerhalb von Siedlungen.

Um diese fälschlicherweise ausgeschlossenen Segmente (Gebiete mit geringer Textur oder Grünflächen) wieder einzugliedern, wurde die Tochterklasse "Mögliche Siedlung eingeschlossene Segmente (2)" über folgende Klassenmerkmale definiert (Abbildung 4.20):

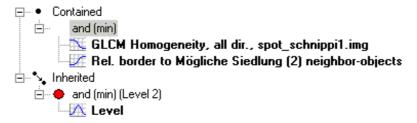


Abbildung 4.20: Merkmale der Klasse "Mögliche Siedlung eingeschlossene Segmente (2)".

Zum einem mussten die betroffenen Segmente dieser Klasse eine geringfügig stärkere Textur aufweisen als die der Klasse "Mögliche Siedlung (2)". Somit soll sichergestellt werden, dass landwirtschaftliche Flächen in Randzonen zu besiedelten Gebieten nicht wieder der Klasse "Mögliche Siedlung (2)" zugeordnet werden. Nach mehreren Versuchen wurde definiert, dass der IDM-Wert unter 0,235 liegen muss (Abbildung 4.21).

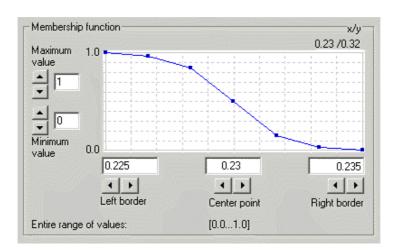


Abbildung 4.21: Zusätzliche Zugehörigkeitsfunktion des Merkmals "GLCM Homogeneity, all dir".

Zum anderem wurde, um die Beziehung zu den Nachbarsegmenten herzustellen, das Klassifikationsmerkmal "Relative border to" (vgl. Kapitel 3.5.3) eingeführt. Da die zweite Segmentierungsebene noch nicht das endgültige Klassifikationsergebnis darstellt, wurden die Schwellwerte für die Zugehörigkeitsfunktion bewusst weit gefasst, so dass möglichst viele Splitterpolygone der Mutterklasse "Gesamt mögliche Sied-

lung (2)" zugeschlagen werden. Demnach müssen die betroffenen Segmente zu mindestens 50 % von Segmenten der Klasse Siedlung umgeben sein (Abbildung 4.22).

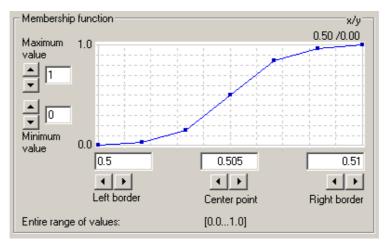


Abbildung 4.22: Zugehörigkeitsfunktion des Merkmals "Relative border to Mögliche Siedlung (2) neighbor objects".

Für die Klasse "Nicht Siedlung (2)" gelten die Klassifikationsregeln wie für die Klasse "Nicht Siedlung (3)" (vgl. Abbildung 4.14) mit dem Unterschied, dass sich die Negation auf die zweite Segmentierungsebene bezieht.

Weil bei den Klassifikationsregeln der aktuellen Segmentierungsebene auch die Klassenmerkmale anderer Objekte aus anderen Ebenen genutzt werden (Nachbarschaftsbeziehungen und Superobjekte), muss die Klassifikation iterativ durchgeführt werden. Dazu wird eine Klassifikation mit "klassenbezogenen Merkmalen" (siehe auch Kapitel 3.5.2) durchgeführt. Nach einer Vorgabe von fünf Iterationsschritten (Zyklen) sind keine Veränderungen im Ergebnis zu erkennen, so dass diese Einstellung benutzt wurde.

Um das Klassifikationsergebnis der zweiten Segmentierungsebene nochmals zu verbessern, wird eine "Classification based segmentation" (vgl. Kapitel 3.5.1) durchgeführt. Dies bewirkt, dass alle Segmente der Klasse "Gesamt mögliche Siedlung (2)" soweit wie möglich zusammengefasst werden. Vor dem Zusammenfassen der Segmente ist das Anlegen einer "structure group" nötig, in der die zu fusionierenden Klassen definiert werden (Abbildung 4.23).

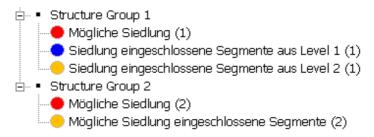


Abbildung 4.23: Structure group zur Fusion von Segmenten.

Da dieser Arbeitschritt für die erste Segmentierungsebene ebenfalls durchgeführt wird, sind in Abbildung 4.23 bereits zwei "structure groups" definiert.

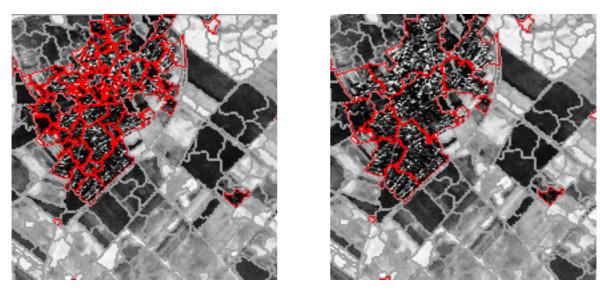


Abbildung 4.24: Segmentierung des zweiten Level vor (links) und nach (rechts) einer Fusion.

Nach der "Classification based segmentation" erfolgt eine Neuklassifizierung mit "klassenbezogenen Merkmalen" in fünf Zyklen mit dem Ziel, durch die fusionierten und größeren Segmente noch vorhandene Splitterpolygone über die Klasse "Mögliche Siedlung eingeschlossene Segmente (2)" erneut in die Mutterklasse einzugliedern.

Wie Abbildung 4.24 verdeutlicht, konnten die Siedlungssegmente (rot umrandet) der Klasse "Gesamt mögliche Siedlung (2)" erfolgreich zusammengefasst werden (Abbildung 4.24, rechts). Eine vollständige Fusion zu einen einzigen großem Siedlungssegment ist (an dieser Stelle des hierarchischen Netzwerks) nicht möglich, da die dritte Segmentierungsebene (vgl. Abbildung 3.10) die Obergrenze für die Fusion von Segmenten im hierarchischen Netzwerk bildet. Abbildung 4.25 zeigt das Klassifikationsergebnis der zweiten Segmentierungsebene.

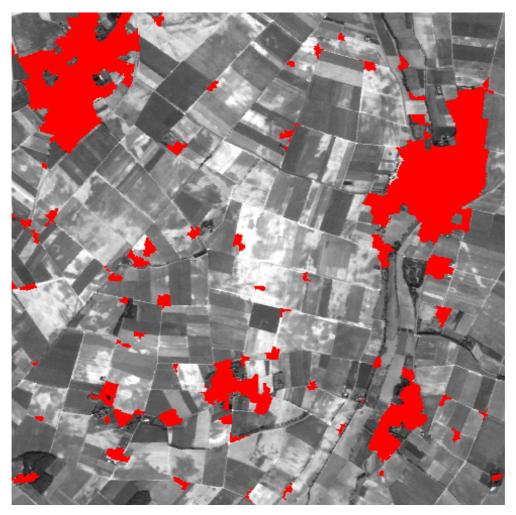


Abbildung 4.25: Klassifikationsergebnis der zweiten Ebene.

4.2.6 Klassifikation der ersten Segmentierungsebene

Entsprechend dem Grundprinzip des Verfahrens (vgl. Kapitel 4.2.3) werden bei der Klassifikation der ersten Segmentierungsebene nochmals die Restriktionen für Textur-, Form- und NDVI-Merkmale angehoben. Die Klassenhierarchie für die erste Segmentierungsebene unterscheidet sich nur geringfügig zu der Hierarchie der zweiten Ebene. So besteht die Mutterklasse "Gesamt mögliche Siedlung (1)" aus insgesamt drei Tochterklassen.

Die erste Tochterklasse "Mögliche Siedlung (1)" beinhaltet die Klassenmerkmale der bereits bekannten Klasse "Mögliche Siedlung (2)" mit schärferen Restriktionen. So wurden für das IDM-Merkmal "GLCM Homogeneity, all dir" die Fuzzy-Grenzen der Zugehörigkeitsfunktion auf 0,22 bis 0,23 erniedrigt. Ebenfalls wurde der Wertebe-

reich für die Texturmerkmale "H-V" und "LD-RD" enger gefasst. Der Wertebereich liegt nun bei 0 bis 0,060.

Das benutzerdefinierte Merkmal "NDVI je Segment" für die Klasse "Mögliche Siedlung (1)" wurde so verschärft, dass potenzielle Siedlungsflächen keinen NDVI im Wertebereich von 0,34 bis 1 haben dürfen. Die Einstellungen für den Kompaktheitsgrad (left border: 3,75 und rigth border: 3,95) und des Längen-Breiten-Verhältnisses (left border: 2,75 und rigth border: 2,85) wurden bei Beibehaltung der Form der Zugehörigkeitsfunktionen ebenfalls erniedrigt.

Da zwar durch die nochmals verschärften Restriktionen die Siedlungsrandbereiche besser abgegrenzt werden, aber wiederum auch innere Siedlungsbereiche (Splitterpolygone) wegfallen, wird (analog zum zweiten Level) eine zweite Tochterklasse "Siedlung eingeschlossene Segmente aus Level 1 (1)" eingefügt, deren Regeln wie folgt aussehen (Abbildung 4.26).

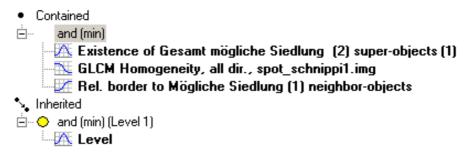


Abbildung 4.26: Merkmale der Klasse "Mögliche Siedlung eingeschlossene Segmente aus Level 1 (1)".

Die Klassenmerkmale und Zugehörigkeitsfunktionen sind insoweit mit denen der bekannten Klasse "Mögliche Siedlung eingeschlossene Segmente aus Level 2 (2)" identisch, mit der Ausnahme, dass sich die Merkmale bzw. Regeln auf den ersten Level beziehen und die Splitterpolygone in möglichen Siedlungsflächen der zweiten Ebene verortet sein müssen. Letztere Bedingung wird über eine "Existence of"-Beziehung realisiert, deren Zugehörigkeitsfunktion nur bei dem Wert 1 (für wahr) eine Zuordnung von Splittersegmenten in diese Klasse möglich macht (siehe dazu auch Abbildung 4.17). Die Einstellungen für das Klassifikationsmerkmal "Relative border to" bleiben im Vergleich zur zweiten Ebene unverändert, die Schwellwerte des IDM werden wiederum leicht erniedrigt (left border: 0,215 und rigth border: 0,225).

Die dritte Tochterklasse "Mögliche Siedlung eingeschlossene Segmente aus Level 2 (1)" dient dazu, die zuvor in Level 2 ermittelten Siedlungssegmente der Klasse "Mögliche Siedlung eingeschlossene Segmente aus Level 2 (2)" im aktuellen Level beizubehalten. Dazu wird eine "Existence of"-Beziehung zu den betroffenen Superobjekten (Splitterpolygone aus dem 2. Level) definiert, wodurch die Zugehörigkeitsfunktion nur einen Wahrheitswert besitzt (vgl. Abbildung 4.17).

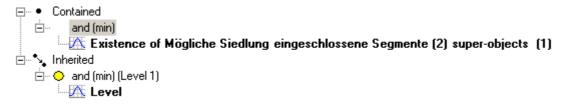


Abbildung 4.27: Merkmale der Klasse "Mögliche Siedlung eingeschlossene Segmente aus Level 2 (1)".

