

Friedrich-Schiller-Universität Jena
Chemisch-Geowissenschaftliche Fakultät
Institut für Geographie
Lehrstuhl für Fernerkundung

Diplomarbeit

**Erfassung und Charakterisierung städtischer Strukturen am Beispiel
Erfurts mittels hoch auflösender optischer und SAR-Daten**

Gutachter:
Prof. Dr. Christiane Schmullius
Dipl.-Geogr. Tanja Riedel

vorgelegt von
Frank Thonfeld

Jena, im November 2007

Danksagung

Mein Dank gilt Frau Prof. Dr. Christiane Schullius, die mir mit ihren Vorlesungen und einer einzigartigen Exkursion nach Kalifornien den Blick in die Welt der Fernerkundung eröffnet hat. Darüber hinaus danke ich für die Bereitstellung eines überaus interessanten Themas.

Ich danke Frau Dipl.-Geogr. Tanja Riedel für zahlreiche Anregungen und die geduldige und effektive Betreuung meiner Diplomarbeit.

Des Weiteren danke ich Herrn Dr. Jürgen Schröder vom Stadtentwicklungsamt Erfurt für die Bereitstellung thematischer Karten sowie Herrn Prof. Dr.-Ing. Manfred Ehlers und Herrn Dipl.-Umweltwiss. Sascha Klonus für Informationen zur Ehlers Fusion und die Bereitstellung der entsprechenden Software.

Ferner danke ich allen, die mit Ratschlägen und kritischen Hinweisen zum Gelingen der Arbeit beigetragen haben. Dies gilt insbesondere Frau Dipl.-Geogr. Jana Lippelt für die Durchsicht des Manuskripts.

Ich danke meinen Eltern und Großeltern, deren persönliche und finanzielle Unterstützung meinen bisherigen Lebensweg und mein Studium erst ermöglichten, und meinem Bruder René, der mich zum Studium der Geographie ermunterte.

Mein ganz besonderer Dank gilt meiner Freundin Livia Leipold für ihre selbstlose und ausdauernde moralische Unterstützung in allen Lebenslagen.

Jena, im November 2007

Frank Thonfeld

Inhalt

Abbildungen	III
Tabellen.....	V
1 Einleitung.....	1
2 Theoretische Grundlagen und Stand der Forschung	3
2.1 Radar- und optische Fernerkundung – Zwei unterschiedliche Prinzipien	3
2.1.1 Funktionsweise und Eigenschaften optischer Systeme.....	4
2.1.2 Reflexionsverhalten kurzweiliger Strahlung.....	4
2.1.3 Funktionsweise und Eigenschaften von SAR-Systemen	5
2.1.4 Speckle	6
2.1.5 Rückstreuverhalten von Radarwellen	8
2.1.6 Streumechanismen und Rückstrahleffekte in urbanen Räumen.....	10
2.2 Bildfusion.....	11
2.2.1 Pixelbasierte Verfahren der Bildfusion.....	12
2.2.1.1 IHS (und HSV).....	13
2.2.1.2 Principle Component Analysis (PCA)	15
2.2.1.3 Color Normalized (Brovey) und CN Spectral Sharpening	16
2.2.1.4 Gram-Schmidt.....	17
2.2.1.5 HPF (High Pass Filtering).....	19
2.2.1.6 Addition und Multiplikation	19
2.2.1.7 Wavelet	19
2.2.1.8 Ehlers Fusion.....	22
2.2.1.9 AIF-Methode.....	24
2.2.2 Pansharpening	26
2.2.3 Segmentbasierte Fusion	26
2.2.4 Beurteilung der Qualität von Bildfusionen	27
2.3 Analyse räumlich hoch auflösender Fernerkundungsdaten	32
2.3.1 Pixel vs. Objekte	32
2.3.2 Objektbasierte Ansätze.....	34
2.3.2.1 Segmentierung	35
2.3.2.2 Evaluierung von Segmentierungen	37
2.3.2.3 Objektbasierte Klassifizierung.....	41
2.4 Urban Remote Sensing.....	43
2.4.1 Eigenschaften urbaner Räume und ihre Abgrenzung.....	43
2.4.2 Technische und methodische Herausforderungen	45
2.4.2.1 Wahl geeigneter Sensoren.....	46
2.4.2.2 Adäquate Bildanalysetechniken.....	47
2.4.2.3 Entwicklungen im Bereich der Datenfusion	50
2.4.3 Potentiale und Grenzen	51
2.4.4 Anwendungsgebiete	52
2.4.4.1 Stadtökologie	53

2.4.4.2 Stadtplanung und -management.....	55
2.4.5 Aktuelle Forschung und Ausblick.....	57
3 Ziel, Datengrundlage und methodisches Vorgehen	59
3.1 Zielsetzung	59
3.2 Untersuchungsgebiet.....	59
3.3 Datengrundlage	60
3.4 Vorgehensweise	63
4 Datenaufbereitung	65
4.1 Pansharpening der QuickBird-Daten	65
4.2 Qualitätsanalyse der Pansharpening-Produkte.....	66
4.2.1 Optische Bewertung.....	67
4.2.2 Erstes Qualitätskriterium.....	69
4.2.3 Zweites Qualitätskriterium.....	70
4.2.4 Drittes Qualitätskriterium.....	71
4.2.5 Profillinien	72
4.3 Ableitung von Textur und NDVI aus den QuickBird-Daten	74
4.4 Aufbereitung der E-SAR-Daten.....	75
4.4.1 Einfallswinkelkorrektur.....	75
4.4.2 Multitemporale Speckle-Filterung	76
4.5 Ableitung von Textur aus den E-SAR-Daten.....	77
4.6 Aufbereitung der Referenzdaten	78
5 Ergebnisse	79
5.1 Segmentierung der Daten.....	79
5.2 Siedlungsmasken.....	81
5.2.1 Siedlungsmaske auf Basis von QuickBird	81
5.2.2 Siedlungsmaske auf Basis von E-SAR	83
5.2.3 Siedlungsmaske durch die synergetische Nutzung von QuickBird und E-SAR....	84
5.2.4 Vergleich und Bewertung der Ergebnisse.....	85
5.3 Objektbasierte Landbedeckungsklassifikation der optischen Daten.....	89
5.3.1 Wolken- und Wolkenschattenmaske.....	90
5.3.2 Landbedeckung	90
5.4 Objektbasierte Landbedeckungsklassifikation der Radardaten	97
5.5 Synergetische objektbasierte Landbedeckungsklassifikation	99
5.6 Ergebnisse der Landbedeckungsklassifikation	102
5.7 Bewertung der Ergebnisse	108
6 Zusammenfassung.....	112
Literatur.....	114

Abbildungen

Abb. 2.1:	Das elektromagnetische Spektrum.....	3
Abb. 2.2:	Mitlicht- und Gegenlichtbereich.....	5
Abb. 2.3:	Einflussgrößen auf die Auflösung bei SLR mit synthetischer Apertur.....	6
Abb. 2.4:	Streumechanismen von Radarstrahlen.....	8
Abb. 2.5:	Geländeeinflüsse auf Radarbilder.....	10
Abb. 2.6:	Ausgewählte Rückstreumechanismen in urbanen Räumen.....	11
Abb. 2.7:	Pixel Level, Feature Level und Decision Level.....	12
Abb. 2.8:	Schematische Darstellung einer Bildfusion mittels IHS-Transformation....	15
Abb. 2.9:	Schematische Darstellung einer Bildfusion mittels PCA-Transformation.....	15
Abb. 2.10:	Schematische Darstellung einer Bildfusion mittels Gram-Schmidt-Transformation.....	17
Abb. 2.11:	Filterbank für den Analyseschritt der Wavelet-Transformation.....	20
Abb. 2.12:	Schema der Wavelet-Fusion.....	21
Abb. 2.13:	Ablaufschema der Ehlers Fusion.....	24
Abb. 2.14:	Vereinfachte Darstellung der Auswirkung der AIF.....	25
Abb. 2.15:	Definition des Homogenitätskriteriums zur Segmentierung.....	36
Abb. 2.16:	Schema der Bildsegmentierung und der entsprechenden Evaluierung.....	38
Abb. 2.17:	Abstrakte Darstellung eines hierarchischen Netzwerks von Bildobjekten.....	41
Abb. 2.18:	Datenfusion im Kontext urbaner Räume.....	51
Abb. 3.1:	QuickBird-Aufnahme von Erfurt vom 26. Mai 2005.....	60
Abb. 3.2:	Ausschnitt des Untersuchungsgebiets.....	61
Abb. 3.3:	Schematische Darstellung der Vorgehensweise.....	64
Abb. 4.1:	Scattergramme zwischen PAN und Multispektralkanälen für zwei Ausschnitte der QuickBird-Szene im Stadtzentrum von Erfurt.....	65
Abb. 4.2:	Pansharpening-Produkte im Vergleich.....	68
Abb. 4.3:	Subset für das Original QuickBird-Multispektralbild und den panchromatischen Kanal.....	69
Abb. 4.4:	Ausschnitt aus den Originalszenen mit der Lage des analysierten Grauwertprofils.....	72
Abb. 4.5:	Profillinien des originalen NIR-Bandes im Vergleich zum NIR-Kanal der Pansharpening-Produkte.....	73
Abb. 4.6:	E-SAR-Daten von 2000 vor der multitemporalen Filterung und danach.....	77
Abb. 5.1:	Die Texturmaße Datarange und Entropy des blauen Kanals zur Identifikation urbaner Gebiete.....	81
Abb. 5.2:	Siedlungsmaske auf Basis der optischen Daten.....	82
Abb. 5.3:	E-SAR HH2001 Datarange (GLOM).....	83
Abb. 5.4:	Siedlungsmaske auf Basis der E-SAR-Daten.....	83
Abb. 5.5:	Siedlungsmaske durch synergetische Nutzung optischer und SAR-Daten.....	84

Abb. 5.6: Referenzdaten und Fernerkundungsprodukte im Vergleich.....	85
Abb. 5.7: Differenzbilder aus der Realflächenkartierung und den Fernerkun- dungsprodukten.	87
Abb. 5.8: Spektrale Eigenschaften der visuell erkennbaren Landbedeckungs- klassen in der QuickBird-Szene.	91
Abb. 5.9: Ausschnitt des Untersuchungsgebiets im Pixellevel, überlagert mit den Segmentgrenzen der verschiedenen Level und im Ergebnis der klassifi- zierten optischen Daten.	94
Abb. 5.10: Schematische Darstellung der Klassifizierung auf Basis der optischen Daten.	95
Abb. 5.11: Klassendefinition zur Klassifizierung der QuickBird-Daten.	96
Abb. 5.12: Radarrückstreusignale der Landbedeckungsklassen in E-SAR.	97
Abb. 5.13: Klassendefinition zur Klassifizierung der E-SAR-Daten.	98
Abb. 5.14: Schema der synergetischen Klassifikation.	100
Abb. 5.15: Klassendefinition zur synergetischen Klassifizierung.	101
Abb. 5.16: Klassifikationsergebnis der Radardaten.	103
Abb. 5.17: Klassifikationsergebnis der optischen Daten.	104
Abb. 5.18: Ergebnis der synergetischen Auswertung von QB und E-SAR.	105

Tabellen

Tab. 3.1:	Charakteristika von QuickBird.....	61
Tab. 4.1:	Korrelation der originalen Multispektraldaten (2,4 m Auflösung) mit den auf 9,6 m degradierten Bildern, die mittels der aufgeführten Verfahren auf die originale Auflösung zurücktransformiert wurden.....	66
Tab. 4.2:	Korrelation zwischen den auf die Auflösung der Originaldaten (2,4 m) degradierten Pansharpening-Produkte und den originalen MS-Daten.....	69
Tab. 4.3:	Statistik der Pansharpening-Produkte nach einer Degradierung auf die Originalauflösung von 2,4 m.....	70
Tab. 4.4:	Korrelation zwischen den Pansharpening-Produkten aus den degradierten Daten und den originalen MS-Daten.....	70
Tab. 4.5:	Statistiken für die Pansharpening-Produkte der degradierten Originaldaten.	71
Tab. 4.6:	Korrelation der auf 0,6 m resampelten Originaldaten mit den Pansharpening-Produkten.	71
Tab. 4.7:	Statistik der Pansharpening-Produkte im Vergleich zu den auf 0,6 m resampelten Originaldaten.	72
Tab. 5.1:	Parameter für die initiale Segmentierung der QuickBird-Daten.....	79
Tab. 5.2:	Parameter für die Segmentierung der Radardaten.....	80
Tab. 5.3:	Konfusionsmatrizen zwischen der Realflächenkartierung und den aus Fernerkundungsdaten ermittelten Siedlungsmasken.....	88
Tab. 5.4:	Klassifikationsgenauigkeit der Siedlungsmasken.....	89
Tab. 5.5:	Parameter für die zweite Segmentierungssequenz.....	93
Tab. 5.6:	Konfusionsmatrix zur Landbedeckungsklassifikation der Radardaten.....	102
Tab. 5.7:	Klassifikationsgenauigkeit der Radardaten.....	103
Tab. 5.8:	Konfusionsmatrix zur Landbedeckungsklassifikation der optischen Daten.	106
Tab. 5.9:	Konfusionsmatrix zur synergetischen Landbedeckungsklassifikation.	107
Tab. 5.10:	Klassifikationsgenauigkeit der QuickBird-Daten.....	107
Tab. 5.11:	Klassifikationsgenauigkeit der synergetischen Auswertung.....	108

1 Einleitung

Die Fernerkundung urbaner Räume ist ein vielfältiges und aufgrund ständig wachsender Städte sowie zunehmender Stadtbevölkerung und der daraus erwachsenden Probleme äußerst wichtiges Instrument für eine erfolgreiche Stadtplanung und nachhaltiges Management. Aufgrund der Dynamik, mit der sich Siedlungsräume – insbesondere Städte – verändern, ist es kaum möglich, die räumlichen Entwicklungsmuster mit herkömmlichen Methoden zu erkennen, zu quantifizieren und auf Basis dieser Erkenntnisse zu steuern. Fernerkundung bietet an dieser Stelle mehr als nur den spätestens durch Google Earth (<http://earth.google.com/intl/de/>) bekannten detaillierten Blick von oben. Zahlreiche Sensoren erfassen eine Fülle an raumbezogenen Informationen, aus denen thematische Produkte abgeleitet werden können. Diese können zeitnah in Geographischen Informationssystemen (GIS) abgelegt und visualisiert werden, um für Entscheidungsträger, Wissenschaftler oder andere Interessengruppen eine einzigartige Informationsquelle bereitzuhalten. Auf dem Gebiet der Fernerkundung existiert kaum ein Arbeitsfeld, das derart vielgestaltig und komplex ist wie der urbane Raum. Daher ist es notwendig, bestehende Technologien auszubauen, neue Methoden zu entwickeln und Wissen zu vernetzen.

Im Folgenden werden die theoretischen Grundlagen der Fernerkundung sowie der derzeitige Stand der Forschung im Feld der Fernerkundung urbaner Räume ausführlich behandelt, um den weiteren Forschungsbedarf zu betonen. Der Hauptteil der Arbeit ist daher zweigeteilt. Zunächst soll im theoretischen Teil die Notwendigkeit und der Nutzen der im praktischen Teil angewandten Methoden hergeleitet werden. Im Kapitel über die theoretischen Grundlagen und den Stand der Forschung werden zuerst die Unterschiede zwischen optischen und Radarsystemen aufgezeigt, um zu verdeutlichen, dass durch die Nutzung beider Systeme über ein und dasselbe Objekt unterschiedliche Informationen erhoben werden, deren synergetische Auswertung ein verbessertes Verständnis der Erdoberfläche bewirkt. Die Betonung liegt dabei auf dem urbanen Kontext. Daran anknüpfend werden die wichtigsten Verfahren der Bildfusion erläutert, auf deren Basis die gemeinsame Analyse verschiedener Daten erst erfolgen kann. *Pansharpening*, das eine spezielle Form der pixelbasierten Bildfusion darstellt, sowie einige Ansätze zur segmentbasierten Datenfusion finden ebenso Beachtung. Danach wird der Qualitätsanalyse von Bildfusionen ein eigenes Kapitel eingeräumt. Im Kapitel über die Auswertung räumlich hoch auflösender Daten erfolgt eine Abwägung der Vor- und Nachteile pixel- bzw. objektbasierter Ansätze, ehe die wichtigsten Schritte der objektbasierten Bearbeitung von Satellitendaten – Segmentierung und Klassifikation – näher beschrieben werden. Die für das Untersuchungsgebiet geeigneten Verfahren kommen später auch zur praktischen Anwendung. Das letzte Kapitel des Theorieteils befasst sich mit der Fernerkundung urbaner Räume. Neben der Abgrenzung von urbanen Räumen wird hier insbesondere auf die technischen und methodischen Herausforderungen eingegangen. Darüber hinaus werden die Möglichkeiten und Grenzen der Fernerkundung urbaner Räume benannt und schließlich weitreichende

Anwendungsmöglichkeiten exemplarisch aufgezeigt. Im gesamten Theorieteil werden bewährte Methoden und neue Entwicklungen in einer Art *Review* beschrieben.

Im praktischen Teil der Arbeit werden im Wesentlichen die im Theorieteil thematisierten Arbeitsschritte aufgegriffen und am Beispiel Erfurts angewandt. Die Untersuchung nutzt hoch auflösende optische und Radardaten, die u. a. synergetisch ausgewertet werden. In diesem Bereich gibt es aufgrund bisher fehlender Daten kaum Erfahrungen, aber speziell mit dem erst kürzlich gestarteten TerraSAR-X-Satelliten große Erwartungen. Dem ersten hoch auflösenden Radarsatelliten wird ein enormes Potential zur Lösung zahlreicher Problemstellungen beigemessen (ROTH 2005). Die vorliegende Arbeit versucht, in bestehende Lücken zu stoßen und zu untersuchen, inwiefern die synergetische Nutzung optischer und Radardaten eine quantitativ und qualitativ höherwertige Charakterisierung urbaner Räume ermöglicht, als die Beschränkung auf eine der beiden Datenquellen.

2 Theoretische Grundlagen und Stand der Forschung

2.1 Radar- und optische Fernerkundung – Zwei unterschiedliche Prinzipien

In der Fernerkundung sind passive Systeme von aktiven zu unterscheiden. Erstere nutzen ausschließlich die in der Natur vorkommende Strahlung, d. h. entweder die an der Erdoberfläche reflektierte Sonnenstrahlung oder die Thermalstrahlung, die jeder Körper aufgrund seiner Oberflächentemperatur abgibt (ALBERTZ 2001:9). Aktive Systeme, zu denen Radar (*Radio Detection and Ranging*) und Lidar (*Light Detection and Ranging*) gehören, senden demgegenüber selbst Strahlung einer definierten Wellenlänge aus und messen den vom Gelände reflektierten Teil dieser Strahlung (LILLESAND et al. 2004:9, 639). In Abb. 2.1 ist das elektromagnetische Spektrum mit der jeweiligen Wellenlänge λ und Frequenz f der Strahlung und ihrer Bezeichnung sowie die atmosphärische Durchlässigkeit dargestellt. Des Weiteren ist zu erkennen, welchen Teil des elektromagnetischen Spektrums Thermal-, Multispektral- und Radarsensoren abdecken. Der rote und blaue Bereich veranschaulicht die spektrale Abdeckung von QuickBird bzw. die Lage des X-Bandes von E-SAR mit einer Wellenlänge von 3 cm (9,6 GHz). Es ist ersichtlich, dass optische und Thermalsensoren die atmosphärischen Fenster im sichtbaren bzw. nahen und mittleren Infrarotbereich nutzen. Die Sensoren im Bereich des sichtbaren Lichts nutzen das Strahlungsmaximum der solaren Strahlung, Thermalsensoren erfassen die Strahlung der Erde, deren Maximum bei etwa $10\ \mu\text{m}$ liegt (Abb. 2.1). Für die Strahlung im Bereich der Mikrowellen ist die Atmosphäre fast vollständig durchlässig. Allerdings ist die Intensität der empfangenen Signale mit passiven Mikrowellensensoren äußerst schwach, so dass nur mit geringer räumlicher Auflösung gearbeitet werden kann. Darüber hinaus ist die Interpretation der Daten aufgrund vielfältiger möglicher Strahlungsquellen besonders anspruchsvoll (LILLESAND et al. 2004:721).

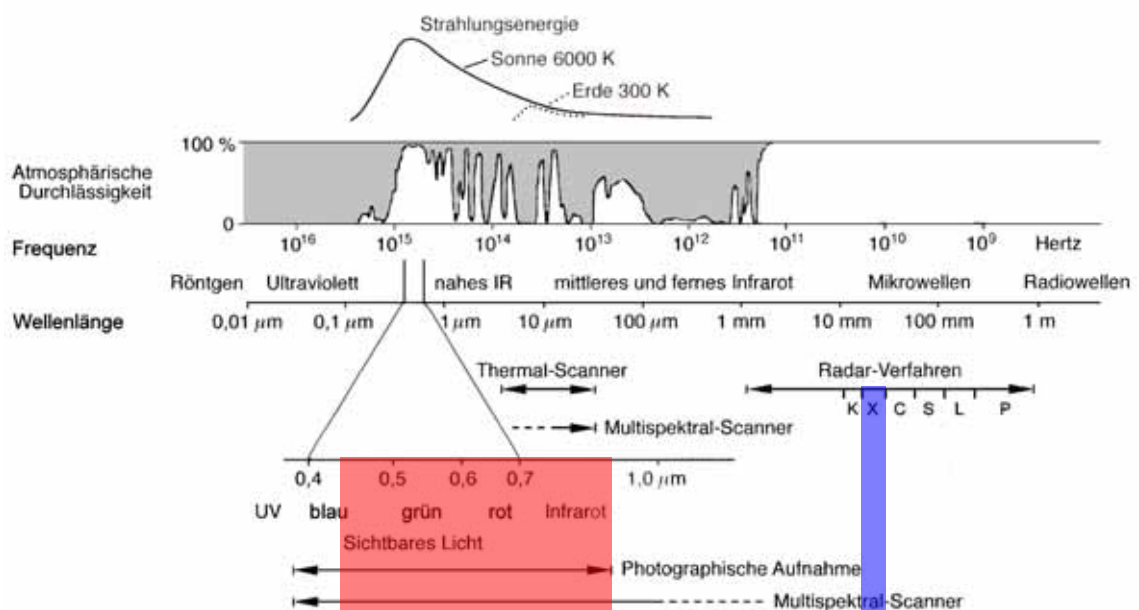


Abb. 2.1: Das elektromagnetische Spektrum. Rot und blau schattiert ist die Lage der QuickBird-Kanäle bzw. des E-SAR X-Bandes dargestellt (verändert nach ALBERTZ 2001:11).

Radarsensoren arbeiten ebenfalls im Bereich der Mikrowellen. Da es sich jedoch um aktive Systeme handelt, sind sie unabhängig von den natürlichen Strahlungsverhältnissen. Daraus ergibt sich die bedeutende Eigenschaft, dass sie nahezu unabhängig von Tag und Nacht sowie von Wolkenbedeckung, Nebel oder Rauch arbeiten (WEYDAHL et al. 2005:243). Allerdings kann Starkregen das Signal im X-Band verfälschen (LILLESAND et al. 2004:661).

Aus der Lage der genutzten Strahlung im elektromagnetischen Spektrum und den damit verbundenen Eigenschaften sowie den Unterschieden zwischen aktiven und passiven Systemen ergeben sich für optische und Radarsysteme grundsätzlich unterschiedliche Aufnahmecharakteristika, die im folgenden näher beschrieben werden.

2.1.1 Funktionsweise und Eigenschaften optischer Systeme

Neben den fotografischen Systemen existieren zur Bildaufnahme mit passiven Systemen verschiedene Abtastsysteme, so genannte *Scanner*, die in optisch-mechanische und optoelektronische *Scanner* unterschieden werden können. Erstere zeichnen die durch einen rotierenden Spiegel auf einen Detektor fokussierten elektrischen Signale senkrecht zur Flugrichtung Pixel für Pixel zeilenweise auf und zerlegen sie mittels Filter, Prismen oder Gitter in einzelne Spektralbereiche (ALBERTZ 2001:45ff.). Bekannteste Vertreter dieser Systeme sind die Landsat-Satelliten. Die neue Generation der räumlich hoch auflösenden Satelliten wie SPOT, Ikonos und QuickBird nutzen optoelektronische *Scanner* (ALBERTZ 2001:56). Deren Bildaufnahme basiert auf zeilenweise angeordneten Halbleitersensoren aus *Charge Coupled Devices* (CCDs). Jedes Spektralband benötigt eine eigene CCD-Zeile (LILLESAND et al. 2004:337). Bei der Aufnahme werden alle Pixel einer quer zur Flugrichtung verlaufenden Bildzeile gleichzeitig erfasst und durch die Eigenbewegung des Sensors zeilenweise aufgezeichnet (ALBERTZ 2001:51). Vorteil dieser Aufnahmetechnik ist die längere Verweilzeit der Detektoren über dem aufgenommenen Geländeausschnitt. Dadurch erhöht sich die am Sensor ankommende Energie, das Signal wird ausgeprägter und kann mit größerer radiometrischer Genauigkeit erfasst werden. Außerdem hat das System keine beweglichen Teile und ist dadurch wesentlich unempfindlicher (LILLESAND et al. 2004:337).

2.1.2 Reflexionsverhalten kurzweiliger Strahlung

Auf dem Weg durch die Atmosphäre wird die solare Strahlung bereits in den obersten Schichten reflektiert. Wie Abb. 2.1 veranschaulicht, ist die Atmosphäre nur für bestimmte Ausschnitte des elektromagnetischen Spektrums durchlässig. Die restliche Strahlung unterliegt auf dem Weg durch die Atmosphäre den Prozessen der Refraktion, Streuung und Absorption und wird dadurch abgeschwächt (Extinktion) (ALBERTZ 2001:14). Resultat der verschiedenen Streumechanismen in der Atmosphäre ist die diffuse Himmelsstrahlung, die die an der Erdoberfläche reflektierte Strahlung teilweise – für die Fernerkundung kontrastmindernd und damit störend – überlagert. Für die verhältnismäßig kurzweilige Strahlung, die von optischen und Thermalsensoren genutzt wird, sind Wolken ein undurchdringliches Hindernis. Dünne Dunstschleier, Nebel oder

Smog beeinträchtigen und verfälschen die reflektierten Signale. Für viele Anwendungen in der Fernerkundung ist daher eine Korrektur des Atmosphäreinflusses notwendig (z. B. ZHANG et al. 2002).

Um Objekte voneinander unterscheiden zu können, ist es wichtig, dass sie sich gegenüber der auftreffenden elektromagnetischen Strahlung unterschiedlich verhalten.

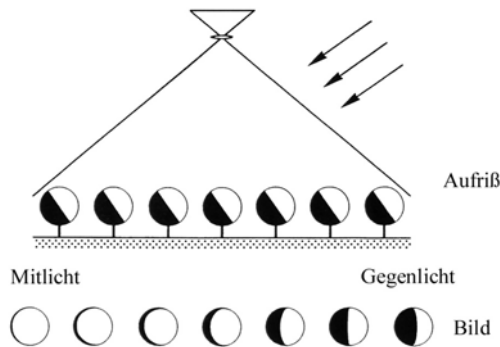


Abb. 2.2: Mitlicht- und Gegenlichtbereich bei schräg einfallender Sonnenstrahlung (ALBERTZ 2001:20).

Die Reflexionseigenschaften der Objekte hängen von Material, physikalischem Zustand, Oberflächenrauigkeit, Beleuchtungswinkel und Beobachtungsrichtung ab (ALBERTZ 2001:17). Ein Teil der Strahlung wird an den Materialien reflektiert. In Abhängigkeit von der Oberflächenrauigkeit findet an glatten Flächen spiegelnde Reflexion statt und an im Verhältnis zur Wellenlänge rauen Oberflächen diffuse Streuung. Naturgemäß kommt an den meisten Oberflächen eine

Mischung aus beiden Reflexionsarten vor, bei der in alle Richtungen ungleich stark reflektiert wird (ALBERTZ 2001:18). Jede Oberfläche hat in den verschiedenen Spektralbereichen unterschiedliche Reflexionsgrade, die wellenlängenabhängig sind und als charakteristische Reflexionskurve darstellbar sind.

Einzelobjekte werden je nach ihrer Position im Bild unterschiedlich von der Sonne angestrahlt (Abb. 2.2). Dies kann auch bei Aufnahmen in Gelände mit markantem Relief auftreten. Im Unterschied zu Radarschatten (Kapitel 2.1.4) ist in den Schatten optischer Daten (spektrale) Information vorhanden, die mit geeigneten Methoden zur weiteren Bildverarbeitung genutzt werden kann.

2.1.3 Funktionsweise und Eigenschaften von SAR-Systemen

Im praktischen Teil der Arbeit kommen Daten von E-SAR (Experimental-SAR) im X-Band zur Anwendung. Aus diesem Grund konzentriert sich dieses Kapitel auf die für dieses System wichtigen Parameter und Eigenschaften. Ausführliche Darstellungen zu den Prinzipien der Radarfernerkundung finden sich in HENDERSON & LEWIS (1998).

Radarsysteme senden in einem schmalen, jedoch recht langen Raumwinkel Mikrowellen senkrecht zur Flugrichtung aus. Das vom Radarimpuls bestrahlte Gebiet ist dabei keulenförmig. Die Wellen treffen auf Objekte der Erdoberfläche, werden von diesen mehr oder weniger stark reflektiert und an die Antenne am Sensor zurückgeworfen. Die Signale werden in ihrer zeitlichen Abfolge erfasst und als Bildzeile aufgezeichnet. Durch die kontinuierliche Bewegung des Sensors erfolgt die zeilenweise Aufzeichnung eines Streifens parallel zur Flugrichtung (ALBERTZ 2001:58f.). Aufgrund des Zusammenhangs von Antennenlänge und Abstrahleigenschaften, d. h. in erster Linie des Antennenöffnungswinkels, ist die geometrische Auflösung derartiger Systeme (z. B. SLAR *Side Looking Airborne Radar*) mit realer Apertur beschränkt (LILLESAND

et al. 2004:649). SAR-Systeme (*Synthetic Aperture Radar*) wie E-SAR besitzen eine kurze Antenne, simulieren jedoch durch die entsprechende Aufnahme- und Prozessierungstechnik eine lange Antenne. Grundlage ist der Doppler-Effekt (Abb. 2.3):




Abb. 2.3: Einflussgrößen auf die Auflösung bei SLR mit synthetischer Apertur (LILLESAND et al. 2004:651).

Als Doppler-Effekt wird die Veränderung der Frequenz einer Welle als Funktion der relativen Geschwindigkeiten eines Transmitters und eines Reflektors bezeichnet. Objekte, die sich innerhalb der Radarkeule in Flugrichtung vor dem Sensor befinden, haben aufgrund des Doppler-Effekts eine höhere Frequenz, Objekte hinter dem Sensor dementsprechend eine niedrigere

(LILLESAND et al. 2004:651).

Am Punkt der geringsten Entfernung zum Objekt ist die Frequenzverschiebung gleich null. Vom SAR-System werden die Wellen mit großem Öffnungswinkel ausgestrahlt, was dazu führt, dass einzelne Objekte während des Fluges mehrfach erfasst werden – Objekte im *Far Range* häufiger, Objekte im *Near Range* aufgrund der geringeren Überlappung der einzelnen Aufnahmekeulen weniger häufig. Die einzelnen Objekte werden in verschiedenen Sensorpositionen bestrahlt und tragen somit auf jeweils unterschiedliche Weise mehrfach zu den Reflexionssignalen bei. Durch die entsprechende Verarbeitung der Daten können die Objekte als einzelne Elemente einer Aufnahme mit langer Antenne aufgelöst werden (RANEY 1998:48ff.). Dabei wird die räumliche Auflösung deutlich erhöht (ALBERTZ 2001:59). Bei SAR-Sensoren ist die Azimutauflösung (Auflösung in Flugrichtung) unabhängig von der Entfernung vom Sensor konstant, während sie bei Systemen mit realer Apertur mit zunehmender Entfernung abnimmt. Mit zunehmender Entfernung vom Sensor in *Range*-Richtung nimmt die *Groundrange*-Auflösung in beiden Systemen zu (LILLESAND et al. 2004:651f.).

2.1.4 Speckle

Eine Besonderheit von Radarbildern sind die körnigen Bildstrukturen, die auch in homogenen Flächen auftreten – der so genannte *Speckle*-Effekt (BRUNIQUEL & LOPES 1997:603). Er entsteht dadurch, dass die abgesandte, kohärente Strahlung an den Objekten innerhalb des Bildpixels unterschiedlich gestreut und in verschiedenen Phasen reflektiert wird (GOODMAN 1976:1145). Das aufgezeichnete Signal ist somit eine Kombination aus verschiedenen Einzelsignalen mit unterschiedlicher Phase (RANEY 1998:69). Die Rückstreuintensität eines Pixels ist durch den *Speckle*-Effekt nur noch gering mit den physikalischen Gegebenheiten am Boden korreliert. Rauschen

beeinflusst insbesondere weitere Bildverarbeitungsschritte wie Segmentierung oder Klassifikation (VIDAL-PANTALEONI & MARTI 2004:4915f.). Deswegen wurden diverse Verfahren entwickelt, um den häufig als störend bewerteten *Speckle*-Effekt zu reduzieren (CAPSTICK & HARRIS 2001:3628). Ziel aller *Speckle*-Filterverfahren ist die Reduktion des *Speckle*-Effekts bei gleichzeitigem Erhalt der räumlichen Details (XIAO et al. 2003:2452), sodass homogene Flächen homogen erscheinen und Textur und Kanten erhalten bleiben. Die Reduktion kann einerseits während oder andererseits nach der Prozessierung der Daten durchgeführt werden (VIDAL-PANTALEONI & MARTI 2004:4916). Dabei können die Filtertechniken in zeitlicher oder räumlicher Domäne ausgeführt werden. Die einfachste Variante in der räumlichen Domäne ist die *Multi-Look*-Prozessierung, die während der Bildgenerierung abläuft (XIAO et al. 2003:2452). Bei diesem Verfahren werden mehrere statistisch unabhängige Aufnahmen desselben Gebiets, die von verschiedenen Positionen aus während der Prozessierung der synthetischen Apertur gemacht wurden, gemittelt (PORCELLO et al. 1976). Die Anzahl der statistisch unabhängigen Einzelbilder, deren Intensitäts- und Phaseninformation gemittelt werden, entspricht der Anzahl an *Looks*, und das Ausmaß des *Speckle*-Effekts ist umgekehrt proportional zur Wurzel dieses Wertes (LILLESAND et al. 2004:663f.). Die Anzahl der *Looks* ist direkt proportional zur Bodenauflösung, d. h. mit zunehmender Anzahl an Einzelbildern, die in den Prozess einbezogen werden, wird die Varianz und somit der *Speckle*-Effekt immer kleiner, allerdings verringert sich die räumliche Auflösung (RANEY 1998:68ff.). Die Filtertechniken in der räumlichen Domäne, die nach der Bildgenerierung durchgeführt werden, erhöhen den Informationsgehalt einzelner Pixel, indem sie die Statistik der umgebenden Pixel beachten (MARTIN & TURNER 1993:1759f.). Die Standardabweichung des *Speckle* ist linear proportional zum Mittelwert und wird häufig als multiplikativer Vorgang modelliert, d. h. je stärker das Signal, desto höher der *Speckle*-Effekt (QIU et al. 2004:245). Die einfachsten Filter sind die Tiefpassfilter, bei denen das zentrale Pixel durch den Mittelwert bzw. den Median ersetzt wird. Ihre Leistungsfähigkeit ist jedoch begrenzt (REES & SATCHELL 1997). Zu den am häufigsten genutzten adaptiven Filtern gehören Lee (LEE 1980), Frost (FROST et al. 1982), Kuan (KUAN et al. 1985), Lee-Sigma (LEE 1983), Kuan Maximum A Posteriori (MAP) (KUAN et al. 1987) und der darauf basierende Gamma-MAP, der auch in modifizierter Form anwendbar ist (LOPES et al. 1993). Während Lee, Frost und Lee-Sigma von einer Gauß-Verteilung des *Speckle* ausgehen, liegt den letztgenannten Verfahren eine Gammaverteilung zugrunde (XIAO et al. 2003:2453). Darüber hinaus existieren zahlreiche weniger bekannte Techniken (z. B. CHUNMING et al. 2002, SMITH 1996), darunter Verfahren, die adaptive Medianfilter (QIU et al. 2004) oder gewichtete Filter (MARTIN & TURNER 1993) nutzen. Inzwischen wurden auch mehrfach waveletbasierte Verfahren erfolgreich zur Reduzierung des *Speckle*-Effekts angewandt (DATCU et al. 1996, DONG et al. 1998, FUKUDA & HIROSAWA 1998, GUPTA & GUPTA 2007). Wenn von einem Gebiet mehrere Bilder vorliegen, kann auch in der zeitlichen Domäne gefiltert werden. Die multitemporale oder *multi-channel* Variante der *Speckle*-Filterung berücksichtigt die Rückstreuung mehrerer Bilder und filtert den

Rauschanteil des Signals heraus. Dabei kann die radiometrische Auflösung verbessert werden, ohne die räumliche Auflösung entscheidend zu beeinträchtigen (BRUNIQUEL & LOPES 1997). Ein vorgeschalteter multitemporaler Filter kann aus diesem Grund die Effizienz der oben genannten räumlichen Filter verbessern (GINESTE 1999:2566, BRUNIQUEL & LOPES 1997:620). Für urbane Anwendungen ist es wichtig, dass Einzelstreuer ebenso erhalten werden wie Kanten. Verfahren, die in zeitlicher Domäne arbeiten, erfüllen diese Anforderung am ehesten (YU & QUEGAN 2000:o. S.).

2.1.5 Rückstreuverhalten von Radarwellen

Die Wiedergabe der Erdoberfläche in Radarbildern hängt vom Zusammenspiel diverser Einzelfaktoren ab. Dies sind einerseits die Parameter des Aufnahmesystems und andererseits Parameter der Geländeoberfläche. Zu den Systemparametern gehören neben der Wellenlänge und Frequenz der abgesandten Strahlung die Polarisation und der Depressionswinkel, die Geländeparameter umfassen insbesondere Oberflächenrauigkeit, Oberflächenform und elektrische Eigenschaften der bestrahlten Medien (ALBERTZ 2001:61). Das X-Band nutzt relativ kurze Mikrowellen, deren Wechselwirkung mit Materialien und Objekten an der Erdoberfläche sich markant von denen anderer Wellenlängen unterscheidet. Die Wellenlänge bestimmt den Anteil der verschiedenen Streuungsarten an bestimmten Objektoberflächen sowie die Eindringtiefe der Wellen und die Signaldämpfung in Medien wie Vegetation oder Boden. Die Polarisation bezeichnet die Ebene, in der die Wellen schwingen. Sie können horizontal (H) oder vertikal (V) abgestrahlt und auch empfangen werden, so dass sich vier mögliche Kombinationen der Polarisation ergeben: HH, VV, HV und VH, wobei der erste Buchstabe die Polarisation der abgesandten Strahlung bezeichnet und der letzte Buchstabe die der empfangenen Strahlung (ALBERTZ 2001:62, LILLESAND et al. 2004:661). Diese Eigenschaft ist in sofern wichtig, als dass verschieden polarisierte Strahlen unterschiedlich mit den Medien an der Erdoberfläche interagieren – Polarisation und Wellenlänge beeinflussen die Reflexionseigenschaften des Radarsignals (LILLESAND et al. 2004:659). Die wichtigsten Streumechanismen und




Abb. 2.4: Streumechanismen von Radarstrahlen (verändert nach RANEY 1998:9ff, HEROLD 2000:6).

Rückstrahleffekte sind in Abb. 2.4 gezeigt: diffuse Streuung an rauen Oberflächen (A), spiegelnde Streuung an glatten Oberflächen (D), Volumenstreuung (C) und *Double-Bounce*-Effekte an natürlichen (B) oder künstlichen

Oberflächen (E). Die Art der Streuung wird bei einer gegebenen Wellenlänge von der Oberflächenrauigkeit, dem lokalen Einfallswinkel und den dielektrischen Eigenschaften des Mediums bestimmt (RANEY 1998:35). Die Rauigkeit muss relativ

zur Wellenlänge betrachtet werden: Oberflächen, die für lange Wellen (z. B. L-Band, vgl. Abb. 2.1) glatt sind und spiegelnde Streuung verursachen, können für Wellen im X-Band bereits rau sein und diffuse Streuung bewirken. Bei der spiegelnden Reflexion an glatten Oberflächen (Abb. 2.4, D) gelangt praktisch keine Strahlung zurück zum Radarsystem, die Fläche erscheint dunkel. An rauen Oberflächen findet diffuse Streuung statt (Abb. 2.4, A), d. h. ein Teil der Strahlung wird zum Sensor zurückreflektiert. Volumenstreuung (Abb. 2.4, C) tritt auf, wenn die Strahlung nicht einfach an der Oberfläche eines Mediums gestreut wird, sondern die Oberfläche durchdringt und mit den darunter liegenden Elementen interagiert. Das Resultat ist ein dreidimensionales Streuverhalten, das vorwiegend an inhomogenen Flächen wie Vegetation stattfindet und ein starkes Signal zum Sensor zurückwirft (LEWIS et al. 1998:162). Der Anteil der Volumenstreuung ist bei kurzen Wellenlängen, so auch X-Band, eher gering.

Der Depressionswinkel – der Winkel zwischen der Horizontebene und dem Strahl zum an der Erdoberfläche beobachteten Objekt – wirkt sich auf die Auflösung in *Range*-Richtung und die Bestrahlungsstärke der Erdoberfläche aus (ALBERTZ 2001:62). Unter der Annahme einer reliefreien Oberfläche nimmt die Reflexion mit zunehmender Entfernung vom Sensor ab (LILLESAND et al. 2004:665). Die tatsächliche Stärke des Rückstreusignals hängt jedoch maßgeblich vom lokalen Einfallswinkel ab – dem Winkel zwischen der Geländenormalen und der abgestrahlten Radarwelle (LEWIS et al. 1998:133f.). Im *Near Range* bzw. bei geringen lokalen Einfallswinkeln kann somit trotz spiegelnder Streuung an glatten Oberflächen ein starkes Signal empfangen werden (LEWIS et al. 1998:166).

Bei gegebener Wellenlänge und Polarisation wird die Stärke des Radarsignals einerseits von den strukturellen Eigenschaften beeinflusst, andererseits von den dielektrischen Eigenschaften der beobachteten Medien (PIERCE et al. 1998:23, ULABY et al. 1996:65). Die relative Dielektrizitätskonstante ϵ beschreibt die Wechselwirkung elektromagnetischer Strahlung mit einem Material und wird durch einen Realanteil ϵ' und einen Imaginäranteil ϵ'' ausgedrückt (RANEY 1998:46). Der Realanteil bestimmt den Grad der Reflexion beim Übergang der Strahlen von einem Medium in ein anderes, der Imaginäranteil ist der Verlustfaktor und beschreibt die Abschwächung des Signals im betreffenden Medium. Die Dielektrizitätskonstante von Wasser ist sehr hoch ($\epsilon' = 81$), während die von trockenen Medien sehr gering ist (trockener Boden $\epsilon' = 5$) (RANEY 1998:46). Daraus folgt, dass die dielektrischen Eigenschaften natürlicher Medien vorrangig von ihrem Wassergehalt determiniert sind (DOBSON et al. 1995:200ff.). Die Eindringtiefe von Wellen im X-Band ist geringer als die von längeren Wellen und schwächt sich mit zunehmender Bodenfeuchte deutlich ab (ULABY et al. 1996). In trockenen Böden kann somit auch Volumenstreuung stattfinden, spielt aber bei kurzen Wellenlängen kaum eine Rolle (ALBERTZ 2001:64). Je deutlicher der Kontrast zwischen den Dielektrizitätskonstanten zweier Medien, umso ausgeprägter ist die Radarrückstreuung. Einige metallische Materialien wie Hochspannungsleitungen haben sehr hohe Rückstreuwerte, wie auch natürliche Oberflächen mit hoher

Dielektrizitätskonstante (Medien mit hohem Wassergehalt, z. B. feuchte Böden) stark reflektieren (ALBERTZ 2001:63, LILLESAND et al. 2004:671). Vereinfacht ausgedrückt ist das Radarrückstreusignal umso stärker, je größer die Rauigkeit und die Dielektrizitätskonstante des erfassten Objekts (KIAGE et al. 2005:5368).

Ein grundlegender Unterschied von Radarsystemen zu optischen Aufnahmesystemen ist, dass der Bildaufbau aus der Laufzeit der Wellenfronten erfolgt. Nahe gelegene Gebiete werden vom Radarimpuls schneller durchlaufen als ferne. Daraus

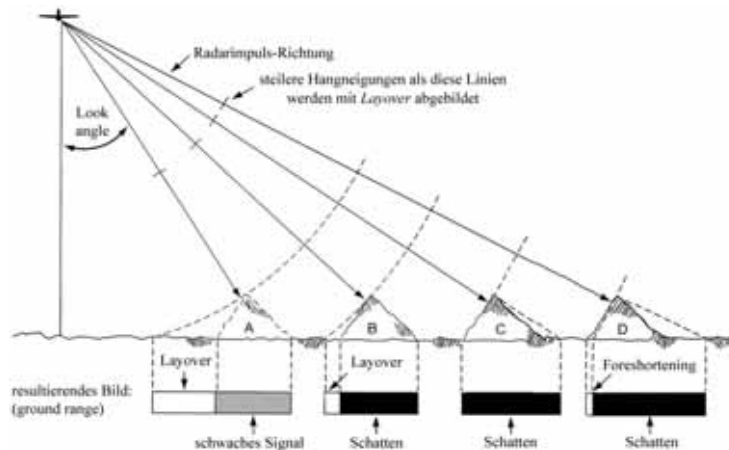


Abb. 2.5: Geländeeinflüsse auf Radarbilder (verändert nach LEWIS 1976 in LILLESAND et al. 2004:655).

resultiert ein verzerrtes Bild, dass sich unter der Annahme idealer Bedingungen korrigieren lässt (ALBERTZ 2001:80). Bei reliefreichem Gelände wird die Spitze eines Berges möglicherweise früher von der Radarwelle erfasst als der Bergfuß, so dass der Gipfel zuerst abgebildet wird (Abb. 2.5, A). Der Effekt heißt *Layover* und ist im *Near Range* am größten (LILLESAND et al.

2004:655). Der vom Sensor abgewandte Hang reflektiert kaum Strahlung zum Sensor und wird daher nur als schwaches Signal empfangen. Wird der sensorabgewandte Hang nicht vom Radarimpuls getroffen, so kann kein Signal reflektiert werden. Dieser Teil des Bildes bleibt informationslos und erscheint schwarz (Abb. 2.5, B). Wenn der sensorabgewandte Hang steiler ist als der *Look Angle*, dann wird das Gebiet jenseits des Bergfußes von informationslosen Radarschatten eingenommen (Abb. 2.5, C, D). Die Radarschatten nehmen im *Far Range* zu. Bei flachen Depressionswinkeln wird der Bergfuß zuerst erfasst. Allerdings wird die dem Sensor zugewandte Hangfläche verkürzt wiedergegeben (*Foreshortening*) (Abb. 2.5, D). Die Verkürzung der Hänge bewirkt zugleich eine Verstärkung des Rückstreusignals (ALBERTZ 2001:81).

2.1.6 Streumechanismen und Rückstrahleffekte in urbanen Räumen

In urbanen Räumen gelten selbstverständlich dieselben Prinzipien wie in natürlichen Räumen. Allerdings sind urbane Räume durch eine ausgeprägte dreidimensionale Struktur sowie regelmäßige und strenge geometrische Formen gekennzeichnet, wie sie in der Natur nur bedingt vorkommen. Die grundlegenden Streumechanismen in urbanen Gebieten sind spiegelnde und diffuse Streuung, wobei erstere aufgrund besonderer Rückstrahleffekte deutlich stärkere Rückstreusignale bewirkt: Verantwortlich sind neben der Neigung von Dachflächen zum Sensor vielfältige *Double-Bounce*- und *Triple-Bounce*-Effekte zwischen Boden und Häuserwänden (Abb. 2.6) (DONG et al. 1997). Die Orientierung von Gebäuden hat maßgeblichen Einfluss auf das Rückstreu-




Abb. 2.6: Ausgewählte Rückstreumechanismen in urbanen Räumen (DONG et al. 1997:1352).

signal (BASLY et al. 1998:168). In vielen Städten sind Straßen und Wohnblöcke häufig in eine bevorzugte Richtung ausgerichtet. Wenn die urbanen Objekte, wie Gebäude oder Eisenbahnlinien, rechtwinklig zur Wellenfront des Radarsystems ausgerichtet sind, bewirkt dies hohe Rückstreuwerte. Dieser Effekt wird *Cardinal*-Effekt genannt (RANEY 1998:42). Zu beachten sind ferner die potentiell großen Radarschattengebiete infolge der Gebäudeform und -höhe und die Rückstreuunterschiede zwischen den zum Sensor geneigten Dachflächen und den abgewandten (DONG et al. 1997:1360).

2.2 Bildfusion

Datenfusion ist ein Überbegriff für vielfältige Anwendungen in unterschiedlichen wissenschaftlichen Disziplinen (EDWARDS & JEANSOULIN 2004:303). WALD (1999:o. S.) gibt eine allgemeine und umfassende Definition von Datenfusion: „*Data fusion is a formal framework in which are expressed means and tools for the alliance of data originating from different sources. It aims at obtaining information of greater quality; the exact definition of 'greater quality' will depend upon the application*“. Daraus geht hervor, dass das Ziel der Datenfusion eine Verbesserung der Qualität ist. Je nach Anwendungsgebiet kann diese Verbesserung unterschiedliche Kriterien zum Maßstab haben. Zu den Anwendungsgebieten von Bild- bzw. Datenfusion gehören nach POHL & VAN GENDEREN (1998:827) die Bildschärfung, geometrische Korrekturen, die Datenvorverarbeitung für Stereophotogrammetrie, die Hervorhebung bestimmter Merkmale, die in den einzelnen Datensätzen nicht zu erkennen sind, die Erweiterung von Datensätzen für eine verbesserte Klassifikation, die Erkennung von Veränderungen (*Change Detection*) mittels multitemporaler Daten, die Ergänzung von Fehlwerten sowie das Ersetzen von defekten Daten.

In der Fernerkundung umfasst der Begriff Fusion die Kombination von Bildern verschiedener Sensoren oder von Bildern desselben Sensors in unterschiedlichen Modi (EHLERS et al. 2006:o. S.). VAN GENDEREN & POHL (1994, zitiert in POHL & VAN GENDEREN 1998:825) definieren Bildfusion als die Kombination von zwei oder mehr verschiedenen Bildern, bei der durch die Anwendung bestimmter Algorithmen ein neues Bild erzeugt wird. Die Fusionsalgorithmen sollten dabei die relevante Information vollständig erhalten, irrelevante Informationen und Rauschen unterdrücken und Artefakte im fusionierten Bild vermeiden (LEWIS et al. 2007:119). Grundsätzlich können der Bildfusion folgende Themenschwerpunkte zugrunde liegen: die Kombination verschiedener Daten von unterschiedlichen Sensoren (multisensoral), die Kombination verschiedener Daten mit unterschiedlicher räumlicher Auflösung (multiskalig) und die

Kombination von Daten mit unterschiedlichem Aufnahmezeitpunkt (multitemporal) (GAMBA et al. 2005:321). Beispiele für Anwendungen von Bildfusionen finden sich z. B. bei SIMONE et al. (2002). Im Kontext der Fernerkundung urbaner Räume (*Urban Remote Sensing*) sind viele wissenschaftliche Arbeiten, die sich mit Datenfusion auseinandersetzen, auf die Bildschärfung fokussiert (z. B. EHLERS 2005a, GARZELLI & NENCINI 2005, LING et al. 2007, MEENAKSHISUNDARAM & COULOIGNER 2005, NENCINI et al. 2007, ZHANG 1999, ZHANG & HONG 2005, ZHOU et al. 1998).

Je nach Anwendungsziel und Datengrundlage gibt es verschiedene Ansätze zur Datenfusion, die bei verschiedenen Prozessierungslevels ausgeführt werden können (POHL & VAN GENDEREN 1998:825). In Abb. 2.7 ist dargestellt, dass die Fusion verschiedener Bilder auf Basis des *Pixel Levels*, des *Feature Levels* oder des *Decision Levels* durchgeführt werden kann. Der *Pixel Level* ist die einfachste Fusionsstufe. Fusioniert werden gemessene physikalische Parameter, repräsentiert durch einzelne Pixel. Die Fusion im *Feature Level* setzt die Ableitung von Bildobjekten voraus. Dies kann durch Segmentierung der Eingangsbilder erreicht werden (BAATZ & SCHÄPE 2000), basierend auf bestimmten Eigenschaften wie Größe, Form, Kontrast oder Textur (PIELLA 2003:259). Die Datenfusion im *Decision Level* nutzt höherwertige, so genannte *value-added* Daten, Informationen die durch die individuelle Prozessierung der Eingangsdaten abgeleitet werden. Diese Informationen werden dann nach spezifisch festgelegten Entscheidungsregeln fusioniert (POHL & VAN GENDEREN 1998:825f.). Die Wahl des Prozessierungslevels hängt unter anderem von den Datenquellen und dem Anwendungsziel ab. Jeder Prozessierungslevel erfordert zudem unterschiedliche Vorarbeiten. Beispielsweise ist es bei Fusionen im *Pixel Level* notwendig, dass die Bilder subpixelgenau koregistriert sind (PIELLA 2003:260).

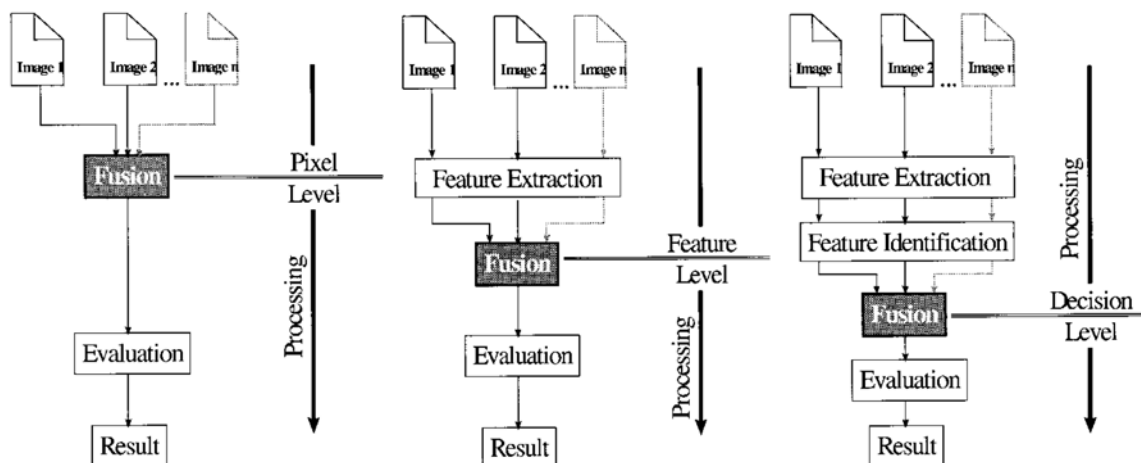


Abb. 2.7: Verschiedene Prozessierungslevel, bei denen Bildfusion ansetzen kann: *Pixel Level* (links), *Feature Level* (Mitte) und *Decision Level* (rechts) (POHL & VAN GENDEREN 1998:825).

2.2.1 Pixelbasierte Verfahren der Bildfusion

Gemäß POHL & VAN GENDEREN (1998:830) können die Bildfusionstechniken in zwei Gruppen eingeteilt werden: einerseits die farbgestützten Methoden und andererseits die statistischen und numerischen Methoden. Die Gruppe der farbgestützten Methoden

umfasst unter anderem die IHS- und die HSV-Transformationen. Die statistischen Verfahren wurden auf Basis der Bandstatistiken entwickelt und stützen sich auf Korrelationen und Filteroperationen. Die numerischen Techniken basieren auf arithmetischen Rechenverfahren, wie die Ratiobildung. Zur Gruppe der statistischen und numerischen Methoden gehören beispielsweise die Hauptkomponentenanalyse [*Principal Components Analysis* (PCA)], die Hochpassfilterung (HPF) und die Brovey-Transformation (LING et al. 2007:382). Zu den ausgereiften numerischen Ansätzen zählen die Wavelet basierten Verfahren. Die einfachste Form der Datenfusion ist die Darstellung unterschiedlicher Informationen als RGB-Komposite (POHL & VAN GENDEREN 1998:831f.).

Eine andere Einteilung von RANCHIN & WALD (2000), die allerdings auf Fusionsverfahren zur Bildschärfung abzielt, unterscheidet drei Gruppen von Fusionsmethoden. Die erste Gruppe umfasst die Methoden, in denen Daten transformiert und teilweise ersetzt werden. Zu diesen Verfahren zählen IHS- und PCA-Methode. Zur zweiten Gruppe zählen die Methoden, in denen durch Ratiobildung oder andere arithmetische Rechenoperationen Daten fusioniert werden, wie beispielsweise die Brovey-Methode. Die dritte Gruppe umfasst die Techniken, in denen die räumlichen Merkmale panchromatischer Bilder in Multispektralbilder eingearbeitet werden. Dazu gehört das ARSIS-Konzept (RANCHIN & WALD 2000, RANCHIN et al. 2003), abgeleitet von seinem französischen Namen *Amélioration de la Résolution Spatiale par Injection de Structures*, das u. a. auf Wavelets oder einer Hochpassfilterung basieren kann (RANCHIN et al. 2003:7, ZHANG & HONG 2005:226).

Von den gegenwärtig existierenden Fusionsmethoden sind PCA und IHS-Transformation die am häufigsten genutzten Verfahren (ZHANG 1999:2004), von zunehmender Bedeutung sind jedoch alle waveletbasierten Verfahren (ZHANG & HONG 2005:226). Im Folgenden werden die gebräuchlichsten Bildfusionsverfahren vorgestellt, von denen die meisten in mindestens einer der Bildverarbeitungsprogramme Erdas und Envi implementiert sind.

