

**Automatisierte
Analyse von Siedlungsflächen
auf der Basis höchstauflösender Radardaten**

Dissertation zur Erlangung des
naturwissenschaftlichen Doktorgrades
der Bayerischen Julius-Maximilians Universität Würzburg

vorgelegt von
Thomas Esch

aus
München

Würzburg, Mai 2006

Eingereicht am: 08.05.2006

1. Gutachter: Prof. Dr. Stefan Dech
2. Gutachter: Prof. Dr. Rüdiger Glaser
der Dissertation.

1. Prüfer: Prof. Dr. Stefan Dech
2. Prüfer: Prof. Dr. Jürgen Rauh
der mündlichen Prüfung.

Tag der mündlichen Prüfung: 26.07.2006

Doktorurkunde ausgehändigt am:

Abstract

Urban areas feature an increasing dynamic of ecological, economic and social changes. This trend increases the demand for innovative methods to detect and monitor the resulting effects on the urban environment. In this context *space borne earth observation* has proven to be a cost-effective tool to gain profitable geo-information on various phenomena that concern spatial planning. Withal, in the near future *new radar satellite systems* such as TerraSAR-X, Radarsat-2 or ALOS-PalSAR will provide a basis for the operational and detailed analysis of settlements for the first time in history.

In view of these satellite missions *this dissertation investigates the capabilities of high resolution SAR imagery with respect to an automated analysis of urban characteristics.*

The underlying methodology is based on the object-oriented image analysis software eCognition. In this context the investigations have shown that both the effect of radar speckle and deficiencies regarding the quality of image segmentation as well as the definition of appropriate segmentation settings restrict the efficiency of a segment-based approach. Hence, this dissertation initially focuses on the development of concepts to *optimise and stabilise the process of an object-oriented analysis of radar data.* So far, numerous speckle suppression filters have been developed. However, this study could show that there is still an ongoing demand for an effective and texture-preserving reduction of image speckle in dissected urban environments. Therefore, an *innovative filtering algorithm is developed* which allows for a more potent reduction of speckle noise in homogeneous areas while still preserving the texture information in highly structured regions of the SAR image. The difficulties associated with the accuracy and robustness of image segmentation are addressed by the *development of a classification-based object-refinement procedure.* At the same time this procedure allows for a more transparent and target-oriented definition of the image segmentation settings.

However, the main focus of this dissertation is put on the *development of concepts for an automated analysis of the regional and local structure of settlements.* In the *regional context* the work aims at both *identifying built-up areas* and *deriving land use categories* such as settlement, open area, forest and water bodies. Thereby a

rule base is first created which allows for the analysis of single-polarised SAR data. These rules mainly involve spatially and temporally robust, textural, hierarchical and context-related features. Next, this knowledge base is modified in order to facilitate the analysis of dual-polarised, dual-frequency or combined optical and radar-based imagery. The results of this study show that the settlements and the defined land use classes can be identified with an overall accuracy of around 90 percent – even on the basis of single-polarised SAR data. By considering an additional polarisation, frequency or optical data set this accuracy can be increased significantly to values of up to 95 percent.

The *local analyses* aim at a spatially and thematically more detailed description of the *land use pattern within built-up areas*. Since an isolated analysis of SAR-data – even when combining different polarisations or frequencies – could not suffice to characterise the highly dissected urban environment, this investigation is based on the synergetic use of a high-resolution SAR image and a medium resolution optical data set. In this context the radar image is mainly employed to describe the urban topography, while the optical data provides important features for the detailed differentiation of the extracted structural units into the categories building, sealed surface, unsealed surface and trees. The result of this study exemplifies that the synergetic analysis of a high resolution SAR image and a medium resolution optical data set enables the survey of the defined urban land use classes with a comparably limited accuracy of 65 percent. Nevertheless, within the scope of this classification the category “building” could be identified with an accuracy of 72 percent.

This dissertation aimed at *demonstrating the suitability of high resolution SAR data for the characterisation of urban environments based on an established image analysis approach*. With regard to this objective the dissertation has demonstrated that an automated analysis of built-up areas encounters significant difficulties due to the limited spectral resolution and the strong dependency of backscatter on the viewing and target geometry. Nevertheless, the functionality of the multiscale object-oriented classification approach could compensate for these limitations to some degrees. Thereby, the regional analyses – including the identification of built-up areas and the analysis of land use – led to convincing results. In contrast, the characterisation of the local urban land use pattern pointed out the limitations of radar remote sensing for classifying complex urban environments.

Kurzfassung

Städtische Agglomerationen und deren Umland zeichnen sich durch eine zunehmende Dynamik ökologischer, ökonomischer und sozialer Veränderungen aus. Um dabei eine nachhaltige Entwicklung urbaner Räume zu gewährleisten, bedarf es verstärkt innovativer Methoden zur Erfassung der raumwirksamen Veränderungen. Diesbezüglich hat sich die *satellitengestützte Erdbeobachtung* als kostengünstiges Instrumentarium zur Erhebung planungsrelevanter Informationen erwiesen. Mit Systemen wie TerraSAR-X, Radarsat-2 oder ALOS-PalSAR wird zudem in naher Zukunft eine *neue Generation von Radarsatelliten* zur Verfügung stehen, deren Leistungsvermögen erstmals eine operationelle und differenzierte Analyse von Siedlungsflächen auf Grundlage von Radardaten ermöglicht.

Vor diesem Hintergrund ist es das Ziel der Dissertation, auf der Basis einer nutzerorientierten Methodik das Potential hochauflösender SAR-Daten zur automatisierten Erfassung und Analyse von Siedlungsflächen zu untersuchen.

Die Methodik setzt dabei auf dem objektorientierten Bildanalysekonzept der Software eCognition auf. In diesem Kontext haben sich der SAR-Speckle sowie Schwächen hinsichtlich der Güte der Bildsegmentierung bzw. der Bestimmung geeigneter Segmentierungseinstellungen als Limitierungen erwiesen. Aus diesem Grunde liegt ein erster Schwerpunkt der Arbeit auf der *Optimierung und Stabilisierung einer segmentbasierten Auswertung von Radardaten*. Obwohl bereits zahlreiche Filterverfahren zur Reduzierung des Bildrauschens entwickelt wurden, hat sich gezeigt, dass mit Blick auf die kleinteilig strukturierten Siedlungsareale weiterhin Optimierungsbedarf hinsichtlich einer effizienten, struktur-erhaltenden Bildglättung besteht. Daher wird zunächst ein *neuer Filteransatz entwickelt*, der gegenüber den etablierten Techniken eine konsequentere Reduzierung des Speckle in homogenen Bildarealen gewährleistet und dabei gleichsam die hochfrequente Information in stark strukturierten Aufnahmebereichen bewahrt. Die Schwierigkeiten im Zusammenhang mit der Güte und Übertragbarkeit der Bildsegmentierung werden ebenso wie die Schwächen im Hinblick auf die zielgerichtete Definition der optimalen Segmentierungsparameter durch die *Entwicklung eines klassenbasierten Ansatzes zur Segmentoptimierung* in der Software-Umgebung von eCognition reduziert. Der zweite Schwerpunkt dieser

Dissertation widmet sich der *Entwicklung von Konzepten zur automatisierten Analyse der regionalen und lokalen Siedlungsstruktur*. Im *regionalen Kontext* liegen die *Identifizierung von Siedlungsflächen* und die *Erfassung der Landnutzungsklassen* Siedlung, Baumbestand, Offenland und Wasserflächen im Fokus der Arbeiten. Dazu wird zunächst ein Regelwerk zur Auswertung einfach-polarisierter SAR-Aufnahmen erstellt, das sich maßgeblich auf räumlich und zeitlich robuste textur-, kontext- und hierarchiebezogene Merkmale stützt. Diese Wissensbasis wird anschließend so erweitert, dass sie die Analyse dual-polarisierter, bifrequenter oder kombinierter optischer und SAR-basierter Bilddaten ermöglicht. Wie die Ergebnisse zeigen, können Siedlungsflächen und Landnutzungsklassen bereits über einfach-polarisierte SAR-Aufnahmen mit Genauigkeiten von rund 90 Prozent erfasst werden. Durch die Einbindung einer weiteren Polarisation, Frequenz oder optischer Daten lässt sich diese Güte auf Werte von bis zu 95 Prozent steigern.

Die *lokalen Analysen* zielen auf die *thematisch und räumlich differenzierte Erfassung der Landnutzung innerhalb bebauter Areale* ab. Die Untersuchung basiert auf der synergetischen Auswertung einer hochauflösenden Radaraufnahme und eines bedeutend geringer aufgelösten optischen Datensatzes. Die isolierte Analyse von SAR-Aufnahmen reichte hingegen selbst bei der Kombination verschiedener Frequenzen oder Polarisationen nicht zur Charakterisierung der kleinteiligen, heterogenen Stadtlandschaft aus. Im Kontext der synergetischen Auswertung dient die SAR-Aufnahme vornehmlich zur Extraktion der urbanen Topografie, während der optische Datensatz wichtige Merkmale zur Differenzierung der erfassten Struktureinheiten in die Kategorien Gebäude, versiegelte Freifläche, unversiegelte Freifläche und Baumbestand beisteuert. Das Resultat zeigt, dass sich trotz des synergetischen Ansatzes lediglich eine Genauigkeit von 65 Prozent erzielen lässt. Dennoch können Gebäude dabei mit einer Güte von 72 Prozent vergleichsweise akkurat erfasst werden.

Im Hinblick auf den zentralen Aspekt dieser Dissertation – *die Demonstration des siedlungsbezogenen Anwendungspotentials höchstauflösender SAR-Daten unter Berücksichtigung eines etablierten Verfahrens zur automatisierten Bildanalyse* – lässt sich resümieren, dass eine automatische Ableitung siedlungsstruktureller Merkmale im komplexen städtischen Umfeld aufgrund der eingeschränkten spektralen Aussagekraft und der starken Geometrieabhängigkeit des Signals mit signifikanten Schwierigkeiten verbunden ist. Dennoch hat sich gezeigt, dass diese Limitierungen in gewissem Umfang über den Ansatz der multiskaligen, objektorientierten Klassifizierung kompensiert werden können. Dabei lassen sich die regionalen Siedlungs- und Landnutzungsmuster mit überzeugenden Genauigkeiten erfassen, während die Betrachtung der lokalen Siedlungsstruktur eindeutig die Grenzen der Radartechnik im Hinblick auf die Analyse komplex strukturierter Stadtlandschaften aufzeigt.

Danksagung

An dieser Stelle möchte ich mich bei allen, die zum Gelingen meiner Dissertation beigetragen haben, recht herzlich bedanken.

Ganz besonders möchte ich mich bei Herrn Prof. Dr. Stefan Dech für die engagierte Betreuung dieser Dissertation, die kompetenten Ratschläge und die stets konstruktive Kritik bedanken, die maßgeblich zum Gelingen meiner Arbeit beigetragen haben. Ebenso sei Herrn Prof. Dr. Rüdiger Glaser für seine fachkundige Betreuung, die Übernahme des Zweitgutachtens und die anregenden Diskussionen gedankt.

Die vorliegende Arbeit entstand am Deutschen Fernerkundungsdatenzentrum (DFD) des Deutschen Zentrums für Luft- und Raumfahrt e.V. (DLR). Mein besonderer Dank gilt daher der Leitung der Abteilung Umwelt und Geoinformation (UG), Herrn Dr. Harald Mehl, für die Bereitstellung der Infrastruktur und Ressourcen zur Erstellung dieser Arbeit. An dieser Stelle sei auch allen Mitarbeiterinnen und Mitarbeitern der Abteilung UG für das angenehme Arbeitsklima und die zahlreichen fachlichen und privaten Diskussionen gedankt.

Mein besonderer Dank gilt darüber hinaus dem Leiter des Team SAR-Topografie, Herrn Achim Roth (DLR), der mit seinem hohen wissenschaftlichen Sachverstand und großem Engagement stets positive Impulse für meine Arbeit gesetzt hat. In diesem Kontext danke ich auch dem gesamten Team SAR-Topografie für die überaus herzliche Atmosphäre, die enorme Hilfsbereitschaft und die immer wieder anregenden, aber auch zerstreuenden Gespräche.

Ein herzliches Dankeschön auch an Herrn Dr. Claus Peinemann vom Raumordnungsverband Rhein-Neckar, Frau Waltraud Funck vom Dezernat 4 für Bau, Umwelt und Verkehr der Stadt Ludwigshafen und Herrn Martin Sturm vom Fachbereich Organisation der Stadt Ludwigshafen für die freundliche Bereitstellung von Vergleichsdaten und die hilfreichen, fachlichen Anmerkungen. Bedanken möchte ich mich zudem bei allen, die mich bei der Erstellung der Arbeit eifrig unterstützt

haben. Dabei sei insbesondere Herr Dr. Jörn Hoffmann hervorgehoben, der durch seine tatkräftige Hilfe bei der Programmierung des Speckle-Filters und die stets wertvollen und kompetenten Beiträge auch neben der Arbeit immer ein wichtiger Ansprechpartner war. Ferner sei Herrn Martin Habermeyer und Herrn Michael Bock für die hohe Diskussionsbereitschaft und ihre zahlreichen fachkundigen Anmerkungen gedankt. Nicht zuletzt möchte ich mich bei sämtlichen Korrekturleserinnen und Korrekturlesern für ihre Unterstützung und aufgebrauchte Zeit bedanken. Besonders sei Herr Norman Beaujean für die professionelle Rechtschreib- und Grammatikkontrolle gedankt.

Mein ganz besonderer Dank gilt Katja Beaujean für ihre bemerkenswerte Geduld beim Diskutieren, Motivieren und Korrigieren. Sie hat mich immer wieder mit den richtigen, aufmunternden Worten unterstützt und die zahlreichen Abende und Wochenenden, die der Arbeit an der Dissertation gewidmet waren, mit liebevoller Geduld hingenommen.

Meine ausdrückliche Anerkennung gebührt meinen Eltern Ursula und Bruno Esch, ohne deren Rückhalt und vorbehaltlose Unterstützung mein Studium und die Durchführung dieser Dissertation nicht möglich gewesen wären.

Abbildungsverzeichnis

Kapitel 2: Grundlagen

Abb. 2-1	Elektromagnetisches Spektrum und Aufnahmebereiche verschiedener Sensortypen	12
Abb. 2-2	Charakteristische Reflektionskurven von Wasser, Vegetation und unbedecktem Boden	13
Abb. 2-3	Clusterbildung im mehrdimensionalen Merkmalsraum	18
Abb. 2-4	Aufnahmegeometrie eines SAR-Systems	22
Abb. 2-5	Wellenlängenabhängige Variation der Radarrückstreuung zwischen X-Band und L-Band	26
Abb. 2-6	Vergleich zwischen den Rückstreubeiträgen in L-HH- und L-HV-Polarisation	28
Abb. 2-7	Einfluss des Einfallswinkels auf das Streuverhalten identischer Oberflächen in Near Range und Far Range	29
Abb. 2-8	Charakteristische Streumechanismen im urbanen Umfeld	31
Abb. 2-9	Variierende Rückstreuintensitäten im X-Band aufgrund wechselnder Oberflächenrauigkeiten	32
Abb. 2-10	Anstieg der Rückstreuintensität mit zunehmendem Wassergehalt in einer X-Band Aufnahme am Beispiel beregneter Ackerflächen	33
Abb. 2-11	Geometriebedingte Verzerrungseffekte in Radaraufnahmen	35
Abb. 2-12	Geometriebedingte Verzerrungs- und Abschattungseffekte am Beispiel eines Gebäudes	36
Abb. 2-13	Komplexer Streuvektor einer Auflösungszelle	37
Abb. 2-14	Speckle-Effekt in SAR-Aufnahmen	39

Kapitel 3: Arbeitsbasis

Abb. 3-1	Region Rhein-Neckar und Lage der Testgebiete	43
Abb. 3-2	Pixelbasierte und objektorientierte Repräsentation urbaner Strukturen	49
Abb. 3-3	Menü zur Steuerung der Multiresolution Segmentation und schematische Darstellung einer drei Ebenen umfassenden Bildsegmentierung	50
Abb. 3-4	Aufbau und Ebenen der Class Hierarchy	52
Abb. 3-5	Definition von Klassen und deren Merkmalsbeschreibung in der Class Hierarchy	53

Kapitel 4: Methodenentwicklung

Abb. 4-1	X-Band Intensitätsbild und daraus abgeleitete Varianz 5x5	56
Abb. 4-2	Bildglättung einer X-Band Aufnahme mittels Frost- und Lee-Sigma-Algorithmus sowie Ableitung der entsprechenden Varianzen	58
Abb. 4-3	Intensitätsbild, lokale Varianz zur Kennzeichnung signifikanter Kanten sowie gemittelte lokale Varianz zur Charakterisierung der Kantendichte	60
Abb. 4-4	Texturabhängige Anpassung der Filterstärke	61

Abb. 4-5	Ergebnis der Filterung mittels des neu entwickelten SelectiveMean-Algorithmus	62
Abb. 4-6	Gegenüberstellung von ursprünglicher Intensitätsaufnahme sowie Frost-, Lee-Sigma- und SelectiveMean-gefiltertem Datensatz	63
Abb. 4-7	Quantitativer Vergleich zwischen der Wirkung verschiedener Filteralgorithmen zur Bildglättung	64
Abb. 4-8	Prozentuale Veränderung der Pixelwerte zwischen ursprünglicher Intensitätsaufnahme und gefiltertem Datensatz	65
Abb. 4-9	Intensitätsbild und Gegenüberstellung des Coefficient of Variation berechnet auf Basis des Frost-, Lee-Sigma- und SelectiveMean-gefilterten Datensatzes	66
Abb. 4-10	Einfluss der Filterung auf die Bildsegmentierung	66
Abb. 4-11	Einsatz des SelectiveMean-Filters zur Aufwertung optischer Daten (HRSC)	67
Abb. 4-12	Segmentierung eines identischen Ausschnitts mit leicht variierender Parametrisierung	69
Abb. 4-13	Ablauf der klassenbasierten Segmentoptimierung	71
Abb. 4-14	Beschreibung der spektralen Affinität zwischen Sub- und Superobjekt	74
Abb. 4-15	Klassenhierarchie zur Segmentoptimierung mehrkanaliger Bilddaten ohne und mit flächenbezogenen Merkmalen	75
Abb. 4-16	Segmentierung eines identischen Ausschnitts mit variierender Parametrisierung basierend auf der Multiresolution Segmentation und neu entwickelter Optimierungsprozedur	78
Abb. 4-17	Vergleich zwischen der Segmentierung eines hochaufgelösten Luftbildes basierend auf der herkömmlichen Multiresolution Segmentation und der klassenbasierten Segmentoptimierung	79
Abb. 4-18	Korrekturebene, Optimierungsebene und Texturebene als Basis zur Klassifizierung von Siedlungsflächen	89
Abb. 4-19	Hierarchischer Klassifizierungsbaum zur Erfassung von Siedlungsflächen auf der Basis einfach-polarisierter SAR-Aufnahmen	91
Abb. 4-20	Identifizierung von Siedlungsflächen auf der Optimierungsebene (Level 2)	94
Abb. 4-21	Siedlungsmaske auf Level 2 und deren Korrektur sowie thematische Erweiterung auf Level 1	96
Abb. 4-22	Identifizierung hochstrukturierter Bildbereiche auf Basis der Intensität und Varianz einer co- bzw. dual-polarisierten SAR-Aufnahme	103
Abb. 4-23	Sichtbarkeit von Baustrukturen im X- und L-Band	106
Abb. 4-24	Regelwerk zur Siedlungserfassung und modifizierte Wissensbasis zur kombinierten Auswertung optischer und radarbasierter Daten	108
Abb. 4-25	Verbesserte Abgrenzung der Siedlungsränder über die Kombination von SAR-basierten und optischen Daten	109
Abb. 4-26	Regionale Landnutzungsklassifikation auf der Basis einer co-polarisierten X-Band Aufnahme im Vergleich zur DTK25 (Flugstreifen 1)	113
Abb. 4-27	Regionale Landnutzungsklassifikation auf der Basis einer co-polarisierten X-Band Aufnahme im Vergleich zur DTK25 (Flugstreifen 2)	114
Abb. 4-28	Regionale Landnutzungsklassifikation auf der Basis einer co-polarisierten X-Band Aufnahme im Vergleich zur DTK25 (Flugstreifen 3)	115
Abb. 4-29	Ausschnitt der regionalen Landnutzungsklassifikation auf Basis HH-polarisierter X-Band Daten	118
Abb. 4-30	Fehlerhafte Ausweisung von Offenland im Kontext von Wasserflächen aufgrund	119

	starker Überstrahlungseffekte durch benachbarte Corner-Reflektoren	
Abb. 4-31	Gegenüberstellung der regionalen Landnutzungsklassifikation basierend auf X-, C- und L-Band Daten	121
Abb. 4-32	Gegenüberstellung der regionalen Landnutzungsklassifikation im X- und L-Band	123
Abb. 4-33	Resultat der regionalen Landnutzungsklassifizierung basierend auf der Auswertung einer dual-polarisierten C-Band Aufnahme (HH,HV)	126
Abb. 4-34	Regionale Landnutzungsklassifikation basierend auf single-polarisierter (HH) bzw. dual-polarisierter (HH,HV) C-Band Datenbasis	127
Abb. 4-35	Verbesserte Abgrenzung bebauter Areale gegenüber bewässerten Ackerflächen durch kombinierte Analyse der Co- und Cross-Polarisation	128
Abb. 4-36	Regionale Landnutzungsklassifikation basierend auf X-Band (HH), L-Band (HH) sowie kombinierter Analyse beider Datensätze	131
Abb. 4-37	Regionale Landnutzungsklassifikation auf der Basis einer bifrequenten Auswertung im Vergleich zur DTK25	132
Abb. 4-38	Vergleichende Betrachtung der regionalen Landnutzungsklassifikation auf der Grundlage einer isolierten Analyse des X- und L-Bandes sowie einer kombinierten Auswertung beider Frequenzen	134
Abb. 4-39	Ergebnis der Landnutzungsklassifizierung basierend auf der synergetischen Auswertung eines X-Band Datensatzes und einer IRS-Aufnahme	136
Abb. 4-40	Landnutzung abgeleitet aus X-Band Datensatz bzw. kombinierter Auswertung von X-Band und IRS-Aufnahme im Vergleich zur DTK25	137
Abb. 4-41	Landnutzungsklassifikation auf der Basis einer isolierten Analyse des X-Bandes und der synergetischen Auswertung von X-Band und IRS-Datensatz	139
Abb. 4-42	Segmentierungsebenen zur Ableitung der urbanen Landnutzung	146
Abb. 4-43	Erscheinungsbild einer Siedlungsfläche in höchstauflösenden SAR-Daten (X-Band, 2m), geringer aufgelöster optischer Aufnahme (IRS, 6m) sowie Überlagerung beider Datensätze	148
Abb. 4-44	Klassenhierarchie zur Erfassung der urbanen Landnutzung	149
Abb. 4-45	Differenzierung zwischen ebenen und vertikalen Raumstrukturen auf Basis von Radardaten	150
Abb. 4-46	Klassifikationsablauf zur Erfassung der urbanen Landnutzung	151
Abb. 4-47	Ergebnis der urbanen Landnutzungsklassifizierung basierend auf der synergetischen Auswertung von X-Band und IRS-Datensatz	153
Abb. 4-48	Vergleich des Detaillierungsgrads einer urbanen Landnutzungskartierung basierend auf X-Band Datensatz, IRS-Aufnahme, Kombination beider Datentypen sowie Luftbild	155
Abb. 4-49	Pseudo-3D-Darstellung der klassifizierten Strukturen am Beispiel repräsentativer Baublöcke	158
Abb. 4-50	Beispiel für pseudo-3D-Darstellung der klassifizierten Stadtstrukturen und darauf basierender Ableitung des Versiegelungsgrades	160

Tabellenverzeichnis

Kapitel 2: Grundlagen

Tab. 2-1	Anforderungen an die Eigenschaften von Satellitendaten im Hinblick auf die Beobachtung raumwirksamer Veränderungen im urbanen Umfeld	16
Tab. 2-2	Frequenz und Wellenlänge ausgewählter Radarbänder	21

Kapitel 3: Arbeitsbasis

Tab. 3-1	Technische Merkmale des E-SAR Systems	45
Tab. 3-2	Aufnahmeparameter der Befliegung im Raum Ludwigshafen/Mannheim	46
Tab. 3-3	Technische Daten des IRS-1D Satelliten	47
Tab. 3-4	Referenzdaten	48

Kapitel 4: Methodenentwicklung

Tab. 4-1	Vergleich der Objektgüte zwischen Multiresolution Segmentation und neu entwickelter Optimierungsprozedur	80
Tab. 4-2	Einstellungen zur Segmentierung einfach-polarisierter E-SAR-Aufnahmen	88
Tab. 4-3	Einstellungen zur Segmentierung dual-polarisierter oder bifrequenter SAR-Daten	99
Tab. 4-4	Segmentierungsparameter für kombinierte Datenbasis aus X-Band Aufnahme und IRS-Datensatz	100
Tab. 4-5	Thematische Güte der Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten	111
Tab. 4-6	Güte der Landnutzungskartierung basierend auf HH-polarisierten X-, C- und L-Band Daten	120
Tab. 4-7	Güte der regionalen Landnutzungserfassung mittels einfach- bzw. dual-polarisierter C-Band Daten	125
Tab. 4-8	Güte der regionalen Landnutzungskartierung auf Basis HH-polarisierter X- und L-Band Daten sowie einer kombinierten Auswertung beider Frequenzen	130
Tab. 4-9	Genauigkeit der regionalen Landnutzungserfassung auf der Basis kombiniert ausgewerteter optischer und SAR-basierter Daten	138
Tab. 4-10	Übersicht der Genauigkeiten in der Siedlungserfassung und regionalen Landnutzungs-klassifizierung	142
Tab. 4-11	Segmentierungsparameter zur urbanen Analyse auf der Grundlage einer kombinierten Datenbasis aus X-Band-Aufnahme und IRS-Datensatz	145
Tab. 4-12	Güte der urbanen Landnutzungserfassung auf Basis einer kombinierten Analyse optischer und SAR-basierter Daten	154

Kapitel 5: Fazit

Tab. 5-1	Einfluss system- und objektspezifischer Aufnahmeparameter im Rahmen der Analyse urbaner Räume	167
Tab. 5-2	Bewertung der Software eCognition 3.2	168

Abkürzungsverzeichnis

ABB	Abbildung
ALOS-PalSAR	Advanced Land Observation Satellite, Phased Array Type L-band Synthetic Aperture Radar
ARES	Airborne Reflective Emissive Spectrometer
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
ATKIS	Amtliches Topografisch-Kartografisches Informationssystem
AVHRR	Advanced Very High Resolution Radiometer
BMU	Bundesministerium für Umwelt, Naturschutz und Reaktorsicherheit
dB	Dezibel
DGK5	Digitale Grundkarte 1:5.000
DTK25	Digitale Topografische Karte 1:25.000
DLR	Deutsches Zentrum für Luft- und Raumfahrt e.V.
DFD	Deutsches Fernerkundungsdatenzentrum des DLR
DN	Digital number
ENVISAT	Environmental Satellite
ERS	European Remote Sensing Satellite
ESA	European Space Agency
E-SAR	Experimental Synthetic Aperture Radar
GMES	Global Monitoring for Environment and Security
GHz	GigaHertz
HyMap	Hyperspectral Mapper
HH	Horizontal gesendet, horizontal empfangen (Polarisation)
HV	Horizontal gesendet, vertikal empfangen (Polarisation)
HF	Institut für Hochfrequenztechnik des DLR
HRSC	High Resolution Stereo Camera
IHS	Intensity Hue Saturation (Farbraum)
IRS	Indian Remote Sensing Satellite
ISODATA	Iterative Self-Organizing Data Analysis Technique
JAXA	Japan Aerospace Exploration Agency
JERS	Japanese Earth Resources Satellite
JPL	Jet Propulsion Laboratory
LOS	Line of sight
MAP-Filter	Maximum-Aposteriori-Filter
MDA	MacDonald, Dettwiler and Associates Ltd.
MHz	MegaHertz
MKRO	Ministerkonferenz für Raumordnung

MODIS	Moderate Resolution Imaging Spectroradiometer
NASA	National Aeronautics and Space Administration
NDVI	Normalized Difference Vegetation Index
NIR	Nah-Infrarot
NOAA	National Oceanic and Atmospheric Administration
NRSA	National Remote Sensing Agency of India
PAN	Panchromatischer Kanal
RAR	Real Aperture Radar
RGB	Rot-Grün-Blau (Farbraum)
ROV	Raumordnungsverband
SAR	Synthetic Aperture Radar
SNR	Signal-zu-Rausch-Verhältnis (signal-to-noise-ratio)
SPOT	System Probatoire d'Observation de la Terre
TAB	Tabelle
TK10	Topografische Karte 1:10.000
TK25	Topografische Karte 1:25.000
UN	Vereinte Nationen
UNPP	United Nations Populations Division
USGS	United States Geological Survey
VGL	Vergleiche
VH	Vertikal senden, horizontal empfangen (Polarisation)
VV	Vertikal senden, vertikal empfangen (Polarisation)

Inhaltsverzeichnis

Abstract.....	V
Kurzfassung.....	VII
Danksagung.....	IX
Abbildungsverzeichnis.....	XI
Tabellenverzeichnis.....	XIV
Abkürzungsverzeichnis.....	XV
Inhaltsverzeichnis.....	XVII
Kapitel 1: Einführung	1
1.1 Stand der Forschung	3
1.2 Zielsetzung	8
Kapitel 2: Grundlagen.....	11
2.1 Erdbeobachtung.....	12
2.1.1 Prinzip der Fernerkundung.....	12
2.1.2 Eigenschaften fernerkundlicher Bilddaten.....	14
2.1.3 Computergestützte Bildklassifizierung.....	17
2.2 Radarfernerkundung	20
2.2.1 Synthetic Aperture Radar (SAR).....	20
2.2.2 Systemspezifische Abbildungsparameter	25
2.2.3 Objektspezifische Abbildungsparameter	29
2.2.4 Rückstreuverhalten und Bildcharakteristik	36
Kapitel 3: Arbeitsbasis	42
3.1 Untersuchungsgebiet	42
3.2 Datengrundlage.....	44
3.3 Bildverarbeitungssoftware.....	48
Kapitel 4: Methodenentwicklung	55
4.1 Optimierung der objektorientierten Bildauswertung	56
4.1.1 Entwicklung des SelectiveMean-Filters.....	56
4.1.1.1 Anforderungen	56
4.1.1.2 Funktionsweise	59
4.1.1.3 Bewertung.....	62

4.1.2	Ansatz zur klassenbasierten Segmentoptimierung.....	68
4.1.2.1	Anforderungen	68
4.1.2.2	Funktionsweise	70
4.1.2.3	Bewertung.....	76
4.1.3	Zusammenfassung.....	84
4.2	Erfassung von Siedlungsflächen und Ableitung einfacher Landnutzungstypen	86
4.2.1	Auswertung einfach-polarisierter SAR-Aufnahmen	87
4.2.1.1	Segmentierungskonzept	87
4.2.1.2	Regelwerk und Klassifizierung.....	90
4.2.2	Integration zusätzlicher Polarisationen, Frequenzen oder Datentypen.....	98
4.2.2.1	Erweitertes Segmentierungskonzept.....	98
4.2.2.2	Modifizierung des Regelwerks zur Klassifizierung.....	101
4.2.3	Diskussion der Ergebnisse	110
4.2.3.1	Einfach-polarisierte SAR-Aufnahmen.....	110
4.2.3.2	Dual-polarisierte SAR-Daten	124
4.2.3.3	Bifrequente SAR-Daten	129
4.2.3.4	Kombinierte Datenbasis aus optischer und SAR-basierter Aufnahme	135
4.2.4	Zusammenfassung.....	140
4.3	Charakterisierung der lokalen Siedlungsstruktur	142
4.3.1	Segmentierung	144
4.3.2	Ableitung urbaner Strukturen	146
4.3.3	Diskussion der Ergebnisse	152
4.3.4	Zusammenfassung.....	161
Kapitel 5: Fazit.....	164
5.1	Potentiale und Limitierungen der urbanen Radarfernerkundung	164
5.2	Zukünftiger Forschungsbedarf	168
Anhang A:	Literatur- und Internetverzeichnis	173
Anhang B:	SelectiveMean-Filter	184
Anhang C:	Segmentoptimierung	189
Anhang D:	Accuracy Assessment (regionale Analysen).....	190
Anhang E:	Accuracy Assessment (lokale Analysen).....	196
Eidesstattliche Erklärung	197
Curriculum Vitae.....	198

Kapitel 1

Einführung

In den vergangenen Jahrzehnten war weltweit eine stetige und sich zunehmend dynamischer entwickelnde *Urbanisierung* zu verzeichnen. Gegenwärtig leben in den hochindustrialisierten Nationen Europas bereits rund 80 Prozent der Menschen in Städten (UNPP, 2006). Doch auch auf globaler Ebene wird die Anzahl der Stadtbewohner in den nächsten Jahren erstmals in der Geschichte der Menschheit den Anteil der ländlichen Bevölkerung übertreffen. Im Jahr 2030 sollen nach Schätzungen der Vereinten Nationen (UN) bereits rund zwei Drittel aller Bürger in urbanen Ballungszentren leben (UNPP, 2006). Dieser Trend wird insbesondere in Entwicklungs- und Schwellenländern von einem drastischen Anstieg der Megastädte mit mehr als 5-10 Millionen Einwohnern begleitet.

Folglich zählen *städtische Agglomerationen* und deren Umland zu den *dynamischsten Regionen der Erde*. Dabei stellen sie aufgrund ihres immensen Bedarfs an Fläche, Energie und Gütern sowie des daraus resultierenden Verkehrsaufkommens eine beträchtliche Belastung für die Umwelt dar. Gleichzeitig sind urbane Ballungszentren durch die enorme Konzentration an Bevölkerung, Infrastruktur und Kapital besonders anfällig gegenüber ökologischen und sozioökonomischen Störungen. Vor diesem Hintergrund stellt der zunehmende Urbanisierungsdruck eine große Herausforderung für die Akteure in Planung und Politik dar. Daher wurden die Nachhaltigkeit der städtischen Entwicklung sowie die Beobachtung und Steuerung der rapiden Veränderungen im Umfeld urbaner Verdichtungsräume schon vor Jahren als elementare Herausforderung für das 21. Jahrhundert identifiziert (BMU, 1992).

Die Implementierung von Nachhaltigkeitsaspekten in *Strategien und Konzepte zur Beobachtung, Steuerung und Bewertung der städtischen Entwicklung* lässt sich jedoch auch in der Bundesrepublik Deutschland kaum mehr mit konventionellen Methoden der Informationserhebung realisieren. So basieren die etablierten Techniken weitestgehend auf Datengrundlagen, die über zeit- und damit arbeits- sowie

kostenintensive Verfahren wie statistische Erhebungen, Kartierungen oder Luftbildauswertungen generiert werden. Zudem erfordert die Dynamik der Veränderungen immer kürzere Fortschreibungsintervalle der Datenbestände, wobei die konventionellen Methoden auch hier an ihre Grenzen stoßen. Aus diesem Grunde gewinnt der *Einsatz alternativer Techniken zur Erhebung raumbezogener Informationen* enorm an Bedeutung.

In diesem Kontext wird die *satellitengestützte Erdbeobachtung* zunehmend als vielversprechender Baustein für ein zukunftsfähiges Instrumentarium zur Beobachtung und Bewertung der Entwicklung urbaner Räume wahrgenommen. Moderne Sensorsysteme sind in der Lage, weltweit flächendeckend und vergleichsweise kostengünstig, raumbezogene Informationen in kurzen Zeitintervallen und mit hohem räumlichem Detaillierungsgrad zu erheben (DECH, 1997). Darüber hinaus können die Aufnahmen mittels digitaler Bildverarbeitung schnell und automatisiert verarbeitet werden. Daher gibt es sowohl auf dem kommerziellen Sektor als auch auf politischer Ebene verstärkt Bestrebungen, einen *fernerkundlichen Sektors* zur Bereitstellung aktueller Geoinformationen zu etablieren. Als Beispiel sei an dieser Stelle die gemeinsame Initiative von europäischer Kommission und europäischer Raumfahrt-Agentur ESA zur globalen Umwelt- und Sicherheitsüberwachung (GMES) genannt (GMES, 2006).

Bisherige Konzepte zur operationellen, fernerkundungsgestützten Ableitung planungsrelevanter Informationen basieren weitestgehend auf einer visuellen bzw. manuellen Auswertung der Bilddaten (KEIL ET AL., 2003; LAVALLE ET AL., 1998). Gerade im Hinblick auf eine flächendeckende und objektiv vergleichbare Erfassung raumwirksamer Phänomene in kurzen Zeitintervallen ist jedoch die Entwicklung von Verfahren zur *automatisierten Analyse der Bildinhalte* von entscheidender Bedeutung. Unterstützt durch die stetig verbesserte Leistungsfähigkeit optischer Satellitensysteme konnten in den vergangenen Jahren gerade auf diesem Sektor entscheidende Fortschritte erzielt werden, die auch das siedlungsbezogene Einsatzspektrum fernerkundlicher Anwendungen deutlich erweitert haben (NETZBAND ET AL., 2005). Mit dem Start neuer Radarsatelliten wie dem deutschen TerraSAR-X werden zukünftig jedoch *erstmalig radarbasierte Satellitenaufnahmen* zur Verfügung stehen, die eine *operationelle* und gleichsam *differenzierte Analyse von Siedlungsflächen* ermöglichen (ROTH ET AL., 2005).

Vor dem Hintergrund der vorangegangenen Ausführungen soll nachfolgend zunächst der aktuelle Stand der Forschung auf dem Gebiet der *urbanen Fernerkundung* dargelegt werden.

1.1 Stand der Forschung

In vielen Nationen stellt die *Luftbildbefliegung* das etablierteste fernerkundliche Verfahren zur Erhebung raumbezogener Informationen dar. So zählt die visuelle Auswertung von Luftbildern auch in der Bundesrepublik Deutschland zum festen Bestandteil in der räumlichen Planung und Verwaltung (MEINEL & LIPPOLD, 1999). Die geringe flächenhafte Abdeckung der Aufnahmen und der verhältnismäßig hohe Aufwand für die Datenerhebung implizieren jedoch, dass Luftbildbefliegungen aus Kostengründen nur in einem mehrjährigen Intervall von fünf bis zehn Jahren realisierbar sind.

Eine erste Alternative zu dieser Technik bot sich in den 1970er Jahren als mit dem Start ziviler *Satellitenmissionen* und der Entwicklung neuartiger Verfahren zur *elektronischen Datenverarbeitung* die ersten Ansätze zur *automatisierten Analyse digitaler Erdbeobachtungsdaten* Einzug in Wissenschaft und Praxis hielten. Somit war der Grundstein für die moderne Fernerkundung gelegt. Das Einsatzspektrum fernerkundlicher Daten und Techniken wird dabei maßgeblich durch die Eigenschaften und Fähigkeiten der zur Verfügung stehenden Sensoren und Auswerteverfahren bestimmt.

So eignen sich räumlich vergleichbar grob aufgelöste Systeme wie NOAA-AVHRR (NOAA, 2006) oder Terra-MODIS (NASA, 2006) ausschließlich zur regionalen oder überregionalen Analyse der Landbedeckung bzw. Landnutzung (DECH ET AL., 1997; NETZBAND ET AL., 2005; STOW & CHEN 2002). Demgegenüber können Multispektralsysteme wie SPOT (SPOT IMAGE, 2006), IRS (NRSA, 2006), ASTER (JPL, 2006) oder Landsat (USGS, 2006) aufgrund einer deutlich verbesserten Bodenauflösung von zweieinhalb bis fünfzehn Metern bei gleichzeitig hoher räumlicher Abdeckung bereits zur Erforschung der *Stadt-Umland-Dynamik* eingesetzt werden (MEINEL & WINKLER, 2004; MÖLLER, 2005). Dabei spielen *multitemporale Auswertungen* der Landnutzung und -fragmentierung, aber auch *Veränderungsanalysen (change detection)* eine besondere Rolle.

MASEK ET AL. (2000) belegen beispielsweise auf der Grundlage von Landsat-Zeitreihen die räumliche Entwicklung der städtischen Strukturen im Großraum Washington D.C. und ZHANG (2001) beschreibt das Wachstum von Siedlungsflächen in China. Darüber hinaus wurden verschiedene Ansätze zur Analyse des Grünanteils, der Bodenversiegelung oder des Bebauungsgrades entwickelt (BRAUN & HEROLD, 2003; STEINNOCHER ET AL., 2005; WILSON ET AL., 2003). Zudem werden mitunter sozioökonomische Informationen wie die Bevölkerungszahl und -dichte abgeleitet (DOBSON ET AL., 2000; LO, 2001; WEEKS ET AL., 2000).

Im Hinblick auf räumlich und thematisch detaillierte Analysen von Siedlungsflächen ist das *geometrische Auflösungsvermögen* der zuvor genannten Satellitensysteme jedoch *weiterhin zu begrenzt* (JENSEN & COWEN, 1999). Daher gibt es diverse Ansätze zur Reduzierung dieser systemspezifischen Limitierung. So kann über eine Kombination von Daten verschiedener Sensoren oder Datenquellen (*sensor fusion, data fusion*) die räumliche und thematische Differenzierbarkeit urbaner Strukturen verbessert werden (DE JONG ET AL., 2000; MEINEL & HERNIG, 2005; RANCHIN ET AL., 2001; WINKLER, 2004). BRAUN & HEROLD (2003), RIDD (1995) und SMALL (2004) beschreiben die Möglichkeit, dieses Ziel alternativ über *Spectral-Unmixing*-Ansätze zu verwirklichen. Diese Verfahren zielen auf eine verbesserte Analyse von Bildelementen ab, deren spektrale Signatur sich aus den Reflektionsbeiträgen mehrerer Oberflächentypen zusammensetzt (Mischpixel-Problematik). Dazu werden für jedes Pixel die Flächenanteile vordefinierter Bedeckungsarten modelliert. Zur Steigerung des geometrischen Auflösungsvermögens multispektraler Bilddaten werden zudem *Resolution-Merge*-Verfahren eingesetzt (EHLERS & KLONUS, 2004; ZHANG, 1999). Dabei werden die Spektralkanäle in die deutlich höhere Bodenauflösung eines zeitgleich vom identischen System aufgezeichneten panchromatischen Datensatzes überführt, um auf diese Weise die erreichbare Detailschärfe der Aufnahme zu verbessern.

Mit einer Erhöhung des räumlichen Detaillierungsgrades können verstärkt *struktur- bzw. texturbezogene Merkmale* genutzt werden. STEINNOCHER (1997) belegt, dass Texturmaße räumlich und zeitlich stabile Merkmale darstellen, die somit eine bessere Übertragbarkeit von Klassifizierungsansätzen gewährleisten. Ähnliche Ergebnisse präsentieren ATKINSON & LEWIS (2000), CABLK & MINOR (2003), DE KOK ET AL. (2003), XIE & BRADY (1996) und ZHANG ET AL. (2002).

Eine neue Ära hinsichtlich der differenzierten Analyse von Siedlungsflächen wurde mit dem Start der *neuesten Generation optischer Satellitensysteme* wie SPOT-5 (SPOT IMAGE, 2006), IKONOS (SPACE IMAGING, 2006) oder QuickBird (DIGITALGLOBE, 2006) eingeläutet. Mit Bodenauflösungen zwischen zwei Metern und 60 Zentimetern erschließen diese Plattformen erstmals ein Anwendungsspektrum, das bisher ausschließlich der Luftbildauswertung vorbehalten war (SEILER ET AL., 2004; STEINNOCHER ET AL., 2005; TANAKA & SUGIMURA, 2001).

Ein enormes Potential hinsichtlich urbaner Analysen bieten *Hyperspektralsysteme*. Solche Sensoren weisen bis zu 250 Spektralkanäle auf und ermöglichen somit eine detaillierte Charakterisierung der städtischen Oberflächenmaterialien (HEIDEN ET AL., 2003; SEGL ET AL., 2003). Qualitativ hochwertige Aufnahmen in geeigneter räumlicher Auflösung werden bisher jedoch nur von flugzeuggetragenen Sensoren wie etwa ARES (MÜLLER ET AL., 2003) oder HyMap (KRUSE ET AL., 2000) bereitgestellt.

Das Gros der Studien zur automatisierten Auswertung fernerkundlicher Bilddaten setzt auf pixelbasierten, statistischen Verfahren auf. Dabei nimmt mit der stetig verbesserten räumlichen Auflösung der Sensoren die spektrale und strukturelle Heterogenität innerhalb der Bedeckungs- oder Nutzungsklassen signifikant zu. Folglich tritt die Analyse räumlicher Zusammenhänge und funktionaler Merkmale verstärkt in den Vordergrund. BARR & BARNESLEY (1997) sowie BLASCKE ET AL. (2000) merken diesbezüglich kritisch an, dass sich die etablierten, pixelbasierten Verfahren zur Bildauswertung nur unzureichend für kontextbezogene Analysen eignen. Diese Einschätzung wird durch Untersuchungen von DONNAY (1999), JOHNSON (1994) sowie ZHANG & WANG (2001) bekräftigt.

Vor diesem Hintergrund gewinnen *objektorientierte Klassifikationsansätze* zunehmend an Bedeutung. Diese stellen eine umfassendere Funktionalität hinsichtlich der Analyse funktionaler, struktureller oder kontextbezogener Charakteristika und Zusammenhänge bereit (BAATZ & SCHÄPE, 2000; BLASCHKE & STROBL, 2001). So wurden im Laufe der letzten Jahre zahlreiche Studien veröffentlicht, die gerade das Potential objektorientierter Techniken im urbanen Kontext aufzeigen (BAUER & STEINNOCHER, 2000; BENZ ET AL., 2004; HOFMANN, 2001). Im Rahmen einer segmentbasierten Auswertung werden spektral mehr oder minder ähnliche Pixel zu Bildobjekten gruppiert, um die eigentliche Klassifizierung auf der Basis dieser nunmehr aussagekräftigeren Grundeinheiten durchzuführen. Aktuelle Ansätze der Bildsegmentierung werden von MEINEL & NEUBERT (2004) vorgestellt.

Im Gegensatz zu optischen Sensoren können *Radarsysteme* ihre Daten unabhängig von Atmosphären- und Wetterbedingungen sowie Tages- und Nachtzeiten aufzeichnen. Damit garantieren sie eine kontinuierliche Beobachtung der Erdoberfläche in Zeitintervallen, die deutlich unter denen optischer Systeme liegen (ROTH ET AL., 2005). Trotz dieser Vorzüge kommen Radardaten im Umfeld städtischer Anwendungen nur begrenzt zum Einsatz. Dieser Umstand ist vor allem darauf zurückzuführen, dass sich der Informationsgehalt von Radaraufnahmen weitaus schwieriger erschließt bzw. mittels automatisierter Verfahren extrahieren lässt (SOERGEL ET AL., 2003; TUPIN & ROUX, 2004).

Aufgrund der begrenzten Bodenauflösung operationell einsetzbarer Radarsatelliten wie ERS (ESA, 2006a), JERS (JAXA, 2006), ENVISAT-ASAR (ESA, 2006b) oder Radarsat (MDA, 2006) adressieren *anwendungsorientierte Ansätze* zur Analyse urbaner Räume nahezu ausschließlich die *regionale Ebene*. Dabei stehen vornehmlich die Identifizierung von Siedlungsflächen und die Ableitung vereinfachter Landnutzungsmuster oder sozioökonomischer Merkmale im Vordergrund (HENDERSON & XIA, 1998; JENSEN, 2000; ULABY ET AL., 1994; WEYDHAL ET AL., 1995; XIA & HENDERSON, 1997).

TAKEUCHI ET AL. (2000), SHINOZUKA ET AL. (2000) und HOFFMANN ET AL. (2004) heben zudem den Nutzen einer radargestützten Auswertung im Kontext von Schadenskartierungen und Kriseninfor- mation hervor. STROZZI & WEGMÜLLER (1998) demonstrieren das Potential von Kohärenzanalysen zur Beobachtung der Siedlungsentwicklung. Wie vergleichende Untersuchungen auf der Basis von Landnutzungsklassifikationen belegen, bleibt die Genauigkeit radarbasierter Analysen jedoch in der Regel hinter der Güte einer entsprechenden Auswertung optischer Daten zurück (HAGG & STIES, 1996; LO, 1998; STIES & HAGG, 1999).

Bedingt durch die starke Geometrieabhängigkeit der Mikrowellentechnik weisen bebaute Areale in Radaraufnahmen *charakteristische Texturen* auf (ULABY ET AL., 1996). Diese strukturelle Information wird häufig als aussagekräftiges Kriterium zur Identifizierung besiedelter Flächen genutzt (HEIKKONEN ET AL., 1997; GOUINAUD ET AL., 1996; SMITS & ANNONI, 1999). ACQUA & GAMBA (2003) versuchen zudem, mittels einer statistischen Modellierung des Rauschens strukturbezogene Informationen abzuleiten, die eine Unterscheidung verschiedener Bebauungsdichten ermöglichen.

Mit Studien zur *Extraktion von Gebäudestrukturen* stellen GAMBA ET AL. (2000) und SOERGEL ET AL. (2003) methodisch dominierte Ansätze zur Analyse kleinräumiger städtischer Struktureinheiten vor. Dabei haben sich besonders die Überlagerung von Rückstreubeiträgen, Schatten- und Layover- Effekte sowie das radarinhärente Bildrauschen (Speckle) als Limitierung hinsichtlich der Auswertung erwiesen. Vergleichbare Schwierigkeiten sind auch im Hinblick auf Verfahrensentwicklungen zur Extraktion des Straßennetzes aufgetreten (ACQUA ET AL., 2002; HOUSHMAND & GAMBA, 1999; TUPIN ET AL., 2002; WESSEL ET AL., 2003). MERCER & GILL (1998) sowie STILLA ET AL. (2003) unter- suchen auf der Basis hochaufgelöster SAR-Daten die Möglichkeit zur dreidimensionalen Erfassung von Siedlungsstrukturen.

Aufgrund der komplexen Interaktion zwischen emittiertem Signal und erfasster Oberfläche ist die urbane Radarfernerkundung weiterhin um ein verbessertes *Verständnis des Zusammenspiels zwischen sys- tem- und objektspezifischen Aufnahmeparametern* bemüht (DONG ET AL., 1997; TUPIN ET AL., 2002). SOERGEL ET AL. (2003) erläutern auf der Basis flugzeuggestützter Radaraufnahmen, dass Limitierun- gen aufgrund aufnahmegeometrischer Effekte teilweise kompensiert werden können, wenn Daten mit orthogonaler bzw. diametraler Ausrichtung oder variierenden Einfallswinkeln kombiniert wer- den. Eine kompakte Übersicht bezüglich der Beziehung zwischen system- bzw. objektspezifischen Aufnahmeparametern und den bio- und geophysikalischen Charakteristika urbaner Räume geben XIA & HENDERSON (1997).

Darüber hinaus gibt es Forschungsansätze, über *multifrequente*, *polarimetrische* oder *Sensor-Fusion-Verfahren* einige der radarinhärenten Limitierungen zu kompensieren (FATONE ET AL., 2001; FORSTER & TICEHURST, 1994; HENDERSON & XIA, 1998; LOMBARDO ET AL., 2001; XIAO ET AL., 1998). AOKI ET AL. (1999) zeigen am Beispiel flugzeuggestützter Pi-SAR Aufnahmen der Region Tokio den Zusammenhang zwischen Siedlungsstruktur und Rückstreuverhalten bzw. polarimetrischen Eigenschaften auf. PELLIZZERI (2003) schreibt auf der Basis einer polarimetrischen Auswertung von AIRSAR C- und L-Band Aufnahmen der Anisotropie einen besonderen Nutzen hinsichtlich der Klassifikation urbaner Strukturen zu. CORR ET AL. (2003) nutzen kombinierte multifrequente, polarimetrische E-SAR Daten mit variierenden Blickrichtungen zur Analyse urbaner Strukturen. Mit Arbeiten zur *Fusion optischer und SAR-basierter Datensätze* konnten WEYDAHL ET AL. (2005) und XIAO ET AL. (1998) die Vorteile von Sensor-Fusion-Ansätzen hinsichtlich der Klassifizierung urbaner Szenen veranschaulichen. SOLBERG ET AL. (1994) liefern ähnliche Ergebnisse im Hinblick auf die Erhebung von Landnutzungsinformationen. TUPIN & ROUX (2004) untersuchen die Möglichkeit einer Kombination höchstauflösender Radardaten und optischer Aufnahmen zur Extraktion von 3D-Informationen.

Eine spezifische Anwendung der SAR-Technik im Umfeld urbaner Räume stellt der Einsatz *interferometrischer Verfahren* zur Erfassung von *Bewegungsmustern der Erdoberfläche* (FERRETTI ET AL., 2001; WORAWATTANAMATEEKUL ET AL., 2003) oder der Beobachtung von *Verkehrsströmen* dar (PALUBINSKAS ET AL., 2005).