In der Klasse "Nicht Siedlung (1)" werden, analog zu der Klasse "Nicht Siedlung (2)", die verbliebenen Nicht-Siedlungsflächen durch Negation der Klasse "Gesamt Siedlung (1)" zusammengefasst. Nach einer klassenbezogenen Klassifikation mit fünf Zyklen und einer "Classification based Segmentation" mit anschließender Neuklassifizierung sind alle Arbeitsschritte in der ersten Segmentierungsebene abgeschlossen. Abbildung 4.28 zeigt das Zwischenergebnis der ersten Ebene.

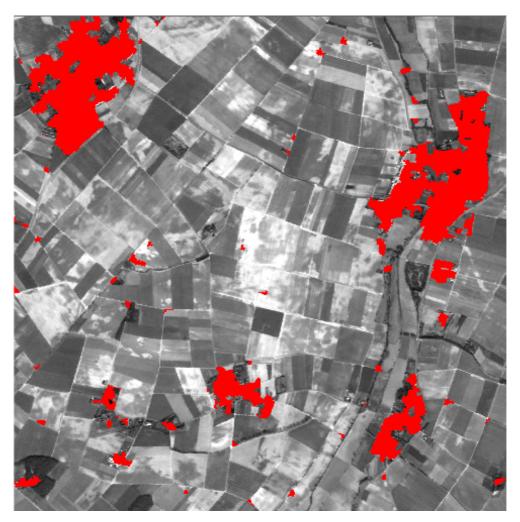


Abbildung 4.28: Klassifikationsergebnis der ersten Ebene.

Alle bis dato beschriebenen Verfahrensschritte wurden in eCognition über den Protokolleditor automatisiert. Abbildung 4.29 stellt die einzelnen Verfahrenschritte im Protokolleditor zusammenfassend dar.

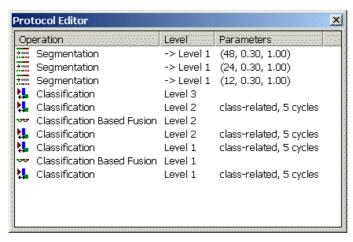
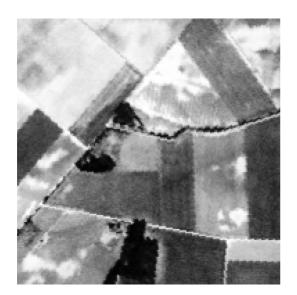


Abbildung 4.29: Automatisierung der Arbeitschritte im Protokolleditor.

4.2.7 Letzte Arbeitschritte zur Erzeugung der Siedlungsmaske

Abweichend vom Grundprinzip des bisher entwickelten Verfahrens, mit jeder Segmentierungsebene die Restriktionen der Klassenmerkmale zu verschärfen, wurden zur nochmaligen Verbesserung der Klassifikationsgüte weitere Verfahrensschritte entwickelt.

Bei einer genaueren Betrachtung des bis dato erreichten Ergebnisses fällt auf, dass zwar viele landwirtschaftliche Flächen durch die Texturmerkmale "H-V", "LD-RD" und das spektrale Merkmal "NDVI je Segment" ausgeschlossen werden konnten, dass aber dennoch Fehlklassifizierungen bei landwirtschaftlich genutzten Flächen nicht völlig vermieden werden konnten (Abbildung 4.30).






Abbildung 4.30: Beispiele für Fehlklassifizierungen.

Bei Interpretation der in Abbildung 4.30 aufgezeigten Fehlzuordnungen (gelb umrandet) bleibt festzustellen, dass insbesondere landwirtschaftliche Flächen ohne Vegetation auf Grund ihrer Texturierung der Klasse "Siedlung" zugerechnet werden.

Einen Ansatz zur Lösung dieses Problems zeigt JÜRGENS (1997) auf, indem er Siedlungsflächen und landwirtschaftliche Flächen über die Grauwertvarianz (statistischer Parameter 1. Ordnung, vgl. Kapitel 3.3.1) differenziert. Demnach weisen Siedlungsflächen im Gegensatz zu landwirtschaftlichen Flächen eine signifikant höhere Grauwertvarianz auf.

Um eine Unterscheidung über von Siedlungsflächen und Nicht-Siedlungsflächen vornehmen zu können, musste zur Umsetzung diese Ansatzes in eCognition ein neues benutzerdefiniertes Merkmal implementiert werden. Dies geschieht über die Quadrierung der Standardabweichung der Grauwerte je Segment (vgl. Formel 3.16), so dass gilt:

$$\nu = s^2$$
 (Formel 4.4)
$$\label{eq:v} \text{mit}$$

$$\label{eq:v} \nu = \text{Grauwertvarianz je Segment}.$$

Die entsprechende Definition des neuen Merkmals "Varianz DN je Segment"¹⁸ in e-Cognition ist in Abbildung 4.31 dokumentiert.

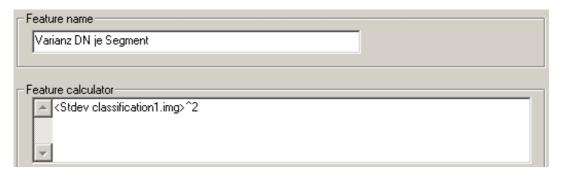


Abbildung 4.31: Benutzerdefiniertes Merkmal "Varianz DN je Segment".

Da der bisherige Ergebnislevel bei einem Scale von 12 sehr viele kleine und nicht zusammenhängende Segmente beinhaltet, besteht bei der Anwendung des neuen Merkmals die Gefahr, eine Vielzahl von neuen, nicht erwünschten Splitterpolygonen zu erzeugen.

Zur Vermeidung dieses Phänomens werden die zweite und dritte Segmentierungsebene gelöscht, um alle Segmente der Klasse "Gesamt mögliche Siedlung (1)" mittels einer "Classification based segmentation" vollständig zu verschmelzen (die notwendige "structure group" ist bereits in Abbildung 4.23 definiert worden). Da durch die Löschung der oberen Hierarchieebenen keine Grenzen für die Fusion bestehen, können insbesondere zusammenhängende Siedlungsflächen vollständig zu einem großen, nicht mehr veränderbaren Segment zusammengefasst werden. Dies hat den

¹⁸ Die Abkürzung "DN" steht in der englischen Sprache für "digital number" und entspricht den Grauwerten im Bild.

Vorteil, dass bei einer nochmaligen Klassifikation das Wegfallen innerer Siedlungsbereiche (Splitterpolygone) vermieden wird und Tochterklassen zur Eingliederung nicht mehr erstellt werden müssen. Nach der Segmentfusion, die in der Erzeugung eines neuen zweiten Levels mündet, können über eine Neudefinition der Klassifikationsregeln weitere Nicht-Siedlungsflächen über die Grauwertvarianz ausgeschlossen werden. Dazu müssen zuvor alle bisherigen Klassen des zweiten und dritten Levels in der alten Klassenhierarchie manuell gelöscht werden, um im nächsten Schritt den Ansatz von JÜRGENS (1997) über eine modifizierte Klassenhierarchie zu implementieren (Abbildung 4.32).

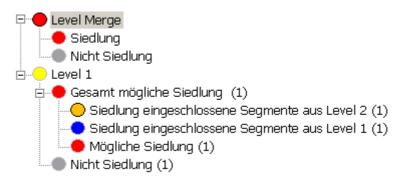


Abbildung 4.32: Modifizierte Klassenhierarchie.

Da der vorhandene erste Level nach wie vor Grundlage für den Klassifikationsprozess ist, werden alle Regeln und Ergebnisse dieser Ebene unverändert beibehalten. Das Regelwerk für den neu generierten Level muss jedoch wiederum manuell editiert werden, da bei einer kompletten Neudefinition der Klassenhierarchie das Ergebnis des ersten Levels verloren gehen würde. Im Einzelnen wurden für die Klasse "Siedlung" des neu generierten "Level Merge" folgende Merkmale definiert (Abbildung 4.33):



Abbildung 4.33: Merkmale der Klasse "Siedlung" im neu erzeugten "Level Merge".

Das erste Merkmal stellt eine Beziehung zu den Sub-Objekten der Klasse "Gesamt mögliche Siedlung (1)" her. Wie bereits zuvor wird die Zuordnung über eine "Existence of"-Beziehung realisiert (Zugehörigkeitsfunktion wie in Abbildung 4.17). Die Schwellwerte des zweiten Merkmals "Varianz DN je Segment" wurden nach manuellen Vergleichen so definiert, dass nur Segmente mit einer Grauwertvarianz von weniger als 75 keine Siedlungsflächen sein können (Abbildung 4.34).

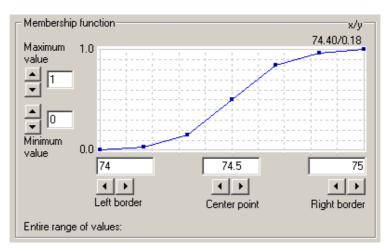


Abbildung 4.34: Zugehörigkeitsfunktion des benutzerdefinierten Merkmals "Varianz DN je Segment".

Die Klasse "Nicht Siedlung" wird über das gleiche Ausschlussprinzip wie die Klasse "Nicht Siedlung (1)" gebildet. Nach einer klassenbezogenen Klassifikation mit fünf Zyklen wird das Ergebnis als Rasterbild im TIFF-Format¹⁹ abgespeichert.

Da das Ziel dieser Arbeit (vgl. Kapitel 1.2) die Erfassung von Siedlungsflächen und nicht etwa die Erfassung von versiegelter Fläche ist (vgl. APEL & HENCKEL 1995), besteht der letzte Arbeitschritt darin, innerstädtische Flächen wie Grünflächen, Wasserflächen oder Friedhöfe, die keine Textur aufweisen, aber per Definition zur Siedlungsfläche gehören, der binären Siedlungsmaske zuzuordnen.

Dazu wird das abgespeicherte Zwischenergebnis mit Hilfe der Software Erdas-Imagine auf 1 bit rekodiert und im Anschluss in eCognition segmentiert. Mit der Wahl der Segmentierungsparameter (Endlevel, vgl. Tabelle 4.1) kann via einer neuen Klassenhierarchie (bestehend aus den Klassen "Siedlung" und "Eingeschlossene Siedlungsflächen") einfach zwischen den bereits ermittelten Siedlungssegmenten,

gi-reports@igf

83

¹⁹ Tagged Image File Format.

mit einem Grauwert von 1 und den gesuchten inneren Segmenten mit dem Grauwert 0 differenziert werden.



Abbildung 4.35: Merkmal der Klasse "Siedlung" im Endlevel.

Dazu muss die Zugehörigkeitsfunktion (Form analog zu Abbildung 4.17) des Merkmals "Layer mean" (Formel 3.15) für die Klasse "Siedlung" exakt den Wert 1 aufweisen und die gesuchte Klasse "Eingeschlossene Siedlungsflächen" (Abbildung 4.36) zu 100 % von den ermittelten benachbarten Siedlungsflächen mit dem Grauwert 1 umgeben sein.

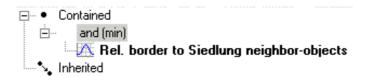


Abbildung 4.36: Merkmal der Klasse "Eingeschlossene Siedlungsflächen" im Endlevel.

Der Wert der Zugehörigkeitsfunktion des Merkmals "Rel. Border to Siedlung neigborobjects" muss dabei exakt 1 (für 100 %) betragen, so dass die Funktionsform von Abbildung 4.17 gilt. Durch eine klassenbezogene Klassifikation mit 5 Zyklen wird der Prozess in eCognition abgeschlossen.