2.2.1.1 IHS (und HSV)

Das Farbsystem mit roten, grünen und blauen Kanälen (RGB) wird gewöhnlich von Computermonitoren verwandt, um Farbbilder darzustellen. Ein anderes Farbsystem, um Farben zu beschreiben, beruht auf *Intensity* (Intensität), *Hue* (Farbton) und *Saturation* (Sättigung) (IHS). Die Intensität repräsentiert die gesamte Menge an Licht in einer Farbe, der Farbton umschreibt die Farbeigenschaft anhand seiner Wellenlänge und die Sättigung beschreibt die Reinheit der Farbe (ZHANG & HONG 2005:226).

Im ersten Schritt des IHS-Verfahrens wird das Multispektralbild auf die Auflösung des panchromatischen Bildes gebracht. Danach erfolgt die Transformation der Daten aus dem RGB-Raum in den IHS-Farbraum. Dazu stehen verschiedene Operationen zur Verfügung (ZHANG & HONG 2005:226), von denen eine gebräuchliche Transformation nachfolgend aufgeführt ist (LING et al. 2007:383):

$$\begin{pmatrix} I \\ v_1 \\ v_2 \end{pmatrix} = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} & 0 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.1)$$

$$H = \tan^{-1}\left(\frac{v_2}{v_1}\right), S = \sqrt{v_1^2 + v_2^2} \quad (2.2).$$

Dabei bezeichnet I *Intensity*, H und S stehen für *Hue* und *Saturation*, v_1 und v_2 sind Zwischenvariablen. Die Intensitätskomponente beinhaltet die räumliche Information, während die spektrale Information in Farbton und Sättigung enthalten ist (ZHANG 2002:o. S.). Für die IHS-Transformation müssen drei Kanäle in einer beliebigen Kombination gewählt werden. Die besten Ergebnisse sind zu erwarten, wenn die Daten hoch korreliert sind (VRABEL 1996:1082). Danach wird die Intensitätskomponente durch ein höher auflösendes panchromatisches Bild ersetzt. Um eine bessere Qualität des Fusionsergebnisses zu erreichen, ist es sinnvoll, das panchromatische Bild vorher an die Intensitätskomponente anzupassen (ZHANG & HONG 2005:226). Im nächsten Schritt wird die ersetzte Intensitätskomponente zusammen mit den originalen H - und S -Komponenten in den RGB-Raum zurücktransformiert. Die Transformationsgleichung lautet (LING et al. 2007:384):

$$\begin{pmatrix} R_{new} \\ G_{new} \\ B_{new} \end{pmatrix} = \begin{pmatrix} 1 & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{2}} \\ 1 & \frac{1}{\sqrt{6}} & -\frac{1}{2} \\ 1 & -\frac{2}{\sqrt{6}} & 0 \end{pmatrix} \begin{pmatrix} I_{new} \\ v_1 \\ v_2 \end{pmatrix} \quad (2.3).$$

Abb. 2.8 zeigt schematisch die wesentlichen Schritte der Bildschärfung mittels IHS-Transformation: IHS-Transformation, Ersetzen der Intensitätskomponente durch ein höher auflösendes Bild und Rücktransformation in den RGB-Raum.

Das in Envi implementierte HSV-Verfahren folgt demselben Prinzip: Ein Multispektralbild wird aus dem RGB-Raum in den HSV-Farbraum transformiert. Die Buchstaben H , S und V bezeichnen *Hue*, *Saturation* und *Value*. Anstelle der Intensitätskomponente wird äquivalent die V -Komponente durch das höher auflösende panchromatische Bild ersetzt. Anschließend erfolgt die Rücktransformation der ersetzten V -Komponente sowie der originalen H - und S -Komponenten (RSI 2003:629). Die IHS-Transformation ist nicht nur ein vielfach angewandtes Verfahren zur Bildschärfung, sondern kann beispielsweise auch für die Fusion von Hyperspektral- und Radardaten (CHEN et al. 2003) oder von Multispektral- und Radardaten (EHLERS 1991) benutzt werden. Zur Fusion von Multispektral- und geringer auflösenden Daten (z. B. Thermalkanäle) oder Daten mit starkem Rauschen (z. B. SAR-Kanäle) wird statt der

Intensitätskomponente die Sättigungskomponente ersetzt (EHLERS 1991:26). Ein weiterer Vorteil der IHS-Transformation ist, dass jede IHS-Komponente bearbeitet




Abb. 2.8: Schematische Darstellung einer Bildfusion mittels IHS-Transformation (ZHANG 2002:o. S.).

werden kann, ohne die anderen zu beeinflussen (EHLERS 1991:28, LING et al. 2007:383). Ein Nachteil ist, dass nur jeweils drei multispektrale Bänder auf einmal prozessiert werden können. Da die meisten multispektralen Systeme mehr als drei Kanäle besitzen, muss das Verfahren für jede gewünschte Kanal-kombination wiederholt werden (LABEN & BROWER 2000:2). Hinsichtlich einer Bildschärfung verspricht das IHS-Verfahren bei Anwendung für Kanäle im sichtbaren Bereich des elektromagnetischen Spektrums gute Ergebnisse.

Bei schwacher Korrelation der Multispektralkanäle mit dem höher auflösenden panchromatischen Kanal sowie unter Verwendung von Kanälen aus dem Infrarotbereich zeigt das Verfahren jedoch deutliche Mängel (VRABEL 1996:1075).

2.2.1.2 Principle Component Analysis (PCA)

Die *Principle Component Analysis* (Hauptkomponentenanalyse) ist eine statistische Methode, die stark korrelierte Daten in einen neuen Datensatz mit unkorrelierten Daten transformiert (POHL & VAN GENDEREN 1998:835). Dabei werden die Kovarianzmatrix sowie Eigenwerte und Eigenvektoren berechnet. Auf Basis der Eigenvektorenmatrix werden dann die Eingangsdaten in einen neuen Merkmalsraum transformiert (ÖZKAN & SUNAR ERBEK 2005:749). Die erste Hauptkomponente enthält die größte Varianz und entspricht damit einem Intensitätsbild (VRABEL 1996:1075). Sie wird durch das höher auflösende Bild ersetzt, dessen Histogramm an die

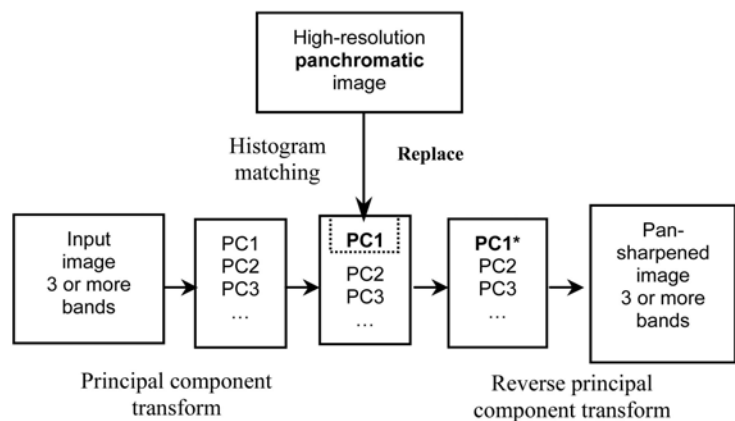


Abb. 2.9: Schematische Darstellung einer Bildfusion mittels *Principle Components* (PC)-Transformation (ZHANG 2002:o. S.).

erste Hauptkomponente angepasst werden muss (LU & WENG 2005:1278f.). Danach erfolgt die Rücktransformation der Daten mittels inverser PCA (Abb. 2.9). Dieses Verfahren hat gegenüber der Bildfusion mittels IHS-Transformation den Vorteil, dass alle multispektralen Bänder auf einmal prozessiert werden können (LABEN & BROWER

2000:3). Allerdings wird auch bei der PCA die spektrale Charakteristik des originalen Multispektralbildes verfälscht, da nur die globale Statistik des panchromatischen Bandes an die der ersten Hauptkomponente angepasst wird, die lokale Statistik jedoch erheblich voneinander abweichen kann (LABEN & BROWER 2000:3).

Neben der Anwendung zur Datenfusion kann die PCA auch zur Datenreduktion und optimalen Bandauswahl von Hyperspektraldaten (HEROLD et al. 2002a, BENEDIKTSSON et al. 2005) sowie als Grundlage von *Spectral-Mixture*-Untersuchungen (SMALL 2003, 2004, 2006, SMALL & LU 2006) durchgeführt werden.

2.2.1.3 Color Normalized (Brovey) und CN Spectral Sharpening

Das *Color-Normalized*-(Brovey)-Verfahren ist eine Fusionsmethode, die Spektraldaten und räumlich hoch auflösende Daten durch mathematische Rechenoperationen kombiniert. Die Basis ist der CN-Algorithmus, auch bekannt als *Energy Subdivision Transform* (VRABEL 1996:1082, RSI 2003:632). Jedes der drei Bänder eines RGB-Bildes wird mit dem Verhältnis von hoch auflösendem Bild zur Summe der Farbkanäle multipliziert (VRABEL 1996:1083):

$$CN_i = \frac{(MSI_i + 1) \times (PAN + 1) \times 3}{\sum_i MSI_i + 3} - 1 \quad (2.4).$$

Dabei stehen *MSI* für *Multispectral Image* und *PAN* für das panchromatische Band, CN_i ist das resultierende normalisierte Band. Die Grauwerte werden mit Konstanten addiert, um Divisionen durch Null zu vermeiden (VRABEL 1996:1083). Der CN-Algorithmus ist eine Ableitung der Brovey-Transformation (POHL & VAN GENDEREN 1998:835, POHL 1999:o. S., PRASAD et al. 2001:1220):

$$DN_f = \frac{DN_{b1}}{DN_{b1} + DN_{b2} + DN_{b3}} \times DN_{HR} \quad (2.5),$$

wobei DN_f für den Grauwert des fusionierten Bildes steht, $b1$ bis $b3$ die Multispektralbänder bezeichnen und *HR* das hoch auflösende Band meint.

Das in Envi implementierte *CN-Spectral-Sharpning*-Verfahren ist eine Erweiterung des CN-Algorithmus, der im Brovey-Verfahren zur Anwendung kommt. Es kann eingesetzt werden, um eine beliebige Anzahl an Kanälen gleichzeitig zu schärfen. Die Eingangskanäle werden nur geschärft, wenn sie im Spektralbereich des hoch auflösenden Bildes liegen. Eingangskanäle, die außerhalb liegen, bleiben unberücksichtigt. Der Spektralbereich des höher auflösenden Bildes wird definiert von der zentralen Wellenlänge des Bandes und dem FWHM (*Full Width Half Maximum*)-Wert. Entsprechend dem Spektralbereich des höher auflösenden Bildes werden die Eingangskanäle in spektrale Segmente unterteilt, die wie folgt prozessiert werden. Jeder Eingangskanal wird mit dem räumlich höher auflösenden Band multipliziert und anschließend normalisiert, indem er durch die Summe der Eingangskanäle in einem spektralen Segment dividiert wird (RSI 2003:632):

$$CN_{Sharp} = \frac{InputBand \times SharpeningBand \times (Num_Bands_In_Segment)}{(\sum Input_Bands_In_Segment) + (Num_Bands_In_Segment)} \quad (2.6).$$

Das Brovey-Verfahren kann genau wie die IHS-Transformation zur Fusion von multispektralen und panchromatischen Bildern angewandt werden (VRABEL 1996:1082f.). Mit dem CN-Verfahren können beispielsweise auch Hyperspektraldaten durch ein Multispektralbild geschärft werden (RSI 2003:632). VRABEL (1996:1079) kam in einer Studie verschiedener Bildschärfungsverfahren zu dem Ergebnis, dass das CN-Verfahren genau wie die IHS-Methode die besten Ergebnisse bei Bandkombinationen erreicht, die den Echtfarben entsprechen.

2.2.1.4 Gram-Schmidt

Das Gram-Schmidt-Verfahren ist eine Methode zur Bildschärfung. Eine genaue Beschreibung geben LABEN & BROWER (2000). In Abb. 2.10 sind die einzelnen Schritte des Gram-Schmidt-Verfahrens aufgeführt.

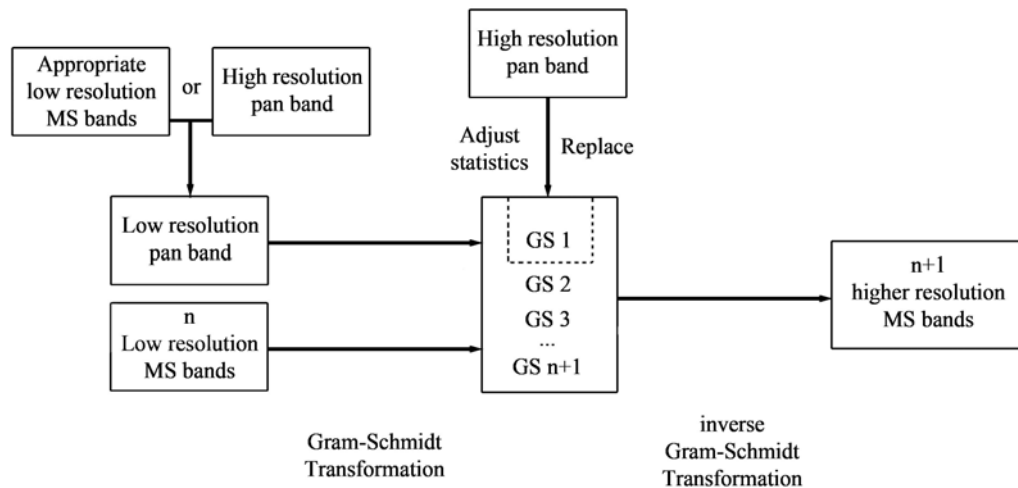


Abb. 2.10: Schematische Darstellung einer Bildfusion mittels Gram-Schmidt-Transformation (verändert nach LABEN & BROWER 2000:Sheet 4).

In einem ersten Schritt wird ein niedrig auflösendes panchromatisches Band simuliert. Dies kann auf zwei unterschiedliche Arten geschehen: Erstens, die niedriger auflösenden Multispektralbänder werden zu einem niedrig auflösenden panchromatischen Band kombiniert. Dazu wird jedes Band unterschiedlich gewichtet. Zweitens, das hoch auflösende panchromatische Band wird degradiert und im entsprechenden Maßstab in eine niedrigere Auflösung interpoliert. In der Software Envi erfolgt die Simulation eines niedrig auflösenden panchromatischen Bandes durch die gewichtete Kombination der einzelnen Multispektralkanäle (RSI 2003:630).

Im nächsten Schritt wird eine modifizierte Form der Gram-Schmidt-Transformation (CLAYTON 1971, FAREBROTHER 1974, MA et al. 2001) auf das simulierte niedrig auflösende panchromatische Band und den Multispektraldatensatz angewandt. Dabei wird das simulierte panchromatische Band als erstes Band verwandt. In der modifizierten Form der Gram-Schmidt-Transformation wird von jedem Pixel eines

Kanals der Mittelwert des Kanals subtrahiert, bevor die eigentliche Transformation durchgeführt wird. In der modifizierten Formel wird das T -te Gram-Schmidt-Band aus dem $T-1$ -ten Gram-Schmidt-Band konstruiert (LABEN & BROWER 2000:5):

$$GS_T(i, j) = (B_T(i, j) - \mu_T) - \sum_{l=1}^{T-1} \phi(B_T, GS_l) \times GS_l(i, j) \quad (2.7)$$

mit: T = das zu transformierende Band

B = original Band

μ_T = Mittelwert von Band T , berechnet nach

$$\mu_T = \frac{\sum_{j=1}^C \sum_{i=1}^R B_T(i, j)}{C \times R} \quad (2.8),$$

wobei: C = Anzahl der Spalten im Bild

R = Anzahl der Reihen im Bild

und $\Phi(B_T, GS_l) =$ Quotient aus der Kovarianz des Gram-Schmidt-Band mit dem originalen Band B und der Varianz des Gram-Schmidt-Bandes, berechnet nach

$$\phi(B_T, GS_l) = \left[\frac{\sigma(B_T, GS_l)}{\sigma(GS_l, GS_l)^2} \right] \quad (2.9).$$

Danach werden Mittelwert (Gleichung 2.8) und Standardabweichung (Gleichung 2.10) des ersten Gram-Schmidt-Bandes (GS_1 in Abb. 2.10) sowie des hoch auflösenden panchromatischen Bandes berechnet. Das hoch auflösende panchromatische Band wird so gestreckt, dass Mittelwert und Standardabweichung mit denen des ersten Gram-Schmidt-Bandes übereinstimmen. Dadurch haben das erste Gram-Schmidt-Band, das aus dem simulierten niedrig auflösenden panchromatischen Band berechnet wurde, und das angepasste hoch auflösende panchromatische Band dieselbe globale Statistik. Die Standardabweichung berechnet sich wie folgt (LABEN & BROWER 2000:5):

$$\sigma_T = \sqrt{\frac{\sum_{j=1}^C \sum_{i=1}^R (B_T(i, j) - \mu_T)^2}{C \times R}} \quad (2.10).$$

Anschließend wird das erste Gram-Schmidt-Band durch das gestreckte hoch auflösende panchromatische Band ersetzt. Durch eine inverse Gram-Schmidt-Transformation des Datensatzes entsteht dann ein neues, hoch auflösendes Multispektralbild. Die Berechnung erfolgt nach LABEN & BROWER (2000:5):

$$B_T(i, j) = (GS_T(i, j) + \mu_T) + \sum_{l=1}^{T-1} \phi(B_T, GS_l) \times GS_l(i, j) \quad (2.11).$$

Das Ergebnis zeigt dann idealerweise einen Multispektraldatensatz mit verbesserter räumlicher Auflösung und unverfälschten Spektraleigenschaften.

2.2.1.5 HPF (High Pass Filtering)

Zur Bildschärfung können Bilder unterschiedlicher räumlicher Auflösung gefiltert und anschließend kombiniert werden. Dazu wird das hoch auflösende panchromatische Bild mit einem Hochpassfilter gefiltert und mit den Multispektraldaten addiert (SHABAN & DIKSHIT 2002:253). VRABEL (1996) nutzt eine Variation der HPF: Die hoch auflösenden panchromatischen Daten werden wie im ursprünglichen HPF-Verfahren mit einem Hochpassfilter gefiltert, um die räumliche Information zu extrahieren. Das räumlich geringer auflösende Multispektralbild wird mit einem Tiefpassfilter gefiltert, um die spektrale Information zu separieren. Danach werden die gefilterten Ergebnisse gewichtet und addiert. Die Transformationsgleichung lautet (VRABEL 1996:1082):

$$HP_i = (W_a \times MSI_{ip}) + (W_b \times PAN_{ihp}) \quad (2.12),$$

wobei W_a und W_b die Gewichtungsfaktoren sind, sodass $W_a + W_b = 1$ ist. MSI_{ip} bezeichnet ein tiefpassgefiltertes Multispektralband i , während PAN_{ihp} das hochpassgefilterte panchromatische Band bezeichnet und HP_i das resultierende geschärfte Band ist. Ein Nachteil des HPF-Verfahrens besteht darin, dass Texturinformationen verloren gehen (POHL & VAN GENDEREN 1998:837).

2.2.1.6 Addition und Multiplikation

Die arithmetischen Verfahren, die auf Addition und Multiplikation basieren, sind aufgrund unterschiedlicher Gewichtungs- und Skalierungsfaktoren zahlreich (POHL & VAN GENDEREN 1998:834). POHL & VAN GENDEREN (1998:834) nennen folgende Möglichkeiten der Multiplikation:

$$DN_f = A \times (w1 \times DN_a + w2 \times DN_b) + B \quad (2.13)$$

$$DN_f = A \times DN_a \times DN_b + B \quad (2.14).$$

A und B sind Skalierungsfaktoren, $w1$ und $w2$ bezeichnen Gewichtungsfaktoren, f steht für das fusionierte Bild und a und b benennen jeweils die Eingangsbilder.

Ein Nachteil dieser Methode ist, dass die resultierenden hoch auflösenden Multispektralbänder stärker korreliert sind als die Ausgangsdaten. Somit erfolgt die Verbesserung der räumlichen Information auf Kosten der spektralen Information (EHLERS 1991:28).

2.2.1.7 Wavelet

Die Verwendung von Wavelets auf dem Gebiet der Bildverarbeitung ist eine verhältnismäßig junge Entwicklung. Die Wavelet-Transformation zerlegt das Signal, ähnlich einer Fourier-Transformation (STRANG 1993), auf der Grundlage elementarer

Funktionen, den Wavelets. Wavelets sind diskrete, d. h. endliche Funktionen im Raum $L^2(\mathbb{R})$, die durch Dilatationen (Stauchungen) und Translationen (Streckungen) der so genannten Mutter-Wavelet $\psi(x)$ mit Zweierpotenzen als Faktor gebildet werden (SHI et al. 2003:514f.). Dilatationen bezeichnen den Schritt von $\psi(x)$ zu $\psi(2x)$, Translationen den Schritt von $\psi(2x)$ zu $\psi(2x-1)$ (STRANG 1993:289). Es existieren zahlreiche Mutter-Wavelets, die alle oszillierende Funktionen sind und gut in Zeit und Frequenz lokalisiert sind (GARGUET-DUPORT et al. 1996:1057, RANCHIN & WALD 2000:50f.). Ihre Form repräsentiert das Eingangsbild. Die Berechnung der Wavelet-Transformation für jeden Maßstab a und jeden Punkt b des Signals $f(x)$ erzeugt eine lokale Repräsentation von $f(x)$, und der Informationsgehalt wird durch den Wavelet-Koeffizienten $WT_f(a,b)$ vermittelt (RANCHIN & Wald 2000:51). Der Prozess kann umgekehrt werden, sodass aus den Wavelet-Koeffizienten das originale Signal ohne Verlust rekonstruiert werden kann.

Die Wavelet-Transformation führte zum Konzept der *Multiresolution Analysis* (MRA), das auf die Arbeit von MALLAT (1989) zurückgeht. Danach werden zweidimensionale Signale (z. B. digitale Bilder) in Strukturen zerlegt und in sukzessiven Maßstäben oder räumlichen Auflösungen analysiert (RANCHIN & WALD 1993:615). Dies gestattet die skalenunabhängige Interpretation des Bildes (MALLAT 1989:674). Die Anwendung der Wavelet-Transformation erlaubt die Beschreibung der Unterschiede, die zwischen jeder aufeinander folgenden Näherung eines Bildes existieren, durch Wavelet-Koeffizienten, die den Detailbildern in drei Richtungen entsprechen: horizontal, vertikal und diagonal (Abb. 2.11). Durch die inverse Wavelet-Transformation werden diese Details in andere, koregistrierte Bilder implementiert (GARGUET-DUPORT et al. 1996:1059).




Abb. 2.11: Filterbank für den Analyseschritt der Wavelet-Transformation (nach RANCHIN & WALD 2000:52).

Zur Anwendung der zweidimensionalen Wavelet-Transformation nach MALLAT (1989) kann ein Bild, wie in Abb. 2.11 dargestellt, mit einer Hoch-Tiefpass-Filterbank gefiltert werden. Dabei sind H ein Hochpassfilter und G ein Tiefpassfilter, die zunächst auf die Spalten angewandt werden. Wie die Pfeile implizieren, wird dazu das Signal jeweils um den Faktor zwei degradiert, wodurch eine von zwei Spalten entfernt wird. Durch Gebrauch der Filter H und G für die Zeilen der beiden entstandenen Bilder wird eine von zwei Reihen entfernt und es entstehen vier neue Bilder: Die hochfrequente Information des Bildes $f_j(x,y)$ ist in den Wavelet-Koeffizienten $C_{j+1}^H(x,y)$, $C_{j+1}^V(x,y)$

und $C_{j+1}^D(x, y)$ gespeichert. In $f_{j+1}(x, y)$ ist das um den Faktor zwei komprimierte Kontextbild enthalten (RANCHIN & WALD 2000:51). Dieser Schritt wird Analyse genannt. Im Beispiel von QuickBird entsteht durch die Wavelet-Transformation des panchromatischen Bildes mit 0,6 m Auflösung neben den drei Wavelet-Koeffizienten ein Kontextbild mit 2,4 m Auflösung. Durch nochmalige Filterung des komprimierten panchromatischen Bildes sowie der vier Multispektralbilder entstehen neue Wavelet-Koeffizienten, die genutzt werden, um die Korrekturparameter zu berechnen. Genauso können auch die Wavelet-Koeffizienten verschiedener Bildquellen (z. B. optisch und Radar) kombiniert werden, um dementsprechend neue Koeffizienten zu erhalten (PAJARES & DE LA CRUZ 2004:1856). Durch die umgekehrte Anwendung der Filterbank (Abb. 2.11) auf die Detailbilder in Verbindung mit einem *Oversampling* um den Faktor zwei kann im Schritt der Synthese das Ausgangsbild rekonstruiert werden. Die Anwendung auf die mittels Korrekturparameter neu berechneten Wavelet-Koeffizienten ermöglicht die Kombination der Informationen eines Bildes A und eines Bildes B durch die inverse Wavelet-Transformation. So kann im Fall einer beabsichtigten Bildschärfung mit der beschriebenen Prozedur (RANCHIN & WALD 2000) aus einem gering auflösenden Multispektralbild und einem höher auflösenden panchromatischen Bild ein hoch auflösendes Multispektralbild erzeugt werden (Kapitel 2.2.2).

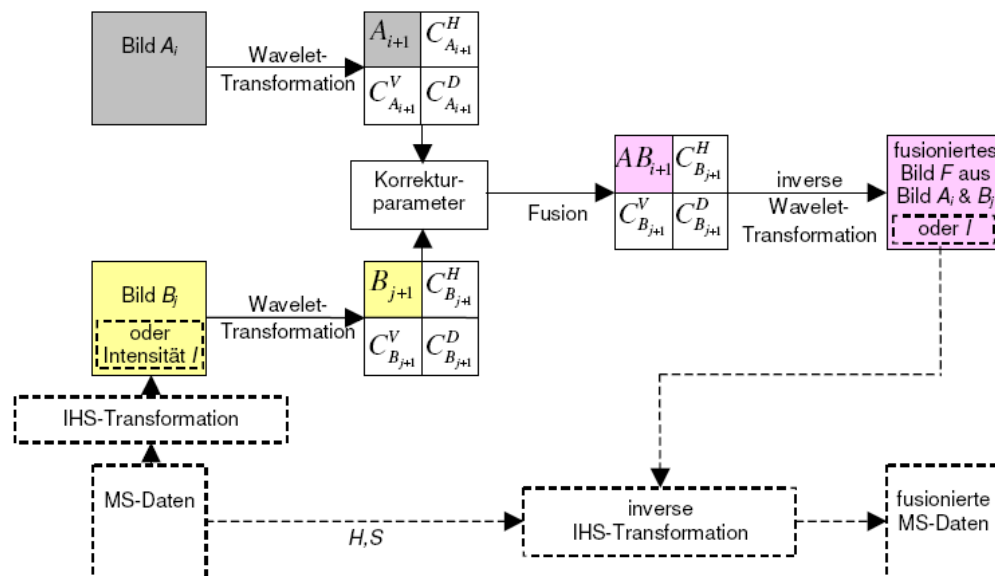


Abb. 2.12: Schema der Wavelet-Fusion.

In Abb. 2.12 ist die waveletbasierte Bildfusion schematisch dargestellt: Zwei Ausgangsbilder werden mittels Wavelet-Transformation in verschiedenen Auflösungen in die horizontalen, vertikalen und diagonalen Strukturen zerlegt, wobei ein degradiertes Kontextbild erhalten bleibt. Die Wavelet-Koeffizienten C_z^H , C_z^V und C_z^D repräsentieren die Unterschiede zwischen zwei Auflösungen. Durch die Berechnung von Korrekturparametern, für die verschiedene Methoden zur Verfügung stehen (PAJARES & DE LA CRUZ 2004:1860ff.), ergeben sich neue Koeffizienten, die mittels inverser Wavelet-Transformation in ein neues, kombiniertes Bildprodukt umgerechnet werden. Bei der Bildschärfung von optischen Daten mittels Wavelets kann in einem ersten Schritt eine

IHS-Transformation (CHIBANI & HOUACINE 2002, ZHANG & HONG 2005) oder eine PCA vorgeschaltet werden. Die hoch auflösende panchromatische Komponente muss an die zu kombinierenden Kanäle (I oder PC1) angepasst werden. Die Intensitätskomponente bzw. die erste Hauptkomponente sowie ein panchromatisches Bild werden dann im nächsten Schritt durch Wavelet-Transformationen schrittweise zerlegt, einhergehend mit der Berechnung der Wavelet-Koeffizienten. Das Kontextbild des niedrig auflösenden Bildes ersetzt teilweise das Kontextbild des hoch auflösenden Bildes in seiner größten Auflösung nach entsprechenden Kombinationsregeln. Dazu müssen die Ausgangsbilder jeweils soweit zerlegt werden, dass beide Kontextbilder dieselbe Dimension haben. Durch die inverse Wavelet-Transformation wird eine neue Intensitäts- bzw. erste Hauptkomponente generiert. Das endgültige fusionierte Bild entsteht durch die inverse IHS-Transformation bzw. PCA in den RGB-Raum.

Detaillierte Beschreibungen zur Wavelet-Theorie finden sich in DAUBECHIES (1992), MALLAT (1989), PAJARES & DE LA CRUZ (2004) und STRANG (1993). Die Wavelet-Transformation bietet weitreichende Anwendungsmöglichkeiten. LI et al. (1995) zeigen den Gebrauch von Wavelets für die Bildschärfung von optischen Daten (Landsat TM und SPOT), zur Fusion von optischen und Radardaten (Landsat TM und Seasat SAR) und zur Kombination von optischen und Infrarotdaten. Waveletbasierte Verfahren sind speziell bei der Fusion von optischen und SAR-Daten den herkömmlichen Methoden wie IHS überlegen, da die bloße Substitution der Intensitätskomponente durch das SAR-Bild zu Verfälschungen der spektralen Charakteristika der optischen Daten führt (CHIBANI 2006:313). Wavelet-Analysen werden unter anderem auch für Zeitreihenanalysen auf dem Gebiet der Geophysik angewandt (TORRENCE & COMPO 1998). Eine Auswahl an Anwendungsbeispielen zur Datenfusion mittels Wavelet-Analyse findet sich außerdem bei CHIBANI (2006), CHIBANI & HOUACINE (2002), GARGUET-DUPORT et al. (1996), LEWIS et al. (2007), RANCHIN et al. (2003), RANCHIN & WALD (1993, 2000), SHI et al. (2003, 2005), SIMONE et al. (2002), YOCKI (1996), ZHANG & HONG (2005) und ZHOU et al. (1998).

Für die Software Envi steht unter <http://www.rsinc.com/codebank/> ein Wavelet-Tool zum Download zur Verfügung. Es bietet unter anderem die Möglichkeit, Wavelet-Familie (Coiflet, Daubechies, Haar, Symlet) und Dekompositionslevel zu bestimmen sowie die Eingabebilder unterschiedlich zu gewichten. In Erdas steht in den aktuellen Versionen ebenfalls ein Wavelet-Tool bereit. Dort kann gewählt werden, mit welcher Methode im Falle eines Multispektralbildes die spektrale Information des geringer auflösenden Bildes auf die Intensität reduziert werden soll. Dazu stehen IHS-Transformation und PCA zur Verfügung. Handelt es sich um ein Graustufenbild, wie z. B. ein Radarbild, so kann entsprechend auf die Transformation verzichtet werden.

2.2.1.8 Ehlers Fusion

Die Ehlers Fusion ist ein auf einer IHS-Transformation (Kapitel 2.2.1.1) basiertes Verfahren, bei dem zusätzlich eine Filterung im Frequenzraum durchgeführt wird (EHLERS 2005a:o. S.), sodass nur der hochfrequente Teil der Intensitätskomponente

ersetzt wird (LING et al. 2007:383). EHLERS & KLONUS (2004) geben eine detaillierte Erläuterung der Ehlers Fusion. Dasselbe Verfahren wird von LING et al. (2007) als „*FFT-enhanced IHS transform*“ beschrieben. Ziel dieses Verfahrens ist die Integration räumlich hoch auflösender panchromatischer Daten in niedrig auflösende multispektrale Bilddaten, ohne die spektrale Information zu verändern (EHLERS & KLONUS 2004:497). Es handelt sich demnach um ein Verfahren, das bevorzugt zum *Pansharpening* (Kapitel 2.2.2) angewandt wird. Es ist allerdings mit dieser Methode auch möglich, die räumliche Auflösung von Hyperspektraldaten zu verbessern (EHLERS & KLONUS 2004:501).

Der erste Schritt der Ehlers Fusion ist das Resampling der Multispektralkanäle auf die Auflösung der panchromatischen Komponente. Die bikubische Faltung verspricht die besten Ergebnisse bei der darauf folgenden Fusion (EHLERS & KLONUS 2004:497f.).

Im zweiten Schritt werden drei Kanäle ausgewählt und in den IHS-Raum transformiert. Das panchromatische Bild wird dann an den Wertebereich der Intensitätskomponente angepasst. Anschließend erfolgt die Transformation des panchromatischen Bildes und der Intensitätskomponente des IHS-Bildes in den Frequenzraum mittels einer zweidimensionalen *Fast Fourier Transformation* (FFT). Die Gleichung dazu lautet (LING et al. 2007:384):

$$H(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} h(x, y) e^{-j2\pi(ux+vy)} dx dy \quad (2.15)$$

$$\text{mit } j = \sqrt{-1} \text{ und } e^{\pm jx} = \cos(x) \pm j \sin(x) \quad (2.16).$$

Durch die Analyse des Powerspektrums können isotrope Hoch- bzw. Tiefpassfilter entworfen werden. Es ist davon auszugehen, dass beim Resampling des multispektralen Bildes auf die Auflösung des panchromatischen Bildes künstliche Information erzeugt wird, die im Frequenzraum herausgefiltert wird. Der Anteil dieser künstlichen Information lässt sich anhand des Verhältnisses zwischen den Pixelkantenlängen der Multispektralkanäle und des panchromatischen Kanals bestimmen. Im Fall von QuickBird beträgt dieses Verhältnis 1:4 (Verhältnis 2,4 m zu 0,6 m). Demnach ist ein Viertel der Informationen künstlich erzeugt. Da die spektrale Information überwiegend in den niedrigen Frequenzen enthalten ist (BRETSCHNEIDER & KAO 2001:4), kann die überflüssige Information mit einem Tiefpassfilter herausgefiltert werden. Der Tiefpassfilter filtert die hochfrequente Information aus dem Multispektralbild heraus, während der Hochpassfilter die niedrigfrequente Information aus dem panchromatischen Bild filtert. Idealerweise wirken die Filter entgegengesetzt, das heißt, die hohen Frequenzen, die der Tiefpassfilter aus dem Multispektralbild herausfiltert, werden in der panchromatischen Komponente durchgelassen. Um Oszillationen im Ortsbereich bei Rechteckfilterungen (GIBB'sches Phänomen) zu vermeiden, werden die Filter durch ein HANNING-Fenster geglättet und es wird ein geringfügiger Überlappungsbereich akzeptiert (EHLERS & KLONUS 2004:499).

Im Anschluss an die Filterung werden beide Komponenten mittels einer inversen FFT in den Ortsraum zurücktransformiert. Danach werden die beiden Bilder addiert und an das Histogramm der ursprünglichen Intensitätskomponente angepasst. Aus dem

neuen, fusionierten Intensitätskanal sowie den ursprünglichen *Hue*- und *Saturation*-Kanälen wird ein neues IHS-Bild erzeugt, das dann durch eine inverse IHS-Transformation in ein RGB-Bild umgewandelt wird (LING et al. 2007:384):

$$h(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} H(u, v) e^{-j2\pi(ux+vy)} dudv \quad (2.17).$$

Die fusionierte RGB-Komposite hat die räumliche Auflösung des panchromatischen Kanals und enthält die spektralen Charakteristika der multispektralen Kanäle. Das Ablaufschema der Ehlers Fusion ist in Abb. 2.13 dargestellt.

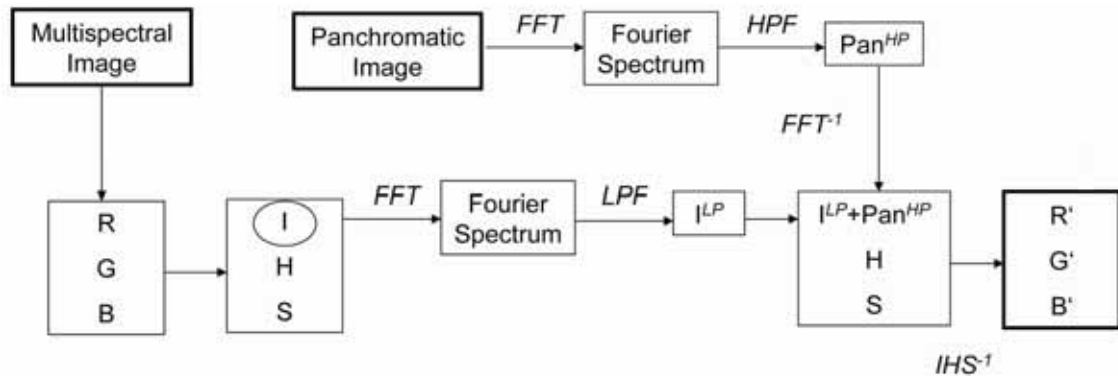


Abb. 2.13: Ablaufschema der Ehlers Fusion (EHLERS 2005b:o. S.).

Das Prinzip der teilweisen Substitution einzelner Komponenten kann auch eingesetzt werden, um die PCA zu erweitern. In diesem Fall wird der hochfrequente Teil der ersten Hauptkomponente mit dem des panchromatischen Bildes ersetzt (LING et al. 2007:383).

2.2.1.9 AIF-Methode

Das AIF-Verfahren (*Adaptive Image Fusion*) (STEINNOCHER 1999) gehört anders als die meisten der bisher vorgestellten Verfahren (noch) nicht zu den Standardmethoden der Bildverarbeitung. Grundlegend ist die Koregistrierung der Bilder mittels *Nearest-Neighbour*-Resampling. Ein komplizierteres Verfahren wie *Cubic Convolution* ist nicht notwendig, weil die blockige Erscheinung des geringer auflösenden Bildes während des Fusionsprozesses ohnehin verändert wird.

Es wird davon ausgegangen, dass ein Objekt von benachbarten Pixeln gebildet wird, deren Grauwerte einer Gauß-Verteilung entsprechen. An einer Objektkante befinden sich daher zwei Grauwertverteilungen, die jeweils eines von zwei Objekten repräsentieren. Um diese Objekte zu differenzieren, wird ein adaptiver Sigma-Filter angewandt, der jedes Pixel einem der beiden Objekte zuordnet. Ein Sigma-Filter bildet nur von den Pixeln den Durchschnitt in einem lokalen Fenster, die innerhalb des zweifachen Sigma-Bereichs (zweifache Standardabweichung) des zentralen Pixels liegen, wobei davon ausgegangen wird, dass das zentrale Pixel den Mittelwert der Gauß-Verteilung darstellt (STEINNOCHER 1999:109, SMITH 1996:2045). Demnach werden Pixel, die zu einer anderen Verteilung gehören, vom Filterprozess nicht gemittelt und die Kanten bleiben erhalten (SMITH 1996:2045). Allerdings muss das zentrale Pixel

nicht zwangsläufig der Mittelwert der Gauß-Verteilung sein. Um dem Rechnung zu tragen, wurde der modifizierte Sigma-Filter eingeführt (SMITH 1996), der den Durchschnitt aller Pixel bildet, die zur selben Verteilung gehören könnten wie das zentrale Pixel, ohne den Mittelwert dieser Verteilung zu kennen. Alle anderen Pixel gehören zu einer anderen Grauwertverteilung, d. h. zu einem anderen Objekt (STEINNOCHER 1999:109). Zur Anwendung des modifizierten Sigma-Filters muss die normalisierte Standardabweichung berechnet werden. Dies geschieht auf Basis des panchromatischen Bildes: Zuerst werden aus dem originalen Bild mit der Fenstergröße, die auch im Filterprozess verwandt wird, der lokale Durchschnitt und die lokale Standardabweichung berechnet. Danach wird die Standardabweichung durch den Durchschnitt geteilt, wodurch ein Bild mit der normalisierten Standardabweichung entsteht. Der Modalwert des Histogramms bildet den Startwert für den Filterprozess (STEINNOCHER 1999:109). Durch den modifizierten Sigma-Filter werden Gebiete mit geringer Standardabweichung geglättet, während in Gebieten mit hoher Standardabweichung nur die Pixel gemittelt werden, die zur selben Verteilung gehören wie das zentrale Pixel.

Im eigentlichen AIF-Algorithmus wird zunächst das panchromatische Bild mit dem modifizierten Sigma-Filter gefiltert. Innerhalb eines gleitenden Fensters wird der zweifache Sigma-Bereich des zentralen Pixels berechnet und alle Pixel, die innerhalb dieses Bereichs liegen, werden ausgewählt. Die Multispektraldaten werden in den Fusionsprozess einbezogen, indem an der Position der im panchromatischen Band gewählten Pixel die Subpixel des resampelten Multispektralbildes gemittelt werden. Es muss betont werden, dass während des gesamten Prozesses keine spektrale Information aus dem panchromatischen Band in die Multispektraldaten integriert wird, sodass die spektrale Information weitgehend unverändert erhalten bleibt (STEINNOCHER 1999:109).




Abb. 2.14: Vereinfachte Darstellung der Auswirkung der AIF (STEINNOCHER 1999:110).

Durch die iterative Ausführung der AIF werden die Mischpixel des Multispektraldatensatzes schrittweise in die Objekte aufgliedert, aus denen sie bestehen. Wie in Abb. 2.14 ersichtlich, bestimmt das panchromatische Bild (a) die Form der Objekte im fusionierten Bild

(c), während die spektrale Information vom Multispektralbild (b) determiniert wird. Objekte, die kleiner sind als die Pixelgröße des originalen Multispektralbildes, werden nur geschärft, wenn sie in starkem Kontrast zu ihrer Umgebung stehen (STEINNOCHER 1999:110). Am besten geeignet ist die AIF, wenn die Zielobjekte größer sind als die Auflösung des geringer auflösenden Bildes (STEINNOCHER 1999:114). Durch die Schärfung der Objektkanten bei gleichzeitiger Glättung der Flächen innerhalb eines Objekts fungiert die AIF als Vorsegmentierung des Multispektralbildes (STEINNOCHER 1999:110). Dabei bleibt die spektrale Information zum größten Teil erhalten. Der Nachteil der Technik liegt darin, dass Texturinformationen aus dem panchromatischen

Bild nicht in das Fusionsprodukt übernommen werden (STEINNOCHER 1999:113). Anwendungsbeispiele für die AIF finden sich unter anderem in BAUER & STEINNOCHER (2001), KOCH et al. 2003 und STEINNOCHER (1999).

2.2.2 Pansharpening

Die gegenwärtig existierenden optischen Fernerkundungssysteme erreichen ihre höchste räumliche Auflösung nur im panchromatischen Kanal (EHLERS & KLONUS 2004:495f.). Die multispektralen Kanäle der hoch auflösenden Satellitensysteme, wie Ikonos oder QuickBird, haben eine geringere räumliche Auflösung als der panchromatische Kanal, der einen breiten Bereich des elektromagnetischen Spektrums abdeckt, erreichen jedoch eine höhere spektrale Auflösung (LING et al. 2007:381). *Pansharpening* ist ein Sonderfall der Bildfusion und umfasst alle Verfahren, die die Fusion räumlich hoch auflösender panchromatischer und niedriger auflösender Multispektraldaten zu räumlich hoch auflösenden Multispektraldaten zum Gegenstand haben (LABEN & BROWER 2000:1). *Pansharpening*-Verfahren nutzen Rasterdaten und basieren auf dem Pixel Level (Abb. 2.7). Die Anwendung des *Pansharpenings* ist auch mit Daten mittlerer räumlicher Auflösung sowie unterschiedlicher Sensoren möglich. Insbesondere vor dem Start der hoch auflösenden Multispektralsatelliten Ikonos und QuickBird waren es vor allem panchromatische SPOT-Daten, die zur Schärfung der Multispektraldaten von SPOT (GARGUET-DUPORT et al. 1996, SHABAN & DIKSHIT 2002, WALD et al. 1997) oder Landsat TM (JUTZ & CHOROWICZ 1993, LIU 2000, SHI et al. 2003, YOCKI 1996, ZHANG 1999, ZHOU et al. 1998) genutzt wurden.

Alle *Pansharpening*-Techniken sollten das Ziel verfolgen, lediglich die zusätzliche räumliche Information aus dem panchromatischen Bild in die Multispektraldaten zu integrieren und dabei deren spektrale Information so wenig wie möglich zu beeinflussen (GARGUET-DUPORT et al. 1996:1057, LABEN & BROWER 2000:3). Die meisten gebräuchlichen Verfahren, wie Brovey, IHS oder PCA, werden jedoch dem Anspruch des Erhalts der Grauwerte nur bedingt gerecht (EHLERS 2005a:o. S.). Aus diesem Grund werden permanent neue Verfahren entwickelt und bestehende Verfahren erweitert, z. B. die Ehlers Fusion (EHLERS & KLONUS 2004), oder kombiniert, z. B. IHS- und Wavelet-Transformationen (CHIBANI & HOUACINE 2002).

2.2.3 Segmentbasierte Fusion

Die meisten der in Kapitel 2.2.1 vorgestellten Verfahren der Bildfusion eignen sich sowohl zum *Pansharpening* als auch zur Kombination von optischen und Radardaten. Es handelt sich dabei jedoch ausschließlich um pixelbasierte Verfahren.

Neben diesen vor allem auf eine optische Schärfung eines Bildes abzielenden Verfahren eröffnet die segmentbasierte Fusion insbesondere für Klassifikationsanwendungen neue Horizonte. Grundlegend für die segmentbasierte Bildfusion ist die Segmentierung eines Bildes, um homogene Regionen abzugrenzen. Es können verschiedene Merkmale dieser Regionen berechnet werden, aus denen bestimmt werden kann, welche Eigenschaften welches Bildes im Fusionsergebnis enthalten sind (LEWIS et al.

2007:119). Daraus ergeben sich einige Vorteile gegenüber pixelbasierten Verfahren. Zu diesen zählen die Möglichkeit, Regionen mit bestimmten Eigenschaften im Fusionsergebnis hervorzuheben oder zu vernachlässigen sowie die geringere Empfindlichkeit hinsichtlich Rauschen oder ungenauen Registrierungen (LEWIS et al. 2007:121). Anders als bei den pixelbasierten Verfahren gibt es für segmentbasierte Fusionen keine Standardalgorithmen. Stattdessen sind die Kombinationsregeln stärker anwendungsabhängig.

Besonders effektiv ist die segmentbasierte Fusion bei der Verwendung von räumlich hoch und spektral gering auflösenden Daten, wie z. B. panchromatische oder Luftbilder, und räumlich geringer, aber spektral hoch auflösenden Daten, wie z. B. Multispektral- oder Hyperspektraldaten. Bei dieser Datengrundlage werden die räumlich hoch auflösenden Bilder segmentiert. Auf Basis der Segmente werden dann in den spektral höher, aber räumlich gering auflösenden Daten Referenzspektren für die einzelnen Materialien gesucht und in der anschließenden Klassifikation berücksichtigt (EHLERS et al. 2006, GREIWE 2005, GREIWE et al. 2004). Ein ähnliches Beispiel für segmentbasierte Fusion findet sich in SEGL et al. (2003). In dieser Arbeit wurden Hyperspektraldaten des flugzeuggetragenen DAIS-Instruments segmentiert, um eine Gebäudemasken zu erstellen, die anschließend zur Bestimmung der *Endmember* für ein *Spectral Unmixing* genutzt wurde. PIELLA (2003) beschreibt eine segmentbasierte Fusionsmethode, bei der im Rahmen einer MRA alle Eingangsdaten segmentiert werden. Die aus den einzelnen Segmenten extrahierten Informationen bestimmen, wie die Koeffizienten der transformierten Daten kombiniert werden (PIELLA 2003:272). LEWIS et al. (2007) nutzen eine *Dual-Tree Complex Wavelet Transform* (DT-CWT), um die Eingangsdaten zu segmentieren. Die Merkmale jeder Region werden berechnet und die Bilder im Wavelet-Raum nach entsprechenden Fusionsregeln kombiniert (LEWIS et al. 2007:124). Darüber hinaus bietet die segmentbasierte Fusion als Alternative zu den *Pansharpening*-Techniken auch die Möglichkeit, multispektrale und höher auflösende panchromatische Daten zu kombinieren. Bei großen homogenen Flächen, wie beispielsweise Seen, ist es nicht notwendig, die räumliche Auflösung mittels *Pansharpening* zu erhöhen, da die Auflösung des multispektralen Bildes ausreicht, um die Klasse zu charakterisieren. Die Einbindung der Informationen aus dem panchromatischen Bild stört hier lediglich die spektralen Eigenschaften der Klasse, da das höher auflösende Bild gewöhnlich ein geringeres *Signal-to-Noise-Ratio* aufweist (BUNTILOV & BRETSCHNEIDER 2004:o. S.). In den heterogenen urbanen Gebieten oder in Übergangsbereichen zwischen homogenen Flächen ist die räumliche Verbesserung dem gegenüber äußerst zweckdienlich. Deswegen kann es sinnvoll sein, das Bild in homogene und nicht-homogene Bereiche zu gliedern, die dann unterschiedlich behandelt werden: homogene Bereiche bleiben unverändert, während heterogene Bereiche kombiniert werden (BUNTILOV & BRETSCHNEIDER 2004:o. S.).

2.2.4 Beurteilung der Qualität von Bildfusionen

Die Qualitätsbeurteilung von Bildfusionen stellt ein schwerwiegendes Problem der digitalen Bildverarbeitung dar. Dennoch gibt es eine Reihe von Methoden, die eine

vergleichbare Überprüfung der Ergebnisse ermöglichen. Dabei hängt die Qualitätsbewertung des erzeugten Fusionsprodukts wesentlich vom ursprünglichen Ziel ab (SHI et al. 2005:241). Für visuelle Interpretationen ist es wichtig, bestimmte Phänomene durch die Fusion hervorzuheben oder lediglich ein schärferes Bild zu erzeugen, das leichter ausgewertet werden kann. In der Fernerkundung zielen jedoch viele Datenfusionen auf eine verbesserte Klassifikation durch die synergetische Nutzung verschiedener Datenquellen ab. Für derartige Anwendungen müssen vor allem die spektralen Eigenschaften erhalten bleiben. Daher ist bei der Qualitätskontrolle von *Pansharpening*-Techniken und -Produkten neben der Bildschärfe insbesondere die Erhaltung der Grauwerte zu überprüfen. Im Folgenden soll ein Überblick über die Möglichkeiten zur Bewertung der Qualität von Bildfusionen gegeben werden. Dabei handelt es sich lediglich um eine Auswahl an möglichst praktikablen, häufig verwendeten und neuen Ansätzen.

SHI et al. (2005) unterscheiden qualitative Methoden von quantitativen. Zu den ersteren zählen alle Bewertungen, die die zumeist subjektiven Eindrücke eines Bildes in Attribute wie z. B. „gut“/ „schlecht“ oder „scharf“/ „unscharf“ fassen oder auch vergleichende Bewertungen wie „schlechter als“ oder „das beste Ergebnis ist“. Somit werden anhand der qualitativen Maße vorrangig visuelle Eindrücke wiedergegeben. Die quantitativen Maße können nach SHI et al. (2005:247f.) in drei Kategorien gegliedert werden: 1) der Mittelwert, 2) die räumlichen Details und 3) die spektrale Information: Erstens: Der Mittelwert eines Bildes (Gleichung 2.8) beschreibt lediglich die über das gesamte Bild gemittelte Intensität. Zweitens: Räumliche Details werden besser durch die Standardabweichung (Gleichung 2.10), die Entropie (Gleichung 2.18) und Profillinien beschrieben. Die Entropie berechnet sich zu (SHI et al. 2005:248):

$$H = -\sum_{i=0}^{L-1} p_i \ln p_i \quad (2.18),$$

wobei L die Anzahl der Grauwerte bezeichnet. Die Variable p_i ist das Verhältnis der Anzahl von Pixeln mit dem Grauwert i ($0 \leq i \leq L-1$) und der Gesamtanzahl von Pixeln in einem Bild. Die Entropie drückt die Informationsfülle aus. Durch die Analyse einzelner besonders interessanter Bildbereiche anhand von Profillinien kann stichprobenhaft die Übereinstimmung von Original und fusioniertem Bild überprüft werden (HIRSCHMUGL et al. 2005:273). Profillinien geben darüber hinaus über Rauschen und Artefakte Aufschluss, die im Zuge der Fusion in das Bild eingebracht wurden (SHI et al. 2005:248). Drittens: Die Analyse der spektralen Information erfolgt anhand von *Bias Index* (Gleichung 2.19), Korrelationskoeffizient (Gleichung 2.20) und *Warping Degree* (Gleichung 2.21) (SHI et al. 2005:248):

$$B_{index} = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \frac{|x_{i,j} - x'_{i,j}|}{x_{i,j}} \quad (2.19).$$

Dabei sind $x_{i,j}$ und $x'_{i,j}$ die Pixel des originalen bzw. des fusionierten Bildes. Je größer der Wert, desto größer ist die Abweichung.

$$\text{corr}\left(\frac{A}{B}\right) = \frac{\sum_{j=1}^n \sum_{i=1}^m (x_{i,j} - \mu(A))(x'_{i,j} - \mu(B))}{\sqrt{\sum_{j=1}^n \sum_{i=1}^m (x_{i,j} - \mu(A))^2 \sum_{j=1}^n \sum_{i=1}^m (x'_{i,j} - \mu(B))^2}} \quad (2.20),$$

wobei A und B die betrachteten Bilder, $x_{i,j}$ und $x'_{i,j}$ die jeweiligen Pixel des Bildes A und B und $\mu(A)$ und $\mu(B)$ die Mittelwerte der Bilder sind. Nähert sich der Korrelationskoeffizient gegen eins, ist die Korrelation sehr stark.

$$W = \frac{1}{m \times n} \sum_{j=1}^n \sum_{i=1}^m |x_{i,j} - x'_{i,j}| \quad (2.21).$$

Dabei bezeichnen $x_{i,j}$ und $x'_{i,j}$ die Pixel des originalen und des fusionierten Bildes. Je größer W , desto größer ist die Verzerrung.

Als Ergänzung zu den vorgestellten statistischen Parametern kann das von ZHENG et al. (2007) entwickelte *Ratio of Spatial Frequency Error* (rSFe) gesehen werden. Dieses ist von einem Maß abgeleitet, das *Spatial Frequency* (SF) genannt wird und Ausdruck der lokalen Intensitätsveränderungen ist. Die SF berechnet sich aus *Row Frequency* (RF) und *Column Frequency* (CF), den räumlichen Veränderungen in vertikaler und horizontaler Bildrichtung (ZHENG et al. 2007:179):

$$SF = \sqrt{(RF)^2 + (CF)^2} \quad (2.22)$$

$$\text{mit: } RF = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=2}^N [I(i, j) - I(i, j-1)]^2} \quad (2.23)$$

$$\text{und } CF = \sqrt{\frac{1}{MN} \sum_{j=1}^N \sum_{i=2}^M [I(i, j) - I(i-1, j)]^2} \quad (2.24).$$

Dabei hat das zu analysierende Bild eine Größe von $M \times N$ Pixeln. Das rSFe berücksichtigt zusätzlich die räumliche Frequenz in zwei diagonalen Richtungen, *Main Diagonal SF* (MDF) und *Secondary Diagonal SF* (SDF) (ZHENG et al. 2007:180):

$$MDF = \sqrt{w_d \times \frac{1}{MN} \sum_{i=2}^M \sum_{j=2}^N [I(i, j) - I(i-1, j-1)]^2} \quad (2.25)$$

$$SDF = \sqrt{w_d \times \frac{1}{MN} \sum_{j=1}^{N-1} \sum_{i=2}^M [I(i, j) - I(i-1, j+1)]^2} \quad (2.26).$$

Der Ausdruck $w_d = 1/\sqrt{2}$ ist ein Distanzgewicht, das in den Gleichungen 2.23 und 2.24 gleich eins ist. Die gesamte räumliche Frequenz eines Bildes ist dann die Kombination aus vier gerichteten SFs (ZHENG et al. 2007:180):

$$SF = \sqrt{(RF)^2 + (CF)^2 + (MDF)^2 + (SDF)^2} \quad (2.27).$$

Mit dieser Gleichung (2.27) können die räumlichen Frequenzen der Eingabebilder (SF_A und SF_B) und des Fusionsergebnisses (SF_F) berechnet werden. Als nächstes wird die Referenz-SF (SF_R) ermittelt. Dabei sind die vier Differenzen aus den Gleichungen 2.23-2.26 die Hauptgradienten in vier Richtungen eines Pixels, ausgedrückt als $Grad(I(i,j))$. Die Maxima der absoluten Gradientenwerte zwischen den Eingabebildern A und B in vier Richtungen ergeben die vier Referenzgradienten (ZHENG et al. 2007:180):

$$Grad^D(I_R(i,j)) = \max\{abs[Grad^D(I_A(i,j))], abs[Grad^D(I_B(i,j))]\} \quad (2.28).$$

Dabei steht D für die vier Richtungen horizontal, vertikal, *main diagonal* und *secondary diagonal*. Die Referenz-SFs (RF_R , CF_R , MDF_R , SDF_R) können dann berechnet werden, indem die eckigen Klammern in den Gleichungen 2.23-2.26 durch die $Grad^D(I_R(i,j))$ -Werte ersetzt werden. Die Gleichung zur Berechnung der Referenz-SF in horizontaler Richtung lautet dann (ZHENG et al. 2007:180):

$$RF_R = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=2}^N [Grad^H(I_R(i,j))]^2} \quad (2.29).$$

Adäquat zu Gleichung 2.27 wird die gesamte Referenz-SF berechnet. Schließlich ergibt sich das rSFe folgendermaßen (ZHENG et al. 2007:180):

$$rSFe = \frac{SF_F - SF_R}{SF_R} \quad (2.30).$$

Für diese Art der Qualitätskontrolle wird kein Referenzbild benötigt. Idealerweise ist $rSFe = 0$. Wenn $rSFe > 0$, dann heißt das, dass in das fusionierte Bild überschüssige Information und Verzerrungen eingebracht wurden. Ist $rSFe < 0$ bedeutet dies, dass durch die Fusion Information verloren gegangen ist. Die Autoren sprechen von *over-fused* und *under-fused* (ZHENG et al. 2007:180). Neben diesem noch neuen Qualitätsmaß verwenden ZHENG et al. (2007) auch den bekannteren *Root Mean Square Error* (RMSE), der sich wie folgt berechnet (ZHENG et al. 2007:179):

$$RMSE = \sqrt{\frac{\sum_{i=1}^M \sum_{j=1}^N [I_R(i,j) - I_F(i,j)]^2}{M \times N}} \quad (2.31)$$

mit $I_R(i,j)$ und $I_F(i,j)$ als den Pixelwerten des originalen oder Referenzbildes und des fusionierten Bildes. Darüber hinaus bietet der *Image Quality Index* (IQI) ebenso ein Maß für die Qualität von Bildfusionen. Er berechnet sich zu (ZHENG et al. 2007:179):

$$Q_0(x,y) = \frac{4\sigma_{xy}\overline{xy}}{(\overline{x^2} + \overline{y^2})(\sigma_x^2 + \sigma_y^2)} \quad (2.32)$$

und kann umgewandelt werden zu:

$$Q_0(x, y) = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \times \frac{2\overline{xy}}{\left(\overline{x^2} + \overline{y^2}\right)} \times \frac{2\sigma_x \sigma_y}{\left(\sigma_x^2 + \sigma_y^2\right)} \quad (2.33),$$

wobei \overline{x} der Mittelwert von x ist, σ_x die Varianz von x und σ_{xy} die Kovarianz von x und y . In Gleichung 2.33 besteht der zu lösende Term aus dem Korrelationskoeffizienten zwischen x und y , der Beleuchtungsverzerrung (*luminance distortion*) und der Kontrastverzerrung (*contrast distortion*). Somit hat Q_0 einen Wertebereich zwischen 0 und 1. Der Maximalwert $Q_0 = 1$ wird erreicht, wenn x und y identisch sind. ZHENG et al. (2007:179) stellen zusätzlich noch eine abgewandelte Form des IQI vor, bei der die Eingabebilder unterschiedlich gewichtet werden können.