HENDERSON & XIA (1998) konstatieren, dass eingehende Studien zur radargestützten Analyse der Siedlungsstrukturen einer Bodenauflösung von wenigen Metern bedürfen und zudem weiterhin mit signifikanten Schwierigkeiten verbunden sind. Hinzu kommt, dass gegenwärtig weder hochaufgelöste Radardaten, noch Verfahren zur Auswertung komplex strukturierter Radarszenen auf einer operationellen Ebene bereitgestellt werden können. Aus diesem Grunde wird die *urbane Radarfernerkundung* bisher von *stark methodisch orientierten Studien* dominiert, während die Entwicklung anwendungs- und nutzerorientierter Ansätze deutlich hinter der optischen Fernerkundung zurücksteht.

Mit der neuesten Generation von Radarsatelliten wie den zukünftigen Systemen TerraSAR-X (ROTH ET AL., 2005) und Radarsat-2 (MDA, 2006) oder dem kürzlich gestarteten ALOS-PalSAR (ICHITSUBO ET AL., 2003) werden jedoch bald erstmals höchstauflösende, dual- oder voll-polarimetrische Radaraufnahmen auf einer operationellen Basis bereitgestellt, die eine differenzierte Analyse von Siedlungsflächen gewährleisten.

1.2 Zielsetzung

Wie die vorangegangenen Ausführungen dokumentieren, ist die Etablierung eines fernerkundungs-basierten Sektors zur operationellen Bereitstellung planungsrelevanter Geoinformationsprodukte gerade im Kontext urbaner Anwendungen von besonderem Interesse. Zentrales Element im Hinblick auf die Umsetzung solcher Bestrebungen ist die Entwicklung von Verfahren und Konzepten zur automatisierten Interpretation der zur Verfügung stehenden Erdbeobachtungsdaten. Diesbezüglich hat der Blick auf den aktuellen Stand der Forschung gezeigt, dass anwendungs- bzw. nutzerorientierte Ansätze bisher ausschließlich auf optischen Bilddaten beruhen. Dies liegt maßgeblich darin begründet, dass bislang keine operationellen Radarsatelliten existieren, die eine differenzierte Analyse urbaner Räume gewährleisten können.

Diese Situation wird sich jedoch in naher Zukunft mit den bereits zuvor erwähnten Starts neuer Radarsatelliten grundlegend ändern. Dabei bietet der Einsatz radarbasierter Techniken gegenüber optischen Sensoren den enormen Vorteil einer wetter- und tageslichtunabhängigen Datenaufzeichnung, was eine Konstanz, Verlässlichkeit und Flexibilität gewährleistet, die mittels optischer Systeme nicht erreicht werden kann.

Vor dem Hintergrund der zukünftigen Satellitenmissionen und der besonderen Bedeutung urbaner Räume ist es daher das **Ziel der vorliegenden Dissertation, auf der Basis einer nutzerorientierten Methodik das Potential hochauflösender Radardaten zur automatisierten Erfassung und Analyse von Siedlungsflächen** zu erforschen.

Grundlegendes Element zur *Umsetzung eines nutzerorientierten Ansatzes* ist die Verwendung einer überschaubaren Datenbasis, die zumindest in naher Zukunft operationell über satellitengestützte SAR-Systeme bereitgestellt werden kann und dadurch eine hohe Verfügbarkeit bei möglichst geringen Anschaffungs- bzw. Fortschreibungskosten gewährleistet. Zum anderen ist es von besonderer Bedeutung, eine bereits etablierte Auswertetechnik zu verwenden, die grundsätzlich eine Automatisierung der Bildanalyse ermöglicht. Des Weiteren wurde der geographische Fokus dieser Arbeit auf den Rhein-Neckar-Raum gelegt, um auf diese Weise eine bestehende Zusammenarbeit mit Planungsträgern des Verbandes Region Rhein-Neckar sowie den Städten Mannheim und Ludwigshafen auszubauen. Dieser Kontakt gewährleistet einen intensiven Erfahrungs-, Daten- und Informationsaustausch mit Akteuren der räumlichen Planung, was letztlich eine wichtige Voraussetzung für die Entwicklung nutzerorientierter Ansätze und Informationsprodukte darstellt.

Mit Blick auf das Potential hochauflösender Radardaten zur automatisierten Erfassung und Analyse von Siedlungsflächen ist die *Klärung folgender Aspekte* von zentraler Bedeutung:

- Welche radarspezifischen Schwierigkeiten treten in urban geprägten Szenen hochaufgelöster Radardaten auf und wie beeinflussen sie die Qualität der Auswertung?
- Kann der Informationsgehalt hochauflösender Radaraufnahmen über ein bereits etabliertes Verfahren zur digitalen Bildauswertung hinreichend erschlossen werden?
- Wo liegen die Limitierungen und Potentiale der Radartechnik im urbanen Kontext und über welche Ansätze können sie gegebenenfalls kompensiert bzw. ausgebaut werden?
- In welchem Umfang kann auf der Grundlage einer praxisorientierten Datenbasis die Erfassung und weiterführende Differenzierung von Siedlungsflächen gewährleistet werden?

Zur Beantwortung dieser Fragestellung steht im Rahmen der Dissertation

- die Auswertung *hochaufgelöster Radardaten*,
- auf der Grundlage der etablierten, *objektorientierten Bildanalysesoftware eCognition*,
- zum Zwecke der *Charakterisierung der lokalen und regionalen Siedlungsstruktur*

im Vordergrund.

Auf dieser Basis soll einerseits das *Leistungsvermögen der objektorientierten Bildanalyse hinsichtlich einer automatisierten Auswertung hochaufgelöster Radaraufnahmen* beleuchtet werden. Die Verwendung eines solchen segmentbasierten Bildanalyseverfahrens wird favorisiert, da ein objektorientiertes Vorgehen gegenüber pixelbasierten Techniken eine deutlich höhere Funktionalität bezüglich der Charakterisierung räumlicher und funktionaler Zusammenhänge bietet (VGL. KAP. 1.1). Dies ist speziell im Hinblick auf die Auswertung von Radaraufnahmen von Vorteil, da die automatisierte Analyse auf der Basis einzelner Pixel durch den begrenzten spektralen Informationsgehalt von Radardaten, die Mehrdeutigkeit des Signals sowie radarinhärente Rauscheffekte (Speckle) signifikant erschwert wird (VGL. KAP. 1.1).

Im Mittelpunkt dieser Dissertation steht jedoch die *Evaluierung hochauflösender Radardaten im Hinblick auf die Erfassung der lokalen und regionalen Siedlungsstruktur*. Diese Analysen sollen das urbane Anwendungsspektrum der Radardaten demonstrieren, um somit gegebenenfalls zu einer erhöhten Akzeptanz bei Akteuren in Forschung und Anwendung beizutragen.

Mit Blick auf diese zentralen Aspekte ist die Arbeit so aufgebaut, dass zu Beginn neben den *Grundlagen der Erdbeobachtung und Radarfernerkundung* zunächst das *Untersuchungsgebiet*, die *Datengrundlage* und die verwendete *Bildverarbeitungssoftware* eingehend erörtert werden. Im Kontext der anschließenden

Methodenentwicklung widmet sich ein erster Schwerpunkt dem *Entwurf von Ansätzen zur Verbesserung und Stabilisierung einer objektorientierten Auswertung hochauflösender Radardaten*. Dieser Arbeitsschritt umfasst die

- Entwicklung eines neuen Verfahrens zur adaptiven Reduzierung des radartypischen Bildrauschens (Speckle-Effekt).
- Entwicklung eines Ansatzes zur akkurateren Segmentierung und gezielteren Bestimmung geeigneter Segmentierungsparameter unter der Umgebung der Software eCognition.

Der zweite, stärker thematisch geprägte Schwerpunkt dieser Dissertation liegt auf der *Definition und Umsetzung von robusten Regelwerken zur Ableitung siedlungsstruktureller Informationen*. Diese Regelwerke beziehen sich dabei auf die

- *regionale Erfassung* der Siedlungsflächen und Landnutzungstypen.
- *lokale Analyse* des urbanen Landnutzungsmusters.

Im Kontext der *regionalen Analysen* ist es das primäre Ziel, vergleichende Auswertungen im Hinblick auf zukünftige Datenszenarien zu ermöglichen. Daher soll der zu entwickelnde Ansatz so ausgelegt sein, dass er die Analyse einfach-polarisierter Daten, dual-polarisierter Aufnahmen und bifrequenter Datengrundlagen – z.B. im Hinblick auf eine Kombination von TerraSAR-X- und ALOS-Daten – gewährleistet. Mit Blick auf die ebenfalls in naher Zukunft startende, deutsche Mission des optischen RapidEye-Satelliten (DECH & SCHREIER, 2004; SCHREIER & DECH, 2005) ist zudem die synergetische Auswertung hochaufgelöster Radardaten (z.B. TerraSAR-X) und optischer Aufnahmen mit geringerer Bodenauflösung (z.B. RapidEye) vorgesehen.

Die Erfassung der *lokalen Siedlungsstruktur* zielt aufgrund der im Vergleich zu den regionalen Analysen deutlich höheren thematischen und räumlichen Komplexität der Auswertung direkt auf eine synergetische Analyse mittelaufgelöster optischer und hochaufgelöster Radaraufnahmen ab. Dieses Datenszenario ist zudem im Hinblick auf die beiden deutschen Missionen TerraSAR-X und RapidEye von besonderem Interesse.

Kapitel 2

Grundlagen

Im Rahmen dieses Kapitels sollen jene *Grundlagen der Fernerkundung* erörtert werden, die für ein Verständnis der im Zuge dieser Arbeit angewandten Techniken und Konzepte von Bedeutung sind.

Dabei werden zunächst die *physikalischen* und *methodischen Grundsätze der satelliten- bzw. flugzeuggestützten Erdbeobachtung* erläutert, um den Fokus anschließend auf die *Eigenschaften fernerkundlicher Bilddaten* zu lenken. Beide Aspekte bestimmen den Informationsgehalt der Aufnahmen und haben dadurch maßgeblichen Einfluss auf die Anwendungsfelder fernerkundlicher Ansätze. Schließlich werden in einem weiteren Abschnitt die Grundlagen der *computergestützten Bildklassifizierung* vorgestellt. Sofern nicht anders vermerkt, liegen diesen Abschnitten die theoretischen Grundlagen aus ALBERTZ (1991), DECH (2005), HILDEBRANDT (1996), JENSEN (2000), LILLESAND & KIEFER (2000), LÖFFLER (1994), RICHARDS & JIA (1999) SOWIE SCHOWENGERDT (1997) zu Grunde.

Da der Schwerpunkt dieser Dissertation auf der Auswertung radarbasierter Aufnahmen liegt, widmet sich der zweite Teil dieses Kapitels den *verfahrenstechnischen Grundlagen der Radarfernerkundung*. In diesem Kontext stehen zu Beginn die *Funktionsweise des Synthetic Aperture Radars (SAR)* sowie die wichtigsten *system- und objektspezifischen Aufnahmeparameter* im Mittelpunkt. Letztere bestimmen den Rückstreuquerschnitt beziehungsweise das am Sensor empfangene Signal und sind damit wichtige Größen für die automatisierte Bildinterpretation. Daran anknüpfend werden abschließend die *Eigenschaften des Radarsignals bzw. Radarbildes* diskutiert. Die Grundlagen zur Radarthematik sind aus HENDERSON & LEWIS (1998), SCHREIER (1993) sowie ULABY & ELACHI (1990) entnommen.

2.1 Erdbeobachtung

2.1.1 Prinzip der Fernerkundung

Unter dem Begriff der *Fernerkundung* werden Techniken zusammengefasst, die Informationen über die Beschaffenheit von festen, flüssigen oder gasförmigen Körpern liefern, ohne unmittelbar mit diesen in Kontakt zu treten. Ziel ist es, über eine flächendeckende, mitunter mehrdimensionale Messung der von den betrachteten Objekten reflektierten oder emittierten Energie quantitative und qualitative Informationen über deren Vorkommen, Zustand sowie Beziehungen zu gewinnen. Als Informationsträger dient die *elektromagnetische Strahlung*. Dabei verwenden *passive Aufnahmesysteme* (z.B. optische Sensoren) reflektierte oder emittierte Strahlung *natürlichen* Ursprungs, während *aktive Aufnahmesysteme* (z.B. Radar, Laser-Scanner) mittels einer eigenen Strahlungsquelle *künstlich erzeugte* elektromagnetische Wellen aussenden und empfangen.

In ihrer Gesamtheit wird die elektromagnetische Strahlung durch das *elektromagnetische Spektrum* beschrieben. Dieses wird nach mess- und aufnahmetechnischen Gesichtspunkten auf der Basis der Wellenlänge beziehungsweise Frequenz in unterschiedliche Bereiche unterteilt, deren Grenzen fließend ineinander übergehen (VGL. ABB. 2-1).

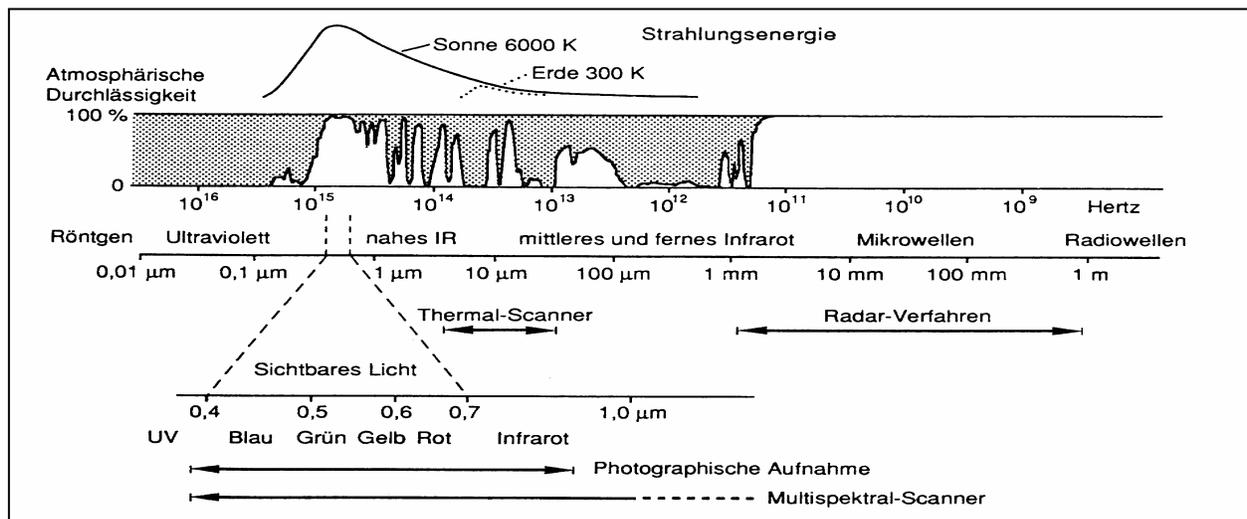


Abb. 2-1: Elektromagnetisches Spektrum und Aufnahmebereiche verschiedener Sensortypen

Quelle: ALBERTZ (1991)

Zur Beobachtung der Erdoberfläche nutzt die *optische Fernerkundung* überwiegend natürliche Strahlungsenergie im Wellenlängenbereich zwischen $0,3$ und 14 Mikrometern. Dabei sind die Aufnahmekanäle

der Sensoren so ausgelegt, dass sie ausschließlich in jenen Zonen des Spektrums aufzeichnen, in denen es nicht zu atmosphärischen Absorptions- und Reflektionsprozessen kommt. Demgegenüber operiert die *Radarfernerkundung* mit aktiv erzeugten Mikrowellen zwischen 0,7 und 140 Zentimetern Wellenlänge in Spektralbereichen, in denen nur geringe atmosphärische Störeinflüsse auftreten (VGL. ABB. 2-1).

Im Hinblick auf die Auswertung von Erdbeobachtungsdaten machen sich alle fernerkundlichen Ansätze den Umstand zu Nutze, dass zwischen den betrachteten Objekten und der auf sie einwirkenden elektromagnetischen Strahlung *material- bzw. objektspezifische Wechselwirkungen* auftreten. Trifft Strahlung auf einen Körper, wird sie als *Funktion der Wellenlänge* und in Abhängigkeit der *physikalischen und chemischen Eigenschaften* des Oberflächenmaterials in *variierenden Anteilen reflektiert, absorbiert oder transmittiert*. Somit weist jedes Material bzw. jeder Oberflächentyp über das gesamte elektromagnetische Spektrum gesehen einen charakteristischen Verlauf der Reflektion auf – die so genannte *spektrale Signatur* (VGL. ABB. 2-2).

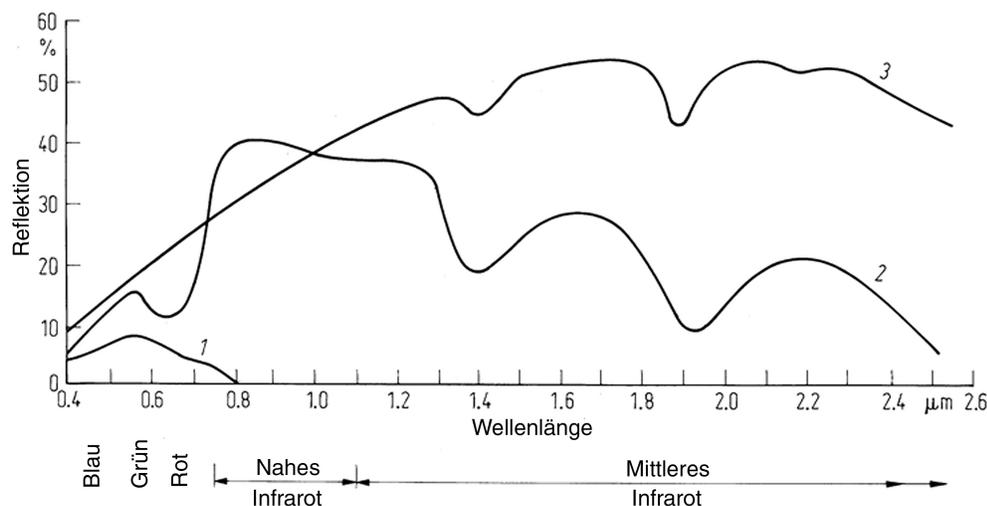


Abb. 2-2: Charakteristische Reflektionskurven von Wasser (1), Vegetation (2) und unbedecktem Boden (3)

Quelle: ergänzt nach RICHARDS & JIA (1999)

Die fernerkundliche Informationserhebung basiert im Grunde genommen auf der Messung dieser spezifischen Reflektionscharakteristik. Dazu wird mit Hilfe entsprechender Sensorsysteme jeweils in verschiedenen Aufnahmekanälen bzw. Wellenlängenbereichen die von einem Körper pro Flächeneinheit und Raumwinkel reflektierte und emittierte Strahlungsleistung aufgezeichnet. Die dabei empfangene *spektrale Strahldichte (at-sensor radiance)* ist eine Funktion der objektspezifischen Eigenschaften, aber auch weiterer Faktoren wie beispielsweise der solaren Einstrahlung, atmosphärischer Einflüsse

oder der räumlichen Orientierung der betrachteten Oberfläche. Sofern eine exakte Bestimmung der tatsächlichen Reflektionswerte an der Erd- bzw. Objektoberfläche notwendig ist, müssen daher die Beiträge dieser unerwünschten Variablen a posteriori mittels geeigneter *Korrekturverfahren* aus dem Signal herausgerechnet werden (z.B. atmosphärische Korrektur, Beleuchtungskorrektur).

Fotografische Verfahren zeichnen in der Regel im sichtbaren Bereich des elektromagnetischen Spektrums (**Rot-Grün-Blau**) auf, während *multispektrale Systeme* über weitere Aufnahmekanäle zusätzliche Wellenlängenbereiche im nahen, mittleren oder auch thermalen Infrarot abdecken (VGL. ABB. 2-1). *Hyperspektralsensoren* verfügen schließlich über bis zu 250 Aufnahmekanäle und ermöglichen dadurch eine nahezu kontinuierliche Nachbildung der spektralen Reflektionscharakteristik einer Oberfläche. Im Kontext *radargestützter Techniken* hingegen ist die zur Aufnahme aktiv emittierte Mikrowellenstrahlung auf eine einzige Wellenlänge beschränkt. Daher kann die Kennzeichnung der Oberflächeneigenschaften selbst bei der Kombination mehrerer Szenen mit unterschiedlichen Frequenzbereichen kaum über eine Auswertung der spektralen Signatur erfolgen. Deshalb finden im Zusammenhang mit einer radarbasierten Auswertung alternative Parameter und Merkmale Berücksichtigung, die in KAPITEL 2.2 eingehend erörtert werden.

Vor dem Hintergrund der vorangegangenen Ausführungen wird deutlich, dass Fernerkundungssysteme primär Informationen über die *physikalischen* bzw. *biophysikalischen Eigenschaften* der Erdoberfläche liefern. Gerade im Hinblick auf raumplanerische Fragestellungen ist jedoch die Bestimmung des sozioökonomischen Gebrauchs einer Fläche – also deren *Nutzung* – von zentralem Interesse. Diese funktionale Dimension lässt sich jedoch aus fernerkundlichen Daten lediglich indirekt über die Analyse räumlicher Zusammenhänge oder multitemporaler Charakteristika extrahieren. Dazu bedarf es spezieller Ansätze und Auswerteverfahren, die Gegenstand der Ausführungen in KAPITEL 2.1.3 sind.

2.1.2 Eigenschaften fernerkundlicher Bilddaten

Im Kontext der modernen flugzeug- und satellitengestützten Fernerkundung werden weitestgehend *bildgebende Techniken* eingesetzt, die das Ergebnis der räumlich kontinuierlichen Messungen in Form *digitaler Bilddaten* ausgeben. Diese Aufnahmen sind in der Regel aus einem Raster ungefähr quadratischer Bildzellen mit identischer Größe aufgebaut, die als *picture elements* oder kurz *pixel* bezeichnet werden. Die Helligkeit der Pixel wird durch ein numerisches Maß – die *digital number (DN)* – definiert. Der DN-Wert des einzelnen Bildelements ist in etwa proportional zur Intensität der am Sensor empfangenen und absorbierten Strahlung bzw. Energie. Bei Systemen, die in mehreren Spektralbe-

reichen Informationen erheben, wird dabei zeitgleich in jedem Kanal ein Messwert aufgezeichnet, so dass der resultierende Bilddatensatz in Abhängigkeit der Anzahl an Aufnahmekanälen als *mehrdimensionale Bildmatrix* mit x Spalten, y Zeilen und z Kanälen vorliegt.

Die Dimensionierung des von einer Auflösungszelle abgedeckten Ausschnitts der Erdoberfläche in x - und y -Richtung definiert den *räumlichen Detaillierungsgrad* bzw. die *geometrische Auflösung* des Systems. Im Kontext optischer Sensoren ist die von einem Pixel erfasste Fläche dabei in der Regel identisch mit der Abdeckung einer Auflösungszelle. Wie in KAPITEL 2.2 eingehend erläutert wird, ist dies bei Radaraufnahmen nicht der Fall. Grundsätzlich hat die *geometrische Auflösung* entscheidenden Einfluss auf den räumlichen und damit auch indirekt auf den thematischen Detaillierungsgrad einer Auswertung und bestimmt somit maßgeblich das Einsatzspektrum fernerkundlicher Bilddaten. Nach dem *Nyquist-Theorem* muss das zu analysierende Gelände dabei grundsätzlich mit einer räumlichen Frequenz abgetastet werden, die maximal halb so groß ist, wie die kleinsten zu kartierenden Raumeinheiten (NEER, 1999). Ist dies nicht der Fall, steigt die Wahrscheinlichkeit, dass mit einer Auflösungszelle gleichsam mehrere Raumeinheiten – sprich Bedeckungstypen – erfasst werden. In der Folge resultiert die spektrale Information des Pixels in diesem Fall aus einer Mischung der Reflektionsbeiträge aller Bedeckungstypen innerhalb der Auflösungszelle (*Mischpixel-Problematik*), was insbesondere im Kontext automatisierter Auswertungen zu signifikanten Schwierigkeiten führt.

Die Anzahl, Bandbreite und Positionierung der Aufnahmekanäle eines Sensors im elektromagnetischen Spektrum bestimmt dessen *spektrale Auflösung*. Diese beschreibt die Fähigkeit, die spektrale Signatur eines Körpers in schmalen Bandbreiten und mehr oder minder kurzen Intervallen wiederzugeben. Je höher also die spektrale Auflösung eines Aufnahmesystems, desto detaillierter kann die Reflektionscharakteristik einer Oberfläche nachvollzogen werden. Folglich steigt mit zunehmendem spektralem Auflösungsvermögen die Fähigkeit zur Differenzierung unterschiedlicher Bedeckungstypen an, was gerade im Hinblick auf die Betrachtung der überaus heterogenen urbanen Umwelt von besonderer Bedeutung ist.

Während die räumliche Charakteristik der Pixel vom geometrischen Auflösungsvermögen geprägt ist, hängt der eigentliche Informationsgehalt der Bilddaten von der *radiometrischen Auflösung* ab. Sie beschreibt die Sensibilität eines Sensors im Hinblick auf die Erfassung von Energieunterschieden in der aufgezeichneten elektromagnetischen Strahlung. Wie bereits zuvor erwähnt, wird die empfangene Energie proportional zu ihrer Intensität in digitale Helligkeitswerte umgesetzt. Bei den Radaraufnahmen, die im Rahmen dieser Arbeit genutzt werden, wird die absorbierte Energie auf einen 16-bit

Farbraum skaliert, d.h. die Aufnahme umfasst einen Grauwertebereich von 2^{16} DN bzw. 65536 Graustufen.

Die *temporale Auflösung* eines Aufnahmesystems definiert das kleinstmögliche Zeitintervall, innerhalb dessen ein identischer Punkt auf der Erdoberfläche erneut aufgenommen werden kann. Während die Repititionsrate (*revisit time*) für Satellitensysteme bis auf wenige Ausnahmen bei Plattformen der neuesten Generation eine konstante Größe darstellt, die sich in der Regel auf wenige Tage bis einen Monat beläuft, ist sie für flugzeuggetragene Sensoren variabel. Im Gegensatz zu Radarplattformen kann dieser Nominalwert der temporalen Auflösung bei optischen Sensoren jedoch nur unter geeigneten atmosphärischen Bedingungen (z.B. keine Wolkenbedeckung, Dunst, Nebel) gewährleistet werden.

Sowohl die siedlungsstrukturellen Raumeinheiten als auch die Veränderungen im Umfeld städtischer Agglomerationen weisen divergierende räumliche und zeitliche Skalierungen auf. Im Hinblick auf eine satellitengestützte Beobachtung dieser raumwirksamen Phänomene resultieren daraus spezifische Anforderungen an die geometrische und temporale Auflösung der fernerkundlichen Bilddaten (VGL. TAB. 2-1). Demgegenüber gilt im Hinblick auf das spektrale Auflösungsvermögen, dass sich mit steigender Anzahl an Aufnahmekanälen grundsätzlich die Möglichkeiten zur Erfassung der raumwirksamen Phänomene verbessern, da eine akkuratere Differenzierung der zu Grunde liegenden Raumeinheiten bzw. Bedeckungstypen gewährleistet wird.

Tab. 2-1: Anforderungen an die Eigenschaften von Satellitendaten im Hinblick auf die Beobachtung raumwirksamer Veränderungen im urbanen Umfeld

Räumliche Skalierung	Raumwirksames Phänomen	Maßstab	Geometrische Auflösung	Temporale Auflösung	Satellitensystem (* = Radar)
Überregional	Verstädterung, Zersiedelung, Überregionale Disparitäten, Bevölkerungswachstum	1:500.000 - 1: 100.000	30m – 1000m	5 -20 Jahre	Envisat-MERIS/ASAR*, ERS*, Radarsat*, Terra-MODIS, ASTER, Landsat, IRS, SPOT
Regional	Suburbanisierung, Reurbanisierung, städtische Dekonzentration, Zersiedlungstendenzen, Bevölkerungsabschätzung	1:100.000 - 1:50.000	5m – 30m	5 – 15 Jahre	Envisat-ASAR*, ERS*, Radarsat*, ASTER, Landsat, IRS, SPOT
Kommunal	Ver- und Entsigelung, Flächenumwidmung, Segregationserscheinungen	1:50.000 - 1:10.000	1m – 5m	1 – 10 Jahre	IRS, SPOT-5, IKONOS, QuickBird
Lokal	Ver- und Entsigelung, Flächenumwidmung	1:10.000 - 1:500	0,5m – 2m	1 – 5 Jahre	SPOT-5, IKONOS, Quick-Bird

Quelle: ergänzt nach NEER (1999) und HEROLD ET AL. (2002)

2.1.3 Computergestützte Bildklassifizierung

Ziel der computergestützten Bildauswertung ist es, die in Form kontinuierlicher Bilddaten abgelegten Messungen mittels spezieller Algorithmen zu analysieren, um somit gezielt und automatisiert Informationen zu extrahieren. Obwohl die thematische Genauigkeit einer solchen Auswertung in der Regel hinter der Güte einer manuellen Interpretation zurückbleibt, weist dieser Ansatz dennoch entscheidende Vorteile auf. So erfolgt die Klassifikation zum einen auf der Basis objektiver Kriterien oder Regelwerke. Darüber hinaus können über eine (semi-)automatisierte Auswertung bedeutend umfassendere Datenmengen in erheblich kürzerer Zeit ausgewertet werden. Zudem sind rechnergestützte Verfahren dem menschlichen Sehvermögen in Bezug auf die quantitative Analyse von Grauwerten, Farben oder Flächengrößen deutlich überlegen. Die inhaltlichen Genauigkeiten einer automatisierten Klassifikation liegen in der Regel je nach Komplexität der zu analysierenden Phänomene zwischen 70 Prozent und 90 Prozent (VGL. KAP. 1.1). Vor diesem Hintergrund stellen computergestützte Ansätze gerade im Kontext eines flächendeckenden und kontinuierlichen Umwelt-Monitorings eine zeitsparende und damit kostengünstige Technik dar.

Wie bereits in KAPITEL 2.1.2 dargelegt, beschreibt ein digitaler Datensatz einen mehrdimensionalen Merkmalsraum, der von einem Koordinatensystem aufspannt wird, dessen Achsen durch die einzelnen Aufnahmekanäle oder Datenlayer definiert sind. Dabei weisen identische Bedeckungsklassen in den einzelnen Kanälen jeweils ähnliche Reflektionswerte auf. Demgegenüber weichen die Rückstreubeiträge unterschiedlicher Bedeckungstypen deutlich voneinander ab. Somit ballen sich die Reflektionswerte identischer Objektklassen im definierten Merkmalsraum und bilden dort mehr oder minder klar abzugrenzende *Cluster* aus (VGL. ABB. 2-3). Die Lage, Größe und Form dieser Ballungen wird durch die inhärente Variabilität der Oberflächentypen bestimmt.

Verfahren zur automatisierten Bildauswertung machen sich den zuvor dargelegten Sachverhalt zu Nutze. Dabei bedienen sich die entsprechenden Techniken speziellen Algorithmen zur mathematischen Mustererkennung, die entweder *unüberwacht* oder *überwacht* ablaufen. Im Rahmen *unüberwachter Ansätze* wird die Anzahl gewünschter Klassen vorgegeben, um im Anschluss daran alle Bildelemente des mehrdimensionalen Merkmalsraums nach Kriterien der spektralen Distanz optimal in die vordefinierte Anzahl an Clustern zu unterteilen. Abschließend muss den daraus resultierenden, rein statistisch generierten Spektralklassen eine inhaltliche Bedeutung zugewiesen werden. Unüberwachte Verfahren (z.B. *K-Means*, *ISODATA*) bedürfen keinerlei Vorkenntnissen hinsichtlich der spektralen Eigenschaften der zu klassifizierenden Oberflächentypen und können daher schnell und ohne großen

Aufwand durchgeführt werden. Im Gegensatz dazu werden im Zuge *überwachter Klassifikationsverfahren* zu Beginn für jede erwünschte Objektklasse repräsentative Trainingsgebiete bestimmt. Auf der Basis dieser Trainingsflächen wird anschließend die Lage und Beschaffenheit des entsprechenden Klassen-zentrums im mehrdimensionalen Merkmalsraum berechnet. Zur Ermittlung der Klassenzugehörigkeit wird für jede Auflösungszelle auf der Basis eines spektralen Distanz- oder Ähnlichkeitsmaßes berechnet, welcher der zuvor definierten Trainingsklasse dieses Pixel im Merkmalsraum am Nächsten liegt. Zu den etabliertesten Methoden der überwachten Klassifikation zählen der *Maximum-Likelihood-Klassifikator* und das *Nearest-Neighbour-Verfahren*. Überwachte Ansätze bieten den Vorteil, dass Art und Anzahl der Objektklassen frei gewählt und damit spezifisch auf die jeweilige Zielsetzung angepasst werden können. Mitunter wird der überwachten Klassifizierung auch eine Cluster-Analyse vorge-schaltet. In einem solchen Fall spricht man von einer *hybriden Klassifizierung*.

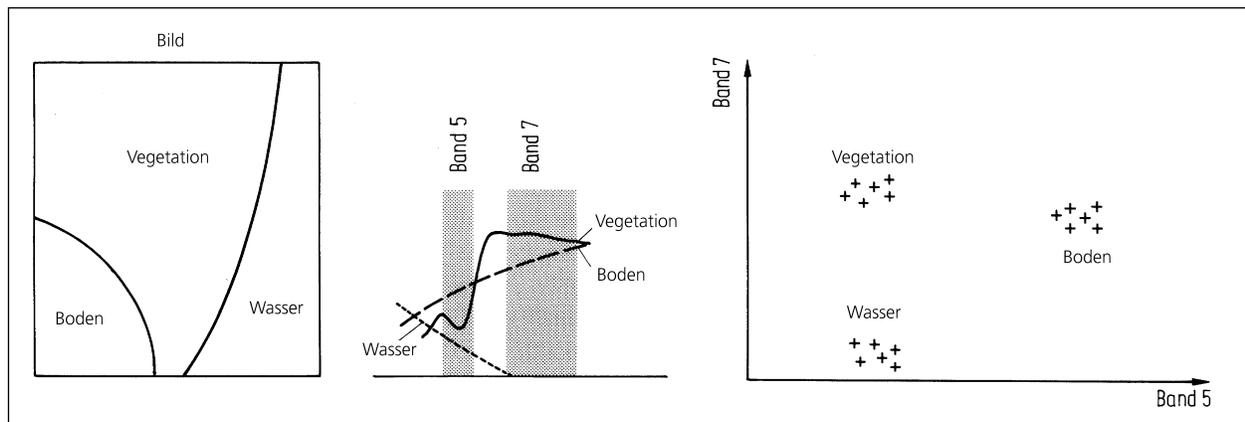


Abb. 2-3: Clusterbildung im mehrdimensionalen Merkmalsraum

Quelle: ergänzt nach RICHARDS & JIA (1999)

Sowohl unüberwachte als auch überwachte Verfahren verwenden Zuordnungskriterien wie Distanz- oder Ähnlichkeitsmaße zur Definition der Klassenzugehörigkeit. Dabei wird der zu Grunde liegende Merkmalsraum in der Regel durch die spektralen Kanäle der fernerkundlichen Bilddaten aufgespannt. Folglich nimmt die erreichbare Genauigkeit automatisierter Auswertungen drastisch ab, sobald sich die Merkmalsausprägung eines Bildelements nicht mehr eindeutig einer Trainingsklasse bzw. einem Clusterzentrum zuordnen lässt. Dies ist insbesondere dann der Fall, wenn eine Auflösungszelle mehrere Oberflächentypen erfasst (*Mischpixel*) oder sich die zu extrahierenden Objektklassen in ihrer Merkmalsausprägung stark ähneln. Ferner erweist es sich als überaus schwierig, Klassen zu identifizieren, deren Differenzierung auf funktionalen Eigenschaften beruht, die sich nicht über spektrale oder texturbezogene Merkmale beschreiben lassen.

Zur Kompensation solcher Schwierigkeiten wird der *spektrale Merkmalsraum* mitunter *transformiert* oder *durch zusätzliche Datensätze erweitert*. Zu den etabliertesten Ansätzen zählen die Verwendung *spektral transformierter Kanäle* (z.B. IHS, Hauptkomponenten, Tasseled Cap) oder die Integration zusätzlicher Datenebenen wie *Texturlayer* (z.B. Varianz, Haralick Parameter), *Indizes* und *Ratios* (z.B. NDVI) oder *thematischen Zusatzinformationen* (z.B. Bodentypenkarte, Straßennetz). Die *multitemporale Auswertung von Zeitreihen* – sprich die Erweiterung des Merkmalsraums um eine zeitliche Dimension – verbessert gerade die Differenzierbarkeit von Landnutzungsklassen, da diese gemeinhin einer charakteristischen, jahreszeitlichen Entwicklung unterliegen, die sich mitunter in einer messbaren spektralen Variation niederschlägt. Im Kontext urbaner Anwendungen hat sich die Berücksichtigung *texturbezogener Merkmale* bewährt, da diese im Gegensatz zu spektralen Attributen verhältnismäßig geringen Schwankungen unterliegen (VGL. KAP. 1.1). Zu den bewährtesten Texturmaßen zählen statistische Ansätze wie die *Kantenhäufigkeit*, die Verwendung von *Korrelationskoeffizienten*, die *Fourier-Transformation* und *Statistiken erster und zweiter Ordnung*. Letztere schließen die oftmals verwendeten Haralick-Parameter ein, die auf einer etwas komplexeren Berechnung von *Grey-Level-Co-Occurrence-Matrizen* beruhen und eine qualitative Bewertung der Textur ermöglichen (HARALICK ET AL., 1973).

Der *technische Ansatz zur automatisierten Klassifizierung fernerkundlicher Aufnahmen* beruht seit der Einführung der digitalen Bildverarbeitung weitestgehend auf einer *pixelbasierten Auswertung* der Bildinformation. Dabei sind die entsprechenden Algorithmen so konzipiert, dass sie die Information jeder Auflösungszelle isoliert auswerten und klassifizieren. Mit dem Aufkommen räumlich sehr hochauflösender Satellitendaten hat sich jedoch gezeigt, dass die pixelbasierte Auswertung zunehmend an ihre Grenzen stößt. So setzen sich bei hoher geometrischer Auflösung selbst verhältnismäßig kleinflächige Objekte aus zahlreichen Pixeln mit mehr oder minder identischen (Spektral-)Eigenschaften zusammen. Vor diesem Hintergrund rücken mit steigendem Auflösungsvermögen die Eigenschaften solcher Pixelgruppierungen immer stärker in den Vordergrund, während die Aussagekraft des einzelnen Bildelements zunehmend an Aussagekraft verliert. Letzteres wird dadurch verstärkt, dass lokale Details der betrachteten Oberflächen (z.B. Kamin auf Hausdach, trockenes Areal auf Rasenfläche) bei hohem Auflösungsvermögen sehr detailliert abgebildet werden, was zu lokalen Variationen zwischen den einzelnen Pixeln führt, die jedoch im Hinblick auf die Identifizierung des eigentlichen Objektes störend wirken. Folglich gewinnen mit steigendem Auflösungsvermögen spektrale, form- und texturbezogene Charakteristika der Pixelgruppen, aber auch deren räumliche Komposition und Beziehung untereinander immer stärker an Bedeutung. Da pixelbasierte Ansätze auf der Basis isolierter Bildelemente bzw. einer starren, rechteckigen bzw. zirkularen Umgebung operieren, können sie

jedoch nur bedingt solche strukturellen, hierarchischen oder kontextbezogenen Merkmale bereitstellen.

Aus diesem Grunde sind mit dem Aufkommen höchstauflösender Satellitendaten zunehmend *objektorientierte Bildanalyseverfahren* in den Mittelpunkt des Interesses gerückt. Im Gegensatz zu pixelbasierten Ansätzen werden die einzelnen Bildelemente im Rahmen einer solchen Auswertung zu Beginn über eine Segmentierung zu aussagekräftigen Objekten fusioniert. Diese neu generierten Grundeinheiten dienen dann als Basis für die anschließende Klassifizierung. Im Gegensatz zu Pixeln bieten Segmente den enormen Vorteil, dass sie realitätsbezogene Raumeinheiten repräsentieren. Dabei können neben spektralen Merkmalen auch eine Vielzahl form-, struktur-, kontext- und hierarchiebezogener Attribute genutzt werden. Folglich weisen objektorientierte Ansätze gegenüber pixelbasierten Verfahren eine deutlich erweiterte Funktionalität im Hinblick auf die Analyse räumlich und inhaltlich komplexer Zusammenhänge auf (VGL. KAP. 1.2).

Obwohl bereits Mitte der 1970er Jahre erste Ansätze zur Segmentierung von Bilddaten entwickelt wurden, gibt es bis heute nur sehr wenige, praktikable Softwarepakete, die eine respektable Segmentierung fernerkundlicher Aufnahmen erlauben und gleichzeitig eine hinreichende Funktionalität zur thematischen Klassifizierung bereitstellen (MEINEL & NEUBERT, 2004). Eines der etabliertesten Verfahren zur objektorientierten Bildanalyse wird im Rahmen dieser Dissertation genutzt und zusammen mit den wichtigsten Grundsätzen der objektorientierten Bildauswertung in KAPITEL 3.3 ausführlich erörtert.

2.2 Radarfernerkundung

2.2.1 Synthetic Aperture Radar (SAR)

Vergleichbar zur optischen Fernerkundung zielt auch der Einsatz von Radartechnik in der Erdbeobachtung auf die Gewinnung flächenhafter Informationen über die Beschaffenheit und den Zustand der Umwelt ab. Wie der Begriff *Radio Detection and Ranging* impliziert, stellen Radarplattformen *aktive Aufnahmesysteme* dar, die ursprünglich dazu entwickelt wurden, mit Hilfe langwelliger Strahlung Objekte aufzuspüren und zu lokalisieren. Dazu verwenden sie *Mikrowellenstrahlung* in einem Frequenzbereich von etwa 0,2 bis 40 GigaHertz, was einer Wellenlänge zwischen einem Meter und einem Milli-

meter entspricht. Zur Kennzeichnung der Radarstrahlung ist der entsprechende Abschnitt des elektromagnetischen Spektrums in so genannte *Bänder* unterteilt (VGL. TAB. 2-2).

Tab. 2-2: Frequenz und Wellenlänge ausgewählter Radarbänder

BAND	FREQUENZ [GHZ]	WELLENLÄNGE [CM]
P-band	0,22 – 0,39	77 – 136
L-band	1,0 – 2,0	15 – 30
S-band	2,0 – 4,0	7,5 – 15
C-band	4,0 – 8,0	3,75 – 7,5
X-band	8,0 – 12,0	2,4 – 3,75
K _u -band	12,5 – 18,0	1,67 – 2,4
K _a -band	26,5 – 40,0	0,75 – 1,18

Quelle: ergänzt nach HENDERSON & LEWIS (1998)

Der aktive Einsatz langwelliger Mikrowellenstrahlung stellt gegenüber optischen Sensoren einen maßgeblichen Vorteil dar, denn dieser Bereich des elektromagnetischen Spektrums wird kaum vom Zustand der Atmosphäre beeinflusst (VGL. ABB. 2-1). Demnach können Radarplattformen weitestgehend unabhängig von den Wetterbedingungen und der natürlichen Beleuchtung eingesetzt werden. Dabei finden im Rahmen fernerkundlicher Anwendungen überwiegend *abbildende Radartechniken* Verwendung, in deren Kontext sich speziell der Einsatz flugzeug- oder satellitengetragener Systeme mit *synthetischer Apertur (SAR)* etabliert hat. Diese sind in der Regel als *monostatisches Radar* ausgelegt, d.h. sie verfügen über ein kombiniertes Sender-Empfänger-Modul, das sich aus Antenne, Transmitter, Receiver sowie verschiedenen elektronischen Komponenten zur Aufzeichnung und Prozessierung der Radarsignale zusammensetzt.

Die flächendeckende Erfassung und bildhafte Wiedergabe der Erdoberfläche mittels Radartechnik stellt einen vergleichbar komplexen Prozess dar. Die wichtigsten aufnahmegeometrischen Kenngrößen sind in ABBILDUNG 2-4 illustriert. Grundsätzlich wird der Aufbau einer zweidimensionalen Aufnahme dadurch erreicht, dass sich das Trägersystem beständig entlang einer festgesetzten Flugbahn (*flight track*) fortbewegt, während das Radargerät kontinuierlich das Gelände senkrecht zur Fortbewegungsrichtung (*range direction*) aufzeichnet. Zu diesem Zweck generiert der Transmitter in konstanten Intervallen hochenergetische Mikrowellenimpulse. Diese werden über die Antenne zu einem zeilenähnlichen Richtstrahl gebündelt, der mit Lichtgeschwindigkeit senkrecht zur Flugrichtung auf einen keulenförmigen Ausschnitt des Geländes (*antenna footprint*) ausgesendet wird. Da dieser Prozess wäh-

rend des Fluges über einen gewissen Zeitraum konstant fortgeführt wird, kann schließlich ein kontinuierlicher Aufnahmestreifen (*swath*) aufgezeichnet werden.

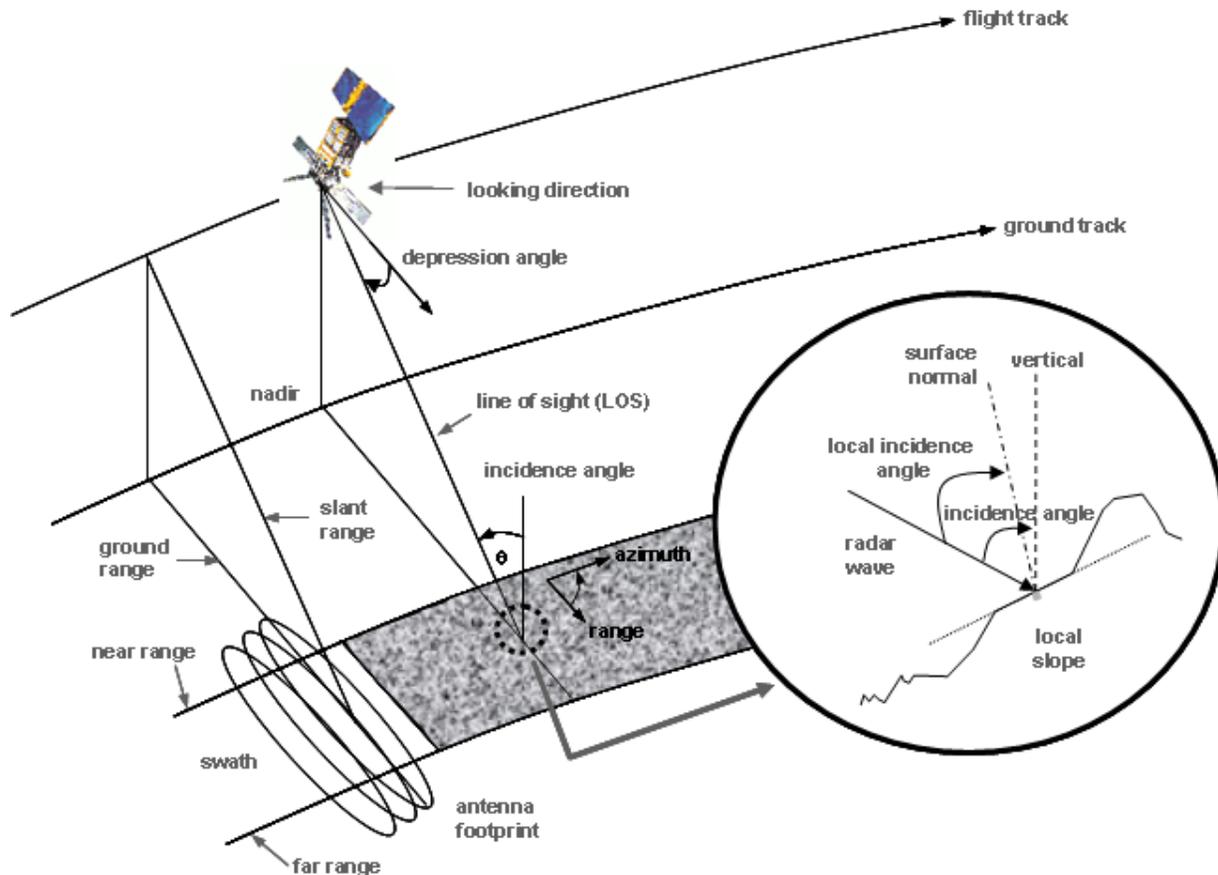


Abb. 2-4: Aufnahmegeometrie eines SAR-Systems

Trifft die Wellenfront des emittierten Radarimpulses auf die Erdoberfläche, wird sie dort in Abhängigkeit der geometrischen und physikalischen Eigenschaften des jeweiligen Flächenelements reflektiert, absorbiert oder transmittiert. Teile der Strahlung gelangen im Rahmen dieser Interaktion über Rückstreuprozesse (*backscatter*) wiederum zum Sensor. Dort werden die entsprechenden Signale von der Antenne aufgefangen und an den Empfänger weitergeleitet, um die Energie des detektierten Radarsignals exakt zu quantifizieren. Als entscheidende *Informationsträger* zur bildhaften Darstellung und Auswertung des Radarsignals dienen dessen *Amplitude*, *Phase* und *Polarisation*. Für die Bildgenerierung ist die Laufzeit des Signals von besonderer Bedeutung, da sie die notwendigen Informationen zur präzisen Berechnung der Schrägdistanz (*slant range*) zwischen Sensor und Zielobjekt ermöglicht. Auf

dieser Grundlage kann wiederum die exakte Position des Streuers auf der Erdoberfläche – und folglich auch im Bild – bestimmt werden.

Im Gegensatz zu optischen Systemen wird das räumliche Auflösungsvermögen eines SAR-Sensors grundsätzlich in zwei verschiedenen Richtungen definiert. Zum einen in der Blickrichtung des Trägersystems senkrecht zur Flugbahn (*range*) und zum anderen parallel zur Fortbewegungsrichtung der Plattform (*azimuth*). Dabei zeichnen sich jeweils unterschiedliche Parameter für die entsprechende geometrische Auflösung in Range bzw. Azimuth verantwortlich.

Range-Auflösung

Hinsichtlich der geometrischen Auflösung in Blickrichtung des Systems lassen sich zwei benachbarte Streuer nur dann als räumlich getrennte Objekte erfassen, wenn sich deren Rückstreuechos zeitlich nicht überlagern. Dabei gilt für ein SAR-System:

$$\Delta SLD = \frac{c}{2BW} \quad (2.1)$$

mit: ΔSLD = Geometrische Auflösung in Schrägdistanz [m]
 c = Lichtgeschwindigkeit [3×10^8 m/s]
 BW = Bandbreite [MHz]

Demzufolge laufen die Signale zweier benachbarter Objekte nur dann getrennt am Sensor ein, wenn ihr Abstand in Schrägdistanz (*slant range*) mindestens die Hälfte der Bandbreite beträgt. Entsprechend ist das Auflösungsvermögen in der Slant Range (*slant range resolution*) unabhängig von der Entfernung zwischen Sensor und Zielobjekt. Im Gegensatz dazu ist die für viele geowissenschaftliche Fragestellungen bedeutendere, räumliche Auflösung mit Bezug auf die Erdoberfläche – die so genannte *ground range resolution* – entfernungsabhängig. Hier vergrößert sich mit abnehmender Horizontaldistanz zwischen Nadirpunkt und Zielobjekt die während einer halben Impulsdauer überstrichene Strecke auf der Erdoberfläche:

$$\Delta GRD = \frac{c}{2BW * \sin \theta} \quad (2.2)$$

mit: ΔGRD = Geometrische Auflösung in Schrägdistanz [m]
 c = Lichtgeschwindigkeit [3×10^8 m/s]
 BW = Bandbreite [MHz]
 $\sin \theta$ = Blickwinkel [Grad]

Damit verringert sich die Ground Range Resolution zum Sensor hin kontinuierlich, bis sie schließlich im Nadir den Wert Null annimmt. Aus diesem Grunde können abbildende Radarsysteme ausschließlich in Schrägsicht hochaufgelöste Bilder liefern. Gleichzeitig hat dieser Effekt zur Folge, dass identische Bodendistanzen in der Slant-Range-Darstellung mit zunehmender Nähe zum Nadir verstärkt gestaucht abgebildet werden.

Azimuth-Auflösung

Wie bei allen elektrooptischen Systemen ist das geometrische Auflösungsvermögen eines Radars mit *realer Apertur* in Azimuth (*along track resolution*) eine Funktion aus eingesetzter *Wellenlänge* (λ), Brennweite bzw. *Abstand zum Streuer* (*SDR*) und *Länge der Radarantenne*. Somit ergibt sich die *Azimuth-Resolution* δ_{RAR} eines Radars mit *realer Apertur* aus:

$$\delta_{RAR} = \frac{\lambda}{l} * SDR \quad (2.3)$$

mit: δ_{RAR} = Geometrische Auflösung in Azimuth [m]
 SRD = Schrägdistanz Streuer-Sensor [m]
 λ = Wellenlänge [m]
 l = Länge der Antenne [m]

Folglich wären bei großen Flughöhen der Trägerplattform eine sehr hohe Frequenz oder eine enorme Antennenlänge erforderlich, um eine hinreichend genaue Bodenauflösung zu gewährleisten. Beide Parameter können aus systemtechnischen Gründen nur in begrenztem Umfang angepasst werden. Entsprechend sind RAR-Systeme im Hinblick auf einen Einsatz aus großen Höhen – z.B. dem Weltraum – nicht praktikabel. So beträgt die geometrische Auflösung der realen Apertur beim zukünftigen TerraSAR-X mit einer Antennenlänge von 4,8 Metern, einer Wellenlänge von 3,1 Zentimetern und einer Schrägdistanz zur Erdoberfläche von rund 600 Kilometern bei einem Depressionswinkel von 30 Grad rund 3,9 Kilometer. Diese Distanz entspricht zugleich der Breite des mit einem Beam erfassten, keulenförmigen Ausschnitts auf der Erdoberfläche (VGL. ABB. 2.4).