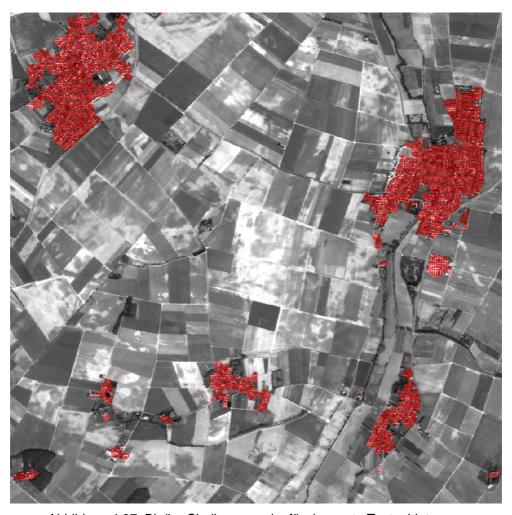


Abbildung 4.37: Binäre Siedlungsmaske für das erste Testgebiet.

Im letzten Arbeitschritt wird die Siedlungsmaske in Erdas Imagine auf 1 bit rekodiert und georeferenziert, womit als Endergebnis (Abbildung 4.37) die binäre Siedlungsmaske (Teilziel 2) vorliegt. Abbildung 4.38 stellt alle Verfahrenschritte (beginnend rechts oben) schematisch und zusammenfassend dar.

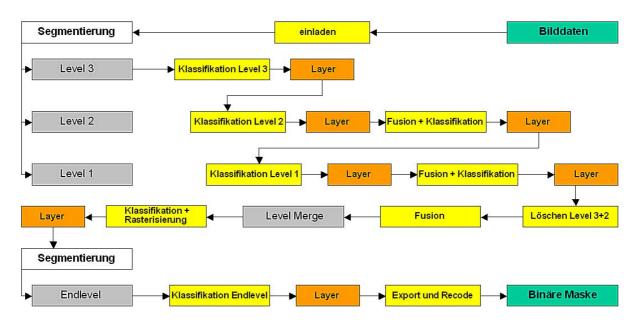


Abbildung 4.38: Verfahrenschritte zur Generierung einer binären Maske (Quelle: Eigene Darstellung).

4.3 Fallbeispiel 2: KOMPSAT und ASTER

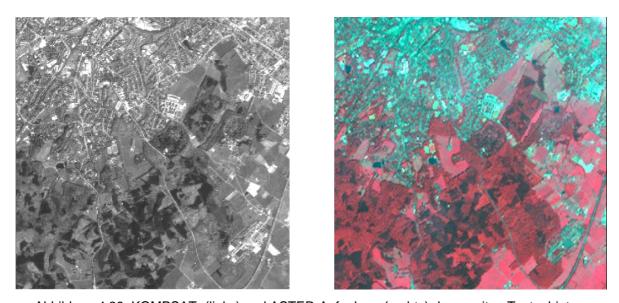


Abbildung 4.39: KOMPSAT- (links) und ASTER-Aufnahme (rechts) des zweiten Testgebietes.

Abbildung 4.39 zeigt die verwendeten KOMPSAT- und ASTER-Aufnahmen des zweiten Untersuchungsgebietes, bei dem es sich um einen Ausschnitt des südlichen Stadtgebietes von Aachen handelt. Im Norden der Aufnahme befinden sich zusammenhängende Siedlungsbereiche, im Süden überwiegend Wald. Im Süd-Osten ist die Autobahn 44 zu erkennen. Insgesamt weist das Gebiet eine Fläche von 25 km² auf.

4.3.1 Vorüberlegungen

Eine Möglichkeit zur Anpassung des in Kapitel 4.2 vorgestellten Verfahrens auf Satellitenbilddaten mit differierender geometrischer Auflösung besteht in dem Ansatz, neue Unterteilungssegmentierungen zu berechnen und die Schwellwerte der Klassenmerkmale entsprechend anzupassen.

Da es sich bei dieser Vorgehensweise um einen zeitaufwendigen Prozess handelt und die in diesem Abschnitt zur Segmentierung verwendeten KOMPSAT-Daten mit 6,6 m räumlicher Auflösung nur geringfügige Unterschiede zu den in Kapitel 4.2 verwendeten SPOT-Daten erwarten ließen, wurde zuerst das in Kapitel 4.2 vorgestellte Verfahren unverändert auf die neuen Datensätze angewendet.



Abbildung 4.40: Anwendung der Einstellungen aus dem ersten Fallbeispiel (Level 1).

Wie Abbildung 4.40 verdeutlicht, können die ermittelten Einstellungen aus dem ersten Fallbeispiel nicht unverändert auf die KOMPAST- und ASTER-Datenbasis angewendet werden, da nahezu keine Siedlungsflächen (rot eingefärbt) erfasst wurden. Eine plausible Begründung für dieses Ergebnis liefert KUHNERT (2003, S. 6), wonach er der Auffassung ist, dass eine Textur eine völlig andere Aussagekraft haben kann, wenn "eine kleinere oder ein größere Auflösungsstufe verwendet wurde". Da die panchromatischen niedriger auflösenden KOMPSAT-Bilddaten (im Vergleich zu den SPOT-Bilddaten) eine veränderte texturale Charakteristik vermuten ließen, wurde beim zweiten Fallbeispiel der Ansatz verfolgt, die Schwellwerte der Texturmerkmale der geänderten räumlichen Auflösung anzupassen.

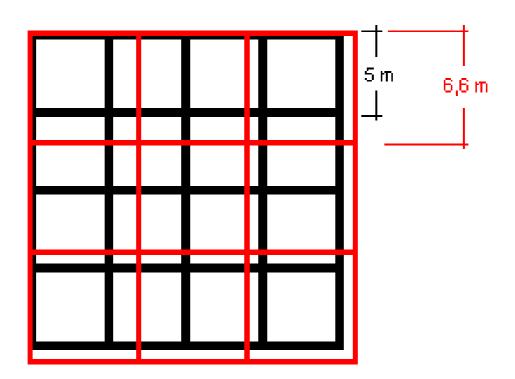


Abbildung 4.41: Räumliche Auflösungen von SPOT (schwarz) und KOMPSAT (rot) im Vergleich (Quelle: Eigene Darstellung).

Wie Abbildung 4.41 verdeutlicht, ist die Anzahl der Rasterzellen auf einer abgegrenzten Fläche bei einem KOMPSAT-Bild geringer als bei den SPOT-Daten.

Somit bedingt eine geringere räumliche Auflösung weniger Detailinformation und weniger potenzielle Textur, wodurch die Schwellwerte des IDM im folgenden Abschnitt weniger stark gewichtet wurden.

4.3.2 Anpassungen des Verfahrens

Aufbauend auf dem in Kapitel 4.2 vorgestellten Verfahren werden in diesem Abschnitt die erfolgten Anpassungen bezüglich der KOMPSAT- und ASTER-Datenbasis dokumentiert. Sofern in diesem Abschnitt keine Veränderungen dokumentiert sind, gelten die Klassifikationsmerkmale, Einstellungen und Verfahrenschritte aus Kapitel 4.2. Analog zum ersten Fallbeispiel wurden die Schwellwerte für die Klassifikationsmerkmale mittels Durchführung mehrerer Versuchsreihen (vgl. Abbildung 4.1) sukzessive ermittelt.

Die vorgenommenen Anpassungen für den dritten Level beschränken sich auf die Herabsetzung der Schwellwerte der Zugehörigkeitsfunktion für das IDM in der Klasse "Mögliche Siedlung (3)" (Abbildung 4.42).

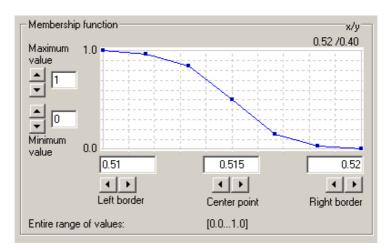


Abbildung 4.42: Veränderte Zugehörigkeitsfunktion des Merkmals "GLCM Homogeneity, all dir" im dritten Level.

Demnach muss der IDM-Wert kleiner als 0,52 sein. Das Klassifikationsergebnis des dritten Level ist in Abbildung 4.43 visualisiert.



Abbildung 4.43: Klassifikationsergebnis der dritten Ebene für das zweite Fallbeispiel.

Die Veränderungen für den zweiten Level beschränken sich auf die Reduzierung der Schwellwerte des IDM für die beiden Klassen "Mögliche Siedlung (2)" und "Mögliche Siedlung eingeschlossene Segmente (2)".

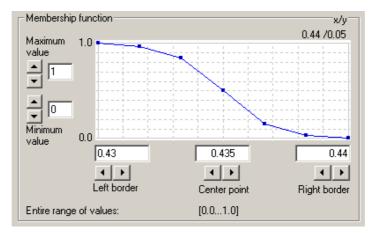


Abbildung 4.44: Veränderte Zugehörigkeitsfunktion des Merkmals "GLCM Homogeneity, all dir" im zweiten Level.

So muss der IDM-Wert für die Klasse "Mögliche Siedlung (2)" kleiner als 0,44 sein (vgl. Abbildung 4.13) und der IDM-Wert für die Tochterklasse "Mögliche Siedlung eingeschlossene Segmente (2)" geringer als 0,435 (left border: 0,425). Das Klassifikationsergebnis des zweiten Level zeigt Abbildung 4.45.

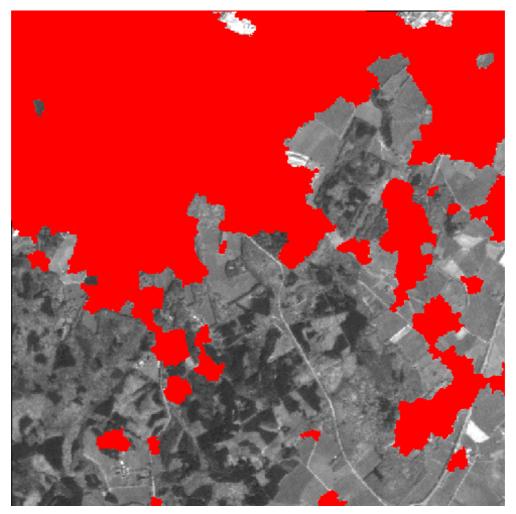


Abbildung 4.45: Klassifikationsergebnis der zweiten Ebene für das zweite Fallbeispiel.

Anpassungen im ersten Level waren analog zum zweiten Level nur für die Klasse "Mögliche Siedlung (1)" und "Mögliche Siedlung eingeschlossene Segmente (1)" nötig. Bei Beibehaltung der Funktionsform aus Abbildung 4.44 wurden die Grenzen für die Klasse "Mögliche Siedlung (1)" auf 0,42 (left border) und 0,43 (right border) determiniert; für die Klasse "Mögliche Siedlung eingeschlossene Segmente (1)" auf 0,415 (left border) und 0,425 (right border). Das Zwischenergebnis für die erste Ebene zeigt Abbildung 4.46.

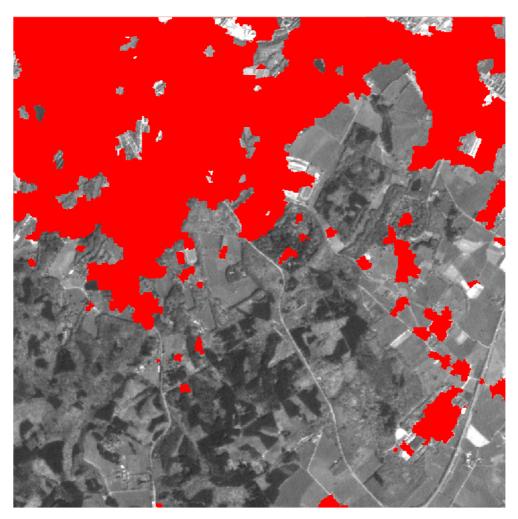


Abbildung 4.46: Klassifikationsergebnis der ersten Ebene für das zweite Fallbeispiel.