WALD et al. (1997) nennen zur quantitativen Bewertung der spektralen Qualität von *Pansharpening*-Produkten verschiedene Möglichkeiten. Dem liegen drei Eigenschaften zugrunde, die ein *Pansharpening*-Produkt erfüllen sollte (WALD et al. 1997:694, RANCHIN et al. 2003:6):

- a) Wird ein fusioniertes Bild auf die originale Auflösung degradiert, sollte es dem originalen Multispektralbild so ähnlich als möglich sein.
- b) Jedes fusionierte Bild mit der Auflösung h sollte dem Multispektralbild entsprechen, das ein Multispektralsensor mit der Auflösung h aufnehmen würde.
- c) Ein Fusionsprodukt mit der Auflösung h sollte dem Datensatz entsprechen, den ein entsprechender Multispektralsensor mit der höchsten Auflösung h erzeugen würde.

Um die erste Eigenschaft zu überprüfen, wird ein *Pansharpening*-Produkt auf die Auflösung des originalen Multispektralbildes degradiert und sollte diesem dann so ähnlich als möglich sein. Durch Differenzbilder lässt sich ergründen, ob Fehler Trends vorhanden sind und ob Ungenauigkeiten mit bestimmten Landbedeckungsklassen assoziiert sind. Des Weiteren können statistische Parameter wie Mittelwert, Standardabweichung, durchschnittliche Abweichung und Korrelationskoeffizient verglichen werden. Die Genauigkeit auf Pixelebene wird durch den *Bias Index* (Gleichung 2.19) erfasst (WALD et al. 1997:694f.). Ein Genauigkeitsmaß, das die Qualität des fusionierten Bildes global überprüft, ist der nach seinem französischen Namen *Erreur Relative Globale Adimensionnelle de Synthèse* benannte ERGAS, der dimensionslose globale relative Fusionsfehler (NENCINI et al. 2007:148, RANCHIN et al. 2003:14):

$$ERGAS = 100 \frac{h}{g} \sqrt{\frac{1}{N} \sum_{n=1}^N \left(\frac{RMSE(n)}{\mu(n)} \right)^2} \quad (2.34).$$

Dieses Maß ist besonders gut geeignet, um die Qualität von *Pansharpening*-Produkten zu überprüfen. Dabei ist h/g das Verhältnis der Pixelgröße von hoch auflösendem und gering auflösendem Kanal (im Fall von QuickBird $1/4$), $\mu(n)$ ist der Mittelwert des Bandes n und N die Anzahl der Kanäle. Die zweite Eigenschaft wird getestet, indem die originalen panchromatischen Daten auf die Auflösung des originalen Multispektralbildes degradiert und die originalen Multispektraldaten mit dem gleichen Faktor degradiert werden. Danach wird das *Pansharpening*-Verfahren durchgeführt, das

Produkt wird mit dem Original verglichen und sollte diesem idealerweise so ähnlich als möglich sein. Die dritte Eigenschaft wird vorrangig visuell überprüft. Dazu werden die aus den degradierten Daten produzierten *Pansharpening*-Produkte mit den originalen Multispektraldaten in eine Datei gefügt. Nach einer Hauptkomponentenanalyse werden die Farbkompositen dargestellt und verglichen (WALD et al. 1997:695).

BUNTILOV & BRETSCHNEIDER (2004) berechnen mit einem gleitenden Fenster die Standardabweichung jedes Pixels und weisen auf Basis von Schwellwerten homogene, nicht-homogene und gemischte Regionen aus. Für jede der drei Kategorien wird der RMSE zwischen dem fusionierten Produkt und dem originalen Multispektralbild berechnet. So kann für jede der ausgewiesenen Regionen individuell der Erfolg der Fusion in spektraler Hinsicht bestimmt werden, und der Nutzer kann abschätzen, inwiefern die Fusion der einzelnen Kategorien sinnvoll ist. Gegebenenfalls kann für jede Homogenitätskategorie ein geeignetes Verfahren bestimmt werden. Zur Abschätzung der räumlichen Fusionsqualität nutzen BUNTILOV & BRETSCHNEIDER (2004) den Roberts-Operator (ROBERTS 1965) als Maß für die räumlichen Veränderungen entlang eines Gradienten. Innerhalb der drei Regionen werden die erhaltenen Werte summiert. Die normalisierte Differenz dieser Summen zwischen Original und fusioniertem Bild gilt als Maß für räumliche Verbesserung bzw. Degradierung (BUNTILOV & BRETSCHNEIDER 2004:o. S.).

In vielen Arbeiten wird die Qualität der Bildfusion anhand eines oder mehrerer der vorgestellten Maße geprüft. Eine Qualitätsbeurteilung mittels Korrelationskoeffizient und qualitativer Bewertung findet sich beispielsweise in PRASAD et al. (2001). SHABAN & DIKSHIT (2002) nutzen ebenfalls qualitative und statistische Maße und überprüfen die von WALD et al. (1997:649) vorgeschlagene erste Eigenschaft.

2.3 Analyse räumlich hoch auflösender Fernerkundungsdaten

Im Folgenden werden zunächst die Vor- und Nachteile von pixel- bzw. objektbasierten Ansätzen in der Fernerkundung diskutiert, ehe auf die letztgenannten näher eingegangen wird. Pixelbasierte Techniken kommen im Rahmen der vorliegenden Arbeit nicht zur Anwendung und werden deshalb nicht ausführlicher behandelt. Detaillierte Beschreibungen der herkömmlichen, pixelbasierten Klassifikationsverfahren finden sich in den Standardwerken der Fernerkundungsliteratur (z. B. ALBERTZ 2001).

2.3.1 Pixel vs. Objekte

Insbesondere bei kleinmaßstäbigen Untersuchungen, z. B. zur Unterscheidung von urbanen und nicht-urbanen Gebieten oder großflächigen Kartierungen, werden mit Erfolg überwiegend pixelbasierte Verfahren eingesetzt, um Daten geringer (z. B. Modis) oder mittlerer Auflösung (z. B. Landsat TM) zu klassifizieren (JIN et al. 2005, KAYA & CURRAN 2006, SCHNEIDER et al. 2003). Zur Unterscheidung intra-urbaner Landbedeckungs- und Landnutzungsklassen reicht dieser Auflösungsbereich nicht aus (JENSEN & COWEN 1999:615). Die noch junge Generation räumlich hoch auflösender Satelliten, wie Ikonos und QuickBird, eröffnet der Fernerkundung neue Möglichkeiten,

speziell in den heterogenen urbanen Gebieten. Mit zunehmender räumlicher Auflösung steigt auch die spektrale Variabilität (OUMA et al. 2006:73) und somit zunächst auch der Anteil an Mischpixeln. Der generalisierende Effekt bei Sensoren mit geringer Auflösung (z. B. Landsat MSS), deren Signal in heterogenen Räumen ein Integral von Gebäuden, Straßen, Bäumen, Gras usw. ist, wird bei Sensoren mit mittlerer räumlicher Auflösung durch die spektrale Dominanz einzelner Klassen in den Pixeln abgelöst (BARNSELY & BARR 1996:949). Die bei mittlerer räumlicher Auflösung in urbanen Räumen als Rauschen wahrgenommene Variabilität entspricht dem tatsächlichen Signal. Es bedarf jedoch entsprechender Techniken, anhand derer nützliche Informationen aus den Daten gewonnen werden können (BARNSELY & BARR 2000:270). Erst bei sehr hoher räumlicher Auflösung werden einzelne Objekte besser aufgelöst und der Anteil an Mischpixeln wird geringer. Damit einhergehend ist eine zunehmende spektrale Variabilität innerhalb der Klassen (WOODCOCK & STRAHLER 1987:325, SCHIEWE et al. 2001:35). Mit herkömmlichen Klassifikationsverfahren wie der *Maximum-Likelihood*-Klassifikation, deren Klassenzuweisung wie die meisten traditionellen Algorithmen darauf beruht, dass Landbedeckungsklassen spektral homogen sind, werden deswegen zu viele oder nur ungenau definierte Klassen ausgewiesen (SCHIEWE & EHLERS 2005:687). Neben der hohen Variabilität innerhalb der Klassen stellen Mischpixel für Klassifikationen mit herkömmlichen Methoden ebenfalls ein Problem dar (MARTINUZZI et al. 2007:289, SMALL 2003:171). Dementsprechend nimmt bei der Verwendung dieser Verfahren auch die Klassifikationsgenauigkeit bei höherer räumlicher Auflösung der Daten ab, weil die spektralen Charakteristika innerhalb der Landbedeckungsklassen mit zunehmender Auflösung immer vielfältiger werden und sich mit denen anderer Klassen teilweise überlappen (BARNSELY & BARR 1996:949, SCHIEWE 2002:o. S., WOODCOCK & STRAHLER 1987:325). Der Breitbandcharakter und die geringe Anzahl an spektralen Kanälen in den Daten von Ikonos und QuickBird stellen die Anwendbarkeit von pixelbasierten Klassifikationsverfahren, die lediglich spektrale bzw. statistische Informationen nutzen, in Frage. Allerdings kommen in hoch auflösenden Daten Strukturen, Textur und räumliche Details von Objekten deutlich zum Ausdruck (SCHIEWE 2002:o. S.). Die meisten Bildanalyseverfahren basieren auf den methodischen Grundlagen der Bildverarbeitung aus den 1970er Jahren und machen keinen Gebrauch von räumlichen Konzepten (BLASCHKE & STROBL 2001:12, BURNETT & BLASCHKE 2003:233). Die Berücksichtigung struktureller und kontextueller Informationen führt zum Konzept der Segmentierung und der Ableitung homogener Objekte (BAATZ & SCHÄPE 2000:12). Die Aussage eines einzelnen Pixels ist aufgrund des Einflusses seiner Nachbarschaft ohnehin nicht verlässlich (DELL'ACQUA et al. 2006:244, TOWNSHEND et al. 2000:842). Insofern bietet die objektbasierte Klassifikation vor allem texturreicher Bilder – u. a. Radarbilder und hoch auflösende Daten – ein viel versprechendes Werkzeug, um die Schwächen der pixelbasierten Verfahren zu umgehen. Durch den Einsatz hoch auflösender Daten sind es nicht mehr einzelne Mischpixel, die die spektrale Signatur mehrerer Objekte in sich vereinen, sondern einzelne, vom Nutzer wahrnehmbare

Objekte werden von mehreren Pixeln gebildet. Die Zusammenfassung von Pixeln zu Objekten reduziert die spektrale Variabilität. Gleichzeitig haben objektbasierte Klassifikationsverfahren den Vorteil, dass Informationen über Textur und räumliche Beziehungen sowie objektbasierte Eigenschaften berücksichtigt werden (YUAN & BAUER 2006:o. S.). Unter der Annahme, dass benachbarte Pixel zur selben Landbedeckungsklasse gehören, ist es möglich, Objekte so abzugrenzen, wie sie vom Betrachter wahrgenommen werden (KOCH et al. 2003:195). Infolge der damit einhergehenden Generalisierung bleiben jedoch Details innerhalb der Objekte unbeachtet. Außerdem erfolgt die Segmentierung durch iterative Parametrisierung auf Basis der subjektiven Wahrnehmung des Betrachters. Pixelbasierte Verfahren sind demgegenüber statistisch basiert und bleiben dadurch nachvollziehbar. Auf einige Schwächen der pixelbasierten Verfahren wurde bereits hingewiesen. Dazu zählt auch, dass keine Ableitung von Objekten möglich ist, die dem menschlichen Wahrnehmungsvermögen entsprechen (KOCH et al. 2003:196). Räumliche Informationen wie Textur werden bei pixelbasierten Verfahren mit einem gleitenden Fenster erfasst, wodurch die Grenzen zwischen verschiedenen Landbedeckungsklassen undeutlich werden (BARNSELY & BARR 2000:272). Die entstehende Textur an der Grenze zweier Klassen ist ausgeprägter als die innerhalb der Klassen und erzeugt im Klassifizierungsergebnis einen Kanteneffekt (*Edge Effect*), der bei segmentbasierten Ansätzen vermieden werden kann (CARLEER et al. 2005:1286).

Die Wahl des geeigneten Verfahrens, pixel- oder objektbasiert, hängt wesentlich von den Eingangsdaten ab. Vor allem in komplexen Untersuchungsgebieten wie urbanen Räumen und strukturierten Landschaften oder bei Veränderungsuntersuchungen (*Change Detection*) sowie bei hoch auflösenden Daten ist die segmentbasierte Klassifikation den pixelbasierten Methoden überlegen (BLASCHKE & STROBL 2001:17). Diverse vergleichende Studien belegen, dass objektbasierte Verfahren bei der Analyse urbaner Räume mittels hoch auflösender Daten bessere Ergebnisse liefern als pixelbasierte Klassifikationsansätze (KAMAGATA et al. 2005, LINDE & KIRSTEIN 2004, MITTELBERG 2002, YUAN & BAUER 2006). Bei Daten geringerer Auflösung sowie zur Analyse spektral und strukturell leicht differenzierbarer Klassen sind pixelbasierte Verfahren auch weiterhin ein zweckmäßiges Mittel (LINDE & KIRSTEIN 2004:525). Unter Umständen kann es sinnvoll sein, innerhalb ausgewiesener Segmente pixelbasiert zu arbeiten, um bestimmte Details besser zu erfassen (KOCH et al. 2003).

2.3.2 Objektbasierte Ansätze

Wie aus dem vorangegangenen Abschnitt hervorgeht, ist es sinnvoll, für die Analyse hoch auflösender Daten in urbanen Räumen objektbasierte Verfahren anzuwenden. Anstelle von Pixeln bilden bei diesen Verfahren einzelne Segmente, so genannte Objekte, die Basis der Prozessierung. Diese stehen in engem Zusammenhang mit realen Objekten und haben neben statistischen Eigenschaften eine Reihe zusätzlicher Merkmale bezüglich Form (z. B. Kantenlänge oder Anzahl der Kanten) und Topologie (z. B. die Lage zu Nachbar- oder Superobjekten), die einzelne Pixel nicht bieten (BENZ et al. 2004:240).

2.3.2.1 Segmentierung

Bei objektbasierten Ansätzen muss zwischen Bildobjekten (*Image Objects*) und Zielobjekten (*Objects of Interest*) unterschieden werden. Zielobjekte entsprechen realen Objekten (z. B. ein Haus). Bildobjekte sind dagegen häufig nur das Produkt eines notwendigen Zwischenschritts, ehe Zielobjekte durch weitere Segmentierung und Klassifikation ausgewiesen werden können. Das kleinste Bildobjekt ist ein Pixel (BENZ et al. 2004:244). Die Segmentierung ist die Unterteilung eines Bildes in einzelne, sich nicht überlappende Regionen, die durch Bildobjekte repräsentiert werden (SCHIEWE 2002:o. S.). Segmentierungsalgorithmen werden immer dann benötigt, wenn aus einem vorhandenen Pixel- oder Objektlevel ein neuer Objektlevel kreiert werden soll. Es existieren verschiedene Segmentierungsalgorithmen, die in grenzbasierte (*boundary-based*) und regionenbasierte (*region-based*) Ansätze untergliedert werden (CARLEER et al. 2005:1286). Erstere erkennen Objektkonturen mit Hilfe von Diskontinuitätsmerkmalen, letztere weisen Objekte nach Ähnlichkeitskriterien aus (ZHANG 1997:964). Die grenzbasierten Methoden, wie beispielsweise *Edge Detector* oder *Watershed Segmentation*, suchen nach Kanten und Ecken. Demgegenüber werden bei regionenbasierten Ansätzen, wie den *Region-Growing*-Techniken, die Segmente durch das schrittweise Zusammenfügen homogener Regionen gebildet (CARLEER et al. 2005:1286).

Während der Begriff Auflösung (*Resolution*) die Fläche bezeichnet, die ein Pixel repräsentiert, beschreibt Maßstab (*Scale*) den Grad der Aggregation, an dem ein bestimmtes Phänomen beschrieben wird (BENZ et al. 2004:241). Die durchschnittliche Bildobjektgröße sollte an den Betrachtungsmaßstab angepasst werden (BAATZ & SCHÄPE 2000:12). Der Hintergrund ist, dass das menschliche Auge zusammenhängende Regionen mit ähnlicher Textur und ähnlichem Grauwert kombiniert, um Objekte zu bilden. Kleine Objekte mit geringem Kontrast werden in hohen Auflösungen analysiert, während für die Untersuchung großer, kontrastreicher Objekte grobe Auflösungen ausreichen. Sind kleine und große Objekte, kontrastarme und -reiche Objekte gleichzeitig vorhanden, so ist es sinnvoll, sie in unterschiedlichen Auflösungen, respektive Maßstäben, zu untersuchen (GONZALEZ & WOODS 2002:350). Entsprechend ist es ratsam, ein Bild in unterschiedlichen Maßstäben zu segmentieren, zumal verschiedene Zielobjekte unterschiedlichen Betrachtungsmaßstäben zugrunde liegen, d. h. ein Baum wird mit kleinen Bildobjekten besser erfasst als ein großer Gebäudekomplex. Durch die Segmentierung eines Bildes mit verschiedenen Parametern in Objektlayer unterschiedlichen Levels entstehen zusätzliche Informationen, die aus der hierarchischen Beziehung zwischen Objekten, Subobjekten und Superobjekten abgeleitet werden können. Die Aggregation, die durch die Wahl eines höheren Levels erreicht wird, kann nicht durch eine einfache Verringerung der Auflösung erzielt werden. Diese würde lediglich zum Verlust wichtiger Informationen führen (BENZ et al. 2004:242).

Nachfolgend wird eine regionenbasierte *Region-Growing*-Technik näher erläutert, die es ermöglicht in verschiedenen Maßstabsebenen sinnvoll Objekte abzuleiten. Es handelt sich dabei um die in der Software eCognition und dem Nachfolgeprodukt Definiens Professional implementierte *Multiresolution Segmentation* (BAATZ & SCHÄPE

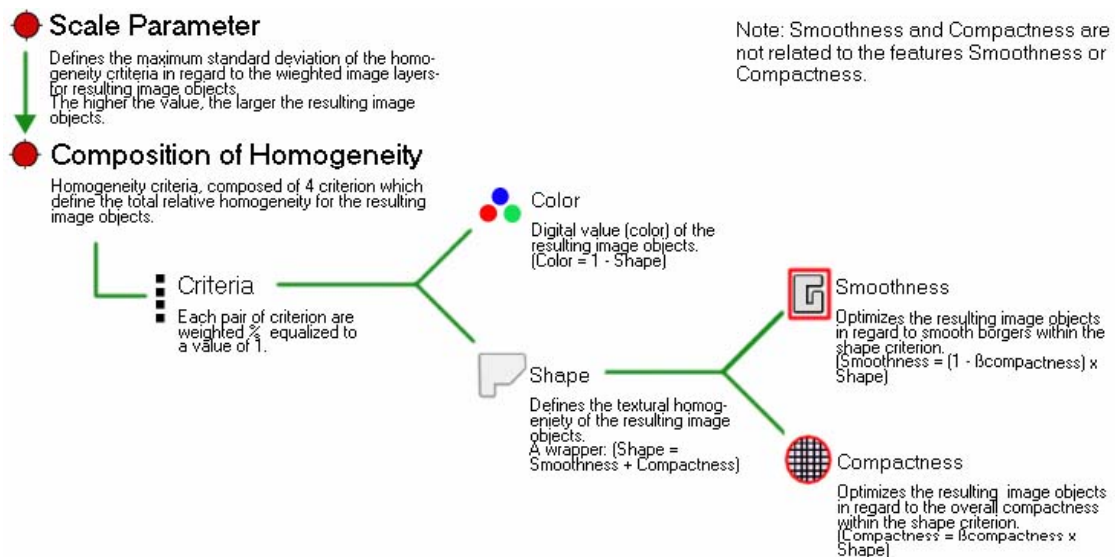


Abb. 2.15: Definition des Homogenitätskriteriums zur Segmentierung (Definiens AG 2006a:11).

2000). Bei dieser Methode wird die kleinstmögliche Heterogenität im gesamten Bild angestrebt (BURNETT & BLASCHKE 2003:245). Der Segmentierungsprozess startet auf der Basis von Ein-Pixel-Objekten, die in aufeinander folgenden Schritten paarweise zu immer größeren Bildobjekten zusammengefügt werden (BENZ et al. 2004:246, CARLEER et al. 2005:1286). Die Kombinationsregel wird durch lokale spektrale und räumliche Homogenitätskriterien bestimmt, die die Ähnlichkeit aneinandergrenzender Bildobjekte beschreiben (BAATZ & SCHÄPE 2000:15). Zwei Bildobjekte gelten dann als ähnlich, wenn sie in einem definierten Merkmalsraum nahe beieinander liegen (BURNETT & BLASCHKE 2003:245). Die Festlegung der Homogenitätskriterien geschieht auf Grundlage von vier wählbaren Parametern, die die spektrale Homogenität und die räumliche Komplexität optimieren: *Color*, *Shape*, *Smoothness* und *Compactness*. Durch die Modifizierung des *Shape*-Parameters wird dabei automatisch definiert, zu wie viel Prozent die spektrale Information des Layers zum gesamten Homogenitätskriterium beiträgt. Die spektrale Homogenität wird durch eine kanalabhängige gewichtete Standardabweichung bestimmt (BENZ et al. 2001:1914). Der *Shape*-Parameter ist seinerseits durch *Smoothness* und *Compactness* definiert (Definiens AG 2006a:11f.). Der *Smoothness*-Parameter gibt das Verhältnis der Objektkantenlänge zur Länge eines das Objekt begrenzenden Rechtecks an, der *Compactness*-Parameter ist das Verhältnis der Objektkantenlänge zur Pixelanzahl im Objekt (BENZ et al. 2001:1914). In Abb. 2.15 ist dargestellt, wie die einzelnen Parameter zur Definition des Homogenitätskriteriums miteinander in Verbindung stehen.

Durch das paarweise Zusammenfügen zu größeren Objekten steigt die durchschnittliche spektrale Heterogenität aller Bildobjekte. Der Segmentierungsalgorithmus zielt darauf ab, die Erhöhung der Heterogenität bei jeder neuen Objektbildung möglichst gering zu halten (BAATZ & SCHÄPE 2000:17, BURNETT & BLASCHKE 2003:245). BAATZ & SCHÄPE (2000:17) beschreiben den Grad der Zugehörigkeit (*Degree of Fitting*) zweier aneinandergrenzender Bildobjekte mit Hilfe der Veränderung der Heterogenität h_{diff} bei virtuellem Zusammenfügen der Bildobjekte:

$$h_{diff} = h_m - \frac{h_1 + h_2}{2} \quad (2.35).$$

Dabei entsprechen h_1 und h_2 der Heterogenität von Objekt 1 und 2, h_m ist die Heterogenität eines virtuell aus den Objekten 1 und 2 zusammengefügt Objekts. Es werden die aneinandergrenzenden Objekte zusammengefügt, deren Kombination die geringste Veränderung in der definierten Heterogenität bewirkt (BENZ et al. 2004:246). Übersteigt dieser Wert einen bestimmten Schwellenwert, den *Scale*-Parameter, wird der Prozess beendet. Der *Scale*-Parameter ist ein abstrakter Ausdruck, der die maximale Heterogenität des resultierenden Bildobjekts bestimmt. In heterogenen Daten sind die Objekte, die bei einem bestimmten *Scale*-Parameter abgeleitet werden, kleiner als in homogenen Daten (Definiens AG 2006a:10). Der Prozess simuliert das simultane Wachstum der Segmente, so dass etwa gleich große Bildobjekte entstehen (BENZ et al. 2004:246). Um verschiedene Objektlevel zu erreichen, wird ein Bild mehrmals segmentiert. Der *Scale*-Parameter wird hierbei jeweils erhöht. Auf Basis des niedrigeren Levels werden die Objekte entsprechend der festgelegten Homogenitätskriterien zu größeren Bildobjekten zusammengefügt. Die Gewichtung der einzelnen Parameter hängt vom gewünschten Ergebnis ab (THOMAS et al. 2003:967). Zwar existiert ein Zusammenhang zwischen der Objektgröße und dem vom Anwender wählbaren *Scale*-Parameter, der den Schwellenwert für das Homogenitätskriterium beschreibt, dennoch bedarf es teilweise zeitraubender Tests, ehe die passende Parameterkonfiguration für eine zufrieden stellende Segmentierung gefunden ist (FRAUMAN & WOLFF 2005). Ein großer Vorteil der *Multiresolution Segmentation* ist das breite Anwendungsspektrum, das auch die Bearbeitung von Radardaten einschließt (BAATZ & SCHÄPE 2000:9f.).

2.3.2.2 Evaluierung von Segmentierungen

Im Allgemeinen erreicht kein Segmentierungsverfahren die gewünschte Untergliederung der Szene – letztlich hängt es von der Wahl der Parameter ab, wie genau die Segmentierung erfolgt (CARLEER et al. 2005:1292). Vielmehr werden entweder zu viele und zu kleine Regionen abgeleitet (Übersegmentierung) oder zu wenige und zu große (Untersegmentierung) (SCHIEWE 2002:o. S.). Der Fall der Übersegmentierung stellt kein großes Problem dar, da benachbarte Segmente derselben Klasse nach der Klassifikation zusammengefügt werden können, sodass durch eine leichte Übersegmentierung sogar bessere Klassifikationsergebnisse zu erwarten sind (FRAUMAN & WOLFF 2005:o. S.). Durch eine zu starke Übersegmentierung gehen allerdings die Vorteile einer der Klassifizierung vorgeschalteten Segmentierung verloren (CARLEER et al. 2005:1288). Über- und Untersegmentierung können in Abhängigkeit der Heterogenität der Objekte auch nebeneinander auftreten und hängen von der Ausweisung des Zielobjekts, d. h. der Fragestellung und der damit verbundenen Generalisierung ab (SCHIEWE 2002:o. S.). Für bestimmte Anwendungen ist ein einzelner Baum von Interesse, für andere ein Wald. Da die Qualität objektbasierter Klassifikationen direkt von der Güte der Segmentierung abhängt, ist es notwendig, diese zu validieren (NEUBERT et al. 2006:o. S.). Deshalb

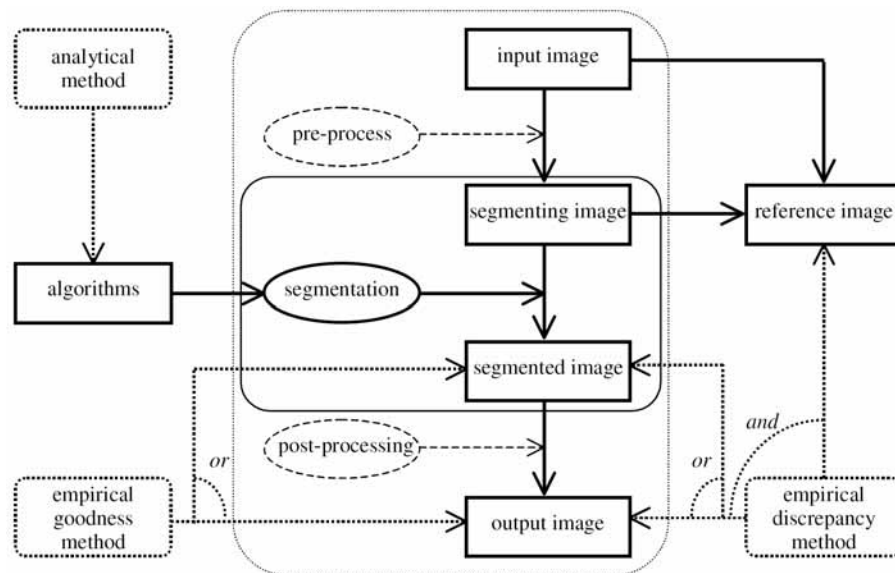


Abb. 2.16: Schema der Bildsegmentierung und der entsprechenden Evaluierung (ZHANG 1996:1336).

wurden zahlreiche Praktiken zur Evaluierung von Segmentierungen entwickelt, die in analytische und empirische Methoden gegliedert werden können (ZHANG 1996:1335). Mit analytischen Methoden werden die Segmentierungsalgorithmen direkt überprüft, indem deren Prinzipien und Besonderheiten analysiert werden (CARLEER et al. 2005:1287, ZHANG 1996:1335). Die empirischen Methoden untersuchen die Leistungsfähigkeit von Segmentierungsalgorithmen indirekt, indem diese auf Beispieldatensätze angewandt werden und anschließend die Resultate mit Referenzdaten verglichen (*Empirical Discrepancy Methods*) oder bestimmte Eigenschaften des segmentierten Bildes erhoben werden (*Empirical Goodness Methods*) (CARLEER et al. 2005:1287f., ZHANG 1996:1335). Somit verfolgen die analytischen Methoden das Ziel, Stärken und Schwächen eines Segmentierungsverfahrens auszumachen, während die empirischen Methoden mehr darauf abzielen, die Qualität des Segmentierungsergebnisses zu bewerten. In Abb. 2.16 ist schematisch dargestellt, an welcher Stelle die einzelnen Evaluationsverfahren zum Einsatz kommen. Ferner ist daraus ersichtlich, dass für die *Empirical Discrepancy Methods* Referenzsegmentierungen vorhanden sein müssen, die beispielsweise durch manuelle Bearbeitung des Ausgangsbildes entwickelt werden können. Zur Anwendung der *Empirical Goodness Methods*, d. h. empirische Methoden zur Bewertung der Segmentierungsgüte, sind keine Referenzdaten notwendig. Die Segmentierungsgüte wird dabei u. a. anhand der Gleichmäßigkeit innerhalb der einzelnen Regionen oder am Kontrast zwischen den Regionen gemessen. Die Homogenität (*Grey-Level Uniformity GU*) einer Region kann auf Grundlage der Varianz aller Pixel dieser Region berechnet werden (ZHANG 1996:1337):

$$GU = \sum_i \sum_{(x,y) \in R_i} \left[f(x,y) - \frac{1}{A_i} \sum_{(x,y) \in R_i} f(x,y) \right]^2 \quad (2.36).$$

Dabei ist R_i die i -te segmentierte Region eines Bildes $f(x,y)$ und A_i die Fläche von R_i . Die Maximierung von GU bedeutet, dass die Segmentierungsgüte steigt. Ebenso ist die

lokale Entropie ein Maß für die Homogenität innerhalb der Region (ZHANG 1996:1338). ZHANG, H. et al. (2004) nutzen ein weiterreichendes, auf Entropie basierendes Maß, um die Effektivität von Segmentierungsmethoden zu testen:

$$E = H_l(I) + H_r(I) \quad (2.37).$$

Die Herleitung der *Layout Entropy* $H_l(I)$ und der *Expected Region Entropy* $H_r(I)$ eines Bildes I findet sich in ZHANG, H. et al. (2004). Mit diesem Maß E können sowohl verschiedene Parameterkonfigurationen einer Methode als auch verschiedene Methoden untereinander verglichen werden (ZHANG, H. et al. 2004:38). Ein weiteres Maß, das keine Referenzdaten benötigt, ist die empirische Evaluierungsfunktion von BORSOTTI et al. (1998:744), die die Homogenität innerhalb der Segmente bewertet:

$$Q(I) = \frac{1}{10000 \times (N \times M)} \sqrt{R} \times \sum_{i=1}^R \left[\frac{e_i^2}{1 + \log A_i} + \left(\frac{R(A_i)}{A_i} \right)^2 \right] \quad (2.38).$$

In dieser Gleichung beschreibt $N \times M$ die Größe eines Bildes I , e_i ist der Farbfehler der Region i und $R(A)$ die Anzahl der Regionen der Größe A . Die exakte Herleitung findet sich in BORSOTTI et al. (1998). Davon ausgehend, dass eine Segmentierung den Kontrast zwischen Regionen erhöht, kann der Grauwertkontrast (*Grey-Level Contrast GC*) eines Bildes $f(x,y)$ mit einem Objekt, das den mittleren Grauwert f_0 hat, und dem Hintergrund, der den mittleren Grauwert f_b hat, berechnet werden (ZHANG 1996:1338):

$$GC = \frac{|f_0 - f_b|}{f_0 + f_b} \quad (2.39).$$

Die Maximierung von GC bedeutet eine steigende Segmentierungsgüte. Die *Empirical Discrepancy Methods* untersuchen die Abweichung des Segmentierungsergebnisses von einem als ideale Segmentierung vermuteten Referenzbild. Ein erstes Maß berechnet den Anteil falsch segmentierter Pixel. Adäquat zu einer Konfusionsmatrix wird einerseits der Anteil an Pixeln erfasst, der fälschlicherweise nicht segmentiert wurde (Gleichung 2.40), und andererseits der Anteil an Pixeln, die eigentlich zu anderen Segmenten gehören (Gleichung 2.41) (ZHANG 1996:1338f.):

$$M_I^{(k)} = \frac{\left[\left(\sum_{i=1}^N C_{ik} \right) - C_{kk} \right]}{\left(\sum_{i=1}^N C_{ik} \right)} \times 100 \quad (2.40)$$

$$M_{II}^{(k)} = \frac{\left[\left(\sum_{i=1}^N C_{ki} \right) - C_{kk} \right]}{\left[\left(\sum_{i=1}^N \sum_{j=1}^N C_{ij} \right) - \sum_{i=1}^N C_{ik} \right]} \times 100 \quad (2.41).$$

In einem Bild der Größe N ist dabei C_{ij} die Anzahl an Pixeln einer Klasse j , die als Klasse i segmentiert wurde. In Gleichung 2.40 gibt der Zähler die Anzahl an Pixeln einer Klasse k , die nicht als k klassifiziert wurde und der Nenner die Gesamtzahl an Pixeln der Klasse k an. In Gleichung 2.41 steht die Anzahl an Pixeln anderer Klassen, die als Klasse k erfasst wurden, im Zähler und die Gesamtzahl der Pixel der anderen Klassen im Nenner (ZHANG 1996:1338f.). Andere Algorithmen, wie der *Generalization Index GEN* (CARLEER et al. 2005), bilden ein Maß für die Unter- oder Übersegmentierung. *GEN* ist ein einfaches Ratio, nämlich das Verhältnis der Anzahl an Regionen im segmentierten Bild N_s und der Anzahl an Segmenten im Referenzbild N_{ref} (CARLEER et al. 2005:1288):

$$GEN = \frac{N_s}{N_{ref}} \quad (2.42).$$

Für $GEN < 1$ handelt es sich um eine Untersegmentierung, für $GEN > 1$ um eine Übersegmentierung. Ein anderes einfaches Maß, der *Area-Fit-Index AFI* (LUCIEER 2004:63), gibt an, inwieweit Segmente mit ausgewählten Referenzobjekten übereinstimmen:

$$AFI = \frac{A_{referenceobject} - A_{largestsegment}}{A_{referenceobject}} \quad (2.43).$$

Dabei ist A die Fläche in Pixeln. Das Bild gilt als übersegmentiert, wenn der *AFI* größer 0 ist, also die Überdeckung weniger als 100 % beträgt. Ist der *AFI* kleiner als 0, so ist das Bild untersegmentiert. Der *Fragmentation Index FRAG* nach STRASTERS & GERBRANDS (NEUBERT et al. 2006:o. S., ZHANG 1996:1340) indiziert ebenfalls, ob die Anzahl der Segmente mit der Anzahl an Regionen im Referenzbild übereinstimmt:

$$FRAG = \frac{1}{1 + p \times |T_N - A_N|^q} \quad (2.44).$$

Dabei ist T_N die Anzahl der Objekte im Referenzbild und A_N die Anzahl der Objekte im segmentierten Bild, p und q bezeichnen Skalierungsparameter. In NEUBERT et al. (2006) wurden zwanzig verschiedene, klar abgrenzbare Gebiete, die sich in Position, Form, Fläche, Textur, Kontrast, Landbedeckungstyp usw. unterscheiden, als Referenz ausgesucht und visuell und geometrisch mit den segmentierten Gegenständen verglichen. Zu den geometrischen Maßen gehören dabei Fläche A , Umfang P und *Shape Index SI* (NEUBERT et al. 2006:o. S.):

$$SI = \frac{P}{4\sqrt{A}} \quad (2.45).$$

Der *Shape Index* ist genau wie die *Circularity C* ein Maß, das die Übereinstimmung der Segmentform mit der Form der Referenzregionen vergleicht. Letztere berechnet sich aus Fläche A und Umfang P zu (YANG et al. 1995:762):

$$C = \frac{4\pi A}{P} \quad (2.46).$$

ZHANG (1996) gibt einen Überblick über Evaluierungsmöglichkeiten und kategorisiert diese. Aktuellere Zusammenfassungen finden sich in ZHANG, H. et al. (2004) und NEUBERT et al. (2006). Ergänzend sei die Arbeit von MÖLLER et al. (2007) genannt, in der mit dem *Comparison Index* ein Maß beschrieben ist, das die iterative Annäherung an eine optimale Segmentierung erlaubt. Trotz aller automatischer Methoden ist die Einschätzung durch den Nutzer ein wichtiges Instrument zur Bewertung der Segmentierungsqualität (BENZ et al. 2004:247, BAATZ & SCHÄPE 2000:15, SCHIEWE 2002:o. S.). Die quantitativen Maße sind nur dann überzeugend, wenn der visuelle Eindruck befriedigt wird (BAATZ & SCHÄPE 2000:15).

2.3.2.3 Objektbasierte Klassifizierung

Objektbasierte Klassifikationen zur Analyse hoch auflösender Daten finden bevorzugt Anwendung bei der Untersuchung urbaner Räume (z. B. BAUER & STEINNOCHER 2001, HEROLD et al. 2002b, HOFMANN et al. 2006, KUX & ARAÚJO 2006, STEINNOCHER et al. 2001, TAUBENBÖCK et al. 2006) und bei der Landschaftsanalyse in überwiegend kleinräumig zergliederten Landschaften (BURNETT & BLASCHKE 2003, KOCH et al. 2003, SEILER et al. 2004).

Häufig besteht der Klassifikationsprozess aus mehreren Teilprozessen, die bei Objekten unterschiedlicher Größe angewandt werden müssen, so dass bestimmte Informationen aus verschiedenen Levels extrahiert werden (BENZ et al. 2004:240). Dies wird durch ein hierarchisches Netzwerk von Bildobjekten ermöglicht, dessen Ableitung auf Basis einer *Multiresolution Segmentation* möglich ist. In Abb. 2.17 ist ein solches hierarchisches Netzwerk dargestellt, dessen Objekte in unterschiedlichen Maßstäben




Abb. 2.17: Abstrakte Darstellung eines hierarchischen Netzwerks von Bildobjekten. Unterster Level ist der Pixellevel, in dem jedes Objekt aus einem Pixel besteht (verändert nach BENZ et al. 2004:248).

abgeleitet wurden. Es ist ersichtlich, dass die Grenzen eines Objekts den Grenzen der Objekte des nächst niedrigeren Levels folgen. Die hierarchische Beziehung zwischen Objekten, Subobjekten und Superobjekten wird durch die blauen Linien versinnbildlicht. Die Beziehungen zwischen Levels und Kom-

binationen verschiedener Levels können für den Klassifikationsprozess genutzt werden (BENZ et al. 2004:248). Die im Rahmen dieser Arbeit genutzte Software Definiens Professional 5 bietet zwei Möglichkeiten zur objektbasierten Klassifikation: einerseits eine *Nearest-Neighbour*-Klassifikation, andererseits eine hierarchische Klassifikation

auf Basis von *fuzzy* Regeln (BENZ et al. 2001:1914). Das *Nearest-Neighbour*-Verfahren nutzt repräsentative Beispielobjekte, die für jede Klasse bestimmt werden müssen. Der Merkmalsraum, auf dessen Grundlage jedes Objekt einer Klasse zugeordnet wird, kann vom Nutzer definiert werden, so dass nur die gewünschten Eigenschaften berücksichtigt werden. Dazu kann zum einen für alle Klassen derselbe Merkmalsraum gewählt (*Standard Nearest Neighbor*) oder zum anderen für jede Klasse individuell ein Merkmalsraum festgelegt werden (*Nearest Neighbor*) (Definiens AG 2006b:117). Die *Fuzzy-Logic*-Klassifikation bietet die Möglichkeit, für jede Klasse individuell unterschiedliche Objektmerkmale auszuwählen und die entsprechenden Zugehörigkeitsfunktionen (*Membership Function*) zu definieren (Definiens 2006b:102). Die grundlegende Idee dabei ist, dass ein Merkmal eines Objekts nicht nur über vorhanden/ nicht vorhanden festgelegt wird, sondern dass es zwischen diesen Extrema einen kontinuierlichen Übergang gibt, so dass Zugehörigkeitsgrade ausgewiesen werden können, die durch die Zugehörigkeitsfunktionen genau definiert sind (BENZ et al. 2004:252). Aus dieser Klassenbeschreibung resultiert eine Klassenhierarchie, die die Basis für die Klassifikation bildet. Bei der Klassenzuordnung handelt es sich um eine relative Zuordnung mit Werten im Intervall $[0,1]$ mit $0 =$ nicht zugeordnet und $1 =$ voll zugeordnet. Die Zuordnungsfunktion ist gegeben mit $z(d) = e^{-d^2}$ (MITTELBERG 2001:40). Dabei ist die Distanz d zwischen dem Beispielobjekt s und dem zu klassifizierenden Objekt o im n -dimensionalen Merkmalsraum folgendermaßen definiert (MITTELBERG 2001:40):

$$d = \sqrt{\sum_f \left(\frac{v_f^{(s)} - v_f^{(o)}}{\sigma_f} \right)^2} \quad (2.47)$$

mit: f = Objektmerkmal (*Feature*)

$v_f^{(s)}$ = Wert des Testgebietes s für Merkmal f

$v_f^{(o)}$ = Wert des Bildobjektes o für Merkmal f

σ_f = Standardabweichung des Merkmals f für alle Bildobjekte.

Der eigentliche Klassifikationsschritt ist dann die Zuordnung eines Objekts zu genau einer bestimmten Klasse. Das Objekt wird der Klasse mit dem größten Zugehörigkeitsgrad zugewiesen, so dass jedes Objekt exakt einer Klasse zugeordnet wird (BENZ et al. 2004:254). Wird ein festlegbarer Schwellenwert für die Zugehörigkeit unterschritten, so wird das Bildobjekt keiner Klasse zugewiesen (Definiens 2006b:106).

In den letzten Jahren wurden diverse Techniken zur Segmentierung von Radardaten entwickelt (z. B. LIU et al. 2000, PELLIZZERI 2003, ZAART et al. 2002). Die darauf aufbauenden Klassifikationen berücksichtigen jedoch nicht in ausreichendem Maß die kontextuellen und semantischen Informationen zwischen einzelnen Objekten bzw. Sub- und Superobjekten. Demgegenüber können SAR-Daten mit objektbasierten Ansätzen auf Grundlage einer *Multiresolution Segmentation* erfolgreich klassifiziert werden (z. B. CORR et al. 2003, LINGENFELDER et al. 2006, MÜLLER 2001). Bei der Bildanalyse mit

Definiens Professional sind der Segmentierungs- und der Klassifikationsprozess zwei getrennte Arbeitsschritte, die beide mitunter sehr zeitaufwendig sein können und nur einen geringen Grad an Automatisierung aufweisen (SCHIEWE et al. 2001:38).

2.4 Urban Remote Sensing

Mitte des 21. Jahrhunderts werden rund zwei Drittel der Weltbevölkerung in Städten leben. Der weitaus größte Zuwachs ist in Entwicklungsländern zu erwarten (MAKTAV et al. 2005:655). Jedoch wächst nicht nur die Bevölkerung in Städten, sondern auch die Städte selbst wachsen und verändern sich ständig (YANG 2005:497, MILLER & SMALL 2003:129). Diese Veränderungen schaffen neue Probleme wie unkontrollierte Verstädterung oder den Verlust von Landwirtschaftsflächen und stellen neue Herausforderungen an Planungsbehörden und Verwaltungseinrichtungen (MAKTAV et al. 2005:655). Dazu gehören unter anderem die Planung der Infrastruktur und eine effiziente Politik sowie ein erfolgreiches Management von Ressourcen und Dienstleistungen. Das Aufeinandertreffen von rasantem Städtewachstum und Umweltveränderungen wird in Zukunft zu schwerwiegenden Umweltproblemen in Städten führen (MILLER & SMALL 2003:136). Im Kontext der raschen Urbanisierung besteht die Notwendigkeit, vielfältige Informationen über Ausmaß und räumliche Verteilung bestimmter städtischer Strukturen und urbaner Landbedeckungsklassen, Bevölkerungsverteilung und -wachstumsmuster sowie über Veränderungen physischer Parameter in kurzer Zeit zu gewinnen und permanent zu aktualisieren. Wissenschaftler und Entscheidungsträger gleichermaßen müssen alle zur Verfügung stehenden Mittel ausschöpfen, um Ursachen, Verlauf und Folgen von Prozessen und Dynamiken sowie Umweltveränderungen in urbanen Gebieten zu verstehen. Urbane Räume und die darin ablaufenden Prozesse sind die Hauptantriebskräfte von Landschaftsveränderungen in lokalen bis globalen Maßstäben (HEROLD & SCHMULLIUS 2005:o. S.).

2.4.1 Eigenschaften urbaner Räume und ihre Abgrenzung

Die begriffliche Abgrenzung von urban zu nicht-urban ist komplizierter als die Unterscheidung einzelner Landbedeckungsklassen innerhalb urbaner Räume (HEROLD 2004:100). Nach der Definition des U.S. Census Bureau (2002:o. S.) umfasst der Begriff urban alle Gebiete, Bewohner und Wohneinheiten, die innerhalb einer „*urbanized area*“ oder eines „*urban cluster*“ liegen. Deren Grenzen schließen dicht besiedelte Gebiete ein, die aus Kernbereichen mit einer Bevölkerungsdichte von mindestens 1.000 E/mi² und Randbereichen mit einer Bevölkerungsdichte von mindestens 500 E/mi² bestehen. Weniger dicht besiedelte Gebiete können unter Umständen Bestandteil von „*urbanized area*“ oder „*urban cluster*“ sein. Ländlich (*rural*) meint demgegenüber alle Gebiete, die außerhalb von „*urbanized area*“ oder „*urban cluster*“ liegen (U.S. Census Bureau 2002:o. S.). Diese Form der Abgrenzung urbaner Räume ist stark administrativ ausgerichtet. Das Fundamentale einer Stadt ist jedoch die Konzentration von Menschen mit spezifischen Lebensgewohnheiten in einem charakteristischen sozialen Gefüge (HARTSHORN 1992:3). Eine räumliche Grenze

zwischen einer Stadt und ihrem Umland nach sozialen, nicht-administrativen Kriterien festzulegen, ist wesentlich schwieriger, da es sich beim Übergang von urban zu nicht-urban um ein Kontinuum handelt (HARTSHORN 1992:3). Hier kommt die Möglichkeit zur Begrenzung urbaner Gebiete mittels Fernerkundungsdaten zum Tragen. Dabei spielen der Betrachtungsmaßstab und die Fragestellung eine wesentliche Rolle. Bislang wurden bei kleinmaßstäbigen Untersuchungen häufig Nachtaufnahmen genutzt. Diese sind jedoch streng genommen eher ein Maß für den nächtlichen Energieverbrauch in einer Region (JIN et al. 2005:1558). Um diese Schwäche zu umgehen, kombinierten SCHNEIDER et al. (2003) die grob auflösenden Nachtaufnahmen mit Bevölkerungsstatistiken und bereits existierenden Landbedeckungsprodukten und spezifizierten die Ergebnisse mit Modis-Daten. GREY & LUCKMAN (2003) nutzten ERS SAR-Daten zur interferometrischen Ableitung von urbanen Gebieten. Bei ausreichend großem zeitlichen Versatz und geringen *Baselines* konnten Genauigkeiten von mehr als 90 % erreicht werden (GREY & LUCKMAN 2003). JIN et al. (2005) nutzten vor dem Hintergrund stadtklimatologischer Untersuchungen den *Urban Index UI*, um urbane Gebiete zu charakterisieren. Dieser ist eine Kombination aus *Skin Temperature* T_{skin} und Albedo α (JIN et al. 2005: 1558):

$$UI_i = (1 - \alpha)T_{skin_i} \quad (2.48).$$

Für Stadtentwickler, Raumplaner und assoziierte Entscheidungsträger ist die Fragestellung eine andere, und somit ist auch die Abgrenzung des urbanen Raumes differenziert zu betrachten. Zur detaillierten Unterscheidung urbaner und nicht-urbaner Gebiete ist es notwendig, die Landnutzungs- und Landbedeckungsklassen klar zu definieren (HEROLD 2004:103). Urbane Oberflächen, also urbane Landbedeckungsklassen, sind häufig künstlich geschaffen und kommen in der Natur in dieser Art nicht vor. Die Ausweisung urbaner Landnutzungsklassen ist schwierig, da sie ein Gemenge sozialer, ökonomischer und natürlicher Faktoren sind und eher durch charakteristische Funktionalität als durch charakteristische Formen gekennzeichnet sind (BAUER & STEINNOCHER 2001:25). Dennoch ist auch im administrativen Interessenfeld die Unterscheidung urbaner Räume von ihrem Umland eine grundlegende Aufgabe, deren Lösung ebenso von Fernerkundlern angestrebt wird. Im Kontext der Fernerkundung sind urbane Räume durch eine hohe Heterogenität gekennzeichnet, die erst bei entsprechend hoher räumlicher Auflösung in unterscheidbare Bildobjekte aufgelöst wird. Dabei steigt jedoch auch die spektrale Variabilität zwischen verschiedenen Landbedeckungsklassen und innerhalb der einzelnen Objekte einer Klasse. Die daraus resultierenden technischen und methodischen Herausforderungen sind Thema des folgenden Kapitels. Allerdings sind es gerade die hohe Variabilität innerhalb der städtischen Klassen und das kleinräumige Nebeneinander unterschiedlichster Oberflächen, die urbanen Räumen spezielle Eigenschaften, wie eine ausgeprägte Textur, verleihen. Vor allem in hoch auflösenden Fernerkundungsdaten sind urbane Flächen durch reiche Textur gekennzeichnet. Textur ist die räumliche Variation von Grauwerten in einem Bild (KIEMA 2002:770). Der Texturreichtum in Siedlungsgebieten resultiert

bei SAR-Daten aus den verschiedenen geometrischen und dielektrischen Charakteristika der Einzelstreuer, während er bei optischen Daten ausnahmslos aus der Variabilität der Reflexionseigenschaften der einzelnen Oberflächen entstammt (THIEL et al. 2006b:o. S.). THIEL et al. (2006a, 2006b) zeigen, dass Siedlungsräume anhand von Texturmaßen bei entsprechend hoher Auflösung gut von ihrem Umland unterschieden und darüber hinaus die wichtigsten Landnutzungsklassen differenziert werden können. LORETTE et al. (2000) konnten mittels Texturmaßen bei Sensoren mittlerer Auflösung (SPOT und ERS 1) urbane Gebiete gut von nicht-urbanen trennen. Andere Studien nutzen neben Texturparametern den NDVI zur Erstellung von Siedlungsmasken (EHLERS et al. 2006). GOMEZ-CHOVA et al. (2006) erreichten durch den synergetischen Gebrauch von Landsat TM und ERS 2 SAR eine gute Abgrenzung urbaner Räume vom Umland.

Die Eigenschaften urbaner Räume sind skalenabhängig. Bei mittlerer Auflösung (z. B. Landsat mit 30 m) sind urbane Gebiete häufig nicht mehr als eine Agglomeration von Mischpixeln, bestehend aus einer jeweils individuellen Zusammensetzung unterschiedlicher Landbedeckungsklassen, die nur mit entsprechenden Techniken aufgelöst werden können (Kapitel 2.4.2.2). Homogene Flächen innerhalb der Siedlungsgebiete sind in dieser Auflösungsstufe praktisch nicht vorhanden. Bei erhöhter räumlicher Auflösung wird das enge Nebeneinander verschiedener Oberflächen, wie Grünflächen, Bäume, Hecken, Gebäude, Verkehrsflächen oder Gewässer besser aufgelöst. Allerdings erhöhen sich durch die unterschiedliche Orientierung einzelner Objekte, Belichtungseffekte, Schatten, Alter und Zustand der häufig künstlichen Oberflächen die spektrale Variabilität innerhalb einzelner Klassen (ROBERTS & HEROLD 2004). Urbane Flächen sind darüber hinaus in interferometrischen Radardaten durch eine hohe Kohärenz gekennzeichnet. Diese bleibt auch bei mehrere Jahre auseinander liegenden Aufnahmen hoch und bildet somit einen deutlichen Kontrast zu veränderlichen Oberflächen wie vegetationsbestandenen Gebieten, die aufgrund phänologischer Entwicklungen, unterschiedlicher Feuchteverhältnisse und Eigenbewegungen der Pflanzen bei entsprechend großem zeitlichen Versatz zwischen den Aufnahmen nur geringe Kohärenzen aufweisen (GREY & LUCKMAN 2003:957).

2.4.2 Technische und methodische Herausforderungen

Es besteht kein direkter Zusammenhang zwischen spektralem Signal und städtischer Landnutzung, so dass im Feld der urbanen Fernerkundung traditionelle Klassifikationsansätze häufig versagen (BAUER & STEINNOCHER 2001:25). Für Anwendungen in urbanen Räumen werden andere Datenquellen und Analysemethoden benötigt als für andere, natürliche Landoberflächen (HEROLD & SCHMULLIUS 2005:o. S.).

Die Oberflächen urbaner Räume sind vielfältiger und durch andere Eigenschaften charakterisiert als natürliche Oberflächen (BEN-DOR et al. 2001:2194, ROBERTS & HEROLD 2004:13, SMALL 2005:662). Die Herausforderung für die Fernerkundung liegt darin, dass urbane Räume aufgrund ihrer vielfältigen Erscheinungsformen äußerst heterogen sind und ein unregelmäßiges, kleinräumiges Mosaik an unterschiedlich großen, vielfältigen Oberflächen bilden, die zudem in ihrer Beschaffenheit stark

variieren (ROBERTS & HEROLD 2004). Folglich ist die Wahl geeigneter Sensoren und der räumlichen Auflösung besonders anspruchsvoll. Da je nach Fragestellung und Erscheinungsform des Untersuchungsgebiets unterschiedliche Sensoren sowie verschiedene Auflösungen zu einem optimalen Ergebnis beitragen, ist es ebenso wichtig, das Potential der vielfältigen zur Verfügung stehenden Daten durch optimierte Fusionsverfahren und den Fragestellungen angepasste Analysemethoden auszuschöpfen.