Um dennoch hochauflösende Aufnahmen aus großen Flughöhen zu ermöglichen, werden Radarsysteme in der Regel als *Synthetic Aperture Radar* ausgelegt. Diese nutzen die Fortbewegung der Trägerplattform zur *synthetischen Verlängerung der realen Antenne*, indem sie im Grunde genommen *mehrere reale Aperturen hintereinander reihen*, um somit eine lange Antenne zu simulieren. Zu diesem Zweck sendet das SAR über eine physikalisch sehr kurze Antenne kontinuierlich kohärente Mikrowellenstrahlung in einem breit gefächerten Richtstrahl aus. Dadurch werden die einzelnen Objekte entlang der Flug-

bahn mehrmals aus verschiedenen, aufeinander folgenden Positionen aufgezeichnet und dann nachträglich zu einem Bild prozessiert bzw. fokussiert. Zur Bildgenerierung wird die *Dopplerfrequenzverschiebung* des kohärenten Radarsignals zwischen den jeweiligen Rückstreuerechos der einzelnen Streuer ausgewertet. Die Länge der synthetischen Apertur berechnet sich grundsätzlich aus der maximalen Strecke, über die ein Streuer von der realen Antenne des SAR-Systems erfasst wird. Diese Distanz beträgt beim SAR das Zweifache des Antenna Footprints. Folglich ist das räumliche Auflösungsvermögen eines Radarsensors in Azimuth theoretisch unabhängig von der Entfernung zum Zielobjekt. Dabei verhält sich die geometrische Auflösung nunmehr ausschließlich proportional zur Länge der realen Antenne:

$$\delta_{SAR} = \frac{l}{2} \quad (2.4)$$

mit: δ_{SAR} = Azimuth-Auflösung der synthetischen Antenne [m]
 l = Länge der realen Antenne [m]

Vor diesem Hintergrund können satellitengestützte SAR-Systeme theoretisch die gleiche geometrische Auflösung erreichen, wie flugzeuggetragene Radarplattformen, die in wesentlich geringeren Höhen operieren.

2.2.2 Systemspezifische Abbildungsparameter

Der Rückstreuquerschnitt einer Auflösungszelle und damit der Informationsgehalt und das Erscheinungsbild von SAR-Aufnahmen werden maßgeblich von einer Reihe system- und objektspezifischer Abbildungsparameter geprägt. Dabei werden im Folgenden zunächst die *systembezogenen Abbildungsparameter* erläutert.

Wellenlänge

Die Wellenlänge bzw. Frequenz der eingesetzten elektromagnetischen Strahlung hat entscheidenden Einfluss auf die Interaktion zwischen Radarsignal und beleuchtetem Medium. Sie bestimmt einerseits die *Eindringtiefe* und *Extinktion (Signaldämpfung)* der Mikrowellen und wirkt sich andererseits auf den *Streumechanismus an der Oberfläche der erfassten Zielobjekte* aus.

Elektromagnetische Strahlung dringt umso tiefer in ein Medium, desto niedriger die Frequenz bzw. größer die Wellenlänge ist. Für die Extinktion gilt, dass diese mit zunehmender Wellenlänge kontinu-

ierlich abnimmt. Demzufolge beschreiben die kurzwelligen X-Band Aufnahmen vornehmlich die Oberflächenbeschaffenheit der erfassten Objekte. Langwellige Strahlen des L- oder P-Bands hingegen dringen mitunter wesentlich stärker in das beleuchtete Medium ein. Folglich dominieren verstärkt Rückstreubeiträge aus tiefer gelegenen Schichten der erfassten Strukturen (*Volumenstreuung*). So zeigt ABBILDUNG 2-5, dass Radarstrahlung im L-Band mitunter durch das Blätterdach der Vegetation transmittiert. Folglich hat im Kontext landwirtschaftlicher Nutzkulturen (z.B. linker Bildrand) bisweilen die heterogene Bodenstruktur maßgeblichen Anteil am reflektierten Signal, während im X-Band das Blattwerk die Rückstreuung dominiert. Im Hinblick auf Baumbestände (z.B. nördlich und südlich der nahezu schwarz erscheinenden Wasserfläche) bewirkt die höhere Eindringtiefe des L-Bands, dass die im X-Band deutlich ausgeprägte Strukturierung des Kronendachs signifikant reduziert ist.



Abb. 2-5: Wellenlängenabhängige Variation der Radarrückstreuung zwischen X-Band (l.) und L-Band (r.) – Ackerbaulich genutzte Freiflächen wirken im langwelligeren L-Band überwiegend als glatte Oberflächen mit entsprechend geringer Rückstreuung (dunkel). Gleichsam nimmt die Eindringtiefe mit abnehmender Frequenz zu – gut zu erkennen am Muster der Bodenstrukturen im Kontext vegetationsbedeckter Ackerflächen (zentral links), die zwar im L-Band, jedoch nicht im X-Band in Erscheinung treten.

Darüber hinaus ist die Wellenlänge eine entscheidende Kenngröße im Hinblick auf die *Streuprozesse an der Oberfläche* des betrachteten Zielobjektes. Nach dem so genannten *Rayleigh-Kriterium* – das in KAPITEL 2.2.4 eingehend erörtert wird – ist eine Oberfläche mit Blick auf ihren Streumechanismus als rau zu definieren, wenn die Dimensionierung der Oberflächenflächenstrukturen etwa im Bereich der Wellenlänge oder darüber liegt. Somit kann beispielsweise ein unbedeckter Boden im X-Band ($\sim 3\text{cm}$ Wellenlänge) rau wirken, damit stark streuen und in der SAR-Aufnahme hell erscheinen, wäh-

rend er im L-Band ($\sim 20\text{-}30\text{cm}$ Wellenlänge) glatt wirkt und eine entsprechend geringe Rückstreuung auftritt (VGL. ABB. 2-5).

Polarisation

Elektromagnetische Wellen setzen sich aus einem elektrischen und einem magnetischen Feld zusammen. Die *Polarisation* elektromagnetischer Strahlung beschreibt die *Position des elektromagnetischen Feldvektors auf einer senkrecht zur Ausbreitungsrichtung angelegten Ebene*. SAR-Sensoren nutzen meist lineare Polarisationen, d.h. die verwendete Mikrowellenstrahlung schwingt in der vertikalen (V) oder horizontalen (H) Ebene. Dabei kann das Radarsignal beim Senden und Empfangen *gleich-polarisiert* (HH oder VV), *kreuz-polarisiert* (HV oder VH) oder *voll-polarisiert* (HH, VV, VH, HV) moduliert werden. Daten, die nur in einer einzigen Polarisation aufgezeichnet werden, sind *einfach-polarisiert (single-pol)*, während *dual-polarisierte (dual-pol)* Aufnahmen zwei Polarisationsebenen und *quad- bzw. voll-polarisierte (quad-pol)* Bilddaten entsprechend alle vier möglichen Polarisationen abdecken.

Trifft ein Puls kohärenter Radarstrahlung auf ein Medium, werden je nach Beschaffenheit des Streuers die Amplitude, Phase und Polarisation des emittierten Signals modifiziert. Umgekehrt sind Art und Stärke dieser Veränderung unter anderem abhängig von den Eigenschaften der verwendeten Strahlung. So ist die Intensität des Radarechos besonders hoch, wenn die Polarisation der Wellen und die Strukturen auf der betrachteten Oberfläche die gleiche Richtungskomponente aufweisen – z.B. vertikale Halme eines Kornfelds und VV-Polarisation des emittierten Signals. Bedingt durch diese Abhängigkeit beeinflusst die Polarisation gleichsam die Eindringtiefe der Radarstrahlung in ein Medium.

Die Wirkung der Polarisation auf das gemessene Radarsignal wird speziell bei einem Vergleich zwischen *Kreuz- und Gleich-Polarisation* deutlich (VGL. ABB. 2-6). Die Kreuz-Polarisation beschreibt das Rückstreusignal depolarisierter Strahlung. *Depolarisation* tritt auf, wenn der Polarisationszustand zwischen gesendetem und empfangenem Signal wechselt, beispielsweise von H nach V (HV-Polarisation). Prinzipiell erhöht sich der Anteil depolarisierter Strahlung mit *zunehmender Anzahl an Streueignissen*. Daher wird die Intensität der Rückstreuung in der Kreuz-Polarisation insbesondere dort hoch sein, wo das emittierte Signal diffus oder mehrfach gestreut wurde – etwa an besonders rauen Oberflächen oder im Volumen eines Mediums. Da in der Kreuz-Polarisation ausschließlich der depolarisierte Anteil des gesendeten Signals aufgezeichnet wird, liegt die empfangene Energiemenge deutlich unter jener der Gleichpolarisation. ABBILDUNG 2-6 zeigt zudem, dass im zentralen Bereich des HH-polarisierten Ausschnitts aufgrund direkter Rückstreuung bzw. Dipolstreuung an oberirdisch

verlegten, metallischen Bewässerungsrohren sowie steilen Ackerfurchen bewässerter Felder überaus signifikante Rückstreubeiträge erreicht werden. Da dieser Streuprozess jedoch kaum zu Depolarisationen führt, tritt das entsprechende Phänomen in der Kreuz-Polarisation nicht in Erscheinung.

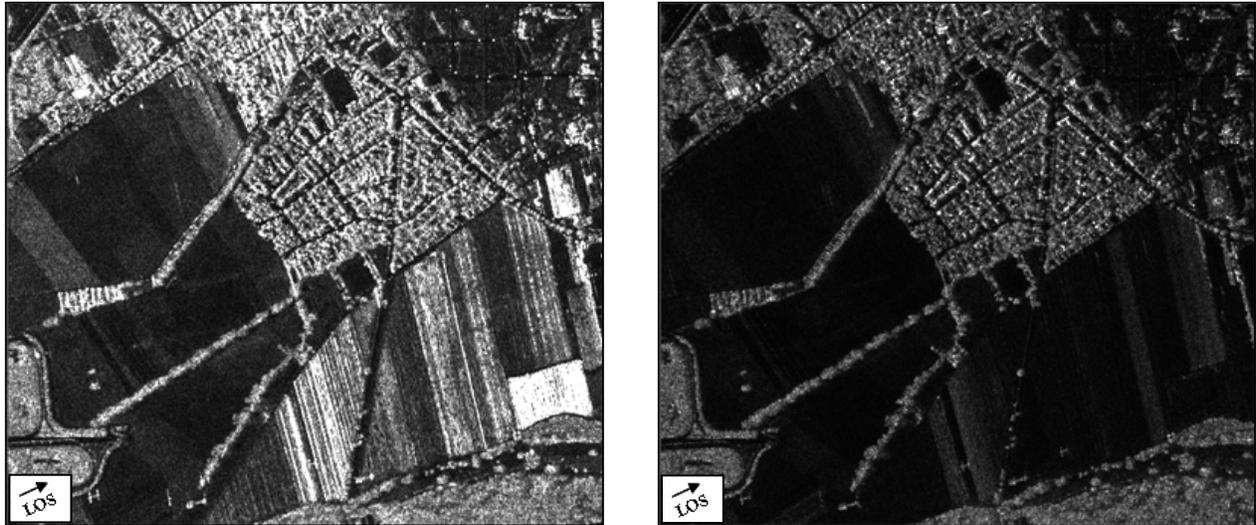


Abb. 2-6: Vergleich zwischen den Rückstreubeiträgen in L-HH- (l.) und L-HV-Polarisation (r.) – Grundsätzlich liegt die Intensität depolarisierter Strahlung (HV) deutlich unter der Intensität des gleich-polarisierten Signals. Ferner wird deutlich, dass in der Gleich-Polarisation direkte bzw. dipolare Rückstreuung – z.B. im rechten unteren Bildbereich an Ackerfurchen bzw. Bewässerungsrohren – auftritt, während sich dieser Effekt in der Kreuz-Polarisation nicht findet.

Aufnahmegeometrie

Ebenso wie die Wellenlänge und Polarisation kann auch die Aufnahmegeometrie die Radarrückstreuung in signifikanter Weise beeinflussen. Von besonderer Bedeutung ist in diesem Kontext der *Einfallswinkel* (*incidence angle*), der den Winkel zwischen der einfallenden Radarstrahlung und der Vertikalen kennzeichnet (VGL. ABB. 2-4). Da SAR-Systeme in Range-Richtung mitunter über eine Länge von vielen Kilometern aufzeichnen, nimmt der Einfallswinkel mit zunehmender Entfernung zum Sensor – d.h. von der Near Range zur Far Range – immer größere Werte an. Diese Variation geht gleichsam mit einer Veränderung der raugkeitsabhängigen Radarrückstreuung einher. Dabei wächst die Rückstreuintensität generell mit abnehmendem Einfallswinkel an. Somit weisen Zielobjekte unter wechselnden Einfallswinkeln jeweils ein verändertes Streuverhalten auf (VGL. ABB. 2-7). Zudem erhöhen sich mit steigendem Einfallswinkel die Volumenstreuung und der Anteil an abgeschatteten bzw. abgedeckten Flächen, während sich die Eindringtiefe aufgrund des verhältnismäßig flachen Aufprallwinkels reduziert (VGL. ABB. 2-7).

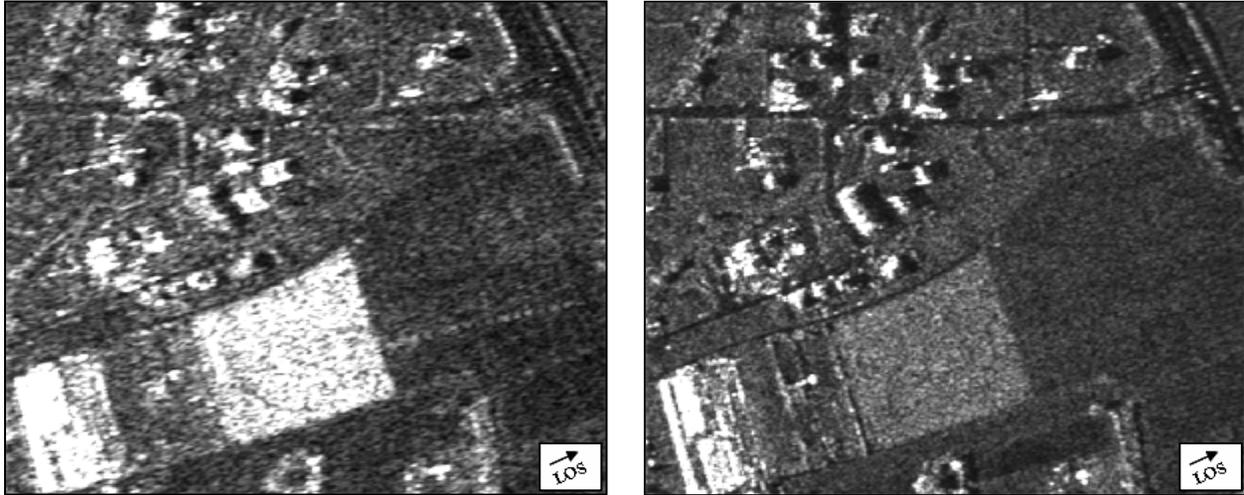


Abb. 2-7: Einfluss des Einfallswinkels auf das Streuverhalten identischer Oberflächen in Near Range (l.) und Far Range (r.) – Besonders signifikant ist die Abnahme der Rückstreuung von der Near Range zur Far Range im Kontext der Ackerfläche im zentralen unteren Bildbereich. Im Hinblick auf die Gebäude im Zentrum des Ausschnitts zeigt sich ferner, dass zur Far Range hin die Länge der Schatten zunimmt.

Neben dem Einfallswinkel spielt auch die *Blickrichtung* (*aspect angle, orientation*) des Radarsensors eine Rolle. Diese beschreibt die relative Orientierung des emittierten Radarsignals im Vergleich zur Ausrichtung der Zielobjekte. Dabei können mit wechselnder Blickrichtung sowohl die Sichtbarkeit als auch die geometrische Charakteristik einzelner Objekte erheblich variieren. Folglich ist das Erscheinungsbild der Zielobjekte bei wechselnder Blickrichtung häufig starken Schwankungen unterworfen.

2.2.3 Objektspezifische Abbildungsparameter

In den folgenden Abschnitten werden jene objektspezifischen Abbildungskriterien vorgestellt, die einen nachhaltigen Einfluss auf die Rückstreuung des Radarechos ausüben. Diesbezüglich spielen vor allem die *Oberflächenrauigkeit*, die *dielektrischen Eigenschaften* und die *geometrischen Charakteristika* der erfassten Zielobjekte eine zentrale Rolle. Im Gegensatz zu den systemimmanenten Abbildungskriterien sind die objektbezogenen Eigenschaften in der Regel nicht bekannt. Zudem führen phänologische Veränderungen, wechselnde Nutzungen oder variierende physikalische Eigenschaften (z.B. Feuchtigkeit) mitunter zu signifikanten Variationen im zeitlichen Rückstreuerverhalten der Objekte.

Oberflächenrauigkeit

Ein sehr bedeutender Faktor im Hinblick auf das Rückstreuerverhalten eines Zielobjektes ist dessen Oberflächenrauigkeit. Diese kennzeichnet die *durchschnittlichen Höhenunterschiede auf der Oberfläche eines Streuers* und wird im Allgemeinen in Zentimetern angegeben. Ob eine Oberfläche rau oder glatt

wirkt, wird vor allem durch die *Wellenlänge* und den *Einfallswinkel* beeinflusst (VGL. KAP. 2.2.2). Sind diese beiden Größen konstant, gilt für den Effekt der Rauigkeit, dass die Streuung umso diffuser wird, je rauer die Oberfläche ist. Dabei dominiert bei spiegelnder Reflektion – d.h. glatten Oberflächen – die kohärente Strahlung, während bei diffuser Streuung der Anteil inkohärenter Wellen stark ansteigt. Hinsichtlich des Einflusses auf das Rückstreuverhalten lassen sich mit der *mikro-, meso- und makroskaligen Rauigkeit* grundsätzlich drei Skalierungen differenzieren.

Mikroskalige Rauigkeit – Die *mikroskalige Rauigkeit* ist in ihrer räumlichen Ausprägung kleiner als das geometrische Auflösungsvermögen des SAR-Systems und ist daher kennzeichnend für die Beschaffenheit der Oberfläche eines Objektes. Sie bestimmt vor allem den *Grauton der entsprechenden Struktur im Radarbild*. Eine etablierte Kenngröße zur Charakterisierung der mikroskaligen Oberflächenrauigkeit ist das so genannte *Rayleigh-Kriterium*. Dieses definiert die relative Rauigkeit einer reflektierenden Oberfläche über die Beziehung zwischen der *Höhe der Oberflächenelemente* (b), der *Wellenlänge* (λ) und dem *Einfallswinkel* (θ). Da die rauigkeitsbedingten Höhenunterschiede der meisten natürlichen Oberflächen häufig im Bereich der verwendeten Wellenlänge liegen, wird zur exakteren Kennzeichnung oftmals ein modifiziertes Rayleigh-Kriterium verwendet. Demnach gilt:

$$S_h > \frac{\lambda}{4.4 \cos \theta} \quad S_h < \frac{\lambda}{25 \cos \theta} \quad \frac{\lambda}{25 \cos \theta} < S_h < \frac{\lambda}{4.4 \cos \theta} \quad (2.5)$$

Glatte Oberfläche

Raue Oberfläche

Mittelraue Oberfläche

mit: b = Höhe der Oberflächenelemente [m]
 λ = Wellenlänge [m]
 θ = Einfallswinkel [Grad]

Mesoskalige Rauigkeit – Die *mesoskalige Rauigkeit* beschreibt die Strukturierung des Geländes oder einzelner Flächen in einer Größenordnung, die etwas über der geometrischen Auflösung des SAR-Systems liegt. Damit prägt sie vor allem die *Textur einer Radaraufnahme*. Diese ist umso stärker ausgeprägt, je größer und abrupter die *Höhen- und Neigungsunterschiede* zwischen den einzelnen Struktureinheiten (z.B. Häuser, Hecken, Straßen) sind.

Makroskalige Rauigkeit – Für die Effekte der *makroskaligen Rauigkeit* zeichnen sich Strukturen verantwortlich, die in ihrer räumlichen Ausprägung das geometrische Auflösungsvermögen des Radarsensors um ein Vielfaches übertreffen. Dazu zählen vor allem die *Reliefierung* des Geländes, die großflächige *Variation der Landnutzung* oder ein *Wechsel in den naturräumlichen Einheiten*.

Wie zuvor beschrieben hat die Rauigkeit also letztlich großen Einfluss auf die Art und Ausprägung der Streuprozesse und somit auch auf die Intensität des Signals und das Erscheinungsbild der erfassten Objekte bzw. Oberflächen. Je nach physikalischer und geometrischer Beschaffenheit der beleuchteten Medien können die Streumechanismen dabei klar getrennt sein, kontinuierlich ineinander übergehen oder sogar in direkter Kombination auftreten. ABBILDUNG 2-8 gibt eine zusammenfassende Übersicht der häufigsten Streuprozesse in einem urbanen Umfeld.

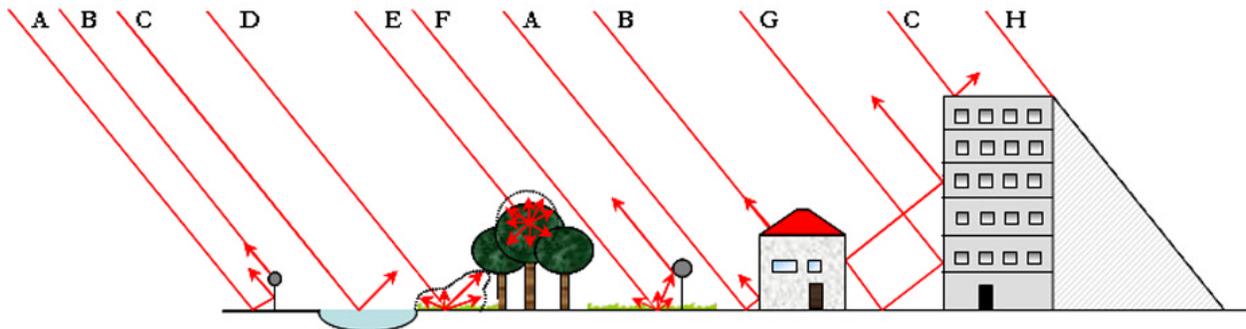


Abb. 2-8: Charakteristische Streumechanismen im urbanen Umfeld – Double Bounce an spiegelnd reflektierenden Flächen (A), direkte, spiegelnde Rückstreuung (B), spiegelnde Reflektion (C), diffus-gerichtete Streuung (D), diffuse Streuung im Volumen (E), diffus-gerichteter Double Bounce (F), mehrfacher Double Bounce (G) und Schatten (H). Letzterer zählt nicht zu den Streuprozessen, ist aber dennoch für das Erscheinungsbild urbaner SAR-Szenen prägend.

Auf welche Weise diese Streumechanismen das Erscheinungsbild einer SAR-Aufnahme prägen, ist schließlich in ABBILDUNG 2-9 illustriert. Wie aus der vorherigen Abbildung ersichtlich, zeichnen sich bebaute Areale vor allem durch einen markanten Wechsel aus hellen Bereichen direkter Rückstreuung und größeren, nahezu schwarz erscheinenden Abschattungsflächen aus. Folglich heben sich diese Zonen hoher mesoskaliger Rauigkeit durch eine entsprechend signifikante Strukturierung von Arealen mit geringer mesoskaliger Rauigkeit (z.B. Freiflächen) ab.

Die ebenfalls deutlich zu erkennenden Helligkeitsunterschiede innerhalb der ackerbaulich genutzten Freiflächen resultieren aus Variationen der Rauigkeit. Im unteren, linken Bildbereich wird diese durch den Wechsel zwischen unbedeckten (rau bzw. hell) und mit Nutzpflanzen bewachsenen (glattes Blattwerk bzw. dunkel) Ackerflächen hervorgerufen (vgl. Abb. 2-9). Signifikant ist zudem der Unterschied in der recht diffusen und damit hellen Rückstreuung des rauen Gleiskörpers einer Eisenbahn (links oben) und dem vergleichsweise glatten und folglich spiegelnd reflektierenden Belag einer Schnellstraße (ebenfalls linker oberer Bildbereich). Ähnliche Effekte treten auch im Kontext von Sportanlagen zwischen der glatten Oberfläche von Hartplätzen und den im X-Band bedeutend rauer wirkenden Rasenplätzen auf.

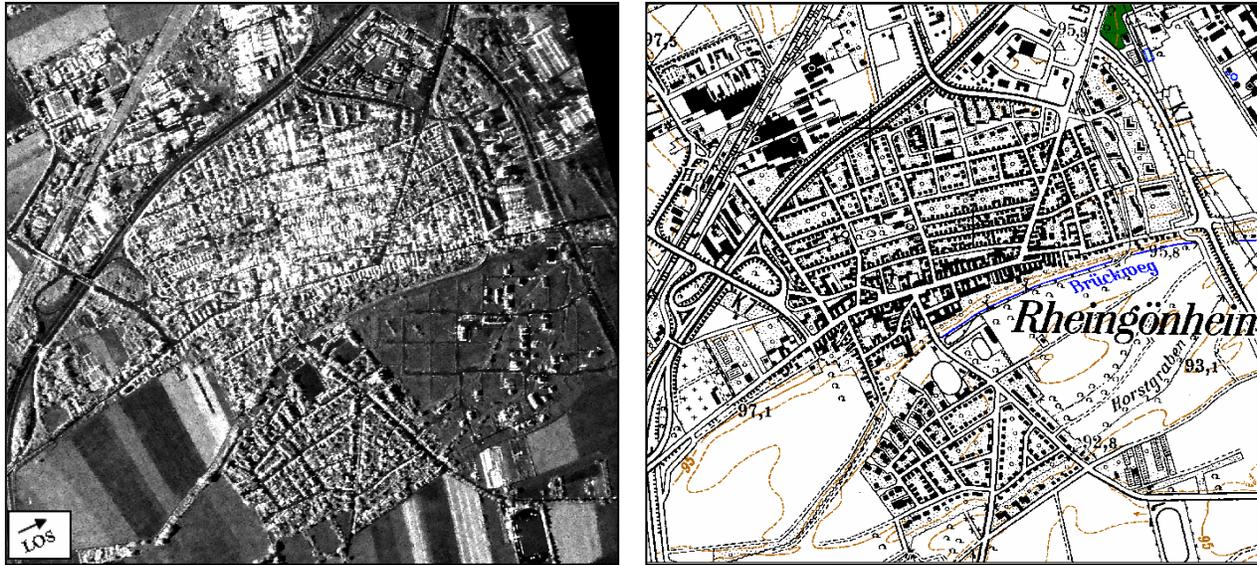


Abb. 2-9: Variierende Rückstreuintensitäten im X-Band aufgrund wechselnder Oberflächenrauigkeiten – Die Grauwertvariationen im Bereich der Freiflächen resultieren überwiegend aus einer unterschiedlichen mikro- und mesoskaligen Rauigkeit. Bedingt durch die enorme mesoskaligen Rauigkeit wird das kontrastreiche Erscheinungsbild von Siedlungsflächen vor allem durch Schattenflächen und hell erscheinende Double-Bounce-Reflektionen hervorgerufen.

An dieser Stelle sei abschließend erwähnt, dass neben der zuvor beschriebenen Oberflächenstreuung noch ein zweiter Streumechanismus von Bedeutung ist – die *Volumenstreuung*. Sie unterscheidet sich grundsätzlich von der Oberflächenstreuung und wird in wesentlich geringerem Umfang von der Rauigkeit des bestrahlten Mediums beeinflusst. Volumenstreuung erfolgt vornehmlich im Zusammenhang mit Medien, die sich aus mehreren strukturellen Einheiten mit unterschiedlichen dielektrischen Eigenschaften zusammensetzen. Da die räumlichen Diskontinuitäten in aller Regel zufallsverteilt sind, wird die Radarstrahlung innerhalb des Volumens mehrfach gestreut. Daraus resultiert ein diffuses Streuverhalten, das im Wesentlichen durch die Inhomogenität des Mediums und die Eindringtiefe der Radarwellen bestimmt wird. Aus diesem Grund übt der Einfallswinkel nur einen recht geringen Einfluss auf die Volumenstreuung aus, während der Polarisierung eine wesentlich größere Bedeutung zukommt.

Dielektrische Eigenschaften

Die Dielektrizitätskonstante ist eine Kenngröße für die *elektrische Leitfähigkeit eines Mediums* und wird maßgeblich von dessen Gehalt an Wasser, Salz oder Metall bestimmt (VGL. ABB. 2-10). Des Weiteren spielen aber auch der strukturelle Aufbau des Mediums sowie die Wellenlänge der auftreffenden Strahlung eine Rolle. Die Dielektrizitätskonstante beschreibt die Fähigkeit eines Materials, unter der Einwirkung elektrischer Felder bestimmte Mengen an Ladung zu verschieben und das einwirkende

elektrische Feld dadurch abzuschwächen. Im Allgemeinen weist Wasser mit einem Wert von 80 eine der höchsten Dielektrizitätskonstanten auf, während die meisten natürlich vorkommenden Materialien in einem Bereich zwischen zwei und acht liegen.

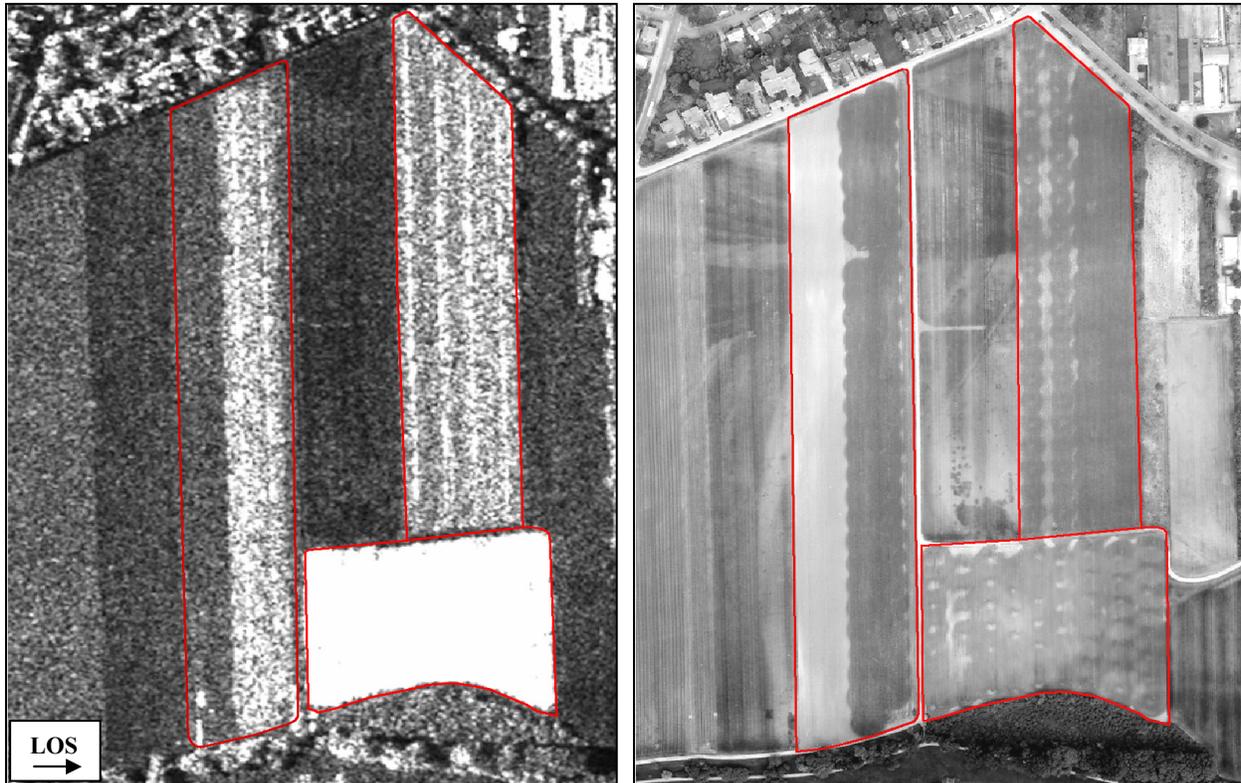


Abb. 2-10: Anstieg der Rückstreuintensität mit zunehmendem Wassergehalt in einer X-Band Aufnahme am Beispiel beregneter Ackerflächen (rot) – Im Luftbild (r.) erscheinen bewässerte Areale dunkel, in der SAR-Aufnahme (l.) hingegen hell. Besonders markant ist die enorme Intensität im Bereich der bewässerten Ackerfläche am unteren Bildrand, da hier neben der hohen Bodenfeuchte auch die signifikante Rauigkeit und Ausrichtung der Ackerfurchen orthogonal zur LOS die Rückstreuung verstärken.

Die dielektrischen Eigenschaften eines Mediums haben maßgeblichen Einfluss auf die Absorption, Transmission und Reflektion auftreffender elektromagnetischer Wellen. Dabei nimmt mit steigender Dielektrizitätskonstante die Rückstreuung eines Körpers zu, d.h. er erscheint im Radarbild heller. Dies gilt jedoch weniger für spiegelnde Oberflächen wie beispielsweise glattes Metall, da in diesem Fall die Orientierung der Fläche die entscheidende Rolle spielt. Gleichzeitig sinkt mit steigender Leitfähigkeit die Eindringtiefe der Mikrowellenstrahlung deutlich ab, so dass zunehmend die Oberflächenstreuung dominiert.

Gelände- und Objektgeometrie

Der Einfluss des systemspezifischen Einfallswinkels auf die Wechselwirkung zwischen Radarstrahlung und Streuer wurde bereits in KAPITEL 2.2.3 erläutert. Allerdings wird die Intensität d.h. Stärke des gestreuten Radarsignals genau genommen durch den objektbezogenen, *lokalen Einfallswinkel* bestimmt. Dieses Maß beschreibt den *Winkel zwischen Radarstrahl und lokaler Normalen der betrachteten Oberfläche* (VGL. ABB. 2-4). Somit wird der lokale Einfallswinkel sowohl von der Hangneigung und Orientierung des Geländes als auch vom Blickwinkel des Sensors und der Ground-Range-Entfernung bestimmt. Folglich schließt er Objekt- und Sensoreigenschaften gleichermaßen ein. Generell weisen dem Sensor zugeneigte Flächen (z.B. Hausdächer) dabei kleinere lokale Einfallswinkel auf und streuen verstärkt in Richtung des einfallenden Radarstrahls.

Der von der Aufnahme- und Geländegeometrie vorgegebene lokale Einfallswinkel hat entscheidenden Einfluss auf das Auftreten *geometrischer und radiometrischer Verzerrungen* (VGL. ABB. 2-11) wie *Foreshortening*, *Layover*, *Shadow* oder *Lengthening*.

Foreshortening (Verkürzung) – Aufgrund der Laufzeitabhängigkeit des Signals werden Flächen, die der Antenne zugeneigt sind und deren lokaler Einfallswinkel kleiner als der Beleuchtungswinkel ist, in der Radaraufnahme gestaucht dargestellt (VGL. ABB. 2-11). Die maximale Verkürzung erfolgt, wenn der Radarstrahl im rechten Winkel auf eine dem Sensor zugeneigte Fläche auftrifft und die Spitze sowie Basis der Struktur gleichzeitig erreicht. Vergleichbar den nachfolgend genannten Layover-Regionen treten diese verkürzt dargestellten Flächen im SAR-Bild als merklich hellere Regionen in Erscheinung, da der Rückstreubeitrag des gesamten Areals auf einen kleineren Bereich in der Radaraufnahme komprimiert wird.

Layover (Umklappung) – Zum so genannten Layover kommt es, wenn der lokale Neigungswinkel einer dem Sensor zugewandten Fläche den vom System vorgegebenen Einfallswinkel übertrifft und die Wellenfront des emittierten Radarsignals in der Folge die Spitze eines Zielobjektes (z.B. Gebäude) erreicht, bevor es an dessen Basis angelangt ist. In einem solchen Fall ist die Schrägentfernung und damit Laufzeit zwischen Antenne und Spitze des Objektes kürzer als diejenige zwischen Antenne und Fußpunkt der Struktur. Folglich wird der höchste Punkt des Zielobjektes im SAR-Bild vom Sensor aus gesehen vor dessen Fußpunkt abgebildet – er klappt zum Sensor hin um (VGL. ABB. 2-12). Damit stellt der Layover eine extreme Form des Foreshortenings dar. Layover-Bereiche erscheinen in der Radaraufnahme stark aufgehellt, d.h. es kommt neben der geometrischen Verzerrung gleichsam zu einer reliefbedingten, radiometrischen Modifizierung.

Radar shadow (Schatten) – Abschattungseffekte entstehen, wenn die Neigung einer dem SAR-System abgewandten Fläche größer ist als der lokale Einfallswinkel (VGL. ABB. 2-11). In solchen Fällen kann das einfallende Radarsignal die dem Sensor abgewandten Bereiche des Zielobjektes nicht erreichen, weshalb für diese Areale keine Information vorliegt. Im Radarbild treten sie folglich als schwarze Flächen in Erscheinung (VGL. ABB. 2-12). Da mit zunehmender Entfernung zum Sensor – bzw. steigendem Einfallswinkel – die Beleuchtung des Geländes kontinuierlich flacher wird, nimmt der Anteil bzw. Länge der Schattenflächen von der Near Range zur Far Range stetig zu (VGL. ABB. 2-11).

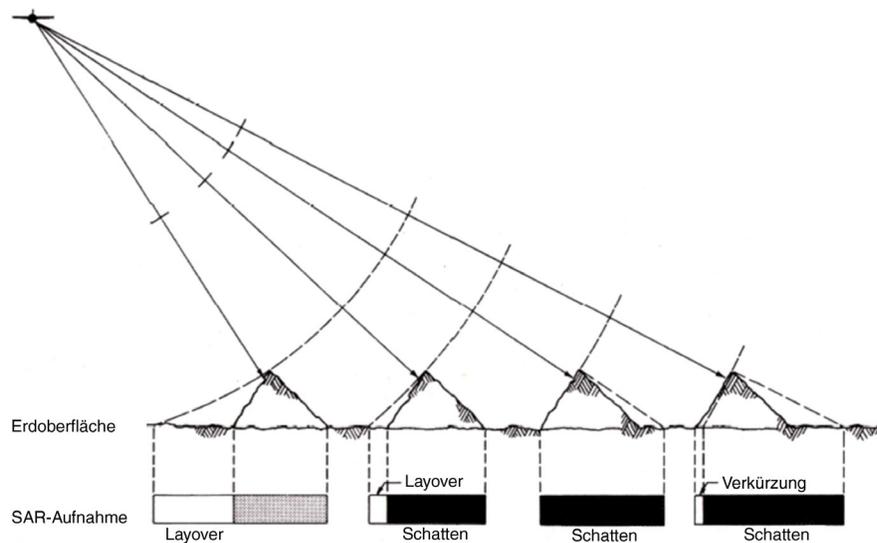


Abb. 2-11: Geometriebedingte Verzerrungseffekte in Radaraufnahmen

Quelle: ergänzt nach LILLESAND & KIEFER (2000)

Lengthening (Verlängerung) – Als Pendant zum Foreshortening können an Flächen, die der Antenne abgeneigt sind, aber gleichsam vom Radarstrahl erfasst werden, Verlängerungseffekte auftreten (VGL. ABB. 2-11). Dabei wird die Laufzeit verlängert und die dargestellte Strecke somit gegenüber der tatsächlichen Entfernung etwas in die Länge gezogen. Dementsprechend erscheint das betreffende Areal in der Radaraufnahme dunkler.

Ein besonderes Rückstrahlphänomen stellt die *Corner-Reflektion (double bounce)* dar. Diese tritt an benachbarten, orthogonal zueinander angeordneten Oberflächen auf, die spiegelnd reflektieren und unmittelbar zum Sensor hin ausgerichtet sind. Trifft ein Radarstrahl auf einen solchen *dibedralen* oder *tribedralen Corner-Reflektor* – d.h. dieser ist aus zwei bzw. drei Ebenen aufgebaut –, wird das eintreffende Signal nahezu vollständig zum Sensor hin zurückgeworfen. Dabei wird der gesamte Rückstreubeitrag in der Radaraufnahme auf ein Reflektionszentrum fokussiert, dessen Lage exakt den Fußpunkt der als Reflektor wirkenden Struktur definiert. Entsprechend erscheinen diese starken, lokal begrenzt-

ten Streuer in der Radaraufnahme als extrem helle Punkte oder Linien (VGL. ABB. 2-12). Corner-Reflektion tritt typischerweise an Gebäuden, Brücken, Geländern oder Masten auf und ist somit vor allem ein Charakteristikum besiedelter Areale.

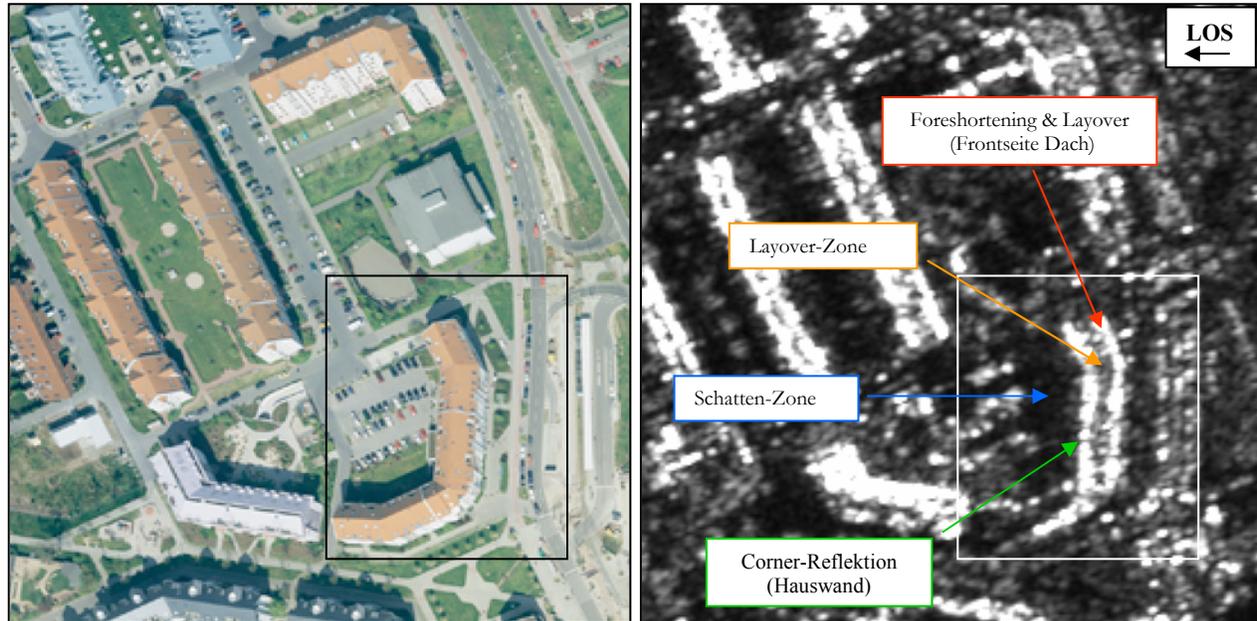


Abb. 2-12: Geometriebedingte Verzerrungs- und Abschattungseffekte am Beispiel eines Gebäudes

2.2.4 Rückstreuverhalten und Bildcharakteristik

SAR-Systeme verwenden kohärente, d.h. phasenkonstante Mikrowellenstrahlung als Medium zur Charakterisierung der erfassten Zielobjekte bzw. Geländeausschnitte. Als Informationsträger dient in diesem Zusammenhang das Radarsignal, dessen Amplitude, Phase und gegebenenfalls Polarisation wichtige Informationen über die Beschaffenheit und Lage der Streuer liefern. Die Amplitude und Polarisation des reflektierten Signals beschreiben dabei die (Streu-)Eigenschaften der erfassten Objekte, während mit Hilfe der Phasenlage des Radarechos die räumliche Verortung des Rückstreuers ermöglicht wird (VGL. KAP. 2.2.1).

Um die *Amplituden- und Phaseninformation des Radarsignals* möglichst umfassend nutzen zu können, werden SAR-Daten gewöhnlich in *komplexer Form* prozessiert und *abgespeichert*. Die vektorielle Darstellung des Rückstreubeitrags einer Auflösungszelle in der komplexen Ebene zeigt ABBILDUNG 2-13. Der Imaginärteil (I) des Radarechos wird von der y-Achse repräsentiert, während der Realteil des aufgezeichneten Signals auf der Abszisse abgetragen ist. Dabei bestimmt die *Länge des Streuvektors* die

Stärke (Amplitude) des empfangenen Radarechos, während dessen *Richtung* – definiert über den Winkel θ – die *Phasenlage* kennzeichnet.

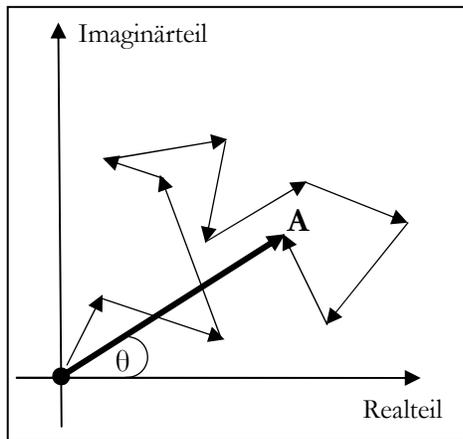


Abb. 2-13: Komplexer Streuvektor einer Auflösungszelle

Wie darüber hinaus hervorgeht, setzt sich die am Radarsensor aufgezeichnete Intensität eines Pixels prinzipiell aus den individuellen Reflektionsbeiträgen zahlreicher elementarer Punktstreuer zusammen. Dieses Phänomen liegt darin begründet, dass die Dimensionierung der Auflösungszelle gewöhnlich ein Vielfaches der verwendeten Wellenlänge einnimmt. So besteht der von einem Pixel abgedeckte Geländeausschnitt oftmals aus zahlreichen individuellen Strukturelementen, die jeweils als eigenständiges Streuzentrum wirken und deren Verteilung gemeinhin als stochastisch (*distributed scatterer*) angesehen wird. Demnach ist die vom Sensor

empfangene Energie letztlich als Summensignal aufzufassen, das sich über eine kohärente Addition der individuellen Streuvektoren innerhalb einer Auflösungszelle integrieren lässt. Im Falle eines *distributed scatterers* folgen die individuellen Streubeiträge dabei einer Gauß'schen Normalverteilung, wobei die Varianz der Einzelvektoren proportional zur Energie des aufgezeichneten Signals ist.

Die vom Receiver eines monostatischen SAR-Systems detektierte Energie des empfangenen Radarsignals wird durch die *Radargleichung* beschrieben. Sie kennzeichnet die Stärke des Radarechos als Funktion aus *emittierter Energie*, *Streuverhalten* und *Fläche* des erfassten Geländeausschnitts, *Antennencharakteristik*, *Frequenz* und *Entfernung* zwischen Antenne und Zielobjekt:

$$P_R = P_T (\sigma^0 A) \left(\frac{G^2 \lambda^2}{(4\pi)^3 R^4} \right) \quad (2.6)$$

mit: P_R = Empfangene Energie
 P_T = Gesendete Energie
 σ^0 = Rückstreuquerschnitt
 A = Beleuchtete Fläche

G = Antennengewinn
 λ = Wellenlänge
 R = Schrägdistanz Antenne - Zielobjekt

Von besonderer Bedeutung für die Radarfernerkundung ist der so genannte *Radarrückstreuquerschnitt* σ (*radar cross section; radar scattering coefficient*). Diese dimensionslose Kennzahl definiert die von einem Punktstreuer zum Sensor zurückgeworfene Energie und charakterisiert damit indirekt das Streuver-

halten des betrachteten Mediums. Da die Radarrückstreuung jedoch jeweils für eine Auflösungszelle (A) gemessen wird, gilt es, den Radarrückstreuquerschnitt über die entsprechende Fläche zu normieren. Daraus geht der *normalisierte Radarrückstreuquerschnitt* σ^0 hervor. Dieser ermöglicht den quantitativen Vergleich des Rückstreuverhaltens zwischen verschiedenen Auflösungszellen eines Radarbildes, aber auch die Gegenüberstellung von SAR-Aufnahmen unterschiedlicher Sensorsysteme oder divergierender Aufnahmezeitpunkte. Aufgrund seines hohen Dynamikbereichs wird der Radarrückstreu-koeffizient mit einem logarithmischen Maß in Dezibel [dB] angegeben und in der Regel mit einer radiometrischen Auflösung von 16-bit (65.536 Graustufen) aufgezeichnet und prozessiert.

Die *bildhafte Wiedergabe* der gemessenen Signalstärke des Radarechos erfolgt gewöhnlich in Form eines so genannten *Intensitätsbildes*. In einer solchen Aufnahme verhalten sich die Grauwerte *proportional zum Quadrat der Amplitude* des am Sensor empfangenen Radarsignals. Dabei ist die quantifizierte Energiemenge das direkte Resultat eines überaus komplexen Wirkungsgefüges zwischen den einzelnen system- und objektspezifischen Aufnahmeparametern. Bereits die Variation einer dieser Kenngrößen kann die Wechselwirkung zwischen Radarstrahlung und streuendem Medium – also den Streuprozess – signifikant modifizieren. Daher ist die Rückstreucharakteristik stets variabel, weshalb sich in der Radarfernerkundung kaum robuste Rückstreusignaturen für spezifische Objekttypen definieren lassen. Im Vergleich zur optischen Fernerkundung, bei der die spektrale Signatur aus vergleichsweise konstanten Molekularresonanzen an der Oberfläche der betrachteten Objekte resultiert, ist der Einsatz automatisierter Verfahren zur Bildauswertung daher mit höheren Unsicherheiten behaftet.

Wie in den vorherigen Kapiteln bereits erwähnt, unterliegt das vom Radarsystem emittierte Signal oftmals *geometrischen* und *radiometrischen Verzerrungen*. Die damit einhergehenden Modifikationen erschweren die Auswertung von Radaraufnahmen dabei mitunter signifikant. Daher werden der inhaltlichen Analyse in der Regel verschiedene *Korrektur-* und *Kalibrierungsverfahren* vorgeschaltet.

Die *radiometrische Kalibrierung* umfasst eine *relative* und *absolute Kalibrierung* der Bilddaten. Im Rahmen der *relativen Kalibrierung* werden die bekannten Variationen der Radarantenne oder weiterer systeminhärenter Parameter korrigiert, um reproduzierbare Messungen zu gewährleisten. Diese Korrektur ermöglicht letztlich den Vergleich zwischen den Rückstreuwerten der einzelnen Auflösungszellen eines Radarbildes. Um quantitative, vergleichende Messungen der Rückstreusignale verschiedener Aufnahmen zu gewährleisten, ist zudem eine *absolute Kalibrierung* erforderlich. Diese erlaubt es, die Stärke des empfangenen Signals direkt auf die von einer Auflösungszelle zurückgestreute Energiemenge umzurechnen. Dadurch gewährleistet sie letztlich die Bestimmung des *normalisierten Radarrück-*

streuquerschnitts σ^0 . Die absolute Kalibrierung von Radardaten kann unter anderem über eine Korrektur der aufgezeichneten Rohdaten mittels einer *Kalibrierungskonstanten* erfolgen, die während der Datenaufzeichnung aus der Rückstreuung zuvor vermessener Corner-Reflektoren ermittelt wird.

Ziel der *geometrischen Korrektur* sind die Beseitigung reliefbedingter, geometrischer Verzerrungen und die Georeferenzierung der Bilddaten. Sie erlaubt eine exakte Lagebestimmung jeder Auflösungszelle in Azimuth- und Range-Richtung und ermöglicht zugleich, die Bildgeometrie auf ein kartographisches Referenzkoordinatensystem abzubilden. Zudem wird gewährleistet, dass die einzelnen Bildobjekte im Hinblick auf ihre tatsächliche Form und Orientierung korrekt wiedergegeben werden.

Ein radarinhärentes Phänomen, das die radiometrische Auflösung von SAR-Aufnahmen bisweilen signifikant herabsetzt, ist der so genannte *Speckle-Effekt*. Diese feinkörnige Strukturierung in SAR-Daten tritt insbesondere in homogenen Bildbereichen nachhaltig in Erscheinung und überlagert die tatsächliche Textur eines Bildes mitunter als störendes, normal verteiltes Rauschen (VGL. ABB. 2-14). Speckle-Effekte sind charakteristisch für kohärente Abbildungsverfahren, die elektromagnetische Strahlung einsetzen, deren Wellenlänge geringer als die Sensorauflösung ist (KUAN ET AL., 1987). Die physikalische Ursache der kleinräumigen Grauwertevariationen liegt in *Interferenz-Erscheinungen*, deren Ursprung und Statistik von GOODMAN (1976) ausführlich beschrieben wird.