Die Veränderungen im Endlevel beschränken sich auf die Reduzierung der Schwellwerte für die Grauwertvarianz, die aufgrund der geringeren räumlichen Auflösung erniedrigt wurde.

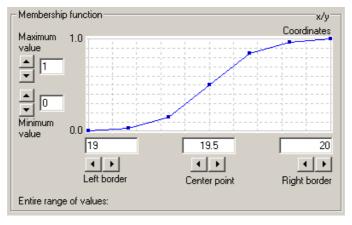


Abbildung 4.47: Veränderte Zugehörigkeitsfunktion des Merkmals "Varianz DN je Segment" im Endlevel.

Nach der Durchführung mehrerer Versuche wurde für das zweite Testgebiet eine "Varianz DN je Segment" von mindestens 19 als Vorraussetzung der Zugehörigkeit zur Klasse Siedlung definiert (Abbildung 4.47).

Alle weiteren Einstellungen und Verfahrenschritte wurden beibehalten, so dass die binäre Siedlungsmaske erfolgreich für das zweite Fallbeispiel generiert werden konnte (Abbildung 4.48).

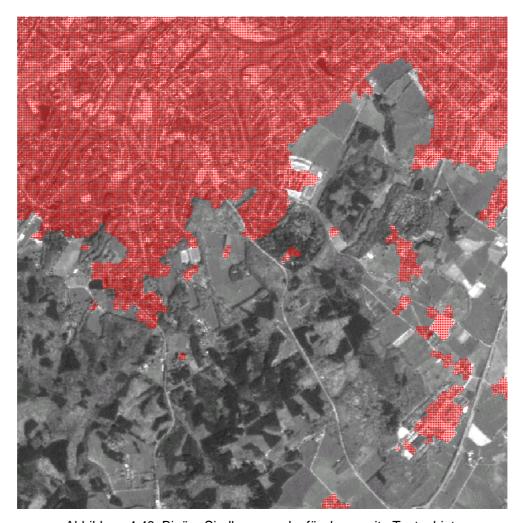


Abbildung 4.48: Binäre Siedlungsmaske für das zweite Testgebiet.

5 AUSWERTUNG DER ERGEBNISSE

Zweck dieses Kapitels ist die Bestimmung der Klassifikationsgenauigkeiten (Teilziel 4) für die vorgestellten Fallbeispiele des vierten Kapitels. Dazu werden die Ergebnisse visuell interpretiert und statistisch ausgewertet, um im Anschluss Gemeinsamkeiten und Unterschiede zusammenzufassen.

5.1 Auswertung des ersten Fallbeispiels

Da keine Referenzdaten (z. B. ALK-Daten²⁰) zur Auswertung zur Verfügung standen, wurde auf Grundlage der panchromatischen SPOT-Szene und unter Zuhilfenahme einer TK 25 mittels der Software ArcView eine eigene Referenzmaske digitalisiert. Abbildung 5.1 zeigt die digitalisierte und anschließend in Erdas Imagine rasterisierte Referenzmaske; Abbildung 5.2 zeigt die generierte binäre Siedlungsmaske.

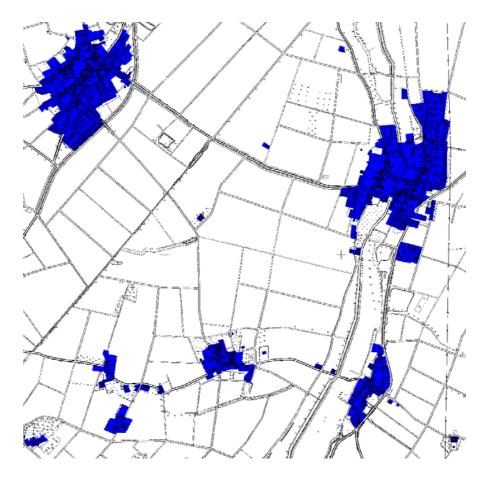


Abbildung 5.1: Erste Referenzmaske mit TK 25.

²⁰ ALK ist die Abkürzung für "Automatisierte Liegenschaftskarte" und ist der vermessungs- und kartentechnische Teil des amtlichen Liegenschaftskatasters.

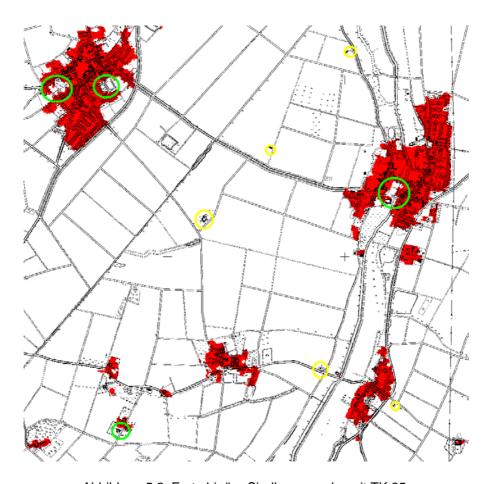


Abbildung 5.2: Erste binäre Siedlungsmaske mit TK 25.

5.1.1 Visuelle Interpretation

Im Vergleich zwischen Referenzmaske und binärer Siedlungsmaske wird erkennbar, dass große zusammenhängende Siedlungsbereiche sicher detektiert worden sind. Ferner wird deutlich, dass die generierte Siedlungsmaske, im Vergleich mit den von menschlichen Interpreten erzeugten Referenzdaten, in Siedlungsrandbereichen weniger generalisierende Grenzen aufweist. Die Siedlungsgrenzen in der binären Maske verlaufen in der Regel nicht so geradlinig wie in der digitalisierten Referenzmaske, sondern orientieren sich eher an den Grenzen, die auf Grundlage unterschiedlicher Landbedeckungen (z. B. Vegetation an Siedlung) vorgegeben sind. Gebiete mit viel Vegetation und geringer Textur (grün umrandet), wie z. B. Sportplätze, wurden nicht erfasst. Des Weiteren werden Einzelhöfe oder einzelne Häuser (gelb umrandet) nur bedingt identifiziert. Somit fehlen diese Gebäude größtenteils in der resultierenden Maske.

5.1.2 Statistische Auswertung

Die statistische Auswertung basiert auf den theoretischen Grundlagen von Kapitel 3.4. Im ersten Schritt wurde eine Konfusionsmatrix mit der Software Microsoft Excel generiert. Die notwendigen Angaben wurden aus den Attributtabellen der binären Siedlungsmaske und der Referenzmaske manuell ausgelesen. Die Anzahl der korrekt klassifizierten Pixel für die Klasse "Siedlung" wurde in der Software Erdas Imagine über ein Minimum-Overlay (Local Minimum, siehe auch TOMLIN 1990, S. 85f.) ermittelt. Bei der Klasse "Nicht-Siedlung" wurde nach vorheriger Rekodierung (Siedlung = 0 und Nicht-Siedlung = 1) eine analoge Vorgehensweise angewandt. Die Anzahl der falsch zugeordneten Pixel wurde über die Differenz von Gesamtpixelzahl der jeweiligen Klassen zu korrekt identifizierten Pixel der jeweiligen Klasse ermittelt. Tabelle 5.1 zeigt die resultierende Konfusionsmatrix für das erste Testgebiet.

Tabelle 5.1: Konfusionsmatrix für das erste Testgebiet.

	Siedlung	Nicht-Siedlung	Summe
Siedlung	77.232	5.364	82.596
Nicht-Siedlung	20.481	906.948	927.429
Summe	97.713	912.312	1.010.025

Aus der Konfusionsmatrix ergibt sich die folgende Gesamtgenauigkeit (Formel 3.11):

$$O_A = \frac{77.232 + 906.948}{1.010.025} = 0.9744$$

Somit liegt die relative Gesamtklassifikationsgenauigkeit für das erste Untersuchungsgebiet bei 97,44 Prozent.

Die Herstellergenauigkeit²¹ (Formel 3.12) der Klasse "Siedlung" wird unter Einbeziehung der Pixelanzahl der Klasse "Siedlung" (hier: 97.713 Pixel) in der Referenzmaske gebildet und beträgt:

$$P_A = \frac{77.232}{97.713} = 0,7904$$

gi-reports@igf 96

-

²¹ Gibt die Wahrscheinlichkeit an, dass die Referenzdaten der Klasse "Siedlung" richtig klassifiziert wurden.

Die relative Herstellergenauigkeit der Klasse "Siedlung" beträgt damit 79,04 Prozent. Die Berechnung der Nutzergenauigkeit²² für die Klasse "Siedlung" geschieht über den Quotienten von korrekt klassifizierten Pixel und Pixelzahl in der binären Siedlungsmaske (Formel 3.13):

$$U_A = \frac{77.232}{82.596} = 0.9351$$

Im Ergebnis ergibt sich für die Klasse "Siedlung" eine relative Nutzergenauigkeit von 93,51 Prozent.

Die Berechnung des Kappa-Koeffizienten (Formel 3.14) wurde ebenfalls in Microsoft Excel auf Grundlage der Konfusionsmatrix berechnet:

$$K = \frac{1.010.025*(77.232+906.948)-854.175.308.769}{1.010.025^2-854.175.308.769} = 0,8427$$

Somit beträgt der um die zufälligen Übereinstimmungen bereinigte Kappa-Wert bei der Klassifizierung mit SPOT- und LANDSAT-Daten 0,8427.

5.2 Auswertung des zweiten Fallbeispiels

Analog zum ersten Beispiel wurde die Interpretation und Auswertung auf Basis einer eigens digitalisierten Referenzmaske vorgenommen. Abbildung 5.3 zeigt die Referenzmaske und Abbildung 5.4 die binäre Siedlungsmaske mit einer topographischen Karte (TK 25) im Hintergrund.

²² Maß für die Wahrscheinlichkeit, das ein in die Klasse "Siedlung" zugeordnetes Pixel auch in der Realität dieser Klasse angehört.

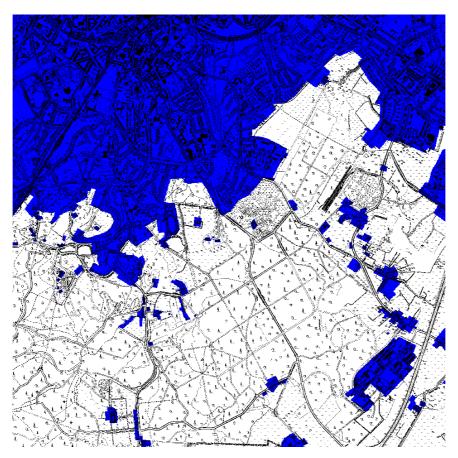


Abbildung 5.3: Zweite Referenzmaske mit TK 25.

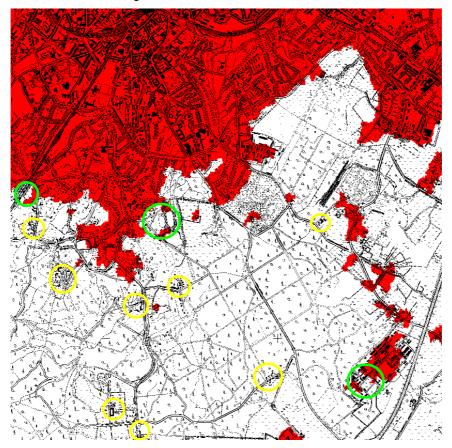


Abbildung 5.4: Zweite binäre Siedlungsmaske mit TK 25.