2.4.2.1 Wahl geeigneter Sensoren

In urbanen Räumen ist die Streubreite an unterschiedlich großen Objekten besonders ausgeprägt. Grundsätzlich sollte die räumliche Auflösung des Sensors halb so groß wie der Durchmesser des kleinsten zu analysierenden Objekts sein (JENSEN & COWEN 1999:614). Eine einzige räumliche Auflösung reicht jedoch oft nicht aus, um die Vielzahl unterschiedlicher Landbedeckungsklassen in urbanen Räumen zu erfassen (ATKINSON & APLIN 2004:3695ff.). Darüber hinaus existiert kein Sensor, der alle Informationen erfasst, die einen urbanen Raum charakterisieren (GAMBA et al. 2005:319), weil die relevanten Eigenschaften urbaner Oberflächen zu komplex und zudem skalenabhängig sind (SMALL 2005:662). Die Wahl des Sensors und der optimalen räumlichen Auflösung zur Untersuchung urbaner Räume ist daher sehr schwierig und hängt unter anderem vom Anwendungsziel ab. Zur Unterscheidung urbaner Räume von nicht-urbanen genügen Sensoren mit mittlerer räumlicher Auflösung (JENSEN & COWEN 1999:615), wie z. B. die Sensoren der Landsat-Satelliten, SPOT oder ASTER. Landsat und SPOT liefern seit einigen Jahrzehnten Daten über urbane Räume und sind somit für Veränderungsanalysen hervorragend geeignet. Allerdings haben diese beiden Systeme genau wie auch ASTER eine zu geringe räumliche Auflösung für detaillierte Analysen urbaner Räume (MILLER & SMALL 2003:132). Zur Unterscheidung urbaner Oberflächen sollte die räumliche Auflösung mindestens 5 m betragen (JENSEN & COWEN 1999:612ff., STEINNOCHER et al. 2001:147). Multispektral- und Lidardaten benötigen feine räumliche Auflösungen, um die besten Ergebnisse zu erreichen, während sich die räumliche Auflösung von Hyperspektraldaten geringer auf die Analyseergebnisse auswirkt (HEROLD & ROBERTS 2006:10). DELL'ACQUA et al. (2005) konstatieren, dass im Kontext der Analyse urbaner Räume eine hohe spektrale Auflösung wertvoller ist als eine hohe räumliche Auflösung, da viele Oberflächen aufgrund ihrer ähnlichen chemischen Zusammensetzung nur bei entsprechend hoher spektraler Auflösung zu unterscheiden sind. Die gegenwärtig existierenden räumlich hoch auflösenden Multispektralsensoren (z. B. Ikonos, QuickBird) können aufgrund der Lage ihrer nur wenigen und zudem spektral grob auflösenden Kanäle die komplexen Eigenschaften urbaner Oberflächen nur bedingt auflösen (HEROLD et al. 2003a:1907, HEROLD & ROBERTS 2006:2). Die Arbeit von HEROLD et al. (2003a) zeigt, dass auch bei hoher räumlicher Auflösung der Multispektraldaten durch eine Erhöhung der spektralen Auflösung die Klassifikation urbaner Räume verbessert werden kann. Jedoch ist die Erfassung und Klassifizierung urbaner Oberflächen selbst bei der Verwendung von Hyperspektraldaten limitiert. Aufgrund von Zustand, Alter,

Geometrie und Exposition bestimmter Oberflächen, wie z. B. Dächer, ist die Variabilität innerhalb der Klassen so groß, dass es Überschneidungen mit den spektralen Eigenschaften anderer Oberflächen gibt und die Klassifikationsgenauigkeit eher gering ist (HEROLD et al. 2003a:1918). Zahlreiche Arbeiten in der jüngeren Vergangenheit zeigen, dass die Verwendung hyperspektraler Daten in urbanen Räumen der Auswertung herkömmlicher Multispektraldaten überlegen ist (BEN-DOR et al. 2001, HEROLD et al. 2003a, HEROLD et al. 2004a, HEROLD & ROBERTS 2006). Einschränkend muss jedoch erwähnt werden, dass die genannten Untersuchungen auf pixelbasierten Ansätzen beruhen und die für die Auswertung hoch auflösender optischer Daten besser geeigneten segmentbasierten Verfahren (BLASCHKE & STROBL 2001:15f.) nicht angewandt wurden.

Speziell für *Monitoring*-Aufgaben sind Satellitendaten hervorragend geeignet, weil sie in regelmäßigen Abständen aktuelle Informationen liefern. Gerade in sich schnell entwickelnden städtischen Regionen ist die regelmäßige Datenverfügbarkeit von großer Bedeutung. Für optische Daten ist jedoch die potenzielle Einschränkung durch Wolkenbedeckung zu beachten. NICHOL & LEE (2005:916f.) schlagen vor, zukünftig für urbane Fragestellungen hoch auflösende Satellitendaten anstelle von Luftbildern zu nutzen, da sie nicht zuletzt kostengünstiger sind. Dennoch muss erwähnt werden, dass Luftbilder immer noch elementar sind für die Anwendung in stadökologischen und stadtplanerischen Fragestellungen.

Im weiten Feld der Fernerkundung urbaner Räume können je nach expliziter Fragestellung alle Arten von Sensoren in nahezu allen Auflösungen sinnvoll Einsatz finden. Da die einzelnen Objekte unterschiedlich groß, verschieden geformt und räumlich differenziert angeordnet sind, gibt es keine räumliche Auflösung, in der alle Objekte optimal dargestellt werden (HAY et al. 1997:14). Stattdessen existieren für alle Objekte jeweils individuell optimale räumliche Auflösungen, denen nur durch multi-skalige Ansätze Rechnung getragen werden kann (ATKINSON & APLIN 2004:3698, HAY et al. 1997:14). Insbesondere zu einer Zeit als Satellitendaten auf geringe und mittlere Auflösungen beschränkt waren, musste bei nur einer räumlichen Auflösung gegebenenfalls für verschiedene Landbedeckungs- oder Landnutzungsklassen individuell die ideale Methode gefunden werden (WOODCOCK & STRAHLER 1987:312). Die Idee der Bildanalyse in verschiedenen Auflösungsstufen ist durch die Möglichkeit der *Multiresolution Segmentation* in Definiens Professional berücksichtigt.

2.4.2.2 Adäquate Bildanalysetechniken

Die Vielfalt und kleinräumige Anordnung von Landbedeckungsklassen innerhalb urbaner Gebiete erschwert die Anwendung traditioneller Klassifikationsmethoden. GAO & SKILLCORN (1998) klassifizierten SPOT-Daten im städtisch-ländlichen Übergangsbereich. Die Klassifikationsgenauigkeit bei Anwendung des pixelbasierten *Maximum-Likelihood*-Verfahrens war durch die mangelnde spektrale Homogenität der Landbedeckungsklassen begrenzt (GAO & SKILLCORN 1998:2890). Wie bereits in Kapitel 2.3.1 beschrieben, bewirkt die Anwendung höher auflösender Sensoren keine unmittelbare Erhöhung der Klassifikationsgenauigkeit. Vielmehr steigt die spektrale Vielfalt derart,

dass nicht mehr von spektral homogenen Klassen ausgegangen werden kann und die spektrale Überschneidung zwischen den einzelnen Landbedeckungsklassen nur durch die Berücksichtigung von Struktur- und Kontextinformationen kompensiert werden kann. Dies kann beispielsweise durch objektbasierte Klassifikationsverfahren geschehen (Kapitel 2.3.2).

Strukturinformationen können jedoch bereits durch die Anwendung von Texturparametern Beachtung finden. In einigen Arbeiten wurden Satellitenbilder nur auf Basis der Textur eines panchromatischen Kanals erfolgreich klassifiziert (z. B. ZHANG et al. 2003). Im Normalfall bringt die Berücksichtigung von Textur deutliche Verbesserungen bei Klassifikationen oder Segmentierungen, im schlechtesten Fall bewirkt sie gar keine Veränderung (RYHERD & WOODCOCK 1996:191). PUISSANT et al. (2005) konnten in hoch auflösenden Satellitenbildern bei Anwendung einer pixelbasierten Methode durch die Berücksichtigung von Textur die Klassifikationsgenauigkeit erhöhen und zudem die Schattenbereiche erheblich reduzieren. Die größten Verbesserungen durch die Textur werden jedoch bei Sensoren mittlerer Auflösung erreicht. Beispiele dafür finden sich in den Arbeiten von KIEMA 2002 und SHABAN & DIKSHIT (2001, 2002). Eine ausführliche Beschreibung der bekanntesten Texturmaße bieten HARALICK et al. (1973), HARALICK & SHANMUGAM (1974), IRONS & PETERSEN (1981) oder ZHANG et al. (2003).

Noch stärkere Beachtung finden Strukturinformationen durch die Anwendung von Raum- oder Landschaftsmaßen (*Spatial Metrics* oder *Landscape Metrics*). Landschaftsmaße haben ihren Ursprung in der Ökologie (HEROLD et al. 2005:371). Sie quantifizieren die räumlichen Verteilungsmuster bestimmter Landbedeckungsklassen auf Basis thematischer Karten oder klassifizierter Fernerkundungsdaten (HEROLD et al. 2002b:o. S.). Dadurch können aus Landbedeckungsdaten Landnutzungsinformationen gewonnen werden, die für viele sozialgeographische, sozioökonomische, stadtplanerische und stadtökologische Fragestellungen von Bedeutung sind (HEROLD et al. 2005:370ff.). Detaillierte Beschreibungen von Landschaftsmaßen geben HEROLD (2004), HEROLD & MENZ (2000), HEROLD et al. (2003c). Beispiele für deren Anwendung finden sich bei BARNESLEY & BARR (1996), die durch die Berücksichtigung der räumlichen Anordnung verschiedener Landbedeckungsklassen erfolgreich die Landnutzung ableiten konnten, sowie bei HEROLD et al. (2002b, 2003c, 2005) und NETZBAND & STEFANOV (2003).

Eine viel versprechende Technik, um die häufig sehr feinen Unterschiede zwischen Landbedeckungsklassen zu erfassen, ist *Imaging Spectroscopy*, das heißt die abbildende Spektrometrie oder, vereinfacht ausgedrückt, die Anwendung von Hyperspektraldaten (BEN-DOR et al. 2001:2193). HEROLD et al. (2003) haben gezeigt, dass die spezifischen Eigenschaften urbaner Oberflächen nur durch eine sehr feine spektrale Auflösung aufgelöst werden können sowie durch Informationen aus dem kurzwelligen Infrarot. Selbst bei der Anwendung von Hyperspektraldaten ist die Klassifikationsgenauigkeit mit herkömmlichen Methoden als eher schlecht einzustufen (HEROLD et al. 2003:1918). Da die gegenwärtig existierenden, räumlich hoch auflösenden, optischen Sensoren Ikonos

und QuickBird nur vier breite Kanäle im sichtbaren bzw. nahinfraroten Bereich haben, ist vor allem in der Weiterentwicklung objektbasierter Techniken enormes Potential zur Verbesserung der Analyse städtischer Strukturen zu erwarten. Sensoren mit besserer spektraler Auflösung arbeiten bislang nur mit geringerer räumlicher Auflösung. Beispiele von *Imaging Spectroscopy* zur Ableitung von *Spectral Libraries* finden sich in BEN-DOR et al. (2001), HEROLD et al. (2003a) und ROBERTS & HEROLD (2004).

Da die räumliche Auflösung hoch auflösender Sensoren etwa der Größe der meisten Objekte in urbanen Räumen entspricht, versprechen für derartige Daten weiche Klassifikationsansätze die besten Ergebnisse (ATKINSON & APLIN 2004:3699). Gegenüber den harten Klassifikationsansätzen, die entsprechend festgelegter Schwellenwerte Pixel für Pixel einer Klasse zuordnen, können mit weichen Ansätzen innerhalb eines Pixels verschiedene Klassen erkannt werden (RASHED et al. 2005:701f.). Dies ermöglicht im Rahmen von *Change-Detection*-Analysen auch die Bestimmung des Ausmaßes von Veränderungen innerhalb eines Pixels (z. B. BAUER et al. 2004, YANG et al. 2003b). Weiche Klassifikationsansätze sind insbesondere bei großem Mischpixelanteil vorzuziehen (ATKINSON & APLIN 2004:3689), während bei großen, homogenen Flächen harte Klassifikationsansätze geeignet sind. Zu den weichen Klassifikationsverfahren zählt u. a. das *Spectral Unmixing* oder auch *Spectral Mixture Analysis* (SMA). Dabei wird die spektrale Signatur eines einzelnen Pixels als Kombination spektral reiner Klassen, so genannter *Endmember*, gesehen (ROBERTS et al. 1998:269, SMALL 2001:1308). Für die meisten Anwendungen wird von einer linearen Kombination ausgegangen (z. B. LU & WENG 2006, PHINN et al. 2002, RASHED et al. 2005, SMALL 2001, WU & MURRAY 2003). Das bedeutet, dass sich die Reflektanz je nach Flächenanteil der einzelnen *Endmember* linear verändert (PHINN et al. 2002:4136, SMALL & LU 2006). Die SMA umfasst die Berechnung der Flächenanteile der berücksichtigten Klassen (*Endmember*) innerhalb eines Pixels (ROBERTS et al. 1998:269, SMALL 2001:1309). Die *Endmember* können direkt aus spektral reinen Pixeln aus dem Bild abgeleitet werden oder auf Basis von *Spectral Libraries* bzw. im Feld ermittelten Referenzspektren festgelegt werden (ROBERTS et al. 1998:279). Es ist sogar möglich, *Endmember* in hoch auflösenden Daten zu suchen und in gröber auflösenden Sensoren mit ähnlicher spektraler Abdeckung anzuwenden (z. B. Ikonos und Landsat) (SONG 2004). Auf Basis von *Spectral-Unmixing*-Analysen können Satellitendaten der Landsat-Sensoren erfolgreich zur Kartierung von Städten genutzt werden (z. B. RASHED et al. 2005, SMALL 2005). Darüber hinaus werden mit dieser Technik Vegetationsbedeckung und/ oder Versiegelungsgrad im Subpixelbereich erfasst (z. B. SMALL & LU 2006, WU & MURRAY 2003). Derartige Klassifikationsansätze sind vor allem bei mittlerer Auflösung sinnvoll, können aber auch für hoch auflösende Sensoren angewandt werden (SMALL 2003). Um für stadtoökologische Fragestellungen urbane Gebiete vergleichbar charakterisieren zu können, entwickelte RIDD (1995) ein biophysikalisches Modell. Es zeichnet urbane Räume als Komposition aus Vegetation, versiegelter Oberfläche und Boden (RIDD 1995:2168). Jedoch repräsentiert das Modell keine unmittelbaren Reflexionseigenschaften und ist daher häufig nicht ohne weiteres auf Fernerkundungsdaten anwendbar (SMALL & LU

2006). Zur spektralen Charakterisierung ist ein Modell mit den drei *Endmembers* Substrat, Vegetation und Dunkle Oberflächen global anwendbar (SMALL 2004).

Die Verwendung von Lidar ist ein Ansatz, um die spektralen Überschneidungen zwischen Oberflächen zu entwirren (HEROLD & ROBERTS 2006:2). Durch die Verwendung von Laser-Altimeter-Daten findet die dritte Dimension Berücksichtigung. Lidarsysteme senden Laserstrahlen, häufig im nahinfraroten Bereich, und messen die Entfernung von Zielen am Boden zum Sensor auf Basis der Laufzeiten (LILLESAND et al. 2004:725ff.). Aus den dreidimensionalen Punkten kann ein digitales Oberflächenmodell (DOM, engl. *Digital Surface Model* DSM) gebildet werden. Die Differenz aus diesem DOM und dem digitalen Geländemodell (DGM, engl. *Digital Terrain Model* DTM) erzeugt ein normalisiertes DOM, das als zusätzlicher Kanal die Klassifikation urbaner Räume verbessert (HAALA & BRENNER 1999:131). Auf diese Weise können vor allem dreidimensionale Oberflächenstrukturen von Gebäuden und Vegetation erfasst werden (HEROLD & ROBERTS 2006:4). DOMs können auch aus den Daten flugzeuggetragener Stereokameras (EHLERS 2005a:o. S.) oder interferometrischer SAR-Systeme (GAMBA et al. 2005:321) gewonnen werden. Das Beispiel von HEROLD & ROBERTS (2006) belegt, dass die Kombination von räumlich hoch auflösenden Multispektraldaten mit dreidimensionalen Daten die Klassifikationsgenauigkeit deutlich verbessert. Die besten Ergebnisse wurden jedoch bei der Kombination von ebenfalls räumlich hoch auflösenden Hyperspektraldaten mit Lidardaten erreicht. Andere Arbeiten (z.B. KAMAGATA et al. 2005) zeigen, dass die Klassifikation von räumlich hoch auflösenden Daten mit Hilfe segmentbasierter Ansätze bessere Resultate verspricht als die von HEROLD & ROBERTS (2006) genutzten pixelbasierten Klassifikationsalgorithmen. Die Möglichkeit der dreidimensionalen Charakterisierung von Räumen durch Fernerkundungsdaten erlaubt unter anderem die Erstellung von 3D-Stadtmodellen (HAALA & BRENNER 1999, SCHIEWE & EHLERS 2005), die beispielsweise zur Modellierung von Luftströmungen in Städten (RATTI et al. 2006) oder zur Untersuchung von Verkehrslärm verwendet werden können (MAKTAV et al. 2005:658), birgt aber auch neue Probleme bei der Analyse der Daten (SCHIEWE & EHLERS 2005:683ff.).

2.4.2.3 Entwicklungen im Bereich der Datenfusion

Da eine Vielzahl unterschiedlicher Sensoren – panchromatisch, multispektral, hyperspektral, Radar, Lidar – mit verschiedenen räumlichen Auflösungen zur Verfügung steht, kann das Potential der Fernerkundung nur durch geeignete Verfahren der Bildfusion ausgeschöpft werden (GAMBA et al. 2005). Wie bereits erläutert, reicht die Verwendung von Daten lediglich eines Sensors für viele Anwendungen im urbanen Bereich nicht aus. In Kapitel 2.2 wurden die wichtigsten traditionellen Bildfusionsmethoden, wie IHS, PCA oder die arithmetischen Techniken, und eine Auswahl neuerer Verfahren, wie Wavelets, Ehlers Fusion und AIF-Methode, vorgestellt. Insbesondere auf dem Gebiet der Wavelets wird derzeit an Erweiterungen und Verbesserungen gearbeitet (z. B. CHIBANI 2006, GARZELLI & NENCINI 2005, LEWIS et al. 2007, SHI et al. 2005, ZHANG & HONG 2005). Jedoch gibt es vor allem im Bereich des *Feature* und des *Decision Level*

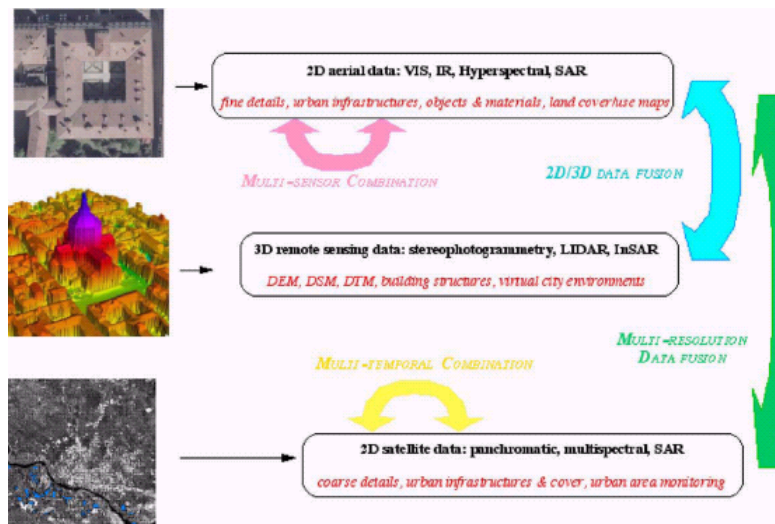


Abb. 2.18: Datenfusion im Kontext urbaner Räume (GAMBA et al. 2005:320).

noch Entwicklungsbedarf. GAMBA et al. (2005:324) sehen in der Datenfusion auf verschiedenen Levels eine der Schlüsseltechniken in der Fernerkundung urbaner Räume. Abb. 2.18 veranschaulicht, welche verschiedenen Fernerkundungsdaten zur Verfügung stehen, welche Informationen daraus primär zu gewinnen sind

und in welchen Dimensionen die Fusion dieser Daten erfolgen kann. Dazu gehören multisensorale, multitemporale, multiskalige und multidimensionale (2D-3D) Fusionen.

2.4.3 Potentiale und Grenzen

Die angewandte Fernerkundung ist als Teilgebiet der Geographie ebenso auf der Schnittstelle zwischen Natur- und Sozialwissenschaften verankert und hat somit das Potential, einen erheblichen Beitrag zum besseren Verständnis urbaner Räume zu leisten und zu einem verbesserten Management beizutragen. Deshalb ermöglicht die Fernerkundung das Zusammenführen räumlicher Muster und der dafür verantwortlichen sozialen, ökonomischen, kulturellen und politischen Faktoren (LONGLEY 2002:237). Darauf aufbauend können Städte hinsichtlich funktionaler und sozialer Zusammenhänge besser verglichen werden. Derzeit sind speziell in den Industrieländern Daten über urbane Räume oft einfacher und billiger bei Behörden oder anderen Institutionen zu erlangen als durch Fernerkundung (MILLER & SMALL 2003:134). In Entwicklungsländern hingegen ist die behördliche Datenlage lückenhaft und die Erfassung von Veränderungen in urbanen Räumen mittels herkömmlicher Methoden hält häufig nicht mit der rasanten Veränderung Schritt. Hier bietet Fernerkundung zwar ein gutes Instrument zur Detektion und zur Aktualisierung bestehender Informationen, allerdings fehlen häufig die entsprechenden Institutionen und Bemühungen, um die Informationen effektiv zu nutzen und in politische Entscheidungen bzw. Managementmaßnahmen einfließen zu lassen (MILLER & SMALL 2003:134). Darüber hinaus laufen die Veränderungen in vielen traditionell strukturierten Siedlungsräumen der Entwicklungsländer weniger organisiert und dokumentiert ab, so dass hier die in den entwickelten Ländern üblichen Praktiken nur bedingt anwendbar sind (NKAMBWE 1991).

Die Stärke der Fernerkundung liegt vor allem in der Erfassung räumlicher Informationen, die dazu genutzt werden können, Zustände und Eigenschaften urbaner Räume zu bestimmten Zeitpunkten zu charakterisieren und die Veränderung dieser Zustände über die Zeit zu quantifizieren (MILLER & SMALL 2003:134). Für die Erfassung einiger

Informationen, wie z. B. Oberflächentemperaturen, ist die Fernerkundung den *In-situ*-Messungen überlegen, da diese nur punktuell vorgenommen werden können, während Fernerkundungssensoren flächenhafte Daten liefern. Die Fernerkundung urbaner Räume ist somit insbesondere aufgrund der stetigen Entwicklung immer besserer Sensoren zunehmend im Blickfeld aktueller Forschung. Ihre Stärke liegt nicht zuletzt in der Vielzahl der verfügbaren Daten und der zeitlichen Dichte ihrer Erhältlichkeit. Es existiert eine Reihe globaler Fernerkundungsprodukte, die urbane Räume umfassen. Sie sind gerade in wenig entwickelten Ländern häufig die einzige Informationsquelle (TATEM et al. 2005:96). Allerdings ist die Anwendbarkeit derartiger globaler Produkte für nationale oder gar lokale Fragestellungen stark limitiert (TATEM et al. 2005).

Um den Anforderungen rezenter und zukünftiger Entwicklungen gerecht zu werden und alle sich bietenden Potentiale auszuschöpfen, ist es essentiell, bereits vorhandenes Wissen sowie am Boden erhobene Daten und Fernerkundungsdaten zu integrieren und in leicht zugängliche Informationssysteme zu implementieren (MAKTAV et al. 2005:658). MARTINUZZI et al. (2007) zeigten am Beispiel Puerto Ricos, wie moderne geographische Technologien und Zensusdaten integriert werden können, um Landnutzung und Landentwicklung zu analysieren. Die für Entwicklungsländer typische ineffektive bzw. nicht existente Raumplanung ist eine der Hauptursachen für teilweise unkontrollierte Verstädterungen, die mit gravierenden Landbedeckungs- und Landnutzungsänderungen (MARTINUZZI et al. 2007:288f.) sowie sozialen, ökologischen und kulturellen Veränderungen einhergehen.

Die Grenzen der Fernerkundung urbaner Räume sind häufig durch den Kompromiss zwischen den verschiedenen Auflösungsdimensionen (räumlich, zeitlich, radiometrisch, spektral) bestimmt. Zudem muss weiterhin an der Optimierung bestehender Analysemethoden und Bildfusionsverfahren sowie an der Entwicklung neuer Strategien gearbeitet werden. Wie bereits mehrfach angedeutet, bieten neue Sensoren eine Reihe neuartiger Anwendungsmöglichkeiten – nicht selten mit bislang unbekanntem Detailreichtum –, aus denen für die Fernerkundung jedoch gleichzeitig neue Probleme erwachsen. Deswegen ist es unerlässlich, bestehende Daten und Produkte sowie vorhandenes Fachwissen zu vernetzen und potentiellen Anwendern zugänglich zu machen.

2.4.4 Anwendungsgebiete

Die Fernerkundung ist ein hilfreiches Werkzeug für viele Fragestellungen in urbanen Räumen. Im Folgenden werden die wichtigsten Anwendungen vorgestellt. Eine der grundlegendsten Leistungen liegt in der Abgrenzung urbaner Räume (Kapitel 2.4.1). Die jüngste Sensorgeneration erlaubt allerdings wesentlich detailliertere Analysen städtischer Räume. So ist das Ziel vieler Arbeiten eine ausdifferenzierte Landbedeckungsklassifikation, aus der dann gegebenenfalls Landnutzungsklassen abgeleitet werden können (z. B. BAUER & STEINNOCHER 2001, HEROLD et al. 2002b, 2003c, MARTINUZZI et al. 2007). Nicht selten streben die Anwender die Ableitung sozialgeographischer und sozioökonomischer Parameter an. Dazu zählen die Abschätzung der Bevölkerungsdichte (WU & MURRAY 2005, WU et al. 2005), die Erfassung von

Energieverbrauch (WELCH 1980) oder die Bewertung von Lebensqualität (LO & FABER 1997). Der übergeordnete Zweck vieler Untersuchungen ist eine verbesserte Stadtplanung, um ein zielgerichtetes Management städtischer Ressourcen betreiben zu können. Da Fernerkundung maßgeblich zu einem besseren Verständnis von Stadtentwicklungsprozessen beiträgt, liegt es nahe, dass sie mit bestehenden Theorien und Stadtentwicklungskonzepten in Verbindung gesetzt und dazu genutzt wird, diese zu verifizieren und gegebenenfalls zu erweitern (z. B. DIETZEL et al. 2005, LO 2004).

2.4.4.1 Stadtökologie

Analyse städtischer Vegetation

Fernerkundung bietet zahlreiche Möglichkeiten zur Erfassung und Analyse urbaner Vegetation (WARD & JOHNSON 2007:17ff.). Die Anwendungen reichen von der Quantifizierung urbaner Vegetation (HAALA & BRENNER 1999, NICHOL & LEE 2005, SMALL 2001, SMALL & LU 2006, SONG 2005) über deren Differenzierung und die Erfassung einzelner Bäume (OUMA et al. 2006) bis hin zu weiterreichenden Ableitungen, wie z. B. das Kohlenstoffspeichervermögen urbaner Wälder (MYEONG et al. 2006). Das Kartieren und Quantifizieren von Vegetation in urbanen Gebieten ist aufgrund der fleckenartigen, unregelmäßigen Verteilung kompliziert. NICHOL & LEE (2005) quantifizierten Vegetationsbedeckung und -dichte anhand hoch auflösender Ikonos-Bilder und nutzten dazu den Chlorophyllindex (KANEMASU 1974) und den *Normalized Difference Vegetation Index* (NDVI) (TUCKER 1979). Der Chlorophyllindex bezeichnet den Quotienten aus grünem und rotem Kanal und wird daher auch Grün-Rot-Verhältnis genannt (NICHOL & LEE 2005:904). Der NDVI ist ebenfalls ein Ratio, das häufig genutzt wird, um Vegetation von vegetationsfreien Landbedeckungsklassen zu unterscheiden. Er berechnet sich folgendermaßen (MYEONG et al. 2001:245):

$$\text{NDVI} = \frac{(\text{nahes IR Band} - \text{rotes Band})}{(\text{nahes IR Band} + \text{rotes Band})} \quad (2.49).$$

Der Wertebereich für den NDVI liegt zwischen -1 und 1 , höhere NDVI-Werte implizieren gewöhnlich höhere Vegetationsanteile in einem Pixel (YUAN & BAUER 2007:376). Darüber hinaus ist der NDVI ein Maß für die Vitalität von Vegetation. Grundlage sind die hohe Absorption grüner Vegetation im roten Kanal und starke Reflexion im nahinfraroten Kanal (MYEONG et al. 2001:245). Durch die Ratiobildung werden Beleuchtungsunterschiede und Geländeeinflüsse weitgehend ausgeglichen (ALBERTZ 2001:219). MYEONG et al. (2006) bestimmten anhand multitemporaler Landsat-Satellitenbilder eine Regressionsgleichung, um aus dem NDVI das Kohlenstoffspeichervermögen städtischer Wälder abzuleiten. Derartige Analysen tragen zum besseren Verständnis der Rolle städtischer Wälder im Kohlenstoffkreislauf bei und erweitern Stadtplanung um einen stadtklimatologischen Parameter (MYEONG et al. 2006:277). Eine vielfach angewandte Technik zur Erfassung und Beobachtung von Vegetation bzw. deren Veränderungen in urbanen Räumen ist *Spectral Unmixing* (SMALL 2001, SMALL & LU 2006, SONG 2005).

Analyse versiegelter Flächen

Eine Anwendung, die häufig parallel zur Bestimmung von Vegetationsvorkommen abläuft, ist die Analyse von Versiegelungsanteilen. In einigen Arbeiten (z. B. BAUER et al. 2004) ist der Ermittlung des Versiegelungsgrades in urbanen Gebieten eine Landbedeckungsklassifizierung vorgeschaltet, um urbane Gebiete von nicht-urbanen zu trennen, weil bestimmte urbane Klassen nur schwer von spektral ähnlichen nicht-urbanen Klassen zu unterscheiden sind. Der Versiegelungsgrad wird dann anschließend anhand geeigneter Modelle ermittelt. BAUER et al. (2004) bestimmten den prozentualen Versiegelungsgrad ausgewählter Trainingsgebiete in Landsat-Daten durch die Auswertung von Luftbildern. Sie erkannten einen starken Zusammenhang zwischen Versiegelungsgrad und *Tasseled Cap Greenness* und ermittelten auf dieser Basis eine Regressionsgleichung zur Bestimmung des Versiegelungsgrads. Die *Tasseled-Cap*-Transformation ist nicht auf die hoch auflösenden Satelliten wie Ikonos anwendbar, so dass hier der NDVI ein gutes Maß zur Ableitung der Versiegelung über eine Regressionsgleichung darstellt (SAWAYA et al. 2003:149). BRAUN & HEROLD (2003) erkannten ebenfalls einen starken Zusammenhang zwischen Versiegelungsgrad und Vegetationsparametern. Sie nutzten neben dem NDVI den aus einer SMA ermittelten Vegetationsanteil pro Pixel, um in Aster-Szenen mittels Regressionsgleichung den Versiegelungsgrad zu bestimmen. Die Korrelation zwischen den Vegetationsparametern und der gemessenen Versiegelungsfläche ist signifikanter als der Zusammenhang zwischen dem *Endmember* der bebauten Fläche und dem Versiegelungsgrad (BRAUN & HEROLD 2003:7). Bei der Anwendung hoch auflösender Daten kann die versiegelte Fläche sehr gut mit objektbasierten Verfahren erfasst werden (YUAN & BAUER 2006). Beispiele zur Erfassung versiegelter Flächen finden sich u. a. bei BAUER et al. (2004), BRAUN & HEROLD (2003), LU & WENG (2006), SAWAYA et al. (2003), WU & MURRAY (2003), YANG et al. (2003a, 2003b) und YUAN & BAUER (2006).

Stadtklimatologische Anwendungen

Atmosphärische Veränderungen sowie Veränderungen der Oberfläche infolge von Verstädterung wirken sich auf das thermale Regime aus, so dass es im städtischen Bereich normalerweise wärmer ist als in den außerstädtischen Gebieten. Dieses Phänomen wird als städtische Wärmeinsel (*Urban Heat Island UHI*) bezeichnet (VOOGT & OKE 2003:370). Mit thermaler Fernerkundung ist es möglich, derartige Effekte zu erkennen und zu beobachten. SMALL (2006) versuchte, den Zusammenhang zwischen optischen Reflektionseigenschaften und Oberflächenenergiebilanz bei mittlerer räumlicher Auflösung für eine Reihe urbaner Gebiete in unterschiedlichen Klimaten und Landschaften zu quantifizieren. Die Korrelation von Oberflächentemperatur und Reflexion liefert Informationen sowohl über die Oberflächeneigenschaften als auch über die Prozesse, die die Oberflächenenergiebilanz bestimmen (SMALL 2006:168f.). Viele urbane Räume, insbesondere in ariden Klimaten, sind indes nicht durch die Ausprägung stereotyper UHI-Signaturen gekennzeichnet. Im Gegensatz zu den städtischen Wärmeinseln der gemäßigten Breiten können in heißen Gebieten aufgrund der städtischen Vegetation und

großen Schattenbereiche, die es in den umliegenden Trockengebieten nicht gibt, sogar städtische Kälteinseln auftreten (SMALL 2006:185ff.). JIN et al. (2005) nutzten Modis-Daten und fanden *Skin-Temperature*-Anomalien zwischen Stadt und Stadtumland, die als UHI-Effekte interpretiert werden. In ariden und semi-ariden Gebieten sind diese Anomalien – adäquat zu den Ergebnissen von SMALL (2006) – teilweise umgekehrt, so dass dort urban von nicht-urban nur schwer zu unterscheiden ist (JIN et al. 2005:1560f.). Demgegenüber konnten STATHOPOULOU & CARTALIS (2007) für eine Reihe griechischer Städte mit Landsat-ETM+-Daten ausgewählter Aufnahmezeitpunkte in der warmen Jahreszeit UHI-Effekte aufzeigen. Demnach ist es auch möglich, *Hot Spots* innerhalb urbaner Gebiete zu ermitteln (STATHOPOULOU & CARTALIS 2007:365ff.). YUAN & BAUER (2007) untersuchten anhand von Landsat TM und ETM+, inwiefern prozentuale versiegelte Fläche, ermittelt durch eine SMA, und NDVI als Indikatoren für den Effekt städtischer Wärmeinseln geeignet sind. Gemäß diesen Untersuchungen besteht ein enger Zusammenhang zwischen prozentualer versiegelter Fläche und Landoberflächentemperatur (*Land Surface Temperature* LST), die als Maß für den Effekt einer städtischen Wärmeinsel an der Oberfläche (*Surface Urban Heat Island* SUHI) angenommen werden kann. Die Korrelation von NDVI und LST variiert im Laufe des Jahres und ist schwächer ausgeprägt (YUAN & BAUER 2007:385). ZHANG, X. et al. (2004) untersuchten anhand von Modis-Daten die Wirkung der städtischen Wärmeinseln auf die Phänologie der Pflanzen und zeigten, dass die Wachstumsperiode der Vegetation in urbanen Gebieten länger ist als in außerstädtischen Gebieten. In VOOGT & OKE (2003) finden sich weitreichende Ausführungen zur thermalen Fernerkundung in urbanen Gebieten mit einem Überblick über wissenschaftliche Arbeiten zu diesem Thema.

Für stadtplanerische Zwecke ist es jedoch ebenfalls wichtig zu wissen, wie die Stadtmorphologie das Lokalklima beeinflusst. RATTI et al. (2006) zeigen, wie aus DGMs Parameter berechnet werden können, mit deren Hilfe sich städtische Windfelder modellieren lassen, darunter die aerodynamische Rauigkeit oder das Höhe-zu-Breite-Verhältnis von Hochhausschluchten. Sie untermauerten mit ihren Ergebnissen, dass diese Parameter richtungsabhängig sind und darüber hinaus je nach Stadtmorphologie zwischen Städten erheblich variieren können.

2.4.4.2 Stadtplanung und -management

Der Übergang von stadtökologischen Analysen zu stadtplanerischen Fragestellungen ist fließend. Nicht selten bilden stadtökologische Untersuchungen die Grundlage für gezielte stadtplanerische Eingriffe, um die Anforderungen der verschiedenen Raumplanungsinstitutionen umsetzen zu können.

Stadtmodelle und Objektextrahierung

Dreidimensionale Stadtmodelle können zur Ableitung einzelner Objekte wie Gebäude oder Bäume angewandt werden (HAALA & BRENNER 1999) und bilden häufig die Grundlage zur Untersuchung lokalklimatologischer Fragestellungen (z. B. RATTI et al. 2006). Die dreidimensionale Darstellung hilft, stadtökologische Auswirkungen der

Stadtmorphologie differenziert zu bewerten und in städtebauliche Planungen bzw. Entscheidungen einfließen zu lassen. Somit steht u. a. die Extrahierung von Gebäuden im Fokus wissenschaftlicher Arbeiten (HAALA & BRENNER 1999, JIN & DAVIS 2005b, TUPIN & ROUX 2003). Darüber hinaus gehört die Erfassung von Straßennetzwerken ins Arbeitsfeld der urbanen Fernerkundung (COULOIGNER et al. 1998, JIN & DAVIS 2005a). Es gibt sogar erste Versuche, mit Fernerkundungsmethoden den Zustand von Straßen zu erfassen (HEROLD et al. 2004b). Dabei ist es derzeit noch nicht möglich, Expertenbewertungen vor Ort zu ersetzen, aber Fernerkundung kann dieses Expertenwissen ergänzen (HEROLD et al. 2004b:o. S.).

Informelle Siedlungen

Rasch und in vielen Ländern unkontrolliert ablaufende Urbanisierungsprozesse und mangelnde Datengrundlagen erhärten die Notwendigkeit permanenter *Monitoring*-Anstrengungen und effektiver Zusammenarbeit zwischen den Behörden (MAKTAV et al. 2005:658). Speziell in Entwicklungsländern konzentriert sich der arme Teil der Bevölkerung in so genannten *Informal Settlements* - Agglomerate meist selbstgebauter Unterkünfte aus dem lokal verfügbaren Material, häufig Wellblech oder Plastikplanen (HOFMANN 2001:107). Synonym werden auch die Begriffe *Slum* oder *Favelle* gebraucht. Derartigen Erscheinungen inhärent sind die meist illegale Errichtung und nicht-planungsgemäße Entwicklung sowie menschenunwürdige Lebensbedingungen (HOFMANN et al. 2006). Fernerkundung bietet eine wichtige Quelle zur Erfassung solcher Siedlungsräume und zur Beobachtung ihrer Entwicklung, um humanitären Katastrophen vorzubeugen und stadtentwicklerische Maßnahmen besser steuern und kontrollieren zu können. Zur Detektion informeller Siedlungen bieten objektbasierte Ansätze ein viel versprechendes Werkzeug (HOFMANN 2001, HOFMANN et al. 2006).

Katastrophenprävention, Risikobewertung und -management

Nicht außer Acht zu lassen ist die Anwendung von Fernerkundung zur Abschätzung von Naturgefahren und den damit verbundenen materiellen und letztendlich finanziellen Schäden (VAN DER SANDE et al. 2003). Derartige Anwendungen sind natürlich keineswegs auf urbane Gebiete beschränkt, jedoch konzentriert sich dort das größte Schadenspotential (VAN DER SANDE et al. 2003:227). KIAGE et al. (2005) konnten anhand von Radardaten Gebiete in Louisiana kartieren, die infolge eines Hurrikans überflutet waren. Der Versuch, nach dem Hurrikan Katrina mit Radardaten eine Überflutungskarte von New Orleans zu erstellen, scheiterte aufgrund der hohen Rückstreuwerte der Gebäude, die als *Corner*-Reflektoren wirkten. Allerdings konnten die Überflutungsgebiete mit SPOT-Daten zeitnah erfasst werden (KIAGE et al. 2005). Neben der Gefahr von Naturkatastrophen, die meist ganze Ortschaften oder Städte betreffen, gibt es auch Schadenspotential an Einzelobjekten infolge von Absinkungsercheinungen oder altersbedingten Instabilitäten der Gebäude. Durch die Anwendung differentieller Interferometrischer SAR-Systeme (DIFSAR) ist es möglich, Absinkungsercheinungen von Gebäuden zu erkennen (LANARI et al. 2004). Durch die Verschnei-

dung mit Zusatzinformationen in geographischen Informationssystemen können somit Gefahrenkarten erstellt werden (LANARI et al. 2004:2862). Darüber hinaus haben hoch auflösende Satellitendaten das Potential, vielfältige Informationen über die Bebauung, wie Gebäudetyp oder Anzahl der Stockwerke, zu liefern und somit einen wichtigen Beitrag zu Vulnerabilitätsanalysen in urbanen Räumen zu leisten (MUELLER et al. 2006).

Monitoring und Change Detection

Seit einigen Jahrzehnten stehen regelmäßig Satellitendaten zur Verfügung. Das spektrale und vor allem das räumliche Auflösungsvermögen der Satelliten wurden stetig weiterentwickelt, so dass heute eine breite Palette an Daten vorhanden ist, die es erlaubt, die Veränderung ausgewählter Räume zu beobachten und zu quantifizieren. Eine Vielzahl von Veränderungsanalysen stützt sich auf Daten der Landsat-Sensoren MSS, TM und ETM+ (z. B. BAUER et al. 2004, KAYA & CURRAN 2006, LIU & ZHOU 2004, YANG & LO 2002, YANG & LIU 2005, YANG et al. 2003b, YUAN et al. 2005). YANG & LO (2002) zeigen anhand von Landsat MSS und TM das Ausmaß von Verstädterung (*Urban Sprawl*) und Landnutzungswandel über einen Zeitraum von 25 Jahren am Beispiel von Atlanta. YUAN et al. (2005) führten eine ähnliche Analyse mit Landsat TM am Beispiel der Twin Cities Metropolitan Area durch. Beide Studien nutzten einen Post-Klassifikationsalgorithmus, um verschiedene Veränderungskombinationen auszuweisen. So kann jede Kombination anteilig berechnet werden und es wird augenscheinlich, welche Klasse durch welche Landbedeckung verdrängt worden ist (YUAN et al. 2005:321). In anderen Arbeiten wurden neben Satellitendaten auch historische Karten und Luftbilder verwendet, um die Zeitreihen noch weiter in die Vergangenheit auszuweiten (z. B. DIETZEL et al. 2005, HEROLD et al. 2003b). Mit Hilfe geeigneter Modelle und bei entsprechender Datengrundlage können auch Vorhersagen für zukünftige Entwicklungen getroffen werden, die jedoch immer noch großen Ungenauigkeiten unterworfen sind (HEROLD et al. 2003b:301). Die Anwendung von Raummaßen ist dabei ein effektives Mittel zur Verbesserung der Modelle (HEROLD et al. 2002c:1456, 2003b:301, 2005:394). Derartige Analysen sind insbesondere für sozialgeographische und sozio-ökonomische Fragestellungen von Interesse. Ziel ist die Erfassung von Urbanisierungsmustern und Stadtentwicklungsdynamiken, um zukünftige Entwicklungen modellieren zu können (DIETZEL et al. 2005, HEROLD et al. 2003b, 2005) und stadtplanerischen Handlungsbedarf aufzudecken (KAYA & CURRAN 2006, YANG & LO 2002, YUAN et al. 2005). Daneben existieren eher stadttökologisch ausgerichtete Untersuchungen, die die Veränderung einzelner physischer Parameter, wie Versiegelungsgrad, erfassen (BAUER et al. 2004, RASHED et al. 2005, YANG & LIU 2005, YANG et al. 2003b). Auf diese Weise können *Hot Spots* der Urbanisierung aufgedeckt werden (YANG & LIU 2005).

2.4.5 Aktuelle Forschung und Ausblick

Im letzten Jahrzehnt nahmen zahlreiche neue Satelliten ihre Arbeit auf, darunter Landsat 7 mit dem ETM+-Sensor (1999) zur Fortführung der Landsat-Serie, SPOT 4 (1998) und

SPOT 5 (2002) mit mittlerer Auflösung sowie die hoch auflösenden Ikonos (1999) und QuickBird (2001).

Neben den Arbeiten mit den etablierten Multispektralsensoren von Landsat und SPOT (z. B. ISLAM & METTERNICHT 2005, LU & WENG 2005, SMALL 2005, 2006, YUAN & BAUER 2007, ZHANG et al. 2003) sowie denen der neueren Generation mit Ikonos und QuickBird (z. B. HEROLD et al. 2002b, HOFMANN et al. 2006, KUX & ARAÚJO 2006, MITTELBERG 2002, SONG 2004, THIEL et al. 2006a, 2006b, VAN DER SANDE et al. 2003) gibt es im Bereich des *Urban Remote Sensing* Untersuchungen mit Hyperspektraldaten (z. B. BENEDIKTSSON et al. 2005, CHEN et al. 2003, DELL'ACQUA et al. 2005, GREIWE et al. 2004, HEROLD et al. 2002a, SEGL et al. 2003), Radardaten (z. B. DELL'ACQUA et al. 2006, DONG et al. 1997, ESCH et al. 2005, GREY & LUCKMAN 2003, LANARI et al. 2004, PELLIZZERI 2003, WEYDAHL 2001, WEYDAHL et al. 2005), Laserscanner- und Lidardaten (z.B. HAALA & BRENNER 1999, HEROLD & ROBERTS 2006, SCHIEWE & EHLERS 2005) sowie Flugzeugscannerdaten (z. B. MYEONG et al. 2001). Die räumliche Auflösung reicht dabei bei den satellitengetragenen Multispektralsensoren von Modis mit mehreren Hundert Metern (z. B. SCHNEIDER et al. 2003) bis hin zu QuickBird mit 2,4 m bzw. 0,6 m im panchromatischen Kanal (z. B. KIM et al. 2005). In der langen Liste der satellitengetragenen Sensoren fehlt derzeit u. a. ein räumlich hoch auflösendes Hyperspektralinstrument.

Urbane Gebiete sind gegenüber ihrem Umland durch eine erhöhte Bewölkung – sowohl Bedeckungsgrad als auch Wolkentage – gekennzeichnet (SCHÖNWIESE 2003:331). Untersuchungen mit optischen Daten sind auf wolkenfreie Bedingungen angewiesen. Radarsysteme sind von dieser Einschränkung nicht betroffen (MEYER et al. 2006:226, WEYDAHL et al. 2005:243). Der Nutzen von Radardaten zur Analyse urbaner Räume ist daher in humiden Gebieten und in Städten mit starker Smogbelastung besonders groß. Mit TerraSAR-X ist seit dem 15. Juni 2007 der erste räumlich hoch auflösende Radarsatellit im Orbit. Es ist zudem das erste voll polarimetrisch arbeitende X-Band-System im All und bietet somit zahlreiche neue Anwendungsmöglichkeiten (ROTH 2005). Die Anwendung von Radardaten wird jedoch speziell in dichten, hoch bebauten urbanen Räumen durch die für SAR-Sensoren typischen Beleuchtungsphänomene wie *Foreshortening*, *Layover* und Radarschatten erschwert (HOFFMANN et al. 2005:25f.). Somit steckt vor allem in der synergetischen Anwendung von optischen und Radardaten großes Potential (DONG et al. 1997:1362).

3 Ziel, Datengrundlage und methodisches Vorgehen

3.1 Zielsetzung

Aus den bisherigen Ausführungen ist ersichtlich, dass es eine Vielzahl Ansätze zur Charakterisierung urbaner Räume gibt. Je nach Anwendungsziel und Untersuchungsgebiet sind den einzelnen Methoden Grenzen gesetzt, die nur durch neue Verfahren bzw. zusätzliche Informationen überwunden werden können. Bisher selten angewandt ist die synergetische Nutzung von hoch auflösenden optischen und Radardaten, weil letztere lange Zeit nur durch Befliegungskampagnen zu erhalten waren. Radardaten mit einer Bodenauflösung von nur wenigen Metern sind erst seit dem Start von TerraSAR-X regelmäßig verfügbar und stellen daher eine neue Ressource mit immensem Potential dar. Ziel der Arbeit ist die Klassifikation hoch auflösender optischer und Radardaten in einem urban geprägten Teil Erfurts. Dabei steht einerseits die Erstellung einer Siedlungsmaske im Vordergrund, in der urbane Flächen von nicht-urbanen abgegrenzt werden, und andererseits eine Landbedeckungsklassifikation, auf deren Basis gegebenenfalls höhere Produkte wie Landnutzungsklassifikationen abgeleitet werden können. Die vorliegende Arbeit konzentriert sich auf die Landbedeckungsklassifizierung, da vergleichbare Kartenprodukte praktisch nicht verfügbar sind. Um Aussagen über den Nutzen der zusätzlichen Informationen aus hoch auflösenden Radardaten treffen zu können, werden zunächst die optischen und die Radardaten individuell klassifiziert, ehe sie synergetisch zur Anwendung kommen. Gemäß den Diskussionen im Theorieteil ist eine objektbasierte Klassifikation der aussichtsreichste Ansatz zur Analyse hoch auflösender Daten. Ein quantitativer Vergleich der Klassifikationsergebnisse sowie eine qualitative Analyse besonderer Problemfelder soll Antwort auf die Frage geben, inwiefern hoch auflösende Radardaten, die inzwischen durch TerraSAR-X verfügbar sind, zu einer verbesserten Charakterisierung urbaner Räume mit Fernerkundungsdaten beitragen können.

3.2 Untersuchungsgebiet

Gegenstand der Untersuchung ist die Thüringische Landeshauptstadt Erfurt. Erfurt hat bei einer Fläche von rund 270 km² ca. 200.000 Einwohner (Landeshauptstadt Erfurt Stadtverwaltung 2007:o. S.). Das Untersuchungsgebiet (Abb. 3.1, rot eingerahmt) umfasst den südöstlichen Teil des Stadtgebietes und ist von einer Vielzahl typisch urbaner Strukturen gekennzeichnet. Dazu gehören neben Teilen der Altstadt mit geschlossener Bebauung auch Stadtteile mit offener Bebauung, Wohnblockbebauung, Industrie- und Gewerbeflächen sowie die eher ländlich geprägten Stadtteile mit lockerer, ungeschlossener Bebauung in der Peripherie. Im Süden des Untersuchungsgebiets befindet sich eine größere zusammenhängende Waldfläche. In der Szene sind weiterhin zahlreiche städtische Grünanlagen, Sportstätten und Kleingartenanlagen sowie der Fluss Gera und ein Flutgraben, Teile des vierspurigen Stadtrings und des Bahnnetzes vorhanden. Große Areale des Gebiets sind von Landwirtschaftsflächen bedeckt. Die vielfältigen Landnutzungsklassen bestehen jeweils aus einer Fülle unterschiedlich orientierter und ausge-



Abb. 3.1: QuickBird-Aufnahme von Erfurt vom 26. Mai 2005. Das Untersuchungsgebiet ist rot umrandet.

prägender Landbedeckungsklassen. Allein das Spektrum verschiedener Bedachungen reicht – wie typisch für mitteleuropäische Städte dieser Größe– von Flachdächern über Satteldächer bis hin zu Leichtbaukonstruktionen. Die Bedeckungen sind aller Art und jeglichen Alters und umfassen neben Ziegeldächern, die insbesondere im Altstadtbereich und in Wohnlagen am Stadtrand vorherrschen, auch geschieferte Dächer, Dächer aus Metall und begrünte Dächer. Darüber hinaus treten unterschiedliche Dachneigungen und vielgestaltige Gebäudeorientierungen auf. Die Gebäudegröße reicht von Laubengänge bis hin zu geräumigen Industriehallen. Dementsprechend mannigfaltig sind die spektralen und radarrelevanten objektbezogenen Eigenschaften der Landbedeckungselemente. Als Untersuchungsgebiet wurde ein Bereich gewählt, der von allen verwendeten Fernerkundungsdaten abgedeckt wird. Die quadratische Form liegt darin begründet, dass im Zuge der Ehlers Fusion eine Transformation in den Frequenzraum durchgeführt wird und die dortige Filterung genauer ist, wenn die Dimensionen des zu bearbeitenden Bildes Vielfache von zwei sind. Die optische Szene hat eine Größe von 8.192 x 8.192 Pixeln, um unter Beachtung dieser Empfehlung ein möglichst großes Gebiet abzudecken.

3.3 Datengrundlage

Der bisherigen Argumentation folgend, versprechen multiskalige und multisensorale Ansätze die besten Ergebnisse bei der Analyse urbaner Räume. Vor dem Hintergrund

Tab. 3.1: Charakteristika von QuickBird (Eurimage 2006:1).

	Panchromatischer Kanal	Multispektralkanäle
Auflösung	0,61 m im Nadir, 0,72 m bei 25° Off-Nadir Standardprodukte werden auf 0,6/0,7 m resampelt	2,44 m im Nadir, 2,88 m bei 25° Off-Nadir Standardprodukte werden auf 2,4/2,8 m resampelt
Bandbreite	450 - 900 nm	blau 450 - 520 nm grün 520 - 600 nm rot 630 - 690 nm NIR 760 - 900 nm
radiometrische Auflösung	11 Bit	
Swath Width	16,5 km im Nadir	

der erst kürzlich gestarteten TerraSAR-X-Mission kamen räumlich hoch auflösende optische und SAR-Daten zur Anwendung. Datengrundlage bildeten E-SAR-Szenen vom 14. September 2000 und vom 2. April 2001 sowie eine QuickBird-Szene vom 26. Mai 2005. E-SAR ist ein flugzeuggetragenes SAR-System (KRAMER 2002:1455) – satellitengetragene hoch auflösende Radardaten waren vor dem Start von TerraSAR-X nicht vorhanden. Ausgewertet wurden X-Band-Intensitätsdaten in HH- und VV-Polarisation. Die *Range*-Auflösung beträgt 2 m, die Azimuthauflösung 3 m. Die Daten lagen mit einer Pixelgröße von 1 m Kantenlänge vor. Die Wellenlänge des E-SAR X-Bandes liegt bei 3 cm. Das entspricht einer Frequenz von 9,6 GHz. Von jedem Aufnahmezeitpunkt existieren für jede Polarisation jeweils zwei Aufnahmestreifen (*Northern* und *Central*), so dass insgesamt acht einzelne Radarbilder zu bearbeiten waren. Die Aufnahmestreifen von 2000 und 2001 sind nicht vollständig deckungsgleich, decken aber generell dasselbe Gebiet ab. QuickBird zählt zur noch relativ jungen Generation der räumlich hoch auflösenden Multispektralsensoren. Der Sensor hat vier Multispektralkanäle mit 2,4 m Auflösung sowie einen panchromatischen Kanal mit 0,6 m Auflösung (Tab. 3.1). Drei der Multispektralkanäle liegen im sichtbaren Bereich, einer im nahinfraroten. Dadurch ist es möglich, Vegetationsindizes wie den NDVI abzuleiten. In Abb. 3.2 ist



Abb. 3.2: Ausschnitt des Untersuchungsgebiets. Links QuickBird (R-G-B 3-2-1), rechts E-SAR (R-G-B XHH2001-XVV2000-XHH2000).

ein Teil des Untersuchungsgebiets im Stadtzentrum von Erfurt abgebildet. Trotz der verschiedenen Aufnahmeprinzipien von optischen und Radarsystemen sind jeweils in beiden Aufnahmen diverse Objekte auszumachen: einzelne Gebäude, Straßen, Bahnlinien, ein Fluss und Vegetation. Selbst im Radarbild sind im Bereich des Parks einzelne Bäume erkennbar.

Aufgrund der unterschiedlichen Aufnahmezeitpunkte repräsentieren die Daten unterschiedliche Zustände. Dies betrifft sowohl je nach Sensor die atmosphärischen Bedingungen sowie die (Feuchte-, Alters-, phänologischen) Zustände der beobachteten Objekte – deren Bedeutung für das Signal des jeweiligen Systems wurde in Kapitel 2.1 diskutiert – als auch den Bestand bestimmter Objekte. Im Zeitraum zwischen den ersten E-SAR-Aufnahmen 2000 und der QuickBird-Aufnahme 2005 entstanden zusätzlich zum nördlichen Abschnitt der vierspurigen Umgehungsstraße komplette Wohngebiete und das neue Eislaufstadion. Der besagte Teil der Umgehungsstraße ist in der E-SAR-Szene von 2000 visuell kaum auszumachen, jedoch in der Szene von 2001 teilweise und zum Zeitpunkt der QuickBird-Aufnahme vollständig zu erkennen. Die Überdachung des Eislaufstadions begann im April 2001 (Erfurter Sportbetrieb o.J.:o. S.), also unmittelbar nach der zweiten E-SAR-Befliegung. Das Gebäude ist in der QuickBird-Szene gut zu erkennen.

Referenzdaten zur Überprüfung der Klassifikationsgenauigkeit sind nur beschränkt verfügbar. Es existieren unterschiedliche Kartenprodukte, die teilweise Informationen über die Landnutzung enthalten oder eine Kombination aus Landnutzung und Landbedeckung bilden. Dazu gehören Grundkarten und Realflächenkartierungen, die auf Basis von *In-situ*-Erhebungen oder durch die Interpretation von Luftbildern durch die Stadt Erfurt erstellt wurden (mündliche Mitteilung J. SCHRÖDER). Die Karten werden ständig aktualisiert und sind für verschiedene Anwendungen nutzbar. Der vorliegende Ausschnitt der Realflächenkartierung wurde zwischen 2000 und 2005 erstellt. Die Nomenklatur entspricht jedoch nicht den in der Fernerkundung üblichen Bezeichnungen und erschwert somit die unmittelbare Verwendung zur Überprüfung der Klassifikationsgenauigkeit. Die Daten in ArcView zu implementieren und die ausgewiesenen Klassen in vergleichbare Referenzklassen zu übersetzen, ist aufgrund der inhaltlichen Diskrepanzen nur mit erheblichem Zeitaufwand zu bewerkstelligen und wurde daher nicht durchgeführt. Landbedeckungsinformationen, wie unterschiedliche Bedachungen, sind darüber hinaus nicht vorhanden. Die Realflächenkartierung eignet sich aber wegen der Aktualität und des breiten Informationsgehalts gut zur Ausweisung urbaner Flächen und kann fernerhin zur visuellen Kontrolle von Referenzpunkten dienen. Angesichts der eindeutigeren Nomenklatur sind die Daten von Linfos (Landschaftsinformationssystem) (TLUG 2001) zur Überprüfung der Genauigkeit von Landnutzungsklassifikationen besser geeignet, zumal sie in einem Datenformat vorliegen, das mit den meisten GIS-Softwarepaketen kompatibel ist. Als nachteilig erweisen sich die schlechte zeitliche Übereinstimmung der Daten mit den in dieser Arbeit genutzten Fernerkundungsdaten sowie mangelnde Landbedeckungsinformationen. Die Linfos-Daten basieren auf einer Farbinfrarotbefliegung von 1993 und sind dementsprechend in einigen Teilen des

Untersuchungsgebiets nicht aktuell. Zur visuellen Kontrolle eignet sich neben der Realflächenkartierung und der optisch gut interpretierbaren QuickBird-Szene auch die in Google Maps (http://maps.google.de/maps?oi=eu_map&q=Erfurt&hl=de) verfügbare Erfurt-Szene. Das hoch auflösende Luftbild ist zeitnah zu den Radarbildern aufgenommen worden, leicht zu erkennen an der im Bau befindlichen vierspurigen Umgehungsstraße im Osten der Stadt. Mit diesen Referenzquellen können zwischen den Aufnahmezeitpunkten neu entstandene Häuser, Wohngebiete oder Infrastruktur bzw. abgerissene Gebäude erkannt und von der Genauigkeitsanalyse ausgeschlossen werden. (Anmerkung: Bei Fertigstellung der vorliegenden Arbeit im November 2007 war das Luftbild durch aktuellere Daten ersetzt worden, sodass die Vergleichbarkeit zu den Radardaten nicht mehr gegeben war.)