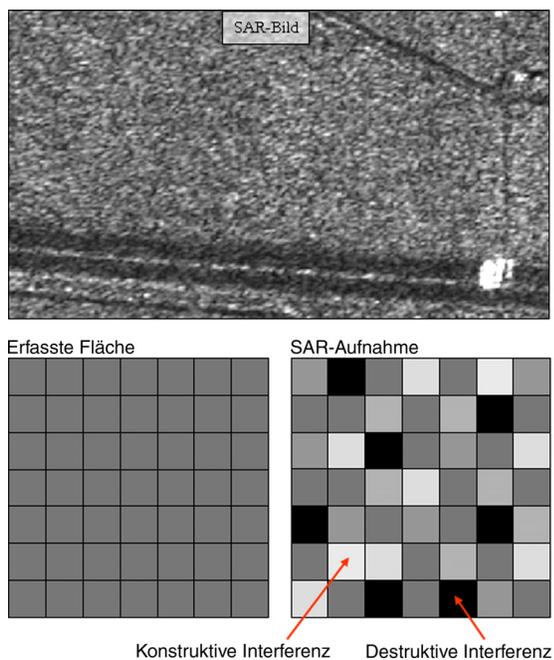


Abb. 2-14: Speckle-Effekt in SAR-Aufnahmen

Wie bereits im Zusammenhang mit den Erläuterungen zu ABBILDUNG 2-13 beschrieben, ergibt sich die Rückstreuung einer Auflösungszelle aus der Summe der Streubeiträge zahlreicher zufallsverteilter Elementarstreuer. Dabei wird das eintreffende Radarsignal von jedem einzelnen Punktstreuer mit einer leicht unterschiedlichen Phase zurückgeworfen. Diese variierenden Phasen der individuellen Streuvektoren überlagern sich mitunter konstruktiv oder destruktiv, so dass es in der Summe zu signifikanten Variationen zwischen den Rückstreubeiträgen der einzelnen Auflösungszellen kommen kann – selbst wenn diese eine identische Bedeckung und Strukturierung aufweisen. Dieser Effekt wird dadurch verstärkt, dass die

Anordnung und Ausrichtung der individuellen Streuer sowohl innerhalb einer Auflösungszelle als auch zwischen benachbarten Flächenelementen eines identischen Oberflächentyps naturgemäß differieren. Die Variation der Rückstreuwerte weist in einem Single-Look-Intensitätsbild eine negative exponentielle Verteilung auf, während sie in einer Multi-Look-Aufnahme eine Gamma-Distribution annimmt. Demgegenüber folgt das Rauschen eines Amplitudenbildes einer Rayleigh-Verteilung (GOODMAN, 1976; ULABY ET AL., 1986).

Um eine *Reduktion des störenden Speckles* und damit eine *Verbesserung der radiometrischen Auflösung* der SAR-Daten zu erzielen, werden verschiedene Verfahren zur Bildoptimierung eingesetzt. Den entsprechenden Ansätzen liegt in aller Regel eine *Modellierung des Speckle-Rauschens* zu Grunde. Hier wird meist von einem *multiplikativen Modell* oder einer *Gauss'schen* bzw. *Gamma-Verteilung* ausgegangen. Grundlegend kann in diesem Kontext zwischen der so genannten *Multi-Look-Prozessierung* und dem Einsatz von *Filtertechniken* unterschieden werden.

Multi-Look-Prozessierung – Im Rahmen der *Multi-Look-Prozessierung* wird die synthetische Antenne des SAR-Systems in mehrere Aperturen (*single-looks*) unterteilt. Jede Apertur erlaubt dabei einen unabhängigen Blick auf die Szene. Anschließend werden die Rückstreubeiträge der einzelnen Looks durch eine kohärente Summierung zusammengefasst, um auf diese Weise den Effekt des zufallsverteilten Bildrauschens zu kompensieren. Dabei bleibt das Signal-zu-Rausch-Verhältnis (*signal-to-noise-ratio*, SNR) erhalten. Der Betrag der Speckle-Reduzierung korreliert mit der Anzahl an Looks, d.h. je höher die Menge an unabhängigen Aperturen, desto größer der Effekt der Speckle-Glättung. Der Nachteil dieser Methode besteht darin, dass mit der Multi-Look-Prozessierung gleichsam eine räumliche Mittelung einhergeht, die einen direkten Verlust an geometrischer Auflösung darstellt, der proportional zur Anzahl der verwendeten Looks ist (VGL. GLEICHUNG 2.4).

Filterverfahren – Als Alternative zur Multi-Look-Prozessierung werden häufig Techniken der *fensterbasierten Filterung* eingesetzt, die im Anschluss an die Bildgenerierung auf die SAR-Aufnahme angewendet werden. Im Rahmen einer solchen Filterung wandert ein Fenster (*Moving-Window*) mit einer vordefinierten Größe und Form pixelweise über das gesamte Bild, wobei jeweils für das zentrale Bildelement ein korrigierter Intensitätswert auf der Basis einer mathematischen Operation berechnet wird. Die Reduktion des Speckle-Effektes wird demnach ebenfalls über eine räumliche Mittelung der Reflektionswerte erzielt. Die Stärke der Mittelung hängt dabei in aller Regel von der Größe des gewählten Filterfensters ab. Die Schwierigkeit bezüglich des Einsatzes solcher fensterbasierter Filtertechniken besteht darin, einen Algorithmus zu verwenden, der die unerwünschte Information des

Rauschens beseitigt, dabei aber gleichzeitig den räumlichen Detaillierungsgrad und damit die Bildschärfe erhält.

Da im Rahmen der vorliegenden Arbeit ein neuer Ansatz zur strukturerhaltenden Bildglättung entwickelt wurde, sollen im Folgenden die etablierten Filterverfahren etwas ausführlicher vorgestellt werden. Grundsätzlich zielen die bestehenden Techniken entweder auf eine Filterung in der *räumlichen Domäne* oder auf Basis der *Frequenz* ab. Die *Filterung in der Frequenzdomäne* beruht hauptsächlich auf Kriterien des *mittleren quadratischen Fehlers (MMSE)* oder umfasst so genannte *Wavelet-Ansätze* (LI, 1988; GAGNON & JOUAN, 1997; FUKUDA & HIROSAWA, 1998; DONG ET AL., 1998; SIMARD ET AL., 1998). Im Rahmen der Fernerkundung finden jedoch insbesondere Verfahren zur *adaptiven, räumlich basierten Reduktion* des Speckle-Effektes Verwendung (WALESSA & DATCU, 2000; PALER ET AL., 1999). Zu den etabliertesten und von zahlreichen Bildverarbeitungsprogrammen bereitgestellten Algorithmen zählen der *Lee*-, *Frost*-, *Lee-Sigma*- sowie *Gamma-MAP*-Filter.

Der *Lee-Filter* basiert auf einem multiplikativen Modell, das von einer Gauß'schen Verteilung des Rauschens ausgeht, wobei die Filterwirkung über die lokale Statistik (Mittelwert, Varianz) der Grauwerte angepasst wird (LEE, 1981). Sehr ähnlich arbeitet der *Frost-Algorithmus*, der ebenfalls von einem multiplikativen Modell und Gauß'scher Verteilung ausgehend die lokale Statistik der Bilddaten berücksichtigt (FROST ET AL., 1982). Zur Reduktion des Rauschens wird dabei die gewichtete Summe der Werte innerhalb des Filterfensters berechnet, wobei sich die Gewichtung der einzelnen Elemente mit zunehmender Entfernung vom zentralen Pixel reduziert, während die Gewichtung des zentralen Bildelements von der lokalen Varianz abhängt. Auf der Basis einer Gauß'schen Verteilung des Speckles geht der *Lee-Sigma-Filter* vereinfachend davon aus, dass verrauschte Pixel nur innerhalb einer bestimmten, über die Standardabweichung zu definierenden Wertespanne liegen (LEE, 1983). Demnach werden lediglich jene Pixel des Filterfensters in die Mittelung einbezogen, die innerhalb der ausgewiesenen Wertespanne liegen. Der von LOPES ET AL. (1990) auf der Basis des Maximum-A-Posteriori-Filter von KUAN ET AL. (1987) entwickelte *Gamma-Maximum-A-Posteriori-Filter (Gamma-MAP)* geht von einer Gamma-Verteilung der Grauwerte aus und nutzt den lokalen Mittelwert sowie die Varianz zur Steuerung der Filterwirkung. Dabei basiert dieser Algorithmus auf der Annahme, dass der tatsächliche Wert des zentralen Pixels zwischen dem gemessenen Grauwert und dem Mittelwert aller Bildelemente innerhalb des Fensters liegt. Darüber hinaus wurden zahlreiche weitere Filter entwickelt bzw. die vorhanden Algorithmen weiter modifiziert. Eine zusammenfassende Beschreibung geben XIAO ET AL. (2003).

Kapitel 3

Arbeitsbasis

Das folgende Kapitel legt die wichtigsten Informationen hinsichtlich der raum-, daten- und softwarebezogenen Grundlagen dieser Dissertation dar. In diesem Kontext werden zu Beginn das Untersuchungsgebiet sowie die darin definierten Testareale skizziert. Der anschließende Abschnitt widmet sich den zu Grunde liegenden Fernerkundungsdaten sowie den im Kontext der Evaluierung verwendeten Referenzinformationen. Das Kapitel endet schließlich mit der Beschreibung aller Software-Pakete, die im Rahmen dieser Arbeit Verwendung finden. Dabei liegt der Schwerpunkt auf der Beschreibung der objektorientierten Bildanalysesoftware eCognition, auf der die gesamte Methodik zur automatisierten Auswertung der Bildinhalte basiert.

3.1 Untersuchungsgebiet

Um die Möglichkeiten eines intensiven Erfahrungs-, Informations- und Datenaustauschs mit Akteuren der räumlichen Planung zu nutzen, setzt die vorliegende Dissertation auf einer mehrjährigen Kooperation zwischen dem Deutschen Fernerkundungsdatenzentrum (DLR-DFD) und dem Raumordnungsverband (ROV) Rhein-Neckar auf. Darüber hinaus konnten Kontakte zu den Stadtverwaltungen Ludwigshafen und Mannheim genutzt werden. Der ROV nimmt grenzüberschreitend zwischen den Ländern Baden-Württemberg, Rheinland-Pfalz und Hessen die Aufgaben der Raumordnung, Regionalplanung und Regionalentwicklung wahr. Damit deckt sich der räumliche Wirkungsbereich größtenteils mit der siedlungsstrukturellen Verdichtungsregion des Rhein-Neckar-Raumes – einer Region, die eine Fläche von rund 3324km² einnimmt (FISCHER, 2000).

Vor diesem Hintergrund liegt der *geografische Fokus* der Arbeit auf dem Kerngebiet und der Umgebung der Städte *Ludwigshafen* und *Mannheim* (VGL. ABB. 3-1). Dieser Bereich bildet das Zentrum der

Rhein-Neckar-Region, die sich im nördlichen Teil der schwach reliefierten Oberrheinischen Tiefebene befindet. Kennzeichnend für dieses Gebiet ist eine hohe *Dynamik der raumwirksamen Veränderungen*. Diese ergibt sich aus dem Charakteristikum, dass in der Region verschiedenste Siedlungstypen, traditionelle Industrielandschaften und agrarwirtschaftlich intensiv genutzte Gebiete auf engstem Raum ineinander übergehen. Von besonderer Bedeutung ist dabei die *polyzentrische Struktur* dieser Region mit den Oberzentren Ludwigshafen, Mannheim und Heidelberg sowie rund 30 weiteren Mittelzentren (FISCHER, 2000). Neben einer *günstigen geopolitischen Lage* im vereinten Europa weist der Rhein-Neckar-Raum darüber hinaus weitere *regionale Standortvorteile* auf, die in den letzten Jahren dazu geführt haben, dass sich die Region überproportional entwickelt hat. Heute stellt das Rhein-Neckar Gebiet mit rund 2,4 Mio. Einwohnern den *siebtgrößten Wirtschaftsraum Deutschlands* dar und nimmt im Hinblick auf die Entwicklungsdynamik eine besondere Stellung ein. Mit Blick auf diese Standortpotentiale wurde der Region Rhein-Neckar im April 2005 von der Ministerkonferenz für Raumordnung (MKRO) der Status einer *Metropolregion* verliehen.

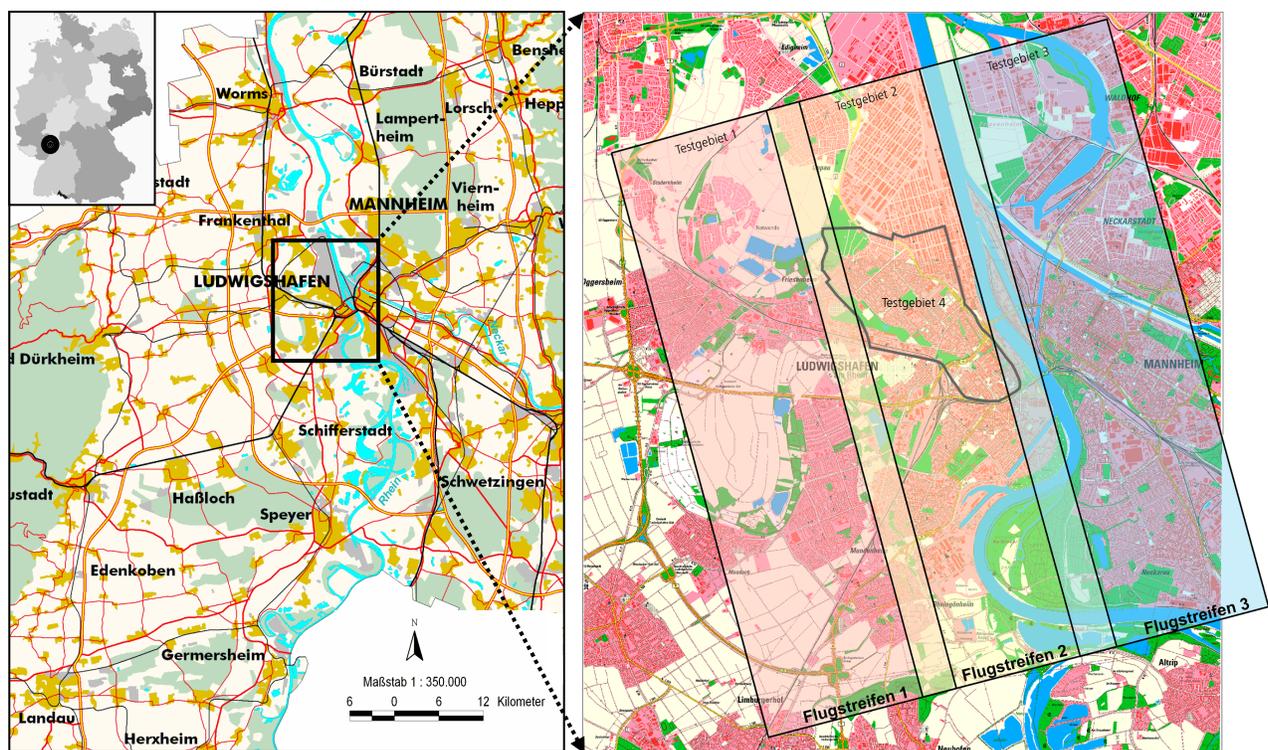


Abb. 3-1: Region Rhein-Neckar und Lage der Testgebiete

Im Hinblick auf die Definition geeigneter *Testgebiete* für die fernerkundungsbasierten Analysen ist ausschlaggebend, dass die ausgewiesenen Areale die Fläche der Städte *Ludwigshafen* und *Mannheim* abdecken und dabei gleichsam eine *hohe Bandbreite unterschiedlicher Siedlungsstrukturen* einschließen. Zum

anderen sind gleich mehrere Untersuchungsflächen auszuweisen, um die Übertragbarkeit der entwickelten Algorithmen und Regelwerke testen zu können. Dabei müssen diese in ihrer räumlichen Lage und Ausdehnung so beschaffen sein, dass sie eine *mehrfache Befliegung* durch das E-SAR-System unter den vorgesehenen Aufnahmemodi gewährleisten.

Auf der Basis dieser Voraussetzungen wurden schließlich *drei Flugstreifen* definiert, die gleichsam als Testgebiete fungieren (VGL. ABB. 3-1). Sie weisen eine flächenhafte Ausdehnung von jeweils 3x10 Kilometern auf und überlappen sich seitlich um je 300 Meter. Im Rahmen der Arbeiten zur Ableitung der urbanen Landnutzung dient darüber hinaus ein Ausschnitt des zweiten Aufnahmestreifens (Testgebiet 4) als Untersuchungsraum (VGL. ABB. 3-1). Die Definition dieser Testfläche liegt darin begründet, dass detaillierte Zusatz- und Referenzdaten, die zur Durchführung und Evaluation jener Auswertung erforderlich sind, nur für ein begrenztes Areal im Raum Ludwigshafen vorlagen (VGL. KAP. 3.2 und KAP. 4.3).

3.2 Datengrundlage

Die bedeutendsten Datengrundlagen im Hinblick auf diese Dissertation stellen die höchstauflösenden Radaraufnahmen des flugzeuggetragenen *Experimental Synthetic Aperture Radars (E-SAR)* dar (HORN, 1996). Die technischen Merkmale dieses am Institut für Hochfrequenztechnik des DLR entwickelten Systems sind in TABELLE 3-1 zusammengefasst. Aufgrund der flexiblen Auslegung des E-SAR lassen sich mit Hilfe dieser Plattform die Daten gegenwärtiger oder zukünftiger SAR-Systeme simulieren. An dieser Stelle sei darauf hingewiesen, dass der Einfallswinkel in den Aufnahmen des E-SAR aufgrund der vergleichsweise niedrigen Flughöhe von rund 3000 Metern innerhalb eines Aufnahmestreifens zwischen Werten von 20 Grad in Near Range und 60 Grad in Far Range variiert. Demgegenüber ist diese Spanne im Kontext reeller Satellitendaten auf einen wesentlich engeren Bereich begrenzt.

Die im Rahmen dieser Arbeit ausgewerteten E-SAR Daten wurden im Zuge einer Befliegungskampagne am 08.05.2003 im Raum Ludwigshafen/Mannheim aufgezeichnet. Auf der Basis der definierten Flugstreifen bzw. Testflächen ließ die systemtechnische Spezifikation des E-SAR-Sensors dabei eine maximale Anzahl von 12 Überflügen bzw. Datenaufzeichnungen zu. Die Aufnahmemodi für diese Überflüge wurden so gewählt, dass die Daten möglichst vielseitige Synergien zu den Aufnahmen zukünftiger und gegenwärtiger SAR-Satelliten zulassen. Gleichzeitig musste gewährleistet werden, dass bifrequente Ansätze und der Einfluss unterschiedlicher Polarisation getestet werden kön-

nen. Die wichtigsten Eckdaten zu dieser Befliegung bzw. den dabei aufgezeichneten Daten sind in TABELLE 3-2 aufgeführt.

Tab. 3-1: Technische Merkmale des E-SAR Systems

Systemparameter	X-Band	C-Band	S-Band	L-Band	P-Band
Frequenz [GHz]	9.6	5.3	3.3	1.3	0.45
Sendeleistung [W]	2500	50	2000	360	180
Azimuth-Öffnungswinkel [Grad]	17	19	20	18	30
Range-Öffnungswinkel [Grad]	30	33	35	35	~60
Polarisation	HH + VV	HH + VV	HH + VV	HH + VV HV + VH	HH + VV HV + VH

Quelle: HORN, 1996

Die Prozessierung der E-SAR Rohdaten erfolgte am Institut für Hochfrequenztechnik (HF) des DLR und umfasste

- eine Transformation der aufgezeichneten Rohdaten in ein rechnerkompatibles Format.
- die SAR-Prozessierung.
- die Kompensation von Bewegungsfehlern des Trägersystems (Motion-Compensation).
- die radiometrische Kalibrierung zur Korrektur des Antennendiagrammes in Abhängigkeit der Schrägentfernung sowie zur Ermittlung der sensorspezifischen Kalibrationskonstanten.
- die Ko-Registrierung, Georeferenzierung und Transformation der Daten in Ground-Range-Geometrie.
- die Multi-Looking-Prozessierung (4 Looks) zur Speckle-Reduktion.

Nach dieser Prozessierung liegen die Daten als 16-bit Intensitätsaufnahmen in Slant-Range- sowie Ground-Range-Geometrie vor. Die Intensitäten entsprechen dabei den quadrierten Amplituden des empfangenen Signals. Auf weitere Korrekturen – etwa zur Berechnung des normalisierten Rückstreuoeffizienten – wurde im Rahmen dieser Arbeit bewusst verzichtet, um einen Ansatz entwickeln zu können, der weitestgehend unabhängig von den spezifischen Rückstreuwerten der einzelnen Pixel arbeitet und sich möglichst neutral gegenüber geometrie- bzw. systembedingten Variationen der Rückstreuung verhält.

Bevor die E-SAR Aufnahmen zur Segmentierung und Auswertung herangezogen werden, müssen sie im Rahmen einer Postprozessierung weiter aufbereitet werden. So erfolgt eine Skalierung der 16-bit Intensitätsdaten auf ein 8-bit Format, um den enormen Dynamikbereich der Grauwerte zu reduzie-

ren und damit eine homogenere Bildsegmentierung zu ermöglichen. Ebenfalls zur verbesserten Segmentierbarkeit werden die konvertierten Bilddaten anschließend einer filterbasierten Speckle-Reduzierung unterzogen. Zu diesem Zweck wird ein im Rahmen dieser Arbeit neu entwickeltes Filterverfahren eingesetzt, das in KAPITEL 4.1.1 ausführlich vorgestellt wird.

Tab. 3-2: Aufnahmeparameter der Befliegung im Raum Ludwigshafen/Mannheim

Überflug	Streifen	Blickrichtung [Grad]	Band	Polarisation	Auflösung ^{*1} [m]	Einfallswinkel ^{*2} [Grad]
1	2	75	X	HH	2 x 1.8	20 - 60
2	3	255	X	HH	2 x 1.8	20 - 60
3	1	75	X	HH	2 x 1.8	20 - 60
4	3	75	X	HH	2 x 1.8	20 - 60
5	2	75	L	HH, VV, HV, VH	2 x 3	20 - 60
6	3	255	L	HH, VV, HV, VH	2 x 3	20 - 60
7	1	75	L	HH, VV, HV, VH	2 x 3	20 - 60
8	3	75	L	HH, VV, HV, VH	2 x 3	20 - 60
9	2	75	C	HH, HV	2 x 2	20 - 60
10	3	255	C	HH, HV	2 x 2	20 - 60
11	1	75	C	HH, HV	2 x 2	20 - 60
12	3	75	C	HH, HV	2 x 2	20 - 60

*1: Range x Azimuth

*2: Near Range – Far Range

Wie bereits im Rahmen der Zielsetzung dieser Arbeit erwähnt, soll speziell mit Blick auf das künftigen RapidEye-System geklärt werden, in welchem Umfang der komplementäre Informationsgehalt *mittelaufgelöster optischer Daten* die Auswertung radarbasierter Aufnahmen unterstützen kann. Um dieser Fragestellung nachzugehen, findet im Zuge dieser Dissertation neben den hochaufgelösten Radardaten des E-SAR Sensors auch eine optische Aufnahme des indischen *Indian Remote Sensing Satellite (IRS)* Verwendung. Dieser Satellit erfasst mit einer Aufnahme eine Fläche von bis zu 140 x 140 Kilometern in einer maximalen Bodenauflösung von 5,8 Metern im panchromatischen Kanal (PAN) und 23,7 Metern bzw. 70 Metern in den Kanälen des LISS-III Sensors (VGL. TAB. 3-3).

Der verwendete Datensatz wurde am 30.07.2001 aufgezeichnet. Bei dieser als so genanntes *pansharp-Produkt* gelieferten Aufnahme ist die begrenzte räumliche Auflösung der LISS-III Bänder Grün, Rot und NIR vom Datenprovider über eine Fusion mit dem wesentlich höher aufgelösten panchromatischen Kanal des PAN-Sensors (*resolution merge*) künstlich auf 5,8 Meter erhöht worden (VGL. KAP. 1.2). Die räumliche Abdeckung der Szene beträgt rund 70 x 70 Kilometer.

Tab. 3-3: Technische Daten des IRS-1D Satelliten

Technische Parameter	PAN	LISS-III
Spektrale Auflösung [μm]	0.5 - 0.75	0.52 - 0.59 (grün)
		0.62 - 0.68 (rot)
		0.77 - 0.86 (NIR)
		1.55 - 1.7 (SWIR)
Geometrische Auflösung [m]	5.8	23.7
Breite des Aufnahmestreifens [km]	65 - 80	127 - 141
Repetitionsrate [Tage]	24	24

Quelle: NRSA, 2005

Im Kontext der Analyse der lokalen Siedlungsstruktur werden darüber hinaus *Straßen-Vektordaten* des *Amtlichen Topografisch-Kartografischen Informationssystem* (ATKIS) in die Auswertung integriert (VGL. KAP. 4.3). ATKIS stellt eine digitale Topografische Datenbasis zur Ergänzung der analogen Landeskartenwerke dar und wird regelmäßig zur Anbindung und Verknüpfung geo-thematischer Zusatzinformationen genutzt. ATKIS-Daten werden von den Landesvermessungsämtern auf der Grundlage der DGK5, TK10, TK25, Orthofotos und Daten des Topografischen Informationsdienstes erhoben, wobei die Aktualisierungshäufigkeit zwischen fünf Jahren bei Objekttypen mit so genannter Grundaktualität und drei bis zwölf Monaten bei der Spitzenaktualität (z. B. Verkehrswege) liegt. Die Lagegenauigkeit beläuft sich auf rund drei Meter. Die ATKIS-Vektoren liegen ausschließlich für das Gebiet der Stadt Ludwigshafen vor. Die letzte Fortschreibung der Geometrie dieses Datensatzes erfolgte im Jahre 1997.

Ebenfalls im Zusammenhang mit der Erfassung der lokalen Stadtstruktur werden für vergleichende Studien *digitale RGB-Luftbilder* eingesetzt. Die entsprechenden Aufnahmen wurden im Jahre 1998 im Auftrag der Stadt Ludwigshafen aufgenommen und stehen somit ausschließlich für das Gemeindegebiet Ludwigshafens zur Verfügung. Zum Zwecke der automatisierten Auswertung wurden die ursprünglich in einer Bodenauflösung von 25 Zentimetern vorliegenden Bilder auf eine Auflösung von 1 Meter reduziert, was dem Auflösungsvermögen der neuesten optischen Satelliten (z.B. IKONOS) entspricht. Die Daten liegen nicht orthoentzerrt vor.

Als *Referenzdaten* zur Definition der Testgebiete, Erstellung der Regelwerke und Validierung der Ergebnisse finden schließlich verschiedenste Datenquellen Verwendung. Diese sind in TABELLE 3-4 aufgelistet.

Abschließend sei erwähnt, dass sämtliche im Rahmen der Bildauswertung eingesetzten Daten mit Hilfe eines Geografischen Informationssystem auf die Geometrie der definierten Testflächen zu-

recht geschnitten wurden. Gleiches gilt für jene Referenzdaten, die im Rahmen der Evaluierung der thematischen Genauigkeiten Verwendung finden.

Tab. 3-4: Referenzdaten

Datentyp	Abdeckung (Trainingsgebiete)	Auflösung / Maßstab	Erstellung
SW-Luftbilder ^{*1}	Kerngebiet der Städte Ludwigshafen und Mannheim (Teilbereiche von T1-T4)	10cm	05/2003
RGB-Luftbilder ^{*2}	Gemeindegebiet der Stadt Ludwigshafen (T1,T2, T4)	25cm	1998
ATKIS-Vektordaten ^{*3}	Gemeindegebiet der Stadt Ludwigshafen (T1,T2, T4)	maßstabslos; 3m Lagegenauigkeit	1991-1995
Biotoptypen-Vektordaten	Gemeindegebiet der Stadt Ludwigshafen (T1,T2, T4)	maßstabslos; 3m Lagegenauigkeit	1990
RGB-Luftbildmosaik ^{*2}	Stadtgebiet Mannheim (T3)	1m	1999
Digitale Topografische Karten	Gesamtes Untersuchungsgebiet (T1-T4)	1:25.000	2002

*1: Schwarz-Weiß-Luftbilder

*2: Rot-Grün-Blau-Farbaufnahme

*3: Amtliches Topografisch-Kartografisches Informationssystem

3.3 Bildverarbeitungssoftware

Die Methodik zur automatisierten Ableitung siedlungsstruktureller Informationen basiert auf der objektorientierten Software *eCognition 3.2*. Somit stellt dieses Bildanalyseverfahren das zentrale Werkzeug der vorliegenden Arbeit dar. Demgegenüber fanden weitere Programme zur digitalen Bildverarbeitung ausschließlich im Kontext der Vor- oder Weiterverarbeitung der Datenbasis Verwendung. So erfolgte die Programmierung des Algorithmus zur strukturerhaltenden Bildglättung und damit auch die Filterung der verwendeten Aufnahmen unter *IDL 6.1* (VGL. KAP. 4.1.1), während zur Berechnung von Texturdatensätzen die Software *ERDAS Imagine 8.6* eingesetzt wurde (VGL. KAP. 4.2). Neben der Definition und Extraktion der Testgebiete erfolgten die Aufbereitung der thematischen Vektorinformationen (VGL. KAP. 4.3), die 3D-Darstellung der extrahierten Siedlungsstrukturen (VGL. KAP.4.3) sowie die kartografische Aufbereitung der Ergebnisse mit Hilfe des Programms *ArcGIS 9.0*.

Aufgrund der exponierten Stellung der *Bildanalysesoftware eCognition* im Kontext dieser Dissertation sind grundlegende Kenntnisse über den methodischen Ansatz und die Funktionalität dieses Verfahrens von zentraler Bedeutung für das Verständnis der durchgeführten Arbeiten. Daher soll diese Software im Folgenden eingehender vorgestellt werden.

Die Bildauswertung unter *eCognition* beruht auf einem *Fractal-Net-Evolution-Konzept*, das über eine *segmentbasierte multiskalige Bildanalyse* das kognitive, *objektorientierte Interpretationsverhalten* eines Menschen

abstrahiert nachbildet (BAATZ & SCHÄPE, 2000; BLASCHKE & STROBL, 2001). Im Gegensatz zu pixelbasierten Techniken wendet sich dieses Verfahren damit von der isolierten Betrachtung der einzelnen Bildelemente ab und setzt verstärkt auf die *Analyse räumlicher Strukturen und Zusammenhänge*. Diese Eigenschaft bietet gerade im Hinblick auf die Auswertung hochaufgelöster Erdbeobachtungsdaten entscheidende Vorteile. Aufgrund des enormen Detaillierungsgrades solcher höchstauflösenden Aufnahmen setzen sich die abgebildeten Objekte verstärkt aus einer ganzen Gruppe von Pixeln mit mehr oder minder homogenen Eigenschaften zusammen (VGL. ABB. 3-2). Folglich lassen sich die abgebildeten Strukturen – und damit der Informationsgehalt der Aufnahme – nur schwerlich über eine rein pixelbasierte Betrachtung der Bildinhalte erschließen. Vielmehr gilt es, zur Beschreibung und Interpretation der erfassten Raumeinheiten die spektralen, strukturellen und formbezogenen Charakteristika auf der Basis der aussagekräftigeren Pixelgruppen abzuleiten (VGL. ABB. 3-2).

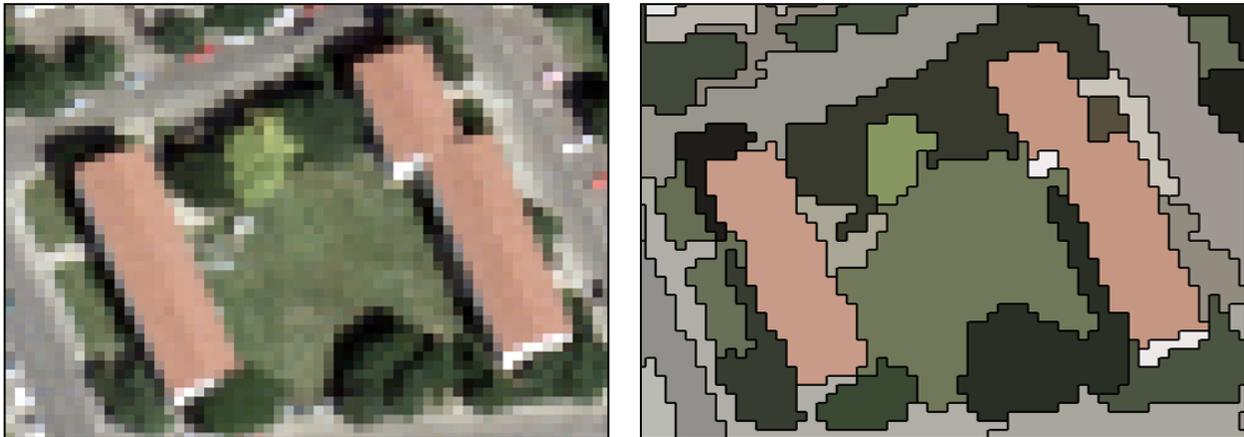


Abb. 3-2: Pixelbasierte (l.) und objektorientierte (r.) Repräsentation urbaner Strukturen – Die objektorientierte Bildanalyse bietet gerade im Kontext hochaufgelöster Aufnahmen eine deutlich erweiterte Funktionalität hinsichtlich der Auswertung form-, kontext- und hierarchiebezogener Merkmale, da die Analyse gegenüber dem pixelbasierten Ansatz auf bedeutend aussagekräftigeren räumlichen Grundeinheiten beruht.

Vor diesem Hintergrund läuft die *Bildauswertung* unter eCognition in *drei Schritten* ab: Zu Beginn werden die Pixel über eine *Segmentierung* zu sinnvollen Objekten gruppiert. Anschließend wird auf der Basis der Eigenschaften dieser neu generierten, nunmehr akkurateren Raumeinheiten ein *Regelwerk definiert*, über das letztlich in einem dritten Schritt die eigentliche *Klassifizierung* der Bildinhalte erfolgt.

Schritt 1: Bildsegmentierung – Die Bildsegmentierung wird über einen Region-Growing-Algorithmus umgesetzt, der die einzelnen Bildprimitive auf der Basis eines heuristischen Optimierungsalgorithmus zu homogenen Objekten zusammenfasst (BAATZ & SCHÄPE, 2000). Im Rahmen dieser *Multiresolution Segmentation* lässt sich eine beliebige Anzahl unterschiedlich skaliert Segmentierungen durchführen.

Dadurch können mehrere Segmentierungsebenen mit variierenden Objektgrößen und -eigenschaften über- oder untereinander angelegt werden (VGL. ABB. 3-3). Um letztlich den Aufbau eines *hierarchischen Netzwerks von Bildobjekten* zu ermöglichen, müssen die Objekte einer neu generierten Segmentierungsebene dabei stets die Geometrie bereits zuvor generierter Objektlevel berücksichtigen. Dadurch können für jedes Segment neben den spektralen, strukturellen oder formbezogenen Informationen auch die entsprechenden Eigenschaften der Nachbar-, Ober- und Unterobjekte abgerufen werden (VGL. ABB. 3-3). Diese Funktionalität ist speziell im Hinblick auf die Auswertung komplexer Sachverhalte von entscheidender Bedeutung.

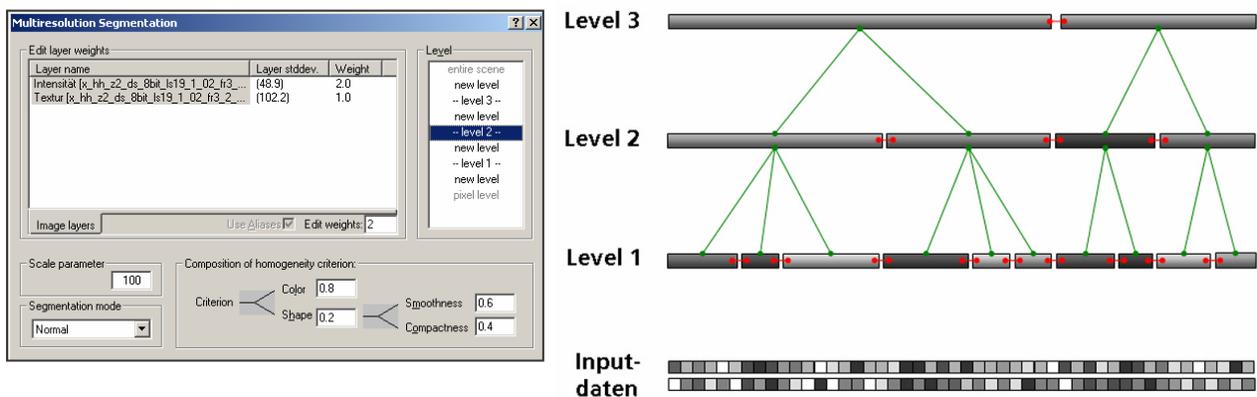


Abb. 3-3: Menü zur Steuerung der Multiresolution Segmentation (l.) und schematische Darstellung einer drei Ebenen umfassenden Bildsegmentierung (r.)

Die *Steuerung der Objekteigenschaften* im Rahmen der Segmentierung kann mit Hilfe farb- und formbezogener *Heterogenitätskriterien*, eines *Scale Parameters* sowie der *Gewichtung* der Eingangsdaten erfolgen (VGL. ABB. 3-3). Die zulässige *Farbheterogenität (Color)* wird über die Summe der Standardabweichungen in den jeweiligen Eingangsdatensätzen (c) bestimmt,

$$h = \sum_c w_c \cdot \sigma_c \quad (3.1)$$

mit: h = zulässige Heterogenität
 w_c = Gewichtung
 σ_c = Standardabweichung

während die *Formheterogenität* über die Kriterien *Smoothness* (Randrauigkeit) und *Compactness* (Kompaktheit) definiert werden kann:

$$h_{smooth} = \frac{l}{b} \quad (3.2)$$

mit: b = Zulässige Heterogenität
 l = Länge der tatsächlichen Umrandungslinie
 b = Kürzestmögliche Umrandungslinie (*bounding box*)

sowie

$$h_{compact} = \frac{l}{\sqrt{n}} \quad (3.3)$$

mit: b = Zulässige Heterogenität
 l = Länge der Umrandungslinie
 n = Anzahl der Pixel des Objekts

Während diese Heterogenitätskriterien im Wesentlichen das räumliche Erscheinungsbild der Segmente beeinflussen, erfolgt die eigentliche Steuerung der Objektgröße über den *Scale Parameter*. Dieser definiert die maximal zulässige Veränderung der Heterogenität, die im Zuge der Fusion zweier Objekte auftreten darf. Zu diesem Zweck wird der eingegebene Scale Parameter quadriert und mit einem so genannten *Fusionswert* verglichen, der sich aus der spektralen und formbezogenen Heterogenität der zu vereinigenden Bildsegmente errechnet. Damit stellt der Scale Parameter das Abbruchkriterium des Segmentierungsprozesses dar.

Letztlich lässt sich das Segmentierungsergebnis noch über die *Anzahl und Gewichtung* der Bilddaten und/oder thematischen Geoinformationen (z.B. Vektordatensätze) verändern (VGL. ABB. 3-3).

Schritt 2: Definition des Regelwerks – Sobald die geeignete Anzahl und Parametrisierung der einzelnen Segmentierungslevel gefunden ist, kann mit der Konzeption eines Regelwerks zur Klassifikation der Bildinhalte begonnen werden. Zentrales Element zur Erstellung dieser Wissensbasis ist die *Class Hierarchy*, innerhalb derer die zu extrahierenden Bildinhalte mittels adäquater Klassen abgebildet werden (VGL. ABB. 3-4). Zur Organisation des Regelwerks werden drei Ebenen bereitgestellt: die *Inheritance* (Vererbung), die *Groups* (Gruppen) und die *Structures* (Struktur).

Im Kontext der *Inheritance* werden die zu identifizierenden Klassen definiert und über eine individuelle Merkmalsbeschreibung charakterisiert (VGL. ABB. 3-5). Das Regelwerk ist dabei aus einem Set *objekt-* oder *klassenbezogener Attribute* aufgebaut, das vom Nutzer aus einem umfassenden Merkmalskatalog zusammengestellt wird (VGL. ABB. 3-5). Dieser Katalog umfasst zum einen so genannte *Object Features*.

Diese kennzeichnen die spektralen, strukturellen, thematischen und form- sowie hierarchiebezogenen Eigenschaften der Bildsegmente. Darüber hinaus werden diese Deskriptoren durch eine Vielzahl klassenbezogener Objektmerkmale – den *Class-related Features* – ergänzt. Diese stehen allerdings erst zur Verfügung, sobald eine Klassifikation vollzogen wurde.

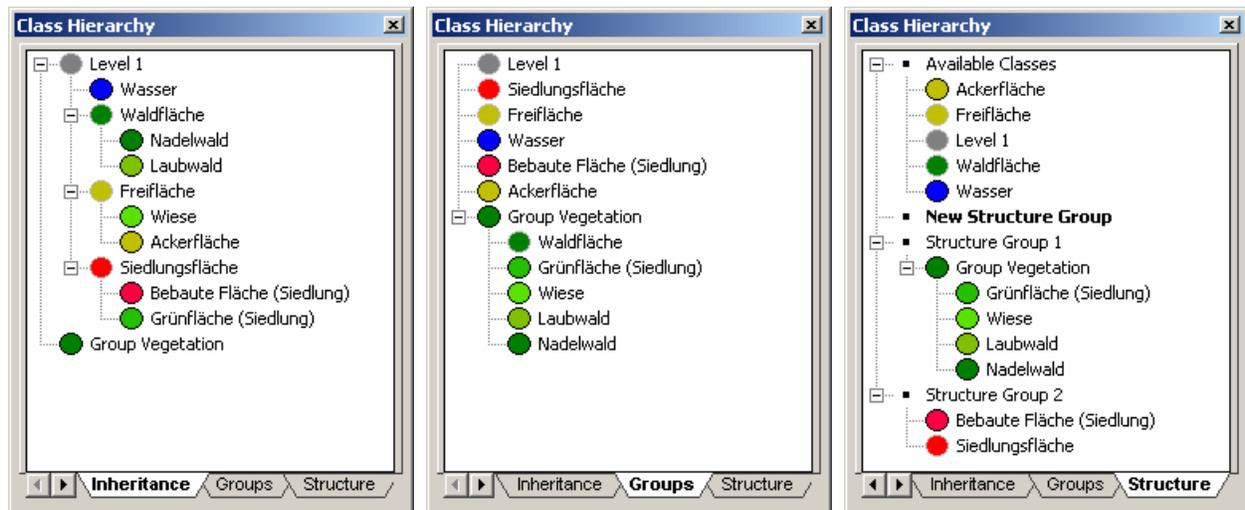


Abb. 3-4: Aufbau und Ebenen der Class Hierarchy – Unter der Inheritance werden die zu klassifizierenden Kategorien definiert, die sich wiederum unter den Groups zu semantischen Gruppen zusammenfassen lassen. Eine Gruppierung unter der Structure-Ebene definiert Klassen, die im Rahmen einer klassenbasierten Segmentoptimierung umfassend berücksichtigt werden.

Im Kontext der *Inheritance* werden die zu identifizierenden Klassen definiert und über eine individuelle Merkmalsbeschreibung charakterisiert (VGL. ABB. 3-5). Das Regelwerk ist dabei aus einem *Set objekt- oder klassenbezogener Attribute* aufgebaut, das vom Nutzer aus einem umfassenden Merkmalskatalog zusammengestellt wird (VGL. ABB. 3-5). Dieser Katalog umfasst zum einen so genannte *Object Features*. Diese kennzeichnen die spektralen, strukturellen, thematischen und form- sowie hierarchiebezogenen Eigenschaften der Bildsegmente. Darüber hinaus werden diese Deskriptoren durch eine Vielzahl klassenbezogener Objektmerkmale – den *Class-related Features* – ergänzt. Diese stehen allerdings erst zur Verfügung, sobald eine Klassifikation vollzogen wurde.

In der Kategorie *Groups* lassen sich anschließend die zuvor in der Inheritance definierten Klassen zu semantischen Gruppen zusammenstellen, was zur Erschließung neuer semantischer Informationsebenen und zur Erleichterung der Klassifikation beiträgt. So könnten beispielsweise die Klassen *Waldfläche*, *Grünfläche (Siedlung)*, *Wiese*, *Laubwald* und *Nadelwald* in der semantischen Gruppe *Vegetation* zusammengefasst werden (VGL. ABB. 3-4).

Die dritte Rubrik *Structure* dient vornehmlich zur Auswahl und Zusammenstellung von Klassen, deren Objekte in ihrer Geometrie modifiziert werden sollen (*Classification-based Segmentation*). Diese Option umfasst die klassenbasierte Fusion verschiedener Segmente (*Classification-based Fusion*), die Optimierung der Grenzen von Objekten auf der Basis klassifizierter Subobjekte (*Border-Optimization*) und die Extraktion von Bildobjekten zweier unterschiedlicher Ebenen (*Extraktion of Image Objects*).

Die *Definition des spezifischen Wertebereichs* für die ausgewählten Merkmale zur Kennzeichnung der definierten Klassen basiert auf dem Prinzip der *Fuzzy-Logic*. Im Gegensatz zu den Zuweisungsalgorithmen der etablierten, pixelbasierten Ansätze erfolgt die Definition der Klassenzugehörigkeit dabei nicht nach einem strikt binären Muster – d.h. der Wert nimmt entweder Eins oder Null an –, sondern wird über eine Zuweisungsfunktion (*Membership Function*) als Wahrscheinlichkeit ausgedrückt (VGL. ABB. 3-5). Diese kann Werte zwischen Null (keine Zugehörigkeit) und Eins (volle Zugehörigkeit) annehmen. Sowohl der Verlauf als auch der Wertebereich dieser merkmalsbezogenen Zugehörigkeitsfunktionen lassen sich über eine manuelle Auswahl oder mittels einer Berechnung auf der Basis von Trainingsgebieten definieren. Im Kontext der Merkmalsdefinition bietet ein solcher Fuzzy-Ansatz den Vorteil, dass alle Attribute unabhängig von der Dimensionierung der zu Grunde liegenden Daten normiert werden, so dass sie sich direkt miteinander verknüpfen lassen.

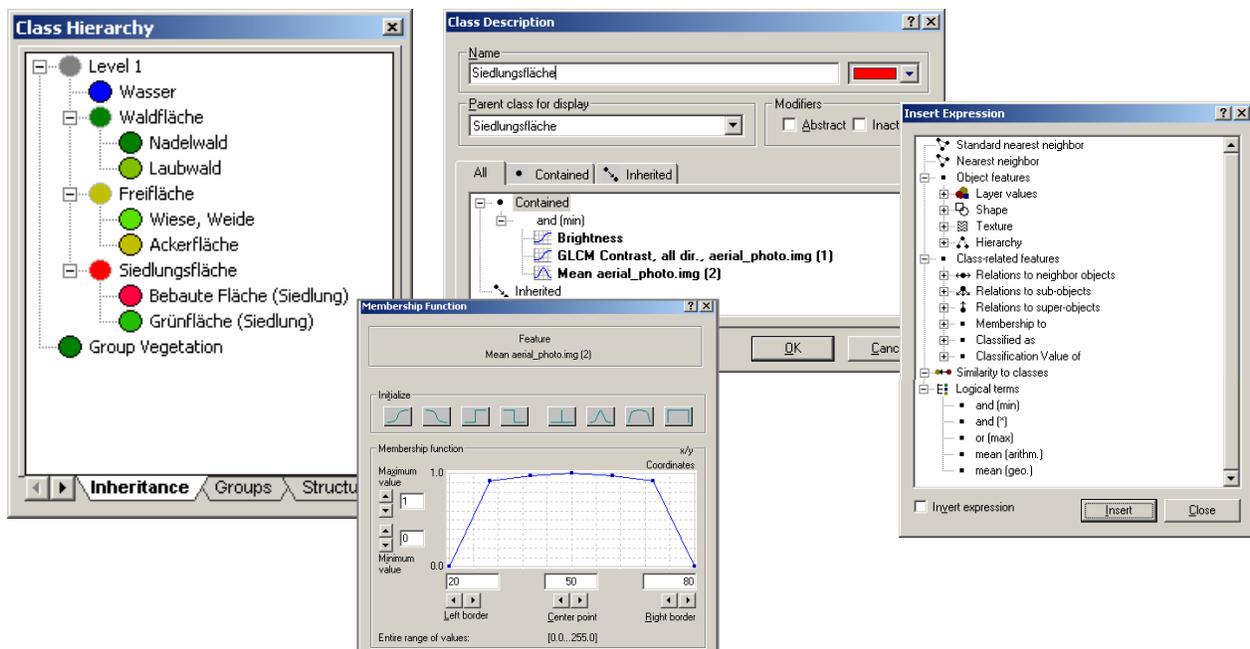


Abb. 3-5: Definition von Klassen und deren Merkmalsbeschreibung in der Class Hierarchy – Unter der Inheritance werden die gewünschten Klassen angelegt, denen wiederum mittels des Insert-Expression-Menüs in der Class Description Merkmale zur Klassenkennzeichnung zugeordnet werden. Dabei lassen sich der Wertebereich und die Zuweisungsfunktion jedes Attributs über das Membership-Funktion-Menü definieren.

Um die Flexibilität und damit die Effizienz im Aufbau des Regelwerks zu steigern, können die einzelnen merkmalsgebundenen Zugehörigkeitsfunktionen letztlich über verschiedene logische Operatoren (*and [min], and [*], or [max], mean [arithm], mean [arithm]*) beliebig miteinander kombiniert werden.

Neben der Möglichkeit zur Nutzung individuell definierter Zuweisungsfunktionen bietet eCognition auch die Möglichkeit, die Klassen direkt über entsprechende Trainingsgebiete (*Samples*) zu charakterisieren. Art und Umfang der Merkmale – und damit die Charakteristik der zur Klassifizierung genutzten Merkmalsräume – lassen sich frei wählen. Eine solche Definition des Regelwerks entspricht letztlich einem Nearest-Neighbour-Ansatz.

Schritt 3: Bildklassifizierung - Im Anschluss an die Implementierung des Regelwerks findet die eigentliche Klassifizierung der Bilddaten statt. Dazu wird für jedes einzelne Objekt auf der Basis der zuvor definierten, klassenspezifischen Merkmale und Zuweisungsfunktionen die Wahrscheinlichkeit der Zugehörigkeit zu einer der vorgegebenen Klassen berechnet. Dabei kann ein Segment durchaus hohe Zugehörigkeitswahrscheinlichkeiten zu mehreren Kategorien aufweisen. Damit bietet dieser Ansatz für den Nutzer den großen Vorteil, dass mit dem Klassifikationsergebnis auch direkt ein Qualitätsmaß hinsichtlich der Sicherheit einer Klassenzuweisung bereitgestellt wird und sich darüber hinaus die Wahrscheinlichkeit einer alternativen Zuordnung einsehen lässt. Da für viele Anwendungen jedoch letztlich eine diskrete Zuordnung erforderlich ist, können die Objekte schließlich der Klasse mit dem höchsten Zuweisungswert zugewiesen (*Defuzzification*) werden.

Zur Automatisierung der gesamten Bildauswertung von der Segmentierung bis zur fertigen Klassifizierung bietet die Software eCognition eine *Protokollfunktion*, mittels derer sämtliche Arbeitsschritte und Einstellungen gespeichert und später selbstständig auf der Basis einer neuen Datenbasis abgearbeitet werden können.

Kapitel 4

Methodenentwicklung

Wie im vorherigen Kapitel dargelegt, stützt sich die Methodik zur automatisierten Auswertung der Bildinhalte auf die objektorientierte Bildanalysesoftware eCognition. Im Kontext eines solchen Ansatzes hat die Güte der Segmentierung entscheidenden Einfluss auf die Effizienz und Qualität der Klassifikation. Vor diesem Hintergrund befasst sich ein erster Schwerpunkt der im Folgenden beschriebenen Methodenentwicklung mit der *Optimierung und Stabilisierung einer objektorientierten Auswertung von SAR-Aufnahmen* über verbesserte Ansätze zur Glättung und Segmentierung der Bilddaten.

Demgegenüber widmen sich die beiden anschließenden Kapitel der *Erstellung von Konzepten und Regelwerken zur Ableitung siedlungsbezogener Informationen aus SAR-Daten*. Diesbezüglich liegen einerseits die *Identifizierung von Siedlungsflächen* und *regionale Ableitung der Landnutzung* sowie andererseits die weiterführende *Erfassung der lokalen Siedlungsstruktur* im Fokus der Entwicklungen. Dabei steht im Kontext der *Identifizierung von Siedlungsflächen* neben der detaillierten Erörterung der entwickelten Segmentierungs- und Klassifizierungskonzepte vor allem der *Vergleich unterschiedlicher Datengrundlagen* im Vordergrund. Im Zusammenhang mit der *Erfassung der lokalen Siedlungsstruktur* soll hingegen ein *synergetischer Klassifikationsansatz* evaluiert werden, der auf einer kombinierten Auswertung hochauflösender SAR-Aufnahmen (E-SAR X-Band) und mittelaufgelöster optischer Daten (IRS-1D) aufsetzt.