5.2.1 Visuelle Interpretation

Die großen zusammenhängenden Siedlungsbereiche von Aachen sind nahezu komplett erfasst worden. Unterschiede zwischen Referenz- und Siedlungsmaske sind in den Siedlungsrandbereichen zu erkennen, die bei der binären Maske weniger generalisierend ausfallen. Wie beim ersten Fallbeispiel wurden Gebiete mit hohem Vegetationsanteil oder geringer Textur (grün umrandet) nicht vollständig erfasst. Des Weiteren wurden Splittersiedlungen oder einzelne Häuser (gelb umrandet) nur unzureichend detektiert.

5.2.2 Statistische Auswertung

Die statistische Auswertung des zweiten Fallbeispiels erfolgte analog zur Vorgehensweise in Abschnitt 5.1.2. Tabelle 5.2 zeigt die Konfusionsmatrix für das zweite Testgebiet.

Tabelle 5.2: Konfusionsmatrix für das zweite Testgebiet.

	Siedlung	Nicht-Siedlung	Summe
Siedlung	210.342	5.706	216.048
Nicht-Siedlung	22.652	338.900	361.552
Summe	232.994	344.606	577.600

Bei Anwendung von Formel 3.11 ergibt sich aus Tabelle 5.2 folgende Gesamtgenauigkeit:

$$O_A = \frac{210.342 + 338.900}{577.600} = 0,9509$$

Damit besitzt die Klassifikation des ersten Untersuchungsgebiets eine relative Gesamtgenauigkeit von 95,09 Prozent.

Die Herstellergenauigkeit (Formel 3.12) für die Klasse "Siedlung" wird unter Einbeziehung der Pixelanzahl der Klasse "Siedlung" in der Referenzmaske (hier: 232.994 Pixel) berechnet:

$$P_{A} = \frac{210.342}{232.994} = 0,9028$$

Damit ergibt sich eine relative Herstellergenauigkeit von 90,28 Prozent für die Klasse "Siedlung".

Die Berechnung der Nutzergenauigkeit (vgl. Formel 3.13) für selbige Klasse ergibt folgendes Ergebnis:

$$U_A = \frac{210.342}{216.048} = 0,9736$$

Somit wurde für die Klasse "Siedlung" eine relative Nutzergenauigkeit von 97,36 Prozent erreicht.

Bei der Berechnung des Kappa-Koeffizienten (Formel 3.14) wurde folgender Wert ermittelt:

$$K = \frac{577.600*(210.342+338.900)-174.926.777.224}{577.600^2-174.926.777.224} = 0,8968$$

Der um die zufälligen Übereinstimmungen bereinigte Kappa-Wert beträgt somit 0,8968.

5.3 Vergleich und Zusammenfassung

Beim Vergleich der Gesamtgenauigkeiten weist das erste Testgebiet mit 97,44 Prozent zwar die bessere Güte auf (Gesamtgenauigkeit des zweiten Fallbeispiels: 95,09 Prozent), dennoch muss bei der Betrachtung der Klassifikationsgüte weiter differenziert werden.

Da es sich beim ersten Fallbeispiel um einen eher ländlich geprägten Raum handelt, der laut Referenzmaske einen tatsächlichen Siedlungsflächenanteil von 9,67 Prozent aufweist, fallen Herstellergenauigkeit (79,04 Prozent) und Nutzergenauigkeit (93,51 Prozent) im Vergleich zum zweiten Testgebiet, bei dem es sich eher um einen urban geprägten Raum (tatsächlicher Siedlungsflächenanteil 40,34 Prozent) handelt, zwar geringer aus, dennoch muss berücksichtigt werden, dass die überproportional hohen Genauigkeiten des zweiten Fallbeispiels (Herstellergenauigkeit 90,28 Prozent und Nutzergenauigkeit 97,36 Prozent) mit hoher Wahrscheinlichkeit durch den überproportional starken Anteil städtischer Bebauung hervorgerufen worden sind.

Durch den Vergleich der Kappa-Koeffizienten kann jedoch gesagt werden, dass beide Fallbeispiele eine ausgezeichnete Klassifikationsqualität aufweisen (vgl. Tabelle 5.3).

Tabelle 5.3: Bewertung des Kappa-Koeffizienten (übersetzt nach ORTIZ et al. 1997, S. 98).

K-Wert	Qualität
< 0,0	Sehr schlecht
0,0 bis 0,2	Schlecht
0,2 bis 0,4	Akzeptabel
0,4 bis 0,6	Gut
0,6 bis 0,8	Sehr Gut
0,8 bis 1,0	Ausgezeichnet

Der Kappa-Koeffizient des zweiten Fallbeispiels (Wert: 0,8968) weist einen leicht besseren Wert als den des ersten Untersuchungsgebietes (Wert: 0,8427) auf. Die Ursache für das bessere Ergebnis des zweiten Fallbeispiels ist dabei sehr wahrscheinlich wiederum auf den hohen Siedlungsflächenanteil zurückzuführen.

Trotz der statistischen Unterschiede ist beiden Testgebieten gemein, dass zusammenhängende und größere Siedlungsstrukturen trotz unterschiedlicher Datenbasis und unterschiedlicher physischer Beschaffenheit der Oberflächen²³ sicher detektiert worden sind.

Ferner sind bei beiden Testgebieten in Siedlungsrandbereichen die Grenzen in der binären Maske weniger generalisierend abgebildet worden als in der Referenzmaske. Weiterhin wurden in beiden Untersuchungsgebieten kleine Siedlungen oder Einzelgehöfte fernab von großen Siedlungsagglomerationen nicht vollständig erfasst.

²³ Fallbeispiel 1: Ländlicher Raum mit wenig Siedlungsflächen und Fallbeispiel 2: Urbaner Raum und Waldflächen.

6 DISKUSSION DER ERGEBNISSE

In diesem Kapitel werden die Problematiken und Vorteile (Teilziel 6) des in dieser Arbeit vorgestellten Verfahrens diskutiert. Zu den angesprochenen Problemen wird versucht, wenn möglich, Lösungsansätze aufzuzeigen. Weiterhin wird in einem abschließenden Resümee darauf eingegangen, inwiefern die in Kapitel 1.2 aufgestellten Ziele umgesetzt werden konnten.

6.1 Probleme

6.1.1 Vergleichsdaten

Da keine terrestrischen Vergleichsdaten (engl.: ground-truth) z. B. in Form einer Landnutzungsklassifizierung zur Verfügung standen, wurde zur Verifizierung der Klassifikationsgüte auf eine selbst digitalisierte Referenzmaske zurückgegriffen.

Wie in Kapitel 5 geschildert, wurden die Referenzmasken auf Basis der panchromatischen Daten digitalisiert und eventuelle fehlende Siedlungsflächen auf Basis einer "TK 25"²⁴ vervollständigt. Da aber weder durch die panchromatischen Daten noch durch die kartographisch generalisierte²⁵ und veraltete topographische Karte (vgl. Abbildung 6.1) die realen administrativen Siedlungsgrenzen sicher bestimmt werden



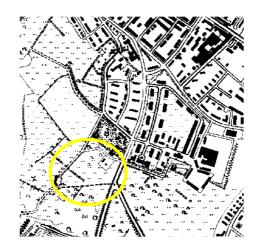


Abbildung 6.1: KOMPSAT-Bild (links) und veraltete topographische Karte (rechts).

²⁴ Topographische Karte im Maßstab 1:25000 = TK 25.

²⁵ Die kartographische Generalisierung befasst sich mit der maßstäblich reduzierten Darstellung von Geodaten durch Vereinfachung, Typisierung, Zusammenfassung, Betonung und Verdrängung.

können, muss die Auswertung in Kapitel 5 unter Vorbehalt gesehen werden. Die manuelle Generierung der Referenzmaske durch einen menschlichen Betrachter ist nicht intersubjektiv wiederholbar, da auf Basis der mangelhaften Datengrundlage nicht eindeutig erkennbar und definierbar ist, wo Siedlung tatsächlich anfängt. bzw. aufhört. Im Ergebnis werden von unterschiedlichen Interpreten auch unterschiedliche (subjektiv beeinflusste) Referenzmasken erzeugt werden, die abweichende Ergebnisse in der Genauigkeitsanalyse hervorrufen können.

Für eine endgültige valide Genauigkeitsanalyse muss entweder eine eigene, kostenintensive Kartierung vorgenommen werden, oder auf Basis von amtlichen ALK-Daten eine Referenzmaske erzeugt werden.

6.1.2 Unterschiedliche Aufnahmezeitpunkte

LILLESAND et al. (2004, S. 596) weisen explizit darauf hin, dass die für ein objektives Monitoring "change detection procedures should involve data data acquired by the [...] same time of day", da sonst bei einer Veränderungsanalyse die Ergebnisse von Umweltfaktoren verfälscht werden können, die sich auf Grund unterschiedlicher Aufnahmezeitpunkte verändert haben.

Beispiele für Umweltfaktoren, die ein Klassifikationsergebnis beeinflussen können, sind unterschiedliche Witterungsverhältnisse, Vegetationszustände oder Sonnenstände, die wiederum alle von der jeweiligen Jahreszeit und von der Tageszeit abhängen. Im Falle eines Siedlungsflächen-Monitoring ist der Mensch durch seine Bautätigkeit als ein die Umwelt verändernder Faktor anzusehen.

Zwischen den verwendeten SPOT-Daten (Aufnahmedatum: 16.3.2003) und den LANDSAT-Daten (Aufnahmedatum: 26.6.2001) dieser Arbeit besteht eine signifikante zeitliche Differenz von ca. 21 Monaten. Somit kann das Verfahren beispielsweise dann falsche Ergebnisse liefern, wenn sich in Siedlungsrandbereichen auf den älteren multispektralen LANDSAT-Daten Vegetation befindet, die knapp 21 Monate später auf den panchromatischen SPOT-Daten z. B. einem Neubaugebiet gewichen ist. Da der NDVI ein wichtiges Ausschlusskriterium für die Bestimmung von Siedlungsflächen bildet (vgl. Kapitel 4), können somit potenzielle Siedlungsflächen möglicherweise gar nicht erfasst werden. Im zweiten Fallbeispiel standen ebenfalls Daten aus unterschiedlichen Jahren zur Verfügung (temporale Differenz ca. 10 Monate, vgl. Ka-

pitel 4.1), womit die Zuverlässigkeit der Ergebnisse ebenfalls beeinträchtigt sein kann.

Zur Vermeidung der geschilderten Problematik müssen dementsprechend Daten mit zeitlich übereinstimmender Auflösung genutzt werden, da sonst eine objektiv richtige Change-Detection-Analyse nicht möglich ist (siehe dazu auch JENSEN 1986, S. 235) und sogenannte Pseudoveränderungen (engl.: pseudo-change) das Ergebnis verfälschen können.

6.1.3 Siedlungsflächen geringer Größe und Vegetation

Wie Abbildung 5.2 und Abbildung 5.4 aufzeigen, weist das vorgestellte Verfahren Schwächen bei der Detektion von kleinen Siedlungsflächen und solchen mit hohem Vegetationsanteil auf. KOCH et al. (2003, S. 195) sind der Auffassung, dass solche Fehler durch die objektorientierte Segmentierung verursacht werden: "Mit der Bildung homogener Objekte geht gleichzeitig auch eine Generalisierung einher. Mit der pixelbasierten Klassifizierung wird jedes Pixel nach spektralen Ähnlichkeiten untersucht [...], was in der Regel keine homogene Objektbildung zulässt, aber andererseits auch keine Generalisierung darstellt".