3.4 Vorgehensweise

Der erste Schritt besteht in der Aufbereitung der Daten, die aufgrund der verschiedenen Aufnahmeprinzipien von optischen und Radarsystemen unterschiedliche Arbeitsschritte beinhaltet. Auf eine Atmosphärenkorrektur der QuickBird-Daten wurde verzichtet, da die Szene weitgehend wolkenfrei ist und nicht für multitemporale Anwendungen vorgesehen war. Die Multispektraldaten von QuickBird haben eine deutlich geringere Auflösung als die panchromatischen Daten. Ein Pixel der Multispektralkanäle bildet somit das Integral von vier Pixeln des panchromatischen Kanals, wobei im ersteren weniger Informationsgehalt vorhanden ist. Insbesondere bei der Analyse komplexer urbaner Räume ist es daher erstrebenswert, die Multispektraldaten in der höchsten räumlichen Auflösung anzuwenden, um alle Objektklassen bestmöglich beschreiben zu können. Durch *Pansharpening* ist es möglich, die Multispektraldaten in die räumliche Auflösung der panchromatischen Daten zu überführen (Kapitel 2.2.2). Inwiefern die Anwendung von *Pansharpening* tatsächlich die Klassifikationsgenauigkeit verbessert, wurde im Rahmen der vorliegenden Arbeit nicht untersucht. Für die anschließende Klassifikation und alle weiteren Interpretationen ist der Erhalt der spektralen Charakteristika bei der Bildfusion von grundlegender Bedeutung (EHLERS et al. 2006:o. S.). Deswegen wurden mehrere Methoden angewandt und schließlich das qualitativ und quantitativ beste Verfahren für die weitere Bearbeitung ausgewählt. Wie in Kapitel 2.3.1 dargestellt, kann der ausgeprägten spektralen Variabilität innerhalb urbaner Landbedeckungsklassen, die sich mit zunehmender Auflösung erhöht, mit objektbasierten Ansätzen begegnet werden. Davon ausgehend, dass die spektralen Eigenschaften im Zuge des *Pansharpenings* erhalten bleiben, können die gewünschten Objektlevels mit der größten Genauigkeit segmentiert werden. Die Aufbereitung der Radardaten umfasst im Wesentlichen Sensorkorrekturen und Filteroperationen zur Reduzierung des *Speckle*-Effekts. Die eigentliche Klassifikation folgt einem objektbasierten Ansatz. Gemäß der Zielsetzung wurden drei Datensätze erzeugt, die individuell mit Definiens Professional 5 segmentiert und klassifiziert wurden: ein Datensatz aus den QuickBird-Daten inklusive abgeleiteter Parameter wie NDVI und Textur, ein Datensatz aus E-SAR-Daten inklusive Texturparameter und ein kombinierter Datensatz aus beiden. In letzterem erfolgte die

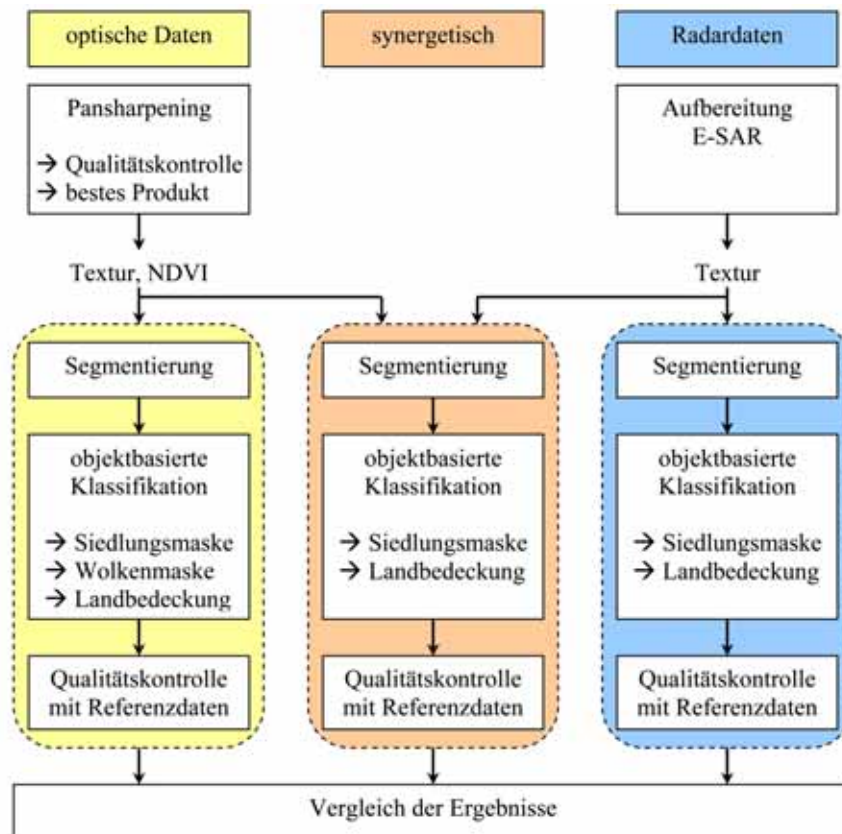


Abb. 3.3: Schematische Darstellung der Vorgehensweise.

Datenfusion nicht im Pixellevel, weil keines der pixelbasierten Fusionsverfahren ein Produkt erzeugen konnte, das im Sinne WALDS (1999:o. S.) von größerer Qualität ist als die Ausgangsdaten. Stattdessen wurden die aufbereiteten Daten und die daraus abgeleiteten Parameter, wie Textur und NDVI, auf Basis der Segmentierungslevel synergetisch genutzt. Die Ergebnisse der drei Verfahren wurden hinsichtlich ihrer Qualität mit den Referenzdaten verglichen und qualitativ bewertet. Abb. 3.3 zeigt schematisch die Folge der einzelnen Arbeitsschritte.

4 Datenaufbereitung

4.1 Pansharpening der QuickBird-Daten

Die Multispektralkanäle sollen mit dem hoch auflösenden panchromatischen Kanal geschärft werden, ohne dass dieser zusätzliche spektrale Informationen liefert (EHLERS & KLONUS 2004:497). Die Erhaltung der Grauwerte ist insbesondere dann problematisch, wenn sich der panchromatische und der nahinfrarote Kanal spektral nicht überdecken und somit nur gering korrelieren (HIRSCHMUGL et al. 2005:270). Im Fall der QuickBird-Daten besteht eine spektrale Überdeckung (Tab. 3.1), die insgesamt für hohe Korrelationen des panchromatischen Kanals mit allen Multispektralkanälen sorgt. Allerdings ist sie nicht in allen Teilen des Bildes gleich. In Gebieten, in denen einzelne Objektklassen in einem Kanal spektral dominieren, ist die Korrelation in den einzelnen Kanälen unterschiedlich ausgeprägt (vgl. Abb. 4.1 a und b). Am deutlichsten wird dies in vegetationsdominierten Bereichen, in denen der hohe Reflexionsgrad der Vegetation im NIR für entsprechend hohe Korrelationen mit dem panchromatischen Kanal sorgt, während die Kanäle mit niedrigem Reflexionsgrad eher gering mit dem panchromatischen Kanal korrelieren (Abb. 4.1 b). Für die Wahl des Verfahrens ist diese Tatsache irrelevant, sie unterstreicht indes, dass der Erhalt der spektralen Charakteristika schwierig ist. Darin besteht jedoch für die anschließende Klassifizierung die Hauptanforderung an das *Pansharpening* (EHLERS et al. 2006:o. S.). Im Rahmen der Arbeit wurden die in den




Abb. 4.1: Scattergramme zwischen PAN (Abszisse) und Multispektralkanälen (Ordinate) für zwei Ausschnitte der QuickBird-Szene im Stadtzentrum von Erfurt (RGB 4-3-2), Kanal 1 – 4 jeweils von oben nach unten: a) fast ausschließlich künstliche Oberflächen mit hohen Reflexionsgraden in allen Kanälen und b) vegetationsdominierter Altstadtbereich mit starker Korrelation zwischen PAN und NIR.

Tab. 4.1: Korrelation der originalen Multispektraldaten (2,4 m Auflösung) mit den auf 9,6 m degradierten Bildern, die mittels der aufgeführten Verfahren auf die originale Auflösung zurücktransformiert wurden.

Verfahren	Band 1	Band 2	Band 3	Band 4
bicubic spline	0.917	0.912	0.917	0.922
nearest neighbor	0.892	0.888	0.892	0.905
bilinear interpolation	0.907	0.902	0.907	0.914
cubic convolution	0.916	0.911	0.917	0.921

Softwarepaketen Envi und Erdas implementierten Standardverfahren angewandt: Gram-Schmidt, CN, PC, Brovey, HSV in Envi sowie IHS (wavelet), Singleband (wavelet), PC (wavelet), Multiplicative, Brovey, PC in Erdas. Ab der Erdas 9.0 Version stehen darüber hinaus das HPF-Verfahren sowie ein modifiziertes IHS-Verfahren zur Verfügung, die ebenfalls verwendet wurden. Ferner wurde in Envi mit der Download-Version eines Wavelet-Tools (<http://www.rsinc.com/codebank/>) gearbeitet. Des Weiteren wurde die Ehlers Fusion (EHLERS & KLONUS 2004) schrittweise in Erdas durchgeführt: Die IHS-Transformation unter Verwendung von 16-Bit-Daten ergab in Erdas verfälschte Ergebnisse. Deswegen wurden die Daten auf 8 Bit skaliert. Das *Resampling* der Multispektralkanäle auf die Auflösung der panchromatischen Komponente erfolgte mittels bikubischer Faltung (*Bicubic Spline*). Im Zuge der späteren Qualitätsanalyse wurde das originale Multispektralbild auf 9,6 m degradiert und anschließend mit den vier in Erdas verfügbaren Verfahren auf die Originalauflösung von 2,4 m resampelt. Dabei zeigte sich, dass das Ergebnis mittels *Bicubic Spline* die besten Korrelationskoeffizienten erreichte, so dass davon ausgegangen werden kann, dass dieses Verfahren die beste Eignung zum *Resampling* besitzt (EHLERS & KLONUS 2004:497f.). *Cubic Convolution* liegt annähernd im selben Bereich. Die Korrelationskoeffizienten von *Nearest Neighbor* und *Bilinear Interpolation* sind nur geringfügig schlechter (Tab. 4.1). Nach der IHS-Transformation erfolgte die Transformation der panchromatischen und der Intensitätskomponente in den Frequenzraum mittels FFT. Gemäß der in Kapitel 2.2.1.8 beschriebenen Vorgehensweise können durch die Analyse des Powerspektrums isotrope Hoch- bzw. Tiefpassfilter entworfen werden, die im Fall von QuickBird ein Viertel der Informationen filtern. Bei einer Größe der Szene von 8.192 x 8.192 Pixel beträgt der Filterradius demnach 2.048 Pixel. Im vorliegenden Beispiel wurde die Intensitätskomponente des multispektralen Bildes mit einer *Cut-off*-Frequenz von 60 und einem Filterradius von 2.048 gefiltert. Die besten Ergebnisse wurden bei einer entsprechenden Filterung des panchromatischen Bildes ab einer *Cut-off*-Frequenz von 50 und einem Filterradius von 1.024 erreicht. Bei einer idealen Filterbreite von 2.048 war das Bild nicht ausreichend scharf. Danach erfolgten die Rücktransformation in den Ortsraum, die Addition der beiden Komponenten und die inverse IHS-Transformation (Kapitel 2.2.1.8).

4.2 Qualitätsanalyse der Pansharpening-Produkte

Im Theorieteil wurde eine Fülle an Methoden und Maßen zur Bewertung der Qualität von Bildfusionen vorgestellt (Kapitel 2.2.4). Dabei ist es nicht möglich und auch nicht sinnvoll, alle anzuwenden. Für die qualitative Analyse wurden die *Pansharpening*-Pro-

dukte zunächst visuell ausgewertet. Neben diesen stark subjektiven Einschätzungen wurden entsprechend der von SHI et al. (2005) und WALD et al. (1997) vorgeschlagenen Vorgehensweisen quantitative Qualitätsanalysen durchgeführt. Dabei wurden u. a. statistische Eigenschaften wie Maximalwert, Minimalwert, Median, Mittelwert, Standardabweichung und Korrelationskoeffizient ausgewertet, von denen die aussagekräftigsten in den Tab. 4.2 – 4.7 aufgeführt sind. Zum einen kann die Qualität eines *Pansharpening*-Ergebnisses ermittelt werden, zum anderen die Qualität des Verfahrens. Dazu müssen die Datensätze dieselben Dimensionen haben. Die Resultate des *Resamplings* werden vom Verfahren beeinflusst. Dem Rechnung tragend, wurde das *Resampling* jeweils mittels *Bicubic Spline* durchgeführt – gemäß Tab. 4.1 ist dieses Verfahren am besten geeignet. Im ersten Qualitätstest wurden die *Pansharpening*-Ergebnisse auf die Auflösung des originalen Multispektraldatensatzes degradiert und dann die Korrelationen zwischen den Daten sowie Standardabweichung und Mittelwerte aller Kanäle berechnet. Diese Vorgehensweise entspricht der Überprüfung des ersten Kriteriums von WALD et al. (1997:694). Im zweiten Qualitätstest, der vor allem als Maß für die Güte der Fusionsverfahren gilt, wurde die Auflösung des panchromatischen Kanals um den Faktor vier auf die Auflösung der originalen Multispektraldaten degradiert. Die Auflösung der Multispektraldaten wurde ebenfalls um den Faktor vier degradiert. Danach wurden die *Pansharpening*-Verfahren auf diese Daten angewandt, so dass fusionierte Multispektralbilder mit der räumlichen Auflösung der originalen Multispektraldaten entstanden. Dem zweiten Kriterium von WALD et al. (1997:694f.) folgend sollten die Fusionsprodukte den originalen Multispektraldaten möglichst ähnlich sein. Dies wurde ebenfalls mittels Korrelationskoeffizient, Standardabweichung und Mittelwert untersucht. Im dritten Qualitätstest wurde die Korrelation zwischen den *Pansharpening*-Ergebnissen und den auf dieselbe Auflösung transformierten Originaldaten berechnet, darüber hinaus Standardabweichung und Mittelwerte. Schließlich erfolgte anhand von Profillinien die Überprüfung, inwiefern ein *Pansharpening*-Produkt die Grauwertabfolge der Originaldaten nachbilden kann.

Einige in den Softwarepaketen implementierte Verfahren geben 8-Bit-Daten aus. Im Sinne unverfälschter Vergleichbarkeit wurden die Daten nicht auf 16 Bit skaliert. Bei der Bewertung der Ergebnisse sollte der Unterschied zwischen 8-Bit- und 16-Bit-Daten bedacht werden. Die signifikantesten Unterschiede zwischen den Ergebnissen werden durch Korrelationskoeffizient, als globales Maß der Übereinstimmung, sowie Standardabweichung und Mittelwert wiedergegeben.

4.2.1 Optische Bewertung

In Abb. 4.3 ist ein Subset für die originalen Multispektraldaten und den panchromatischen Kanal abgebildet. Es ist deutlich ersichtlich, dass die Multispektraldaten aufgrund ihrer geringeren Auflösung gegenüber den panchromatischen Daten unscharf erscheinen und räumliche Details daher nur bedingt erkennbar sind. Abb. 4.2 zeigt denselben Ausschnitt wie in Abb. 4.3 nach Schärfung mit den jeweiligen Verfahren. Dabei ist festzustellen, dass die Standardverfahren wie Gram-Schmidt, Brovey, Multi-



a) Envi Gram-Schmidt



b) Envi-CN



c) Envi PC



d) Envi Brovey



e) Envi HSV



f) Envi Wavelet



g) Erdas IHS (wavelet)



h) Erdas Singleband (wavelet)




i) Erdas PC (wavelet)



j) Erdas Multiplicative



k) Erdas Brovey



l) Erdas PC



m) Erdas HPF



n) Erdas Mod-IHS



o) Erdas Ehlers

Abb. 4.2: *Pansharpening*-Produkte im Vergleich (Subset).

plicative, CN, HSV, HPF und Mod-IHS eine Schärfung des Bildes erzielen. Die PC-Verfahren erreichen keine deutliche Verbesserung der Bildschärfe. Bei Versuchen mit



a) b)
Abb. 4.3: Subset für das Original QuickBird-Multispektralbild (a) und den panchromatischen Kanal (b).

kleineren *Subsets* konnten allerdings auch mit den PC-Verfahren hochwertige Bildschärfungen erzielt werden. Die Ursache für die mangelnde Bildschärfung bei großen Bildausschnitten war nicht feststellbar. Die auf Wavelets basierten Produkte zeigen teilweise unerwünschte Artefakte. Das Envi Wavelet-Ergebnis kann dabei als

Ausnahme gesehen werden. Die meisten Produkte erreichen in der RGB-Kombination 3-2-1 eine farbliche Ähnlichkeit mit dem Original, wobei dennoch deutliche Unterschiede auftreten.

4.2.2 Erstes Qualitätskriterium

Zur Bewertung des ersten Kriteriums wurden die *Pansharpening*-Produkte auf die Auflösung der originalen Multispektraldaten degradiert. Alle Produkte sind stark mit den Originaldaten korreliert (Tab. 4.2). Die höchsten Werte erreichen indes Ehlers Fusion und Envi Wavelet. Bei der Statistik in Tab. 4.3 gibt es erhebliche Unterschiede: Während Ehlers Fusion, alle Wavelet-Verfahren und Gram-Schmidt dem Original sehr ähnlich sind, weichen die meisten anderen Verfahren stark ab. Einige Verfahren, wie Envi PC haben fast den identischen Mittelwert, tendieren aber zu einer Gauß-Verteilung, was sich in einer vom Original abweichenden Standardabweichung ausdrückt.

Tab. 4.2: Korrelation zwischen den auf die Auflösung der Originaldaten (2,4 m) degradierten *Pansharpening*-Produkte und den originalen MS-Daten. Oben 8-Bit-Produkte, unten 16-Bit.

Korrelationskoeffizienten	Band 1	Band 2	Band 3	Band 4	Durchschnitt
Envi Brovey	0,84	0,88	0,90	0,89	0,88
Envi HSV	0,88	0,90	0,92	0,93	0,90
Erda's Multiplicative	0,83	0,87	0,87	0,91	0,87
Erda's IHS wavelet	0,96	0,97	0,98	0,98	0,97
Erda's PC wavelet	0,98	0,99	0,99	0,94	0,97
Erda's Ehlers	0,96	0,98	0,98	0,98	0,98
Envi CN	0,85	0,89	0,93	0,95	0,91
Envi Gram-Schmidt	0,96	0,93	0,95	0,97	0,95
Envi PC	0,97	0,99	0,98	0,63	0,89
Envi Wavelet	0,98	0,98	0,98	0,99	0,98
Erda's Singleband	0,96	0,96	0,96	0,96	0,96
Erda's PC	0,88	0,95	0,91	-0,85	0,89
Erda's Brovey	0,88	0,92	0,96	0,98	0,94
Erda's Mod-IHS	0,93	0,94	0,97	0,95	0,95
Erda's HPF	0,96	0,96	0,96	0,96	0,96

Tab. 4.3: Statistik der *Pansharpening*-Produkte nach einer Degradierung auf die Originalauflösung von 2,4 m. Oben 8-Bit-Produkte, unten 16-Bit.

Verfahren	Band 1		Band 2		Band 3		Band 4	
	mean	std	mean	std	mean	std	mean	std
Envi Brovey	111,31	48,07	107,37	54,22	109,92	58,80	170,41	82,96
Envi HSV	57,01	43,55	71,86	54,53	59,36	49,65	89,84	50,63
Erdas Multiplicative	7,27	3,44	8,89	6,30	7,32	4,73	15,22	8,57
Erdas IHS wavelet	11,84	9,29	26,45	17,03	20,91	15,63	70,89	28,74
Erdas PC wavelet	12,19	9,48	26,38	16,98	20,80	15,08	71,89	27,45
Erdas Ehlers	12,38	9,31	26,83	17,32	21,31	15,58	71,05	29,05
MS-8-Bit original	12,69	10,08	26,92	17,91	21,33	16,01	72,00	30,70
Envi CN	287,49	69,37	414,51	126,30	259,66	120,62	721,14	302,57
Envi Gram-Schmidt	256,41	54,14	369,74	96,44	232,920	95,29	623,58	244,71
Envi PC	256,62	45,67	369,66	92,35	232,91	79,77	623,57	237,04
Envi Wavelet	254,25	60,49	371,28	109,01	242,42	105,46	633,55	217,63
Erdas Singleband	252,88	59,98	365,78	107,88	229,26	103,89	619,24	212,04
Erdas PC	167,48	67,01	267,59	120,25	94,99	109,58	1.427,9	74,26
Erdas Brovey	71,81	17,12	103,60	31,63	64,93	30,49	180,52	76,50
Erdas Mod-IHS	253,98	59,69	372,99	125,81	237,40	120,03	611,73	189,09
Erdas HPF	256,59	56,49	369,58	100,52	232,81	98,21	623,21	199,29
MS-16-Bit original	256,69	64,90	369,76	116,15	232,99	112,70	623,44	228,72

4.2.3 Zweites Qualitätskriterium

Zur Überprüfung des zweiten Qualitätskriteriums wurden die Originaldaten mit dem Faktor vier auf 2,4 m (PAN) bzw. 9,6 m (MS) degradiert. Danach kamen die *Pansharpening*-Verfahren zur Anwendung. Die Produkte wurden mit dem Originalbild korreliert. Die besten Korrelationen weisen Ehlers Fusion, Envi Wavelet, Erdas Mod-IHS und HPF auf (Tab. 4.4). Eine gute Übereinstimmung der Mittelwerte erreichen mehrere Verfahren, wobei fast alle Ergebnisse eine vom Original abweichende Standardabweichung aufweisen (Tab. 4.5). Die beste Annäherung erreichen hierbei die waveletbasierten Methoden, Gram-Schmidt, Envi PC, HPF und Mod-IHS.

Tab. 4.4: Korrelation zwischen den *Pansharpening*-Produkten aus den degradierten Daten und den originalen MS-Daten. Oben 8-Bit-Produkte, unten 16-Bit.

Korrelationskoeffizienten	Band 1	Band 2	Band 3	Band 4	Durchschnitt
Envi Brovey	0,26	0,83	0,58	0,81	0,62
Envi HSV	0,38	0,48	0,54	0,86	0,56
Erdas Multiplicative	0,84	0,85	0,84	0,88	0,85
Erdas IHS wavelet	0,83	0,88	0,89	0,90	0,87
Erdas PC wavelet	0,86	0,89	0,87	0,62	0,81
Erdas Ehlers	0,89	0,93	0,93	0,94	0,92
Envi CN	0,75	0,82	0,87	0,91	0,84
Envi Gram-Schmidt	0,86	0,85	0,87	0,92	0,87
Envi PC	0,69	0,77	0,71	0,60	0,69
Envi Wavelet	0,87	0,90	0,90	0,93	0,90
Erdas Singleband	0,81	0,82	0,81	0,83	0,82
Erdas PC	0,77	0,84	0,79	-0,73	0,78
Erdas Brovey	0,80	0,87	0,91	0,95	0,88
Erdas Mod-IHS	0,86	0,89	0,92	0,92	0,90
Erdas HPF	0,89	0,90	0,90	0,93	0,91

Tab. 4.5: Statistiken für die *Pansharpening*-Produkte der degradierten Originaldaten. Die Ergebnisse von Brovey, HSV und Erdas Multiplicative waren ungewöhnlich und wurden daher ausgeblendet. Oben 8-Bit-Produkte, unten 16-Bit.

Verfahren	Band 1		Band 2		Band 3		Band 4	
	mean	std	mean	std	mean	std	mean	std
Erdas IHS wavelet	11,97	8,98	26,84	16,30	21,08	14,82	70,70	26,90
Erdas PC wavelet	12,19	8,55	26,36	15,14	20,80	13,45	71,67	27,98
Erdas Ehlers	25,20	14,44	26,04	15,63	27,40	17,95	88,62	32,04
MS-8-Bit original	12,69	10,08	26,92	17,91	21,33	16,01	72,00	30,70
Envi CN	287,96	72,68	415,21	126,75	260,16	116,30	719,82	291,91
Envi Gram-Schmidt	256,38	50,77	369,70	91,41	232,83	88,82	623,99	225,27
Envi PC	256,62	39,68	369,65	76,95	232,87	68,21	623,86	229,60
Envi Wavelet	253,58	56,91	369,93	98,60	241,08	95,39	631,82	199,80
Erdas Singleband	254,60	58,82	366,24	104,79	230,00	101,90	620,22	209,13
Erdas PC	194,60	57,41	289,53	105,84	131,23	98,22	1.058,30	45,05
Erdas Brovey	71,96	18,14	103,77	31,73	65,02	29,22	179,99	73,16
Erdas Mod-IHS	254,86	60,88	375,45	131,33	239,13	120,23	610,88	176,17
Erdas HPF	256,69	55,05	369,76	97,97	232,98	95,39	623,52	199,09
MS-16-Bit original	256,69	64,90	369,76	116,15	232,99	112,70	623,44	228,72

4.2.4 Drittes Qualitätskriterium

Die originalen Multispektraldaten wurden mittels *Bicubic Spline* auf 0,6 m resampelt und mit den *Pansharpening*-Produkten korreliert. Fast alle Verfahren erreichen in allen Kanälen hohe Korrelationskoeffizienten – Envi Wavelet, Ehlers Fusion sowie die auf Wavelets basierten Erdas-Verfahren IHS und PC erzielen die höchsten Werte (Tab. 4.6). Diese Verfahren sind auch bezüglich Mittelwert und Standardabweichung den Originaldaten sehr ähnlich. Gute Übereinstimmung erreichen auch Mod-IHS, HPF und Gram-Schmidt (Tab. 4.7). Die Betrachtung der Tab. 4.2 bis 4.7 bestätigt für einige Verfahren die visuellen Eindrücke. So sind die statistischen Kennwerte für das HPF-Verfahren oder das Envi Wavelet-Verfahren dem Original jeweils sehr ähnlich. Bei den PC-Produkten ist die Statistik besser als der optische Eindruck. Diese Aussage gilt je-

Tab. 4.6: Korrelation der auf 0,6 m resampelten Originaldaten mit den *Pansharpening*-Produkten. Oben 8-Bit-Produkte, unten 16-Bit.

Korrelationskoeffizienten	Band 1	Band 2	Band 3	Band 4	Durchschnitt
Envi Brovey	0,82	0,87	0,88	0,88	0,86
Envi HSV	0,84	0,87	0,89	0,90	0,88
Erdas Multiplicative	0,82	0,87	0,87	0,91	0,86
Erdas IHS wavelet	0,91	0,95	0,95	0,95	0,94
Erdas PC wavelet	0,97	0,98	0,97	0,87	0,95
Erdas Ehlers	0,93	0,97	0,97	0,97	0,96
Envi CN	0,78	0,85	0,90	0,93	0,87
Envi Gram-Schmidt	0,92	0,89	0,92	0,96	0,92
Envi PC	0,95	0,98	0,96	0,60	0,87
Envi Wavelet	0,96	0,97	0,97	0,98	0,97
Erdas Singleband	0,90	0,90	0,90	0,91	0,90
Erdas PC	0,88	0,95	0,91	-0,78	0,88
Erdas Brovey	0,83	0,89	0,95	0,97	0,91
Erdas Mod-IHS	0,88	0,92	0,96	0,94	0,92
Erdas HPF	0,91	0,91	0,91	0,91	0,91

Tab. 4.7: Statistik der *Pansharpening*-Produkte im Vergleich zu den auf 0,6 m resampelten Originaldaten. Oben 8-Bit-Produkte, unten 16-Bit.

Verfahren	Band 1		Band 2		Band 3		Band 4	
	mean	std	mean	std	mean	std	mean	std
Envi Brovey	111,22	50,10	107,30	56,01	109,83	60,66	170,48	84,74
Envi HSV	56,94	45,93	71,79	56,85	59,30	51,84	89,86	52,89
Erdas Multiplicative	7,25	3,55	8,86	6,49	7,30	4,85	15,19	8,79
Erdas IHS wavelet	11,97	10,63	26,29	18,74	20,72	16,72	70,68	31,48
Erdas PC wavelet	12,34	10,05	26,41	17,92	21,07	15,91	72,04	30,89
Erdas Ehlers	12,33	9,92	26,78	18,08	21,25	16,21	71,01	30,23
MS-8-Bit original	12,69	10,07	26,91	17,90	21,32	16,01	71,99	30,70
Envi CN	287,06	75,11	414,23	134,96	259,54	126,71	721,81	314,95
Envi Gram-Schmidt	256,38	56,27	369,69	101,78	232,84	99,40	623,65	249,66
Envi PC	256,65	46,19	369,70	92,73	232,93	80,62	623,46	251,29
Envi Wavelet	254,27	61,92	371,32	110,83	242,40	107,23	633,75	220,68
Erdas Singleband	254,12	68,86	367,92	123,84	230,91	117,75	620,38	237,01
Erdas PC	167,38	68,29	267,46	122,32	94,77	111,57	1.427,90	82,55
Erdas Brovey	71,77	18,78	103,56	33,74	64,89	31,68	180,45	78,74
Erdas Mod-IHS	254,32	64,68	372,68	132,20	237,03	124,75	610,32	198,62
Erdas HPF	256,65	62,99	369,71	112,55	232,94	109,48	623,57	222,43
MS-16-Bit original	256,65	64,87	369,69	116,12	232,91	112,66	623,37	228,76

doch nur für die Bearbeitung eines großen Bildausschnitts. Als besonders leistungsfähig erwies sich die Ehlers Fusion. Lediglich das *Pansharpening* der degradierten Originaldaten brachte hinsichtlich der Statistik weniger gute Ergebnisse. Deren Qualität ist möglicherweise durch die Optimierung der Filtergröße zu steigern. Die Ergebnisse von Envi Wavelet und Ehlers Fusion zeigen jeweils die besten Korrelationen mit dem Original (vgl. Tab. 4.2, 4.4, 4.6) und ebenso hervorragende Übereinstimmungen hinsichtlich der statistischen Parameter. Bei einigen Verfahren, wie Envi PC oder Erdas PC, ähnelt die Grauwertverteilung in den Histogrammen Gauß-Verteilungen – ein Defizit, das Envi Wavelet und Ehlers Fusion, aber auch Erdas HPF und Mod-IHS nicht aufweisen.

4.2.5 Profillinien

Die statistischen Parameter vermitteln einen Gesamteindruck vom Leistungsvermögen einzelner Bildfusionstechniken bzw. von den damit erzeugten Ergebnissen. Eine Aussage über die lokale Genauigkeit ist auf deren Basis nur bedingt möglich. Die Detailbetrachtung mittels Profillinien erlaubt hingegen den direkten Vergleich von Originaldaten und fusionierten Bildern. Diese geben Aufschluss über lokale Abweichungen, die durch globale Statistiken häufig nicht zum Ausdruck kommen. Die rote Linie in Abb. 4.4 zeigt die Lage der Profillinie. Sie schneidet ein Feld, quert eine mehrspurige Straße




Abb. 4.4: Ausschnitt aus den Originalszenen (links NIR, rechts PAN) mit der Lage des analysierten Grauwertprofils.

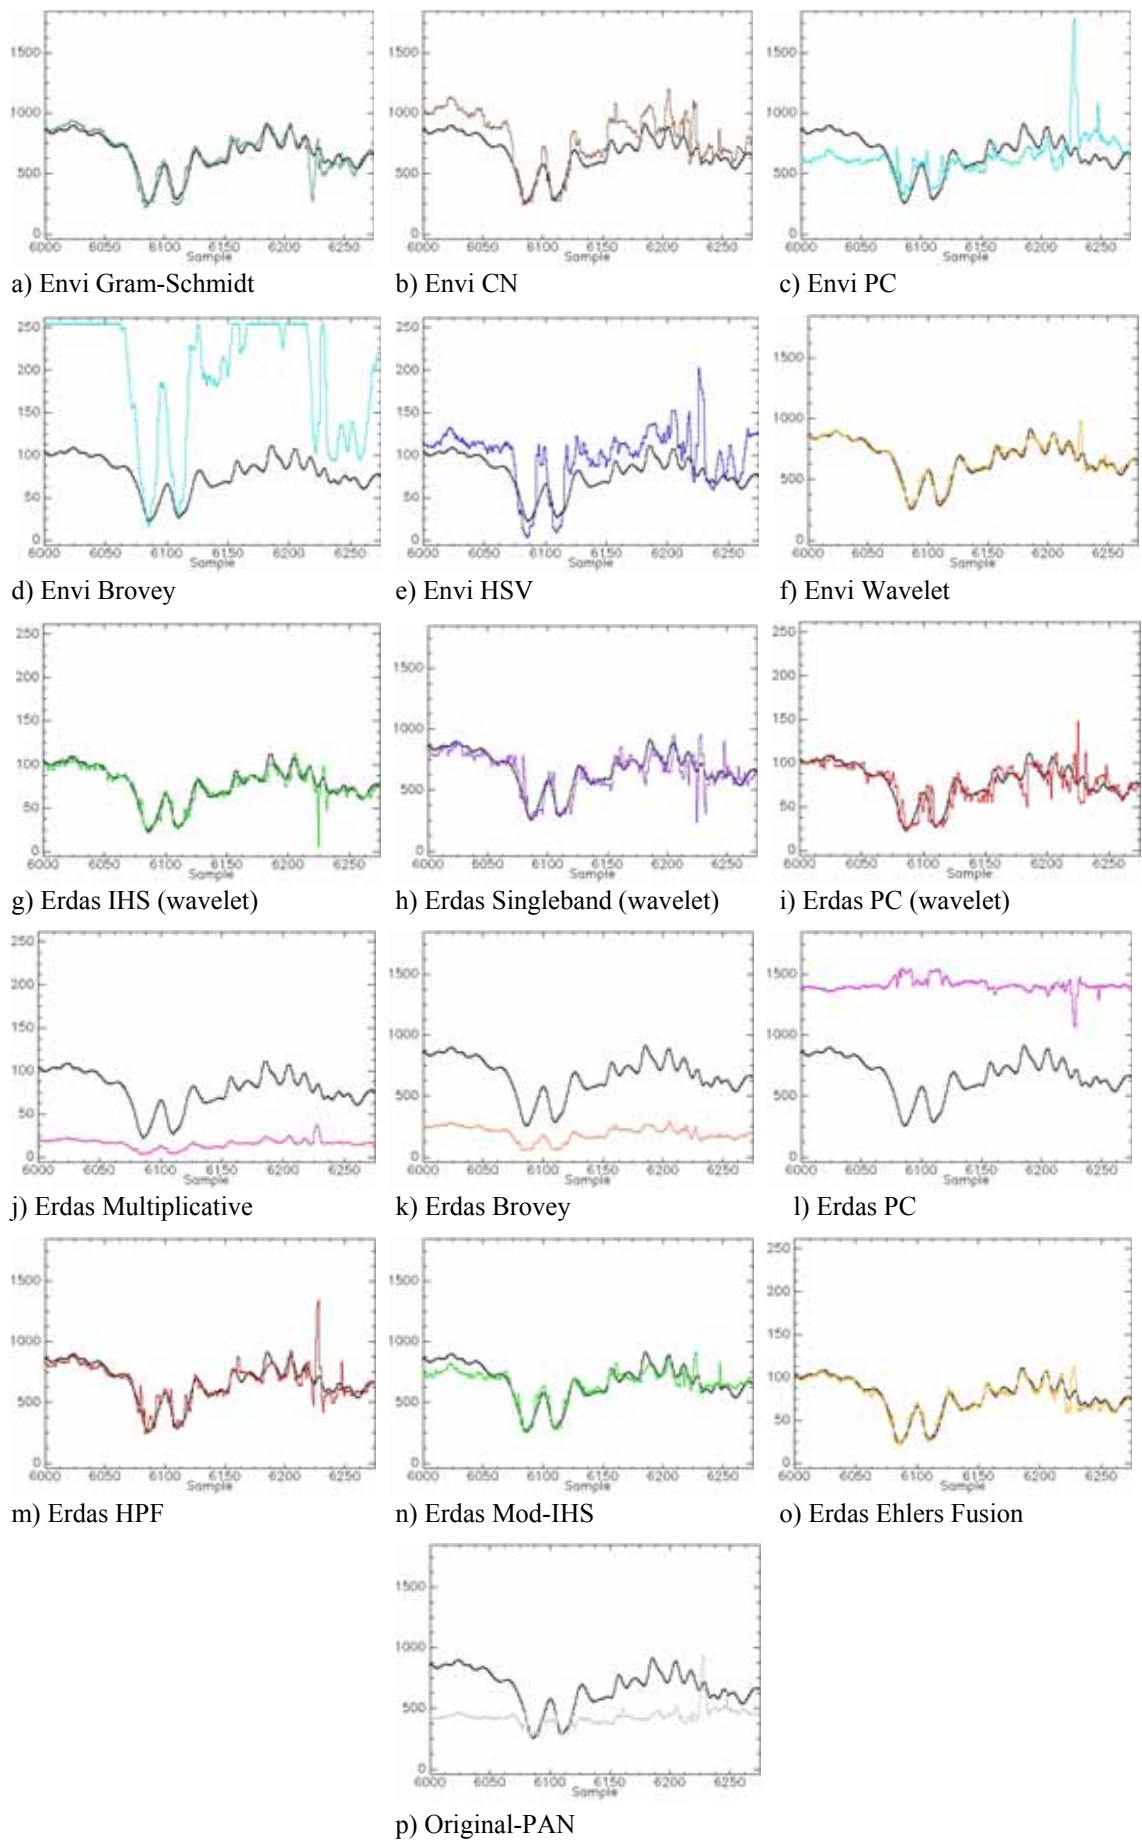


Abb. 4.5: Profillinien des originalen NIR-Bandes (schwarz), mittels *Bicubic Spline* auf 0,6 m gebracht, im Vergleich zum NIR-Kanal der *Pansharpening*-Produkte.

und reicht schließlich bis in eine Siedlung. Dargestellt ist einerseits der nahinfrarote Kanal der Originaldaten und andererseits – zur besseren Visualisierung – der panchromatische Kanal. Verglichen wurden jeweils der nahinfrarote Kanal der *Pansharpening*-Produkte und der nahinfrarote Kanal der Originaldaten (Abb. 4.5). Envi PC, Envi Brovey, Erdas Multiplicative, Erdas Brovey und Erdas PC weichen deutlich vom Grauwertprofil der Originaldaten ab (Abb. 4.5 c, d, j, k, l), in Erdas PC ist das Profil sogar als Negativ ausgeprägt (Abb. 4.5 l). Envi CN und Envi HSV zeichnen in etwa den Verlauf des Profils nach, haben aber große Schwankungen um die tatsächliche Kurve (Abb. 4.5 b, e). Envi Gram-Schmidt, die waveletbasierten Standardverfahren in Erdas und Erdas HPF folgen dem Verlauf des Profils recht gut, weichen aber in einigen Teilen – insbesondere im rechten Drittel – markant von der Kurve ab (Abb. 4.5 a, g, h, i, m). Erdas Mod-IHS bildet den Profilverlauf ebenfalls gut ab, erzeugt aber speziell in vegetationsreichen Abschnitten zu geringe Grauwerte und wird damit dem Erhalt der spektralen Charakteristika nicht gerecht (Abb. 4.5 n). Envi Wavelet und das Ehlers-Verfahren zeichnen den Profilverlauf des Originalbildes am besten nach (Abb. 4.5 f, o). Das Ausschwingen beider Kurven im rechten Drittel ist offensichtlich durch das panchromatische Band gesteuert (Abb. 4.5 p). Zusammenfassend kann festgestellt werden, dass folgende Verfahren am besten geeignet sind, um das Bild zu schärfen, ohne dabei die spektrale Information zu beeinträchtigen: Ehlers Fusion (Erdas), Envi-Wavelet, Erdas HPF, Erdas Mod-IHS und Envi Gram-Schmidt. Insgesamt sind davon die Ehlers Fusion und die waveletbasierte Fusion in Envi die flexibelsten Methoden. Aufgrund des besseren optischen Eindrucks bei sonst sehr ähnlichen Leistungseigenschaften wurde das Ehlers-Verfahren für die weitere Bearbeitung ausgewählt.

4.3 Ableitung von Textur und NDVI aus den QuickBird-Daten

QuickBird besitzt nur vier Spektralkanäle und ist somit zur spektralen Charakterisierung von Landbedeckungsklassen stark limitiert (HEROLD et al. 2003a:1907, HEROLD & ROBERTS 2006:2). Angesichts der Lage der QuickBird-Kanäle im elektromagnetischen Spektrum können allerdings diverse Indizes wie der NDVI abgeleitet werden (Gleichung 2.49). Dieser Index wird vielfach zur Charakterisierung von Vegetation eingesetzt (MYEONG et al. 2001, MYEONG et al. 2006, NICHOL & LEE 2005) und stellt eine wichtige Ergänzung zu den Spektralkanälen dar. Er wurde im Zuge dieser Arbeit auf Basis des hoch auflösenden *Pansharpening*-Produkts mit den Kanälen 3 (rot) und 4 (NIR) berechnet. Der NDVI kann, wie andere Ratios auch, in Definiens Professional erzeugt werden und muss nicht als separater Kanal eingelesen werden. Darüber hinaus wurden die *Grey Level Co-Occurrence* Matrizen (GLCM) sowie die *Grey Level Occurrence* Matrizen (GLOM) in Envi berechnet. Dadurch sind die Texturmaße *Contrast*, *Correlation*, *Entropy*, *Dissimilarity*, *Homogeneity*, *Mean*, *Angular Second Moment* und *Variance* (GLCM) sowie *Datarange*, *Entropy*, *Mean*, *Skewness* und *Variance* (GLOM) verfügbar. Ihre Herleitung ist in HARALICK et al. (1973), HARALICK & SHANMUGAM (1974), IRONS & PETERSEN (1981) und ZHANG et al. (2003) dokumentiert. Die Textur ist u. a. ein wichtiges Bildmerkmal zur Unterscheidung urbaner

von nicht-urbanen Gebieten (SHABAN & DIKSHIT 2001, THIEL et al. 2006a, 2006b). Die aufgeführten Texturmaße wurden für den blauen Kanal berechnet, weil dieser zur Erkennung urbaner Areale am besten geeignet ist (THIEL et al. 2006a:o. S., 2006b:o. S.). Nach Tests mit verschiedenen Filterformaten wurde die Größe des Filterfensters auf 7 x 7 Pixel festgelegt. Als *Greyscale Quantization Level* war 16 gewählt worden.

4.4 Aufbereitung der E-SAR-Daten

Die zur Verfügung stehenden E-SAR-Daten waren teilweise vorprozessiert, die Datensätze von 2000 und 2001 hatten allerdings verschiedene Prozessierungslevels. Folgende Bearbeitungen waren bereits für beide Aufnahmezeitpunkte durchgeführt worden:

1. Die Bewegungskompensation (*Motion Compensation*), bei der mit Hilfe der während des Fluges aufgezeichneten Daten zur Fluglage und geographischen Position die durch die Bewegungen des Flugzeuges bedingten geometrischen Verzerrungen korrigiert werden.
2. Die Prozessierung der SAR-Daten, wobei aus den Radarrohdaten Bilddaten generiert wurden.
3. Die radiometrische Kalibrierung der SAR-Daten zu β^0 -Daten.
4. Die Umwandlung von *Slant-Range*- in *Ground-Range*-Geometrie.
5. Die Erzeugung von Multilook-Bildern zur *Speckle*-Reduzierung mit vier *Looks*.
6. Die Koregistrierung und Geokodierung der Daten in UTM-Projektion, Zone 32 Nord mit Bezugsellipsoid und Datum WGS 84.

Die Daten von 2001 waren darüber hinaus weiter prozessiert worden und lagen als kalibrierte Rückstreukoeffizienten (σ^0 -Daten) vor, d.h. eine Einfallswinkelkorrektur war bereits angewandt worden. Bei den Daten von 2000 mussten die dazu notwendigen Prozesse noch ausgeführt werden.

4.4.1 Einfallswinkelkorrektur

In diesem Arbeitsschritt wird die systembedingt abnehmende Rückstreuintensität zwischen *Near Range* und *Far Range* sowie der Einfluss des lokalen Einfallswinkels auf die Rückstreuintensität durch die Berechnung des Radarrückstreukoeffizienten σ^0 bereinigt. Im Zuge dieser Korrektur ergibt sich ein von den Reliefeinflüssen unabhängiger Grauwert, der den Vergleich der Rückstreueigenschaften unterschiedlicher SAR-Aufnahmen mit verschiedenen Sensoren ermöglicht. Dabei wurde analog zu den bereits prozessierten Daten vorgegangen. Die Gleichungen sind in den Metadaten abgelegt. Danach berechnet sich der Rückstreukoeffizient σ^0 zu:

$$\sigma^0 [dB] = \beta^0 [dB] \times 10 \times \log_{10} \sin \theta \quad (4.1).$$

Dabei ist θ der lokale Einfallswinkel und β^0 die *Radar Brightness*, die folgendermaßen berechnet wird:

$$\beta^0 [dB] = 10 \times \log_{10} (\text{Pixelwert} + 32768)^2 - 60000 \quad (4.2).$$

Grund für den Helligkeitsgradienten in *Range*-Richtung ist einerseits die zunehmende räumliche Auflösung mit zunehmender Entfernung vom Sensor. Dadurch verringert sich die bestrahlte Fläche und somit die Stärke des am Sensor ankommenden Signals. Andererseits ist die Rückstreuung umgekehrt proportional zum lokalen Einfallswinkel. Daher werden Radarbilder mit zunehmender *Range*-Entfernung dunkler (LILLESAND et al. 2004:665). Zur Korrektur des Einflusses der lokalen Einfallswinkel wurde die Software Erdas genutzt. Im Einzelnen bedeutet dies zunächst den Import der Intensitätskomponente sowie der Datei mit den dazugehörigen lokalen Einfallswinkeln, die aus einem digitalen Geländemodell (DGM) abgeleitet worden sind. Die Daten müssen gespiegelt und mittels *Nearest Neighbor* resampelt werden. Damit die Datei mit den Einfallswinkeln weiterverwendet werden kann, muss diese durch 1.000 dividiert werden. Die in den Metadaten abgelegten Lageinformationen (Eckkoordinaten, Pixelkantenlänge, Projektion) müssen anschließend in allen Dateien entsprechend neu editiert werden. Danach erfolgt die Einfallswinkelkorrektur mit einem Modell zur Berechnung von σ^0 , der *Normalized Radar Cross Section*. Diese dimensionslose Größe charakterisiert diffus streuende Oberflächen und variiert mit Wellenlänge, Polarisierung, dielektrischen Eigenschaften und Depressionswinkel (PORCELLO et al. 1976:1306). Im Ergebnis entsteht ein Datensatz, in dem die aus den unterschiedlichen lokalen Einfallswinkeln resultierenden Grauwertdifferenzen berücksichtigt und mathematisch korrigiert sind. Trotz der Korrektur sind insbesondere SAR-Aufnahmen von flugzeuggetragenen Systemen durch einen signifikanten Helligkeitsübergang zwischen *Near Range* und *Far Range* gekennzeichnet, der sich dadurch begründet, dass aufgrund der geringen Flughöhe große Differenzen zwischen den Depressionswinkeln in *Near Range* und *Far Range* herrschen, die an gleichartigen Objekten zu unterschiedlichen Reflexionsmechanismen führen.

4.4.2 Multitemporale Speckle-Filterung

Die Software Gamma bietet u. a. eine Möglichkeit zur multitemporalen *Speckle*-Reduktion. Die dabei angewandte Form der multitemporalen Filterung ist die lineare Kombination von M koregistrierten Bildern des gleichen Gebiets, um M *Speckle*-reduzierte Bilder zu erhalten (QUEGAN & YU 2001:2377, QUEGAN et al. 2005:o. S.):

$$J_i = \frac{\sigma_i}{M} \sum_{j=1}^M \frac{I_j}{\sigma_j} \quad (4.3).$$

Dabei ist i die Dateinummer im Bereich $1, \dots, M$. M steht für die Anzahl der gefilterten Bilder, I_j bezeichnet die Intensität des Originalbildes i , J_i drückt die Intensität des gefilterten Bildes aus und σ_i bezeichnet den abgeschätzten mittleren Rückstreuoeffizienten in Bild i . Die Bestimmung basiert auf der Mittelung der Intensitäten in einem lokalen Fenster um jedes Pixel in jedem Bild (QUEGAN et al. 2005:o. S.).

Grundvoraussetzung für die Filterung der Radardaten ist, dass die zu filternden Daten möglichst genau koregistriert und ihre Bilddimensionen deckungsgleich sind. Als erstes wurden die in Dezibel (dB) vorliegenden Daten in lineare Daten transformiert.




Abb. 4.6: E-SAR-Daten von 2000 vor der multitemporalen Filterung (links) und danach (rechts) (R-G-B VV-VV-HH).

Anschließend wurde für jede Teilszene (*Northern* und *Central*) ein Bildausschnitt gewählt, der zu beiden Aufnahmezeitpunkten abgedeckt wurde. Als Resultat lagen acht Dateien vor, von denen jeweils vier deckungsgleich sind: Central-XHH von 2000, Central-XHH von 2001, Central-XVV von 2000 und Central-XVV von 2001 sowie Northern-XHH von 2000, Northern-XHH von 2001, Northern-XVV von 2000 und Northern-XVV von 2001. Danach wurden die Daten mit einem 5 x 5 Pixel großen Fenster im oben beschriebenen Multitemporalfilter gefiltert. Abschließend wurden die *Central*- und *Northern*-Bildstreifen jeweils für 2000 und 2001 mosaikiert und ein *Subset* des Untersuchungsgebiets gebildet. Alle weiteren Bearbeitungen der SAR-Daten erfolgten mit dB-Werten. In Abb. 4.6 ist zu erkennen, dass das Bild durch die Filterung kontrastreicher erscheint. Das Rauschen in homogenen Flächen ist deutlich vermindert, Objektkanten bleiben erhalten und werden z. T erst nach der Filterung sichtbar.

4.5 Ableitung von Textur aus den E-SAR-Daten

Die Ableitung der Textur erfolgte analog zur Texturberechnung der optischen Daten in Envi. Allerdings wurde die Textur nicht nur für einen Kanal berechnet, sondern jeweils für die HH- und VV-polarisierten Kanäle von 2000 und 2001. Aufgrund der unterschiedlichen Aufnahmezeitpunkte in September und April und der verschiedenen Polarisierungen, deren Effekt in Kapitel 2.1.5 beschrieben wurde, liefert jeder Kanal spezifische Texturinformationen, die gleichermaßen nützlich sein können. Insgesamt wurden die Texturmaße *Contrast*, *Correlation*, *Entropy*, *Dissimilarity*, *Homogeneity*, *Mean*, *Angular Second Moment* und *Variance* (GLCM) sowie *Datarange*, *Entropy*, *Mean*, *Skewness* und *Variance* (GLOM) für die vier Einzelkanäle berechnet. Grundlage waren die dB-Daten, gefiltert wurde mit einem 7 x 7 Pixel großen Fenster und einem *Greyscale Quantization Level* von 16. Mehrere Tests mit verschieden großen Filterfenstern waren für die Wahl der Filtergröße ausschlaggebend.

4.6 Aufbereitung der Referenzdaten

Die Linfos-Daten sind Ergebnis einer Biotop-Offenland-Kartierung. Die darauf basierenden Landnutzungsklassen sind in unterschiedlich detaillierten thematischen Komplexen abgelegt. Zum Zweck der Genauigkeitsanalyse müssen diese Klassen sinnvoll zusammengefasst werden. Zunächst wurden alle urbanen und speziell anthropogen geschaffenen Oberflächen des Level-1-Datensatzes zu einer Klasse urban und alle natürlichen Landnutzungsklassen zu nicht-urban zusammengefasst. Der resultierende Datensatz wurde bei der Genauigkeitsanalyse der Siedlungsmasken verwendet.

Die Lage der Linfos-Daten war nicht mit der der anderen Datensätze identisch. Deswegen wurden die Daten um einen konstanten Versatz von dreißig Meter nach Süden und fünf Meter nach Westen verschoben.

Die Realflächenkartierung lag in zwei Einzelteilen im PDF-Format vor und musste zusammengefügt und georeferenziert werden. Die Georeferenzierung erfolgte mit zehn Passpunkten per Bild-zu-Bild-Registrierung in Envi. Der RMSE betrug 5,22. Alle Wald- und Ackerflächen wurden maskiert und zusammen mit den Siedlungsflächen als *Shapefile* exportiert.

5 Ergebnisse

5.1 Segmentierung der Daten

Die Qualität der Segmentierung beeinflusst maßgeblich die Klassifikationsgüte (NEUBERT et al. 2006:o. S.). Die Wahl der Segmentierungsparameter in Definiens Professional 5 hängt stark von Bildinhalt und Klassifikationsziel ab. In der Literatur finden sich dementsprechend verschiedene Beispiele für die Wahl sowohl der Parameter als auch der Anzahl an Segmentierungslevels (z. B. HEROLD et al. 2002b, HOFMANN 2001, HOFMANN et al. 2006, SEILER et al. 2004). Aus diesem Grund müssen die Parameter mehr oder weniger iterativ gefunden werden. Gemäß der im Theorieteil beschriebenen Prozedur wurde eine *Multiresolution*-Segmentierung durchgeführt (BAATZ & SCHÄPE 2000). Wie bereits angedeutet, ist die Bebauung der Stadt Erfurt infolge einer langen Siedlungsgeschichte und dem daraus gewachsenen historischen Stadtzentrum sowie den durch verschiedene politische Systeme gesteuerten vielfältigen Stadtaus- und -umbaumaßnahmen äußerst heterogen. Viele Arbeiten über urbane Gebiete wurden am Beispiel nordamerikanischer Städte durchgeführt, die eine wesentlich kürzere Siedlungsgeschichte aufweisen und nicht selten in regelmäßigen geometrischen Strukturen angelegt sind. Derartige Siedlungsmuster können bei objektbasierten Klassifikationsansätzen verhältnismäßig leicht berücksichtigt werden. Das Untersuchungsgebiet in Erfurt ist demgegenüber äußerst unregelmäßig strukturiert und wesentlich komplexer aufgebaut, sodass auch eine größere Anzahl Objektlevel benötigt wird, um die zu klassifizierenden Objekte möglichst genau zu segmentieren. Da die Segmentierung und der Klassifikationsprozess aufeinander aufbauen und auch interaktiv gestaltet werden können, indem beispielsweise bereits klassifizierte Objekte aggregiert oder neu segmentiert werden, ist es nicht sinnvoll, mit starr vorgegebenen Segmentierungslevels zu arbeiten. Die drei verschiedenen Ansätze – auf optischen Daten basierend, auf Radardaten stützend und auf der synergetischen Anwendung ruhend – wurden einzeln abgearbeitet. Im ersten Ansatz wurde das gesamte Untersuchungsgebiet zunächst in vier Levels segmentiert. Die Parameter dieser initialen Segmentierung sind in Tab. 5.1 festgehalten. Der *Scale*-Parameter für den ersten Level ist sehr klein gewählt, um kleinere Objekte, wie Swimmingpools und Wochenendhäuser zu erfassen und Bäume von Rasenflächen unterscheiden zu können. Das Vorhandensein von Pools kann z. B. im Falle einer Landnutzungsableitung ein markantes Merkmal sein. Darüber hinaus sind sie spektral gut zu charakterisieren (Abb. 5.8). Im zweiten und dritten Level sollten vor allem größere Objekte mit charakteristischen Formeigenschaften identifiziert werden.

Tab. 5.1: Parameter für die initiale Segmentierung der QuickBird-Daten.

Level	Eingangskanäle	Scale-Parameter	Shape	Compactness	Verwendung
1	Multispektralkanäle 1-4	10	0,3	0,6	Landbedeckung
2	Multispektralkanäle 1-4	30	0,3	0,6	Landbedeckung
3	Multispektralkanäle 1-4	80	0,3	0,6	Landbedeckung, Wolkenmaske, Wolkenschattenmaske
4	Multispektralkanäle 1-4	120	0,3	0,6	Siedlungsmaske

Tab. 5.2: Parameter für die Segmentierung der Radardaten.

Level	Eingangskanäle	Scale-Parameter	Shape	Compactness	Verwendung
1	HH & VV 2000, 2001	10	0,1	0,3	Landbedeckung
2	HH & VV 2000, 2001	40	0,1	0,3	Siedlungsmaske, Landbedeckung
3	HH & VV 2000, 2001 auf Basis der Siedlungsmaske	80	0,1	0,6	Landbedeckung

Zudem wurden im dritten Level Wolken- und Wolkenschattengebiete maskiert. Der vierte Level diente ausschließlich der Unterscheidung von urbanen und nicht-urbanen Gebieten und wurde nicht zur Landbedeckungsklassifikation genutzt. Im Zuge der Landbedeckungsklassifizierung erfolgte die weitere Segmentierung einzelner Klassen, die im entsprechenden Kapitel näher beschrieben ist.

Die Segmentierung der Radardaten erwies sich als schwierig, weil selbst eine visuelle Analyse des Ergebnisses nur bedingt möglich ist und in der Literatur nur wenige Beispiele für die Segmentierung von Radardaten mit Definiens dokumentiert sind (z. B. WEISE 2002). Allerdings sind verschiedene Objekte in den hoch auflösenden X-Banddaten sehr gut zu erkennen (z. B. einige freistehende Bäume, Wasserflächen, Gebäude, Sportplätze oder Straßen). Die Wahl der Segmentierungsparameter erfolgte iterativ, indem versucht wurde, diese Objekte möglichst genau zu segmentieren. Eine Unterscheidung von Bäumen und Grünland war auch hier erwünscht, um eine große Klassentiefe zu erhalten. Bei einer späteren Landnutzungsklassifizierung können beispielsweise durch die unterschiedliche Komposition dieser Klassen Parks von unbebauten Grünflächen unterschieden werden. Eine Vergrößerung des *Scale*-Parameters hat bei den Radardaten größere Auswirkungen als bei den QuickBird-Daten – die Segmentgröße erhöht sich bereits bei verhältnismäßig geringfügig wachsenden *Scale*-Parametern deutlich. Die Wahl der Klassen bestimmt maßgeblich, wie viele Segmentierungsniveaus schließlich notwendig und angemessen sind. Im vorliegenden Beispiel wurden drei Level ausgewiesen, wobei im zweiten Level die Siedlungsmaske erstellt und der dritte Level auf Basis der bereits als Siedlung ausgewiesenen Objekte eigens für die Landbedeckungsklassifizierung segmentiert wurde. Die Parameter für die Segmentierung sind in Tab. 5.2 aufgeführt.