Im Anschluss an die drei thematischen Schwerpunkte findet sich jeweils ein zusammenfassendes Kapitel, das noch einmal die wichtigsten Aspekte der zuvor erörterten Thematik komprimiert darlegt.

4.1 Optimierung der objektorientierten Bildauswertung

Im Zusammenhang mit der Optimierung der objektorientierten Analyse von Radaraufnahmen wird zu Beginn ein *neuer Algorithmus zur strukturerhaltenden Bildglättung* – der SelectiveMean-Filter – konzipiert und mit bereits etablierten Verfahren verglichen. Darüber hinaus liegt ein weiterer Fokus auf der Entwicklung eines *Ansatzes zur klassenbasierten Segmentoptimierung*. Dieser soll die Güte der generierten Objekte verbessern, gleichsam die Robustheit der Segmentierung erhöhen und dabei die Ermittlung der optimalen Segmentierungsparameter erleichtern.

4.1.1 Entwicklung des SelectiveMean-Filters

4.1.1.1 Anforderungen

Wie ABBILDUNG 4-1 zeigt, wird die tatsächliche Textur eines SAR-Bildes aufgrund des systembedingten Speckle-Effekts von einem störenden Rauschen überlagert. Dies hat zur Folge, dass selbst in homogenen Bildbereichen Grauwertvarianzen auftreten, die denen im Kontext einer tatsächlich vorhandenen Struktur sehr nahe kommen. Mit Blick auf eine objektorientierte Auswertung der Bildinhalte wirkt sich dieses Phänomen in zweifacher Hinsicht negativ aus.

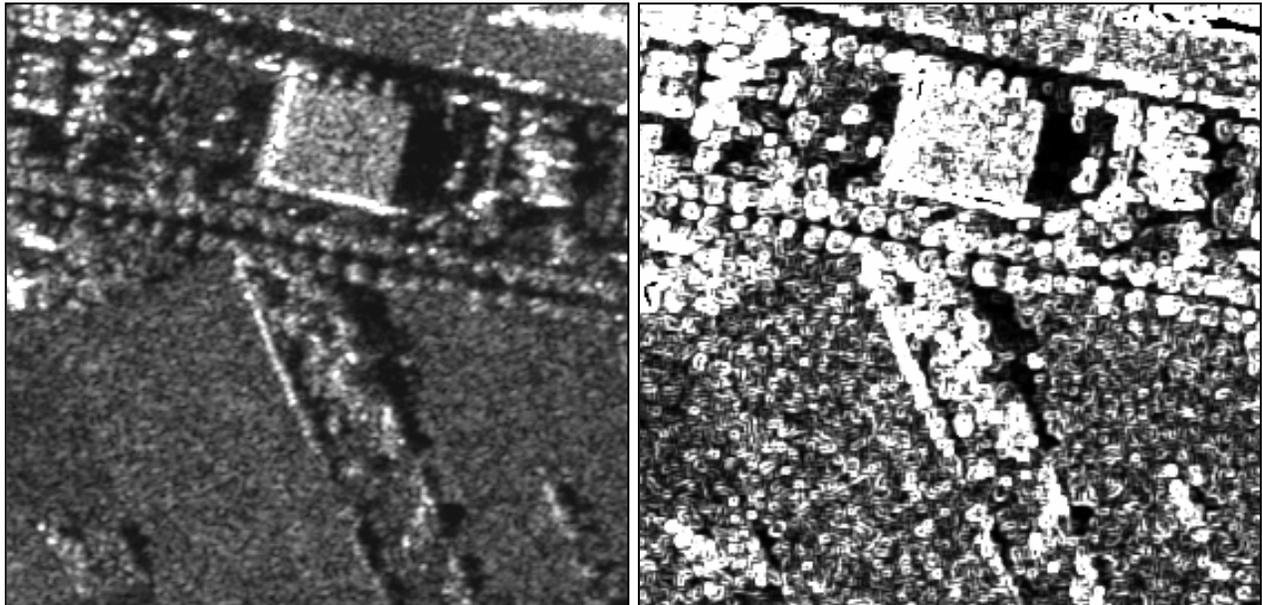


Abb. 4-1: X-Band Intensitätsbild (l.) und daraus abgeleitete Varianz 5x5 (r.) – Aufgrund des SAR-Speckle weisen selbst äußerst schwach strukturierte Bildareale (z.B. Freiflächen) mitunter signifikante Texturen auf, die eine Erfassung der tatsächlichen Strukturen im zugehörigen Texturbild deutlich erschweren.

Zum einen beruht der unter eCognition implementierte Segmentierungsalgorithmus auf der Analyse *farb- und formbezogener Heterogenitätskriterien*. Durch die mit dem Speckle-Effekt einhergehende lokale Varianz der Grauwerte wird folglich die korrekte Identifizierung und Abgrenzung der reellen Raumstrukturen erschwert. Darüber hinaus neigt der Algorithmus verstärkt zur Generierung zerklüfteter Bildsegmente (VGL. KAP. 4.1.1.3). Dieser Effekt kann zwar über eine geringere Gewichtung des grauwertbezogenen Heterogenitätskriteriums (*Color*) minimiert werden, allerdings geht mit diesem Vorgehen gleichsam eine verschlechterte Differenzierung der einzelnen Struktureinheiten einher.

Neben diesem direkten Effekt hat der SAR-Speckle jedoch auch indirekt Nachteile im Hinblick auf die Bildanalyse, indem das Bildrauschen die Berechnung aussagekräftiger Texturmaße erschwert (VGL. ABB. 4-1). Dabei belegen zahlreiche Veröffentlichungen, dass gerade strukturbezogene Merkmale überaus robuste und aussagekräftige Attribute zur Bildauswertung bereitstellen (VGL. KAP. 1.2). Gleichsam haben Tests im Rahmen dieser Arbeit gezeigt, dass die Integration eines Texturlayers in die Bildsegmentierung zu einer verbesserten Abgrenzung der Strukturen im SAR-Bild beitragen kann.

Vor diesem Hintergrund ist die Reduktion des SAR-Speckle von entscheidender Bedeutung für eine effiziente Klassifizierung und Segmentierung von Radaraufnahmen. Wie in KAPITEL 2.2.4 dargelegt, werden zu diesem Zweck vornehmlich fensterbasierte Filteransätze verwendet. Im Kontext der vorliegenden Arbeit sind daher zunächst die etablierten Algorithmen des *Lee*-, *Frost*-, *Lee-Sigma*- sowie *Gamma-MAP-Filters* getestet worden. Dabei konnten die besten Resultate mittels des *Lee-Sigma*- bzw. des *Frost-Filters* erzielt werden. Ein Blick auf ABBILDUNG 4-2 belegt, dass die specklebedingte Heterogenität der Grauwerte über eine solche Bildglättung sichtlich reduziert und somit die Berechnung von Texturen deutlich verbessert werden kann. Dennoch zeigt sich bei genauerem Hinsehen, dass bei der Speckle-Reduzierung stets ein Kompromiss zwischen maximaler Glättung in homogenen Arealen und Erhaltung der hochfrequenten Informationen in stark strukturierten Bildarealen eingegangen werden muss (VGL. ABB. 4-2).

Im Falle des *Frost-Filters* erlaubt die Berücksichtigung der lokalen Statistik prinzipiell eine selektive Steuerung der Bildglättung (VGL. KAP. 2.2.4). Allerdings besteht die Schwierigkeit darin, die entsprechenden Einstellungen so zu wählen, dass die Übergänge zwischen texturbedingt stark bzw. schwach gefilterten Arealen nicht zu abrupt sind, woraus letztlich ein sehr künstliches Erscheinungsbild resultiert. Diesbezüglich hat sich gezeigt, dass ein harmonisches Zusammenspiel zwischen Glättung in homogenen Arealen und Kanten- bzw. Texturerhaltung in stark strukturierten Bildbereichen nur begrenzt realisierbar ist. Folglich lässt sich die rauschinduzierte Variation der Rückstreuung im Be-

reich der homogenen Freiflächen nicht vollständig beseitigen, ohne andererseits die hochfrequenten Bildbereiche über Gebühr zu glätten (VGL. ABB. 4-2).

Mit dem *Lee-Sigma-Filter* lassen sich sehr ansprechende Resultate erzielen, die im Vergleich zum Frost-Algorithmus bei deutlicher Glättung in homogenen Arealen ein merklich detailschärferes Erscheinungsbild bewahren (VGL. ABB. 4-2). Im Gegensatz zum Frost-Ansatz glättet der Lee-Sigma-Filter allerdings das gesamte Bild unabhängig von der lokalen Textur (VGL. KAP. 2.2.4). Zudem hat sich gezeigt, dass speziell die dunklen Speckle-Pixel nicht umfassend beseitigt werden können, ohne dabei die hochfrequente Information in stark strukturierten Bildarealen zu vehement zu glätten. Folglich rufen die dunklen Speckle-Bereiche in der gefilterten Aufnahme gerade auf homogenen Freiflächen ein fleckiges Erscheinungsbild hervor, wodurch vor allem die Strukturierung bzw. Musterung der Freiflächen einseitig geprägt wird.

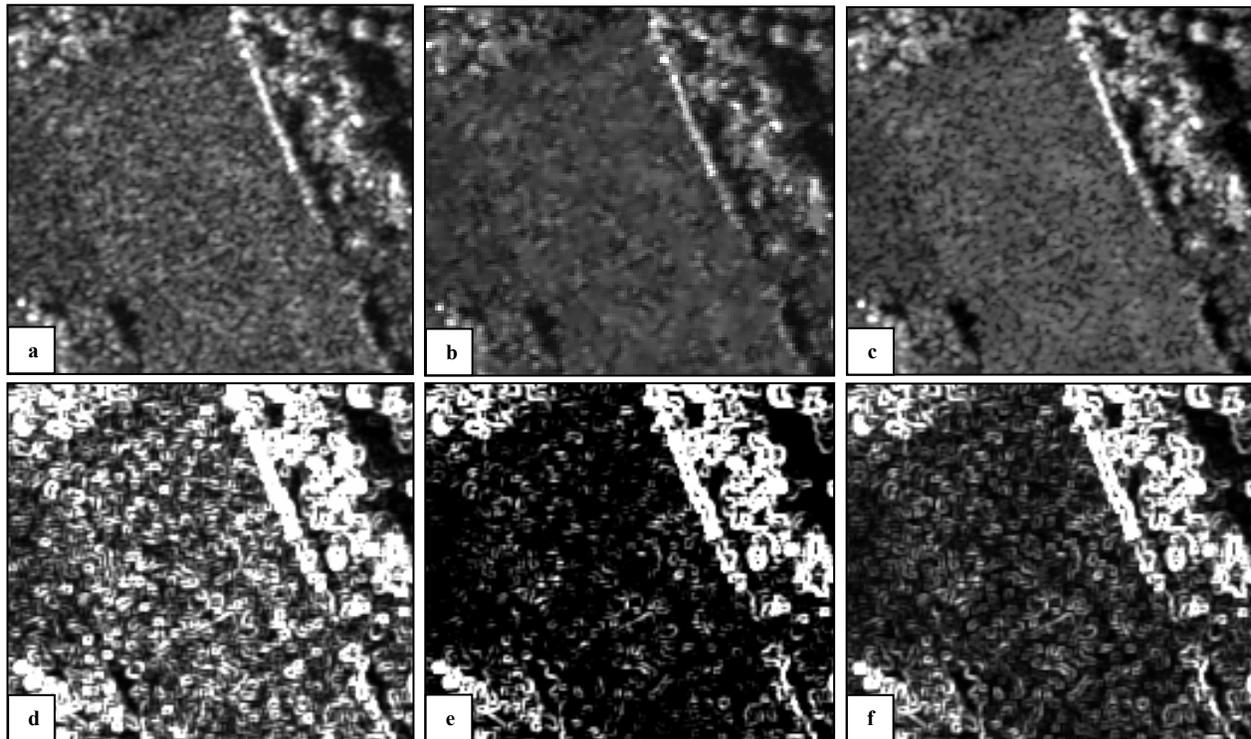


Abb. 4-2: Bildglättung einer X-Band Aufnahme (a) mittels Frost- (b) und Lee-Sigma-Algorithmus (c) sowie Ableitung der entsprechenden Varianzen (d,e,f)

Mit Blick auf die zuvor beschriebenen Limitierungen der etablierten Ansätze besteht also weiterhin Optimierungsbedarf in Bezug auf eine effektive, strukturehaltende Reduzierung des Speckle in SAR-Aufnahmen. Aus diesem Grunde wird im Folgenden ein neuer Filteralgorithmus vorgestellt, der die Qualität der Bildglättung gegenüber den bisher verfügbaren Ansätzen verbessert.

4.1.1.2 Funktionsweise

Der im Rahmen dieser Dissertation entwickelte *SelectiveMean-Filter* ist grundlegend als *adaptives Moving-Window-Verfahren* ausgelegt. Zentrales Element dieses Ansatzes ist die räumlich flexible *Anpassung der Filterung* an die *lokale Textur* der zu glättenden Bildbereiche. Diese strukturabhängige Modellierung der Filterwirkung soll gewährleisten, dass hochfrequente Informationen erhalten bleiben, während gering strukturierte Areale umfassend homogenisiert werden. Von entscheidender Bedeutung ist dabei eine flexible Steuerung der Filterwirkung, bei der ein möglichst homogener Übergang zwischen Bereichen starker Bildglättung und Arealen geringer Modifizierung gewährleistet wird. Die *Quantifizierung des lokalen Strukturierungsgrades* erfolgt über ein einfach und schnell zu berechnendes Texturmaß – wahlweise den *Coefficient of Variation* oder die *Varianz*:

$$C_v = \frac{\sigma_n}{\mu_n} \quad (4.1)$$

mit: C_v = Coefficient of Variation

σ_n = Standardabweichung

μ_n = Mittelwert

$$\sigma_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \langle x \rangle)^2 \quad (4.2)$$

mit: σ_n^2 = Varianz

n = Anzahl der Messwerte

x = Messwert

$\langle x \rangle$ = Mittelwert

Zur Filterung wird das definierte Texturmaß intern über eine Umgebung von 3x3 Pixeln berechnet, um anschließend auf der Basis einer Filterbox - deren Größe vom Nutzer definiert werden kann - gemittelt zu werden. Die Berechnung der lokalen Textur in einem 3x3 Fenster dient zur Extraktion signifikanter Kanten. Über die Mittelung dieses Kantenbildes wird folglich ein Maß für die Kantendichte - und damit den Strukturierungsgrad - generiert. Dieser ist naturgemäß in heterogenen Bildarealen besonders hoch, während er in homogenen Bereichen niedrige Werte annimmt (VGL. ABB. 4-3).

Die *Variation der Filterwirkung* wird über einen speziellen Algorithmus zur *selektiven Mittelwert-Glättung* realisiert. Dieser berücksichtigt während des Filterungsprozesses nur jene Pixel des Filterfensters, deren Grauwerte innerhalb einer spezifischen *Wertespanne* liegen. Zur Kalkulation der am jeweiligen Bildpunkt anzusetzenden Spanne wird dessen Grauwert mit einem zu definierenden *Toleranz-Faktor* multipliziert. Das Resultat liefert die maximal zulässige Abweichung vom Wert des zentralen Bildelements und definiert damit gleichsam die zur Filterung zulässigen Pixel innerhalb der Filter-Kernel.

Die *Koppelung* zwischen *lokaler Textur* und *anzusetzender Grauwertespanne* erfolgt über eine lineare Funktion, deren Eigenschaften von Schwellwerten für die gemittelte Textur und den Toleranz-Faktor

bestimmt werden (VGL. ABB. 4-4). Liegt die Textur unterhalb eines definierten Wertes ($minTex$), wird dieser Bereich als homogen strukturiert angesehen und daher zur Berechnung der gültigen Grauwertespanne ein *maximaler Toleranz-Faktor* ($maxTol$) angesetzt. Umgekehrt kann eine maximale Norm ($maxTex$) vorgegeben werden, oberhalb derer das betreffende Areal als stark untergliedert angesehen wird und der Einfluss der Filterung daher minimiert werden soll. Hier erfolgt die Multiplikation zur Definition der gültigen Wertespanne folglich mittels eines *minimalen Toleranz-Faktors* ($minTol$). In dem Bereich zwischen $minNorm$ und $maxNorm$ bzw. $minTol$ und $maxTol$ werden die jeweils anzusetzenden Toleranzen über eine *lineare Funktion* bestimmt (VGL. ABB. 4-4).

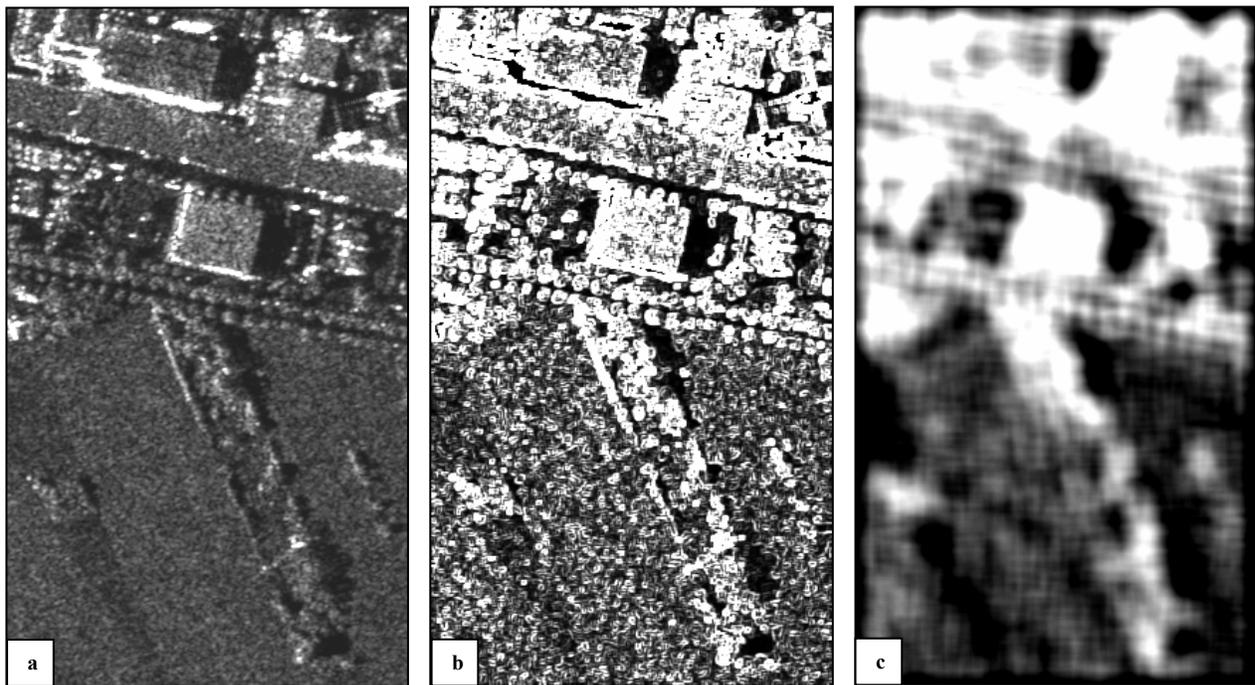


Abb. 4-3: Intensitätsbild (a), lokale Varianz zur Kennzeichnung signifikanter Kanten (b) sowie gemittelte lokale Varianz zur Charakterisierung der Kantendichte (c) – Der Algorithmus ist so ausgelegt, dass die Filterung stets dort abgeschwächt wird, wo eine hohe Kantendichte auf die Existenz tatsächlicher Strukturen hindeutet.

Auf dieser Basis wird gewährleistet, dass in stark strukturierten Bereichen nur solche Pixel in die Filterung einbezogen werden, deren Reflektionen dem Grauwert des zu filternden Bildpunktes stark ähneln. Dies kommt einer Minimierung der Filterwirkung und damit der Bildglättung gleich. Demgegenüber ist in homogen gestalteten Arealen die Spanne der zur Mittelung herangezogenen Werte deutlich erweitert und die Bildinhalte werden vergleichsweise stark modifiziert. Gleichzeitig bleibt durch die Vorgabe der maximalen Toleranz auch an diesen Stellen gewährleistet, dass die Grenzen zwischen spektral unterschiedlichen, in sich jedoch homogenen Arealen erhalten bleiben. Gleiches gilt für punktförmige, lokal sehr begrenzte Strukturen in einer niederfrequenten Umgebung.

Eine zusätzliche Funktion erlaubt darüber hinaus die Definition eines *Toleranz-Off-Sets*, der als absoluter Wert auf die berechnete Toleranz addiert wird (VGL. ANHANG B). Dadurch lässt sich insbesondere in dunklen Bildbereichen – d.h. Flächen mit vergleichbar geringer Rückstreuung – die Filterwirkung verstärken, während der Einfluss dieses Parameters in Zonen starker Reflektion minimal ist. Auf diese Weise kann vermieden werden, dass die Filterwirkung in sehr dunklen Bildarealen selbst bei hohen Toleranzfaktoren de facto vernachlässigbar bleibt. So werden unter einem Toleranzfaktor von 0.2 für einen Grauwert von 10 DN lediglich Werte zwischen 8 DN und 12 DN ($10 \pm 10 \cdot 0.2$) berücksichtigt, d.h. die Filterwirkung ist minimal. Für einen DN-Wert von 200 wäre eine Spanne zwischen 160 DN und 240 DN ($200 \pm 200 \cdot 0.2$) zulässig, was eine vergleichsweise starke Modifizierung der Grauwerte zur Folge hat. Wird der Toleranzfaktor von 0.2 mit einem Toleranz-Offset von 10 DN kombiniert, erweitert sich die zulässige Grauwertspanne für 10 DN auf Werte zwischen -2 und 22 ($10 \pm [10 \cdot 0.2 + 10]$). Der Toleranzbereich für ein Pixel mit dem Wert 200 beträgt 250 DN bis 150 DN ($200 \pm [200 \cdot 0.2 + 10]$). Somit wird der Toleranzbereich in den dunklen Bildbereichen deutlich aufgeweitet, während der Off-Set in hellen Arealen kaum ins Gewicht fällt.

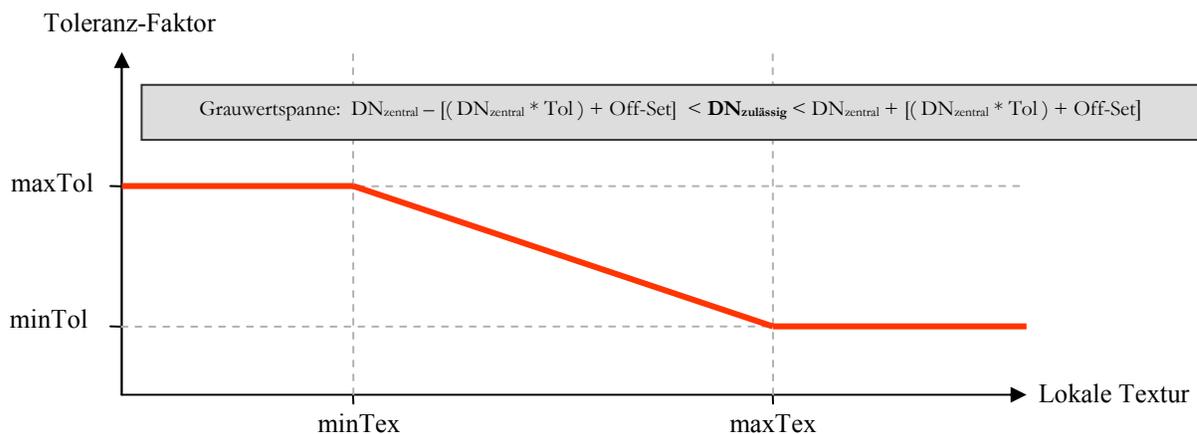


Abb. 4-4: Texturabhängige Anpassung der Filterstärke – Bis zu einem definierten Schwellwert für die Kantendichte (*minTex*) gilt ein Bildareal als unstrukturiert, so dass dort die maximale Toleranz (*maxTol*) - d.h. Filterwirkung - angesetzt wird. Demgegenüber definiert der Schwellwert *maxTex* jene Textur, ab der die Toleranz auf einen Minimalwert reduziert werden soll (*minTol*). Die Anpassung der Filterung zwischen *minTex* und *maxTex* erfolgt über eine lineare Funktion.

Der SelectiveMean-Filter bietet ferner die Option, überdurchschnittlich ausgeprägte, punktuelle Variationen in der Rückstreuung gezielt zu nivellieren. Dies ist speziell im Zusammenhang mit der Beseitigung stark ausgeprägter Speckle-Pixel von Nutzen. Dazu wird ein Minimum-Kriterium eingesetzt, welches vorgibt, wie viel Bildelemente mindestens in die Filterung eingehen müssen. Unterschreitet die Menge der Pixel, die auf der Basis der regulären Grauwertspanne gefunden werden, die gewählte *Mindestanzahl*, so wird der maximale Toleranz-Faktor für diesen Bildpunkt iterativ um einen definierten Betrag erhöht. Somit steigen die zulässige Toleranz und folglich auch die Filterwirkung

lokal an. Diese Erhöhung wird so lange fortgesetzt, bis entweder die Mindestanzahl gültiger Bildpunkte (*minCount*) oder aber ein maximal zulässiger Wert für die Zunahme der lokalen Toleranz (*maxDeltaTol*) erreicht ist. Letzteres verhindert, dass signifikante Punktstreuer eliminiert werden. Hinsichtlich der erforderlichen Mindestanzahl kann für homogene Bildbereiche ($\text{Textur} < \text{minTex}$) bzw. heterogene Areale ($\text{Textur} > \text{minTex}$) bei Bedarf ein separater Wert eingestellt werden (VGL. ANHANG B).

4.1.1.3 Bewertung

Die visuelle Begutachtung der geglätteten E-SAR-Daten zeigt, dass mit Hilfe der SelectiveMean-Filterung in den homogenen Bereichen der Aufnahmen eine signifikante Reduktion des Bildrauschens erzielt werden kann (VGL. ABB. 4-5). Gleichzeitig bleibt der Detaillierungsgrad im Umfeld stark strukturierter Bildareale weitestgehend erhalten. Von besonderer Bedeutung ist in diesem Zusammenhang, dass die im Kontext der Filterung mit etablierten Algorithmen auftretenden Artefakte kaum in Erscheinung treten (VGL. ABB. 4-6).



Abb. 4-5: Ergebnis der Filterung mittels des neu entwickelten SelectiveMean-Algorithmus – In Bereich der gering strukturierten Bildareale wird der SAR-Speckle durch die Maximierung der Filterung nahezu vollständig beseitigt, wobei die Detailinformation im Kontext hochstrukturierter Aufnahmebereiche weiterhin erhalten bleibt.

Um die Filterwirkung der etablierten Ansätze mit den Eigenschaften des neu entwickelten Verfahrens vergleichen zu können, werden im Folgenden die *Reduktion des Rauschens*, die *Bewahrung der Textur*

und die *Erhaltung der Kanteninformation* statistisch quantifiziert. Die Bewertung erfolgt auf der Basis eines Vorher-Nachher-Vergleichs zwischen zweckmäßigen Kenngrößen, die jeweils für die ursprüngliche SAR-Aufnahme und die geglättete Median-, Frost-, Lee-Sigma- und SelectiveMean-Variante berechnet werden. Zur Kennzeichnung des *Bildrauschens* wird der *Coefficient of Variation* auf der Grundlage von 20 Testflächen (25 x 25 Pixel) in *homogenen Bildarealen* verglichen. Demgegenüber basiert die Beurteilung der *texturerhaltenden Wirkung* auf einer Quantifizierung der Varianz in 20 *hochstrukturierten Bildbereichen* (25 x 25 Pixel). Um die *Modifizierung der Kanteninformation* zu erfassen, werden schließlich die lokalen Gradienten an 20 repräsentativen Grenzlinien erhoben. Das Resultat dieses quantitativen Vergleichs der Filtereigenschaften ist in ABBILDUNG 4-7 grafisch wiedergegeben.

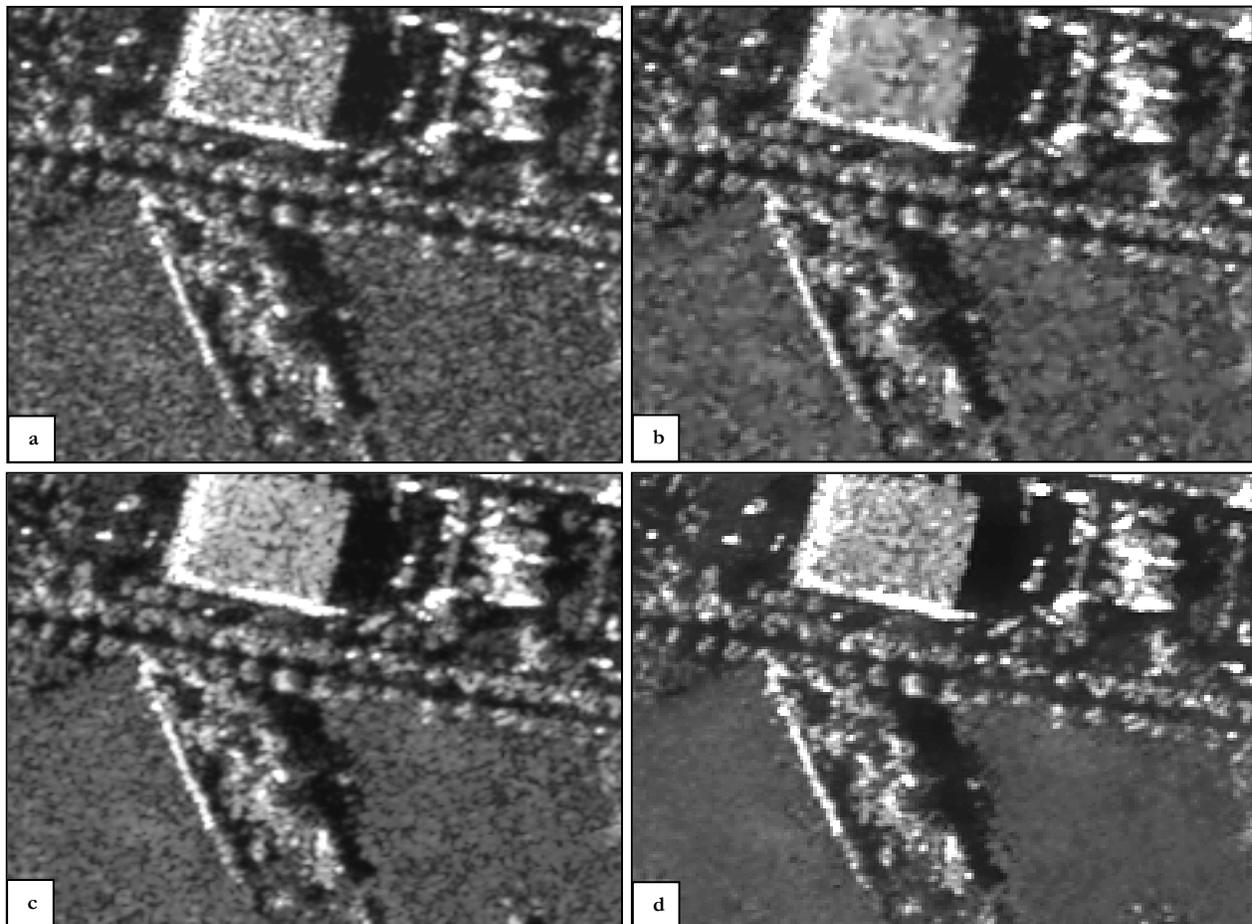


Abb. 4-6: Gegenüberstellung von ursprünglicher Intensitätsaufnahme (a) sowie Frost- (b), Lee-Sigma- (c) und SelectiveMean-gemfiltertem Datensatz (c) – Deutlich zu erkennen, dass der neu entwickelte Filter das Bildrauschen in gering strukturierten Bildbereichen wesentlich stärker reduziert, was vor allem auf eine rigorosere Glättung der dunklen Speckle-Areale zurückzuführen ist. Gleichsam verbleiben die Grauwerte der bedeutenden Strukturen nahezu unverändert.

Dabei zeigt sich, dass der SelectiveMean-Filter das *Bildrauschen* auf homogenen Flächen um *66 Prozent reduziert*. Somit übertrifft dieser Ansatz die Wirkung der etablierten Techniken um *30 bis 50*

Prozent. Dagegen wird die *Textur* innerhalb stark strukturierter Areale nur leicht modifiziert. Hier verringert sich die Varianz der Grauwerte um *acht Prozent*. Dem stehen Werte von *38 Prozent* beim Median-, *19 Prozent* beim Frost- und *30 Prozent* beim Lee-Sigma-Filter gegenüber. Ein ähnliches Bild bietet sich im Hinblick auf die *kantenerhaltende Wirkung* der jeweiligen Algorithmen. Erwartungsgemäß werden diese im Rahmen einer Median-Filterung am Stärksten abgeschwächt (*13 Prozent*), wobei auch der Lee-Sigma-Filter eine deutliche Dämpfung (*10 Prozent*) zur Folge hat. Demgegenüber bleibt die Kanteninformation im Kontext einer Frost- und SelectiveMean-Filterung mit *zwei* bzw. *einem Prozent* nahezu unverändert. An dieser Stelle sei jedoch erwähnt, dass sowohl der Frost- als auch der Lee-Sigma- und SelectiveMean-Filter an der Grenze stark gegensätzlicher Flächen sogar zu einer Verstärkung des Gradienten führen. Dieser kantenverstärkende Effekt ist aus der Statistik jedoch nicht ersichtlich, da alle drei Algorithmen Grenzlinien zwischen homogenen Raumeinheiten, die sich in ihrer Intensität nur schwach voneinander unterscheiden, vergleichsweise stark abschwächen.

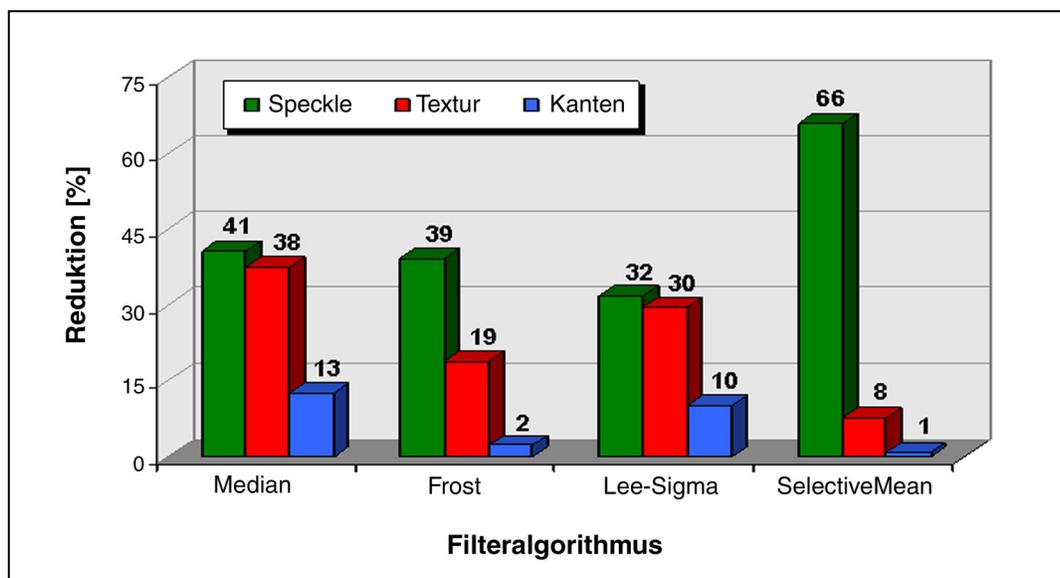


Abb. 4-7: Quantitativer Vergleich zwischen der Wirkung verschiedener Filteralgorithmen zur Bildglättung – Die Resultate belegen, dass der SelectiveMean-Algorithmus das Bildrauschen bedeutend stärker reduziert als die etablierten Filterverfahren, dabei aber zugleich die Textur und Kanteninformation in deutlich geringerem Umfang beeinflusst.

Die quantitative Betrachtung der Filterresultate zeigt, dass der SelectiveMean-Algorithmus das Maß der Bildglättung effizient an die lokale Textur anpasst. Diese selektive Wirkung lässt sich mit Hilfe eines entsprechenden Differenzbildes visualisieren. So zeigt ABBILDUNG 4-8 die prozentuale Veränderung der Grauwerte zwischen dem ursprünglichen E-SAR-Datensatz und der mittels des SelectiveMean-Filters geglätteten Aufnahme. Dabei wird deutlich, dass die Filterwirkung vor allem dort

sichtlich reduziert wird, wo eine signifikante Textur zu einer hohen lokalen Varianz der Rückstreuung führt und damit auf eine strukturbedingte Heterogenität der Reflektionswerte hinweist.

Wie sich diese verbesserten Glättungseigenschaften auf die Berechnung eines Texturdatensatzes auswirken, veranschaulicht ABBILDUNG 4-9. Dort wird der aus einem ungefilterten Intensitätsbild abgeleitete *Coefficient of Variation* dem entsprechenden Pendant eines Frost- bzw. SelectiveMean-gefilterten Datensatzes gegenübergestellt.

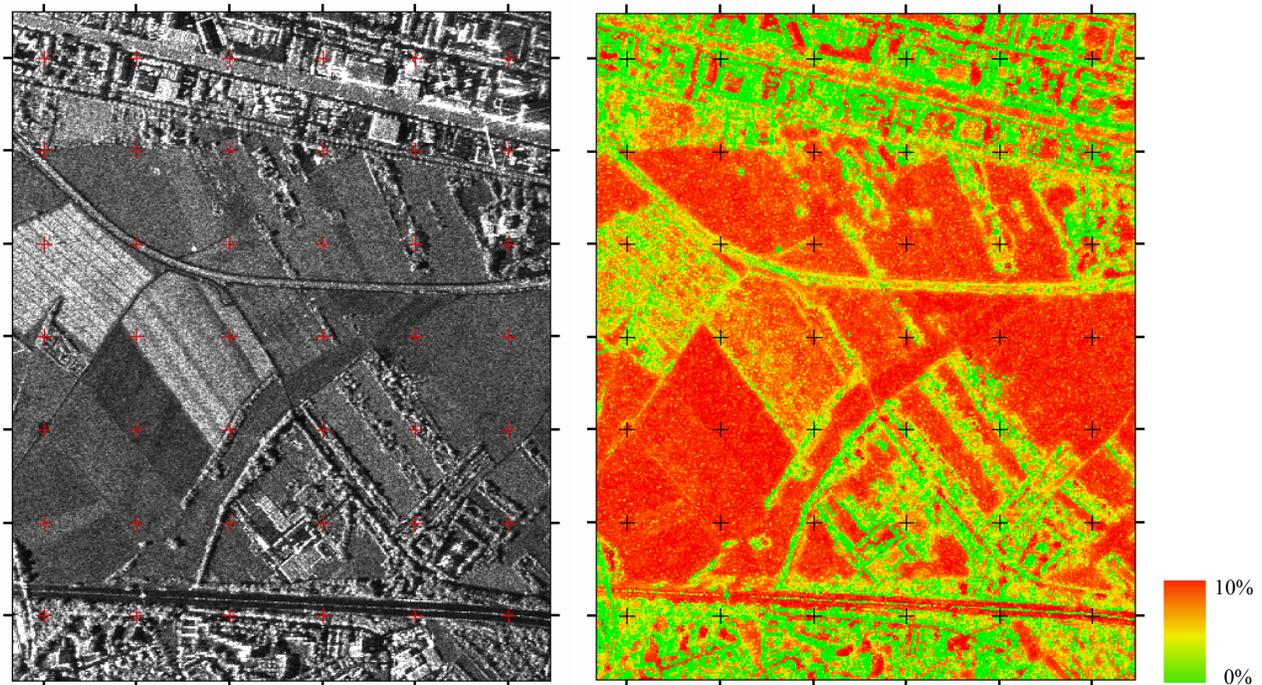


Abb. 4-8: Prozentuale Veränderung der Pixelwerte ($r.$) zwischen ursprünglicher Intensitätsaufnahme (l.) und gefiltertem Datensatz – Das Differenzbild veranschaulicht die adaptive Steuerung der Filterwirkung in Abhängigkeit der lokalen Textur, wobei hochstrukturierte Areale stark, homogene Bereiche hingegen schwach modifiziert werden.

In ABBILDUNG 4-9 zeigt sich zudem ein zweiter, interessanter Effekt. Sowohl im Original als auch im Frost-gefilterten Bild zeichnen sich die dunklen Bildbereiche – speziell die Schattenflächen – durch eine enorm hohe Variation der Grauwerte aus. Ein vergleichbares Phänomen lässt sich im Zusammenhang mit der Lee-Sigma-Filterung beobachten. Dies hat zur Folge, dass einerseits im Bereich von Schattenflächen der Eindruck einer signifikanten Strukturierung entsteht und andererseits gerade in bebauten Arealen die Differenzierbarkeit der einzelnen Gebäude und Baumbestände erheblich erschwert wird (VGL. ABB. 4-9). Im Kontext einer Filterung mittels des SelectiveMean-Algorithmus treten diese Effekte hingegen nicht in Erscheinung. Der Grund liegt in der Definition des Off-Sets, der gerade in dunklen Bildbereichen eine verbesserte Glättung zulässt (VGL. KAP. 4.1.1.2). Da dies beim Lee-Sigma- und Frost-Filter nicht in diesem Umfang möglich ist, äußern sich die - absolut gesehen -

vergleichbar geringen Grauwertvariationen innerhalb der Schattenbereiche in einer erheblichen Strukturierung dieser Areale im entsprechenden Texturdatensatz.

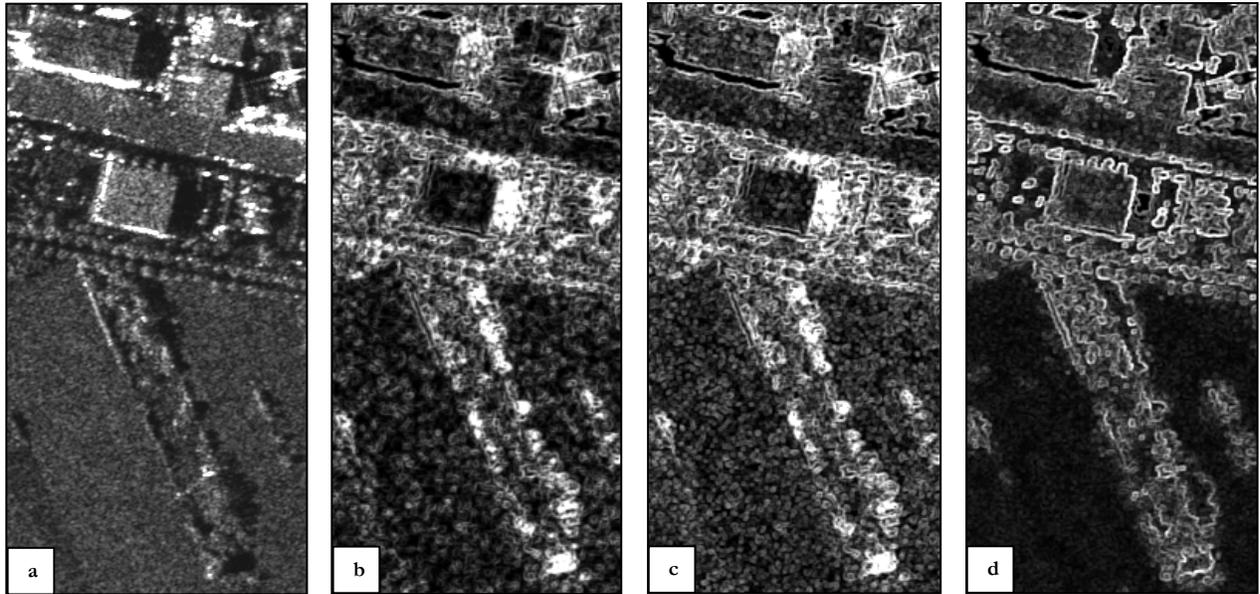


Abb. 4-9: Intensitätsbild (a) und Gegenüberstellung des Coefficient of Variation berechnet auf Basis des Frost- (b), Lee-Sigma- (c) und SelectiveMean-gefilterten Datensatzes (c) – Da das Bildrauschen im Kontext der Frei- und Schattenflächen durch die SelectiveMean-Filterung bedeutend stärker reduziert wird als beim Frost- und Lee-Sigma-Ansatz, lässt sich die tatsächliche Strukturierung der abgebildeten Szene im Texturdatensatz der SelectiveMean-gefilterten Szene (d) am Besten nachvollziehen.

Im Hinblick auf die Optimierung der Segmentierung zeigt ABBILDUNG 4-10, dass die Filterung durch die Homogenisierung gering strukturierter Flächen bei gleichzeitiger Wahrung der hochfrequenten Informationen zudem die akkurate Abgrenzung der einzelnen Raumeinheiten unterstützt.

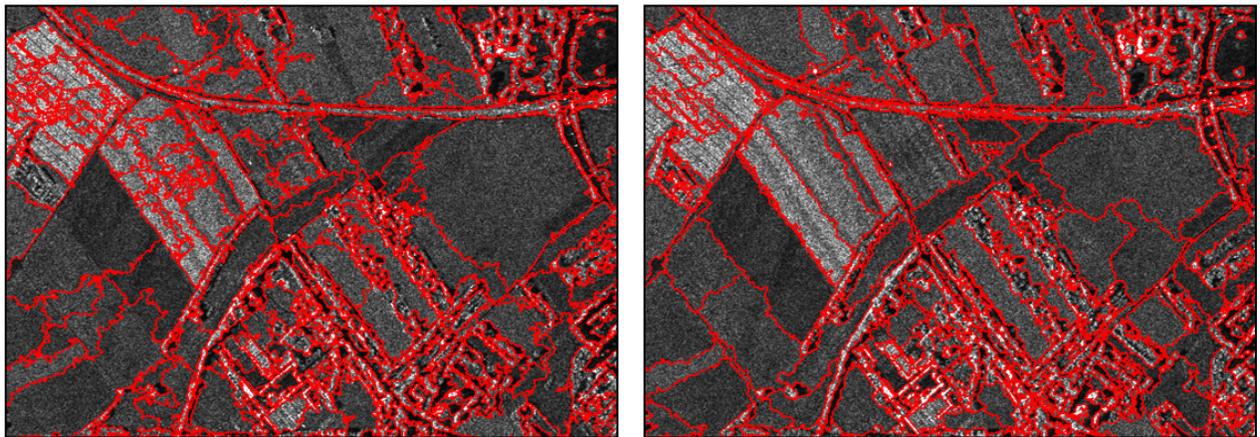


Abb. 4-10 : Einfluss der Filterung auf die Bildsegmentierung – Im Vergleich zur ungefilterten Aufnahme (l.) folgen die Objekte bei identischen Segmentierungsparametern in der geglätteten Szene (r.) besser der vorgegebenen Strukturierung und sind dabei gleichsam an den Rändern weniger stark zerklüftet.

So geht die Segmentierung auf der Grundlage der Datenbasis aus ungefiltertem Intensitätsbild und zugehörigem Texturdatensatz (Coefficient of Variation) mit einer Generierung relativ stark zergliederter Bildsegmente einher. Dieser Effekt tritt im Kontext der gefilterten Datensätze in geringerem Umfang in Erscheinung. Zudem wird die Differenzierbarkeit der jeweiligen Raumeinheiten durch eine Filterung der Intensitätsaufnahme und die anschließende Berechnung eines neuen, nunmehr aussagekräftigeren Texturlayers verbessert (VGL. ABB. 4-10). Die resultierenden Segmente folgen daher akkurater den vorgegebenen Strukturen und auch die Form der generierten Objekte orientiert sich stärker an den tatsächlichen Gegebenheiten.

Letztlich sei angemerkt, dass auch die Qualität optischer Bilddaten mitunter von Rauscheffekten gemindert wird. Somit ist eine effiziente Glättung der entsprechenden Aufnahmen auch im Bezug auf eine verbesserte Segmentierung und Analyse optischer Datensätze von Bedeutung. Daher soll ABBILDUNG 4-11 abschließend am Beispiel einer HRSC-Aufnahme das Potential des SelectiveMean-Filters zur Aufwertung optischer Daten demonstrieren (VGL. ANHANG B).



Abb. 4-11: Einsatz des SelectiveMean-Filters zur Aufwertung optischer Daten (HRSC) – Die Filterung wurde auf jeden Aufnahmekanal (RGB) separat angewendet und die geglätteten Bänder anschließend zu einem Komposit zusammengefügt. Durch die Glättung homogener Flächen bei gleichzeitiger Bewahrung der Kanteninformation heben sich die einzelnen Struktureinheiten nach der Filterung bedeutend klarer voneinander ab.

4.1.2 Ansatz zur klassenbasierten Segmentoptimierung

4.1.2.1 Anforderungen

Die akkurate Segmentierung der Bildinhalte ist von elementarer Bedeutung für eine erfolgreiche, objektorientierte Auswertung fernerkundlicher Aufnahmen. Daher stellt die Software eCognition mit der Multiresolution Segmentation eine umfassende Funktionalität zur Steuerung der Bildsegmentierung bereit (VGL. KAP. 3.3). Dabei ist das Verfahren so ausgelegt, dass dem Nutzer hohe Freiheitsgrade hinsichtlich der adäquaten Einstellung der bereitgestellten Segmentierungsparameter eingeräumt werden. Dadurch wird eine Flexibilität gewährleistet, die es ermöglichen soll, die Segmentierung optimal auf die individuellen Ziele des Anwenders abzustimmen.

In der Praxis hat sich jedoch gezeigt, dass diese Flexibilität mitunter die Praktikabilität der Multiresolution Segmentation merklich einschränkt. So sieht sich der Anwender mit der komplexen Aufgabe konfrontiert, zu entscheiden, wie viele Segmentierungsebenen mit welchen Einstellungen zur hinreichend genauen Repräsentation der zu klassifizierenden Sachverhalte erforderlich sind. Dabei unterscheiden sich die zu identifizierenden Bedeckungstypen oder Objektarten in ihren räumlichen und spektralen Charakteristika naturgemäß erheblich. Daher können im Grunde genommen kaum allgemein gültige Werte bestimmt werden. Hinzu kommt, dass selbst innerhalb identischer Objektklassen verbreitet signifikante Variationen in den räumlichen und spektralen Eigenschaften auftreten. Zudem sollte im Rahmen der Segmentierung darauf geachtet werden, die Anzahl der Objektebenen möglichst gering zu halten, um die Komplexität des Regelwerks – und letztlich auch den Rechenaufwand im Kontext der Klassifizierung – zu minimieren. Nicht zuletzt muss sich die Wahl der Segmentierungsparameter schließlich auch nach den Charakteristika der Datenbasis bzw. der thematischen Komplexität der Auswertung richten.

Vor diesem Hintergrund ist der Anwender im Grunde genommen darauf angewiesen, die bestmöglichen Einstellungen nach einem mehr oder minder aufwendigen Trial-and-Error-Prinzip zu ermitteln. Dieses Vorgehen kann jedoch selbst für erfahrene Nutzer leicht zu einem überaus zeitintensiven Unterfangen werden. Wird demgegenüber auf eine aufwendige Ermittlung der optimalen Parameter verzichtet, implizieren die daraus resultierenden Abstriche in der Güte der Segmentierung, dass die einzelnen Raumeinheiten und Zielobjekte nur begrenzt in ihrer typischen Ausprägung erfasst werden. In der Folge wird die Aussagekraft des bereitgestellten Merkmalskatalogs zur Charakterisierung der zu klassifizierenden Objekttypen zwangsläufig signifikant eingeschränkt.

Eine zweite Schwierigkeit im Kontext der Bildsegmentierung unter eCognition betrifft Probleme bezüglich der Übertragbarkeit des Segmentierungsprozesses. Dabei spielen zwei Aspekte eine Rolle. Zum einen hat sich im Verlauf zahlreicher Tests gezeigt, dass bereits *leichte Veränderungen der Segmentierungsparameter* mitunter *signifikante Variationen der Objekteigenschaften* hervorrufen (VGL. ABB. 4-12). Zum anderen konnte im Zusammenhang mit der Auswertung der Radaraufnahmen beobachtet werden, dass eine *variierende Filterung* der Ausgangsdaten bisweilen ebenfalls *Abweichungen im Segmentierungsergebnis* nach sich zieht.

Angesichts dieser Limitierungen besteht ein *zentrales Ziel* der vorliegenden Dissertation in der *Entwicklung eines Optimierungsansatzes zur vereinfachten und gleichsam akkurateren Segmentierung* unter eCognition. Dabei soll die zu entwickelnde Methodik die zeitintensive Suche nach den optimalen Segmentierungseinstellungen vereinfachen und somit den erforderlichen Arbeits- und Zeitaufwand reduzieren. Zum anderen gilt es, die Robustheit der Bildsegmentierung gegenüber einer Variationen der Segmentierungsparameter oder Schwankungen der Bildqualität zu erhöhen. Auf diese Weise soll die Übertragbarkeit und Güte des Segmentierungsprozesses verbessert werden.