Da, wie in Kapitel 4 erläutert, das entwickelte objektorientierte Verfahren bei einem hohen Scale-Parameter (große Segmente) beginnt, kann nicht ausgeschlossen werden, dass trotz bewusst niedrig angesetzter Schwellwerte der Fuzzy-Funktionen eine Generalisierung im dritten Klassifikationslevel aufgetreten ist (Abbildung 6.2).

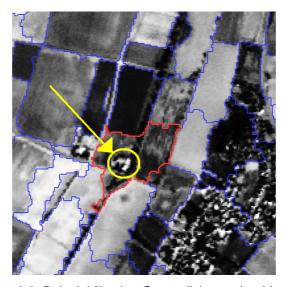


Abbildung 6.2: Beispiel für eine Generalisierung im dritten Level.

Abbildung 6.2 zeigt beispielhaft eine Siedungsfläche (gelb umrandet), die durch die Generalisierung in der dritten Segmentierungsebene nicht als einzelnes Segment (rot umrandet) eingegrenzt wurde, sondern Teil eines größeren (homogenen) Segmentes ist.

Ebenfalls als nachteilig erweist sich bei der Klassifikation in Siedlungsrandbereichen die Mittelwertbildung des NDVI für jedes Segment, die zur Nicht-Detektion von Siedlungsflächen führen kann. Abbildung 6.3 zeigt ein Beispiel aus dem zweiten Untersuchungsgebiet am Südrand von Aachen.

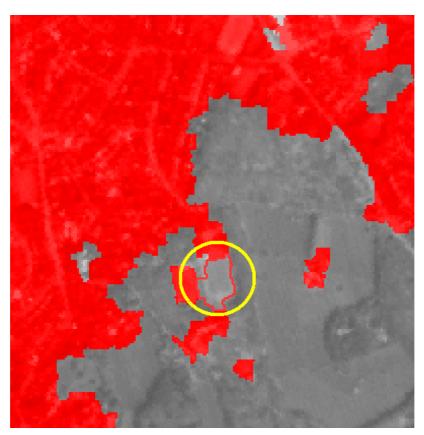


Abbildung 6.3:Siedlungsrandbereich mit hohem NDVI-Wert im ersten Level.

Das gelb umrandete Segment in Abbildung 6.3 weist einen NDVI je Segment von 0,37 auf. Laut Referenzmaske (siehe Abbildung 5.3, grün umrandet) handelt es sich um eine Siedlungsfläche und wurde auf Grund des definierten NDVI-Schwellwertes von 0,34 im ersten Level (vgl. Kapitel 4.2.6) nicht als Siedlung erkannt.

Eine Möglichkeit zur Vermeidung der beschriebenen Fehler ist, neben der iterativen Suche nach besseren Schwellwerten, die Zusammenführung der Ergebnisse des

objektorientierten Ansatzes mit denen eines pixelbasierten Ansatzes, indem z. B. die beide Ansätze miteinander kombiniert werden (vgl. Kapitel 7).

6.1.4 Verfahrens- und softwarebedingte Einschränkungen

SCHIEWE et al. (2001, S.38) sehen insbesondere den Zeitaufwand, der zu Findung von passenden Segmentierungseinstellungen in eCognition notwendig ist, als nachteilig an: "the choice of scale parameters as well as the setting of weigths for the input data sources have to be done by the user". FRANKEN (2002, S. 110) merkt dazu an, dass insbesondere "fehlende Richtlinien bei der Parameterwahl innerhalb der Analysesoftware [...] die Operartionalität der Methode" beeinträchtigen.

Des Weiteren erweist sich nach SCHIEWE et al. (2001, S. 38) die strikte Trennung von Segmentierung und Klassifizierung als nachteilig, da die Nutzbarkarbeit der generierten Segmente erst von einem Interpreten manuell bewertet werden muss, bevor eine Klassifizierung vorgenommen werden kann. Ferner ist das Aufstellen bzw. Anpassen des Regelwerks (Klassenhierarchie) sowie das Austarieren von Fuzzy-Schwellwerten ebenfalls zeitintensiv und nicht automatisierbar, da der menschliche Bearbeiter bei einer wissensbasierten Klassifikation durch Vorwissen und iterative Versuchsreihen die optimalen Einstellungen sukzessive ermitteln muss.

Weiterhin sind die Möglichkeiten von eCognition zur Implementierung eigener Algorithmen begrenzt. Zwar können Objektmerkmale durch arithmetische Operatoren miteinander zu neuen Merkmalen kombiniert werden (vgl. Kapitel 3.5.3), die Entwicklung von neuen Funktionalitäten zur Erweiterung der Segmentierungssoftware ist auf Grund einer fehlenden Programmierschnittstelle bzw. des nicht zugänglichen Quellcodes nicht realisierbar.

Dadurch ist z. B. die angestrebte vollständige Automatisierung (Teilziel 3) aller Arbeitschritte nicht machbar, da eCognition nicht die Möglichkeit bietet, Klassenhierarchien zu löschen und das Ergebnis dabei gleichzeitig beizubehalten. Hierdurch mussten alle Arbeitsschritte nach Erzeugung des ersten Levels (ab Kapitel 4.2.7) manuell durchgeführt werden.

6.2 Vorteile

6.2.1 Verbesserung im Vergleich zu pixelbasierten Verfahren

Durch die Zielstellung, eine binäre Maske (Teilziel 2) mit den beiden Klassen "Siedlung" und "Nicht-Siedlung" zu erzeugen, erwies sich die Wahl der objektorientierten Bildanalysesoftware eCognition als vorteilhaft. Im Ergebnis sind beide Klassen durch zusammenhängende Flächen abgebildet, die im Vergleich mit der Referenzmaske ausgezeichnete Genauigkeiten (vgl. Kapitel 5.3) aufweisen. Der bei pixelbasierten Verfahren auftretende "Salz und Pfeffer"-Effekt (vgl. Abbildung 3.4) konnte durch die Anwendung der objektorientierten Bildanalysesoftware eCognition vermieden werden.

Weiterhin kann die Meinung von MEINEL et al. (2001, S. 170) bestätigt werden, dass der "segmentorientierte Ansatz eine Verringerung des Anteils unklassifizierter Flächen" ermöglicht. In der vorliegenden Arbeit konnte durch konsequente Nutzung des Ausschlussverfahrens für die Klasse "Nicht-Siedlung" (vgl. Abbildung 4.14) der Anteil unklassifizierter Flächen auf Null reduziert werden.

6.2.2 Grundlage für Landnutzungsklassifizierungen

Die generierte binäre Siedlungsmaske differenziert zwar nicht nach Landnutzungen (Gewerbegebiete, Wohngebiete, Grünflächen, etc.), ist aber auf Basis der Definition von APEL & HENCKEL (1995) im Ergebnis als Summe der Flächen unterschiedlicher Landnutzungen in Siedlungen anzusehen. Im Gegensatz zu reinen Versiegelungskartierungen, die die Landbedeckung erfassen, kann eine mit dem vorgestellten Verfahren erzeugte Siedlungsmaske als Grundlage für eine weitere Differenzierung nach Landnutzungen (z. B.: Gewerbe- und Wohngebiete) verwendet werden, indem z. B. die Nicht-Siedlungsflächen über einen hierarchischen Klassifikationsansatz in einem neuen Verfahren einfach ausgeschlossen werden. Somit kann die Bewertung von MEINEL & HENNERSDORF (2002, S. 275), dass fernerkundliche Auswertemethoden weniger gut für die Ermittlung von Flächennutzungen geeignet seien (vgl. Tabelle 2.1), relativiert werden, da mittels der objektorientierten Klassifikation dieser Arbeit

auf jeden Fall die Basis für eine weitere Unterscheidung von Flächennutzungen geschaffen worden ist.

6.2.3 Erkennen von zusammenhängenden Siedlungsstrukturen

Die in dieser Arbeit angewandte Klassifikationsstrategie, auf Grundlage von Segmentierungsverfahren sowie statistischer Texturparameter (vgl. Kapitel 4.2.1) zusammenhängende Siedlungsflächen über eine hierarchischen entscheidungsbasierten Ansatz zu detektieren, konnte an beiden in dieser Arbeit vorgestellten Testgebieten erfolgreich demonstriert werden. Dabei ist insbesondere bei der visuellen Interpretation der binären Siedlungsmasken (vgl. Abbildung 5.2 und 5.4) festzustellen, dass große zusammenhängende Siedlungsagglomerationen sicher als Siedlungsfläche erkannt werden.

6.2.4 Übertragbarkeit auf KOMPSAT- und ASTER-Daten

Da das Verfahren zuerst mit SPOT- und LANDSAT-Bilddaten entwickelt worden ist, ist die Reproduzierbarkeit der Ergebnisse mit anderen Datensätzen eine zentrale Frage (Teilziel 5). Zusammenfassend kann gesagt werden, dass das vorgestellte Verfahren erfolgreich auf KOMPSAT- und ASTER-Daten übertragen werden kann, ohne die Segmentierungseinstellungen, Verfahrensschritte und Klassifikationsmerkmale zu ändern. Es ist lediglich eine Änderung der Fuzzy-Schwellwerte der Texturmerkmale (IDM und Grauwertvarianz) notwendig, die auf Grund der veränderten räumlichen Auflösung der panchromatischen Daten angepasst werden mussten.

Da die Größe von Segmenten beim Regionenwachstumsverfahren (vgl. Kapitel 3.2.2) von der Größe der räumlichen Auflösung abhängt und die räumlichen Bodenauflösungen von SPOT- (5 m) und KOMPSAT-Daten (6,6 m) nicht wesentlich differieren, konnte das Skalenniveau (Scale) unverändert übertragen werden.

Die Klassifikationsgenauigkeiten des zweiten Fallbeispiels (vgl. Kapitel 5) sind sogar geringfügig besser als beim ersten Testgebiet, was den Schluss nahe legt, dass die KOMPSAT- und ASTER-Datenbasis sogar besser zur Erfassung von Siedlungsgebieten geeignet ist. Zur Relativierung dieser Aussage muss jedoch berücksichtigt werden, dass das zweite Aachener Testgebiet einen im Vergleich zum ersten Fall-

beispiel höheren realen Siedlungsflächenanteil (40,34 Prozent) aufweist und somit nicht direkt mit dem eher ländlich geprägten ersten Gebiet mit geringeren Siedlungsflächenanteil (9,67 Prozent) verglichen werden kann. Des Weiteren standen bei der Auswahl der Testgebiete in dem Pilotforschungsprojekt (vgl. Kapitel 1.1), aus dem diese Arbeit entstanden ist, zu wenig überlagerbare und wolkenfreie Satellitenbildszenen auf KOMPSAT- und ASTER-Basis zur Verfügung als bei der SPOT- und LANDSAT-Kombination, so dass zur Klärung der Frage, welche Datenbasis besser geeignet ist, noch weitere (großflächige) Testreihen (mit der KOMPSAT- und ASTER-Datenbasis) durchgeführt werden müssen. Es kann demzufolge nicht generell gesagt werden, dass eine Klassifikation auf KOMPSAT- und ASTER-Datenbasis besser ist.

Prinzipiell kann das Verfahren aber nahezu ohne Abänderungen auf beide Datensatz-Kombinationen angewendet werden und mit hoher Zuverlässigkeit Siedlungsflächen mit mindestens gleich hoher Qualität (vgl. Kapitel 6.2.3) detektieren.