Die Segmentierung zur synergetischen Anwendung von optischen und Radardaten erfolgte auf Basis der optischen Kanäle, da diese aufgrund des Aufnahmeprinzips und der höheren räumlichen Auflösung eine bessere Segmentierung urbaner Objekte mit genauerer Erfassung der Kanten erlauben. Die E-SAR-Eingangskanäle wurden für die Segmentierung nicht berücksichtigt. Die Segmentierungsparameter für die initiale Segmentierung sind daher dieselben wie bei den optischen Daten (vgl. Tab. 5.1).

Die Überprüfung der Segmentierungen basiert im Wesentlichen auf visuellen Vergleichen. Die Wahl der Segmentierungsparameter erfolgte in allen Fällen iterativ, wobei für die Teilaufgabe der synergetischen Anwendung die Erfahrungen aus der Auswertung der optischen Daten genutzt werden konnten.

5.2 Siedlungsmasken

5.2.1 Siedlungsmaske auf Basis von QuickBird

Alle Wälder und landwirtschaftlichen Nutzflächen sollten im Zuge der Diplomarbeit als nicht-urbane Gebiete erkannt werden, um von der Analyse der urbanen Objektklassen ausgeschlossen zu werden. Es handelt sich dabei zwar ebenfalls um anthropogen gestaltete Oberflächen. Sie können aber als naturnah angesehen werden, während die typisch urbanen Oberflächen wie Straßen oder Gebäude meist aus Materialien bestehen, die in der Natur nicht vorkommen. Darüber hinaus sind Parks und Seen aufgrund ihrer Erholungsfunktion als urbane Flächen anzusehen. Eine gute Trennbarkeit von urbanen und nicht-urbanen Flächen wird dann erreicht, wenn die Texturwerte der (quasi-) natürlichen Oberflächen, wie Wälder oder Äcker, gegenüber denen der anthropogenen Klassen sehr klein sind (THIEL et al. 2006b:o. S.). Dies wird in der vorliegenden Arbeit durch die Texturmaße *Entropy* (GLCM) und *Datarange* (GLOM) des blauen Kanals am besten erreicht (Abb. 5.1). Die Entropie ist das kontrastreichste Texturmaß zur Differenzierung von natürlichen und bebauten Flächen, allerdings erscheinen teilweise auch unbewachsene Ackerflächen texturreich. Im *Datarange* sind auch diese Flächen verhältnismäßig texturarm (vgl. rote Kreise Abb. 5.1). Um kleinräumige Texturvarianzen nicht zu stark zu berücksichtigen, musste ein großer *Scale*-Parameter zur Segmentierung möglichst großer Objekte gewählt werden. Am besten geeignet war ein *Scale*-Parameter von 120 bei einem *Shape*-Faktor von 0,3 und einer *Compactness* von 0,6 (Tab. 5.1). Zunächst wurden drei urbane Klassen ausgewiesen: Die erste hatte einen Schwellenwert für die Entropie von mindestens 0,15 und für den *Datarange* von mindestens 9,35 und umfasst nahezu alle anthropogenen Oberflächen. Die zweite urbane Klasse wurde angelegt, um vegetationsreiche, dünn bebaute Wohngebiete in Stadtrandlage sowie städtische Grün- und Kleingartenanlagen zu erfassen und von angrenzendem Wald zu separieren. Sie ist durch hohe Texturwerte im *Datarange* ($> 7,5$) bei geringen Entropie-




Abb. 5.1: Die Texturmaße *Datarange* (links) und *Entropy* (rechts) des blauen Kanals zur Identifikation urbaner Gebiete (hell). Rot umrandet sind nicht-urbane Flächen, die nur durch die Berücksichtigung beider Maße ausgeschlossen werden können.



Abb. 5.2: Siedlungsmaske auf Basis der optischen Daten. Links die Originaldaten (R-G-B 3-2-1), rechts überlagert mit der Siedlungsmaske.

werten ($< 0,15$) gekennzeichnet. Zusätzlich wurde ein Schwellenwert für den NDVI ($< 0,83$) angewandt. Die dritte urbane Klasse sollte insbesondere Bahnflächen erfassen. Sie hat eine geringe *Brightness* (< 17), einen Mittelwert für den *Datarange* von mehr als fünf und einen NDVI kleiner 0,4. Die *Brightness* berücksichtigt ausschließlich die Multispektralkanäle. Anschließend wurden die drei Klassen zusammengefasst. Wie in Abb. 5.1 ersichtlich, existieren auch innerhalb der urbanen Gebiete diverse naturnahe Flächen, die dementsprechend sehr geringe Texturwerte aufweisen und deswegen im Texturbild dunkel erscheinen. Bei der Ausweisung urbaner Gebiete entstehen dadurch keine homogenen Flächen, sondern vielmehr ein Mosaik aus urbanen und nicht-urbanen Bereichen. Die objektbasierte Verfahrensweise erlaubt die Reklassifizierung über Lagebeziehungen, sodass nicht-urbane Gebiete, die vollständig von urbanen Gebieten eingeschlossen sind, als urban reklassifiziert werden können. Die genaue Einstellung der Parameter zur Reklassifizierung – *Shapeindex*, *Distance-to* und *Relative-border-to-urban* – muss an die jeweilige Szene angepasst werden und ist daher nur prinzipiell auf andere Untersuchungsgebiete anwendbar. Im vorliegenden Fallbeispiel wurden zunächst alle nicht-urbanen Gebiete mit weniger als vier Nachbarn derselben Klasse zusammengefasst und anschließend diejenigen mit einer Distanz zu nicht-urban größer drei Meter der Klasse urban zugeordnet. Danach erfolgte die Zuordnung aller verbliebenen nicht-urbanen Gebiete zur Klasse urban über die Funktion *Relative-border-to-urban* für Werte größer 0,9. Um zu vermeiden, dass einzelne Landwirtschafts- oder Waldparzellen, die lediglich von als urban erkannten Straßen eingeschlossen sind, ebenfalls reklassifiziert werden, können die Straßen vor der Reklassifizierung über den *Shapeindex* (> 4) bei gleichzeitiger *Relative-border-to-urban* kleiner eins einer neuen Unterklasse von urban zugeordnet werden. Somit ist gewährleistet, dass nur innerstädtische naturnahe Flächen, wie Parks, als urban reklassifiziert werden. Die an Straßen grenzenden Ackerflächen bleiben nicht-urban. Die Siedlungsmaske ist in Abb. 5.2 im Vergleich zur Originalszene zu sehen.

5.2.2 Siedlungsmaske auf Basis von E-SAR

Zur Erstellung der Siedlungsmaske für die Radardaten erwies sich die Textur ebenfalls als gut geeignet. Nach verschiedenen Testdurchläufen konnte festgestellt werden, dass der *Datarange* (GLOM) im HH-polarisierten Kanal urbane Strukturen am besten durch



Abb. 5.3: Textur zur Maskierung urbaner Gebiete (hell): E-SAR HH2001 *Datarange* (GLOM).

hohe Texturwerte charakterisiert (Abb. 5.3). Die Trennung zwischen urban und nicht-urban war bei möglichst grober Segmentierung am besten zu realisieren. Zur Anwendung kam ein *Scale*-Parameter von 40 bei einem *Shape*-Faktor von 0,1 und einer *Compactness* von 0,3. Die Ausweisung einer urbanen Klasse erfolgte über einen Schwellenwert von 8,2 im *Datarange* des HH-Kanals von 2001. Die Szene von 2001 wurde gewählt, um die im Bau befindliche Umgehungsstraße im Osten der Stadt erfassen zu können. Wie auch bei den optischen Daten blieben texturarme innerstädtische Areale wie Parks oder

Bahngleise unberücksichtigt. Alle nicht-urbanen Gebiete mit weniger als drei Nachbarobjekten der Klasse nicht-urban wurden über die *Merge*-Funktion im *Process Tree* zusammengefasst, um die innerstädtischen texturarmen Gebiete zu Einzelobjekten zu aggregieren, die sich leichter durch die Beschreibung ihrer Topologie zur Klasse urban reklassifizieren lassen. Über die *Distance-to*-Funktion wurden alle isoliert gelegenen nicht-urbanen Gebiete mit einer Mindestentfernung von fünf Metern zu nicht-urbanen Flächen einer Unterklasse von urban zugewiesen. Auf diese Weise konnte vermieden



Abb. 5.4: Siedlungsmaske auf Basis der E-SAR-Daten. Links die Originaldaten (R-G-B HH2001-VV2000-HH2000), rechts überlagert mit der Siedlungsmaske.

werden, dass aneinandergrenzende nicht-urbane Flächen als urban reklassifiziert werden. Die verbliebenen falsch zugeordneten innerstädtischen Gebiete wurden über die *Relative-border-to*-Funktion ab einem Schwellenwert größer 0,89 einer weiteren Unterklasse von urban zugewiesen. Einige große, zusammenhängende Ackerflächen dieser Klasse, die komplett von urbanen Flächen (z. B. Straßen) eingeschlossen waren, wurden über einen Flächenschwellenwert von 24.000 m² zu nicht-urban reklassifiziert. Die urbanen Unterklassen wurden schließlich der Klasse urban zugewiesen. In Abb. 5.4 ist die Siedlungsmaske im Vergleich zu den Ausgangsdaten dargestellt.

5.2.3 Siedlungsmaske durch die synergetische Nutzung von QuickBird und E-SAR

Die Unterscheidung der urbanen Klasse von der nicht-urbanen folgte den Erfahrungen aus den Anwendungen mit nur einem Datensatz und geschah auf Grundlage eines großen *Scale*-Parameters. Die Parameter wurden analog zu den optischen Daten gewählt. Das Prinzip bei der separaten Erstellung der Siedlungsmasken war, eindeutig als urban identifizierbare Gebiete der Klasse urban zuzuordnen und anschließend alle eingeschlossenen als nicht-urban erkannten urbanen Flächen zu reklassifizieren. Unter der Annahme, dass die Basisklassen der beiden gesonderten Siedlungsmasken ausschließlich eindeutig ausweisbare urbane Objekte repräsentieren, wurden diese bei der synergetischen Anwendung von optischen und Radardaten ebenfalls als Basisklassen ausgewiesen. So wurde zusätzlich ersichtlich, welche Flächen nur mit einer der beiden Methoden ohne Reklassifizierung detektierbar sind. Demnach ergab sich eine urbane Klasse auf Grundlage der *Entropy* (ab einem Schwellenwert größer 0,15) und des *Datarange* (ab einem Schwellenwert größer 9,35) des blauen Kanals von QuickBird. Die zweite urbane Klasse nutzte den Schwellenwert größer 8,2 im *Datarange* des HH-polarisierten Kanals von 2001 von E-SAR. Auf diese Weise konnten auch diejenigen urbanen Gebiete erfasst werden, die zwischen den Aufnahmezeitpunkten neu entstanden sind. Hierbei muss darauf hingewiesen werden, dass die Segmentierung auf den



Abb. 5.5: Siedlungsmaske durch synergetische Nutzung optischer und SAR-Daten. Links optische Daten (R-G-B 3-2-1), rechts überlagert mit der Siedlungsmaske.

optischen Daten basiert und somit die Rückstreuensignale auf Objektbasis in den Radarkanälen andere Eigenschaften haben können als bei einer Segmentierung, die ausschließlich auf Radardaten beruht. Im nächsten Schritt wurden die verbleibenden innerstädtischen Gebiete mit weniger als vier Nachbarobjekten der Klasse nicht-urban zusammengefasst. Diejenigen Objekte der Klasse nicht-urban, die vor allem im optischen Bereich durch geringe Textur gekennzeichnet sind, wurden einer Unterklasse von urban zugeordnet. Zur Beschreibung dienten der *Datarange* des HH-polarisierten E-SAR-Kanals von 2000 (zwischen den Schwellenwerten 7,8 und 9), der *Datarange* von QuickBird (Schwellenwert kleiner 8) und der NDVI (Schwellenwert kleiner 0,8). Danach wurden die wenigen übrigen intra-urbanen Gebiete, die noch nicht einer der urbanen Klassen zugewiesen werden konnten, mit der Funktion *Distance-to-nicht-urban* größer 0 als urban klassifiziert. Dabei fand für die Fläche ein Schwellenwert von kleiner 25.000 m² Anwendung, um eingeschlossene Ackerflächen ausschließen zu können. Das Ergebnis ist in Abb. 5.5 im Vergleich zu den optischen Daten abgebildet.

5.2.4 Vergleich und Bewertung der Ergebnisse

Die drei Produkte wurden statistisch ausgewertet, visuell überprüft und qualitativ bewertet. Die Überprüfung der Genauigkeit der Siedlungsmasken erfolgte im GIS (Geographisches Informationssystem) mit den Softwareprodukten ArcGIS und ArcView. Dort wurden alle Ergebnisse derart miteinander verschritten, dass alle Datensätze exakt dasselbe Gebiet abdecken. Die zu einer Klasse gehörenden Segmente wurden über den


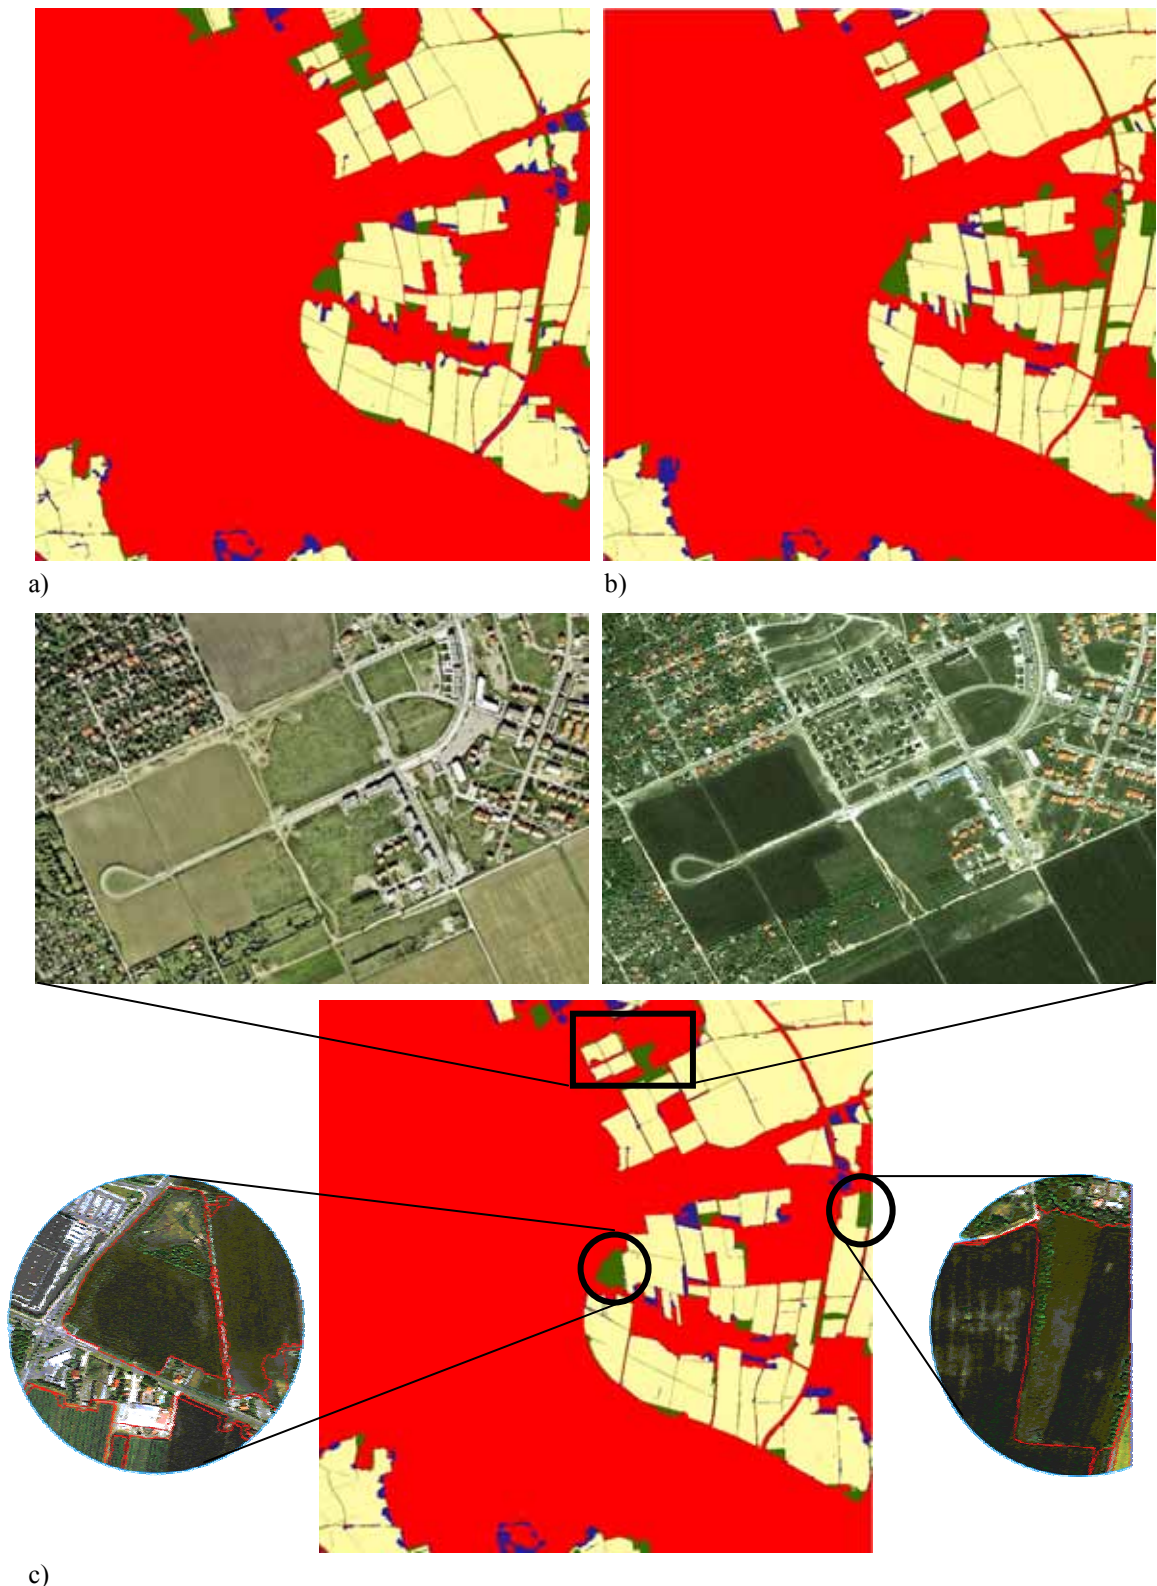


Abb. 5.6: Referenzdaten und Fernerkundungsprodukte im Vergleich (Siedlungsflächen sind rot eingefärbt): a) Realflächenkartierung von 2000-2005, b) Linfos-Daten von 1993-1994, c) Differenz aus Realflächenkartierung und Linfos-Daten (neu entstandene urbane Flächen sind grün eingefärbt), d) QuickBird-Produkt aus Daten von 2005, e) E-SAR-Produkt aus Daten von 2000 und 2001 und f) Produkt aus der synergetischen Verwendung von QuickBird und E-SAR.

Dissolve-Befehl zusammengefasst und der jeweilige Flächenanteil der Klassen urban und nicht-urban berechnet. Die Abb. 5.6 zeigt die Siedlungsmasken im direkten Vergleich. Die betrachtete Gesamtfläche beträgt etwa 24 km². Interessant ist in diesem Zusammenhang die Frage nach der Art der falsch zugewiesenen Flächen. Das Differenzbild zwischen der Realflächenkartierung von 2000-2005 und den Linfos-Daten von 1993-1994 zeigt deutlich die in dieser Zeitspanne neu entstandenen urbanen Flächen (Abb. 5.6, grüne Flächen). Diese umfassen die neu errichteten Gewerbegebiete im Osten der Stadt (Abb. 5.6 c, Bildmitte und rechter Bildrand), die vierspurige Umgehungsstraße sowie neue Eigenheimsiedlungen (Bildmitte oben). Diese Gebiete unterlagen demnach kontinuierlich Umgestaltungen, sodass hier aufgrund der unterschiedlichen Aufnahmezeitpunkte verschiedene Ergebnisse recht wahrscheinlich sind. Die schwarz umkreisten Gebiete in Abb. 5.7 sind in keinem der Fernerkundungsprodukte als urban erkannt worden. Es handelt sich hierbei um Grünflächen, die lediglich aufgrund ihrer Funktion als urbane Fläche in der Realflächenkartierung abgelegt sind. Sie sind in Fernerkundungsdaten mit Texturmaßen nicht als solche fassbar. Die Größe der beiden Flächen beträgt etwa 7 ha bzw. 3,6 ha. Alle weiteren falsch klassifizierten Gebiete umfassen meist Grünflächen am Rand von Siedlungen oder Straßen. Insbesondere in der QuickBird-Szene betreffen diese Fehlklassifikationen Grünflächen. Sie sind texturarm und auch über Ratios wie den NDVI kaum in urban und nicht-urban trennbar. Falsche Zuordnungen treten daher vor allem im Übergangsbereich zwischen städtischen Grünflächen und anschließenden Land- oder Forstwirtschaftsflächen auf. Diese Übergänge werden mit den Radardaten wesentlich besser abgezeichnet (vgl. Abb. 5.7 a und b). Der größte Teil der nicht erkannten urbanen Gebiete befindet sich im Bereich der neu entstandenen Eigenheimsiedlung im Norden des Untersuchungsgebiets (Abb. 5.7 c, schwarzer Kasten). Die Abweichung von der Referenz ist an dieser Stelle primär durch den zeitlichen Versatz zwischen E-SAR-Befliegung und Referenzdatengewinnung bedingt. Da die genaue *Ground Truth* zum Zeitpunkt der E-SAR-Befliegung mit den vorhandenen Referenzdaten nicht rekonstruierbar ist, wurde der Fehler durch Vergleich mit dem Luftbild in Google Maps ermittelt. Die Fläche der betreffenden Segmente, die in E-SAR nicht erkannt werden konnten, beträgt etwa 9,9 ha. Sie wurden von der Genauigkeitsanalyse aller Produkte ausgeschlossen. Bei der synergetischen Erzeugung einer Siedlungsmaske mit der beschriebenen Vorgehensweise erfolgte eine Synthese der Eigenschaften der getrennt erstellten Siedlungsmasken. Dadurch wurden einerseits Verbesserungen erzielt, andererseits aber auch die Fehler weitervererbt. Es handelt sich dabei jedoch größtenteils um Gebiete, die je nach Definition sowohl als urban als auch als nicht-urban angesehen werden können – zumeist naturnahe Flächen mit einer speziellen Funktion, die sie als urbane Gebiete kennzeichnen. Einige der nicht erkannten urbanen Objekte sind Wege zwischen den Landwirtschaftsflächen, die einen Grenzfall von urbaner Fläche darstellen. Sie können gegebenenfalls mit kleineren Segmentierungslevels als separate Objekte erfasst und über Formparameter als urbane Flächen beschrieben werden. Dies war hier jedoch nicht beabsichtigt.



c)

Abb. 5.7: Differenzbilder aus der Realflächenkartierung und den Fernerkundungsprodukten. Rot dargestellt sind Gebiete, die in beiden Produkten als urban klassifiziert sind, gelb diejenigen, die in beiden Produkten als nicht-urban klassifiziert wurden, blau diejenigen, die in der Referenz als nicht-urban abgelegt sind, aber als urban klassifiziert wurden und grün diejenigen urbanen Gebiete, die nicht als solche erkannt wurden: a) Realflächenkartierung und E-SAR-Produkt, b) Realflächenkartierung und QuickBird-Produkt und c) Realflächenkartierung und synergetisch erzeugtes Produkt. In c) sind darüber hinaus urbane Grünflächen gezeigt, die mit keiner Methode als urban erkannt wurden (Kreise) sowie eine Eigenheimsiedlung, die zwischen 2000 (Luftbild in Google Maps, links) und 2005 (QuickBird, rechts) entstanden ist (Rechteck).

Tab. 5.3: Konfusionsmatrizen zwischen der Realflächenkartierung und den aus Fernerkundungsdaten ermittelten Siedlungsmasken.

		Fläche [ha]			Prozent		
		Realkartierung		Summe	Realkartierung		Summe
	urban	nicht-urban	urban		nicht-urban		
QuickBird	urban	1.676	35,7	1.711,7	95,4	5,5	71,2
	nicht-urban	80,7	611,8	692,5	4,6	94,5	28,8
Summe		1.756,7	647,5	2.404,2	100	100	100
Gesamtgenauigkeit: 95,16 % Kappakoeffizient: 0,88							
E-SAR	urban	1.681,7	41,4	1.723,1	95,7	6,4	71,7
	nicht-urban	75	606,1	681,1	4,3	93,6	28,3
Summe		1.756,7	647,5	2.404,2	100	100	100
Gesamtgenauigkeit: 95,16 % Kappakoeffizient: 0,88							
Synergie	urban	1.705,6	49,7	1.755,3	97,1	7,7	73,0
	nicht-urban	51,1	597,8	648,9	2,9	92,3	27,0
Summe		1.756,7	647,5	2.404,2	100	100	100
Gesamtgenauigkeit: 95,81 % Kappakoeffizient: 0,89							

Die Klassifikationsgenauigkeiten wurden in einer Konfusionsmatrix (CONGALTON 1991:36) zusammengefasst (Tab. 5.3). In der vertikalen Spalte „Summe“ der Tab. 5.3 ist der Flächenanteil der einzelnen Datensätze jeweils in absoluten Werten und prozentual aufgeführt. In der horizontalen Spalte „Summe“ ist der Flächenanteil von urban und nicht-urban der Realkartierung ablesbar. Ferner ist der Tab. 5.3 zu entnehmen, wie viel urbane bzw. nicht-urbane Fläche richtig erkannt wurde und wie viel fälschlicherweise einer der beiden Klassen zugeordnet wurde. Auf Basis der QuickBird-Daten wurden so etwa 35,7 ha als urban erkannt, die laut Realflächenkartierung zu nicht-urban zu rechnen sind, und etwa 80,7 ha als nicht-urban klassifiziert, die urban sind. Zudem erfolgte die Berechnung der Gesamtgenauigkeit, die sich aus dem Quotienten der richtig klassifizierten Fläche und der Gesamtfläche ergibt (FOODY 2002:188):

$$\text{prozentual_korrekt} = \frac{\sum_{i=1}^r x_{ii}}{N} \times 100 \quad (5.1).$$

Dabei ist r die Anzahl an Reihen in der Konfusionsmatrix, x_{ii} ist der Wert in Reihe i und Spalte i und N ist die Gesamtanzahl an Referenzpixeln oder die Gesamtfläche. Der Kappakoeffizient κ (COHEN 1960) berechnet sich aus dem Produkt aller Pixel (N) und den richtig klassifizierten Pixeln (x_{ii}), die in einer Konfusionsmatrix diagonal von links oben nach rechts unten angeordnet sind, minus den summierten Produkten aus den *Ground-Truth*-Pixeln einer Klasse und den klassifizierten Pixeln dieser Klasse in allen Klassen ($x_i + x_{+i}$), geteilt durch das Quadrat der Gesamtpixelanzahl minus den summierten Produkten aus den *Ground-Truth*-Pixeln einer Klasse und den klassifizierten Pixeln dieser Klasse in allen Klassen (CONGALTON 1991:40, FOODY 2002:188, RSI 2003:606):

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (5.2).$$

Er hat einen Wertebereich von -1 bis 1 und gilt als aussagekräftiger als die Gesamtgenauigkeit (FITZGERALD & LEES 1994:368).

In Tab. 5.4 sind die Genauigkeiten aller Produkte für jede Klasse aufgeführt. Wie Tab. 5.4 ferner zeigt, sind nur bei der synergetisch erzeugten Siedlungsmaske alle Genauigkeiten größer als 90 %. Es werden allerdings bei der synergetischen Nutzung von E-SAR- und QuickBird-Daten mehr nicht-urbane Flächen als urban erkannt als bei der separaten Verwendung der Daten. Insgesamt sind die Genauigkeiten für alle drei Produkte sehr hoch. Ein abschließendes Urteil lässt sich nur unter dem Vorbehalt treffen, dass die Daten mehrere Jahre auseinander liegen. Gemäß den Statistiken in Tab. 5.3 und 5.4 ist die Genauigkeit von E-SAR- und QuickBird-Produkt etwa dieselbe. Das Synergieprodukt weist eine geringfügig größere Gesamtgenauigkeit und einen minimal höheren Kappakoeffizienten auf (Tab. 5.3). Durch die synergetische Anwendung können insbesondere in Übergangsbereichen Verbesserungen erzielt werden. Die Verwendung zeitnah aufgenommener Daten verspricht großes Potential zur synergetischen Nutzung der Daten. Als alternative Methode zur Ausweisung der Siedlungsflächen kann in einem *Bottom-up*-Ansatz auf der Basis einer Landbedeckungs- oder Landnutzungs-klassifikation eine Einteilung in urban und nicht-urban erfolgen. Die Erstellung von Siedlungsmasken auf Grundlage von Textur erwies sich als geeignete Methode. In einem objektbasierten Ansatz konnte durch die Berücksichtigung kontextueller Zusammenhänge die inhaltliche Verknüpfung städtischer naturnaher Flächen zu urbanen Räumen hergestellt werden.

Tab. 5.4: Klassifikationsgenauigkeit der Siedlungsmasken.

		Commission [%]	Omission [%]	Hersteller- genauigkeit [%]	Nutzer- genauigkeit [%]
QuickBird	urban	2,1	4,6	95,4	97,9
	nicht urban	11,6	5,5	94,5	88,4
E-SAR	urban	2,4	4,3	95,7	97,6
	nicht urban	11,0	6,4	93,6	89,0
Synergie	urban	2,8	2,9	97,1	97,2
	nicht urban	7,9	7,7	92,3	92,1

5.3 Objektbasierte Landbedeckungsklassifikation der optischen Daten

Im Untersuchungsgebiet befinden sich kleine Areale, die von Wolken bzw. Wolken-schatten bedeckt sind. Im Gegensatz zu den informationslosen Radarschatten sind aus den Schattenflächen optischer Daten mitunter Informationen über die Landbedeckung zu gewinnen. Die Reflexion der einzelnen Objekte ist allerdings enorm reduziert, sodass nur aufwendige Bildverarbeitungstechniken die Extraktion der verschiedenen Klassen ermöglichen (MADHAVAN et al. 2004, ZHAN et al. 2005). Ein nützliches Maß ist der

NDVI, da infolge der Ratiobildung Beleuchtungsunterschiede ausgeglichen werden (ALBERTZ 2001:219). Auf diese Weise können Vegetationsflächen in Wolkenschatten gut bestimmt werden. Wolken sind indes für optische Sensoren praktisch undurchdringlich und hinsichtlich einer Klassifikation informationslos. Aus diesen Gründen wurde für die wolkenbedeckten sowie die Wolkenschattengebiete eine Maske erstellt. Die maskierten Wolken- und Wolkenschattengebiete waren von der weiteren Bearbeitung ebenso ausgeschlossen wie die nicht-urbanen Gebiete.

5.3.1 Wolken- und Wolkenschattenmaske

Die Definition von Wolken- und Wolkenschattengebieten erfolgte im dritten Level der initialen Segmentierung. Wolken, als auffallend helle Gebilde, können spektral leicht durch Schwellenwerte für den Mittelwert des blauen (> 30) und des nahinfraroten Kanals (> 70) beschrieben werden. Um Fehlklassifikationen mit hellen Gebäuden und Brachflächen zu vermeiden, wurden zusätzlich für den Mittelwert der Entropie ($< 0,65$) und die Standardabweichung des *Datarange* (< 5) Schwellenwerte festgelegt. Wolkenschattengebiete haben eine sehr geringe Reflexion im blauen (5 - 10), im grünen (< 14) und im nahinfraroten Kanal (< 38) sowie eine geringe Standardabweichung im *Datarange* ($< 3,6$). Mit dieser Klassenbeschreibung wurden auch einige andere Schattengebiete von Gebäuden oder Baumreihen erfasst. Um diese meist lang gestreckten Areale auszuschließen, wurden alle als Wolkenschatten erkannte Flächen mit einem *Length/Width*-Ratio kleiner als 3,5 im *Process Tree* vereinigt. Alle Wolkenschattengebiete mit einer Fläche kleiner als ein Schwellenwert von 4.000 m² wurden anschließend zu *unclassified* reklassifiziert. Die Qualität wurde ausschließlich visuell geprüft.

5.3.2 Landbedeckung

Für die Landbedeckungsklassifizierung wurde ein hierarchisches Regelwerk entwickelt, dass die Klassifizierung der visuell wahrnehmbaren Objektklassen ermöglichen soll. Um einen Überblick zu gewinnen, welche Eigenschaften dazu geeignet sind, diese zu definieren, musste eine Möglichkeit gefunden werden, um die vielfältigen Eigenschaften aller Klassen im direkten Vergleich zu visualisieren. Deswegen wurden alle Segmentierungslevel als *Shapefiles* exportiert und in ArcView den Bilddaten überlagert. So konnten in allen Levels Beispielsegmente für verschiedene Landbedeckungsklassen gesucht werden. Deren Eigenschaften wurden tabellarisch abgespeichert, um in Diagrammen veranschaulicht werden zu können. Die Visualisierung diente in erster Linie der Orientierung, welche Eigenschaften eine Klasse charakterisieren. Die genaue Parametereinstellung kann dann in Definiens über den *Sample View* und den *Feature View* vorgenommen werden. In Abb. 5.8 sind die spektralen Eigenschaften der wichtigsten Landbedeckungsklassen dargestellt, die in der QuickBird-Szene erkennbar sind, sowie die Standardabweichungen in den einzelnen Kanälen. Vegetation, Pools, helle Dächer und rote Dächer haben charakteristische Reflexionskurven, die sich relativ deutlich von denen der anderen Klassen unterscheiden. Demgegenüber sind die Reflexionskurven von Schatten und Wasser sowie von grauen Dächern und Straßen

praktisch identisch. Bei letzteren ist die Ursache darin zu sehen, dass die Oberflächen aus gleichen Materialien bestehen. Die Reflexionskurven aller anderen Klassen haben einen ähnlichen Verlauf und können daher auch nur bedingt über Ratios differenziert werden. Die Schwankung des Wertebereichs in den einzelnen Kanälen aller Klassen führt zu ausgeprägten Überschneidungen, so dass auf Basis der spektralen Eigenschaften eine Trennung dieser Klassen nicht möglich ist. Erschwerend erweist sich die Tatsache, dass einige Klassen keinen kennzeichnenden Formenschatz aufweisen und nur über Ausschlussverfahren separiert werden können.

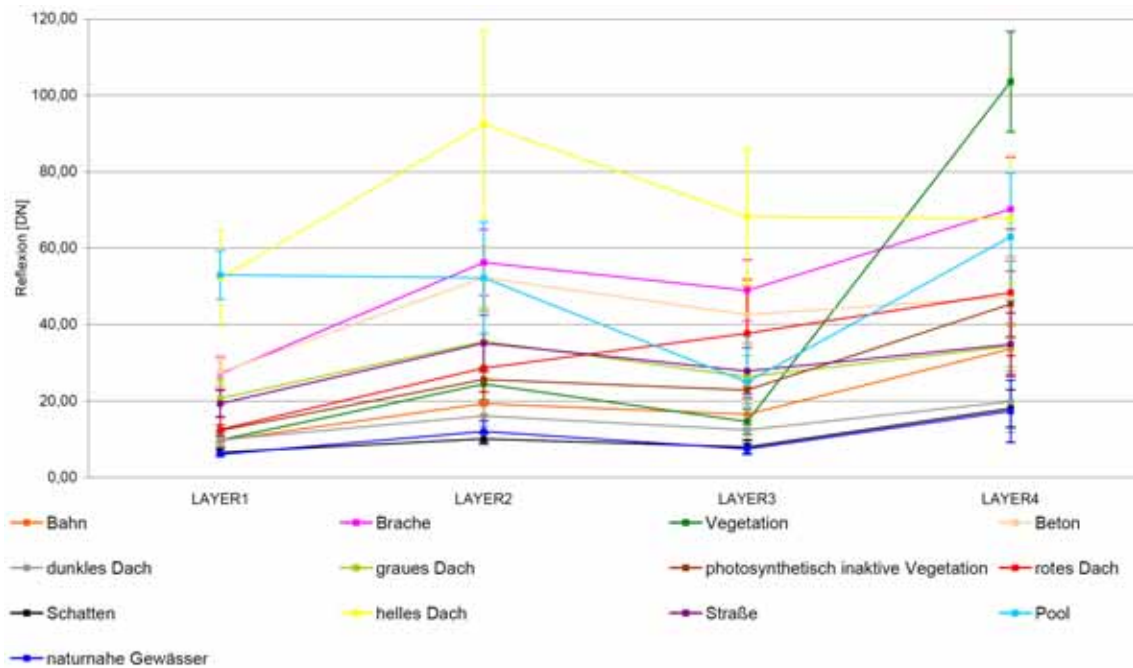


Abb. 5.8: Spektrale Eigenschaften der visuell erkennbaren Landbedeckungsklassen in der QuickBird-Szene. Die Angabe der Standardabweichung zeigt die spektrale Überschneidung der Klassen.

In einer initialen Segmentierungssequenz wurden drei Levels zur Landbedeckungsklassifikation erstellt, ein vierter diente ausschließlich der Abgrenzung des urbanen Raums (Tab. 5.1). Einige Klassen sind hinsichtlich ihrer spektralen Eigenschaften eindeutig zu beschreiben: Vegetation ist über einen Schwellenwert des NDVI von allen anderen Klassen zu differenzieren, Pools haben eine besonders hohe Reflexion im blauen Kanal sowie ein sehr geringes Ratio von rotem und grünem Kanal, und der durchgängig ansteigende Verlauf der Reflexionskurve von roten Flächen ist durch Ratios gut definierbar. Im ersten Level wurden deswegen vor allem die auf Basis der spektralen Information unterscheidbaren Klassen erfasst. Andere Klassen überschneiden sich spektral und müssen daher ähnlich einem Entscheidungsbaum schrittweise ausgeschlossen werden. Dabei gehen die Vorteile der *fuzzy* Klassenzuweisung verloren, indem ein Objekt entweder der einen Klasse zugeordnet wird oder nicht. Auf diese Weise konnten Brachflächen ausgewiesen werden. Zudem wurde eine Schattenklasse definiert. Die verbleibenden Gebiete – Straßen, Gebäude mit grauen Dächern, Bahnflächen und photosynthetisch inaktive Vegetation – sind spektral sehr ähnlich und wurden in versiegelt und unversiegelt unterschieden. Lediglich die als spektrale Extrema auffallenden

hellen und dunklen Gebäude wurden innerhalb der versiegelten Klasse unterschieden, um insbesondere Gartenlauben im Bereich von Kleingärten zu erfassen – diese sind häufig mit geteerten Bitumenschweißbahnen oder Wellblech bedeckt und trotz ihrer geringen Größe spektral gut erfassbar. Eine weitere Differenzierung der unversiegelten Gebiete in photosynthetisch inaktive Vegetation und Bahnflächen war aufgrund der starken spektralen Überschneidung der beiden Klassen zunächst nicht möglich. Im zweiten Level wurden die Klassen des ersten Levels, die eine charakteristische Form aufweisen, noch einmal klassifiziert, sodass beispielsweise das rote Dach eines Reihenhauses als rechteckige Form erfasst werden kann und seine charakteristische Form nicht aufgrund der spektralen Störung eines Schornsteins oder einer Gaube verloren geht. Im dritten Level wurden in erster Linie Objekte mit einer kennzeichnenden Form und Größe klassifiziert. So ist die Größe von Fußballfeldern kaum variabel, ihre Form nahezu rechteckig – zu beschreiben über den *Rectangular Fit*. Die Ausweisung von naturnahen und natürlichen Gewässern ist gewöhnlich aufgrund der geringen Reflexion von Wasser im nahinfraroten Kanal leicht zu realisieren. Fließgewässer und Seen oder Teiche lassen sich über den *Shape*-Index trennen. Die meisten Gewässer im Untersuchungsgebiet sind jedoch infolge unterschiedlichen Lichteinfalls und Algenvorkommen nur durch die Beschreibung weiterer Merkmale ausweisbar. Dennoch gibt es Überschneidungen mit Schattenflächen. Diese konnten über Nachbarschaftsbeziehungen reklassifiziert werden, da Flüsse im Satellitenbild im Normalfall nur durch Brücken unterbrochen sind und daher die Objekte der Klasse Fluss innerhalb einer Mindestdistanz zueinander liegen müssen. Die Objekte der höheren Levels wurden auf den kleinsten Level kopiert, der den Basislevel für alle weiteren Arbeiten darstellt.

Die Unterscheidung von Verkehrsflächen und den verbleibenden Gebäuden bildet das Hauptproblem bei der Landbedeckungsklassifikation urbaner Räume auf Basis von QuickBird-Daten, die in ihrer spektralen Auflösung eingeschränkt sind. HEROLD et al. (2002b) konnten bei einem Beispiel aus Kalifornien die ausgeprägt geradlinige Form der Straßen im untersuchten Gebiet zur erfolgreichen Klassifikation nutzen. Andere Arbeitsgruppen nutzten Zusatzinformationen wie *GIS-Layer*. Diese standen für die vorliegende Arbeit nicht zur Verfügung. Die verbleibenden Klassen bestehen z. T. aus gleichartigen Materialien und sind am ehesten über Formparameter voneinander zu unterscheiden. Dies ist jedoch nur möglich, wenn die Objekte genau segmentiert sind.

Bei der Segmentierung in Definiens entstehen etwa gleich große Objekte (BENZ et al. 2004:248), sodass es nahezu unmöglich ist, mit einer Segmentierungssequenz kompakte, geometrische Strukturen wie Gebäude und schmale, lang gestreckte und vielfältig gekrümmte Objekte wie Straßen gleichermaßen zu erfassen. In der vorliegenden Arbeit konnten Gebäude nur bei entsprechend geringem *Shape*-Faktor und recht hoher *Compactness* zufrieden stellend segmentiert werden (Tab. 5.1). Die Gebäude im Untersuchungsgebiet umfassen allerdings Größenordnungen von wenigen Quadratmetern Fläche bis hin zu über 10.000 m². Insbesondere die Bedachungen der großen Gebäude bestehen aus Materialien, die in ihrer Beschaffenheit spektral mit Straßen nahezu identisch sind. Sie müssen äußerst genau segmentiert werden, damit sie über ihre Form

von Parkplätzen unterschieden werden können. Im vorliegenden Beispiel mussten ungewöhnlich viele Segmentierungslevels ausgewiesen werden, damit Gebäude verschiedener Größenkategorien abgebildet werden konnten (Abb. 5.9). Für einzelne Teilbereiche des Untersuchungsgebiets reichte bereits eine wesentlich geringere Anzahl an Levels für eine erfolgreiche Klassifizierung aus. Mit zunehmender Größe des Untersuchungsgebiets und der damit verbundenen Erhöhung der Vielfalt an Objekten mit spezifischen Eigenschaften wächst auch die Komplexität des Klassifikationsansatzes.

Wegen der spektralen Vielfalt innerhalb der einzelnen Klassen und der daraus resultierenden Ähnlichkeit der Klassen untereinander bilden die Objekte der Klassen versiegelt und unversiegelt stellenweise Mosaike und keine einheitlichen Strukturen. So wurden beispielsweise im Bereich von Straßen dunkle Dächer erkannt. Die entsprechenden Objektklassen – die aus der ersten Klassifizierungssequenz resultierenden Klassen unversiegelt und versiegelt – wurden deswegen inklusive aller Unterklassen neu segmentiert. Dadurch sollte es möglich sein, Straßen und Bahngleise als lang gestreckte Objekte zu segmentieren, die nicht von Objekten einer spektral ähnlichen Klasse unterbrochen sind. Nur so können Formparameter sinnvoll zur näheren Beschreibung der Klassen definiert werden. Die Form der Gebäude wird bei einem *Shape*-Faktor von 0,1 und einer *Compactness* von 0,6 am besten segmentiert. Es wurden zwei Level mit einem *Scale*-Parameter von 40 bzw. 100 ausgewiesen. Segmentiert wurden alle Objekte der Klassen versiegelt und unversiegelt, alle nicht neu segmentierten Objekte blieben für die weiteren Arbeitsschritte unberücksichtigt. Ausgangspunkt war der Basislevel. Die Abb. 5.9 zeigt, dass die zu klassifizierenden Objekte aufgrund der hohen räumlichen Auflösung gut segmentiert werden konnten. Allerdings sind auch in Level 2 (Abb. 5.9 c) Straßen noch nicht mit einer charakteristischen Form erfassbar. In den höheren Levels werden zunehmend angrenzende Gebäude in die Straßensegmente involviert (Abb. 5.9 d - e). Erst durch die erneute Segmentierung auf Grundlage der initialen Klassifizierung werden die Objekte ihrer Form entsprechend abgebildet. Infolge der neuen Segmentierung konnten besonders große Gebäude in den Leveln 1a und 1b über ihre Form als Gebäude erfasst und von den spektral nahezu gleichen Asphaltflächen getrennt werden. Im Untersuchungsgebiet existieren zahlreiche große Gebäude wie Industriehallen oder Einkaufszentren, die zwar insgesamt homogen sind, jedoch keine regelmäßige geometrische Form aufweisen und zudem mit Klimaanlage, Brandschutzmauern oder ähnlichen Konstruktionen bestückt sind, die als *Hot Spots* im Satellitenbild erscheinen. Nur durch die erneute Segmentierung werden diese Gebäude als Einheit erfasst und klassifiziert. Aus diesem Grund wurden auch in den Leveln 1a und 1b helle und dunkle Gebäude klassifiziert. Lediglich die immer noch verbleibenden unklassifizierten Objekte wurden nochmals

Tab. 5.5: Parameter für die zweite Segmentierungssequenz.

Level	Eingangskanäle	Scale-Parameter	Shape	Compactness	Verwendung
1a	Multispektralkanäle 1-4	40	0,3	0,6	Gebäude
1b	Multispektralkanäle 1-4	100	0,3	0,6	Gebäude
1c	Multispektralkanäle 1-4	120	0,1	0,6	Straßen, Bahn




Abb. 5.9: Ausschnitt des Untersuchungsgebiets im Pixellevel [a)], überlagert mit den Segmentgrenzen der verschiedenen Level [b) - h)] und im Ergebnis der klassifizierten optischen Daten.

segmentiert (Level 1c, Tab. 5.5). Um möglichst lang gestreckte Objekte zu erhalten, die es ermöglichen, zur Ausweisung von Bahnflächen und Straßen neben den spektralen Charakteristika auch eine spezifische Form zu definieren, wurde für den *Shape*-Faktor 0,1 gewählt. Alle ermittelten Bahnflächen, die nicht innerhalb einer Mindestentfernung von 25 m zu anderen Bahnflächen lagen, wurden reklassifiziert. Es handelte sich dabei überwiegend um beschattete Straßen. Im Zuge dieser Reklassifizierung wurden auch einige isoliert erfasste Straßenbahnabschnitte ausgesondert. Alle Bahn- und Asphaltflächen wurden auf die niedrigeren Levels kopiert. Die wenigen übrigen Gebiete beinhalteten noch nicht klassifizierte Gebäude, die aufgrund ihrer spezifischen Formparameter in den Levels 1a und 1b abschließend klassifiziert werden konnten. Schließlich wurden beginnend bei Level 1a alle klassifizierten Gebäude auf den Basislevel kopiert. Die Gebiete der Klasse unversiegelt blieben dabei unberücksichtigt und wurden der Klasse photosynthetisch inaktive Vegetation zugewiesen. Alle Objekte, die aus der initialen Klassifizierung als graue Flächen übrig blieben, wurden als unklassifiziert ausgewiesen, da sie keiner Landbedeckungsklasse zugewiesen werden konnten.

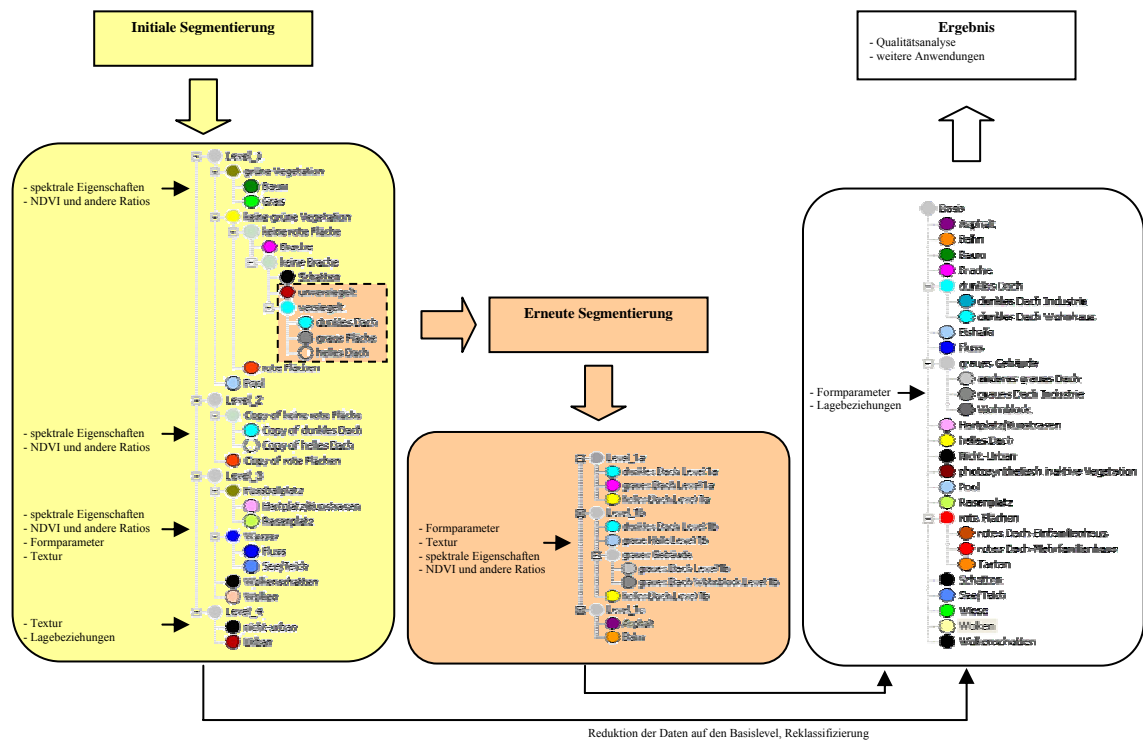


Abb. 5.10: Schematische Darstellung der Klassifizierung auf Basis der optischen Daten.

Die Reduktion der einzelnen Klassifikationslevels auf einen Ergebnislevel ist eine situationsabhängige Aufgabe, bei der abgewogen werden muss, welchen Klassen bzw. welchen Levels Priorität eingeräumt wird. Im vorliegenden Beispiel betrifft dies vor allem die Straßenflächen, da sie bei einem relativ großen *Scale*-Parameter erfasst wurden. Die zu klassifizierenden Gebäude treten in unterschiedlichen Größen auf und grenzen häufig an Straßen, so dass bei großen *Scale*-Parametern kleinere Gebäude mit den Objekten der Straßen verschmelzen und nicht erfasst werden können (Abb. 5.9 d - e). Dieses Problem ist jedoch dem Prinzip der Objektbildung in Definiens inhärent und nur bedingt vermeidbar (HEROLD et al. 2002b:o. S.). Letztendlich kann der Anwender entscheiden, ob die bereits in kleineren Levels klassifizierte Gebäudeklassen in das Ergebnis eingehen und somit auch fehlklassifizierte Gebäude im Bereich von Straßen erhalten bleiben oder ob in Kauf genommen wird, dass einige kleinere Gebäude zugunsten der Straßen nicht berücksichtigt werden, dafür aber das Straßennetz annähernd lückenlos abgebildet werden kann.

Im Basislevel wurden die Objekte aller roten Flächen sowie aller grauen, hellen und dunklen Gebäude jeweils separat über den *Merge*-Befehl verschmolzen und konnten dann über Formparameter – insbesondere den Flächeninhalt – in Wohn- bzw. Industriegebäude unterteilt werden. Für die Ableitung weiterer Produkte, wie die Ausweisung der Landnutzung, ist dies ein wichtiger Schritt. Allerdings wurden viele Objekte aggregiert, die räumlich nicht zusammen gehören, sodass in einigen Fällen mehrere kleine Gebäude zu einem großen Objekt verschmolzen und dementsprechend in eine falsche Klasse zugeordnet wurden.

Wie das Ablaufschema in Abb. 5.10 zeigt, basiert die Klassenzuweisung bei sehr feiner Segmentierung vorrangig auf den spektralen Eigenschaften, während mit




Abb. 5.11: Klassendefinition zur Klassifizierung der QuickBird-Daten.

zunehmender Objektgröße die charakteristischen Formparameter der schlecht trennbaren Klassen genauer zu beschreiben sind. Textur kann ebenfalls bei größeren Segmenten sinnvoller eingesetzt werden. Form- und Lageparameter sowie Textur sind hilfreiche Zusatzinformationen, wenn die spektrale Auflösung nicht mehr ausreicht, um ähnliche Klassen zu unterscheiden. Die genaue Klassenausweisung ist in Abb. 5.11 dargestellt. Die berechneten Ratios sind Ausdruck eines charakteristischen Verlaufs der Reflexionskurve einer Klasse, Spektralwerte schränken die Ausprägung einer Klasse in einem Kanal ein und die Formparameter verdeutlichen die spezifische Form einzelner Klassen. Die *Number of Segments* bezieht sich auf *Skeletons* (BENZ et al. 2004:249ff.) und ist bei kompakten Strukturen besonders gering.

5.4 Objektbasierte Landbedeckungsklassifikation der Radardaten

Die Klassifikation von Radardaten gestaltet sich schwieriger, da selbst in natura rechteckige Gebilde nur zu unregelmäßigen Objekten segmentiert werden können, deren Kanten kaum geometrische Formen nachbilden. Dadurch ist es nur eingeschränkt möglich, Formparameter für die Klassenbeschreibung zu nutzen. Dies gilt insbesondere für Segmentierungen mit kleinen *Scale*-Parametern. Wie Abb. 5.12 veranschaulicht, sind die verschiedenen Landbedeckungsklassen über die Radarrückstreuung aufgrund der großen Standardabweichungen der Daten nicht vollständig trennbar. Vor allem die Klassen Bahn und Wohnblock zeigen ähnliche Rückstreueigenschaften, ebenso wie Kleingarten, Gewerbe und Baum. Für bestimmte Abschnitte trifft zu, dass zu beiden Aufnahmezeitpunkten Züge auf den Gleisen standen. Abb. 5.12 zeigt, dass diese hinsichtlich ihrer Rückstreueigenschaften nicht mit den Bahnflächen konform sind und separat ausgewiesen werden müssen. Bedingt durch die Ähnlichkeit im Rückstreuverhalten mussten bestimmte Klassen in verschiedenen Levels ausgewiesen werden und konnten dann über Kontextbeziehungen definiert werden.




Abb. 5.12: Radarrückstreusignale der Landbedeckungsklassen in E-SAR.