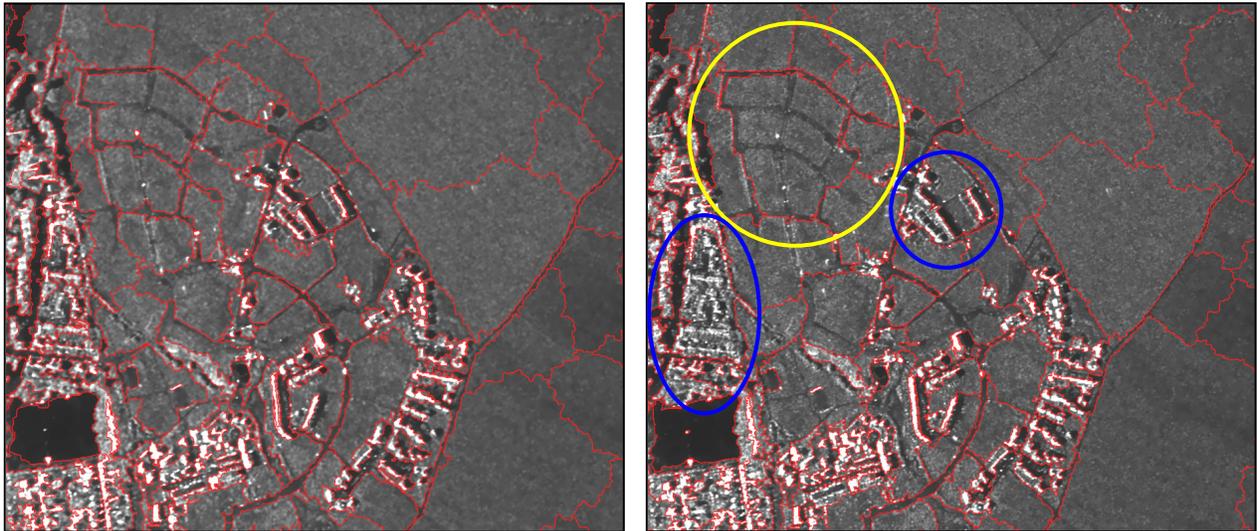


Abb. 4-12: Segmentierung eines identischen Bildausschnitts mit leicht variierender Parametrisierung – Die Einstellungen zwischen linkem und rechtem Bild differieren lediglich in der Compactness um einen Betrag von 0.1 (Einstellungen: Scale Parameter = 60, Color = 0.7, Compactness = 0.4 (l.) und 0.5 (r.)). Diese äußerst geringe Variation führt jedoch dazu, dass beispielsweise die Straßenzüge (gelb) bedeutend schlechter nachvollzogen werden und im Siedlungsbereich heterogene Strukturen bereits durch ein einziges Objekt repräsentiert sind. (blau).

4.1.2.2 Funktionsweise

Um die zuvor formulierten Ziele zu erreichen, wurde in der Software-Umgebung von eCognition ein klassenbasierter Segmentierungsablauf entwickelt, der auf Basis eines einfach strukturierten und damit leicht nachvollziehbaren Regelwerks eine akkuratere Segmentierung der Bilddaten gewährleisten soll. Ferner zielt der Ansatz darauf ab, sämtliche spektral differenzierbaren Objekte unabhängig von ihrer räumlichen Ausdehnung durch ein individuelles Segment auf einer einzigen Segmentierungsebene zu repräsentieren. Die dazu entwickelte Prozedur kombiniert die Funktionalität der Multiresolution Segmentation mit einer merkmalsbasierten Klassifizierung und klassenbasierten Segmentoptimierung.

Das Optimierungsverfahren startet mit der Generierung einer Segmentierungsebene (*Basisebene*), deren Objektgrößen sich zur Repräsentation der kleinsten, zu klassifizierenden Objekttypen (z.B. Häuser) eignen. Im Anschluss daran wird ein zweites, übergeordnetes Segmentlevel (*Optimierungsebene*) mit leicht vergrößerten Objekten angelegt (VGL. ABB. 4-13). Da mit der Basisebene zu diesem Zeitpunkt bereits eine Bildsegmentierung existiert, müssen die neu generierten Objekte der Optimierungsebene aus verfahrenstechnischen Gründen die vorgegebenen Umrisse der bereits vorhandenen Segmente des Basislevels berücksichtigen (VGL. KAP. 3.3). Folglich geht die Segmentierung der Optimierungsebene im Grunde genommen aus einer Fusion der Segmente des Basislevels hervor (VGL. ABB. 4-13).

Dabei werden bei einem geringen Scale Parameter – sprich der Generierung vergleichbar kleiner Objekte – weitestgehend spektral ähnliche Segmente fusioniert. Demgegenüber kommt es mit zunehmender Objektgröße - d.h. der Steigerung des Scale Parameters bzw. der maximal zulässigen Heterogenität - verstärkt zur Fusion spektral recht unterschiedlicher Segmente. Um dies zu korrigieren, wird im Anschluss an die Generierung der Basis- und Optimierungsebene auf der Grundlage einer entsprechenden Klassenhierarchie für jedes Objekt der Basisebene (*Subobjekt*) geprüft, ob sich dieses in seinen spektralen Eigenschaften in signifikanter Weise vom übergeordneten Segment der Optimierungsebene (*Superobjekt*) unterscheidet (VGL. ABB. 4-13A). Die Quantifizierung der grauwertbezogenen Affinität zwischen Sub- und Superobjekt erfolgt über Ähnlichkeitsmaße, die im weiteren Verlauf dieses Kapitels ausführlich erörtert werden. Segmente, die eine zu hohe spektrale bzw. grauwertbezogene Abweichung gegenüber dem zugehörigen Superobjekt auf der Optimierungsebene aufweisen, werden auf dem Basislevel als *signifikantes Subobjekt* klassifiziert (VGL. ABB. 4-13A). Diese Klassenzuweisung bedeutet, dass das entsprechende Objekt auf der Optimierungsebene offensichtlich mit benachbarten Segmenten fusioniert wurde, die sich in ihrem Reflektionsverhalten deutlich von den

Eigenschaften des betrachteten Subobjektes unterscheiden. Somit sollte das entsprechende Segment auf der Optimierungsebene weiterhin durch ein individuelles Objekt repräsentiert werden.

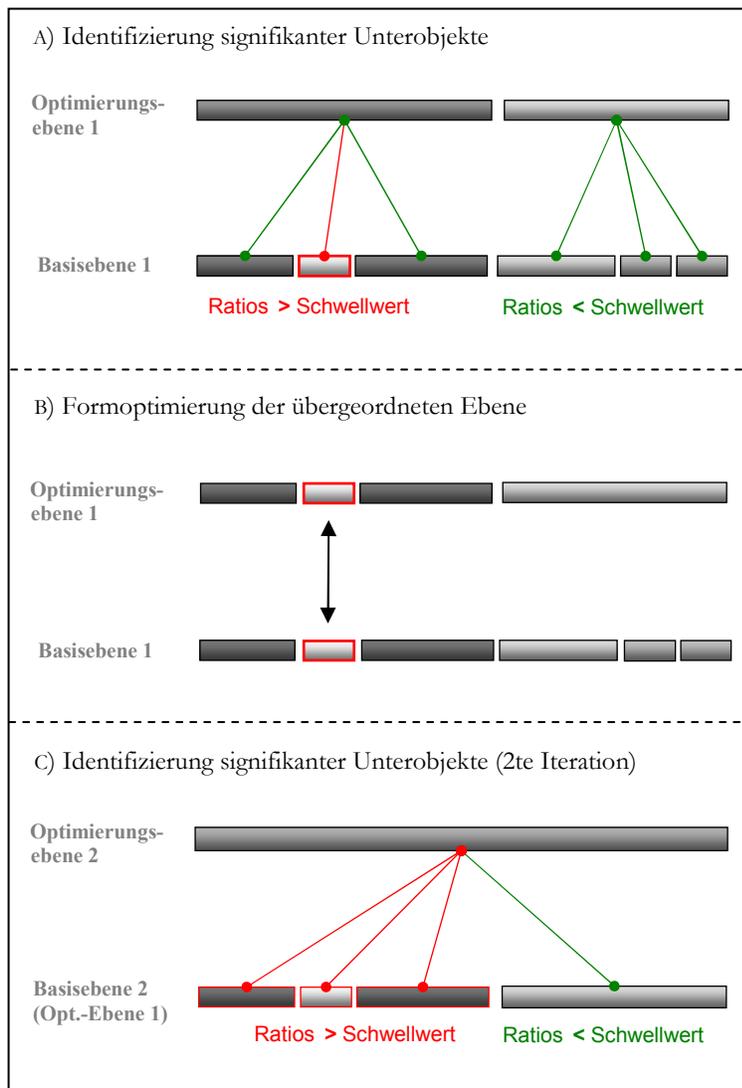


Abb. 4-13: Ablauf der klassenbasierten Segmentoptimierung – Nach Generierung einer Basis- und Optimierungsebene wird für jedes Objekt der Basisebene geprüft, ob es sich signifikant vom übergeordneten Segment unterscheidet (A). Ist dies der Fall (rot), wird das betreffende Basisobjekt auf die Optimierungsebene übertragen (B). In der zweiten Iteration (C) dient die ehemalige Optimierungsebene als Basisebene und der Prozess der Optimierung beginnt erneut. Die Anzahl der Iterationen ist frei wählbar und richtet sich vornehmlich nach der Beschaffenheit der Daten und den Erfordernissen der thematischen Auswertung.

Um dies zu gewährleisten, werden sämtliche *signifikanten Subobjekte* nach der Klassifizierung mittels der in eCognition bereitgestellten Funktion zur klassenbasierten Segmentoptimierung auf die Objektstruktur der übergeordneten Segmentierungsebene übertragen (VGL. ABB. 4-13B). Im Anschluss an die Modifizierung der betreffenden Superobjekte auf der Optimierungsebene wird der erste Durchlauf der Optimierungsprozedur mit dem Löschen der Basisebene abgeschlossen.

Nachfolgend beginnt die zweite Iteration der Optimierungsprozedur. Deren Ablauf entspricht grundsätzlich dem des vorangegangenen Durchlaufs. Der einzige Unterschied besteht darin, dass die zuvor modifizierte Optimierungsebene nun als Basisebene dient und die zweite Iteration demnach unmittelbar mit der Generierung eines neuen Optimierungslevels beginnt (VGL. ABB. 4-13C). Der angesetzte Scale Parameter wird dabei gegenüber dem entsprechen-

den Wert des vorangegangenen Optimierungslevels erhöht, d.h. die Größe der Objekte wird erneut gesteigert. Im Anschluss daran werden auf dem ehemaligen Optimierungslevel, das ja bereits korrigiert wurde und das jetzt als Basislevel dient, erneut alle signifikanten Subobjekte identifiziert (VGL.

ABB. 4-13C). Entsprechend dieser Klassifizierung werden auf der neu generierten Optimierungsebene wiederum jene Segmente modifiziert, die offensichtlich aus einer Fusion von Objekten mit signifikant variierenden Spektraleigenschaften hervorgegangen sind. Auch die zweite Iteration der Optimierung endet schließlich mit dem Löschen des Basislevels.

Das zuvor dargelegte Prozedere der iterativen Erhöhung des Scale Parameters und der anschließenden Korrektur der Optimierungsebene wird so lange fortgeführt, bis die Segmente des jeweils neu angelegten Optimierungslevels eine Größe erreichen, die zur adäquaten Wiedergabe der größten zu klassifizierenden Objekttypen (z.B. Waldflächen, Freiflächen) geeignet ist. Sobald die Segmente dieser Objektebene optimiert sind, kann davon ausgegangen werden, dass alle im Bild enthaltenen Strukturen bzw. Objekttypen erfasst und gegebenenfalls auf eine akkurate räumliche Skalierung und Form überführt wurden. Folglich kann der Optimierungsprozess an dieser Stelle beendet werden (VGL. ANHANG C).

Wie der zuvor beschriebene Ablauf des Verfahrens aufzeigt, wird die eigentliche *Steuerung der Segmentierung* von der Multiresolution Segmentation auf eine *wissensbasierte Klassifikation* verlagert. Dadurch lässt sich erreichen, dass die Einstellung der Segmentierungsparameter zur Generierung der Objektebenen für die Charakteristik der letztlich resultierenden Objektebene nunmehr von untergeordneter Bedeutung ist. Vielmehr stützt sich der gesamte Segmentierungsprozess auf die Verwendung von Ähnlichkeitsmaßen, die den spektralen Unterschied zwischen Sub- und zugehörigem Superobjekt charakterisieren.

Im Falle *einkanaliger Bilddaten* ist die Beurteilung des spektralen Unterschieds zwischen Sub- und zugehörigem Superobjekt zwangsläufig auf einen *Vergleich der Graustufen in einem einzigen Kanal* reduziert. Zur Quantifizierung wird dabei die *prozentuale Abweichung in der Helligkeit* zwischen dem DN-Wert des Basissegments und dem Grauwert des korrespondierenden Superobjektes berechnet. Liegt die prozentuale Abweichung oberhalb eines definierten Schwellwertes, wird das Segment als *signifikantes Subobjekt* klassifiziert. Die Wahl des geeigneten Schwellwerts hängt vor allem von der Art und Qualität der Bilddaten ab (z.B. Sensor, Signal-zu-Rausch-Verhältnis, Dynamikbereich) und hat maßgeblichen Einfluss auf die Sensibilität bzw. Wirkungsweise der Optimierung. So führt ein niedriger Schwellwert – z.B. 0.15, was einer maximal zulässigen Abweichung von 15 Prozent entspricht – bereits bei einem geringen Grauwertunterschied zwischen Sub- und Superobjekt zur Modifizierung des Optimierungslevels. Demgegenüber geht eine großzügigere Auslegung mit einer weniger sensiblen Untergliederung der erfassten Raumeinheiten einher. Die Verwendung der prozentualen Abwei-

chung bietet gegenüber einer Berechnung der absoluten Differenz den Vorteil, dass bei der Bemessung der Ähnlichkeit zweier Objekte deren Helligkeit adäquater berücksichtigt wird. So stellt eine absolute Differenz von 10 Grauwerten zwischen zwei Objekten, die eine Helligkeit von 10 DN bzw. 20 DN aufweisen im Radarbild einen markanteren Unterschied dar als zwischen Segmenten mit den Werten 250 DN und 240 DN. Diesem Umstand wird durch den Einsatz der prozentualen Abweichung Rechnung getragen.

Im Rahmen der Optimierung *multispektraler Bilddaten* beschränkt sich die Charakterisierung der spektralen Ähnlichkeit nicht mehr einzig auf den Vergleich der Helligkeit zwischen Sub- und Superobjekt. Vielmehr erlaubt die erhöhte Anzahl an Aufnahmekanälen nunmehr die Beschreibung der *Ähnlichkeit mit Bezug auf die spektrale Signatur* der zu vergleichenden Segmente. Zu diesem Zweck wird in diesem Fall ein Attribut verwendet, das über einen Abgleich der partiellen Steigungen der Reflektionskurve zwischen den einzelnen spektralen Bändern die *gemittelte, prozentuale Abweichung in der spektralen Signatur* definiert. Auf diese Weise kann im Prinzip die Parallelität der Reflektionskurven zweier Objekte abgeglichen werden. Dies alleine reicht jedoch noch nicht zur eindeutigen Unterscheidung aus. So weisen beispielsweise ein heller und ein dunkler Boden mitunter einen nahezu parallelen Verlauf der spektralen Signatur auf, obwohl sie sich visuell eindeutig durch eine differierende Helligkeit voneinander abheben. Folglich ist es von besonderer Bedeutung, auch das absolute Maß der Rückstreuung zu berücksichtigen. Daher schließt das Regelwerk zur Analyse multispektraler Bilddaten als zweites Kriterium erneut die *prozentuale Abweichung in der Helligkeit* zwischen Sub- und Superobjekt ein. Dabei ergibt sich die Helligkeit allerdings nun aus einer Mittelung der Grauwerte über sämtliche Spektralkanäle.

ABBILDUNG 4-14 illustriert den Abgleich der spektralen Signatur auf der Basis eines Datensatzes mit vier spektralen Bändern (B-G-R-NIR). Im vorliegenden Beispiel wird davon ausgegangen, dass auf der übergeordneten Optimierungsebene insgesamt vier Subobjekte des Basislevels fusioniert wurden, von denen drei vegetationsbedeckte Flächen repräsentieren, während das vierte Segment ein Gebäude kennzeichnet. Zur Vereinfachung wird angenommen, dass die drei Vegetations-Objekte drei Viertel, und das Haus-Segment entsprechend ein Viertel der Fläche des Superobjektes einnehmen. Daraus resultiert eine spektrale Mischsignatur des übergeordneten Superobjekts, die von den Merkmalen der Vegetation dominiert wird (VGL. ABB. 4-14). Die Berechnung der *prozentualen Abweichung* in der *Helligkeit* und *spektralen Signatur* zeigt, dass jene drei Segmente, welche die Vegetation repräsentieren, folglich maximal 10 Prozent bzw. 20 Prozent vom Superobjekt abweichen. Demgegenüber beläuft sich die Divergenz im Kontext des Haus-Segments auf rund 20 Prozent bzw. 55 Prozent. Wäre für

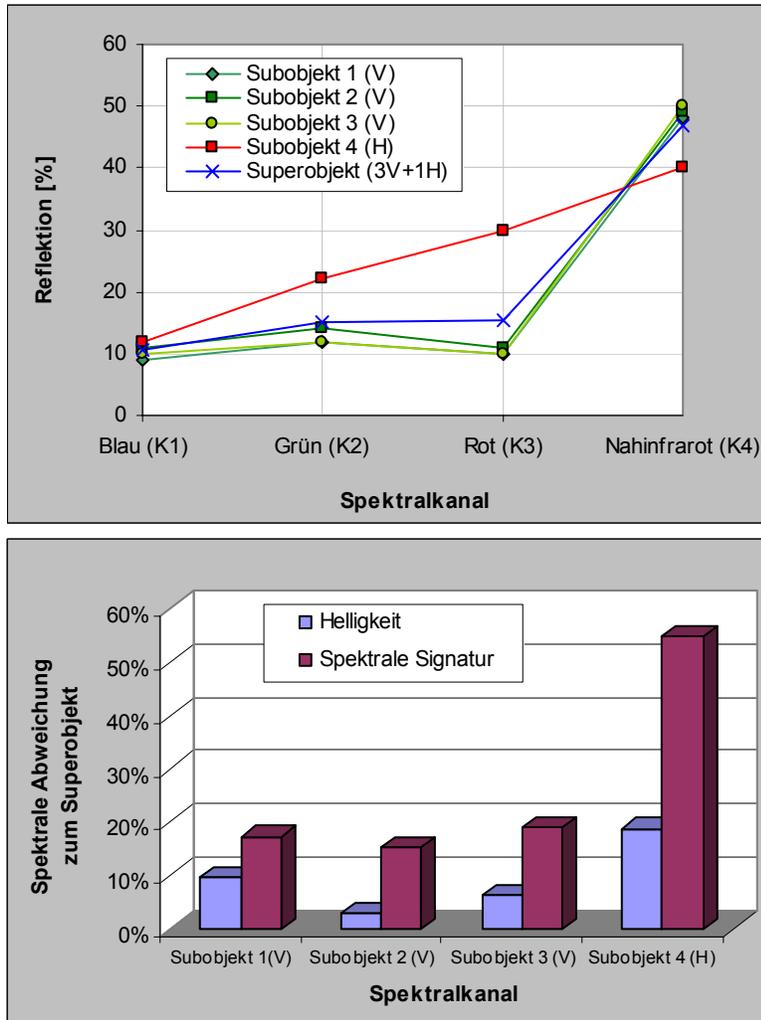


Abb. 4-14: Beschreibung der spektralen Affinität zwischen Sub- und Superobjekt – Die spektrale Abweichung zwischen Unterobjekten und Superobjekt wird über einen Vergleich der Helligkeit und des Verlaufs der spektralen Signatur (vier Aufnahmebänder) quantifiziert.

beide Kriterien ein maximal zulässiger Schwellwert von 25 Prozent vorgegeben, so würden im Hinblick auf die *helligkeitsbezogene Ähnlichkeit* alle Subobjekte den zulässigen Grenzwert unterschreiten – sprich es erfolgt keine Korrektur des zugehörigen Superobjektes. Beim Abgleich des zweiten Kriteriums – der spektralen Signatur – würde das Haus-Segment hingegen den zulässigen Schwellwert weit übertreffen, daher als *signifikantes Unterobjekt* klassifiziert und im entsprechenden Segment auf der Optimierungsebene extrahiert.

Wie ABBILDUNG 4-15 am Beispiel der Klassenhierarchie zur Optimierung eines multispektralen Datensatzes aufzeigt, können die zuvor erörterten, spektralen Attribute (*ProzDiff_Helligkeit*, *ProzDiff_SpektraleSignatur*) optional durch einen Block *flächenbezogener Merkmale* ergänzt werden. Zum

einen gibt es dabei die Möglichkeit, eine *Mindestgröße (Area)* für sämtliche *signifikanten Unterobjekte* zu definieren. Dadurch lässt sich verhindern, dass spektral markante, lokal jedoch sehr begrenzte Details (z.B. Schornsteine auf Dächern) im Kontext der Optimierung berücksichtigt werden und somit zu einer übermäßigen Zergliederung der Segmentierung führen. Die zweite zur Verfügung stehende Option zielt ebenfalls auf diese Problematik ab, wobei in diesem Fall der *relative Anteil des Subobjektes an der Fläche des zugehörigen Superobjektes* mit den beiden spektralen Kriterien kombiniert wird (VGL. ABB. 4-15). Durch diese Merkmalskombination kann beispielsweise vorgegeben werden, dass sich sämtliche Subobjekte, die weniger als fünf Prozent der Fläche des Superobjektes einnehmen, spektral deutlich stärker von ihrem übergeordneten Segment abheben müssen als dies durch die im ersten Block

definierten Abweichungen in Helligkeit und spektraler Signatur der Fall ist. Auf diese Weise kann mittels eines räumlich flexiblen Attributs verhindert werden, dass lokale Details über die gesamte Optimierung erhalten bleiben.

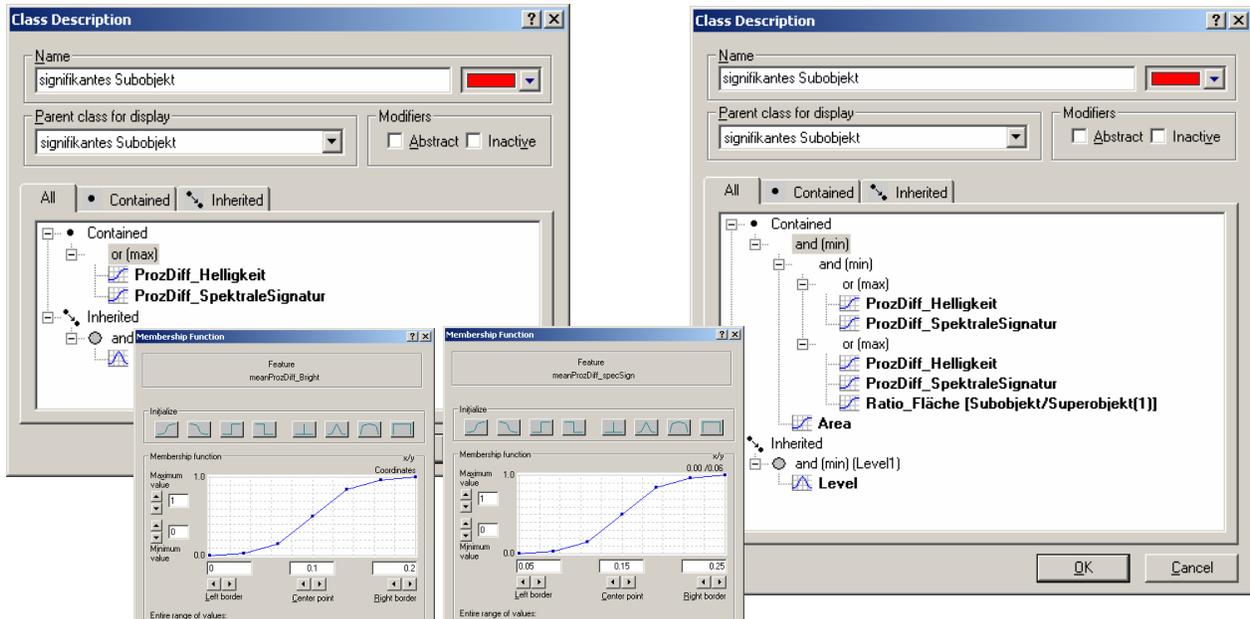


Abb. 4-15: Klassenhierarchie zur Segmentoptimierung mehrkanaliger Bilddaten ohne (l.) und mit flächenbezogenen Merkmalen (r.) – Die Optimierung erfolgt über die Quantifizierung der prozentualen Abweichung zwischen Sub- und Superobjekt hinsichtlich ihrer Helligkeit (ProzDiff_Helligkeit) und spektralen Signatur (ProzDiff_SpektraleSignatur). Diese Merkmale können wahlweise durch flächenbezogene Attribute ergänzt werden, die beispielsweise verhindern, dass lokale Details im Kontext der Optimierung Berücksichtigung finden.

Abschließend sei erwähnt, dass die gesamte Optimierungsprozedur in Form eines Protokolls abgelegt ist, das jeden einzelnen Schritt des Verfahrens dokumentiert (VGL. ANHANG C). Durch entsprechende Ergänzungen oder Modifikationen können der zuvor beschriebene Ablauf sowie das jeweils zur Optimierung verwendete Regelwerk daher flexibel kombiniert oder variiert werden. Dies stellt gerade hinsichtlich der Auswertung einer *mehrdimensionalen Datenbasis unterschiedlicher Bildprodukte* (z.B. SAR-Intensitätsbild und multispektrale Aufnahme) einen enormen Vorteil dar. So lassen sich die Regelwerke zur Optimierung ein- bzw. mehrkanaliger Datensätze beliebig miteinander kombinieren, indem die Optimierungsschritte für jeden einzelnen Datensatz hintereinander geschaltet werden. Ein solches Vorgehen gewährleistet, dass die letztlich resultierende Segmentierung die räumliche Strukturierung aller genutzten Datensätze adäquat repräsentiert, was sich auf der Basis der Multiresolution Segmentierung nur eingeschränkt verwirklichen lässt.

4.1.2.3 Bewertung

Das zentrale Ziel der entwickelten Optimierungsprozedur besteht darin, die oftmals zeitintensive Suche nach den geeigneten Segmentierungseinstellungen deutlich zu vereinfachen und gleichzeitig die Güte der Segmentierung zu erhöhen. Wie bereits erwähnt, wurde der gesamte Ablauf des entwickelten Verfahrens mit Hilfe der unter eCognition implementierten Protokollfunktion aufgezeichnet (VGL. ANHANG C). Auf diese Weise lässt sich die Segmentierungsoptimierung einfach und schnell auf wechselnde Bilddaten übertragen. Zudem können die einzelnen Komponenten beliebig modifiziert, ergänzt oder entfernt werden.

Dabei ist das entwickelte Verfahren so ausgelegt, dass der Nutzer ein *Minimum an Einstellungen* vornehmen muss, um die *Optimierungsprozedur* an die *Daten unterschiedlicher Sensoren* oder die spezifischen Anforderungen einer *thematischen Auswertung anzupassen*.

Zum einen gilt es, den *Scale Parameter* für das Basislevel der ersten Iteration und die Optimierungsebene des abschließenden Durchlaufs so zu definieren, dass die Größe der Segmente zur Repräsentation der kleinsten bzw. größten zu klassifizierenden Objekttypen geeignet ist. Die Scale Parameter der zwischengeschalteten Optimierungsdurchläufe können anschließend so gesetzt werden, dass sie in ungefähr konstanten Schritten zwischen den zuvor ermittelten Einstellungen ansteigen. Alle weiteren Optionen – wie die Definition der Color, Shape, Smoothness und Compactness – sind nicht weiter relevant und können folglich frei gewählt bzw. unverändert gelassen werden. Somit ist der Aufwand im Kontext der Multiresolution Segmentation deutlich reduziert.

Die eigentliche *Steuerung der Segmentierung* erfolgt über die *Definition der Schwellwerte* für die beiden Ähnlichkeitskriterien *ProzDiff_Helligkeit* und *ProzDiff_SpektraleSignatur* (VGL. ABB. 4-15). Wie bereits dargelegt, wird die Bestimmung der Objekteigenschaften damit von der Multiresolution Segmentation auf eine wissensbasierte Klassifikation verlagert. Ein solcher klassenbasierter Ansatz bietet gegenüber der herkömmlichen Multiresolution Segmentation den Vorteil, dass die Parameter zur Segmentierung weitaus weniger abstrakt sind und sich daher schneller und gezielter an die vorliegende Datenbasis anpassen lassen.

So muss der Nutzer im Zusammenhang mit der klassenbasierten Segmentoptimierung lediglich entscheiden, um wie viel Prozent ein Objekt spektral bzw. in Bezug auf seine Helligkeit maximal von seinem zugehörigen Superobjekt – und damit im Prinzip von seiner Umgebung – abweichen darf, um als eigenständige Struktur betrachtet zu werden. Zudem kann während der Optimierung – sprich der Modifizierung der Segmente – zu jedem Zeitpunkt anhand der Zuweisungswerte nachvollzogen

werden, wann welches Objekt aus welchen Gründen mit seiner Umgebung zusammengefasst wird bzw. warum es als eigenständige Struktur erhalten bleibt. Dementsprechend lassen sich gegebenenfalls erforderliche Korrekturen der gesetzten Schwellwerte schnell und unkompliziert quantifizieren und umsetzen. Somit sind die (Aus-)Wirkungen von Veränderungen in den Einstellungen stets transparent. Vor diesem Hintergrund kann das vormals notwendige Trial-and-Error-Vorgehen durch eine zielgerichtetere Vorgehensweise ersetzt werden.

Gleichzeitig lassen sich mittels der Optimierungsprozedur auch die *Robustheit und Qualität der Bildsegmentierung sichtlich verbessern*. ABBILDUNG 4-15 illustriert dies wiederum am Beispiel jener identischen Ausschnitte, die bereits in ABBILDUNG 4-12 beschrieben wurden. Dabei entsprechen die in der oberen Bildreihe dargestellten Segmentierungen denen der ABBILDUNG 4-12 – d.h. sie zeigen die Variation im Segmentierungsergebnis bei leichter Modifikation der Compactness. Die untere Reihe repräsentiert das Resultat einer Optimierung dieser Segmentierungen auf der Grundlage des zuvor beschriebenen Optimierungsansatzes. Dabei wurden die im Rahmen dieses Verfahrens verwendeten Einstellungen zur Segmentierung in wesentlich größerem Umfang variiert als dies zuvor im Kontext der herkömmlichen Multiresolution Segmentation der Fall war (VGL. ABB-4.16). Dennoch zeigt ABBILDUNG 4-15, dass die Ergebnisse der Optimierungsprozedur einander wesentlich ähnlicher sind als die ursprünglich unter einer bedeutend geringeren Variation der Segmentierungsparameter erstellten Objektlevel.

Die zuvor beschriebenen Eigenschaften der klassenbasierten Segmentoptimierung können auch auf der Basis optischer Daten belegt werden. So zeigt ABBILDUNG 4-17 unterschiedliche Varianten eines segmentierten, hochaufgelösten Luftbildes (a). Dabei ist einerseits ein Objektlevel mit verhältnismäßig kleinen Segmenten dargestellt (b), welches auf der Basis der herkömmlichen Multiresolution Segmentation angelegt wurde und der adäquaten Wiedergabe kleinräumiger Bildobjekte (z.B. Bäume, Autos, Häuser) dient. Daneben ist eine Segmentierung zur akkuraten Repräsentation großflächiger Raumeinheiten (z.B. Freiflächen, Straßenzüge) zu sehen, die ebenfalls mittels der Multiresolution Segmentation generiert wurde (c). Diesen Objektebenen wird letztlich eine Segmentierung gegenübergestellt, die mittels des klassenbasierten Optimierungsverfahrens erstellt wurde (d). Dieser Vergleich zeigt, dass die kleinteilige Segmentierung (b) die räumlich begrenzten Objekte in geeigneter Form erfasst. Demgegenüber sind großflächigere Objekttypen wie ausgedehnte Häuserkomplexe, Straßen und Grünflächen stets in mehrere Teilobjekte untergliedert. Diese werden daher nicht in ihrem charakteristischen Habitus repräsentiert. Daher eignen sich diese kleinen Segmente nicht zur Kennzeichnung großflächiger Objekttypen.

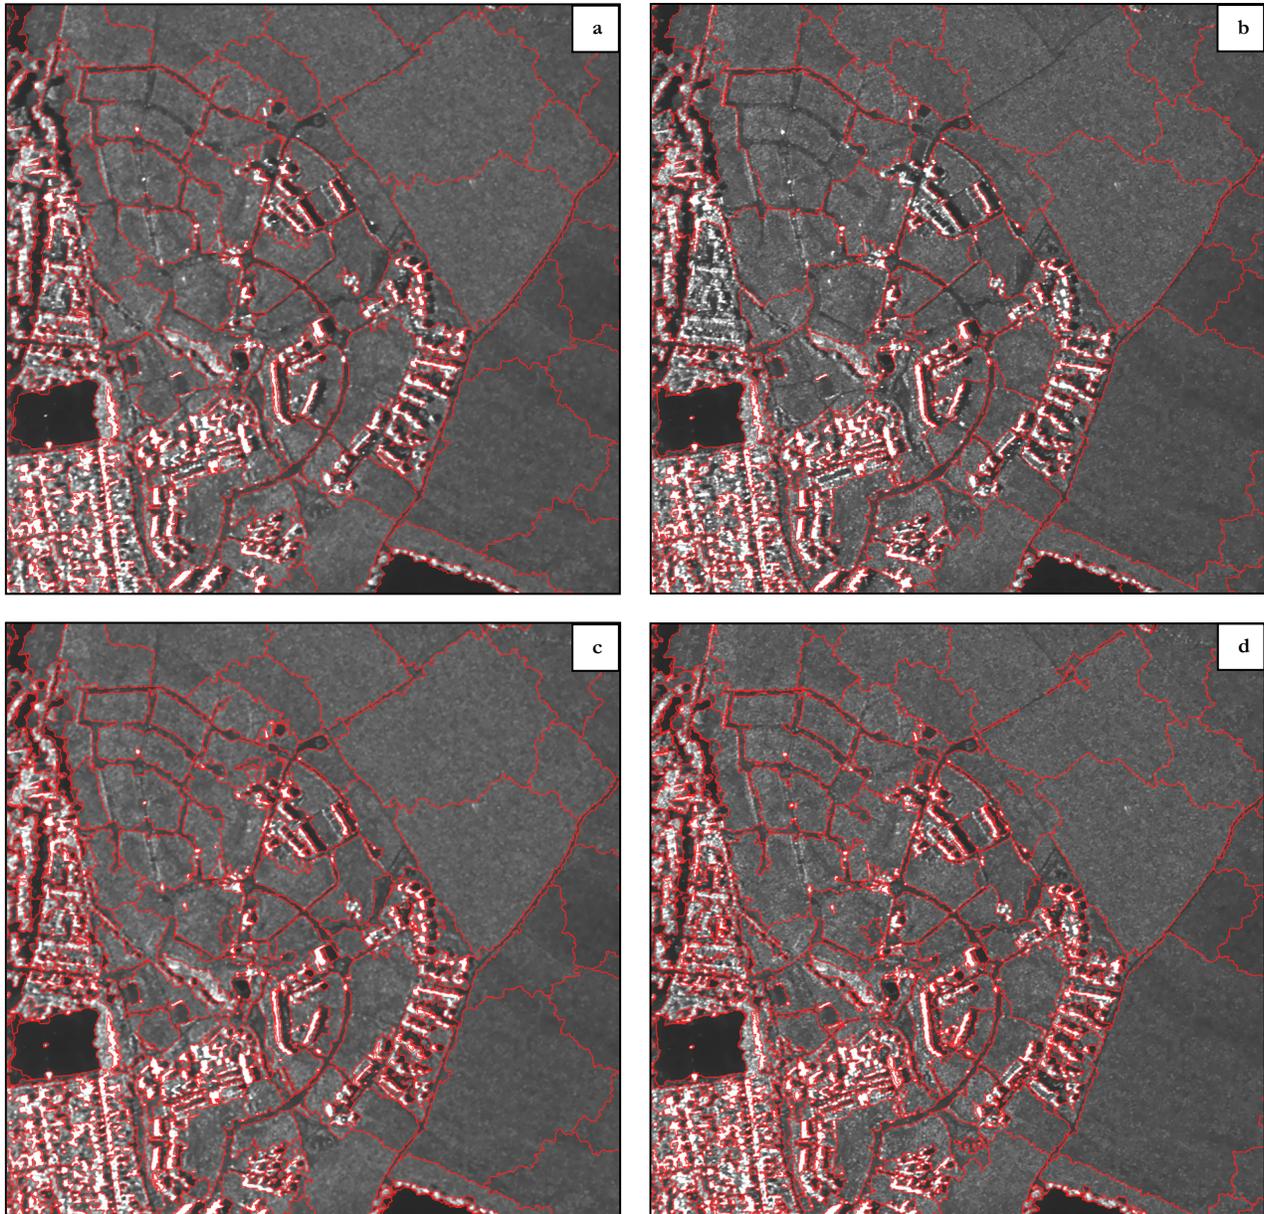


Abb. 4-16: Segmentierung eines identischen Ausschnitts mit variierender Parametrisierung basierend auf der Multiresolution Segmentation (a, b) und neu entwickelter Optimierungsprozedur (c, d) – Während im Falle der Multiresolution Segmentation bereits eine Variation der Compactness von 0.4 (a, c) auf 0.5 (b, d) zu klaren Abweichungen führt, werden unter Verwendung der Optimierungsprozedur selbst bei erheblich stärkerer Variation mehrerer Segmentierungsparameter übereinstimmendere Segmentierungen erzielt (Color: a,c = 0.5, b,d = 0.8; Compactness: a,c = 0.8, b,d = 0.3). Darüber hinaus wird ersichtlich, dass die einzelnen Objekttypen (z.B. Straßen, Häuser) im optimierten Bild akkurater erfasst und dadurch stets über Objekte mit vergleichbaren Eigenschaften repräsentiert werden.

Ein ähnliches Problem offenbart sich beim Blick auf die verhältnismäßig grob angelegte Segmentierung (c). Hier werden zwar die großflächigen Raumelemente meist durch ein einziges und damit aussagekräftiges Segment repräsentiert, gleichzeitig zeigt sich aber, dass nunmehr viele der kleinräumigen Strukturen mit den umliegenden Objekten fusioniert wurden. Dies hat zur Folge, dass die Seg-

mente mitunter verschiedene Nutzungstypen abdecken, weshalb sie im Rahmen einer automatisierten Klassifizierung kaum eindeutig zugeordnet werden dürften.



Abb. 4-17: Vergleich zwischen der Segmentierung eines hochauflösten Luftbildes (a) basierend auf der herkömmlichen Multiresolution Segmentation (b, c) und der klassenbasierten Segmentoptimierung (d) – Während auf der Basis der Multiresolution Segmentation jeweils eine separate Ebene zur Repräsentation kleiner (b) bzw. großer (c) Objekte angelegt werden muss, werden die Objekte im Kontext der Prozedur zur Segmentoptimierung direkt in ihrer optimalen Ausdehnung auf einem einzigen Level erfasst (d).

Um diesem Umstand Rechnung zu tragen, müssen auf der Basis der herkömmlichen Multiresolution Segmentation stets mehrere Objektebenen angelegt werden, deren Eigenschaften jeweils auf die akkurate Wiedergabe bestimmter Objekttypen ausgerichtet sind. Durch die Anwendung der Segmentierungsoptimierung besteht diese Notwendigkeit nicht mehr. Obwohl im Zuge der Optimierung eben-

falls nicht alle Objekte ideal repräsentiert werden, zeigt sich, dass dieser Ansatz die Strukturen dennoch weitestgehend unabhängig von ihrer Größe mittels eines individuellen Segments auf einer einzigen Ebene repräsentiert und dabei gleichsam eine deutlich zutreffendere Erfassung der Bildobjekte gewährleistet (VGL. ABB. 4-17).

Um einen quantitativen Vergleich der Güte der einzelnen Segmentierungen vornehmen zu können, wurden auf der Grundlage des zuvor betrachteten Luftbilds insgesamt 28 Objekte in ihrer idealen Form abdigitalisiert und anschließend in ihren Eigenschaften mit den automatisch generierten Segmenten abgeglichen. Dabei sind die Referenzflächen so gewählt, dass sie das gesamte Größen- und Formenspektrum urbaner Strukturen abdecken (vier Größenkategorien á sieben Beispielflächen). Die Ergebnisse dieses Vergleichs sind in TABELLE 4-1 aufgeführt.

Tab. 4-1: Vergleich der Objektgüte zwischen Multiresolution Segmentation und neu entwickelter Optimierungsprozedur

Merkmal	Multiresolution Segmentation (fein)	Multiresolution Segmentation (grob)	Optimierte Segmentierung
Referenzflächen	28	28	28
zutreffend segmentiert [%]	43	50	89
unzutreffend segmentiert [%]	57	50	11
unterteilt [%] (Ø Teilsegmente)	100 (5)	14 (2)	33 (2)
fusioniert [%] (Ø StndDev [%])	0 (-)	86 (19)	67 (7)
Abweichung Fläche [%]	40	16	17
Abweichung Umfang [%]	19	15	16
Abweichung Shape Index [%]	13	10	16
Abweichung Band 1 [%]	9	4	8
Abweichung Band 2 [%]	7	3	6
Abweichung Band 3 [%]	5	3	5

Dabei zeigt sich, dass auf der Basis der klassenbasierten Segmentoptimierung insgesamt 89 Prozent der Referenzflächen korrekt erfasst werden, sprich die entsprechenden Strukturen sind über ein individuelles Objekt adäquat repräsentiert. Von den drei unzutreffend segmentierten Objekten werden zwei (67 Prozent) fälschlicherweise mit ihrer Umgebung fusioniert und eines (33 Prozent) in Form von zwei separaten Segmenten wiedergegeben. Demgegenüber bleibt die mittels der herkömmlichen Multiresolution Segmentation erreichbare Güte mit 43 Prozent für die kleinteilige bzw. 50 Prozent für die großflächige Segmentierung deutlich hinter der Qualität der Optimierungsprozedur zurück. Dieser Qualitätsverlust lässt sich insbesondere dadurch begründen, dass die Segmentierung im Rahmen der Multiresolution Segmentation ausschließlich auf Objekte in einer bestimmten Größenord-

nung ausgerichtet werden kann. Demzufolge sind in der feinen Segmentierung zwangsläufig alle raumgreifenden Objekte in mehrere Unterobjekte aufgeteilt, während im Kontext der groben Segmentierung insbesondere kleinräumige Strukturen mit ihrer Umgebung fusioniert werden.

In der Statistik ist dieser Effekt daran zu erkennen, dass im Rahmen der kleinteiligen Segmentierung sämtliche unzutreffend erfassten Referenzareale zu stark unterteilt werden, wobei sich die Anzahl der Unterobjekte auf durchschnittlich fünf Segmente beläuft. Das gegenteilige Phänomen zeigt sich im Zusammenhang mit der großflächigen Segmentierung. Hier werden 86 Prozent der unzutreffend segmentierten Referenzareale nicht über ein eigenständiges Segment repräsentiert, sondern mit ihrer Umgebung fusioniert. Dies betrifft im Speziellen sehr kleine Objekte, die sich allerdings spektral mitunter erheblich voneinander unterscheiden. Ein solcher Effekt kann im Zusammenhang mit der optimierten Segmentierung nur in begrenztem Umfang auftreten, da hier die spektrale Ähnlichkeit das ausschlaggebende Bewertungskriterium zur Modifizierung der Segmente darstellt. Dieser Umstand lässt sich unter anderem dadurch belegen, dass die Grauwerte der fälschlicherweise fusionierten Objekte beim herkömmlichen Ansatz durchschnittlich um 19 Prozent vom Mittelwert abweichen, während die durchschnittliche Standardabweichung fusionierter Segmente beim optimierten Verfahren lediglich sieben Prozent beträgt – d.h. die spektrale Ähnlichkeit zwischen den einzelnen Elementen ist sichtlich höher.

Neben den zuvor beschriebenen Genauigkeiten wurde darüber hinaus die Güte der Segmente im Hinblick auf ihre flächenmäßige, formbezogene und spektrale Qualität beurteilt. In diesem Zusammenhang sei angemerkt, dass diese Eigenschaften ausschließlich auf der Basis der korrekt segmentierten Objekte ermittelt wurden. Folglich finden in Bezug auf die Qualität der kleinteiligen Segmentierung überwiegend kleine Objekte Berücksichtigung, während im Kontext der groben Segmentierung vorwiegend mittlere bis große Objekte betrachtet werden. Dabei hat sich generell gezeigt, dass die zutreffend erfassten Referenzflächen bei allen drei Segmentierungen mit einer vergleichbaren Güte repräsentiert werden. Die besten Werte weist die grobe Segmentierung auf. Hier dürfte jedoch der Umstand eine Rolle spielen, dass die Bewertung in diesem Fall nahezu ausschließlich auf großen Segmenten beruht. Daher wirken sich Abweichungen von einigen Pixeln weit weniger drastisch auf die Statistik des Segments aus als dies bei der kleinteiligen Segmentierung der Fall ist. Letzteres dürfte auch die starke flächenbezogene Abweichung der feinen Segmentierungsebene von durchschnittlich 40 Prozent gegenüber der Größe der Referenzobjekte erklären.

Wie der quantitative Vergleich gezeigt hat, ergibt sich der entscheidende Vorteil des Optimierungsverfahrens vor allem aus der Eigenschaft, die multiskalige Segmentierung von der starren Struktur einzelner Segmentierungsebenen zu lösen. Damit wird die Möglichkeit eröffnet, sämtliche Bildobjekte flexibel, d.h. unabhängig von ihrer räumlichen Ausdehnung, zu erfassen und gleichzeitig auf einem einzigen Segmentierungslevel bereitzustellen. Zwar ließe sich eine solche Segmentierung theoretisch auch auf dem herkömmlichen Weg durch die Fusion mehrerer Segmentierungsebenen realisieren, allerdings wäre dazu eine vorgeschaltete thematische Klassifizierung erforderlich. Dabei ist ein Regelwerk zur Klassifizierung thematischer Klassen mit deutlich höheren Unsicherheiten bzw. Fehlern behaftet als eine Wissensbasis, die auf relativen und damit flexiblen und robusten Ähnlichkeitsmaßen basiert.

Die Fähigkeit, sämtliche Bildobjekte auf einem einzigen Segmentierungslevel zu präsentieren, bietet speziell im Hinblick auf die Klassifizierung entscheidende Vorteile. Zum einen wird gewährleistet, dass die spektralen und formbezogenen Eigenschaften der einzelnen Objekttypen weitestgehend die tatsächliche Charakteristik der Struktur widerspiegeln. Dadurch erhöht sich einerseits die Aussagekraft und Übertragbarkeit der zur Beschreibung der Objekte bereitgestellten Merkmale zur Klassenkennzeichnung. Darüber hinaus entfällt die Notwendigkeit, zur Identifizierung bestimmter Klassen gegebenenfalls die Objekteigenschaften mehrerer Segmentierungsebenen miteinander verknüpfen zu müssen. Dadurch lassen sich die Komplexität und somit auch die Laufzeit der Klassifizierung merklich reduzieren. Zudem ist der Anwender von der überaus schwierigen Aufgabe befreit, im Vorfeld einer Klassifizierung die optimale Anzahl und Eigenschaft der Segmentierungsebenen definieren zu müssen.

Betrachtet man die *Schwierigkeiten im Kontext der Optimierung*, so tritt hervor, dass die entwickelte Technik insbesondere dann an ihre Grenzen stößt, wenn ein Superobjekt sehr wenige Subobjekte aufweist, die zwar unterschiedliche Bedeckungsarten repräsentieren, jedoch in etwa identische Anteile an der Fläche des übergeordneten Segmentes einnehmen. Letzteres resultiert in einer gleichteiligen Mischung der spektralen Signaturen, weshalb in diesem Fall keines der einzelnen Unterobjekte signifikant von der spektralen Charakteristik des Superobjektes abweicht. In der Folge wird das betreffende Superobjekt oftmals nicht modifiziert, d.h. die Subobjekte bleiben trotz ihrer spektralen Gegensätze fusioniert. Allerdings hat sich gezeigt, dass eine Nutzung der bereits erwähnten, flächenbezogenen Merkmalskombination aus *relativem Anteil des Subobjektes an der Fläche des zugehörigen Superobjektes* und der *prozentualen Abweichung in der Helligkeit und spektralen Signatur* an dieser Stelle hilfreich sein kann (VGL. KAP. 4.1.2.2). So ist es möglich, die beiden Schwellwerte zur Beschreibung der spektra-

len Ähnlichkeit herabzusetzen, wenn das betreffende Subobjekt eine große relative Fläche des Superobjektes einnimmt. Somit erfolgt die Korrektur in diesem speziellen Fall bereits bei einer etwas geringeren spektralen Differenz, wodurch sich der zuvor geschilderte Effekt zu einem gewissen Grad kompensieren lässt.

Eine vergleichbare Schwierigkeit ergibt sich zudem aus der Tatsache, dass der Optimierungsprozess ausschließlich auf der Berücksichtigung spektraler Merkmale beruht. Dabei kommt es durchaus vor, dass die Strukturen oder Objekttypen weniger spektral als vielmehr in ihrer Textur differieren. Dies legt eine Ergänzung der spektralen Attribute durch entsprechende Texturmerkmale nahe, was technisch ohne weiteres umsetzbar wäre. Aus Zeitgründen konnte dieser Ansatz jedoch nicht weiter verfolgt werden.

Abschließend sei darauf verwiesen, dass die verfahrenstechnische Auslegung der Optimierungsprozedur die Ableitung texturbezogener Merkmale einschränkt. So setzen sich bestimmte Landbedeckungs- bzw. Landnutzungstypen aus einer Vielzahl individueller Strukturen zusammen, die sich spektral sehr stark voneinander abheben. Die räumliche Anordnung dieser Einzelobjekte ergibt dabei oftmals eine charakteristische Musterung oder Textur, die letztlich das entscheidende Merkmal zur Identifizierung des betreffenden Nutzungs- bzw. Bedeckungstyps darstellt. Eine solche Strukturierung kann mittels geeigneter Texturmaße beschrieben werden, die zudem zeitlich und räumlich vergleichsweise stabile Merkmale darstellen. Daher sind diese speziell im Hinblick auf die automatisierte Klassifizierung von besonderem Interesse (VGL. KAP. 2.1.3).

Um die Textur einer Fläche effektiv beschreiben zu können, müssen die einzelnen Strukturprimitive in ihrer Gesamtheit erfasst bzw. betrachtet werden. Dies wird im Kontext eines objektorientierten Vorgehens dadurch erreicht, dass die entsprechenden Raumeinheiten – beispielsweise eine Siedlungsfläche – von Objekten repräsentiert werden, die alle Einzelstrukturen (z.B. Häuser, Bäume, Straßen) in einem Segment einschließen. Die Methodik der Optimierungsprozedur hingegen ist auf die Extraktion spektral homogener Objekte ausgerichtet. Demzufolge werden die heterogen zusammengesetzten Siedlungsflächen im Rahmen der Optimierung stets in ihre strukturellen Primitive zerlegt. Folglich wird das betreffende Areal nicht durch flächendeckende Segmente beschrieben – wie es eine Multiresolution Segmentation mit hohem Scale Parameter erlauben würde –, sondern jede spektral eigenständige Struktur innerhalb des Siedlungskörpers wird vielmehr über ein individuelles und damit spektral homogenes Objekt repräsentiert. Somit kann auf der Basis der optimierten Segmentierung keine Texturinformation abgeleitet werden.

Eine Lösung dieses Problems besteht darin, im Anschluss an die Optimierungsprozedur über der resultierenden Objektebene mittels der herkömmlichen Multiresolution Segmentation ein zweites Level mit großflächigen Segmenten anzulegen. Auf der Basis dieser Segmentierung können dann im Rahmen der Klassifizierung bei Bedarf texturbezogene Merkmale abgeleitet werden.