6.2.5 Kostenersparnis

"Fernerkundungsdaten waren schon immer relativ teuer, wenn der Nutzer die gesamten Kosten tragen mußte" (LÖFFLER 1994, S. 223). Mit der Verwendbarkeit von KOMPSAT- und ASTER-Daten verringern sich die Kosten für eine landesweite Erfassung von Siedlungsflächen merklich (vgl. Tabelle 3.1):

Beträgt der Preis für die Kombination SPOT/LANDSAT 0,7814 Euro je km², muss für die Kombination KOMPSAT/ASTER nur ein Preis von 0,3931 Euro je km² bezahlt werden.

Für das Bundesland Nordrhein-Westfalen mit einer Grundfläche von 34.080 km² (Quelle: http://de.wikipedia.org/wiki/Nordrhein_Westfalen) würden die Kosten zur Anschaffung der Bilddaten auf Basis von KOMPSAT- und ASTER-Daten somit 13.396,85 Euro betragen und im Vergleich zu der Kombination SPOT/LANDSAT (Gesamtkosten: 26.630,11 Euro) eine Kostenersparnis von 13.233,26 Euro bedeuten.

Da die Landesgrenzen von Nordrhein-Westfalen jedoch nicht rechtwinklig an den Grenzen der Satellitenbilddaten verlaufen, muss für die Datenbeschaffung ein höhe-

rer Preis veranschlagt werden, weil die Abdeckung der gesamten Landesfläche mehr Satellitenbilder mit größerer Grundfläche erfordert, als hier berechnet wurde.

6.3 Resümee

Im Hinblick auf die in Kapitel 1.2 definierten Ziele ist es gelungen, ein objektorientiertes Klassifikationsverfahren zur Bestimmung von Siedlungsflächen unter der Verwendung von panchromatischen SPOT-Daten und multispektralen LANDSAT-Daten (Oberziel) zu entwickeln, das zusammenhängende Siedlungsbereiche sicher in Form einer binären Siedlungsmaske (Teilziel 2) detektiert.

Des Weiteren konnte das Verfahren erfolgreich auf die KOMPSAT/ASTER-Datenbasis übertragen werden (Teilziel 5), ohne Segmentierungseinstellungen und Klassenmerkmale verändern zu müssen.

Die ermittelten Klassifikationsgenauigkeiten (Teilziel 4) müssen jedoch solange unter Vorbehalt gesehen werden, bis eine Analyse mit genaueren Ground-Truth-Daten (z. B. ALK oder eigene Kartierung) durchgeführt werden kann.

Eine Automatisierung des Verfahrens (Teilziel 3) konnte nur bedingt erreicht werden, da die von der Software eCognition (vgl. Kapitel 6.1.4) bereitgestellten Funktionen und Verfahrensweisen vom Benutzer nicht oder nur bedingt abänderbar sind. Des Weiteren muss im Verfahren der Aufwand für die Datenvorverarbeitung (vgl. Abbildung 4.1), die nicht Gegenstand dieser Arbeit war, berücksichtigt werden, womit im Ergebnis der Verfahrensablauf bis zur Erstellung einer binären Siedlungsmaske als semiautomatisch anzusehen ist.

Im Ergebnis konnten alle gesetzten Ziele dieser Arbeit (vgl. Kapitel 1.2), mit Ausnahme der soeben geschilderten Problematiken, erfolgreich umgesetzt werden.

7 ZUSAMMENFASSUNG UND AUSBLICK

Das Thema dieser Arbeit "Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten" entstand im Rahmen des Pilotforschungsprojektes "Landesweite Erfassung der Siedlungsflächen in Nordrhein-Westfalen" am Institut für Geoinformatik und Fernerkundung der Universität Osnabrück. Der schnelle Wandel urbaner Gebiete führt zu einem ständig zunehmenden Bedarf an Geodaten, um Veränderungen zeitnah erfassen und analysieren zu können. Insbesondere zur objektiven Entscheidungsfindung in Landesplanung und Politik sind heute aktuelle und verlässliche Daten zur Siedlungsflächenentwicklung unumgänglich.

Ziel dieser Arbeit war es daher, auf Grundlage von multisensoralen Fernerkundungsdaten eine möglichst reliable Methode zur Erfassung von Siedlungsflächen zu entwickeln.

Im Ergebnis wurde ein Verfahren entwickelt, das sowohl auf Grundlage von panchromatischen SPOT-Daten und multispektralen LANDSAT-Daten als auch mit panchromatischen KOMPSAT- und multispektralen ASTER-Daten Siedlungsflächen detektieren kann. Der Verfahrensablauf erfolgt semiautomatisiert, da zur Erhöhung der Klassifikationsgüte Verarbeitungsschritte notwendig werden, die mit der verwendeten Bildanalysesoftware eCognition nicht automatisierbar sind. Die visuelle Interpretation der Ergebnisse ergab für beide Beispielgebiete, trotz unterschiedlicher Siedlungsstruktur, vergleichbar gute Ergebnisse, die durch eine Genauigkeitsanalyse bestätigt werden konnten. Insbesondere wurden zusammenhängende Siedlungsagglomerationen sicher erfasst. Die ermittelten Ergebnisse müssen jedoch unter Vorbehalt gesehen werden, da die Referenzdaten auf einer selbst digitalisierten Siedlungsmaske basieren.

Weiterer Optimierungsbedarf besteht bei der Detektion von sehr kleinen Siedlungsflächen und einzelnen Gehöften, die nicht immer zuverlässig erfasst werden, sowie bei der Erfassung von Siedlungsrandgebieten mit hohem Vegetationsanteil (vgl. Kapitel 6.1.3).

Eine erste mögliche Lösung zur Optimierung der Klassifikation ist der in Kapitel 6.1.3 angedachte Weg, das in dieser Arbeit entwickelte objektorientierte Verfahren mit einem herkömmlichen pixelbasierten Klassifikationsalgorithmus (vgl. Kapitel 3.1.3) zu kombinieren und z. B. die Ergebnisse beider Ansätze (bei entsprechender Qualität

des pixelbasierten Klassifikationsergebnisses) mit einem Minimum-Overlay zu verschneiden oder den Ergebnislayer der pixelbasierten Klassifizierung zu Beginn des in dieser Arbeit vorgestellten Verfahrens durch Festlegung von Gewichtungsfaktoren (vgl. Kapitel 3.5.1) direkt in die Segmentierung mit einfließen zu lassen. Durch eine Verknüpfung von objektorientiertem und pixelbasierten Ansatz würde sich z. B. die Problematik der Generalisierung in einem Segment (vgl. Kapitel 6.1.3 und Abbildung 6.2) auflösen, da ein pixelbasiertes Verfahren auch kleinere Siedlungsbereiche im Außenbereich detektieren kann, ohne zu generalisieren.

Ein weiterer vielversprechender Ansatz, der jedoch mit dem vorgestellten Bildanalysesystem eCognition nicht umsetzbar ist, kann in der Veränderung des Regionenwachstumsverfahrens liegen: Anstatt die Farbhomogenität (vgl. Formel 3.2) als Basis für die Segmentierung zu nutzen und dann die Segmente über Textur- und andere Merkmale zu klassifizieren, bietet es sich an, das Kriterium der Farbhomogenität gegen das Kriterium der Texturhomogenität bzw. -Heterogenität auszutauschen (IDM), um so von vornherein Segmente zu erzeugen, die auf Basis von Texturparametern Siedlungsflächen besser eingrenzen. Ein Beispiel für eine texturbasierte Segmentierung liefern SALI & WOLFSON (1992).

Im Ergebnis ist es mit dem in dieser Arbeit entwickelten Verfahren möglich, den Ist-Zustand zuverlässig zu erfassen und mit gleichbleibender Datengrundlage ein Siedlungsflächen-Monitoring durchzuführen.

8 LITERATURVERZEICHNIS

ADAM, H. (1995): Wirtschaftspolitik und Regierungssystem der Bundesrepublik Deutschland – Eine Einführung. Bundeszentrale für politische Bildung. Bonn.

ALBERTZ, J. (2001): Einführung in die Fernerkundung - Grundlagen der Interpretation von Luft- und Satellitenbildern. Wissenschaftliche Buchgesellschaft. Darmstadt.

APEL, D. & HENCKEL, D. (1995): Flächen sparen, Verkehr reduzieren – Möglichkeiten zur Steuerung der Siedlungs- und Verkehrsentwicklung. In: *Deutsches Institut für Urbanistik (Hrsg.): Difu-Beiträge zur Stadtentwicklung*, Band 16. Berlin.

BAATZ, M. & SCHÄPE, A. (2000): Multiresolution segmentation — an optimization approach for high quality multi-scale image segmentation. In: *STROBL, J.; BLASCH-KE, T.; GRIESSEBENER, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung*, Beiträge zum AGIT-Symposium Salzburg: 12-23.

BARTELME, N. (2000): Geoinformatik – Modelle, Strukturen, Funktionen. Springer Verlag. Berlin.

BILL, **R.** (1999): Grundlagen der Geo-Informationssysteme - Band 2. Wichmann Verlag. Heidelberg.

BLASCHKE, T.; GLÄSSER, C. & LANG, S. (2002): Bildverarbeitung in einer integrierten GIS/Fernerkundungsumgebung – Trends und Konsequenzen. In: *BLASCH-KE, T. (Hrsg.) (2002): Fernerkundung und GIS: Neue Sensoren – Innovative Methoden.* Wichmann Verlag. Heidelberg: 1-8.

BUNDESAMT FÜR BAUWESEN UND RAUMORDNUNG (2000): Raumordnungsbericht 2000. Bonn.

BUNDESMINESTERIUM FÜR VERKEHR, BAU- UND WOHNUNGSWESEN (2003): Bundesverkehrswegeplan 2003. Berlin.

COHEN, J. (1960): A coefficient of agreement for nominal scales. In: *Educ. and Psychol. Meas.*, 20: 37-46.

CONGALTON, R. & GREEN, K. (1999): Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Lewis Publishers. New York.

DEFINIENS IMAGING GmbH (2003): eCognition Userguide 3. München.

DOSCH, F. & EINIG, K. (2005): Mengensteuerung der Siedlungsflächenentwicklung durch Plan und Zertifikat. In: *BUNDESAMT FÜR BAUWESEN UND RAUMORD-NUNG (Hrsg.): Informationen zur Raumentwicklung*, Heft 4/5: I-VIII.

EHLERS, M. (1984): Digitale Bildverarbeitung. Institut für Photogrammetrie und Ingenieurvermessungen der Universität Hannover. Hannover.

EHLERS, M.; MICHEL, U.; BOHMANN, G. & TOMOWSKI, D. (2005): Entscheidungsbasierte Datenfusion von multisensoralen Fernerkundungsdaten zur Erkennung von Siedlungsgebieten. In: SEYFERT, E. (Hrsg.): GEO-GOVERMENT - Wirtschaftliche Innovation durch Geodaten - Vorträge 25. Wissenschaftlich-Technische Jahrestagung der DGPF. 21.-23. September. Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung, Band 14: 209-216.

FORSCHUNGSZENTRUM FÜR GEOINFORMATIK UND FERNERKUNDUNG (2005): Tätigkeitsbericht 2003. Online im Internet unter: http://www.fzg.uni-osnabrueck.de/aktuelles/TB2003_FZG.pdf, [Stand 25.07.2005].