Problematisch ist die Vermischung von Landbedeckungsklassen mit Landnutzungskategorien, die sich jedoch trotz der hohen räumlichen Auflösung der Daten nicht vermeiden lässt. So können beispielsweise Kleingärten als eigene Klasse in einem hohen Level gut klassifiziert werden. Demgegenüber sind auch bei sehr kleinen *Scale*-Parametern einzelne Elemente innerhalb der Kleingärten nur marginal klassifizierbar, da infolge der kleinräumigen Interaktionen des Radarsignals mit den verschiedenen Objekten die Radarrückstreusignale zu einem Mischsignal überlagert werden. Die Beziehungen zu Sub- und Superobjekten erleichtert beispielsweise die Klassifikation von Kleingärten und Bahnflächen. Die Baumreihen entlang des Flusses können

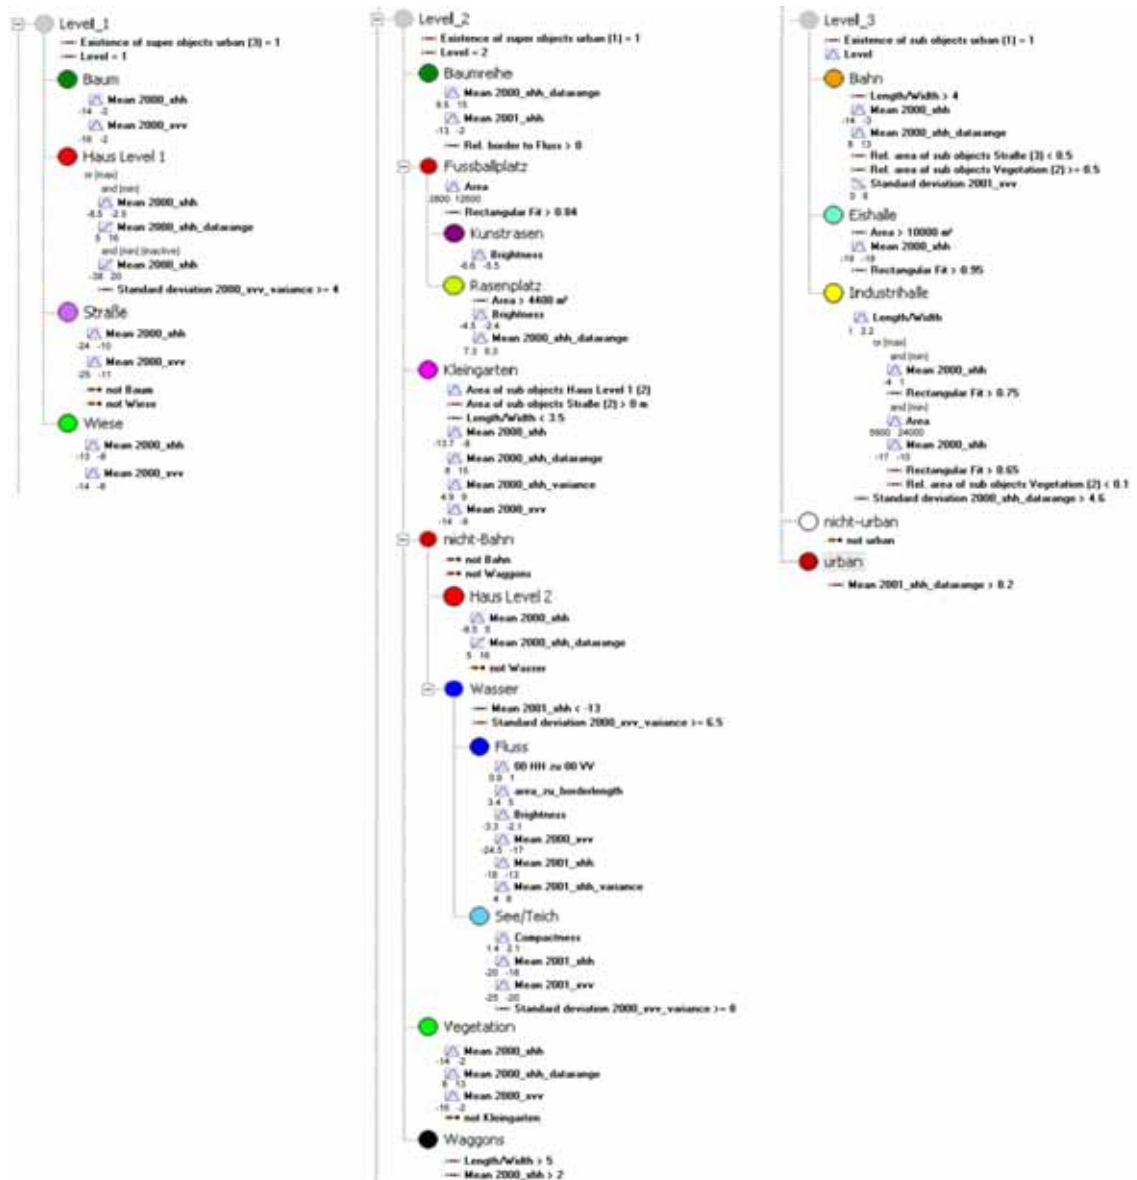


Abb. 5.13: Klassendefinition zur Klassifizierung der E-SAR-Daten.

ebenfalls über Nachbarschaftsbeziehungen ausgewiesen werden. Der Fluss unterscheidet sich im Rückstreuverhalten von den Seen und überschneidet sich dabei mit Straßen (Abb. 5.12). Über ein Distanzkriterium (> 20 m) konnten die falsch klassifizierte Objekte der Klasse Fluss reklassifiziert werden. Die Beschreibung von Gebäuden war in allen drei Levels notwendig, da Industriegebäude im Mikrowellenbereich ein anderes Verhalten zeigen als andere, kleinere Gebäude. An großen Gebäuden tritt der *Double-Bounce*-Effekt nur in einem kleinen Bereich an der zum Sensor zugewandten Seite auf und die restliche Dachfläche erscheint als mehr oder weniger homogen mit deutlich geringeren Rückstreusignalen. Je nach Beschaffenheit des Daches ist die Rückstreuung gering bis hoch, sodass eine genaue Klassendefinition schwierig ist. Rechteckige Industriegebäude sind verhältnismäßig gut über den *Rectangular Fit* zu beschreiben, unregelmäßig geformte sind kaum von Parkplätzen zu trennen. Industriegebäude waren nur im höchsten Level erfassbar, während kleine Wohnhäuser nur im kleinsten Level klassifiziert werden konnten. Die Erfassung größerer Gebäude in ihrer gesamten Streu-

breite an Formen war nur im zweiten Level zu realisieren. Bahnflächen sind hinsichtlich ihres Radarrückstreuerverhaltens Vegetation recht ähnlich (Abb. 5.12) und konnten nur durch die Berücksichtigung der Beziehung zu Subobjekten und die Reklassifikation über ein Distanzkriterium ausgewiesen werden. Dabei wurden alle als Bahn klassifizierten Objekte reklassifiziert, die eine Mindestentfernung von 20 m zu anderen Bahnflächen überschritten. Die klassifizierten Waggonen als temporäre Phänomene, die eindeutig mit Bahnflächen zu assoziieren sind, wurden der Klasse Bahn zugewiesen. In Abb. 5.13 ist das Klassifikationsschema inklusive der Klassenbeschreibung aufgeführt. Daraus geht hervor, dass anders als bei den optischen Daten Ratios kaum Verwendung finden konnten. Die Definition der Klassen musste stärker in den Kontext eingebunden werden.

5.5 Synergetische objektbasierte Landbedeckungsklassifikation

Wie bei den optischen Daten wurde auch hier eine Wolken- und Wolkenschattenmaske erstellt, da die spektralen Eigenschaften im Bereich der Wolkenschattengebiete stark modifiziert sind und im Bereich der Wolken überhaupt nicht berücksichtigt werden können. Diese Gebiete müssen separat behandelt werden. Zur Erstellung eines Kartenproduktes kann das Ergebnis aus der Radarklassifizierung in einem GIS in den maskierten Bereich eingefügt werden.

Die grundlegende Strategie bei der synergetischen Verwendung von optischen und Radardaten war, die Merkmale aus den unterschiedlichen Informationsquellen derart zu kombinieren, dass die Landbedeckungsklassen eindeutig beschrieben werden. Aufgrund der höheren räumlichen Auflösung und der insgesamt detailreicheren Wiedergabe in den optischen Daten wurde versucht, spektral gut differenzierbare Klassen mit den Merkmalen im optischen Bereich zu beschreiben und vorrangig die spektral schlecht trennbaren Klassen durch die zusätzliche Berücksichtigung der Radardaten zu unterscheiden. Dies gilt insbesondere für Verkehrsflächen und graue Dächer, da diese aus gleichen bzw. ähnlichen Materialien bestehen und daher bei der gegebenen spektralen Auflösung von QuickBird über die spektralen Merkmale nicht zu trennen sind. Wie die Klassifizierung auf Basis der optischen Daten gezeigt hat, bietet selbst die objektbasierte Auswertung, die die Berücksichtigung von Formparametern erlaubt, nur bedingt Möglichkeiten zur Lösung dieses Problems. Die eindeutigen Unterschiede im Rückstreuerverhalten von Gebäuden und Verkehrsflächen im Mikrowellenbereich erlauben die Differenzierung dieser beiden Klassen auf Basis der Radardaten. Infolge des radarspezifischen Bildaufbaus (Kapitel 2.1.5) treten hier jedoch teilweise geometrische Verzerrungen auf: Im innerstädtischen Bereich verlaufen Straßen häufig unmittelbar neben mehrstöckigen Häuserblocks. An diesen entstehen *Layover* und *Foreshortening*, sodass die Rückstreusignale der Gebäude in Richtung des Sensors versetzt sind. Wenn dort eine Straße parallel zur Bewegungsrichtung des Sensors liegt, dann überlagern die Rückstreusignale der Gebäude die der Straße. Bei Klassen, die optisch gut zu beschreiben sind, würde die Berücksichtigung der Radareigenschaften aufgrund der beschriebenen geometrischen Verzerrungen keine verbesserte Klassentrennung bewir-

ken. Außerdem liegt die Radarinformation von Gebäuden infolge der systembedingten Verzerrungen nur teilweise auf dem Gebiet der optisch erfassten Gebäude. Da die Schattenareale der optischen Szene aufnahmebedingt in dieselbe Richtung fallen wie die *Layover*- und *Foreshortening*-Effekte der Radarszene ist es nahezu unmöglich, durch die synergetische Nutzung in diesen Schattengebieten zusätzliche Landbedeckungsinformationen zu gewinnen. Es erwies sich als sinnvoll, auch bei der synergetischen Auswertung eine Schattenklasse zu definieren.

Analog zur Klassifizierung auf Grundlage der optischen Daten wurde eine initiale Segmentierung durchgeführt, auf deren Basis eine Landbedeckungsklassifikation in drei Levels erfolgte (Tab. 5.1). Im ersten Level wurden Klassen ausschließlich nach ihren spektralen Charakteristika getrennt. Dadurch kann eine größere Klassentiefe erreicht werden als mit den Radardaten. Im zweiten Level wurden Objekte mit kennzeichnenden Formen erneut klassifiziert, um kleinräumige Strukturen innerhalb dieser Objekte zu unterdrücken. Es handelt sich dabei um die Klassen rote Flächen, dunkles Dach und helles Dach. Im dritten Level wurden große Objekte mit speziellen Formeigenschaften klassifiziert, darüber hinaus auch Wolken und Wolkenschattengebiete sowie Wasserflächen. Hier wurde die Unterscheidung durch die Berücksichtigung der Radarrückstreuung erleichtert. Die Klassen wurden wie bei der Klassifizierung der optischen Daten auf einen Basislevel kopiert. Dabei hatten die Objekte des höheren Levels jeweils Priorität. Allerdings blieben als Vegetation klassifizierte Objekte von der damit teilweise einhergehenden Reklassifikation ausgenommen. Danach wurden die nicht eindeutig klassifizierbaren Objekte erneut in drei Levels segmentiert (Tab. 5.5, Abb. 5.14). Dabei besteht der wesentliche Unterschied zur Klassifizierung der optischen Daten

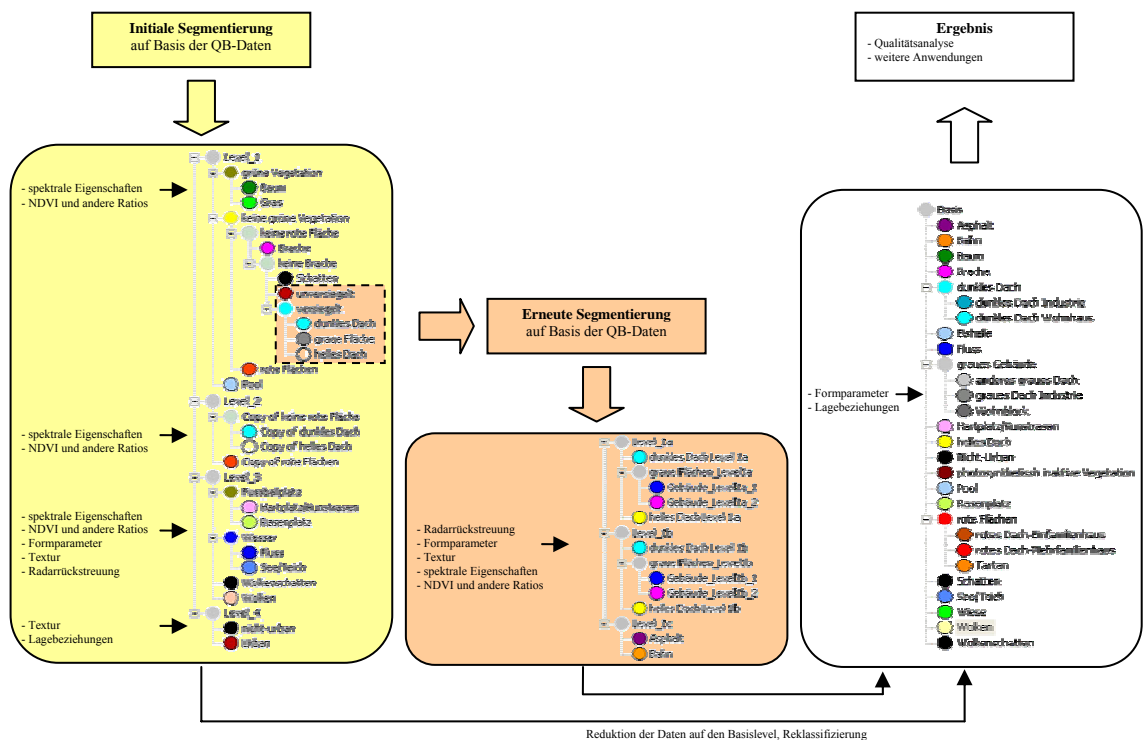


Abb. 5.14: Schema der synergetischen Klassifikation. Signifikante Unterschiede zur Klassifizierung der optischen Daten treten insbesondere ab der erneuten Segmentierung auf.




Abb. 5.15: Klassendefinition zur synergetischen Klassifizierung.

darin, dass die Verwendung der Rückstreusignale sowie der Textur aus den Radardaten eine eindeutige Klassenbeschreibung ermöglicht. Dies führte dazu, dass auch kleinere Gebäude eindeutig ausgewiesen werden konnten, sofern sie nicht im Radarschatten liegen. Bei der Reduktion der Daten auf den Basislevel wurden die Gebäude der Level

1a und 1b am stärksten gewichtet: Bahnflächen und Asphalt wurden auf den Basislevel kopiert und gleichzeitig die wenigen Gebäude beseitigt, die in der initialen Klassifizierung fälschlicherweise im Bereich von Straßen oder Bahnflächen ausgewiesen worden waren. Schließlich wurden die Gebäude der Level 1a und 1b als korrekt klassifiziert angenommen und auf den Basislevel kopiert. Danach wurden alle hellen, dunklen, grauen und roten Dächer jeweils mit dem *Merge*-Befehl zusammengefügt und ihrer Größe und Form entsprechend in Kategorien wie Wohnhaus oder Industrie aufgeteilt. Die Zuweisungsregeln für diese Kategorisierung sind dieselben wie bei der Klassifizierung der optischen Daten (Abb. 5.11, letzte Spalte). Abb. 5.14 zeigt das Klassifikationsschema der synergetischen Auswertung, in Abb. 5.15 sind die Klassenbeschreibungen dargestellt. Es wird deutlich, dass die Klassenbeschreibung mehr Merkmale umfasst als die auf Basis einer einzigen Datengrundlage.

5.6 Ergebnisse der Landbedeckungsklassifikation

Zur Qualitätskontrolle der Landbedeckungsklassifikationen mussten in den hoch auflösenden QuickBird-Daten mit Hilfe einer visuellen Interpretation Referenzpunkte gesucht werden, da alle verfügbaren Referenzquellen nur marginal Informationen über die Landbedeckung liefern. Partiiell konnten auch die Realflächenkartierung und das Luftbild in Google Maps Berücksichtigung finden. Infolge der abweichenden Klassentiefe umfassen die Radardaten teilweise andere Referenzklassen als die beiden anderen Produkte. Für jede Klasse wurden fünfzig Referenzpunkte festgelegt, die nach Möglichkeit in allen drei Produkten vorhanden sind. Die Klassifikation der Radardaten ergab zwölf Klassen (Abb. 5.16). Die Klassifikationsgenauigkeit der einzelnen Klassen ist Tab. 5.7

Tab. 5.6: Konfusionsmatrix zur Landbedeckungsklassifikation der Radardaten (Angaben in Prozent).

Klasse	Referenzklassen												Summe
	Gras	Fluss	See/Teich	Baum	Bahn	Kleingarten	Kunstrasen	Rasenplatz	Wohnhaus	Eishalle	Straße	Gewerbe	
Unklassifiziert	0	0	0	0	0	0	0	0	0	0	0	0	0
Gras	40	4	4	14	6	0	0	4	6	6	2	0	7,17
Fluss	0	50	0	0	0	0	0	0	0	0	0	0	4,17
See/Teich	0	0	70	0	0	0	0	0	0	0	0	0	5,83
Baum	10	22	0	54	18	4	0	0	8	4	6	6	11,0
Bahn	4	0	0	6	70	0	0	0	4	0	0	0	7,0
Kleingarten	4	0	2	8	0	94	0	2	0	0	0	2	9,33
Kunstrasen	0	0	0	0	0	0	74	0	0	0	2	0	6,33
Rasenplatz	4	0	0	0	0	0	26	88	0	0	0	0	9,83
Wohnhaus	2	6	0	4	4	0	0	0	70	0	10	28	10,33
Eishalle	0	0	0	0	0	0	0	0	0	90	0	0	7,50
Straße	36	16	24	14	2	2	0	6	6	0	76	12	16,17
Gewerbe	0	2	0	0	0	0	0	0	6	0	4	52	5,33
Summe	100	100	100	100	100	100	100	100	100	100	100	100	100
Gesamtgenauigkeit: 69,00 %													
Kappakoeffizient: 0,66													

Tab. 5.7: Klassifikationsgenauigkeit der Radardaten.

Klasse	Commission [%]	Omission [%]	Hersteller- genauigkeit [%]	Nutzer- genauigkeit [%]
Gras	53,5	60,0	40,0	46,5
Fluss	0	50,0	50,0	100,0
See/Teich	0	30,0	70,0	100,0
Baum	59,1	46,0	54,0	40,9
Bahn	16,7	30,0	70,0	83,3
Kleingarten	16,1	6,0	94,0	83,9
Kunstrasen	2,6	26,0	74,0	97,4
Rasenplatz	25,4	12,0	88,0	74,6
Wohnhaus	43,6	30,0	70,0	56,4
Eishalle	0	10,0	90,0	100,0
Straße	60,8	24,0	76,0	39,2
Gewerbe	18,8	48,0	52,0	81,2

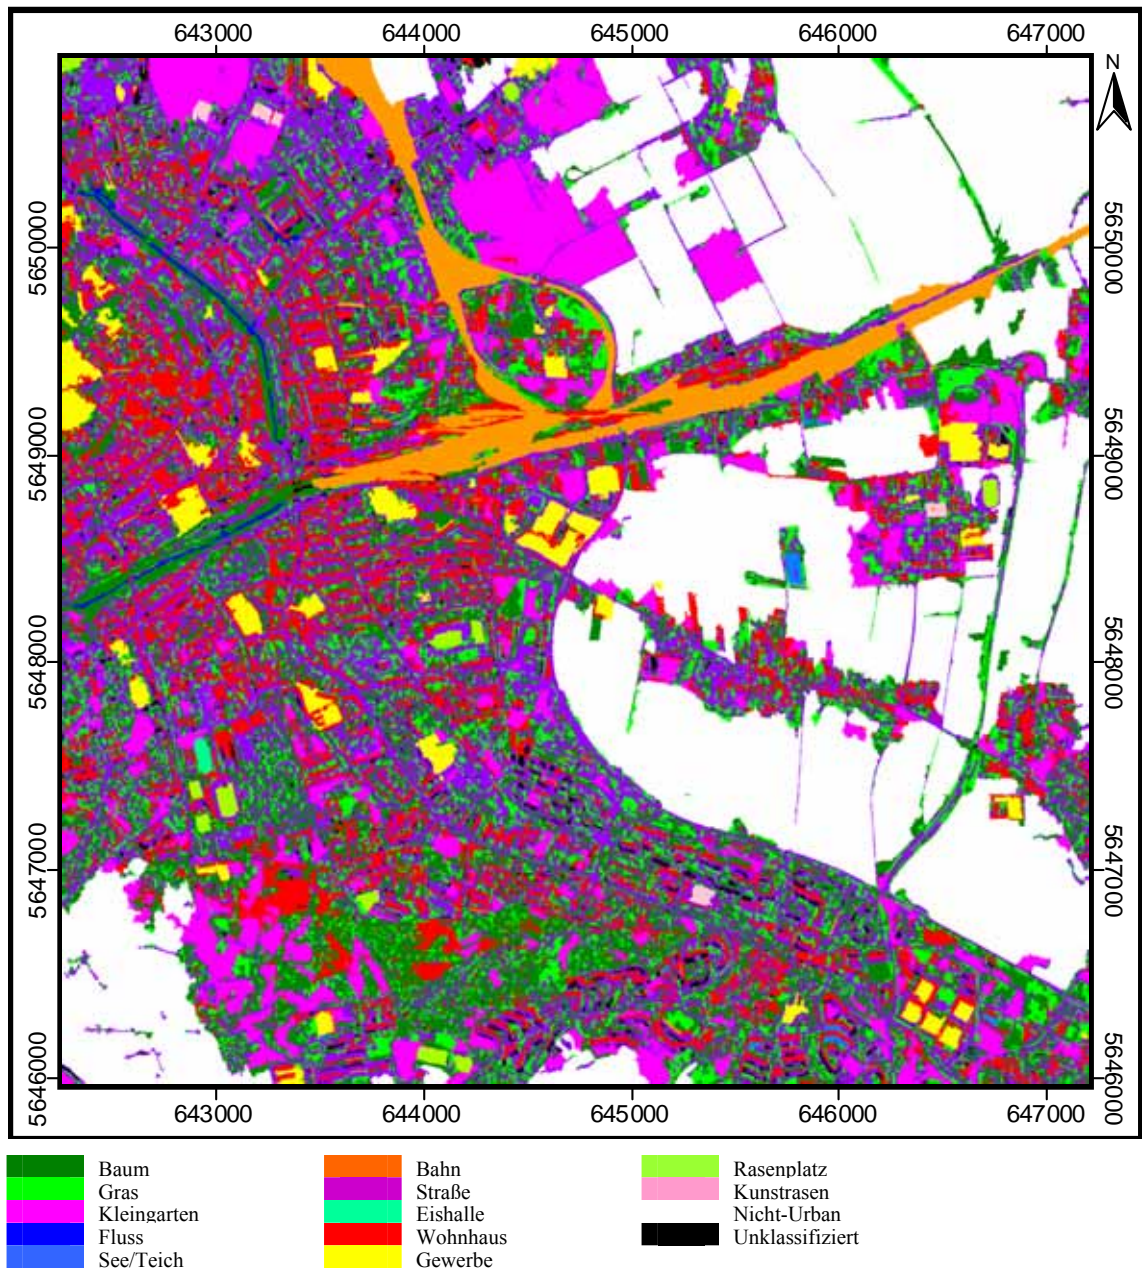


Abb. 5.16: Klassifikationsergebnis der Radardaten (Projektion: UTM Zone 32, WGS 84).

zu entnehmen. Die Gesamtgenauigkeit und der Kappakoeffizient sind recht gering. Die Konfusionsmatrix verdeutlicht, dass die Klasse Straße überrepräsentiert ist (Tab. 5.6), weil insbesondere mit allen dreidimensionalen Strukturen, wie Gebäude oder Bäume, Fehlklassifikationen auftreten. Ein Grund für Fehlklassifikationen sind die radarbedingten geometrischen Verzerrungen: Die Objekte wurden zwar erkannt, sind aber infolge von *Layover* und *Foreshortening* räumlich zum Sensor versetzt und liegen deswegen abseits der Referenzpunkte. Derartige Effekte verursachten u. a. Fehlklassifikationen zwischen den Klassen Fluss und Baum. Abb. 5.16 zeigt, dass der Fluss trotz schlechter Statistik (Tab. 5.7) gut erfasst wurde. Die Klasse Gras weist ebenso wie Fluss Fehlklassifikationen mit Straße auf. Insgesamt sind die Fehlklassifikationen zwischen Straßen und Gebäuden deutlich geringer als bei den optischen Daten (vgl. Tab. 5.6 und

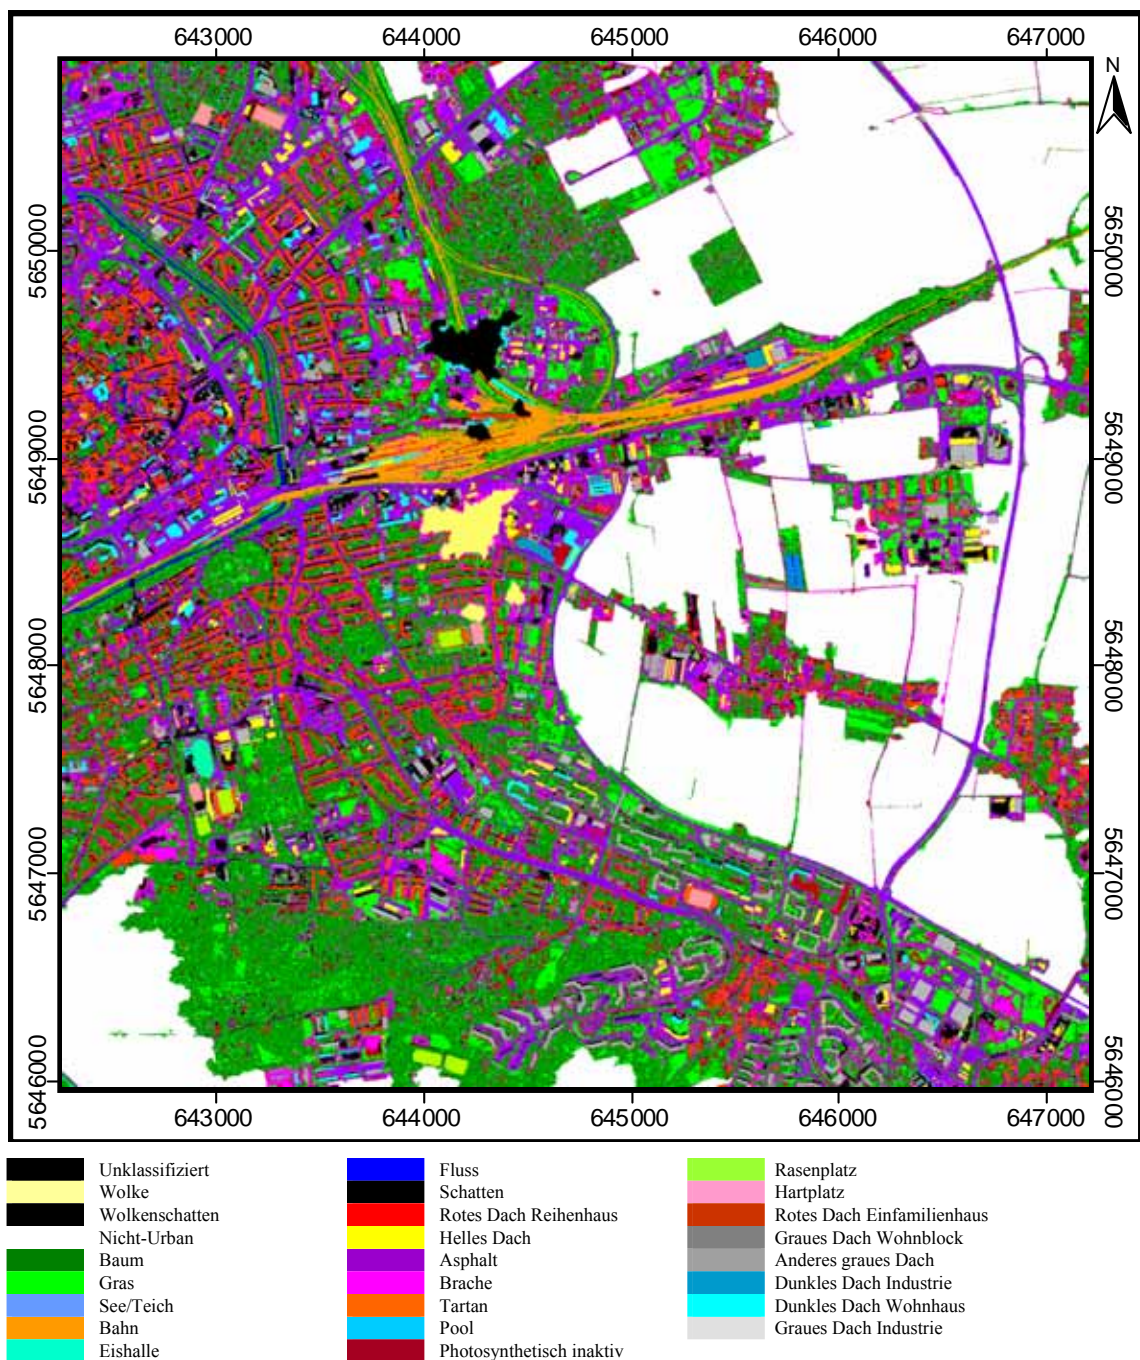


Abb. 5.17: Klassifikationsergebnis der optischen Daten (UTM Zone 32, WGS 84).

5.8). Allerdings treten häufig zwischen Wohnhaus und Gewerbe Fehlklassifikationen auf. Kleingärten und Sportanlagen zeigen hohe Genauigkeiten. Unklassifizierte Areale befinden sich vor allem im Radarschatten von hohen Wohngebäuden (Abb. 5.16).

Die Klassifikation der optischen Daten und die synergetische Anwendung mit den Radardaten ergab jeweils 22 Klassen (ohne Wolken und Wolkenschatten) (Abb. 5.17, 5.18). Trotz der Wahl der gleichen Parameter und derselben Eingangsdaten (Tab. 5.1) zeigen die Segmentierungen geringfügige Abweichungen. Die größten Ungenauigkeiten ergeben sich zwischen den Kategorien, die nur auf Basis von Form und Flächeninhalt getrennt wurden, z. B. rotes Dach Einfamilienhaus und rotes Dach Reihenhaus, und bereits einen ersten Schritt in Richtung einer möglichen Landnutzungsklassifizierung darstellen (Tab. 5.8, 5.9). Daraus kann geschlossen werden, dass bei einer derart kom-

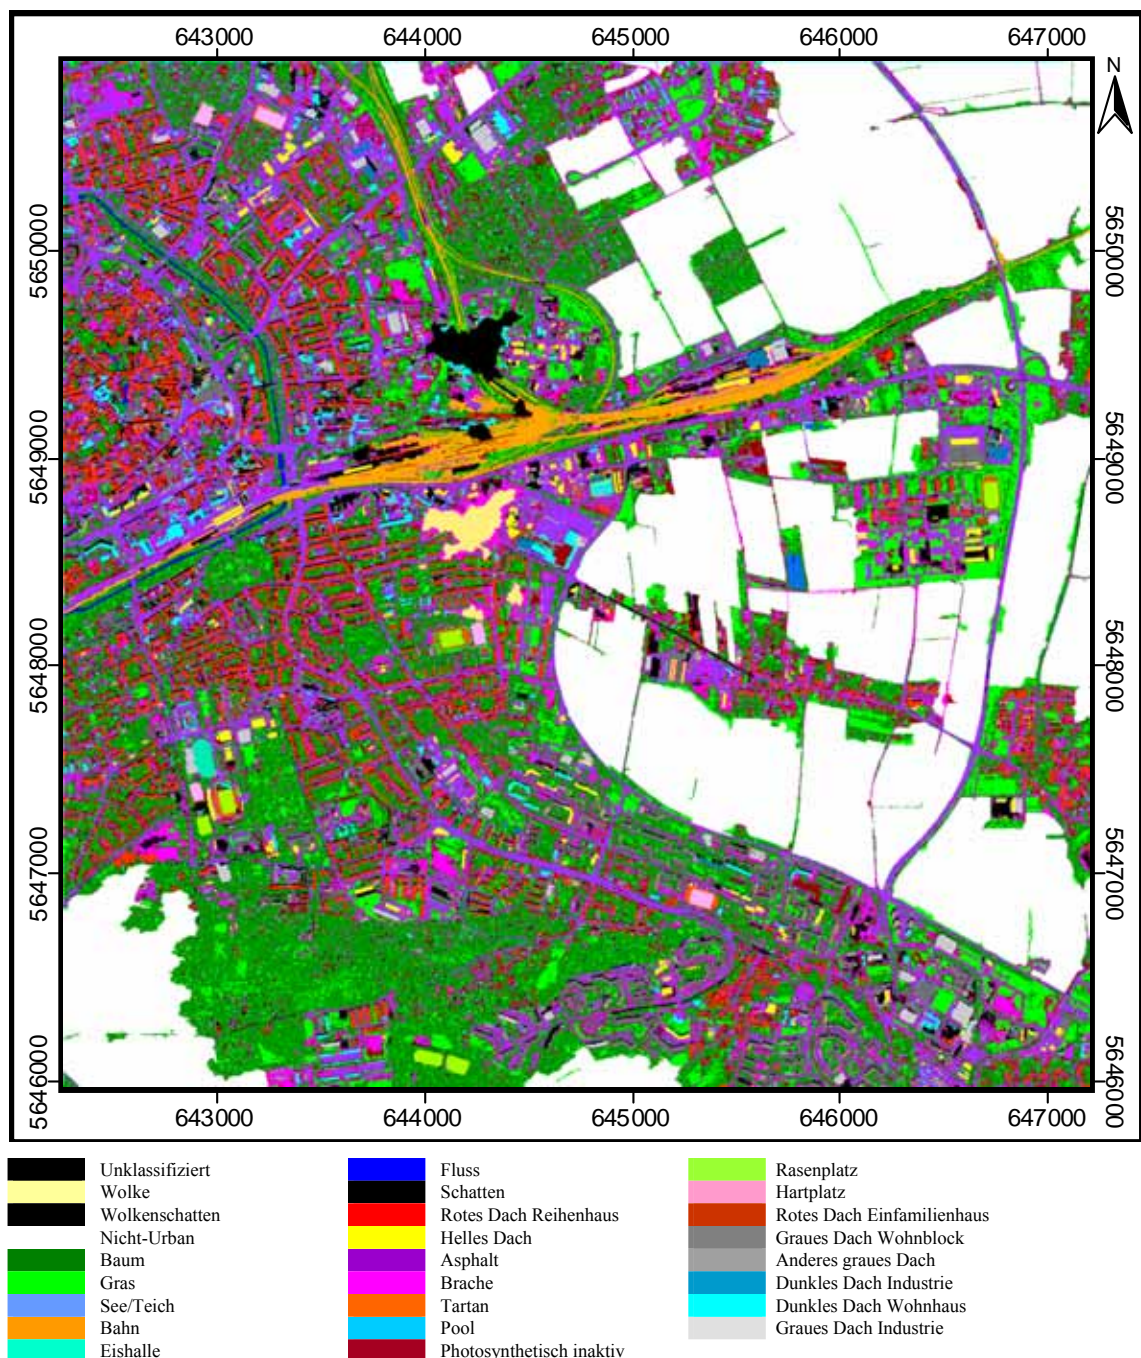


Abb. 5.18: Ergebnis der synergetischen Auswertung von QB und E-SAR (UTM Zone 32, WGS 84).

plexen Szene die Berücksichtigung von Form und Größe nicht ausreicht, um Objekte gleicher Beschaffenheit detaillierter zu kategorisieren. Versuche, Nachbarschaftsbeziehungen zu nutzen, waren nur bei sehr kleinen Subsets erfolgreich und scheiterten bei der Anwendung auf die ganze Szene. Nachteilig wirkte sich die Verschmelzung aneinander grenzender Gebäude im Zuge des *Merge*-Prozesses aus: Einzelne Wohnhäuser wurden zu großflächigen Gebäuden aggregiert und entsprechend einer falschen Kategorie zugeordnet. Bei der Betrachtung der Konfusionsmatrizen der optischen und der synergetischen Auswertung (Tab. 5.8, 5.9) wird deutlich, dass die Genauigkeit für die Klasse Pool recht gering ist. Die im Untersuchungsgebiet vorkommenden Pools haben eine geringe Fläche und sind daher häufig trotz des kleinen *Scale*-Parameters nicht genau segmentiert worden. Augenscheinlich sind auch die Fehlklassifikationen der Klasse Asphalt, die überwiegend entweder als Brache oder graues Dach klassifiziert wurden oder unklassifiziert blieben. Vor allem Straßenkreuzungen, aber auch größere, leere Parkplätze waren auf Basis der optischen Daten kaum klassifizierbar. Bei der synergetischen Verwendung konnte die Fehlklassifikation mit grauen Dächern erheblich reduziert werden. Ebenso sank die Zahl der unklassifizierten grauen Dächer und Asphaltflächen deutlich (vgl. Tab. 5.8 und 5.9). Entsprechend nahmen im synergetischen Produkt auch Hersteller- und Nutzergenauigkeit zu (vgl. Tab. 5.10 und 5.11). Neben den bereits angesprochenen Fehlklassifikationen zwischen unterschiedlichen Klassen derselben Kategorie traten vorrangig bei den Klassen Schatten und Brache Fehlzuordnungen auf. Während ersteres Problem u. a. auf eine subjektive Einschätzung der Attribute hell und dunkel zurückzuführen sein kann, hat letzteres auch eine Ursache in der geringen spektralen Auflösung von QuickBird, die die Unterscheidung heller

Tab. 5.8: Konfusionsmatrix zur Landbedeckungsklassifikation der optischen Daten (Angaben in Prozent).

Klasse	Baum	Gras	Bahn	Fluss	Schatten	rotes Dach	Reihenhaus	helles Dach	Asphalt	Brache	Tartan	Pool	Rasenplatz	rotes Dach	Einfamilienhaus	graues Dach	Wohnblock	dunkles Dach	Industrie	graues Dach	Industrie	Eishalle	See/Teich	Kunstrasen	anderes graues Dach	dunkles Dach	Wohnhaus	photosynthetisch inaktiv	Vegetation	Summe
unklassifiziert	0	0	0	0	0	0	2	12	10	0	2	0	0	10	0	12	0	0	0	0	0	0	0	22	4	2	3,5			
Baum	90	0	0	0	0	0	0	0	0	0	0	20	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5,1	
Gras	10	98	0	2	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5,2	
Bahn	0	0	92	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	2	4,4		
Fluss	0	0	0	86	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4,0	
Schatten	0	0	0	4	64	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	6	0	3,6		
rotes Dach	0	0	0	0	2	100	0	0	6	0	0	0	50	0	0	0	0	0	0	0	0	0	0	0	0	0	2	7,3		
helles Dach	0	0	0	0	0	0	92	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	4,3		
Asphalt	0	0	2	2	14	0	0	74	0	0	2	0	0	26	4	14	0	0	0	0	22	18	2	8,2						
Brache	0	0	0	0	0	0	8	84	0	4	0	0	0	0	0	2	0	0	0	0	0	0	0	0	4	4,6				
Tartan	0	0	0	0	0	0	0	0	94	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4,3		
Pool	0	0	0	0	0	0	0	0	0	0	70	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3,2		
Rasenplatz	0	2	0	0	0	0	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4,6		
rotes Dach	0	0	2	0	0	0	0	0	2	0	0	0	50	0	0	0	0	0	0	0	0	0	0	0	0	8	2,8			
graues Dach	0	0	0	4	0	2	2	0	0	0	0	0	62	24	28	0	0	0	0	26	4	0	6,9							
Wohnblock	0	0	0	0	0	0	0	0	0	0	0	0	0	20	0	0	0	0	0	0	6	0	1,2							
dunkles Dach	0	0	0	0	2	0	0	2	0	0	0	0	0	2	42	0	0	0	6	2	0	2,6								
Industrie	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	4,6								
Industrie	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	96	0	0	0	0	4,5								
Eishalle	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	100	0	4,7								
See/Teich	0	0	0	0	0	0	4	2	0	0	2	0	0	2	2	2	0	0	0	18	8	1,8								
Kunstrasen	0	0	2	4	8	0	0	0	0	0	0	0	0	46	0	0	0	0	4	46	0	5,0								
anderes graues Dach	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	80	4,0								
dunkles Dach	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	80	4,0			
Wohnhaus	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	
photosynthetisch inaktiv																														
Summe	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	

Gesamtgenauigkeit: 75,27 %
Kappakoeffizient: 0,74

Tab. 5.9: Konfusionsmatrix zur synergetischen Landbedeckungsklassifikation (Angaben in Prozent).

Klasse	Fluss	Schatten	rotes Dach Reihenhaus	helles Dach	Brache	Tartan	Pool	Rasenplatz	rotes Dach Einfamilienhaus	graues Dach Wohnblock	dunkles Dach Industrie	Asphalt	Baum	Bahn	Eishalle	graues Dach Industrie	See/Teich	Kunstrasen	photosynthetisch inaktive Vegetation	Gras	dunkles Dach Wohnhaus	anderes graues Dach	Summe
unklassifiziert	0	0	0	0	4	0	2	0	0	4	2	4	0	2	0	8	0	0	2	0	2	4	1,6
Fluss	84	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3,8
Schatten	6	78	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	4,3
rotes Dach Reihenhaus	0	0	100	0	6	0	0	0	44	0	0	0	0	0	0	0	0	2	0	0	0	0	6,9
helles Dach	0	0	0	94	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4,4
Brache	0	0	0	0	84	0	4	0	0	0	0	8	0	0	0	2	0	0	4	0	0	0	4,6
Tartan	0	0	0	0	0	90	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4,1
Pool	0	0	0	0	0	0	66	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3,0
Rasenplatz	0	0	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	2	0	0	4,6
rotes Dach Einfamilienhaus	0	0	0	0	0	6	0	0	56	0	0	0	6	0	0	0	0	8	0	0	0	0	3,5
graues Dach Wohnblock	0	2	0	4	0	0	0	0	84	4	0	0	0	0	0	30	0	0	0	2	36	7,4	
dunkles Dach Industrie	0	0	0	0	0	0	0	0	0	36	0	0	0	0	0	0	0	0	0	0	6	0	1,9
Asphalt	6	2	0	2	6	0	2	0	4	2	86	0	0	0	14	0	0	2	0	10	20	7,1	
Baum	0	0	0	0	0	0	22	2	0	0	0	0	94	0	0	0	0	0	4	0	0	0	5,6
Bahn	0	0	0	0	0	0	0	0	0	0	0	0	0	90	0	0	0	2	0	0	0	0	4,2
Eishalle	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0	0	4,6
graues Dach Industrie	0	0	0	0	0	0	0	0	2	2	0	0	0	0	0	40	0	0	0	4	8	2,6	
See/Teich	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	96	0	0	0	0	0	0	4,5
Kunstrasen	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	4,7
photosynthetisch inaktiv	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	80	0	4	0	0	3,9
Gras	0	4	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	94	0	0	0	4,7
dunkles Dach Wohnhaus	2	14	0	0	0	0	0	0	0	50	2	0	0	0	0	4	0	0	0	64	6	6,5	
anderes graues Dach	0	0	0	0	0	0	2	0	6	0	0	0	0	0	6	0	0	0	0	2	26	1,9	
Summe	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100

Gesamtgenauigkeit: 79,09 %
Kappakoeffizient: 0,78

Asphaltflächen und Brachen sowie die von dunklen Dächern und Schatten erschwert (Abb. 5.8). Formparameter konnten wegen der unregelmäßigen Form von Brachflächen nicht genutzt werden. Insbesondere Klassen mit charakteristischer Form wie Sportplätze

Tab. 5.10: Klassifikationsgenauigkeit der QuickBird-Daten

Klasse	Commission [%]	Omission [%]	Hersteller- genauigkeit [%]	Nutzer- genauigkeit [%]
Baum	19,6	10,0	90,0	80,4
Gras	14,0	2,0	98,0	86,0
Bahn	4,2	8,0	92,0	95,8
Fluss	2,3	14,0	86,0	97,7
Schatten	17,9	36,0	64,0	82,1
rotes Dach Reihenhaus	37,5	0	100,0	62,5
helles Dach	2,1	8,0	92,0	97,9
Asphalt	58,9	26,0	74,0	41,1
Brache	17,7	16,0	84,0	82,3
Tartan	0	6,0	94,0	100,0
Pool	0	30,0	70,0	100,0
Rasenplatz	2,0	2,0	98,0	98,0
rotes Dach Einfamilienhaus	19,4	50,0	50,0	80,6
graues Dach Wohnblock	59,2	38,0	62,0	40,8
dunkles Dach Industrie	23,1	80,0	20,0	76,9
graues Dach Industrie	25,0	58,0	42,0	75,0
Eishalle	0,0	0,0	100,0	100,0
See/Teich	2,0	4,0	96,0	98,0
Hartplatz	3,9	0,0	100,0	96,1
anderes graues Dach	55,0	82,0	18,0	45,0
dunkles Dach Wohnhaus	58,2	54,0	46,0	41,8
photosynthetisch inaktiv	9,1	20,0	80,0	90,9

und die Eishalle konnten aufgrund der sehr genauen Segmentierung über Formparameter mit großer Genauigkeit klassifiziert werden. Die Gesamtgenauigkeit ist bei der synergetischen Klassifizierung etwa 4 % höher als bei der Klassifizierung auf Basis der optischen Daten und ca. 10 % höher als die Klassifizierung der Radardaten (vgl. Tab. 5.6, 5.8, 5.9).

Tab. 5.11: Klassifikationsgenauigkeit der synergetischen Auswertung.

Klasse	Commission [%]	Omission [%]	Hersteller- genauigkeit [%]	Nutzer- genauigkeit [%]
Fluss	0	16,0	84,0	100,0
Schatten	17,0	22,0	78,0	83,0
rotes Dach Reihenhaus	34,2	0	100,0	65,8
helles Dach	2,1	6,0	94,0	97,9
Brache	17,6	16,0	84,0	82,4
Tartan	0	10,0	90,0	100,0
Pool	0	34,0	66,0	100,0
Rasenplatz	2,0	2,0	98,0	98,0
rotes Dach Einfamilienhaus	26,3	44,0	56,0	73,7
graues Dach Wohnblock	48,2	16,0	84,0	51,8
dunkles Dach Industrie	14,3	64,0	36,0	85,7
Asphalt	44,9	14,0	86,0	55,1
Baum	22,9	6,0	94,0	77,1
Bahn	2,2	10,0	90,0	97,8
Eishalle	0	0	100,0	100,0
graues Dach Industrie	28,6	60,0	40,0	71,4
See/Teich	2,0	4,0	96,0	98,0
Kunstrasen	3,9	0	100,0	96,1
photosynthetisch inaktiv	7,0	20,0	80,0	93,0
Gras	9,6	6,0	94,0	90,4
dunkles Dach Wohnhaus	54,9	36,0	64,0	45,1
anderes graues Dach	38,1	74,0	26,0	61,9

5.7 Bewertung der Ergebnisse

Aufgrund des großen Untersuchungsgebiets und der damit verbundenen Heterogenität, die durch die Verwendung eines *Pansharpening*-Produkts noch zusätzlich erhöht wurde, ist die Klassifikation der optischen Szene nur durch einen komplexen Klassifikationsansatz realisierbar. Dabei erwies es sich als wirksam, bereits vorklassifizierte Areale neu zu segmentieren, um die vielfältigen Objekte schrittweise in allen Größenklassen gut charakterisieren und auflösen zu können. Diese Vorgehensweise erfordert jedoch insbesondere bei der Wahl der Parameter ein hohes Maß an Interaktion. Alternativ könnte die spektrale Vielfalt durch die Verwendung der originalen Multispektraldaten reduziert werden. Inwiefern dadurch die Klassen besser zu beschreiben sind, war nicht Gegenstand dieser Arbeit und müsste überprüft werden. Wie Segmentierungsversuche mit kleinen Bildausschnitten gezeigt haben, steht zu erwarten, dass bei der Verwendung der Originaldaten bestimmte räumliche Details und einzelne Landbedeckungsklassen nicht erfassbar bzw. nur schlecht nachzubilden sind. Deswegen wurden für die vorliegende Arbeit die geschärften Daten genutzt. Für die hier verfolgte Absicht der Landbedeckungsklassifikation sollte die Fusion der panchromatischen und Multispek-

traldaten idealerweise so erfolgen, dass vor allem die Kanten realer Objekte geschärft werden, die Objekte selbst jedoch als homogene Flächen erhalten bleiben, sodass beispielsweise der spektrale Einfluss von Schornsteinen in Gebäuden unterdrückt werden kann. Die segmentbasierte Fusion (Kapitel 2.2.3) der panchromatischen und Multispektraldaten verspricht eine erleichterte Klassifikation, da zur genauen Segmentierung eine geringere Anzahl an Levels ausreichen sollte und die Objekte homogener und somit leichter beschreibbar werden. Bei Verwendung von *Pansharpening*-Produkten ist trotz des Erhalts der spektralen Charakteristika insbesondere bei derart hoch komplexen Situationen wie dem urbanen Raum die Analyse der Daten mit Definiens nur durch eine Abfolge von Segmentierung, Klassifizierung und darauf basierender erneuter Segmentierung und Klassifizierung in befriedigender Qualität zu bewerkstelligen. Die Parametrisierung in Definiens ermöglicht nicht, in einem Schritt kompakte, geometrische Formen und unregelmäßig geformte, lang gestreckte Objekte zu segmentieren, es sei denn, sie unterscheiden sich spektral markant. Allerdings erlaubt die objektbasierte Klassifikation in Definiens verschiedene äußerst flexible Strategien zur Klassifizierung hoch auflösender Daten. Die Klassifikation optischer Daten ist im Fall der spektral nur schwach auflösenden QuickBird-Daten trotz allem limitiert. Vor allem die Unterscheidung spektral ähnlicher Objekte, die keine ausgeprägte Formcharakteristik aufweisen, ist schwierig. Texturinformationen konnten erfolgreich in den Klassifikationsaufbau integriert werden. Durch die Lage der QuickBird-Kanäle und der daraus resultierenden Möglichkeit, den NDVI zu berechnen, ist eine weitere wertvolle Information verfügbar. Die Berechnung von Ratios über die *Customized-Features*-Option erleichterte die Beschreibung vieler Klassen, z. B. rote Flächen. Bei größeren Segmentierungsebenen und zunehmender Objektgröße ist auch das *Area-to-Borderlength*-Ratio ein Maß, das gut geeignet ist, um kompakte Strukturen von unregelmäßig geformten zu trennen. Dabei ist der Wert für Gebäude üblicherweise deutlich größer als für Straßen. Lediglich große Parkplätze oder ähnliche versiegelte Flächen können auch mit Hilfe dieses Ratios nicht näher beschrieben werden. Versuche, die Lage der zu klassifizierenden Objekte zu Schattengebieten zu berücksichtigen, scheiterten. Um die Lagebeziehungen von Gebäuden zu den von ihnen geworfenen Schattengebieten nutzen zu können, ist es unabdingbar, eine genaue Erfassung der Schattengebiete voranzustellen. Umgekehrt ist eine genaue Erfassung der Gebäude notwendig, um deren Schatten über Lagebeziehungen zu beschreiben. Im vorliegenden Beispiel war die Ausweisung von Schattengebieten ein notwendiges Instrument, um Fehlklassifikationen anderer Klassen (z. B. Wasser, dunkle Dächer, Bahn) zu minimieren. Sofern innerhalb der Schattenareale andere Landbedeckungsklassen genau klassifizierbar waren, wurde diesen Priorität eingeräumt. Beispielsweise sind Schatten, die auf vegetationsbestandene Flächen fallen, durch den NDVI eindeutig zu klassifizieren. Eine Ausweisung als Schattengebiet wäre bezüglich der Landbedeckung ein Informationsverlust. Die zu starke Gewichtung der Schattenareale hätte andere Strukturen, wie z. B. Straßen, unterdrückt und weitere Klassifikationsschritte erschwert.

Eine Zusatzinformation, die die Differenzierung intra-urbaner Klassen erleichtern könnte, z. B. die Unterscheidung von Straßen und Gebäuden, bieten Lidardaten durch

die Erfassung der Höheninformation einzelner Objekte relativ zu ihrer Umgebung (HEROLD & ROBERTS 2006:9). Sie sind jedoch derzeit noch teuer und waren für die vorliegende Arbeit nicht verfügbar. Darüber hinaus bieten auch Radarsysteme Informationen, die eine bessere Klassenbeschreibung ermöglichen. Wie die Arbeit zeigt, wird diese dadurch jedoch nicht zwangsläufig vereinfacht. Um eine verbesserte Klassenbeschreibung zu erzielen, reicht es nicht aus, die Klassendefinitionen aus den Radar- oder den optischen Daten zu übernehmen und um eine komplementäre Information zu erweitern. Vielmehr muss eine eindeutigere Charakteristik der einzelnen Klassen erstellt werden. Durch nicht erfassbare Veränderungen, wie z. B. Autos auf den Straßen, Züge auf den Bahnanlagen, Bauarbeiten oder dergleichen, und vor allem durch die aufnahmebedingt auftretenden Unterschiede zwischen den Datensätzen (Kapitel 2.1) ist es nicht möglich, eine Klassenbeschreibung zu finden, die die ideale Kombination aus optischen und Radardaten darstellt. Vielmehr ist es notwendig, die Klassenbeschreibung zu erweitern (Abb. 5.15). Innerhalb des Untersuchungsgebiets treten markante Unterschiede zutage. Während in Bereichen hoher offener Bebauung eine einfache Klassenbeschreibung ausreicht, um Gebäude von Straßen zu unterscheiden, muss im innerstädtischen Bereich, in dem *Foreshortening* und *Layover* erheblich größeren Einfluss haben, die Klassencharakteristik sehr viel detaillierter aufgebaut werden.

Die Analyse der räumlich hoch auflösenden Radardaten konnte ebenfalls erfolgreich mit einem objektbasierten Ansatz durchgeführt werden. Das Prinzip der *Fuzzy Classification* erwies sich als vorteilhaft. Dennoch war die erreichbare Klassentiefe bei den Radardaten erwartungsgemäß am geringsten, da Informationen zur Spezifikation gleicher Kategorien fehlen. Die Anwendung von Ratios zwischen den Aufnahmezeitpunkten brachte nicht die erwünschten Effekte, da das erfasste Radarsignal und die Art der Interaktion mit der Landoberfläche, d. h. der Rückstreuprozess, von der Flugbahn des Sensors abhängig sind und deswegen innerhalb der Klassen erheblich variieren. Straßen konnten infolge spiegelnder Streuung und sehr kleinen Radarrückstreuoeffizienten als dunkel erscheinende Flächen erfasst werden. Demgegenüber finden an Gebäuden *Double-Bounce*-Effekte statt, die diese Objekte auffällig hell erscheinen lassen, sodass Straßen und Gebäude anders als in der Auswertung der optischen Daten gut zu unterscheiden sind. Die Notwendigkeit der ausgeführten *Speckle*-Filterung kann nicht belegt werden. Da die Ableitung von Segmenten ohnehin eine Homogenisierung der Daten bewirkt, kann möglicherweise auf diesen Schritt verzichtet werden. Erschwert wurde die Klassendefinition dadurch, dass innerhalb des Radarbilds gleichartige Objekte im *Near Range* durch andere Rückstreumechanismen gekennzeichnet sind als im *Far Range*. Des Weiteren haben Objekte speziell in kleinen Levels kaum charakteristische Formen. Die Klassenbeschreibung in den Radardaten ist stärker kontextbezogen als in den optischen Daten.

Bei der synergetischen Anwendung gibt es zahlreiche Möglichkeiten der Datenfusion. Im Rahmen dieser Arbeit wurden lediglich auf dem *Feature Level* Radardaten in die optisch leichter interpretierbaren QuickBird-Daten integriert. Eine Alternative wäre, aus den Radardaten abgeleitete Klassen als thematische Layer in die synergetische

Klassifikation einzuarbeiten. Aufgrund der systembedingten geometrischen Differenzen zwischen den Datensätzen und der dadurch aufwendigeren Fusion wurde diese Möglichkeit nicht ausprobiert.

6 Zusammenfassung

Im Mittelpunkt der vorliegenden Arbeit steht die Charakterisierung urbaner Räume mittels hoch auflösender optischer und Radarfernerkundungsdaten. Die Fernerkundung urbaner Räume ist als vielseitiges Forschungsfeld für diverse Entscheidungsträger und Wissenschaftler gleichermaßen ein relevantes Werkzeug, um Entwicklungsstadien und -prozesse zu visualisieren und zu analysieren. Dazu stehen eine Reihe bewährter und neuer Sensoren zur Verfügung. In einer knappen Abhandlung wurden die grundlegenden Prinzipien der optischen und der Radarfernerkundung dargelegt. Fokussiert wurden dabei die für den urbanen Kontext bedeutenden Eigenschaften. Das Potential der Fernerkundung – speziell in den hochgradig komplexen urbanen Räumen – kann nur ausgeschöpft werden, wenn die verschiedenen Informationen mittels geeigneter Verfahren kombiniert und synergetisch genutzt werden. Aus diesem Grund wurde der Bildfusion und ihrer Qualitätskontrolle ein eigenes, umfangreiches Kapitel eingeräumt. Die Erläuterung der Vor- und Nachteile der verschiedenen pixelbasierten Verfahren führt zu dem Fazit, dass die herkömmlichen Verfahren dem Anspruch des Erhalts der spektralen Charakteristika nur bedingt gerecht werden. Dies konnte im Zuge der Vorarbeiten für die Klassifikation der QuickBird-Daten bestätigt werden. Im zweiten Kapitel des Theorieteils wurden argumentativ pixel- und objektbasierte Klassifikationsverfahren diskutiert. Den Schlussfolgerungen dieser Diskussion folgend sind objektbasierte Verfahren für die Analyse räumlich hoch auflösender Daten zu bevorzugen. Im dritten Abschnitt des Theorieteils wurden methodische Konzepte, bestehende Problemfelder sowie die vielfältigen Anwendungsmöglichkeiten im Bereich der urbanen Fernerkundung beleuchtet. Es konnte aufgezeigt werden, dass insbesondere im Feld der Datenfusion und bei der synergetischen Verwendung unterschiedlicher Informationsquellen, vor allem multisensoral, noch große Potentiale auszuschöpfen sind. Durch die erfolgreiche Inbetriebnahme von TerraSAR-X im Sommer dieses Jahres steht die Anwendung hoch auflösender Radardaten im Zentrum der Fernerkundung. Die vorliegende Arbeit hat die synergetische Verwendung hoch auflösender optischer und Radardaten aufgegriffen. Am Beispiel Erfurts wurde das Potential der Daten hinsichtlich der Charakterisierung urbaner Räume untersucht. Schwerpunkte waren dabei diverse Analysen zur Datenfusion sowie die Ausweisung von Siedlungsmasken und eine Landbedeckungsklassifikation. Zunächst wurden die panchromatischen und die multispektralen Kanäle der QuickBird-Daten fusioniert, um einen räumlich hoch auflösenden Multispektraldatensatz zu erhalten. Die Ehlers Fusion zeigte die besten Ergebnisse. Alle pixelbasierten Versuche zur Fusion der optischen und der Radardaten waren nicht zufrieden stellend. Deswegen erfolgte dieser Schritt der Datenfusion objektbasiert auf dem *Featurelevel*. Es wurden zwei Datensätze erzeugt, in denen die optischen und Radardaten jeweils einzeln klassifiziert wurden, und ein Datensatz zur synergetischen Anwendung. In einem objektbasierten Klassifikationsansatz wurden jeweils drei unterschiedliche Produkte für die Siedlungsmaske und die Landbedeckung erstellt. Erstere basieren ausschließlich auf Textur- und Kontexteigenschaften, letztere haben das volle Informationsspektrum der vorhandenen Daten zur Grundlage: Textur, spektrale Infor-

mationen, Radarrückstreuung, Ratios sowie Lage- und Kontexteigenschaften. Die Klassifizierung der optischen Daten mit einer einfachen Klassenhierarchie war infolge der Heterogenität der Szene nicht möglich, sodass zunächst auf Grundlage einer initialen Segmentierung die verhältnismäßig gut beschreibbaren Klassen analysiert wurden. Alle Restklassen, deren spektrale und Formeigenschaften keine spezifische Charakteristik aufweisen, wurden erneut segmentiert und klassifiziert. Nach einer stark situationsabhängigen Reduktion der Klassifikationslevel auf einen Basislevel konnten einzelne Klassen über Formparameter und Lagebeziehungen weiter spezifiziert werden. Die Klassifikation der Radardaten erfolgte in einer einfachen Klassifikationshierarchie, bei der ebenfalls neben den Rückstreusignalen Formparameter und Lagebeziehungen berücksichtigt wurden. Die synergetische Klassifikation folgte dem Aufbau der optischen Klassifizierung. Spektral nicht trennbare Klassen konnten durch die zusätzliche Information aus den Radardaten wesentlich besser klassifiziert werden. Allerdings wurde die Klassenbeschreibung infolge der geometrischen Radareffekte komplizierter. Die Klassifizierung der optischen Daten erlaubte eine größere Klassentiefe als die der Radardaten. Die größte Genauigkeit konnte sowohl bezüglich der Erstellung der Siedlungsmasken als auch hinsichtlich der Landbedeckungsklassifikation unter der synergetischen Verwendung von optischen und Radardaten erreicht werden. Hinsichtlich der Siedlungsmasken haben alle Produkte eine Gesamtgenauigkeit von mehr als 95 % und einen Kappakoeffizienten von 0,88 bzw. 0,89. Bei der Landbedeckung beträgt die Gesamtgenauigkeit der Klassifizierung der Radardaten ca. 69 % (Kappakoeffizient 0,66), die der optischen Daten ca. 75 % (Kappakoeffizient 0,74) und die der synergetischen Auswertung ca. 79 % (Kappakoeffizient 0,78).