4.1.3 Zusammenfassung

Effizienz und Qualität einer objektorientierten Bildauswertung hängen maßgeblich von der Güte der Segmentierung ab. In diesem Kontext konnten zwei zentrale Faktoren identifiziert werden, die das Nutzungspotential einer segmentbasierten Auswertung mitunter nachhaltig einschränken. Hier ist zum einen der SAR-spezifische *Speckle-Effekt* zu nennen, der die charakteristische Textur eines SAR-Bildes als störendes Rauschen überlagert. Dadurch wird einerseits die Möglichkeit zur Berechnung bzw. dem Gebrauch aussagekräftiger Texturinformationen limitiert und andererseits die akkurate Segmentierung der abgebildeten Bildinhalte erschwert. Dabei hat sich im Hinblick auf eine Reduktion des SAR-Speckle gezeigt, dass weiterhin Optimierungsbedarf hinsichtlich einer strukturerhaltenden Bildglättung besteht. Eine zweite Limitierung bezüglich der objektorientierten Bildauswertung resultiert aus dem Umstand, dass die Multiresolution Segmentation unter eCognition ein *zeitintensives Trial-and-Error-Vorgehen* erfordert. Darüber hinaus können bereits moderate Variationen in den Segmentierungsparametern oder den Bildeigenschaften zu signifikant veränderten Resultaten in der Segmentierung führen. In der Folge werden die *Praktikabilität und Übertragbarkeit des objektorientierten Verfahrens* merklich eingeschränkt. Vor diesem Hintergrund galt der erste Schwerpunkt dieser Dissertation der Entwicklung neuer Ansätze zur Stabilisierung und Optimierung der objektorientierten Auswertung.

Um eine effizientere, d.h. strukturerhaltende Minimierung des Speckle-Effektes zu gewährleisten, wurde zu Beginn ein neuer *Filteralgorithmus zur strukturerhaltenden Bildglättung* entwickelt. Der dabei konzipierte SelectiveMean-Filter zeichnet sich insbesondere durch eine *flexible Adaption der Filterstärke an die lokale Textur* der zu filternden Bildareale aus. Durch diese Eigenschaft kann in homogenen Bereichen der Aufnahme eine signifikante Reduktion des Bildrauschens erzielt werden, während der Detaillierungsgrad hochstrukturierter Raumeinheiten weiterhin erhalten bleibt. Wie ein Vergleich mit etablierten Filtertechniken erbracht hat, lässt sich das Bildrauschen in homogenen Arealen gegenüber den bereits vorhandenen Algorithmen um weitere 30 bis 50 Prozent reduzieren. Gleichsam kann der glättende Einfluss in hochstrukturierten Arealen gegenüber den etablierten Verfahren um rund 70 bis

80 Prozent verringert werden. Ferner konnte belegt werden, dass signifikante Kanten im Kontext einer Bildglättung auf Basis des SelectiveMean-Filters nur minimal modifiziert werden.

Somit zeigt die quantitative Betrachtung der Filterwirkung, dass der SelectiveMean-Algorithmus eine effiziente Anpassung der Bildglättung an die lokale Textur ermöglicht. Dabei wird die glättende Wirkung insbesondere dort herabgesetzt, wo eine signifikante Textur der betrachteten Oberfläche auf eine reell vorhandene Strukturierung hindeutet. Durch die Homogenisierung schwach strukturierter Raumeinheiten unter gleichzeitiger Wahrung der hochfrequenten Informationen wird zudem die akkurate Erfassung der einzelnen Raumeinheiten im Kontext der Segmentierung verbessert. Abschließend konnte gezeigt werden, dass sich der entwickelte Filteralgorithmus auch zur Aufwertung optischer Datensätze eignet.

Zur *optimierten Segmentierung unter eCognition* wurde ein klassenbasierter Segmentierungsablauf entwickelt, der auf der Basis eines einfach strukturierten Regelwerks die schnelle und akkurate Segmentierung der Bilddaten gewährleisten soll. Die erarbeitete Prozedur kombiniert die Multiresolution Segmentation mit der Funktionalität einer merkmalsbasierten Klassifizierung bzw. klassenbasierten Segmentoptimierung. Auf diese Weise wird die Steuerung der Segmentierung von der Multiresolution Segmentation auf eine wissensbasierte Klassifikation verlagert. Dies eröffnet die Möglichkeit, die Bildobjekte unabhängig von ihrer räumlichen Ausdehnung zu erfassen. Dadurch wird die Bindung der multiskaligen Objektgenerierung an die starre Struktur einzelner Segmentierungsebenen aufgehoben, so dass sämtliche Objekte in ihrer charakteristischen räumlichen Ausprägung auf einem einzigen Segmentierungslevel bereitgestellt werden. Dies gewährleistet eine verbesserte Charakterisierung der spektralen und formbezogenen Eigenschaften und erhöht somit die Aussagekraft und Übertragbarkeit von Merkmalsbeschreibungen zur Klassenkennzeichnung. Gleichzeitig entfällt die Notwendigkeit, im Rahmen der Klassifizierung mehrere Segmentierungsebenen miteinander verknüpfen zu müssen, was die Komplexität der Auswertung merklich reduziert. Im Hinblick auf eine Datenbasis aus verschiedenen Datentypen lässt sich die Optimierung durch eine Verknüpfung mehrerer Optimierungsabläufe individuell an die Eigenschaften jedes einzelnen Datensatzes anpassen.

Der Ablauf der Optimierungsprozedur ist in Form eines unter eCognition angelegten Protokolls abgelegt. Dabei ist das Optimierungsverfahren grundsätzlich so konzipiert, dass eine schnelle und einfache Anpassung der Einstellungen an unterschiedliche Eingangsdaten (SAR, optisch, thematisch) gewährleistet ist. Auf der Basis dieser Funktionalität kann der erforderlichen Arbeits- und Zeitaufwand zur Erstellung einer hinreichend genauen Segmentierung merklich reduziert werden. Wie ein

quantitativer Vergleich zwischen herkömmlicher und optimierter Segmentierung zeigt, gewährleistet die Optimierungsprozedur eine akkuratere Erfassung der Bildstrukturen. Diese Eigenschaft resultiert nicht zuletzt aus einer erhöhten Robustheit gegenüber der Veränderung von Segmentierungsparametern oder Variationen in der Bildqualität. Schwierigkeiten hinsichtlich der Optimierung treten vor allem dann auf, wenn wenige, spektral unterschiedliche Segmente in etwa identische Flächenanteile des Superobjektes einnehmen und sich die Subobjekte dadurch kaum von der spektralen Signatur des übergeordneten Segments abheben.

4.2 Erfassung von Siedlungsflächen und Ableitung einfacher Landnutzungstypen

Grundsätzlich setzt die Entwicklung der Methodik zur Erfassung besiedelter Flächen und weiterer Landnutzungsklassen auf der Auswertung einfach-polarisierter Radardaten auf, da dieser Datentyp von nahezu sämtlichen SAR-Systemen bereitgestellt wird. Das erforderliche Regelwerk wird zunächst auf der Basis eines repräsentativen Ausschnitts einer HH-polarisierten E-SAR X-Band Aufnahme erarbeitet. Im Anschluss an die Fertigstellung dieses Regelwerks wird die Wissensbasis auf die gesamte Fläche der drei Flugstreifen des X-Bandes angewendet, um die räumliche Übertragbarkeit und inhaltliche Robustheit der Methodik zu überprüfen. Darüber hinaus wird das Regelwerk auf C- und L-Band Aufnahmen transferiert. Auf diese Weise soll geklärt werden, in welchem Umfang sich der konzipierte Ansatz auf unterschiedliche Frequenzen abbilden lässt.

Mit Blick auf zukünftige Anwendungs- und Datenszenarien werden in einem zweiten Unterkapitel der Nutzen einer *Integration zusätzlicher Polarisierungen und Frequenzen*, aber auch die Möglichkeit der *Kombination mit optischen Daten* untersucht. Zu diesem Zweck muss das Segmentierungskonzept an eine *mehrdimensionale Datenbasis* angepasst und das zuvor entwickelte Regelwerk durch entsprechende Merkmale ergänzt werden.

Im dritten Teil dieses Kapitels werden die erzielten Ergebnisse schließlich quantitativ und qualitativ bewertet und umfassend diskutiert.

Der letzte Abschnitt fasst noch einmal die wichtigsten Aspekte hinsichtlich einer Erfassung der Siedlungsflächen bzw. regionalen Ableitung der Landnutzung in kompakter Form zusammen.

4.2.1 Auswertung einfach-polarisierter SAR-Aufnahmen

4.2.1.1 Segmentierungskonzept

Die Segmentierung im Kontext der Identifizierung besiedelter Areale ist auf die Generierung von *drei Objektebenen* ausgerichtet (VGL. TAB. 4-2). Die geringe Anzahl an Segmentierungsleveln soll gewährleisten, dass die Komplexität des nachfolgend zu definierenden Regelwerks bzw. Klassifikationsablaufs möglichst gering gehalten wird. Als Datenbasis dienen ein geglättetes *Intensitätsbild* (*Int_filt*) sowie die daraus abgeleitete *Textur* (*Int_filt_tex*) in Form der Varianz (7x7 Pixel). Letztlich hat sich im Rahmen der Segmentierung gezeigt, dass neben der Verwendung geglätteter Radardaten (VGL. KAP. 4.1.1) auch die Nutzung von 8-bit kodierten Daten gegenüber der 16-bit Formatierung zu besseren Ergebnissen in der Segmentierung von SAR-Aufnahmen führt. Dieser Effekt dürfte auf den Umstand zurückzuführen sein, dass die mit der Komprimierung des Farbraums von 16-bit auf 8-bit einhergehende Reduzierung des Dynamikbereichs die Arbeit des Region-Growing-Algorithmus erleichtert.

Der *Segmentierungsablauf* umfasst einerseits die Generierung mehrerer, unterschiedlich skaliertes Segmentierungsebenen auf der Basis der herkömmlichen Multiresolution Segmentation und andererseits die bereits in KAPITEL 4.1.2 erörterte, klassenbasierte Segmentoptimierung. Mit Hilfe dieses Optimierungsansatzes wird ein *erstes Objektlevel* (*Optimierungsebene*) generiert, auf dessen Segmenten später das Gros der Klassifizierung basiert. Dabei umfasst der Ablauf der Optimierungsprozedur insgesamt *sechs Iterationen*, wobei im Rahmen der Multiresolution Segmentation zwischen jedem Durchlauf die Größe des Scale Parameters kontinuierlich gesteigert wird (VGL. TAB. 4-2). Die Gewichtung der Farbinformation beträgt *0.7*, was einer zu starken Zerklüftung der Segmentränder vorbeugen soll.

Während der ersten Iterationen beruht die Segmentierung einzig auf der Intensitätsaufnahme, während mit steigender Objektgröße schließlich auch der Texturlayer Verwendung findet (VGL. TAB. 4-2). Die relative Gewichtung der Textur gegenüber der Intensität wird fortan stetig erhöht. Dieses Vorgehen liegt darin begründet, dass sich flächendeckende Strukturen mit steigender Objektgröße verstärkt durch die Ausprägung struktureller Merkmale unterscheiden, während deren Reflektionscharakteristik zunehmend an Aussagekraft verliert. Damit kann die Textur mit steigender Objektgröße einen wichtigen Beitrag zur adäquaten Abgrenzung der räumlichen Strukturen leisten.

Tab. 4-2: Einstellungen zur Segmentierung einfach-polarisierter E-SAR-Aufnahmen

Segmentierungsablauf*			Layer** (Gewichtung)	Scale Parameter	Color	Compactness	
Level 2 (Optimierungsebene)	Segmentierungsoptimierung	1. Iteration	BL	Int_filt (1)	20	0,7	0,5
			OL	Int_filt (1)	40	0,7	0,5
	2. Iteration (OL)		Int_filt (1)	60	0,7	0,5	
	3. Iteration (OL)		Int_filt (4) Int_filt_tex (1)	80	0,7	0,5	
	4. Iteration (OL)		Int_filt (3) Int_filt_tex (1)	120	0,7	0,5	
	5. Iteration (OL)		Int_filt (2) Int_filt_tex (1)	160	0,7	0,5	
	6. Iteration (OL)		Int_filt (1) Int_filt_tex (1)	200	0,7	0,5	
Level 3 (Texturebene)			Int_filt (1) Int_filt_tex (1)	260	0,8	0,6	
Level 1 (Korrekturbene)			Int_filt (1)	40	0,8	0,5	
* : BL = Basislevel; OL = Optimierungslevel							
** : Int_filt: geglättetes Intensitätsbild ; Int_filt_tex: Texturbild (Varianz 7x7), berechnet auf Basis von gefilterter Intensität							

Zur klassenbasierten Modifikation der jeweils erstellten Optimierungsebene werden die im entsprechenden Regelwerk definierten Ähnlichkeitsmaße zwischen unter- und übergeordnetem Level ausschließlich auf der Basis des Intensitätsbildes berechnet, während die Texturinformation an dieser Stelle keine Berücksichtigung findet. Die letztlich aus der Optimierungsprozedur resultierende Segmentierungsebene ist in ABBILDUNG 4-18C dargestellt.

Dabei ist deutlich zu erkennen, dass homogene Freiflächen durch entsprechend große Segmente repräsentiert werden, während sich heterogene Areale – in diesem Fall vertreten durch eine Siedlungsfläche – aus einer Vielzahl kleiner Objekte zusammensetzen. Dieses Charakteristikum hat sich als überaus robust erwiesen. Daher kann die durchschnittliche Größe der optimierten Segmente im Kontext der späteren Klassifizierung als effizientes Merkmal zur Identifizierung stark strukturierter Flächen genutzt werden (VGL. KAP. 4.2.1.2).

Wie bereits im Zusammenhang mit der Bewertung des klassenbasierten Optimierungsverfahrens erwähnt, schränkt diese verfahrensbedingte Eigenschaft allerdings gleichzeitig die Ableitung texturbezogener Merkmale deutlich ein (VGL. KAP. 4.1.2.3). Um dennoch die Berechnung bzw. Nutzung dieser zeitlich und räumlich vergleichsweise stabilen Attribute zu gewährleisten, wird die optimierte Segmentierungsebene durch eine übergeordnete *Texturebene* ergänzt (VGL. TAB. 4-2). Dieses Objektlevel wird auf dem herkömmlichen Wege über die Multiresolution Segmentation erzeugt und besteht auch

in heterogenen Bildarealen aus vergleichsweise großflächigen Segmenten (vgl. Abb. 4-18). Das Intensitätsbild und der Texturdatensatz (Varianz 7×7) fließen in diesem Fall jeweils mit gleicher Gewichtung in die Segmentierung ein, wobei die Farbinformation und Kompaktheit gegenüber den Einstellungen im Rahmen der Segmentierungsoptimierung etwas stärker gewichtet werden.

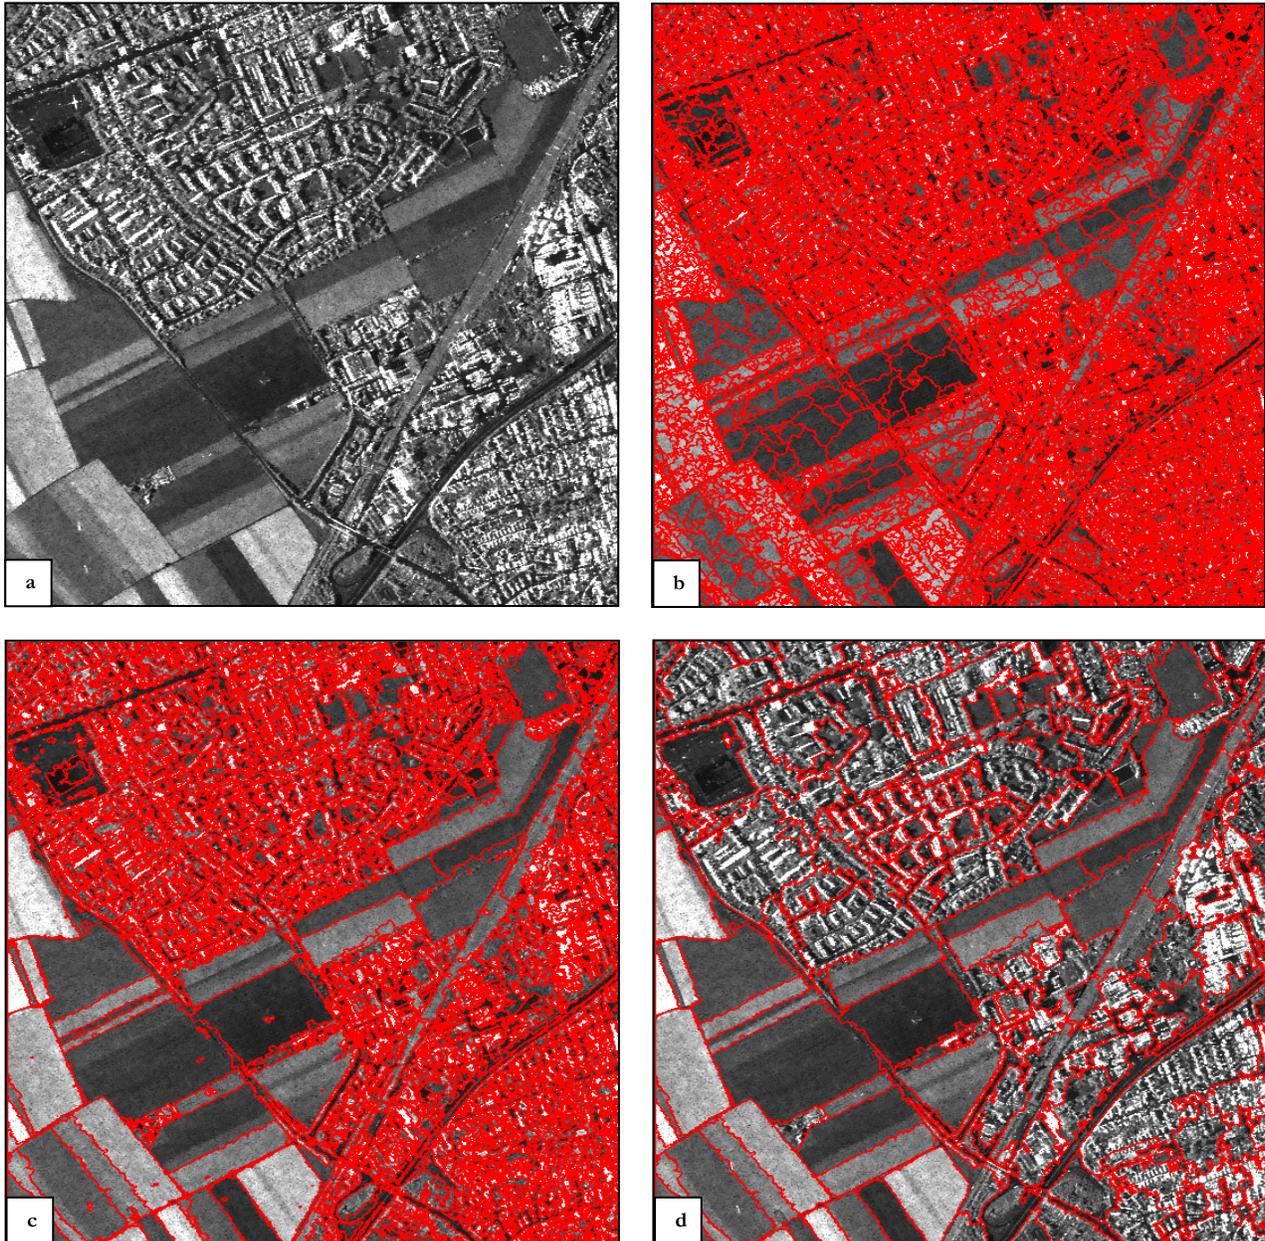


Abb. 4-18: Korrektorebene (b), Optimierungsebene (c) und Texturebene (d) als Basis zur Klassifizierung von Siedlungsflächen – Die Optimierungsebene dient als Basis zur Klassifizierung. Da bebauter Areale durch kleinräumige Segmente repräsentiert werden und homogene Freiflächen durch große Objekte gekennzeichnet sind, wird diese Charakteristik im Rahmen der Klassifizierung als robustes Merkmal zu Identifizierung bebauter Areale eingesetzt. Demgegenüber wird die Texturebene zur Ableitung texturbezogener Attribute verwendet, während die Korrektorebene zur Verbesserung und thematischen Erweiterung der Klassifizierung dient.

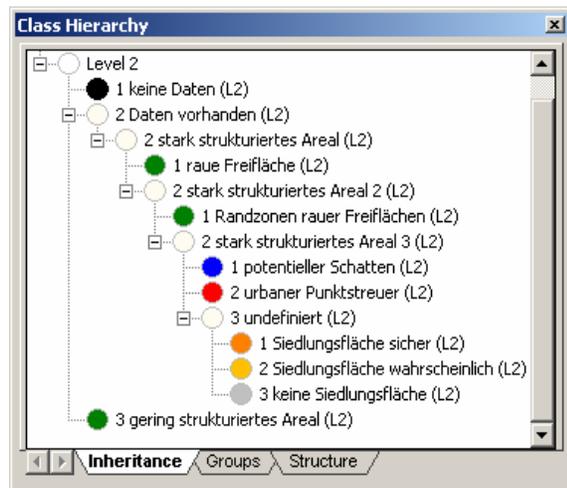
Zum Schluss wird unterhalb der Optimierungsebene ein drittes Segmentierungsniveau mit sehr kleinen Segmenten generiert (VGL. TAB. 4-2). Diese Objektebene wird im Verlauf der späteren Klassifizierung als abschließendes *Korrekturlevel* dienen und soll unter anderem Klassifikationsungenauigkeiten kompensieren, die aus unzutreffend optimierten Segmenten resultieren (VGL. KAP. 4.2.1.2). Darüber hinaus wird auf dieser Ebene eine thematische Erweiterung der zuvor auf der Optimierungsebene erstellten Klassifizierung erfolgen.

4.2.1.2 Regelwerk und Klassifizierung

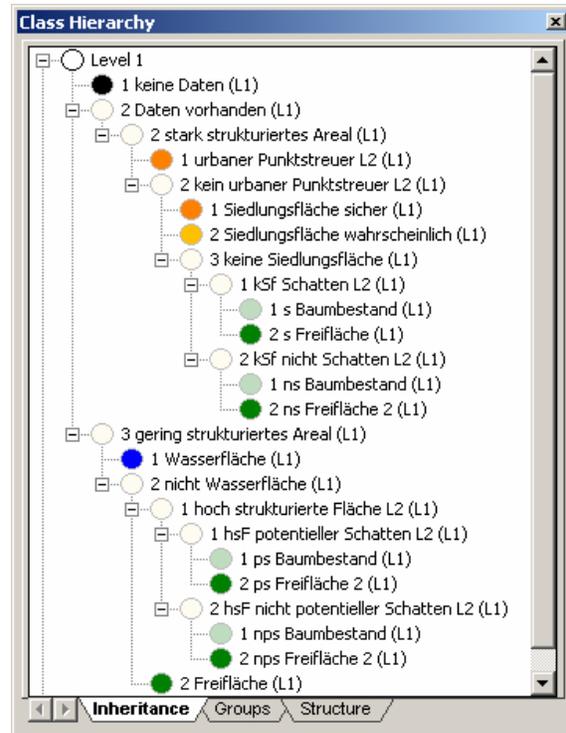
Wie bereits im vorangegangenen Kapitel erwähnt, liegen dem Regelwerk zur Erfassung der besiedelten Areale drei Objektebenen zu Grunde. Dabei beginnt der Klassifikationsprozess mit einer Analyse der *Optimierungsebene* (Level 2), auf der die *Identifizierung der Siedlungsflächen* erfolgt. In diesem Kontext finden unter anderem Merkmale Verwendung, die auf der Basis von Segmenten der übergeordneten *Texturebene* (Level 3) berechnet werden. Die Texturebene als solche wird jedoch nicht klassifiziert. In einem zweiten Auswertungsschritt findet auf der untergeordneten *Korrekturebene* (Level 1) eine *Verbesserung* der zuvor auf Level 2 erzielten Klassifizierung statt. Dabei ist die Klasseneinteilung gleichzeitig so definiert, dass sie eine weitere *thematische Differenzierung* in vereinfachte Landnutzungsklassen ermöglicht.

ABBILDUNG 4-19 zeigt den Klassifizierungsbaum, welcher dem zuvor beschriebenen Klassifikationsablauf zu Grunde liegt. Das Grundprinzip der Siedlungserfassung und die dabei verwendeten Merkmale zur Kennzeichnung der einzelnen Klassen werden im Folgenden ausführlich dargelegt.

Oberstes Ziel im Rahmen der Erstellung des Regelwerks zur Siedlungserfassung ist die zeitliche und räumliche Übertragbarkeit des Ansatzes. Unter dieser Prämisse ist es zwingend erforderlich, zur Beschreibung der jeweiligen Klassen ausschließlich Merkmale zu verwenden, die in ihren Eigenschaften möglichst geringen räumlichen und zeitlichen Schwankungen unterliegen. Abgesehen von texturbezogenen Attributen werden dabei alle eingesetzten Kriterien ausschließlich auf der Basis der Originalaufnahmen definiert bzw. berechnet. Dadurch soll vermieden werden, dass sich aus einer variierenden Vorverarbeitung der Bilddaten (z.B. Speckle-Filterung) Schwankungen in den Merkmalsausprägungen ergeben, die letztlich die Klassifizierung beeinflussen könnten. Somit liegen der Klassifizierung letztlich drei Datensätze zu Grunde: das geglättete und auf 8-bit konvertierte Intensitätsbild, der daraus abgeleitete Texturlayer (Varianz 7x7) und die ursprüngliche 16-bit Intensitätsaufnahme.



Siedlungserfassung (Level 2)



Korrektur und thematische Erweiterung (Level 1)

Abb. 4-19: Hierarchischer Klassifizierungsbaum zur Erfassung von Siedlungsflächen auf der Basis einfachpolarisierter SAR-Aufnahmen

Im Kontext der *Erfassung von Siedlungsflächen* bietet sich die Analyse räumlicher Charakteristika an, die durch die hohe mesoskalige Rauigkeit der urbanen Umwelt geprägt werden (VGL. KAP. 4.2.4). So rufen die abrupten Höhen- und Neigungsunterschiede zwischen den einzelnen Häusern, Straßen, Freiflächen, Masten oder Bäumen eine spezifische Strukturierung der SAR-Aufnahme hervor, die sich in einer prägnanten Textur widerspiegelt. Wie bereits in ABBILDUNG 2-9 illustriert wurde, äußert sich diese charakteristische Musterung vor allem durch ein *enges Nebeneinander* von extrem *hellen Reflektionszentren* und sehr *dunklen Schattenflächen* (VGL. KAP. 2.2.3). Diese enorme Heterogenität im Reflektions- bzw. Streuverhalten ist ein raum-zeitlich überaus *stabiles Charakteristikum* von Siedlungsflächen und bildet daher das Kernelement der im Folgenden beschriebenen Identifizierung besiedelter Areale.

Nach der Abgrenzung jener Bildbereiche, die *keine Daten* enthalten, wird das hierarchisch aufgebaute Regelwerk zu Beginn auf die *Erfassung stark strukturierter Bildareale* ausgerichtet (VGL. ABB. 4-19). Sämtliche Segmente, die dabei nicht als heterogene Bereiche identifiziert werden, gelten als *gering strukturiertes Areal*. Bereits in KAPITEL 4.2.1.1 wurde darauf hingewiesen, dass die mittlere Segmentgröße der optimierten Objekte diesbezüglich ein sehr aussagekräftiges und robustes Merkmal darstellt. Auf Level 2 werden folglich zur Klassifizierung stark strukturierter Bildbereiche zunächst Attribute ge-

nutzt, die sich zur Beschreibung der durchschnittlichen Segmentgröße eignen. Dazu zählen die mittlere Größe der Subobjekte auf Level 2, abgeleitet von den großflächigen Segmenten der übergeordneten Texturebene, die durchschnittliche Größe der Objekte in einer Nachbarschaft von 25 Pixeln sowie die gemittelte Größe der Subobjekte auf Level 1. Ferner werden Texturmerkmale (Varianz, Kontrast) eingesetzt, die ebenfalls auf Basis der übergeordneten Segmentebene berechnet werden.

Eine besondere Schwierigkeit im Kontext der Erfassung heterogener Bildbereiche stellt die Ausgrenzung spezifischer Ackerflächen dar, die aufgrund einer rauen Oberflächenbeschaffenheit eine sehr hohe und gleichsam stark variierende Rückstreuung aufweisen. Daher werden zur Identifizierung dieser Problemflächen zwei weitere Klassen - *raue Freifläche* sowie *Randzonen rauer Freiflächen* - angelegt, die neben der Intensität vornehmlich auf textur- und formbezogene Merkmale zurückgreifen (VGL. ABB. 4-19). ABBILDUNG 4-20b zeigt das Resultat der klassenbasierten Einteilung in *gering* bzw. *stark strukturierte Bildareale*. Dabei ist gut zu erkennen, dass die grau dargestellten, stark strukturierten Zonen grundsätzlich drei Oberflächentypen umfassen: Siedlungsbereiche, Baumbestände und Ackerflächen mit hoher Oberflächenrauigkeit.

Zur Trennung dieser drei Kategorien ist daher eine weitere Differenzierung innerhalb der entsprechenden Regionen erforderlich. Ausgehend von der Annahme, dass sich Siedlungen in der SAR-Aufnahme durch das gleichzeitige Auftreten zahlreicher Double-Bounce-Reflektionen (Corner-Reflektoren) und Schattenflächen auszeichnen, werden in einem ersten Schritt *potentielle Schatten* sowie *urbane Punktstreuer* klassifiziert (VGL. ABB. 4-19). Die *potentiellen Schattenflächen* sind dabei durch niedrige Intensitätswerte, eine hohe relative Grenzfläche zu helleren Objekten, einen niedrigen Ratio der Intensität zu ihren Nachbarn sowie eine formabhängige, maximale Größe definiert. *Urbane Punktstreuer* kennzeichnen sich demgegenüber durch extrem hohe Werte in der Intensität und lokalen Varianz, eine punkt- oder linienhafte Form sowie das Vorkommen mehrerer Schattenflächen in ihrer näheren Umgebung. Letzteres hat sich als effizientes Merkmal zum Ausschluss oberirdisch verlegter, metallischer Leitungssysteme auf bewässerten Feldern erwiesen, die in siedlungstypischer Dichte als starke Streuzentren in Erscheinung treten. Im Gegensatz zu tatsächlichen Siedlungssegmenten fehlen auf derartigen Flächen jedoch die typischen Schatten. Sämtliche Segmente, die nicht den Merkmalsbeschreibungen der *Punktstreuer* oder *Schattenflächen* entsprechen, werden der Kategorie *undefiniert* zugeordnet. Das Klassifizierungsergebnis auf der Basis der dargelegten Hierarchieebene des Regelwerks ist in ABBILDUNG 4-20c dargestellt.

Im Anschluss an die Ausweisung *potentieller Schattenflächen* und *urbaner Punktstreuer* kann die eigentliche Erfassung der Siedlungsflächen beginnen. Dazu wird das Regelwerk um die beiden Klassen *Siedlungsfläche sicher* und *Siedlungsfläche wahrscheinlich* ergänzt. Als entscheidendes Kriterium zur Identifizierung besiedelter Areale gilt das gleichzeitige Vorkommen von Schattenflächen und Punktstreuern. So tritt im Kontext stark strukturierter Ackerflächen mitunter eine hohe Anzahl an Punktstreuern in Erscheinung, allerdings kommen dort im Allgemeinen keine Schattensegmente vor. Waldflächen und Heckensäume wiederum weisen eine deutlich größere Menge an Schattenflächen auf, allerdings ist hier das Aufkommen punkt- oder linienförmiger Streuer vergleichsweise gering (VGL. ABB. 4-20d).

Daher werden *sichere Siedlungsflächen* nur dort ausgewiesen, wo in der Umgebung der zu klassifizierenden Segmente gleichzeitig eine hohe Anzahl *potentieller Schatten* und *urbaner Punktstreuer* vorkommen (VGL. ABB. 4-20d). Neben diesen beiden Merkmalen werden zudem die Form (Shape Index) sowie texturbezogene Attribute (Varianz in definierter Nachbarschaft) berücksichtigt. Die *wahrscheinlichen Siedlungsflächen* stützen sich auf die als sicher klassifizierten Siedlungssegmente und werden im Prinzip durch identische Merkmale definiert. Der Unterschied besteht jedoch darin, dass im Gegensatz zu den sicheren Siedlungsflächen eine geringere Anzahl an Streuern und Schattenflächen in der Umgebung erforderlich ist. Gleichsam muss bereits ein hoher relativer Anteil der Objekte in ihrer Umgebung als *sichere Siedlungsfläche* ausgewiesen sein (VGL. ABB. 4-20d). Durch diese Auslegung wird gewährleistet, dass auch untypisch ausgeprägte Siedlungsbereiche noch der bebauten Fläche zugeordnet werden. Objekte die keiner der beiden Klassen angehören, werden abschließend der Kategorie *keine Siedlungsfläche* zugewiesen. Damit ist die Erstellung der Siedlungsmaske abgeschlossen.

Wie zu Beginn dieses Kapitels angemerkt, wird die auf Level 2 erstellte Siedlungsmaske abschließend auf der untergeordneten *Korrekturebene* (Level 1) verbessert. Zudem werden die nicht der Siedlungsfläche zugehörigen Bildbereiche in die thematischen Kategorien *Freifläche*, *Baumbestand* und *Wasserfläche* unterteilt. In diesem Kontext sei jedoch darauf hingewiesen, dass der Fokus der vorliegenden Arbeit auf der Identifizierung von Siedlungsflächen liegt, so dass die Ausweisung der zusätzlichen Landnutzungsklassen auf vergleichbar simplen Merkmalsbeschreibungen basiert, die folglich noch mit entsprechenden Unsicherheiten behaftet sind.

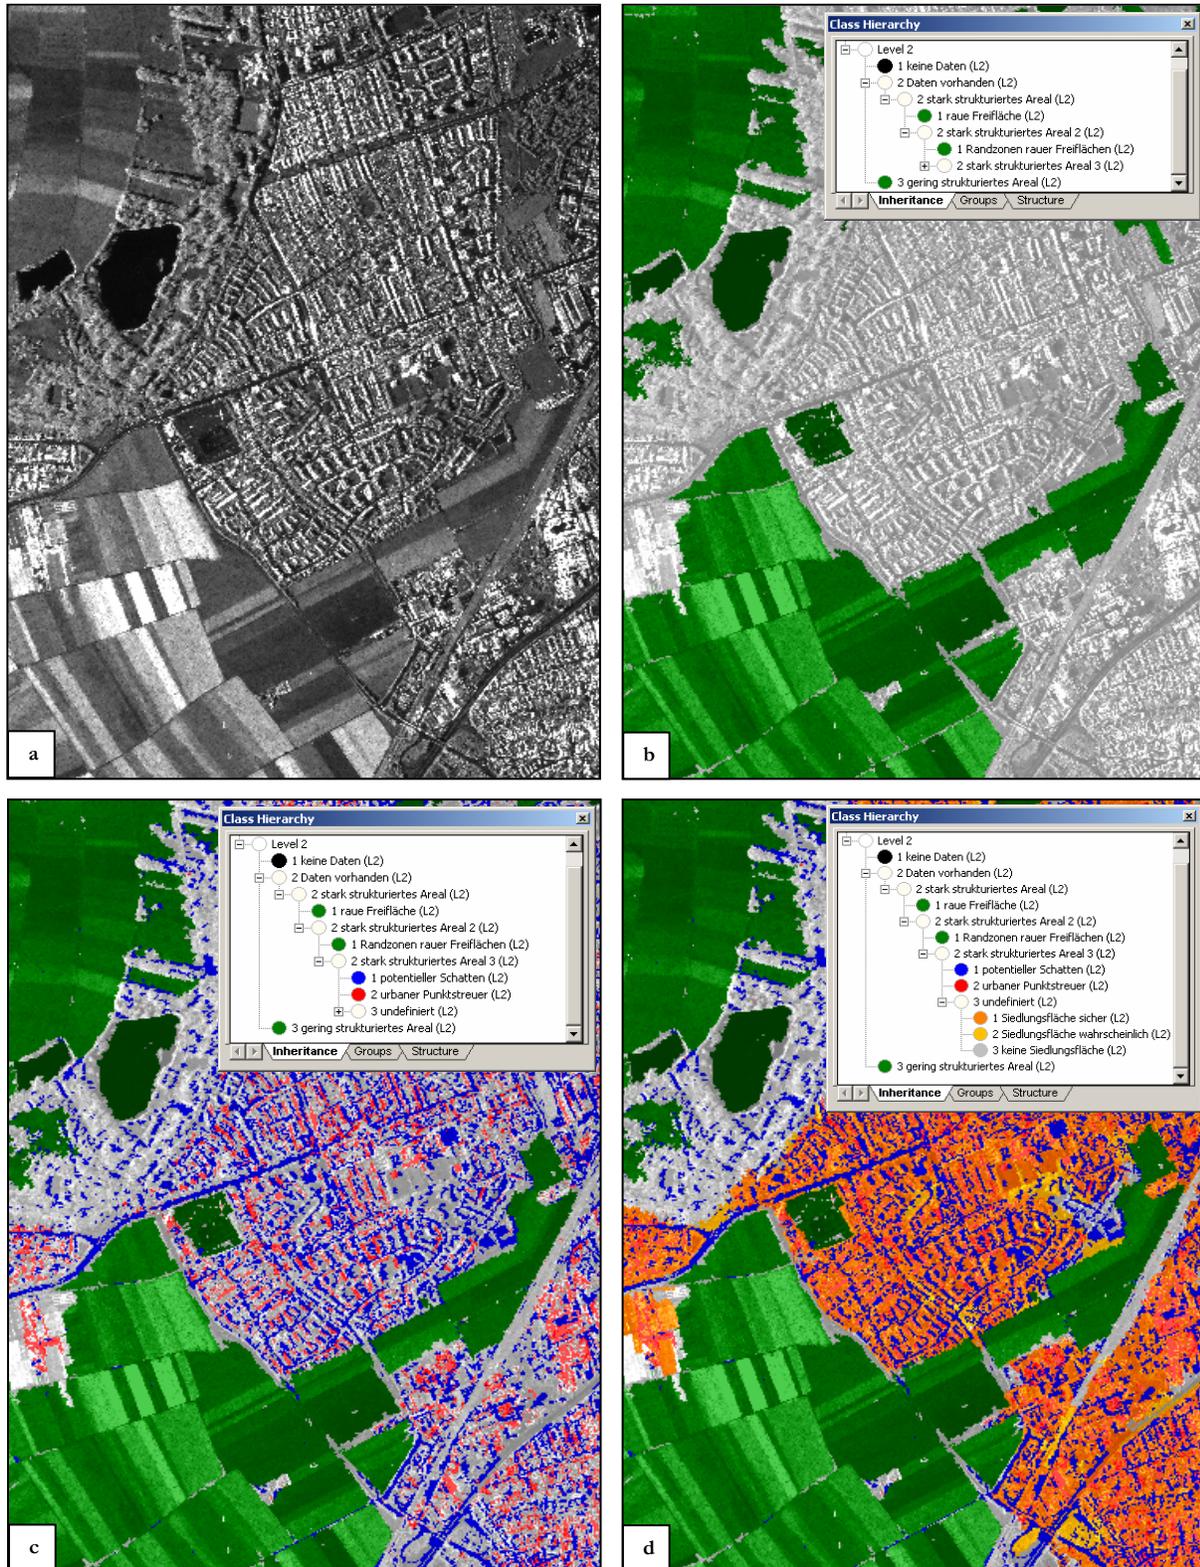


Abb. 4-20: Identifizierung von Siedlungsflächen auf der Optimierungsebene (Level 2) – Im Anschluss an die Identifizierung stark strukturierter Areale (b) werden innerhalb dieser Bereiche potentielle Corner-Reflexionen und Schattenflächen klassifiziert (c). Als potentielle Siedlungsfläche werden schließlich all jene Objekte eingestuft, die gleichzeitig eine hohe Anzahl an Corner-Reflexionen und Schatten in ihrer Umgebung aufweisen (d).

Der Aufbau des Regelwerks auf der Korrektorebene orientiert sich grundlegend an der zuvor erstellten Wissensbasis des zweiten Levels. Dabei werden allerdings die nachbarschaftsbezogenen Merkmale auf der Basis der nunmehr kleineren Segmente neu berechnet. Durch dieses Vorgehen sollen Ungenauigkeiten kompensiert werden, die auf der übergeordneten Ebene bisweilen durch eine zu grobe Segmentierung hervorgerufen werden. Solche Fehler treten beispielsweise an den Rändern der Siedlungsflächen auf. Dort laufen peripher gelegene Siedlungsobjekte mitunter recht deutlich in das unbebaute Umland hinaus. Umgekehrt erstrecken sich Segmente des Umlandes fälschlicherweise weit in die Siedlung hinein. Dadurch sind insbesondere die nachbarschaftsbezogenen Merkmale untypisch ausgeprägt und die entsprechenden Segmente werden bisweilen inkorrekt klassifiziert. Da die Unterobjekte des ersten Levels deutlich kleinteiliger gestaltet sind, tritt dieser Effekt auf der Korrektorebene hingegen kaum mehr in Erscheinung. Somit reduzieren sich auch die entsprechenden Fehler.

Grundlegend beginnt die Klassifizierung auf der Korrektorebene erneut mit der Ausweisung *stark* bzw. *gering strukturierter Bildbereiche* (VGL. ABB. 4-19). Zur Identifizierung der *stark strukturierten Areale* wird das Klassifikationsergebnis der Optimierungsebene direkt vom zweiten Level übernommen. D.h. ein Objekt der Korrektorebene wird dann als stark strukturiert ausgewiesen, wenn das zugehörige Superobjekt auf der Optimierungsebene der korrespondierenden Klasse *stark strukturiertes Areal (L2)* angehört. Um Fehlklassifikationen aufgrund einer zu groben Segmentierung des zweiten Levels zu korrigieren, umfasst die Merkmalsbeschreibung zusätzlich jene Attributkombination, die bereits auf der übergeordneten Ebene zur Identifizierung stark strukturierter Bildbereiche verwendet wurde. Der Unterschied besteht allerdings darin, dass die Berechnung der einzelnen Merkmale nunmehr auf den kleineren Segmenten der Korrektorebene beruht. Ebenfalls vergleichbar zur vorangegangenen Klassifizierung auf dem zweiten Level werden alle Segmente, die nicht als stark strukturiert klassifiziert wurden, automatisch der Klasse *gering strukturiertes Areal* zugewiesen.

Zur weiteren Differenzierung der heterogenen und homogenen Bildbereiche werden beide Kategorien in zusätzliche Klassen unterteilt. Im Kontext der *gering strukturierten Areale* werden dabei zunächst *Wasserflächen* identifiziert (VGL. ABB. 4-19). Diese kennzeichnen sich einerseits durch eine überdurchschnittliche Segmentgröße und andererseits durch sehr niedrige Intensitätswerte. Zudem muss das zugehörige Superobjekt auf der Texturebene eine sehr niedrige Intensität und Textur aufweisen, nahezu vollständig von helleren Nachbarobjekten umgeben sein und darf auf Level 2 nur in sehr geringem Umfang Schattenflächen beinhalten.

Jene Segmente innerhalb der gering strukturierten Bereiche, die nicht den Wasserflächen zugehörig sind, werden entweder als *Freifläche* oder als *stark strukturierte Flächen L2* gekennzeichnet. Die Klasse *stark strukturierte Flächen L2* weist sämtliche Objekte aus, die auf der Optimierungsebene als stark strukturierte Areale klassifiziert wurden, während sie nunmehr auf der Basis der neuerlichen Berechnung auf der ersten Ebene als homogene Bereiche eingestuft werden. Die *Freiflächen* hingegen beschreiben alle Segmente, die nicht als *stark strukturierte Flächen L2* ausgewiesen werden, d.h. Flächen die auf beiden Ebenen den gering strukturierten Arealen angehören. Als einziges Merkmal der *stark strukturierten Flächen L2* muss die Zugehörigkeit des korrespondierenden Superobjektes zur Klasse *stark strukturiertes Areal* zutreffen. Um nun zu überprüfen, ob es sich tatsächlich um Freiflächen handelt oder ob diese Objekte wirklich signifikante Strukturen repräsentieren, wird die Kategorie in weitere Subklassen unterteilt (VGL. ABB. 4-19).

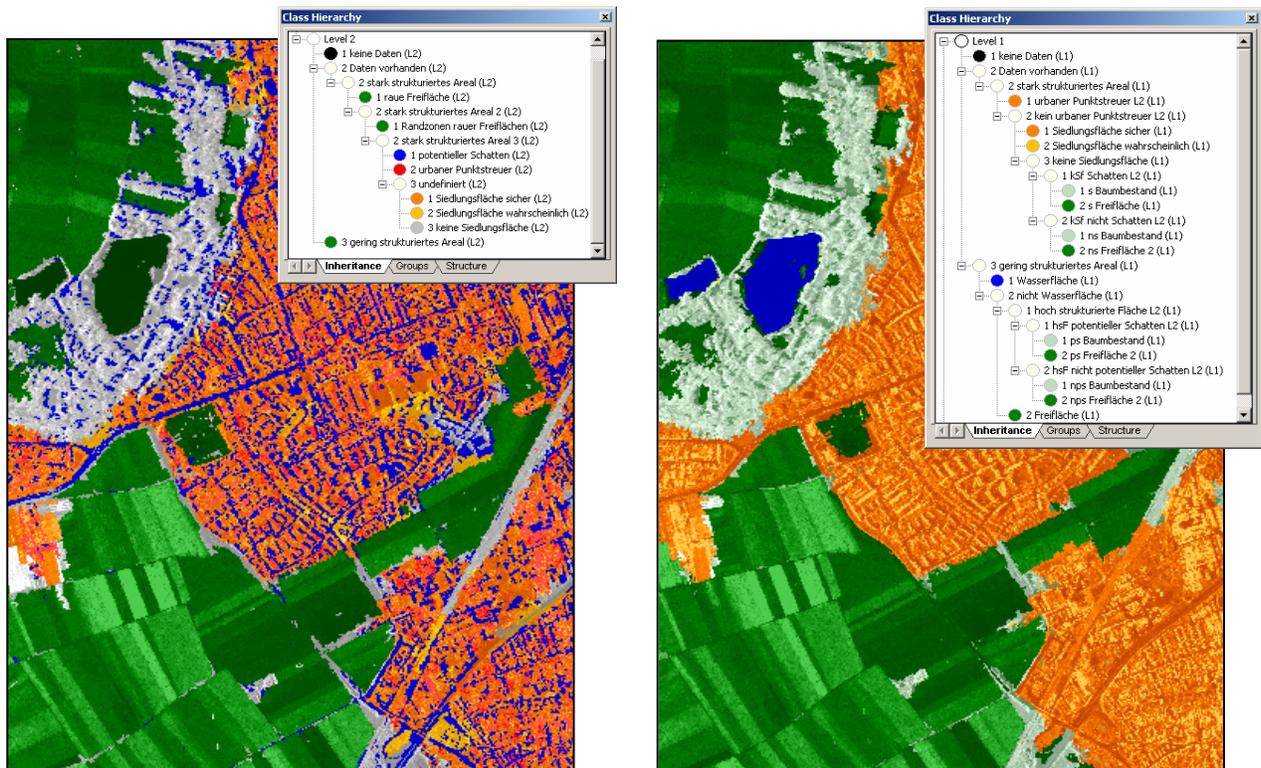


Abb. 4-21: Siedlungsmaske auf Level 2 (l.) sowie deren Korrektur und thematische Erweiterung auf Level 1 (r.)

Dabei werden zu Beginn jene Flächen ausgesondert, die auf der zweiten Ebene als Schatten klassifiziert wurden (*hsF potentieller Schatten L2*). Der Grund hierfür liegt darin, dass sich deren exakte Kennzeichnung einzig aus der sie umgebenden Landbedeckung ergibt. Diese Landbedeckung wird über die weitere Differenzierung der Flächen ermittelt, die keinen Schattenbereich repräsentieren (*nicht potentieller Schatten L2*). Weisen die entsprechenden Segmente eine hohe lokale Textur auf und umfasst

ihr Superobjekt auf der Texturebene mehrere Schattenflächen auf Level 2 oder befinden sich Schattensegmente in unmittelbarer Nachbarschaft, spricht dies für einen Baumbestand (*nps Baumbestand*). Ist dies nicht der Fall, werden die Objekte entsprechend als Freifläche klassifiziert (*nps Freifläche 2*). Auf der Basis dieser Klassifizierung wird anschließend für die zuvor ausgewiesenen Schattenflächen (*hsF potentieller Schatten L2*) überprüft, zu welcher der beiden Klassen sie die längste relative Grenzfläche aufweisen bzw. welche der beiden Kategorien die größte relative Fläche in der Umgebung einnimmt. Entsprechend werden die Schattensegmente abschließend ebenfalls in Freiflächen (*ps Freifläche 2*) oder Baumbestand (*ps Baumbestand*) eingeordnet (VGL. ABB. 4-21).

Die Unterteilung der *stark strukturierten Bildbereiche* beginnt mit der Klassifizierung *urbaner Punktstreuer* (VGL. ABB. 4-19). Diese werden direkt aus der Klassifizierung der zweiten Ebene übernommen. Vergleichbar der Vorgehensweise auf Level 2 werden sämtliche nicht dieser Klasse zugehörigen Segmente (*kein urbaner Punktstreuer L2*) weiter in die Kategorien *Siedlungsfläche sicher*, *Siedlungsfläche wahrscheinlich* und *keine Siedlungsfläche* untergliedert (VGL. ABB. 4-19). Zur Definition der *sicheren Siedlungsflächen* ist einerseits die Anzahl bzw. Dichte an urbanen Punktstreuern in einer definierten Umgebung ausschlaggebend. Andererseits werden verschiedene klassenbasierte Merkmale definiert. Letztere werden über die Segmente der Texturebene ermittelt und beschreiben die relative Fläche an Siedlungsobjekten auf Level 2 sowie die relative Fläche an Level 2 Siedlungsobjekten in einer definierten Nachbarschaft. Die *wahrscheinlichen Siedlungsflächen* dienen wiederum als Ergänzung zu den *sicheren Siedlungsflächen*. Erstere werden entsprechend durch identische Merkmale definiert, die jedoch in ihren Wertespannen etwas weiter gefasst sind als im Falle der *sicheren Siedlungsflächen*. Um ein Segment dieser Klasse zuzuweisen, muss zudem bereits ein hoher relativer Anteil der umgebenden Objekte als *sichere Siedlungsfläche* klassifiziert sein. Die Gesamtheit aus beiden Siedlungsklassen und den urbanen Punktstreuern ergibt die endgültige Siedlungsmaske (VGL. ABB. 4-21).

Sämtliche Segmente, die *keine Siedlungsfläche* repräsentieren, werden abschließend jeweils einer der beiden Unterklassen *kSf Schatten* und *kSf nicht Schatten* zugewiesen, wobei diese Kategorien letztlich weiter in die Klassen *Freifläche* oder *Baumbestand* unterteilt werden (VGL. ABB. 4-19). Die dabei zu Grunde liegende Klasseneinteilung und Merkmalsdefinition entspricht exakt jener, die bereits im Kontext der Differenzierung *gering strukturierter Areale* verwendet wurde und soll daher an dieser Stelle nicht noch einmal erörtert werden.

4.2.2 Integration zusätzlicher Polarisationen, Frequenzen oder Datentypen

4.2.2.1 Erweitertes Segmentierungskonzept

Um eine Auswertung auf der Basis mehrerer Bilddatensätze – beispielsweise unterschiedlicher Polarisationen, Frequenzen oder kombinierter optischer und SAR-basierter Aufnahmen – zu ermöglichen, muss sichergestellt sein, dass die Charakteristika jedes einzelnen Datensatzes durch adäquate Segmente repräsentiert werden. Wie bereits in KAPITEL 4.1.2.2 eingehend erörtert, können dazu mehrere Durchläufe der Segmentierungsoptimierung hintereinander geschaltet werden. Dabei wird die Segmentierung letztlich über eine individuelle Optimierung auf der Basis jeder einzelnen Aufnahme sukzessive an die mehrdimensionale Datenbasis angepasst.

Mit Blick auf zukünftige Anwendungs- und Datenszenarien sollen an dieser Stelle der Arbeit einerseits Datensätze kombiniert segmentiert werden, die sich entweder in der *Polarisation* (Gleich- und Kreuz-Polarisation) oder der *Frequenz* (X- und L-Band) unterscheiden. Darüber hinaus soll eine weitere Optimierung auf die Segmentierung einer Datenbasis aus einfach-polarisierter Radaraufnahme und 3-kanaligem, optischen Datensatzes ausgelegt werden (E-SAR X-Band und IRS).

Die optimierte Segmentierung auf der Basis zweier *SAR-Aufnahmen unterschiedlicher Polarisation* oder *Frequenz* ist prinzipiell identisch mit dem Ablauf und der Parametrisierung eines einzigen, einfach-polarisierten Datensatzes (VGL. KAP. 4.2.1.1). Der einzige Unterschied besteht darin, dass nacheinander zweimal eine Optimierung eines einfach-polarisierten SAR-Kanals erfolgt. Wie aus TABELLE 4-3 ersichtlich, werden dabei wiederum *drei Objektebenen* angelegt, deren Generierung ebenfalls auf einem geglätteten *Intensitätsbild* (*Int_filt_1*, *Int_filt_2*) und der daraus abgeleiteten *lokalen Varianz* (*Int_filt_tex_1*, *Int_filt_tex_2*) beruht.