FRANKEN, F. (2002): Ableitung von Rauheitsklassen aus flugzeuggestützten Fernerkundungsdaten. Diplomarbeit. Hochschule Vechta. Online im Internet unter: http://www.frank-franken.net/diplomarbeit_umweltmonitoring.pdf, [Stand 14.10. 05].

GORTE, B. (1998): Probabilistic Segmentation of Remotely Sensed Images. Dissertation. Wageningen.

GRUPPE VON LISSABON (2001): Grenzen des Wettbewerbs. Luchterhand Literaturverlag. München.

HAKE, G.; GRÜNREICH, D. & MENG, L. (2002): Kartographie. Walter de Gruyter. Berlin.

HARALICK, R. M.; SHANMUGAM, K. & DINSTEIN, I. (1973): Textural features for image classification. In: *IEEE Trans. Syst., Man, Cybern.*, SMC-3: 610-621.

HARALICK, R. M. & SHAPIRO, L. G. (1992): Computer & Robot Vision. Volume 1. Addison-Wesley. Reading.

HOFMEISTER, B. (1999): Stadtgeographie. Westermann Verlag. Braunschweig.

HUDSON, **W. & RAMM**, **C. (1987):** Correct Formulation of the Kappa Coefficient of Agreement. In: *Photogrammetric Engineering & Remote Sensing*, Vol. 53, Nr. 4: 421-422.

JÄHNE, B. (1989): Digitale Bildverarbeitung. Springer Verlag. Berlin.

JAIN, R.; KASTURI, R. & SCHUNK, B. G. (1995): Machine Vision. McGraw-Hill. New York.

JENSEN, J. R. (1986): Introductory Digital Image Processing – A Remote Sensing Perspective. Prentice-Hall. Englewood Cliffs. New Jersey.

JÜRGENS, C. (1997): Bestimmung von ländlichen Siedlungsflächen anhand von Satellitenbilddaten. In: BREUER, T.; HEINE, K.; HERMES, K.; OBST J. & RIN-SCHEDE, G. (Hrsg.): Regensburger geographische Schriften, Heft 28: 133-139.

KANG, J.; HEUN HONG, S. & CHUL LEE, J. (2002): Determination of the extract basin parameter using compsat. Online im Internet unter: http://www.isprs.org/commission4/proceedings/pdfpapers/534.pdf, [Stand 28.7.05].

KOCH, B.; JOCHUM, M.; IVITS, E. & DEES, M. (2003): Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren. In: *Photogrammetrie Fernerkundung Geoinformation*, Heft 3: 195-204.

KRONSBERG, P. (1985): Fernerkundung der Erde – Grundlagen und Methoden des Remote Sensing in der Geologie. Ferdinand Enke Verlag. Stuttgart.

KUNERT, L. (2003): Texturbasierte Segmentierung. Online im Internet unter: http://www.iaim.ira.uka.de/Teaching/ProseminarMedizin/Ausarbeitungen/WS0203/07-_Texturbasierte_Segmentierung.pdf, [Stand 29.9.05].

KUTTLER, W. (1993): Stadtklima. In: *SUKOPP, H. & WITTIG, R. (Hrsg.): Stadtökologie*. Fischer Verlag. Stuttgart.

LILLESAND, T.; KIEFER, R. & CHIPMAN, J. (2004): Remote sensing and image interpretation. John Wiley & Sons. New York.

LÖFFLER, E. (1994): Geographie und Fernerkundung. Teubner Studienbücher Geographie. Stuttgart.

MA, Z. & REDMOND, R. (1995): Tau Coefficients for Accuracy Assessment of Classification of Remote Sensing Data. In: *Photogrammetric Engineering & Remote Sensing*, Vol. 54, Nr. 4: 435-439.

MARSHALL, D. (2005): Vision Systems. Online im Internet unter: http://www.cs.cf.ac.uk/Dave/Vision_lecture, [Stand 3.8.2005].

MATHER, P. (1999): Computer Processing of Remotely-Sensed Images - an Introduction. John Wiley & Sons. New York.

MEINEL, G.; NEUBERT, M. & REDER, J. (2001): Pixelorientierte versus segment-orientierte Klassifikation von IKONOS-Satellitenbilddaten - ein Methodenvergleich. In: *Photogrammetrie Fernerkundung Geoinformation*, Heft 3: 157-170.

MEINEL, G. & HENNERSDORF, J. (2002): Erhebungsmethoden, Programme und Nomenklaturen der Flächenbedeckung und Flächennutzung. In: *Photogrammetrie Fernerkundung Geoinformation*, Heft 4: 271-186.

MICHEL, U. (2004): Untersuchungen zum automatisierten wissensbasierten Monitoring der Landnutzung durch GIS- und Fernerkundungsintegration. Forschungszentrum für Geoinformatik und Fernerkundung (Hrsg.) (2004): gi-reports@fzg, Band 1. Vechta.

MITTELBERG, B. (2001): Objektorientierte Klassifikation von Fernerkundungsdaten urbaner Räume - Möglichkeiten und Grenzen. Diplomarbeit. Universität Bonn. Online im Internet unter: http://www.rsrg.uni-bonn.de/RSRFwww/Deutsch/Diplomarbeiten/Mittelberg_Diplomarbeit_2001.pdf, [Stand 14.12.05].

MITTENECKER, E. (1968): Planung und statistische Auswertung von Experimenten. Verlag Franz Deuticke. Wien.

NETZBAND, M. (1998): Möglichkeiten und Grenzen der Fernerkundung zur Versiegelungskartierung in Siedlungsräumen. *Institut für ökologische Raumgliederung e.V.* (*Hrsg.*): *IÖR-Schriften*, Band 28. Dresden.

ORTIZ, M.; FORMAGGIO, R. & EPIPHANIO, J. (1997): Classification of croplands through integration of remote sensing, GIS and historical database. In: *International journal of remote sensing*, Vol.18, Nr.1: 95-105.

REDER, J. (2002): Automatische Detektion neuer Siedlungsflächen durch Vergleich hochauflösender Satellitenbilddaten. In: *BLASCHKE, T. (Hrsg.): Fernerkundung und GIS: Neue Sensoren – innovative Methoden.* Wichmann Verlag. Heidelberg: 169–178.

RENGER, M. (1993): Bodenwasser- und Grundwasserhaushalt. In: *SUKOPP, H. & WITTIG, R. (Hrsg.): Stadtökologie*. Fischer Verlag. Stuttgart.

SALI, E. & WOLFSON, H. (1992): Texture classification in aerial photographs and Satellite data. In: *International journal of remote sensing*, Vol. 13, Nr. 18: 3395-3408.

SCHIEWE, J.; TUFTE, L. & EHLERS, M. (2001): Potential and Problems of Multi-Scale Segmentation Methods in Remote Sensing. In: *Geo-Informations-Systeme*, Heft 6: 34-39.

SCHIEWE, J. & TUFTE, L. (2002): Potenzial regionen-basierter Verfahren für die integrative Auswertung von GIS- und Fernerkundungsdaten. In: *Blaschke, T. (Hrsg.): Fernerkundung und GIS - Neue Sensoren - innovative Methoden.* Wichmann-Verlag. Heidelberg: 42-52.

SCHIEWE, **J.** (2003): Auswertung hoch auflösender und multi-sensoraler Fererkundungsdaten – Entwicklung von Methoden und Transfer in die Lehre. *Materialien Umweltwissenschaften Vechta*, Heft 18.

SCHIEWE, **J.** (2005): Segmentierungsverfahren in der Fernerkundung. Online im Internet unter: http://www.fzg.uni-osnabrueck.de/mitarbeiter/schiewe/segm/ls_intro_f-rame.htm, [Stand 3.8.05].

SCHRÖDER, D. (1992): Bodenkunde in Stichworten. Verlag Ferdinand Hirth. Stuttgart.

SCHWARZE, **J.** (1997): Grundlagen der Statistik II – Wahrscheinlichkeitsrechnung und induktive Statistik. Verlag Neue Wirtschafts-Briefe. Berlin.

STATISTISCHES BUNDESAMT (2002): Bodenfläche nach Art der tatsächlichen Nutzung 2001 – Methodische Erläuterungen und Eckzahlen. Wiesbaden.

STATISTISCHES BUNDESAMT (2004): Siedlungs- und Verkehrsfläche nach Art der tatsächlichen Nutzung 2004 – Erläuterungen und Eckzahlen. Wiesbaden.

STEINBRECHER, R. (2002): Bildverarbeitung in der Praxis. Oldenbourg Verlag. München. Online im Internet unter: http://www.rst-software.de/dbv/download.html, [Stand 17.11.05].

STEINNOCHER, K. (1997): Texturanalyse zur Detektion von Siedlungsgebieten in hochauflösenden panchromatischen Satellitenbilddaten. In: *AGIT IX, 2.-4. Juli 1997, Salzburger Geographische Materialien*, Heft 26: 143-152.

STEINNOCHER, K. & TÖTZER, T. (2001): Analyse von Siedlungsdynamik durch Verknüpfung von Fernerkundungs- und demographischen Daten. In: ÖSTERREI-CHISCHES UMWELTBUNDESAMT (Hrsg.): Versiegelt Österreich? Der Flächenverbrauch als Indikator für Umweltbeeinträchtigungen. UBA Conference Papers, CP-030, Wien: 39-47.

STREIT, B. (1992): Umweltlexikon. Herder Verlag. Freiburg im Breisgau.

TIZHOOSH, **H. R. (1998)**: Fuzzy-Bildverarbeitung – Einführung in Theorie und Praxis. Springer Verlag. Berlin.

TOMLIN, C. (1990): Geographic information systems and cartographic modelling. Prentice-Hall. Englewood Cliffs. New Jersey.

TRAPPMANN, **H. (2004)**: Urbanes Wohnen - Begrenzung von Stadt-Umland-Wanderung durch urbanen Wohnungsneubau. Diplomarbeit. Universität Dortmund. Online im Internet unter: http://www.demografie-und-raum.nrw.de/download/Diplomarbeit-trappmann.pdf, [Stand 7.7.2005].

UMWELTBUNDESAMT (2004): Reduzierung der Flächeninanspruchnahme durch Siedlungen und Verkehr – Strategiepapier des Umweltbundesamtes. Erich Schmidt Verlag. Berlin.

VON WEIZSÄCKER, E. U. (1997): Erdpolitik. Wissenschaftliche Buchgesellschaft. Darmstadt.

WAGNER, H-G. (1998): Wirtschaftsgeographie. Westermann Verlag. Braunschweig.

Sonstige Internetquellen:

http://de.wikipedia.org/wiki/Fraktal, [Stand 11.8.05].

http://de.wikipedia.org/wiki/Greedy, [Stand 20.10.05].

http://de.wikipedia.org/wiki/Nachhaltige_Entwicklung, [Stand 15.7.05].

http://de.wikipedia.org/wiki/Nordrhein_Westfalen, [Stand 12.10.05].

http://www.bbr.bund.de/raumordnung/siedlung/methoden.htm, [Stand 13.7.05].

http://www.bild-medizin/bild-medizin_4.html, [Stand 3.8.05].

http://www.destatis.de/download/d/vgr/biplangereihe.xls, [Stand 15.7.05].

http://www.eurimage.com/products/docs/eurimage_price_list.pdf, [Stand 22.8.05].

http://www.ipi.uni-hannover.de/html/aktuelles/earsel_symposium/BuySymp.pdf, [Stand 28.7.05].

http://www.isprs.org/commission3/proceedings/papers/paper129.pdf, [Stand 12.9.05].

http://www.stadtentwicklung.berlin.de/umwelt/umweltatlas/e_text/ka102.pdf, [Stand 6.7.05].