Die fast schon revolutionär zu bezeichnende Inbetriebnahme von TerraSAR-X erweitert das Angebot räumlich hoch auflösender Daten um eine Informationsquelle, die in dieser Art bisher nicht operationell zur Verfügung stand. Wie die vorliegende Arbeit zeigt, verspricht die synergetische Anwendung der X-Band-Daten mit optischen Multi-spektraldaten quantitative und qualitative Verbesserungen hinsichtlich der Ableitung von Landbedeckungsinformationen und der Erstellung von Siedlungsmasken. Im Bereich der Fusion von optischen und Radardaten besteht noch Forschungsbedarf, damit systembedingte Lageunterschiede von Objekten besser Berücksichtigung finden können. In Zukunft sollte es leichter möglich sein, zeitnah hoch auflösende optische und Radardaten zu erheben und dadurch die Auswertung zu erleichtern. Im Falle der Notwendigkeit, Geoinformationen unabhängig von Witterung oder Tageszeit zu erfassen, bieten hoch auflösende Radardaten mehr als eine hilfreiche Alternative zu den visuell leichter interpretierbaren optischen Daten.

Literatur

- ALBERTZ, J. (2001²): Einführung in die Fernerkundung. Grundlagen der Interpretation von Luft- und Satellitenbildern. Darmstadt: Wissenschaftliche Buchgesellschaft.
- ATKINSON, P. M. & P. APLIN (2004): Spatial variation in land cover and choice of spatial resolution for remote sensing. In: *International Journal of Remote Sensing* 25, 18, 3687-3702.
- BAATZ, M. & A. SCHÄPE (2000): Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: STROBL, J., T. BLASCHKE & G. GRIESEBNER (Hrsg.): *Angewandte geographische Informationsverarbeitung. Beiträge zum AGIT-Symposium Salzburg 2000*. Karlsruhe, 12-23. <http://www.dlr.de/caf/anwendungen/projekte/projekte_nutzung/landsat/landsat_projekte/Projekt%20Hoffmann/lit/baatz_schaepe.pdf> (Zugriff: 2006-11-07).
- BARNESLEY, M. J. & S. L. BARR (1996): Inferring urban land use from satellite sensor images using kernel-based spatial reclassification. In: *Photogrammetric Engineering & Remote Sensing* 62, 8, 949-958.
- BARNESLEY, M. J. & S. L. BARR (2000): Monitoring urban land use by earth observation. In: *Surveys in Geophysics*, 21, 269-289.
- BASLY, L., F. CAUNEAU, T. RANCHIN & L. WALD (1998): SAR imagery in urban area. In: NIEUWENHUIS, G. J. A., R. A. VAUGHAN & M. MOLENAAR (Hrsg.): *Operational remote sensing for sustainable development. Proceedings of 18th Symposium of EARSeL*, 11.-14. Mai 1998, Enschede, 165-170.
- BAUER, M. E., N. J. HEINERT, J. K. DOYLE & F. YUAN (2004): Impervious surface mapping and change monitoring using Landsat remote sensing. In: *ASPRS Annual Conference Proceedings*, Mai 2004, Denver.
- BAUER, T. & K. STEINNOCHER (2001): Per-parcel land use classification in urban areas applying a rule-based technique. In: *GeoBIT* 6, 6, 24-27.
- BEN-DOR, E., N. LEVIN & H. SAARONI (2001): A spectral based recognition of the urban environment using the visible and near-infrared spectral region (0.4-1.1µm). A case study over Tel-Aviv, Israel. In: *International Journal of Remote Sensing* 22, 11, 2193-2218.
- BENEDIKTSSON, J. A., J. A. PALMASON & J. R. SVEINSSON (2005): Classification of hyperspectral data from urban areas based on extended morphological profiles. In: *IEEE Transactions on Geoscience and Remote Sensing* 43, 3, 480-491.
- BENZ, U., M. BAATZ & G. SCHREIER (2001): OSCAR – Object oriented segmentation and classification of advanced radar allow automated information extraction. In: *Geoscience and Remote Sensing Symposium IGARSS 2001*, 4, 1913-1915. <http://www.definiens.com/binary_secure/387_ucbenz_igarss2001_1.pdf>
- BENZ, U. C., P. HOFMANN, G. WILLHAUCK, I. LINGENFELDER & M. HEYNEN (2004): Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 58, 239-258.
- BLASCHKE, T. & J. STROBL (2001): What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. In: *GeoBIT* 6, 6, 12-17.
- BRAUN, M. & M. HEROLD (2003): Mapping imperviousness using NDVI and linear spectral unmixing of ASTER data in the Cologne-Bonn region (Germany). In: *Proceedings of SPIE 2003*, Barcelona.
- BRETSCHNEIDER, T. & O. KAO (2001): Image fusion in remote sensing. <<http://wwwcs.uni-paderborn.de/cs/ag-cao/en/persons/cao/pdfPapers/osee.pdf>> (Zugriff: 2006-08-05).
- BRUNIQUEL, J. & A. LOPES (1997): Multi-variate optimal speckle reduction in SAR imagery. In: *International Journal of Remote Sensing* 18, 3, 603-627.
- BUNTILOV, V. & T. BRETSCHNEIDER (2004): Objective content-dependent quality measures for image

- fusion of optical data. In: IEEE International Geoscience and Remote Sensing Symposium Proceedings, 20.-24. September 2004, Anchorage.
- BURNETT, C. & T. BLASCHKE (2003): A multi-scale segmentation/ object relationship modelling methodology for landscape analysis. In: *Ecological Modelling*, 168, 233-249.
- CAPSTICK, D. & R. HARRIS (2001): The effects of speckle reduction on classification of ERS SAR data. In: *International Journal of Remote Sensing* 22, 18, 3627-3641.
- CARLEER, A. P., O. DEBEIR & E. WOLFF (2005): Assessment of very high spatial resolution satellite image segmentations. In: *Photogrammetric Engineering & Remote Sensing* 71, 11, 1285-1294.
- CHEN, C.-M., G. F. HEPNER & R. R. FORSTER (2003): Fusion of hyperspectral and radar data using the IHS transformation to enhance urban surface features. In: *ISPRS Journal of Photogrammetry & Remote Sensing*, 58, 19-30.
- CHIBANI, Y. (2006): Additive integration of SAR features into multispectral SPOT images by means of the à trous wavelet decomposition. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 60, 306-314.
- CHIBANI, Y. & A. HOUACINE (2002): The joint use of IHS transform and redundant wavelet decomposition for fusing multispectral and panchromatic images. In: *International Journal of Remote Sensing* 23, 18, 3821-3833.
- CHUNMING, H., G. HUADONG, W. CHANGLIN & F. DIAN (2002): A novel method to reduce speckle in SAR images. In: *International Journal of Remote Sensing* 23, 23, 5095-5101.
- CLAYTON, D. G. (1971): Gram-Schmidt orthogonalization. Algorithm AS 46. In: *Applied Statistics* 20, 3, 335-338.
- COHEN, J. (1960): A coefficient of agreement for nominal scales. In: *Educational and Psychological Measurement* 20, 1, 37-46.
- CONGALTON, R. G. (1991): A review of assessing the accuracy of classifications of remotely sensed data. In: *Remote Sensing of Environment*, 37, 35-46.
- CORR, D. G., A. WALKER, U. BENZ, I. LINGENFELDER & A. RODRIGUES (2003): Classification of urban SAR imagery using object oriented techniques. In: *Proceedings of IGARSS 2003 IEEE*, Juli 2003, Toulouse.
- COULOIGNER, L., T. RANCHIN, V. P. VALTONEN & L. WALD (1998): Benefit of the future SPOT-5 and of data fusion to urban roads mapping. In: *International Journal of Remote Sensing* 19, 8, 1519-1532.
- DATCU, M., D. LUCA & K. SEIDEL (1996): Multiresolution analysis of SAR images. In: *Proceedings of the European Conference on Synthetic Aperture Radar EUSAR'96*, Königswinter, 375-378.
- DAUBECHIES, I. (1992): Ten lectures on wavelets. CBMS-NSF Regional Conference Series in Applied Mathematics 61. Philadelphia: SIAM.
- Definiens AG (Hrsg.) (2006a): *Definiens Professional 5 Reference Book*. Version 5.0.6.1. <<http://www.definiens.com>> (Zugriff: 2006-08-11).
- Definiens AG (Hrsg.) (2006b): *Definiens Professional 5 User Guide*. Version 5.0.6.1. <<http://www.definiens.com>> (Zugriff: 2006-08-11).
- DELL'ACQUA, F., P. GAMBA & G. LISINI (2005): Urban land cover mapping using hyperspectral and multispectral VHR sensors: Spatial versus spectral resolution. In: *Proceedings of the ISPRS joint conference 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) & 5th International Symposium Remote Sensing of Urban Areas (URS 2005)*, 14.-16. März 2005, Tempe.
- DELL'ACQUA, F., P. GAMBA & G. TRIANNI (2006): Semi-automatic choice of scale-dependent features for

- satellite SAR image classification. In: *Pattern Recognition Letters* 27, 244-251.
- DIETZEL, C., M. HEROLD, J. J. HEMPHILL & K. C. CLARKE (2005): Spatio-temporal dynamics in California's Central Valley: Empirical links to urban theory. In: *International Journal of Geographical Information Science* 19, 2, 175-195.
- DOBSON, M. C., F. T. ULABY & L. E. PIERCE (1995): Land-cover classification and estimation of terrain attributes using synthetic aperture radar. In: *Remote Sensing of Environment*, 51, 199-214.
- DONG, Y., B. C. FORSTER, A. K. MILNE & G. A. MORGAN (1998): Speckle suppression using recursive wavelet transform. In: *International Journal of Remote Sensing* 19, 2, 317-330.
- DONG, Y., B. FORSTER & C. TICEHURST (1997): Radar backscatter analysis for urban environments. In: *International Journal of Remote Sensing* 18, 6, 1351-1364.
- EDWARDS, G. & R. JEANSOULIN (2004): Data fusion – from a logic perspective with a view to implementation. In: *International Journal of Geographical Information Science* 18, 4, 303-307.
- EHLERS, M. (2005a): Urban remote sensing: New developments and trends. In: *Proceedings of the ISPRS joint conference 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) & 5th International Symposium Remote Sensing of Urban Areas (URS 2005)*, 14.-16. März 2005, Tempe.
- EHLERS, M. (2005b): Spectral characteristics preserving image fusion to facilitate computer-assisted photo-interpretation (CAPI). <http://agrifish.jrc.it/marspac/cwrs/meetings/krak%C3%B3w/T5/T5_Ehlers_Panmerge_presentation.pdf> (Zugriff: 2006-08-25).
- EHLERS, M. & S. KLONUS (2004): Erhalt der spektralen Charakteristika bei der Bildfusion durch FFT basierte Filterung. In: *Photogrammetrie, Fernerkundung, Geoinformation*, 6, 495-506.
- EHLERS, M., A. GREIWE & D. TOMOWSKI (2006): On segment based image fusion. In: *Proceedings of the 1st International Conference on Object-based Image Analysis OBIA*, 4.-5. Juli 2006, Salzburg.
- Erfurter Sportbetrieb (o.J.): Geschichte des Eissportzentrum Erfurt. <<http://www.gunda-niemannstirnemann-halle.de/geschichte.php>> (Zugriff: 2007-04-25).
- ESCH, T., A. ROTH & S. DECH (2005): Robust approach towards an automated detection of built-up areas from high resolution radar imagery. In: *Proceedings of the ISPRS joint conference 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) & 5th International Symposium Remote Sensing of Urban Areas (URS 2005)*, 14.-16. März 2005, Tempe.
- Eurimage (2006): QuickBird. The World's highest resolution commercial satellite. <<http://www.eurimage.com/products/docs/quickbird.pdf>> (Zugriff: 2006-11-29).
- FAREBROTHER, R. W. (1974): Gram-Schmidt regression. Algorithm AS 79. In: *Applied Statistics* 23, 3, 470-476.
- FITZGERALD, R. W. & B. G. LEES (1994): Assessing the classification accuracy of multisource remote sensing data. In: *Remote Sensing of Environment*, 47, 362-368.
- FOODY, G. M. (2002): Status of land cover classification accuracy assessment. In: *Remote Sensing of Environment*, 80, 185-201.
- FRAUMAN, E. & E. WOLFF (2005): Segmentation of very high spatial resolution satellite images in urban areas for segments-based classification. In: *Proceedings of the ISPRS joint conference 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) & 5th International Symposium Remote Sensing of Urban Areas (URS 2005)*, 14.-16. März 2005, Tempe.
- FROST, V. S., J. A. STILES, K. S. SHANMUGAN & J. C. HOLTZMAN (1982): A model for radar images and its

- application to adaptive digital filtering of multiplicative noise. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 4, 2, 157-166.
- FUKUDA, S. & H. HIROSAWA (1998): Suppression of speckle in synthetic aperture radar images using wavelet. In: *International Journal of Remote Sensing* 19, 3, 507-519.
- GAMBA, P., F. DELL'ACQUA & B. V. DASARATHY (2005): Urban remote sensing using multiple data sets: Past, present, and future. In: *Information Fusion*, 6, 319-326.
- GAO, J. & D. SKILLCORN (1998): Capability of SPOT XS data in producing detailed land cover maps at the urban-rural periphery. In: *International Journal of Remote Sensing* 19, 15, 2877-2891.
- GARGUET-DUPORT, B., J. GIREL, J.-M. CHASSERY & G. PAUTOU (1996): The use of multiresolution analysis and wavelets transform for merging SPOT panchromatic and multispectral image data. In: *Photogrammetric Engineering & Remote Sensing* 62, 9, 1057-1066.
- GARZELLI, A. & F. NENCINI (2005): Interband structure modelling for Pan-sharpening of very high-resolution multispectral images. In: *Information Fusion* 6, 213-224.
- GINESTE, P. (1999): A simple, efficient filter for multitemporal SAR images. In: *International Journal of Remote Sensing* 20, 13, 2565-2576.
- GOMEZ-CHOVA, L., D. FERNÁNDEZ-PRIETO, J. CALPE, E. SORIA, J. VILA & G. CAMPS-VALLS (2006): Urban monitoring using multi-temporal SAR and multi-spectral data. In: *Pattern Recognition Letters* 27, 234-243.
- GONZALEZ, R. C. & R. E. WOODS (2002²): *Digital image processing*. New Jersey: Prentice Hall.
- GOODMAN, J. W. (1976): Some fundamental properties of speckle. In: *Journal of the Optical Society of America* 66, 11, 1145-1150.
- GREIWE, A. (2005): Feature based fusion of multisensor data – inclusion of hyperspectral data into classification of high resolution orthophotos. In: ERASMI, S., B. CYFFKA & M. KAPPAS (Hrsg.): *Remote sensing & GIS for environmental studies*. Göttinger Geographische Abhandlungen 113, 273-280.
- GREIWE, A., M. BOCHOW & M. EHLERS (2004): Segmentbasierte Fusion geometrisch hoch aufgelöster und hyperspektraler Daten zur Verbesserung der Klassifikationsgüte am Beispiel einer urbanen Szene. In: *Photogrammetrie, Fernerkundung, Geoinformation*, 6, 485-494.
- GREY, W. & A. LUCKMAN (2003): Mapping urban extent using satellite radar interferometry. In: *Photogrammetric Engineering & Remote Sensing* 69, 9, 957-961.
- GUPTA, K. K. & R. GUPTA (2007): Despeckle and geographical feature extraction in SAR images by wavelet transform. In: *ISPRS Journal of Photogrammetry & Remote Sensing*, doi:10.1016/j.isprsjprs.2007.06.001.
- HAALA, N. & C. BRENNER (1999): Extraction of buildings and trees in urban environments. In: *ISPRS Journal of Photogrammetry & Remote Sensing*, 54, 130-137.
- HARALICK, R. M. & K. S. SHANMUGAM (1974): Combined spectral and spatial processing of ERTS imagery data. In: *Remote Sensing of Environment*, 3, 3-13.
- HARALICK, R. M., K. SHANMUGAM & I. DINSTEN (1973): Textural features for image classification. In: *IEEE Transactions on Systems, Man and Cybernetics* 3, 610-621.
- HARTSHORN, T. A. (1992): *Interpreting the city. An urban geography*. New York: John Wiley & Sons.
- HAY, G. J., K. O. NIEMANN & D. G. GOODENOUGH (1997): Spatial thresholds, image-objects, and upscaling: A multiscale evaluation. In: *Remote Sensing of Environment*, 62, 1-19.
- HENDERSON, F. M. & A. J. LEWIS (Hrsg.) (1998³): *Principles and applications of imaging radar*. Manual

- of remote sensing 2. New York: John Wiley & Sons.
- HEROLD, M. (2000): Ableitung hydrologischer Parameter aus multifrequenten und multipolarimetrischen E-SAR Flugzeugdaten. Diplomarbeit, Jena.
- HEROLD, M. (2004): Remote sensing and spatial metrics for mapping and modelling of urban structures and growth dynamics. Dissertation, Santa Barbara.
- HEROLD, M., H. COUCLELIS & K. C. CLARKE (2005): The role of spatial metrics in the analysis and modelling of urban land use change. In: *Computers, Environment and Urban Systems*, 29, 369-399.
- HEROLD, M., M. E. GARDNER, B. HADLEY & D. A. ROBERTS (2002a): The spectral dimension in urban land cover mapping from high-resolution optical remote sensing data. Proceedings of the 3rd Symposium on Remote Sensing of Urban Areas, Juni 2002, Istanbul.
- HEROLD, M., M. E. GARDNER & D. A. ROBERTS (2003a): Spectral resolution requirements for mapping urban areas. In: *IEEE Transactions on Geoscience and Remote Sensing* 41, 9, 1907-1919.
- HEROLD, M., N. C. GOLDSTEIN & K. C. CLARKE (2003b): The spatiotemporal form of urban growth: measurement, analysis and modeling. In: *Remote Sensing of Environment*, 86, 286-302.
- HEROLD, M., X. LIU & K. C. CLARKE (2003c): Spatial metrics and image texture for mapping urban land use. In: *Photogrammetric Engineering & Remote Sensing* 69, 9, 991-1001.
- HEROLD, M., A. MÜLLER, S. GÜNTHER & J. SCEPAN (2002b): Object-oriented mapping and analysis of urban land use/cover using IKONOS data. In: Proceedings of the 22nd EARSEL Symposium "Geoinformation for European-wide integration", Juni 2002, Prag.
- HEROLD, M. & D. A. ROBERTS (2006): Multispectral satellites – imaging spectrometry – LIDAR: Spatial – spectral tradeoffs in urban mapping. In: *International Journal of Geoinformatics* 2, 1, 1-14.
- HEROLD, M., D. A. ROBERTS, M. E. GARDNER & P. E. DENNISON (2004a): Spectrometry for urban area remote sensing – Development and analysis of a spectral library from 350 to 2400 nm. In: *Remote Sensing of Environment*, 91, 304-319.
- HEROLD, M., D. A. ROBERTS, O. SMADI & V. NORONHA (2004b): Road Condition Mapping Using Hyperspectral Remote Sensing. In: Proceedings of the 2004 AVIRIS workshop, 31. März - 2. April 2004, Pasadena.
- HEROLD, M., J. SCEPAN & K. C. CLARKE (2002c): The use of remote sensing and landscape metrics to describe structures and changes in urban land uses. In: *Environment and Planning A*, 34, 1443-1458.
- HEROLD, M. & C. C. SCHMULLIUS (2005): International earth observation initiatives and programs: the context for global urban mapping. In: Proceedings of URS2005 conference, März 2005, Phoenix.
- HIRSCHMUGL, M., H. GALLAUN, R. PERKO & M. SCHARDT (2005): „Pansharpening“-Methoden für digitale, sehr hoch auflösende Fernerkundungsdaten. In: STROBL, J., T. BLASCHKE & G. GRIESEBNER (Hrsg.): *Angewandte Geoinformatik 2005. Proceedings of 17th AGIT Symposium Salzburg 2005*. Heidelberg, 270-276. <<http://vicos.fri.uni-lj.si/roli/publications/hirschmugl/05pansharpening.pdf>> (Zugriff: 2006-09-20).
- HOFFMANN, J., T. ESCH & T. RIEDEL (2005): Risk management and security. In: ROTH, A. (Hrsg.): *Application potential of TerraSAR-X. Annex to TerraSAR-X Science Plan*. 22-37. <http://www.dlr.de/tsx/start_ge.htm> (Zugriff: 2006-08-12).
- HOFMANN, P. (2001): Detecting informal settlements from Ikonos image data using methods of object oriented image analysis – An example from Cape Town (South Africa). In: JÜRGENS, C. (Hrsg.): *Remote Sensing of Urban Areas/ Fernerkundung in urbanen Räumen*. Regensburger Geographische Schriften 35. Regensburg, 107-118.

- HOFMANN, P., J. STROBL, T. BLASCHKE & H. KUX (2006): Detecting informal settlements from QuickBird data in Rio de Janeiro using an object based approach. In: Proceedings of the 1st International Conference on Object-based Image Analysis OBIA, 4.-5. Juli 2006, Salzburg.
- IRONS, J. R. & G. W. PETERSEN (1981): Texture transforms of remote sensing data. In: Remote Sensing of Environment, 11, 359-370.
- ISLAM, Z. & G. METTERNICHT (2005): The performance of fuzzy operators on fuzzy classification of urban land covers. In: Photogrammetric Engineering & Remote Sensing 71, 1, 59-68.
- JENSEN, J. R. & D. C. COWEN (1999): Remote sensing of urban/ suburban infrastructure and socio-economic attributes. In: Photogrammetric Engineering & Remote Sensing 65, 5, 611-622.
- JIN, M., R. E. DICKINSON & D.-L. ZHANG (2005): The footprint of urban areas on global climate as characterized by MODIS. In: Journal of Climate 18, 1551-1565.
- JIN, X. & C. H. DAVIS (2005a): An integrated system for automatic road mapping from high-resolution multi-spectral satellite imagery by information fusion. In: Information Fusion 6, 257-273.
- JIN, X. & C. H. DAVIS (2005b): Automated building extraction from high-resolution satellite imagery in urban areas using structural, contextual, and spectral information. In: EURASIP Journal on Applied Signal Processing, 14, 2196-2206.
- JUTZ, S. L. & J. CHOROWICZ (1993): Geological mapping and detection of oblique extensional structures in Kenyan Rift Valley with SPOT/Landsat-TM datamerge. In: International Journal of Remote Sensing 14, 9, 1677-1688.
- KAMAGATA, N., Y. AKAMATSU, M. MORI, Y. Q. LI, Y. HOSHINO & K. HARA (2005): Comparison of pixel-based and object-based classifications of high resolution satellite data in urban fringe areas. In: Proceedings of the 26th Asian Conference on Remote Sensing, 7.-11. November 2005, Hanoi.
- KANEMASU, E. T. (1974): Seasonal canopy reflectance patterns of wheat, sorghum, and soybean. In: Remote Sensing of Environment 3, 43-47.
- KAYA, S. & P. J. CURRAN (2006): Monitoring urban growth on the European side of the Istanbul metropolitan area: A case study. In: International Journal of Applied Earth Observation, 8, 18-25.
- KIAGE, L. M., N. D. WALKER, S. BALASUBRAMANIAN, A. BABIN & J. BARRAS (2005): Applications of Radarsat-1 synthetic aperture radar imagery to assess hurricane-related flooding of coastal Louisiana. In: International Journal of Remote Sensing 26, 24, 5359-5380.
- KIEMA, J. B. K. (2002): Texture analysis and data fusion in the extraction of topographic objects from satellite imagery. In: International Journal of Remote Sensing 23, 4, 767-776.
- KIM, H.-O., B. KLEINSCHMIT & H. KENNEWEG (2005): High resolution satellite imagery for the analysis of sealing in the metropolitan area Seoul. In: Remote Sensing & GIS for Environmental Studies, Göttinger Geographische Abhandlungen 113, 281-286.
- KOCH, B., M. JOCHUM, E. IVITS & M. DEES (2003): Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren. In: Photogrammetrie, Fernerkundung, Geoinformation, 3, 195-204.
- KRAMER, H. J. (2002): Observation of the earth and its environment. Survey of missions and sensors. Berlin, Heidelberg, New York, Barcelona, Hongkong, London, Mailand, Paris, Tokio.
- KUAN, D. T., A. A. SAWCHUK, T. C. STRAND & P. CHAVEL (1985): Adaptive noise smoothing filter for images with signal-dependent noise. In: IEEE Transactions on Pattern Analysis and Machine Intelligence 7, 2, 165-177.
- KUAN, D. T., A. A. SAWCHUK, T. C. STRAND & P. CHAVEL (1987): Adaptive restoration of images with speckle. In: IEEE Transactions on Acoustics, Speech, and Signal Processing 35, 373-383.

- KUX, H. J. H. & E. H. G. ARAÚJO (2006): Multi-temporal object-oriented classifications and analysis of QuickBird scenes at a metropolitan area in Brazil (Belo Horizonte, Minas Gerais State). In: Proceedings of the 1st International Conference on Object-based Image Analysis OBIA, 4.-5. Juli 2006, Salzburg.
- LABEN, C. A. & B. V. BROWER (2000): Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. United States Patent 6,011,875.
- LANARI, R., G. ZENI, M. MANUNTA, S. GUARINO, P. BERARDINO & E. SANSOSTI (2004): An integrated SAR/GIS approach for investigating urban deformation phenomena: a case study of the city of Naples, Italy. In: International Journal of Remote Sensing 25, 14, 2855-2862.
- Landeshauptstadt Erfurt Stadtverwaltung (Hrsg.) (2007): 2007. Landeshauptstadt Erfurt. Daten · Fakten. <<http://www.erfurt.de/ef/de/rathaus/sv/veroeffentl/statistik/22507.shtml>> (Zugriff: 2007-08-22).
- LEE, J.-S. (1980): Digital image enhancement and noise filtering by use of local statistics. In: IEEE Transactions on Pattern Analysis and Machine Intelligence 2, 2, 165-168.
- LEE, J.-S. (1983): Digital image smoothing and the sigma filter. In: Computer Vision, Graphics and Image Processing 24, 255-269.
- LEWIS, A. J., F. M. HENDERSON & D. W. HOLCOMB (1998): Radar fundamentals: The geoscience perspective. In: HENDERSON, F. M. & A. J. LEWIS (Hrsg.): Principles and applications of imaging radar. Manual of remote sensing 2. New York: John Wiley & Sons, 131-182.
- LEWIS, J. J., R. J. O'CALLAGHAN, S. G. NIKOLOV, D. R. BULL & N. CANAGARAJAH (2007): Pixel- and region-based image fusion with complex wavelets. In: Information Fusion 8, 119-130.
- LI, H., B. S. MANJUNATH & S. K. MITRA (1995): Multisensor image fusion using the wavelet transform. In: Graphical Models and Image Processing 57, 3, 235-245.
- LILLESAND, T. M., R. W. KIEFER & J. W. CHIPMAN (2004⁵): Remote sensing and image interpretation. New York: John Wiley & Sons.
- LINDE, L. & W. KIRSTEIN (2004): Vergleich unterschiedlicher Klassifikationsansätze am Beispiel von hoch auflösenden Satellitenbilddaten im Raum Leipzig. In: Photogrammetrie, Fernerkundung, Geoinformation, 6, 519-526.
- LING, Y., M. EHLERS, E. L. USERY & M. MADDEN (2007): FFT-enhanced IHS transform method for fusing high-resolution satellite images. In: ISPRS Journal of Photogrammetry & Remote Sensing, 61, 381-392.
- LINGENFELDER, I., U. BENZ, R. WINKLER, R. LESSING & F. LÜNSMANN (2006): Basic land cover classification of polarimetric SAR data. <http://www.definiens.com/binary_secure/191_sar.pdf> (Zugriff: 2007-06-12).
- LIU, G., H. XIONG & S. HUANG (2000): Study on segmentation and interpretation of multi-look polarimetric SAR images. In: International Journal of Remote Sensing 21, 8, 1675-1691.
- LIU, H. & Q. ZHOU (2004): Accuracy analysis of remote sensing change detection by rule-based rationality evaluation with post-classification comparison. In: International Journal of Remote Sensing 25, 5, 1037-1050.
- LIU, J. G. (2000): Smoothing filter-based intensity modulation: a spectral preserve image fusion technique for improving spatial details. In: International Journal of Remote Sensing 21, 18, 3461-3472.
- LO, C. P. (2004): Testing urban theories using remote sensing. In: GIScience and Remote Sensing 41, 2, 95-115.
- LO, C. P. & B. J. FABER (1997): Integration of Landsat Thematic Mapper and census data for quality of life assessment. In: Remote Sensing of Environment, 62, 143-157.

- LONGLEY, P. A. (2002): Geographical information systems: will developments in urban remote sensing and GIS lead to 'better' urban geography? In: *Progress in Human Geography* 26, 2, 231-239.
- LOPES, A., E. NEZRY, R. TOUZI & H. LAUR (1993): Structure detection and statistical adaptive speckle filtering in SAR images. In: *International Journal of Remote Sensing* 14, 9, 1735-1758.
- LORETTE, A., X. DESCOMBES & J. ZERUBIA (2000): Texture analysis through a Markovian modelling and fuzzy classification: Application to urban area extraction from satellite images. In: *International Journal of Computer Vision* 36, 3, 221-236.
- LU, D. & Q. WENG (2005): Urban classification using full spectral information of Landsat ETM+ imagery in Marion County, Indiana. In: *Photogrammetric Engineering & Remote Sensing* 71, 11, 1275-1284.
- LU, D. & Q. WENG (2006): Use of impervious surface in urban land-use classification. In: *Remote Sensing of Environment*, 102, 146-160.
- MA, J., H. GUO, C. WANG, G. CHEN & V. SINGHROY (2001): Extraction of polymetallic mineralization information from multispectral Thematic Mapper data using the Gram-Schmidt Orthogonal Projection (GSOP) method. In: *International Journal of Remote Sensing* 22, 17, 3323-3337.
- MADHAVAN, B. B., K. TACHIBANA, T. SASAGAWA, H. OKADA & Y. SHIMOZUMA (2004): Automatic extraction of shadow regions in high-resolution ADS40 images. In: *International Archives of Photogrammetry & Remote Sensing* 35, Part B, 173-178.
- MAKTAV, D., F. S. ERBEK & C. JÜRGENS (2005): Remote sensing of urban areas. In: *International Journal of Remote Sensing* 26, 4, 655-659.
- MALLAT, S. G. (1989): A theory for multiresolution signal decomposition: the wavelet representation. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 11, 7, 674-693.
- MARTIN, F. J. & R. W. TURNER (1993): SAR speckle reduction by weighted filtering. In: *International Journal of Remote Sensing* 14, 9, 1759-1774.
- MARTINUZZI, S., W. A. GOULD & O. M. RAMOS GONZÁLEZ (2007): Land development, land use, and urban sprawl in Puerto Rico integrating remote sensing and population census data. In: *Landscape and Urban Planning* 79, 288-297.
- MEENAKSHISUNDARAM, V. & I. COULOIGNER (2005): Quality assessment of fusion methods for high resolution images. In: *Proceedings of the ISPRS joint conference 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) & 5th International Symposium Remote Sensing of Urban Areas (URS 2005)*, 14.-16. März 2005, Tempe.
- MEYER, F., S. HINZ, A. LAIKA, D. WEIHING & R. BAMLER (2006): Performance analysis of the TerraSAR-X Traffic monitoring concept. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 61, 225-242.
- MILLER, R. B. & C. SMALL (2003): Cities from space: potential applications of remote sensing in urban environmental research and policy. In: *Environmental Science & Policy*, 6, 129-137.
- MITTELBERG, B. (2001): *Objektorientierte Klassifikation von Fernerkundungsdaten urbaner Räume – Möglichkeiten und Grenzen*. Diplomarbeit, Bonn.
- MITTELBERG, B. (2002): Pixel versus object: A method comparison for analysing urban areas with VHR data. In: *Ecognition Application Note* 3, 2.
- MÖLLER, M., L. LYMBURNER & M. VOLK (2007): The comparison index: A tool for assessing the accuracy of image segmentation. In: *International Journal of Applied Earth Observation and Geoinformation* 9, 311-321.
- MUELLER, M., K. SEGL, U. HEIDEN & H. KAUFMANN (2006): Potential of high-resolution satellite data in

- the context of vulnerability of buildings. In: *Natural Hazards* 38, 247-258.
- MÜLLER, A. (2001): eCognition-Advanced land use classification using polarimetric high-resolution SAR. In: *eCognition Application Note* 2, 6.
- MYEONG, S., D. J. NOWAK & M. J. DUGGIN (2006): A temporal analysis of urban forest carbon storage using remote sensing. In: *Remote Sensing of Environment* 101, 277-282.
- MYEONG, S., D. J. NOWAK, P. F. HOPKINS & R. H. BROCK (2001): Urban cover mapping using digital, high-spatial resolution aerial imagery. In: *Urban Ecosystems*, 5, 243-256.
- NENCINI, F., A. GARZELLI, S. BARONTI & L. ALPARONE (2007): Remote sensing image fusion using the curvelet transform. In: *Information Fusion* 8, 143-156.
- NETZBAND, M. & W. L. STEFANOV (2003): Assessment of urban spatial variation using ASTER data. In: JÜRGENS, C. (Hrsg.): *Remote Sensing of Urban Areas. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, Vol XXXIV-7/W9*, 27.-29. Juni 2003, Regensburg, 138-143.
- NICHOL, J. & C. M. LEE (2005): Urban vegetation monitoring in Hong Kong using high resolution multispectral images. In: *International Journal of Remote Sensing* 26, 5, 903-918.
- NKAMBWE, M. (1991): URBANIFE: a geographical information system for monitoring internal developments in an African traditional urban area. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 46, 346-358.
- OUMA, Y. O., T. G. NGIGI & R. TATEISHI (2006): On the optimization and selection of wavelet texture for feature extraction from high-resolution satellite imagery with application towards urban-tree delineation. In: *International Journal of Remote Sensing* 27, 1, 73-104.
- ÖZKAN, C. & F. SUNAR ERBEK (2005): Comparing feature extraction techniques for urban land-use classification. In: *International Journal of Remote Sensing* 26, 4, 747-757.
- PAJARES, G. & J. M. DE LA CRUZ (2004): A wavelet-based image fusion tutorial. In: *Pattern Recognition*, 37, 1855-1872.
- PELLIZZERI, T. M. (2003): Classification of polarimetric SAR images of suburban areas using joint annealed segmentation and "H/A/ α " polarimetric decomposition. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 58, 55-70.
- PHINN, S., M. STANFORD, P. SCARTH, A. T. MURRAY & P. T. SHYY (2002): Monitoring the composition of urban environments based on the vegetation-impervious surface-soil (VIS) model by subpixel analysis techniques. In: *International Journal of Remote Sensing* 23, 20, 4131-4153.
- POHL, C. (1999): Tools and methods for fusion of images of different spatial resolution. In: *International Archives of Photogrammetry and Remote Sensing* 32, Part 7-4-3 W6, 3.-4. Juni 1999, Valladolid.
- POHL, C. & J. L. VAN GENDEREN (1998): Multisensor image fusion in remote sensing: concepts, methods and applications. In: *International Journal of Remote Sensing* 19, 5, 823-854.
- PORCELLO, L. J., N. G. MASSEY, R. B. INNES & J. M. MARKS (1976): Speckle reduction in synthetic-aperture radars. In: *Journal of the Optical Society of America* 66, 11, 1305-1311.
- PRASAD, N., S. SARAN, S. P. S. KUSHWAHA & P. S. ROY (2001): Evaluation of various image fusion techniques and imaging scales for forest features interpretation. In: *Current Science* 81, 9, 1218-1224.
- PIELLA, G. (2003): A general framework for multiresolution image fusion: from pixels to regions. In: *Information Fusion* 4, 259-280.
- PIERCE, L. E., K. M. BERGEN, M. C. DOBSON & F. T. ULABY (1998): Multitemporal land-cover classification using SIR-C/X-SAR imagery. In: *Remote Sensing of Environment*, 64, 20-33.

- PUISSANT, A., J. HIRSCH & C. WEBER (2005): The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. In: *International Journal of Remote Sensing* 26, 4, 733-745.
- QIU, F., J. BERGLUND, J. R. JENSEN, P. THAKKAN & D. REN (2004): Speckle noise reduction in SAR imagery using a local adaptive median filter. In: *GIScience and Remote Sensing* 41, 3, 244-266.
- QUEGAN, S., G. HE, M. SANTUARI, X. WANG & Q. WANG (2005): Land use/cover classification and rice mapping based on Envisat ASAR data. In: *Proceedings of the 2005 Dragon Symposium "Mid-Term Results"*, 27. Juni – 1. Juli 2005, Santorini.
- QUEGAN, S. & J. J. YU (2001): Filtering of multichannel SAR images. In: *IEEE Transactions on Geoscience and Remote Sensing* 39, 11, 2373-2379.
- RANCHIN, T., B. AIAZZI, L. ALPARONE, S. BARONTI & L. WALD (2003): Image fusion – the ARSIS concept and some successful implementation schemes. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 58, 4-18.
- RANCHIN, T. & L. WALD (1993): The wavelet transform for the analysis of remotely sensed images. In: *International Journal of Remote Sensing* 14, 3, 615-619.
- RANCHIN, T. & L. WALD (2000): Fusion of high spatial and spectral resolution images: The ARSIS concept and its implementation. In: *Photogrammetric Engineering & Remote Sensing* 66, 1, 49-61.
- RANEY, R. K. (1998³): Radar fundamentals: Technical perspective. In: HENDERSON, F. M. & A. J. LEWIS (Hrsg.): *Principles and applications of imaging radar. Manual of remote sensing 2*. New York: John Wiley & Sons, 9-130.
- RASHED, T., J. R. WEEKS, D. STOW & D. FUGATE (2005): Measuring temporal compositions of urban morphology through spectral mixture analysis: toward a soft approach to change analysis in crowded cities. In: *International Journal of Remote Sensing* 26, 4, 699-718.
- RATTI, C., S. DI SABATINO & R. BRITTER (2006): Urban texture analysis with image processing techniques: winds and dispersion. In: *Theoretical and Applied Climatology*, 84, 77-90.
- REES, W. G. & M. J. F. SACHELL (1997): The effect of median filtering on synthetic aperture radar images. In: *International Journal of Remote Sensing* 18, 13, 2887-2893.
- RIDD, M. K. (1995): Exploring a V-I-S (vegetation-impervious surface-soil) model for urban ecosystem analysis through remote sensing: comparative anatomy for cities. In: *International Journal of Remote Sensing* 16, 12, 2165-2185.
- ROBERTS, D. A., M. GARDNER, R. CHURCH, S. USTIN, G. SCHEER & R. O. GREEN (1998): Mapping Chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models. In: *Remote Sensing of Environment* 65, 267-279.
- ROBERTS, D. A. & M. HEROLD (2004): Imaging spectrometry of urban materials. In: King, P., M. S. Ramsey & G. Swayze (Hrsg.): *Infrared spectroscopy in geochemistry, exploration and remote sensing*. Mineral Association of Canada, Short Course Series 33, London, Ontario, 155-181.
- ROBERTS, L. G. (1965): Machine perception of three-dimensional solids. In: TIPPET, J. T., D. A. BERKOWITZ, L. C. CLAPP, C. J. KOESTER & A. VANDERBURGH Jr. (Hrsg.): *Optical and electro-optical information processing*. Cambridge: The Massachusetts Institute of Technology Press, 159-197.
- ROTH, A. (Hrsg.) (2005): Application potential of TerraSAR-X. Annex to TerraSAR-X Science Plan. <http://www.dlr.de/tsx/start_ge.htm> (Zugriff: 2006-08-12).
- RSI (Research Systems Inc.) (2003): *Envi User's Guide*. Boulder.
- RYHERD, S. & C. WOODCOCK (1996): Combining spectral and texture data in the segmentation of

- remotely sensed images. In: *Photogrammetric Engineering & Remote Sensing* 62, 2, 181-194.
- SAWAYA, K. E., L. G. OLMANSON, N. J. HEINERT, P. L. BREZONIK & M. E. BAUER (2003): Extending satellite remote sensing to local scales: land and water resource monitoring using high-resolution imagery. In: *Remote Sensing of Environment*, 88, 144-156.
- SCHIEWE, J. (2002): Segmentation of high-resolution remotely sensed data – concepts, applications and problems. In: *Symposium on Geospatial Theory, Processing and Applications, Symposium sur la théorie, les traitements et les applications des données Géospatiales, 2002, Ottawa*.
- SCHIEWE, J. & M. EHLERS (2005): A novel method for generating 3D city models from high resolution and multi-sensor remote sensing data. In: *International Journal of Remote Sensing* 26, 4, 683-698.
- SCHIEWE, J., L. TUFTE & M. EHLERS (2001): Potential and problems of multi-scale segmentation methods in remote sensing. In: *GeoBIT* 6, 6, 34-39.
- SCHNEIDER, A., M. A. FRIEDL, D. K. MCIVER & C. E. WOODCOCK (2003): Mapping urban areas by fusing multiple sources of coarse resolution remotely sensed data. In: *Photogrammetric Engineering & Remote Sensing* 69, 12, 1377-1386.
- SCHÖNWIESE, C.-D. (2003²): *Klimatologie*. Stuttgart: Ulmer.
- SEGL, K., S. ROESSNER, U. HEIDEN & H. KAUFMANN (2003): Fusion of spectral and shape features for identification of urban surface cover types using reflective and thermal hyperspectral data. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 58, 99-112.
- SEILER, U., M. NEUBERT & G. MEINEL (2004): Automatisierte Erfassung von Biotop- und Nutzungstypen – Beispiel der segmentbasierten Klassifikation von IKONOS-Satellitenbilddaten. In: *Naturschutz und Landschaftsplanung*, 4, 101-106.
- SHABAN, M. A. & O. DIKSHIT (2001): Improvement of classification in urban areas by the use of textural features: the case study of Lucknow City, Uttar Pradesh. In: *International Journal of Remote Sensing* 22, 4, 565-593.
- SHABAN, M. A. & O. DIKSHIT (2002): Evaluation of the merging of SPOT multispectral and panchromatic data for classification of an urban environment. In: *International Journal of Remote Sensing* 23, 2, 249-262.
- SHI, W., C.Q. ZHU, Y. TIAN & J. NICHOL (2005): Wavelet-based image fusion and quality assessment. In: *International Journal of Applied Earth Observation and Geoinformation*, 6, 241-251.
- SHI, W., C. ZHU, C. ZHU & X. YANG (2003): Multi-band wavelet for fusing SPOT panchromatic and multispectral images. In: *Photogrammetric Engineering & Remote Sensing* 69, 5, 513-520.
- SIMONE, G., A. FARINA, F. C. MORABITO, S. B. SERPICO & L. BRUZZONE (2002): Image fusion techniques for remote sensing applications. In: *Information Fusion*, 3, 3-15.
- SMALL, C. (2001): Estimation of urban vegetation abundance by spectral mixture analysis. In: *International Journal of Remote Sensing* 22, 7, 1305-1334.
- SMALL, C. (2003): High spatial resolution spectral mixture analysis of urban reflectance. In: *Remote Sensing of Environment*, 88, 170-186.
- SMALL, C. (2004): The Landsat ETM+ spectral mixing space. In: *Remote Sensing of Environment*, 93, 1-17.
- SMALL, C. (2005): A global analysis of urban reflectance. In: *International Journal of Remote Sensing* 26, 4, 661-681.
- SMALL, C. (2006): Comparative analysis of urban reflectance and surface temperature. In: *Remote Sensing of Environment*, 104, 168-189.

- SMALL, C. & J. W. T. LU (2006): Estimation and vicarious validation of urban vegetation abundance by spectral mixture analysis. In: *Remote Sensing of Environment*, 100, 441-456.
- SMITH, D. M. (1996): Speckle reduction and segmentation of Synthetic Aperture Radar. In: *International Journal of Remote Sensing* 17, 11, 2043-2057.
- SONG, C. (2004): Cross-sensor calibration between Ikonos and Landsat ETM+ for spectral mixture analysis. In: *IEEE Geoscience and Remote Sensing Letters* 1, 4, 272-276.
- SONG, C. (2005): Spectral mixture analysis for subpixel vegetation fractions in the urban environment: How to incorporate endmember variability? In: *Remote Sensing of Environment*, 95, 248-263.
- STATHOPOULOU, M. & C. CARTALIS (2007): Daytime urban heat islands from Landsat ETM+ and Corine land cover data: An application to major cities in Greece. In: *Solar Energy* 81, 358-368.
- STEINNOCHER, K. (1999): Adaptive fusion of multisource raster data applying filter techniques. In: *International Archives of Photogrammetry and Remote Sensing* 32, Part 7-4-3 W6, 3.-4. Juni 1999, Valladolid, 108-115.
- STEINNOCHER, K., T. BAUER, M. KÖSTL & F. KRESSLER (2001): Beobachtung von Stadtentwicklung mit Fernerkundung – Applikationen und Innovationen. In: *Österreichische Zeitschrift für Vermessung und Geoinformation* 89, 3, 145-148.
- STRANG, G. (1993): Wavelet transforms versus Fourier transforms. In: *Bulletin of the American Mathematical Society* 28, 2, 288-305.
- TAUBENBÖCK, H., T. ESCH & A. ROTH (2006): An urban classification approach based on an object-oriented analysis of high resolution satellite imagery for a spatial structuring within urban areas. In: 1st EARSel Workshop of the SIG Urban Remote Sensing, 2.-3. März 2006, Berlin.
- THIEL, C., T. RIEDEL & C. SCHMULLIUS (2006a): Investigation of scaling effects on image texture in urban areas. In: 2nd International Symposium on Recent Advances in Quantitative Remote Sensing, 25. - 29. September 2006, Torrent (Valencia), CD-ROM.
- THIEL, C., T. RIEDEL & C. SCHMULLIUS (2006b): Untersuchung der Skalenabhängigkeit der Textur im urbanen Raum mit Quickbird Daten. In: 26. Wissenschaftlich-Technische Jahrestagung der DGPF, 11. - 13. September 2006, Berlin, CD-ROM.
- THOMAS, N., C. HENDRIX & R. G. CONGALTON (2003): A comparison of urban mapping methods using high-resolution digital imagery. In: *Photogrammetric Engineering & Remote Sensing* 69, 9, 963-972.
- TLUG (Thüringer Landesanstalt für Umwelt und Geologie) (2001): Biotoptypen und Nutzungstypen. Datenstand 2003/2004.
- TORRENCE, C. & G. P. COMPO (1998): A practical guide to wavelet analysis. In: *Bulletin of the American Meteorological Society* 79, 1, 61-78.
- TOWNSHEND, J. R. G., C. HUANG, S. N. V. KALLURI, R. S. DEFRIES & S. LIANG (2000): Beware of per-pixel characterization of land cover. In: *International Journal of Remote Sensing* 21, 4, 839-843.
- TUCKER, C. J. (1979): Red and photographic infrared linear combinations for monitoring vegetation. In: *Remote Sensing of Environment* 8, 127-150.
- TUPIN, F. & M. ROUX (2003): Detection of building outlines based on the fusion of SAR and optical features. In: *ISPRS Journal of Photogrammetry & Remote Sensing* 58, 71-82.
- ULABY, F. T., P. C. DUBOIS & J. VAN ZYL (1996): Radar mapping of surface soil moisture. In: *Journal of Hydrology*, 184, 57-84.
- U.S. Census Bureau (2002): Census 2000 urban and rural classification. <http://www.census.gov/geo/www/ua/ua_2k.html> (Stand: 2006-06-23) (Zugriff: 2007-05-24).

- VAN DER SANDE, C. J., S. M. DE JONG & A. P. J. DE ROO (2003): A segmentation and classification approach of Ikonos-2 imagery for land cover mapping to assist flood risk and flood damage assessment. In: *International Journal of Applied Earth Observation and Geoinformation* 4, 217-229.
- VIDAL-PANTALEONI, A. & D. MARTI (2004): Comparison of different speckle-reduction techniques in SAR images using wavelet transform. In: *International Journal of Remote Sensing* 25, 22, 4915-4932.
- VOOGT, J. A. & T. R. OKE (2003): Thermal remote sensing of urban climates. In: *Remote Sensing of Environment*, 86, 370-384.
- VRABEL, J. (1996): Multispectral imagery band sharpening study. In: *Photogrammetric Engineering & Remote Sensing* 62, 9, 1075-1083.
- WALD, L. (1999): Definitions and terms of reference in data fusion. In: *International Archives of Photogrammetry and Remote Sensing* 32, Part 7-4-3 W6, 3.-4. Juni 1999, Valladolid.
- WALD, L., T. RANCHIN & M. MANGOLINI (1997): Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images. In: *Photogrammetric Engineering & Remote Sensing* 63, 6, 691-699.
- WARD, K. T. & G. R. JOHNSON (2007): Geospatial methods provide timely and comprehensive urban forest information. In: *Urban Forestry & Urban Greening* 6, 15-22.
- WEISE, C. (2002): Machbarkeitsuntersuchung zur Detektion urbaner Strukturen aus polarimetrischen SAR-Satellitenbilddaten. Diplomarbeit, Jena.
- WELCH, R. (1980): Monitoring urban population and energy utilization patterns from satellite data. In: *Remote Sensing of Environment* 9, 1-9.
- WEYDAHL, D. J. (2001): Analysis of ERS SAR coherence images acquired over vegetated areas and urban features. In: *International Journal of Remote Sensing* 22, 14, 2811-2830.
- WEYDAHL, D. J., F. BRETAR & P. BJERKE (2005): Comparison of RADARSAT-1 and IKONOS satellite images for urban features detection. In: *Information Fusion* 6, 243-249.
- WOODCOCK, C. E. & A. H. STRAHLER (1987): The factor of scale in remote sensing. In: *Remote Sensing of Environment* 21, 311-332.
- WU, C. & A. T. MURRAY (2003): Estimating impervious surface distribution by spectral mixture analysis. In: *Remote Sensing of Environment*, 84, 493-505.
- WU, C. & A. T. MURRAY (2005): A cokriging method for estimating population density in urban areas. In: *Computers, Environment and Urban Systems*, 29, 558-579.
- WU, S.-S., X. QIU & L. WANG (2005): Population estimation methods in GIS and remote sensing: A review. In: *GIScience and Remote Sensing* 42, 1, 80-96.
- XIAO, J., J. LI & A. MOODY (2003): A detail-preserving and flexible adaptive filter for speckle suppression in SAR imagery. In: *International Journal of Remote Sensing* 24, 12, 2451-2465.
- YANG, L., F. ALBREGTSEN, T. LØNNESTAD & P. GRØTTUM (1995): A supervised approach to the evaluation of image segmentation methods. In: *Proceedings of the 6th International Conference on Images and Patterns*, 5.-8. September 1995, Prag. *Lecture Notes in Computer Science*, 970, 759-765.
- YANG, L., C. HUANG, C. G. HOMER, B. K. WYLIE & M. J. COAN (2003a): An approach for mapping large-area impervious surfaces: synergistic use of Landsat-7 ETM+ and high spatial resolution imagery. In: *Canadian Journal of Remote Sensing* 29, 2, 230-240.
- YANG, L., G. XIAN, J. M. KLAVER & B. DEAL (2003b): Urban land-cover change detection through sub-

- pixel imperviousness mapping using remotely sensed data. In: *Photogrammetric Engineering & Remote Sensing* 69, 9, 1003-1010.
- YANG, X. (2005): Editorial. Remote sensing for urban analysis: An introduction. In: *Computers, Environment and Urban System*, 29, 497-500.
- YANG, X. & Z. LIU (2005): Use of satellite-derived landscape imperviousness index to characterize urban spatial growth. In: *Computers, Environment and Urban Systems*, 29, 524-540.
- YANG, X. & C. P. LO (2002): Using a time series of satellite imagery to detect land use and land cover changes in the Atlanta, Georgia metropolitan area. In: *International Journal of Remote Sensing* 23, 9, 1775-1798.
- YOCKI, D. A. (1996): Multiresolution wavelet decomposition image merger of Landsat Thematic Mapper and SPOT panchromatic data. In: *Photogrammetric Engineering & Remote Sensing* 62, 9, 1076-1074.
- YU, J. J. & S. QUEGAN (2000): Multi-channel filtering of SAR images. In: ERS-Envisat Symposium "Looking down to Earth in the New Millenium", 16.-20. Oktober 2000, Göteborg. <http://earth.esa.int/pub/ESA_DOC/gothenburg/1408queg.pdf> (Zugriff: 2007-05-24).
- YUAN, F. & M. E. BAUER (2006): Mapping impervious surface area using high resolution imagery: A comparison of object-based and per pixel classification. In: *ASPRS 2006 Annual Conference*, 1.-5. Mai 2006, Reno.
- YUAN, F. & M. E. BAUER (2007): Comparison of impervious surface area and normalized difference vegetation index as indicators of surface urban heat island effects in Landsat imagery. In: *Remote Sensing of Environment* 106, 375-386.
- YUAN, F., K. E. SAWAYA, B. C. LOEFFELHOLZ & M. E. BAUER (2005): Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing. In: *Remote Sensing of Environment*, 98, 317-328.
- ZAART, A. EL, D. ZIOU, S. WANG & Q. JIANG (2002): Segmentation of SAR images. In: *Pattern Recognition* 35, 713-724.
- ZHAN, Q., W. SHI & Y. XIAO (2005): Quantitative analysis of shadow effects in high-resolution images of urban areas. In: *Proceedings of the ISPRS joint conference 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) & 5th International Symposium Remote Sensing of Urban Areas (URS 2005)*, 14.-16. März 2005, Tempe.
- ZHANG, H., J. E. FRITTS & S. A. GOLDMAN (2004): An entropy-based objective evaluation method for image segmentation. In: *Proceedings of SPIE Electronic Imaging – Storage and Retrieval Methods and Applications for Multimedia*, 5307, 38-49.
- ZHANG, Q., J. WANG, P. GONG & P. SHI (2003): Study of urban spatial patterns from SPOT panchromatic imagery using textural analysis. In: *International Journal of Remote Sensing* 24, 21, 4137-4160.
- ZHANG, X., M. A. FRIEDL, C. B. SCHAAF, A. H. STRAHLER & A. SCHNEIDER (2004): The footprint of urban climates on vegetation phenology. In: *Geophysical Research Letters* 31, L12209, doi:10.1029/2004GL020137.
- ZHANG, Y. (1999): A new merging method and its spectral and spatial effects. In: *International Journal of Remote Sensing* 20, 10, 2003-2014.
- ZHANG, Y. (2002): Problems in the fusion of commercial high-resolution satellite images as well as Landsat 7 images and initial solutions. In: *International Archives of Photogrammetry and Remote Sensing (IAPRS)* 34, Part 4 "GeoSpatial Theory, Processing and Applications", Juli 2002, Ottawa.
- ZHANG, Y., B. GUINDON & J. CIHLAR (2002): An image transform to characterize and compensate for spatial variations in thin cloud contamination of Landsat images. In: *Remote Sensing of*

Environment, 82, 173-187.

ZHANG, Y. & G. HONG (2005): An IHS and wavelet integrated approach to improve pan-sharpening visual quality of natural colour Ikonos and QuickBird images. In: Information Fusion, 6, 225-234.

ZHANG, Y. J. (1996): A survey on evaluation methods for image segmentation. In: Pattern Recognition 29, 8, 1335-1346.

ZHANG, Y. J. (1997): Evaluation and comparison of different segmentation algorithms. In: Pattern Recognition Letters 18, 963-974.

ZHENG, Y., E. A. ESSOCK, B. C. HANSEN & A. M. HAUN (2007): A new metric based on extended spatial frequency and its application to DWT based fusion algorithms. In: Information Fusion 8, 177-192.

ZHOU, J., D. L. CIVCO & J. A. SILANDER (1998): A wavelet transform method to merge Landsat TM and SPOT panchromatic data. In: International Journal of Remote Sensing 19, 4, 743-757.

Internetseiten

<<http://earth.google.com/intl/de/>> (Stand: variabel) (Zugriff: 2007-10-05).

<http://maps.google.de/maps?oi=eu_map&q=Erfurt&hl=de> (Stand: 2005) (Zugriff: 2007-06-02).

<<http://www.rsinc.com/codebank/>> (Stand: 2006-10-10) (Zugriff: 2006-10-10).

Erklärung

Ich erkläre, dass ich die vorliegende Arbeit selbstständig und nur unter Verwendung der angegebenen Literatur und Hilfsmittel verfasst habe. Sämtliche Stellen, die anderen Werken entnommen sind, wurden unter Angabe der Quellen als Entlehnung kenntlich gemacht.

Jena, 13. November 2007

Frank Thonfeld