Beginnend mit der Optimierungsprozedur wird zuerst der co-polarisierte Datensatz (dual-pol-Auswertung) bzw. die X-Band Aufnahme (bifrequente Auswertung) segmentiert. Sowohl die Einstellungen zur Multiresolution Segmentation als auch das Regelwerk und die Parametrisierung der klassenbasierten Segmentoptimierung entsprechen dabei exakt den zuvor im Rahmen der Optimierung einer einzigen, einfach-polarisierten SAR-Aufnahme verwendeten Werten (VGL. TAB. 4-3 und TAB. 4-2).

Sobald die Optimierung der ersten Aufnahme beendet ist, beginnt das Segmentierungsprozedere für den zweiten Datensatz (Kreuz-Polarisation bzw. L-Band). Dabei repräsentiert das aus dem ersten Durchlauf resultierende Objektlevel während des gesamten Ablaufs die Optimierungsebene. Folglich

fungieren die iterativ neu angelegten Objektebenen stets als Basislevel (VGL. TAB. 4-3). Durch dieses Vorgehen werden die aus der Optimierung des ersten Datensatzes hervorgegangenen Segmente korrigiert, wenn dies aufgrund der Strukturen in der zweiten Informationsebene erforderlich ist. Somit resultiert der zweite Optimierungsdurchlauf in einer Objektebene, welche die strukturellen Charakteristika beider Datensätze vollständig repräsentiert.

Tab. 4-3: Einstellungen zur Segmentierung dual-polarisierter oder bifrequenter SAR-Daten

Segmentierungsablauf*			Layer** (Gewichtung)	Scale Parameter	Color	Compactness	
Level 2 (Optimierungsebene)	Segmentierungsoptimierung (Regelwerk 1)	1. Iteration	BL	Int_filt_1 (1)	20	0,7	0,5
			OL	Int_filt_1 (1)	40	0,7	0,5
		2. Iteration (OL)		Int_filt_1 (1)	60	0,7	0,5
		3. Iteration (OL)		Int_filt_1 (4) Int_filt_tex_1 (1)	80	0,8	0,5
		4. Iteration (OL)		Int_filt_1 (3) Int_filt_tex_1 (1)	120	0,8	0,5
		5. Iteration (OL)		Int_filt_1 (2) Int_filt_tex_1 (1)	160	0,8	0,5
	6. Iteration (OL)		Int_filt_1 (1) Int_filt_tex_1 (1)	200	0,9	0,5	
	Segmentierungsoptimierung (Regelwerk 2)	1. Iteration (BL)		Int_filt_2 (1)	20	0,7	0,5
		2. Iteration (BL)		Int_filt_2 (1)	40	0,7	0,5
		3. Iteration (BL)		Int_filt_2 (1)	60	0,7	0,5
		4. Iteration (BL)		Int_filt_2 (4) Int_filt_tex_2 (1)	80	0,8	0,5
		5. Iteration (BL)		Int_filt_2 (3) Int_filt_tex_2 (1)	120	0,8	0,5
		6. Iteration (BL)		Int_filt_2 (2) Int_filt_tex_2 (1)	160	0,8	0,5
		7. Iteration (BL)		Int_filt_2 (1) Int_filt_tex_2 (1)	200	0,9	0,5
Level 3 (Texturebene)			Int_filt_1 (1) Int_filt_2 (1)	260	0,9	0,5	
Level 1 (Korrekturbene)			Int_filt_1 (1) Int_filt_2 (1)	40	0,8	0,5	

* : BL = Basislevel; OL = Optimierungslevel
 **: Int_filt_1: Intensitätsbild HH Polarisation bzw. X-Band; Int_filt_tex: Texturbild der Intensität von HH Polarisation bzw. X-Band
 Int_filt_2: Intensitätsbild HV Polarisation bzw. L-Band; Int_filt_tex: Texturbild der Intensität von HV Polarisation bzw. L-Band

Abschließend werden abermals ein übergeordnetes Texturlevel und eine untergeordnete Korrekturbene angelegt. Dabei erfolgt die Multiresolution Segmentation auf der Grundlage beider Intensitätsbilder, die jeweils in gleicher Gewichtung in die Segmentierung eingehen (VGL. TAB. 4-3).

Zur Segmentoptimierung auf der Basis einer *X-Band Aufnahme* und eines *optischen Datensatzes* werden ebenfalls zwei Optimierungsabläufe miteinander kombiniert (VGL. TAB. 4-4). Dabei gilt die erste Optimierung der geometrisch deutlich höher aufgelösten X-Band Szene. Ablauf und Regelwerk entsprechen wiederum dem bereits vorgestellten Ansatz zur Optimierung von einfach-polarisierten SAR-Aufnahmen und sollen daher an dieser Stelle nicht weiter beschrieben werden (VGL. KAP. 4.2.1.1). Nach Abschluss der radarbasierten Segmentierung startet erneut ein kompletter Optimierungsdurchlauf, in diesem Fall jedoch einzig auf der Basis des optischen IRS-Datensatzes. Vergleichbar zur bereits beschriebenen Segmentierung einer dual-polarisierten oder bifrequenten Datengrundlage dient die zuvor generierte Segmentebene nunmehr als Optimierungslevel. Wie TABELLE 4-4 aufzeigt, werden dabei im Rahmen dieses Durchlaufs neue Einstellungen zur Multiresolution Segmentation verwendet, die speziell auf die Eigenschaften der optischen Daten ausgerichtet sind.

Tab. 4-4: Segmentierungsparameter für kombinierte Datenbasis aus X-Band Aufnahme und IRS-Datensatz

Segmentierungsablauf*			Layer** (Gewichtung)	Scale Parameter	Shape	Compactness	
Level 2 (Optimierungsebene)	Optimierung (Regelwerk X-Band)	1. Iteration	BL	Int_filt (1)	20	0,7	0,5
			OL	Int_filt (1)	40	0,7	0,5
		2. Iteration (OL)		Int_filt (1)	60	0,7	0,5
		3. Iteration (OL)		Int_filt (4) Int_filt_tex (1)	80	0,8	0,5
		4. Iteration (OL)		Int_filt (3) Int_filt_tex (1)	120	0,8	0,5
		5. Iteration (OL)		Int_filt (2) Int_filt_tex (1)	160	0,8	0,5
	6. Iteration (OL)		Int_filt (1) Int_filt_tex (1)	200	0,9	0,5	
	Optimierung (Regelwerk IRS)	1. Iteration (BL)		G; R; NIR (1,1,1)	10	0,8	0,5
		2. Iteration (BL)		G; R; NIR (1,1,1)	20	0,8	0,5
		3. Iteration (BL)		G; R; NIR (1,1,1)	40	0,8	0,5
		4. Iteration (BL)		G; R; NIR (1,1,1)	60	0,8	0,5
		5. Iteration (BL)		G; R; NIR (1,1,1)	80	0,8	0,5
	Level 3 (Texturebene)			G; R; NIR (1,1,1)	80	0,8	0,6
	Level 1 (Korrekturbene)			Int_filt (1) Int_filt_tex (1)	40	0,8	0,5

* : BL = Basislevel; OL = Optimierungslevel
 **: Int_filt: geglättetes Intensitätsbild ; Int_filt_tex: Texturbild (Varianz 7x7), berechnet auf Basis von gefilterter Intensität
 IRS-Aufnahmekanäle: G = Grün (Band 1); R = Rot (Band 2); NIR = Nah-Infrarot (Band 3)

Zudem kommt im Zuge der klassenbasierten Segmentanpassung das Regelwerk zur Optimierung mehrkanaliger Bilddaten zur Anwendung, welches in KAPITEL 4.1.2.2 ausführlich beschrieben wurde.

Im Gegensatz zu den vorangegangenen Ansätzen basiert die abschließende Erstellung der Textur-ebene im Kontext der kombinierten Auswertung nicht mehr auf den Radardaten, sondern ausschließlich auf den drei Aufnahmekanälen der IRS-Aufnahme. Dies liegt darin begründet, dass der IRS-Datensatz aufgrund seiner deutlich erweiterten spektralen Auflösung und der geringeren lokalen Dynamik der Grauwerte eine adäquatere Segmentierung der großflächigen Struktureinheiten erlaubt. Demgegenüber findet im Rahmen der kleinteiligen Segmentierung des Korrekturlevels wiederum ausschließlich die SAR-Intensität Verwendung, da diese Datenbasis einen deutlich höheren räumlichen Detaillierungsgrad aufweist (VGL. TAB. 4-4).

4.2.2.2 Modifizierung des Regelwerks zur Klassifizierung

Wie bereits erwähnt, zeichnen nahezu sämtliche satellitengestützten SAR-Systeme zumindest einfach-polarisierte Radardaten auf. Daher wurde die grundlegende Methodik zur Erfassung von Siedlungsflächen primär auf diesen Datentyp ausgerichtet (VGL. KAP. 4.2.1). Im Hinblick auf die Eigenschaften zukünftiger Aufnahmen von Radarsystemen wie ALOS-PalSAR, TerraSAR-X oder Radarsat-2 werden jedoch vermehrt dual- oder gar voll-polarisierte Aufnahmen zur Verfügung stehen. Zudem gewinnen die synergetische Nutzung verschiedener Frequenzen und die Verknüpfung mit optischen Daten (z.B. RapidEye, IRS, IKONOS) zunehmend an Bedeutung.

Daher wird nachfolgend erläutert, wie sich das in KAPITEL 4.2.1 vorgestellte Regelwerk zur Analyse einfach-polarisierter SAR-Aufnahmen so ausbauen lässt, dass es die Berücksichtigung einer zusätzlichen *Polarisation (HH und HV)* oder *Frequenz (X-Band und L-Band)* ermöglicht. Zudem wird ein Ansatz zur kombinierten Analyse *optischer und SAR-basierter Daten (IRS und X-Band)* präsentiert. Dabei soll das bereits vorhandene Regelwerk auf möglichst effiziente Weise durch Attribute des zusätzlich bereitgestellten Datensatzes ergänzt werden, ohne jedoch die Struktur der bereits entwickelten Wissensbasis grundlegend modifizieren zu müssen. Entsprechend des Fokus dieser Arbeit liegt der Schwerpunkt dabei ausschließlich auf der verbesserten Klassifizierung der Siedlungsflächen. Die optimierte Abgrenzung der übrigen Kategorien *Freifläche*, *Baumbestand* und *Wasser* wird hingegen an dieser Stelle keine Berücksichtigung finden.

Das Konzept zur Erfassung der Siedlungsflächen stützt sich maßgeblich auf die Extraktion stark strukturierter Bildbereiche und die anschließende Identifizierung urbaner Punktstreuer und Schatten-

flächen (VGL. KAP. 4.2.1). Aus diesem Grunde sollen die Modifikationen des bestehenden Regelwerks speziell auf jene Klassen abzielen. Wie dies im Einzelnen geschieht, wird nachfolgend dargelegt.

Auswertung dual-polarisierter SAR-Daten (Co- und Cross-Polarisation)

Im Gegensatz zu den bisher betrachteten co-polarisierten SAR-Aufnahmen (HH) ermöglichen dual-polarisierte Radardaten (HH, HV) eine erweiterte Beschreibung des an der Erdoberfläche aufgetretenen Streumechanismus. So ist die Rückstreuung in der Kreuz-Polarisation (HV) ein Maß für die *Depolarisation* des emittierten Signals (VGL. KAP. 2.2.3). Folglich lässt sich über eine Gegenüberstellung der Cross- und Co-Polarisation eine Aussage hinsichtlich der Volumen- bzw. Oberflächenstreuung einer Fläche treffen. Dabei ruft Volumenstreuung in der Kreuz-Polarisation prinzipiell einen höheren Rückstreuquerschnitt hervor als dies bei Oberflächenstreuung der Fall ist. Weiter gilt, dass die diffuse Rückstreuung – und damit auch der Anteil depolarisierter Strahlung – mit zunehmender Oberflächenrauigkeit ansteigen. Demgegenüber äußert sich eine (mehrfach-)spiegelnde Reflektion an glatten Oberflächen vornehmlich in niedrigen Werten der Kreuz-Polarisation (VGL. KAP. 2.2.5).

Diese Charakteristika lassen sich zur verbesserten Identifizierung der Siedlungsflächen nutzen. So werden zur Klassifizierung *hochstrukturierter Areale* unter anderem Texturmerkmale eingesetzt, die bislang ausschließlich auf der Basis der Intensität des co-polarisierten Signals (HH) berechnet wurden (VGL. KAP. 4.2.1.2). Wie bereits erwähnt, bereiten dabei gerade Ackerflächen mit oberirdischen Bewässerungssystemen aus Metall gewisse Schwierigkeiten, da sie im Hinblick auf ihre texturbezogenen Eigenschaften mitunter typische Merkmale von Siedlungsflächen aufweisen (VGL. ABB. 4-22). Dies ist darauf zurückzuführen, dass die Metallrohre und -pfosten des Bewässerungssystems in der HH-Polarisation als klassische Dipolstreuer wirken.

Da weder direkte Rückstreuung noch Double-Bounce-Effekte an den glatten, metallischen Oberflächen zu nennenswerter Depolarisationen führen, ist der Rückstreuquerschnitt und damit letztlich auch die lokale Textur in der Kreuz-Polarisation erheblich geringer als in der entsprechenden co-polarisierten Aufnahme (VGL. ABB. 4-22). Vor diesem Hintergrund werden sämtliche Merkmalsbeschreibungen zur Kennzeichnung *hochstrukturierter Areale* (Level 2 und Level 1) um die komplementären, auf der Basis der Cross-Polarisation berechneten Texturmerkmale ergänzt. Demnach wird eine Fläche nur noch dann als hochstrukturiert ausgewiesen, wenn das entsprechende Objekt sowohl in der Gleich- als auch in der Kreuz-Polarisation eine signifikante Textur aufweist. ABBILDUNG 4-22 illustriert die daraus resultierende Verbesserung in der Ausgrenzung bewässerter Ackerflächen.

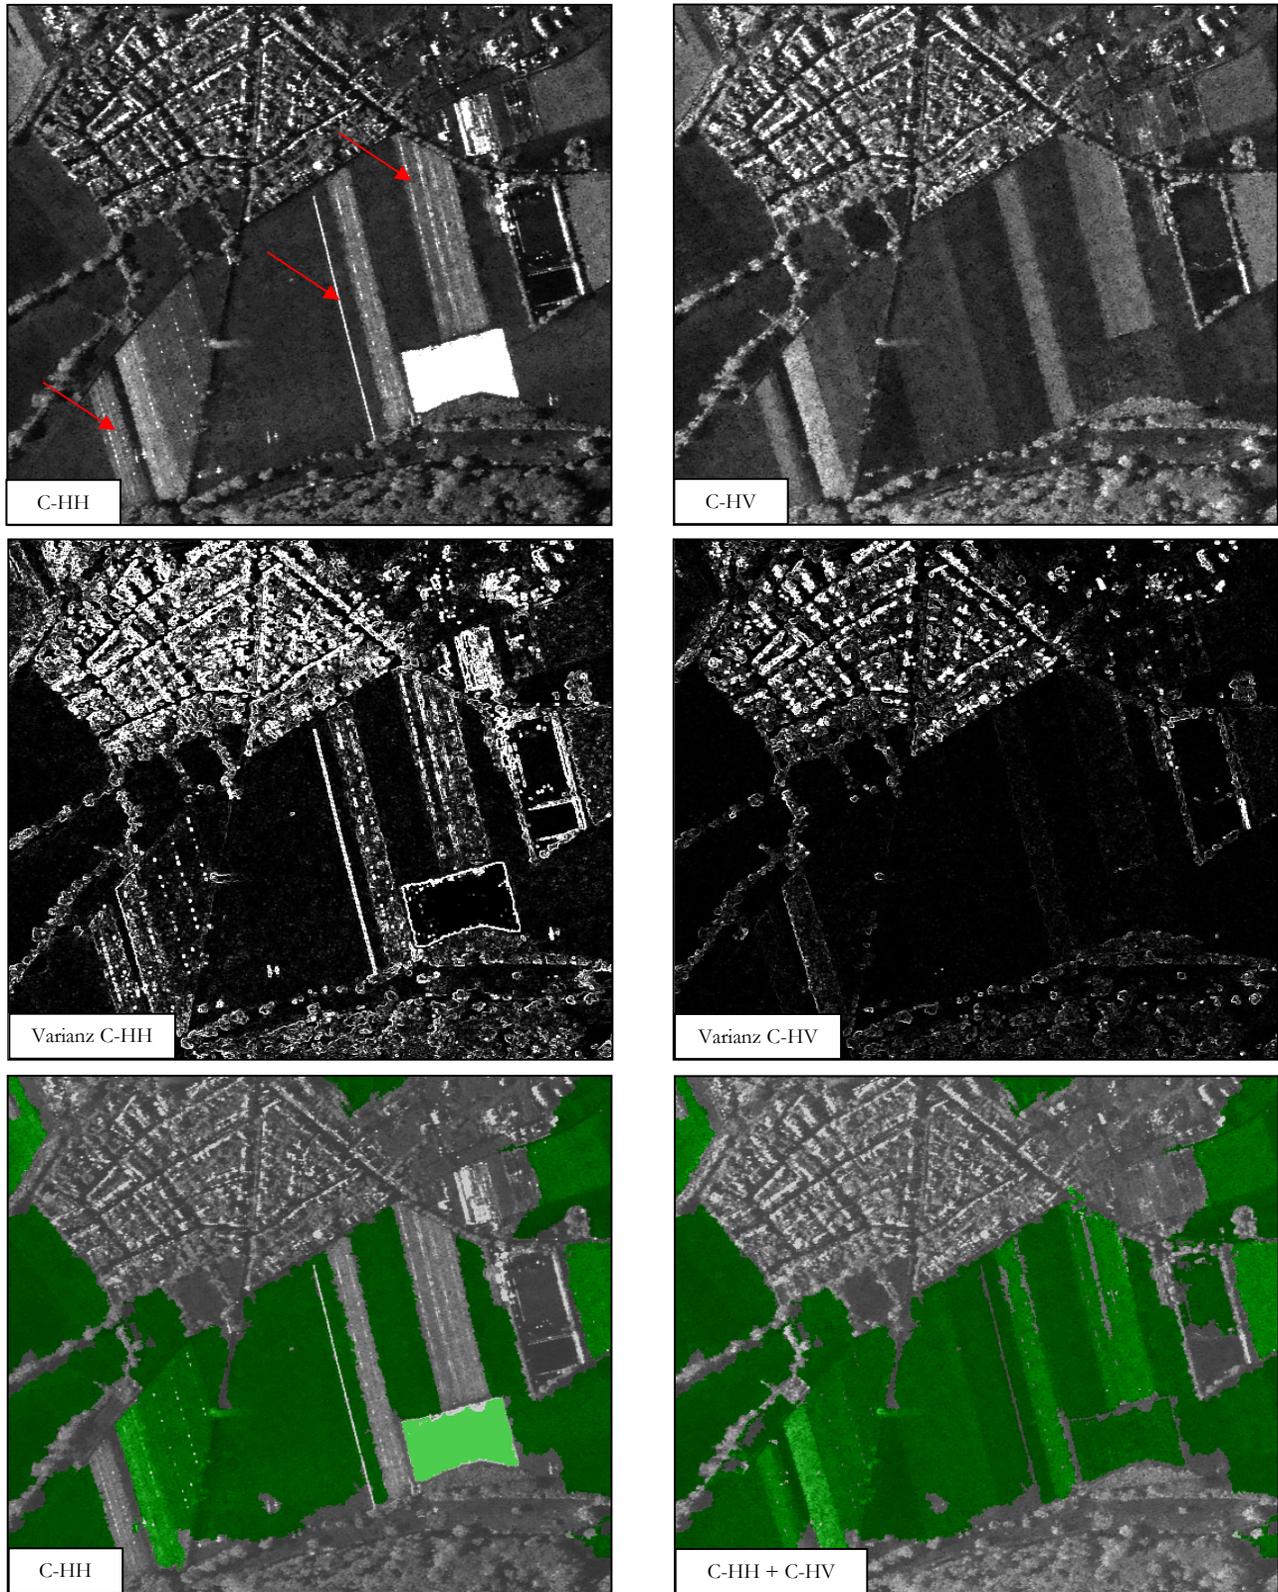


Abb. 4-22: Identifizierung hochstrukturierter Bildbereiche (grau) auf Basis der Intensität und Varianz einer co- bzw. dual-polarisierten SAR-Aufnahme – Durch die Berücksichtigung von Gleich- und Kreuz-Polarisation kann insbesondere die Ausgrenzung von bewässerten Ackerflächen (Pfeile) – deren metallene Rohrsysteme in Form punktueller oder linienhafter Streuzentren in Erscheinung treten – gegenüber einer isolierten Auswertung der Gleich-Polarisation signifikant verbessert werden.

Der zuvor beschriebene Effekt lässt sich darüber hinaus zur präzisierten Identifizierung *urbaner Punktstreuer* nutzen. Solche Streuer werden bisher laut Regelwerk unter anderem durch eine hohe Intensität und lokale Textur gekennzeichnet (VGL. KAP. 4.2.1.2). Beides trifft in der HH-Polarisation ebenfalls auf die Bewässerungsrohre innerhalb der bereits beschriebenen Ackerflächen zu (VGL. ABB. 4-22). Würden sich nun noch zusätzlich Schattenflächen in der näheren Umgebung dieser Streuer befinden – etwa von einer benachbarten Heckenreihe oder einer Waldfläche –, dürften zumindest einige dieser signifikanten Streuzentren fälschlicherweise als *urbane Punktstreuer* klassifiziert werden.

Wie ABBILDUNG 4-22 verdeutlicht, treten die punktuellen Streuer im Bereich der Ackerflächen in der Kreuz-Polarisation allerdings nicht mehr in Erscheinung. Daher weisen Regionen, deren hohe Strukturierung ausschließlich durch direkte oder spiegelnde Rückstreuung hervorgerufen wird, in der Kreuz-Polarisation sehr niedrige Texturen auf. Gleichsam verringert sich in der Kreuz-Polarisation jedoch auch innerhalb der urbanen Umgebung die Anzahl der charakteristischen, hellen Punktstreuer, was mit einer merklichen Abnahme der Textur verbunden ist. Im Gegensatz zu den besagten Ackerflächen bleibt die Textur der Siedlungsflächen allerdings aufgrund der enormen strukturellen Heterogenität dieser Areale weiterhin auf einem deutlich höheren Niveau (VGL. ABB. 4-22).

Aufgrund der zuvor beschriebenen Effekte wird die Kennzeichnung der *urbanen Punktstreuer* um eine weitere Merkmalskombination ergänzt. Diese definiert zum einen, dass die lokale Textur und Intensität grundsätzlich auch in der Cross-Polarisation hohe Werte annehmen müssen. Isoliert betrachtet, werden dadurch gegenüber der ursprünglichen Definition sämtliche Corner-Reflektoren und Objekte mit direkter Rückstreuung – also auch jene innerhalb besiedelter Areale – von einer Klassifikation als *urbaner Punktstreuer* ausgeschlossen. Um zu gewährleisten, dass dieses Ausschlusskriterium jedoch nicht auf signifikante Streuer innerhalb von Siedlungsflächen zutrifft, wird diese Merkmalskombination durch ein drittes Attribut ergänzt. Dieses beschreibt die Textur in einer Umgebung von 50 Pixeln, berechnet auf der Basis des kreuz-polarisierten Datensatzes. Ist diese weiterhin sehr hoch – wie im Falle einer urbanen Umgebung –, reichen eine hohe Intensität und lokale Textur in der HH-Polarisation zur Klassifikation eines *urbanen Punktstreuers* aus. Umgekehrt bleibt das Ausschlusskriterium wirksam, wenn das Umfeld des entsprechenden Objektes durch eine sehr geringe Textur in der HV-Polarisation gekennzeichnet wird – eine Eigenschaft, die für besiedelte Areale sehr untypisch ist, jedoch auf die bewässerten Ackerflächen zutrifft (VGL. ABB. 4-22).

Eine letzte Modifikation des ursprünglichen Regelwerks betrifft die beiden Klassen *sichere Siedlungsfläche* und *Siedlungsfläche wahrscheinlich*. Hier wird zusätzlich definiert, dass solche Flächen lediglich dort

ausgewiesen werden dürfen, wo die Varianz der zugehörigen Superobjekte auf der Texturebene auch auf der Grundlage des kreuz-polarisierten Datensatzes eine signifikante Ausprägung aufweist. Dadurch soll gewährleistet werden, dass Siedlungsflächen ausschließlich in Arealen ausgewiesen werden, die sich durch eine hohe mesoskalige Rauigkeit kennzeichnen.

Auswertung bifrequenter SAR-Daten (X- und L-Band)

Die Wellenlänge der eingesetzten Radarstrahlung stellt eine entscheidende Kenngröße im Hinblick auf die Streuprozesse an der Oberfläche der beleuchteten Medien dar. In KAPITEL 2.2.3 wurde erläutert, dass eine Oberfläche mit Blick auf ihren Streumechanismus rau wirkt, wenn die Dimensionierung der Oberflächenstrukturen im Bereich der Wellenlänge oder darüber liegt (*Rayleigh Kriterium*). Somit kann eine Oberfläche, die im X-Band ($\sim 3\text{cm}$ Wellenlänge) rau erscheint und dadurch eine mehr oder minder diffuse Streuung hervorruft, im L-Band ($\sim 20\text{-}30\text{cm}$ Wellenlänge) durchaus glatt wirken. Infolge dessen nimmt im L-Band der Anteil der Rückstreuung gerade im Kontext von Freiflächen oftmals merklich ab. Folglich treten die betreffenden Areale in der niedrigeren Frequenz als bedeutend dunklere Flächen in Erscheinung (VGL. ABB. 2-5). Aufgrund der vergleichsweise hohen Differenz in der Wellenlänge lässt sich dieser Effekt speziell bei der Kombination von X- und L-Band Aufnahmen zur verbesserten Klassifizierung nutzen.

So werden im Kontext der Klassifizierung *hochstrukturierter Areale* und *rauer Freiflächen* die vordefinierten Texturmaße durch komplementäre Attribute ergänzt, die zusätzlich auf der Basis des L-Bandes berechnet werden. (VGL. KAP. 4.2.1.2). Dabei wird ein Objekt fortan nur noch dann der Klasse *hochstrukturiertes Areal* zugewiesen, wenn die Textur sowohl im X- als auch im L-Band hohe Werte aufweist. Diese neue Merkmalsdefinition bietet speziell hinsichtlich einer Abgrenzung zwischen besiedelten Arealen und hochstrukturierten Freiflächen einen Vorteil, da zum Beispiel unbedeckte Ackerflächen, die im X-Band aufgrund einer mitunter hohen Rauigkeit enorme Varianzen der Grauwerte aufweisen, im langwelligen L-Band in aller Regel als glatte Oberflächen mit vergleichsweise niedrigen Rückstreuwerten und Varianzen in Erscheinung treten. Umgekehrt trägt die Bodenstruktur im L-Band auch im Kontext von bepflanzen Ackerflächen mitunter erheblich zur Rückstreuung bei, da die langwellige Radarstrahlung das Blattwerk der Pflanzen durchdringt. In der Folge werden daher zum Teil enorme Texturen erreicht, die im X-Band aufgrund der nahezu vollständigen Rückstreuung an der Vegetationsschicht nicht auftreten.

Durch die Integration der Texturinformation des L-Bands können gleichsam bestimmte Merkmalskombinationen ersetzt werden, die vormals noch zur Identifizierung stark strukturierter Areale sowie

rauer Freiflächen erforderlich waren. Dadurch lässt sich der Merkmalskatalog zur Definition beider Klassen zusätzlich vereinfachen.

Des Weiteren wird die Attributkombination zur Beschreibung der Klasse *urbaner Punktstreuer* so ergänzt, dass die Intensität und die lokale Textur nunmehr neben dem X- auch im L-Band hohe Werte

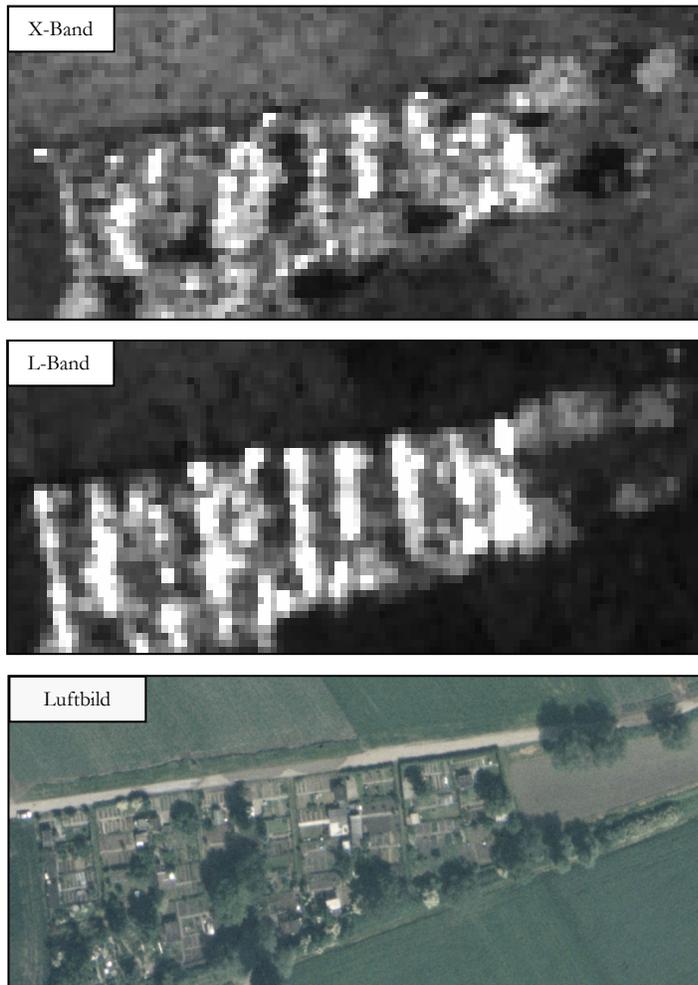


Abb. 4-23: Sichtbarkeit von Baustrukturen im X- und L-Band – Der Einfluss der Vegetation übt im langwelligen L-Band weniger Einfluss aus, weshalb sich die bebauten Strukturen besser abzeichnen. Das verstärkte Auftreten glatt wirkender Oberflächen erschwert jedoch gleichsam die Identifizierung der für die Klassifizierung bedeutsamen Schattenflächen.

annehmen müssen (VGL. KAP. 4.2.1.2). Dadurch sollen beispielsweise lokal begrenzte Streuzentren ausgegrenzt werden, die bisweilen im X-Band aufgrund direkter Rückstreuung von vegetationsbedeckten Oberflächen auftreten, im L-Band jedoch aufgrund der teilweisen Durchdringung der Vegetation nicht mehr präsent sind. Dies betrifft insbesondere punktförmige Streuzentren im Kronendach von Waldflächen. Gleichzeitig wird das Regelwerk so erweitert, dass alternativ zu der zuvor dargelegten Merkmalskombination auch eine sehr hohe Intensität und lokale Textur im L-Band zur Kennzeichnung eines urbanen Punktstreuers ausreichen – natürlich nur, sofern die übrigen Bedingungen wie Schattenflächen in der Umgebung etc. weiterhin erfüllt sind und die entsprechende Fläche auch im X-Band eine signifikante Textur aufweist (VGL. KAP. 4.2.1.2).

Hintergrund dieser Auslegung ist, dass L-Band Strahlung im Gegensatz zum X-Band Vegetation zu einem gewissen Grad durchdringen kann. Somit rufen speziell Häuser, die in Blickrichtung des Sensors von Hecken oder Bäumen verdeckt sind, im L-Band mitunter signifikante Double-Bounce-Reflektionen hervor, während dies aufgrund der mangelnden Sichtbarkeit im X-Band in deutlich geringerem Umfang der Fall ist. ABBILDUNG 4-23 illustriert dies am Beispiel einer Kleingartenanlage.

Zudem werden auch die Klassenkennzeichnungen der *Siedlungsflächen sicher* und *Siedlungsflächen wahrscheinlich* so modifiziert, dass die texturbezogenen Attribute (Varianz in definierter Nachbarschaft) auch im L-Band signifikant ausgeprägt sein müssen (VGL. KAP. 4.2.1.2). Dadurch soll insbesondere die Abgrenzung zwischen Siedlungsarealen und angrenzenden Waldflächen bzw. rauen Ackerflächen verbessert werden. Während letztere im X-Band ebenfalls hohe Texturen aufweisen können, erscheinen sie im L-Band in aller Regel als deutlich homogenere Areale.

Wie aus den vorangegangenen Ausführungen hervorgeht, zeigt sich in L-Band Aufnahmen gegenüber X-Band Daten grundsätzlich ein stärkerer Kontrast zwischen bebauten Arealen und Frei- bzw. Waldflächen (VGL. ABB. 2-5). Im Hinblick auf eine automatisierte Auswertung auf der Basis des entwickelten Regelwerks weist das L-Band jedoch den entscheidenden Nachteil auf, dass die eindeutige Identifizierung von Schattenflächen enorm erschwert wird, da sich diese Areale aufgrund des deutlich höheren Anteils glatt wirkender Oberflächen kaum mehr von letzteren abheben (VGL. ABB. 4-23). Hinzu kommt, dass auch die Bodenauflösung deutlich hinter der des X-Bands zurückbleibt, was die Auswertung ebenfalls negativ beeinflusst (VGL. KAP. 3.2).

Kombinierte Auswertung SAR-basierter und optischer Daten (X-Band und IRS-Kanäle)

Im Gegensatz zu den beiden vorangegangenen Ansätzen werden die einfach-polarisierten SAR-Daten in diesem Fall nicht durch Radaraufnahmen mit ähnlicher räumlicher Auflösung und identischer Geometrie ergänzt, sondern vielmehr durch einen völlig neuen Datentyp mit fundamental unterschiedlichem Aufnahmeprinzip. Daher unterscheiden sich zum einen die Geometrien der Bilddaten signifikant, was die exakte Ko-Registrierung beider Datensätze erschwert, da die Lageungenauigkeiten von Objekten mit vertikaler Komponente aufgrund von Verkippungseffekten im Radarbild ohne entsprechend hochaufgelöstes Geländemodell nicht kompensiert werden können. Allerdings dürften diese Effekte im Kontext der regionalen Analysen keinen nennenswerten Einfluss ausüben.

Von wesentlich entscheidenderer Bedeutung für die Auswertung ist die Tatsache, dass die Bildinhalte beider Datentypen aufgrund der variierenden Aufnahmetechnik grundverschiedene Eigenschaften der betrachteten Oberflächen beschreiben (VGL. KAP. 2.1). Während das Erscheinungsbild einer SAR-Aufnahme maßgeblich durch die geometrische Charakteristik, die Rauigkeit und die elektrische Leitfähigkeit der erfassten Oberflächen bestimmt wird, spielen diese physikalisch-geometrischen Eigenschaften für die Merkmale optischer Aufnahmen eine weit weniger bedeutende Rolle. Vielmehr übt in diesem Kontext die physikalisch-chemische Beschaffenheit der betrachteten Medien den größten Einfluss aus.

Vor diesem Hintergrund zeichnen sich im Radarbild die Strukturierung und Textur der erfassten Oberflächen bedeutend besser ab als im verwendeten optischen Datensatz, während die optische Aufnahme umgekehrt eine aussagekräftigere Charakterisierung des Bedeckungstyps ermöglicht.

Daher sollen die bisher rein SAR-basierten Attribute des bestehenden Regelwerks nun so durch komplementäre *Merkmale des optischen Datensatzes* ergänzt werden, dass sie eine präzisere Charakterisierung der Raumeinheiten ermöglichen und damit die Identifizierung der siedlungsbezogenen Klassen verbessern. Die Modifikationen im Zusammenhang mit der Integration zusätzlicher Polarisierungen oder Frequenzen begannen bisher stets mit den *stark strukturierten Arealen*. Im Hinblick auf die Integration optischer Bilddaten setzen die Ergänzungen in den klassenspezifischen Merkmalsbeschreibungen allerdings erst eine Stufe später, also im Anschluss an die Identifizierung der *stark strukturierten Areale*, ein (VGL. ABB. 4-24). Dies liegt darin begründet, dass die optischen Daten aufgrund ihrer deutlich geringeren räumlichen Auflösung gegenüber dem rein SAR-basierten Ansatz keine robusteren Kriterien zur Identifizierung der stark untergliederten Raumeinheiten beisteuern können.

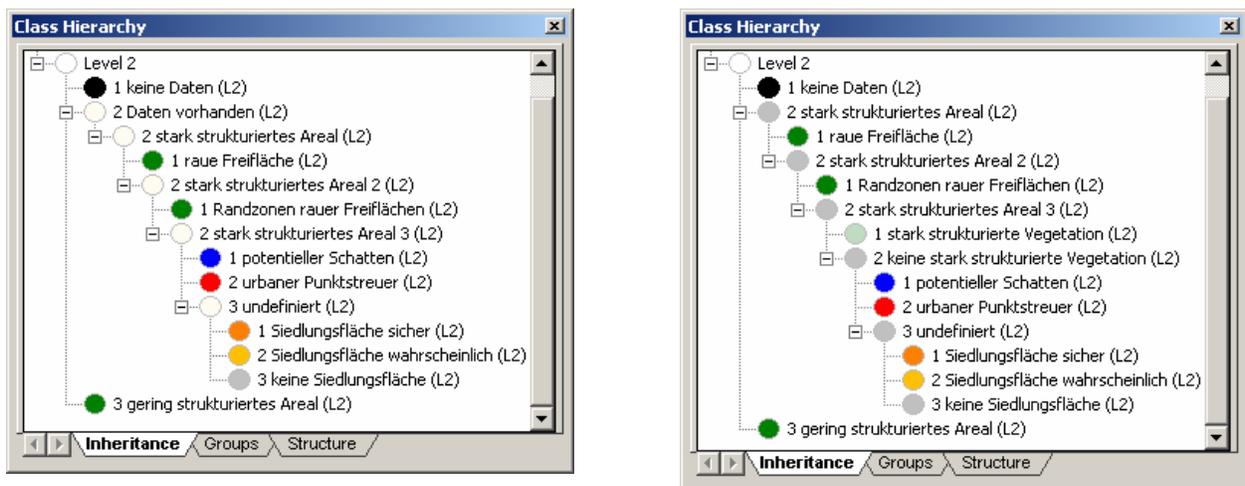


Abb. 4-24: Regelwerk zur Siedlungserfassung (l.) und modifizierte Wissensbasis zur kombinierten Auswertung optischer und radarbasierter Daten (r.)

Im Gegensatz zu den zuvor genutzten Regelwerken werden jedoch im Anschluss an die Ausweisung der hochstrukturierten Bildbereiche innerhalb dieser Areale sämtliche Vegetationsflächen extrahiert (VGL. ABB. 4-24). Zur Identifizierung der *stark strukturierten Vegetation* werden die Reflektionswerte im Grün- und Rotkanal, vor allem aber der *Normalized Difference Vegetation Index (NDVI)* genutzt (VGL. KAP. 2.1.3). Der NDVI beschreibt die Differenz im Reflektionsverhalten zwischen Rot- und Nah-Infrarotkanal und kann als effektives Merkmal zur Identifizierung von Vegetationsflächen eingesetzt werden.

Mit Hilfe dieses Klassifikationsschrittes, der ausschließlich auf dem optischen Datensatz basiert, können Wald- und Heckenbereiche auf der Grundlage weniger Merkmale extrahiert werden. Dies bietet den Vorteil, dass die betreffenden Areale automatisch von der anschließenden Extraktion der *Schattenflächen* und *urbanen Punktstreuer* ausgenommen sind. Gegenüber dem ursprünglichen Ansatz lassen sich durch das beschriebene Vorgehen insbesondere Ungenauigkeiten in der Abgrenzung zwischen Siedlungsflächen und stark strukturierten Vegetationsbereichen reduzieren (VGL. ABB. 4-25).

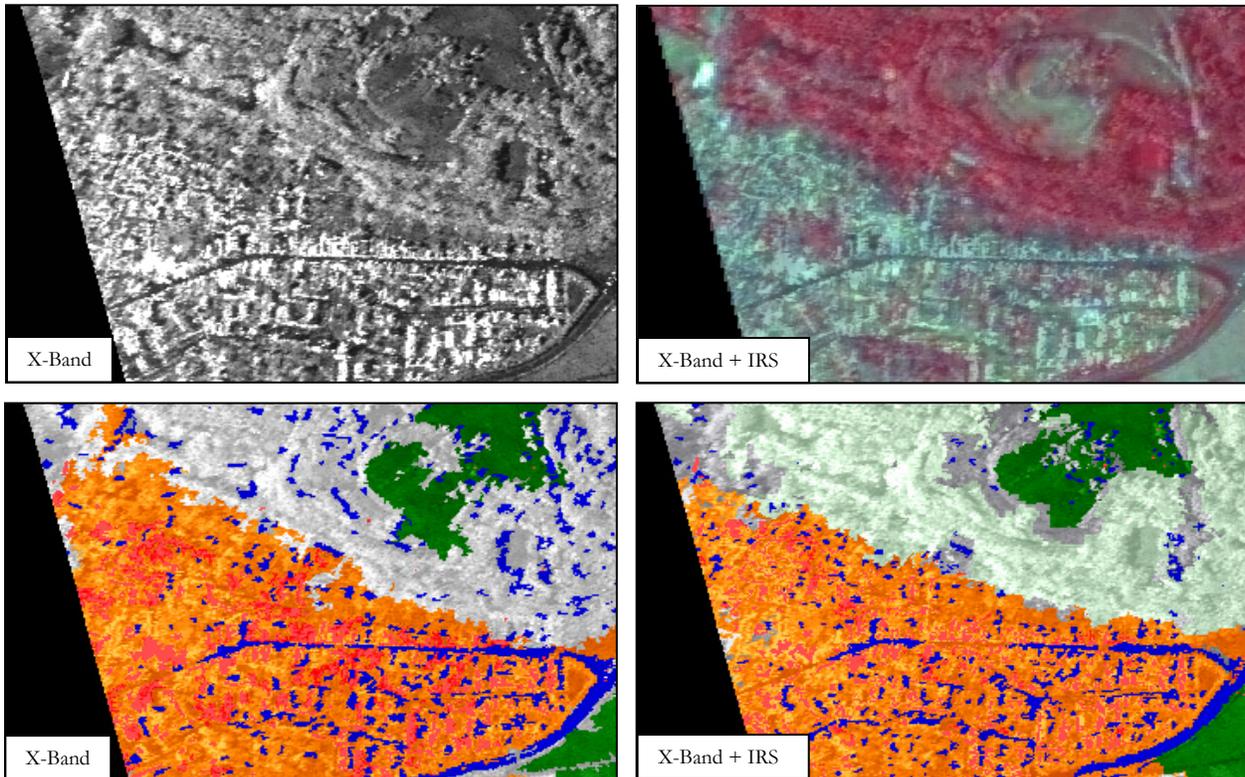


Abb. 4-25: Verbesserte Abgrenzung der Siedlungsränder über die Kombination von SAR-basierten und optischen Daten – Im Gegensatz zur rein SAR-basierten Identifizierung bebauter Areale, die vornehmlich auf strukturellen und texturbezogenen Merkmalen basiert, ermöglicht die Integration des aus optischen Daten abgeleiteten NDVI vor allem eine verbesserte Abgrenzung gegenüber hochstrukturierten Vegetationsflächen.

Der NDVI wird zudem zur akkurateren Identifizierung der *urbanen Punktstreuer* eingesetzt. So wird die ursprüngliche Klassenbeschreibung durch eine Merkmalskombination ergänzt, die vorschreibt, dass weder der vermeintliche Punktstreuer selbst noch dessen unmittelbare Umgebung einen hohen NDVI aufweisen dürfen. Beides würde die Präsenz einer reinen Vegetationsfläche nahe legen. Darüber hinaus wird vorgegeben, dass die Varianz des übergeordneten Superobjektes auch in den optischen Kanälen verhältnismäßig hoch sein muss. Letzteres ersetzt eine aufwendigere Merkmalskombination aus SAR-basierten Attributen, die ursprünglich zur Abgrenzung solcher Ackerflächen notwendig war, die in ihrer Textur nur bedingt von Siedlungsflächen getrennt werden konnten.

Abschließend werden die Kategorien *Siedlungsfläche sicher* und *Siedlungsfläche wahrscheinlich* so ergänzt, dass eine fehlerhafte Ausbreitung beider Klassen in hochstrukturierte Nachbarbereiche von tatsächlichen Siedlungsflächen eingedämmt wird. Dazu wird der NDVI eingesetzt, wobei definiert ist, dass die Umgebung eines potentiellen Siedlungsobjekts einen bestimmten Wert dieses Indizes nicht überschreiten darf. Sollte dies der Fall sein, handelt es sich mit hoher Wahrscheinlichkeit um eine rein vegetationsbedeckte Fläche und die Ausweisung eines besiedelten Areals wird ausgeschlossen.

4.2.3 Diskussion der Ergebnisse

4.2.3.1 Einfach-polarisierte SAR-Aufnahmen

Die Erstellung der Wissensbasis zur Analyse einfach-polarisierter SAR-Daten basiert auf einem kleinen Ausschnitt des ersten Flugstreifens im X-Band (HH-Polarisation), wobei der gesamte Klassifikationsablauf in Form eines Protokolls festgehalten ist. Um letztlich belastbare Aussagen zu ermöglichen, wurde das entwickelte Regelwerk daher zunächst mit Hilfe des entsprechenden Protokolls jeweils automatisiert auf die drei vollständigen Flugstreifen des X-Bandes angewendet. Zusätzlich wurde das Klassifikationsschema auf co-polarisierte C- und L- Band Daten übertragen. Eine Auswertung basierend auf der kreuz-polarisierten Aufnahme war leider nicht möglich, da die entsprechenden C-Band bzw. L-Band Datensätze ein zu schlechtes Signal-zu-Rausch-Verhältnis aufwiesen. Dies hat insbesondere die klare Identifizierung von Schattenflächen, aber auch die Berechnung einiger kontext- sowie texturbezogener Merkmale zu sehr eingeschränkt.

Zur Kalkulation der *thematischen Genauigkeit* der jeweiligen Auswertung wurden für jeden Aufnahme-streifen 250 *Referenzpunkte* definiert, um diese mit den Ergebnissen der Klassifizierungen abzugleichen. Dabei sind die entsprechenden Punkte so gewählt, dass sie in allen betrachteten Datensätzen – deren räumliche Abdeckung zum Teil leicht variiert – innerhalb der aufgezeichneten Fläche liegen. Als Referenzdatensatz dienten die hochauflösenden Luftbilder der Städte Ludwigshafen und Mannheim, sowie die zeitgleich mit der SAR-Befliegung erhobenen Luftbilddaten, die jedoch nur für einen Teil des Untersuchungsgebietes vorlagen (VGL. KAP. 3.2).

Im Folgenden sollen zunächst die auf der Basis der co-polarisierten SAR-Aufnahmen erzielten Ergebnisse vorgestellt und eingehend erläutert werden.

Die Güte der auf Basis der X-Band Daten erzielten Resultate ist in TABELLE 4-5 dargestellt. Wie diese belegt, lassen sich mittels des entwickelten Regelwerks *Siedlungsflächen* mit einer Genauigkeit von deutlich *über 90 Prozent* erfassen. Dabei werden die geringsten Werte mit *90,63 Prozent* für die Hersteller- und *93,55 Prozent* für die Nutzergüte im Zusammenhang mit der Auswertung des ersten Flugstreifens erzielt. Dies dürfte darauf zurückzuführen sein, dass die Siedlungsfläche innerhalb dieses Testareals nicht in dem Maße dominiert, wie in den beiden übrigen Aufnahmestreifen. Somit weist diese Testfläche letztlich das höchste Potential hinsichtlich fehlerhafter Zuweisungen auf. Aus einem Blick auf die zugehörigen Fehlermatrizen geht hervor, dass Fehlzugeweisungen im Kontext *tatsächlicher Siedlungsflächen* vor allem im Zusammenhang mit der Klasse *Baumbestand* auftreten, während auf der anderen Seite insbesondere *Offenland* fälschlicherweise als *Siedlung* klassifiziert wird (VGL. ANHANG D).

Darüber hinaus verdeutlicht TABELLE 4-5, dass sich über den entwickelten Ansatz auch die einfachen Landnutzungskategorien hinreichend genau bestimmen lassen. So kann die *Landnutzung* in *allen drei Aufnahmestreifen* mit einer Gesamtgenauigkeit von *rund 90 Prozent* abgeleitet werden. Schwankungen in der Güte zwischen den einzelnen Testarealen resultieren insbesondere aus Schwierigkeiten, die in Aufnahmestreifen 2 und Aufnahmestreifen 3 im Kontext der Klassifikation von Wasserflächen aufgetreten sind. Diese Fehlzugeweisungen werden zu einem späteren Zeitpunkt umfassend diskutiert.

Tab. 4-5: Thematische Güte der Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten

Klasse	Aufnahmestreifen 1		Aufnahmestreifen 2		Aufnahmestreifen 3	
	Hersteller*	Nutzer**	Hersteller*	Nutzer**	Hersteller*	Nutzer**
Siedlung	90,63%	93,55%	95,71%	97,50%	95,98%	95,98%
Offenland	89,83%	95,50%	87,18%	79,07%	95,83%	62,16%
Baumbestand	93,94%	72,09%	78,26%	64,29%	83,33%	75,00%
Wasser	100,00%	100,00%	76,00%	100,00%	52,94%	94,74%
Gesamt	90,80 %		90,80 %		89,20 %	

* Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse eigentlich angehören

** Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse insgesamt zugewiesen wurden

Die Konstanz in der Qualität der Klassifikationen – speziell in Bezug auf die Identifizierung von Siedlungsflächen – kann als Beleg für die thematische und räumliche Robustheit des entwickelten Ansatzes angesehen werden. Dies wird durch einen Blick auf die ABBILDUNGEN 4-26 bis 4-28 bekräftigt. Dort werden die Ergebnisse der einzelnen Klassifizierungen jeweils dem betreffenden Ausschnitt einer digitalen topografischen Karte (DTK25) gegenübergestellt. In diesem Zusammenhang zeigt sich, dass gerade die Verteilung der als *Siedlungsflächen* klassifizierten Areale gut mit der tatsächli-

chen Lage der Ortschaften übereinstimmt. Größere Abweichungen treten lediglich im Far-Range-Bereich (Osten) sowie im Kontext von Neubaugebieten bzw. Park- und Kleingartenanlagen auf.

Die Unterschiede im Zusammenhang mit Neubaugebieten liegen maßgeblich darin begründet, dass diese in der DTK25 stets über den gesamten, diesbezüglich ausgewiesenen Bereich dargestellt werden. Demnach werden auch Flächen als besiedelte Areale aufgeführt, die bisher noch nicht erschlossen bzw. bebaut sind. Als Beispiel können zwei in ABBILDUNG 4-26 erfasste Neubaugebiete aufgeführt werden, von denen sich eines zentral im Norden des Flugstreifens befindet, während das andere im Südosten liegt. In beiden Fällen ist erkennbar, dass im Rahmen der automatisierten Auswertung lediglich kleinere Teilbereiche dieser Areale als Siedlungsflächen identifiziert werden. Wie ABBILDUNG 4-29 verdeutlicht, resultieren diese Abweichungen vor allem aus der Tatsache, dass sich die Klassifizierung vornehmlich an der Verteilung der urbanen Punktstreuer orientiert. Folglich werden Siedlungsareale nur dort ausgewiesen, wo bereits mehrere Häuser stehen, sprich eine signifikante Dichte an Punktstreuern und Schattenflächen vorliegt. Demgegenüber werden die übrigen Bereiche entweder als *Baumbestand* klassifiziert – sofern sich in der näheren Umgebung mehrere *Schatten-Segmente* befinden – oder den *Freiflächen* zugeordnet. Die fehlerhafte Ausweisung von Baumbeständen legt nahe, dass die Kennzeichnung dieser Klasse durch weitere Attribute präzisiert werden sollte.

Im Kontext von Kleingartenanlagen rühren die visuellen Divergenzen zwischen Klassifikation und Referenz daher, dass diese Bereiche in der DTK25 stets als grün eingefärbte *Flächen* dargestellt sind. Demgegenüber wird dieser Strukturtyp im Rahmen der automatisierten Klassifizierung entweder den *Siedlungsflächen* oder der Kategorie *Baumbestand* zugeordnet. Diese Schwierigkeit in der Klassenzuweisung liegt in der Charakteristik von Kleingartenanlagen begründet. Diese sind in aller Regel durch ein dichtes Nebeneinander von Lauben, Freiflächen, Bäumen und Hecken geprägt. Folglich handelt es sich um hochstrukturierte Bereiche, die immer dann als *Siedlung* klassifiziert werden, wenn eine hinreichende Erkennbarkeit der einzelnen Gartenhäuser und Lauben gewährleistet ist. Sind sie in Blickrichtung des SAR-Systems nicht von Hecken oder Bäumen verdeckt, wirken sie als signifikante Streuzentren und das entsprechende Areal wird in aller Regel als bebaute Fläche eingestuft. Treten die Gebäude aufgrund mangelnder Sichtbarkeit nicht in Erscheinung, liegt mit hoher Wahrscheinlichkeit eine stark untergliederte Fläche vor, die zahlreiche Schattenflächen, jedoch kaum Streuer aufweist. Folglich wird sie als *Baumbestand* klassifiziert.

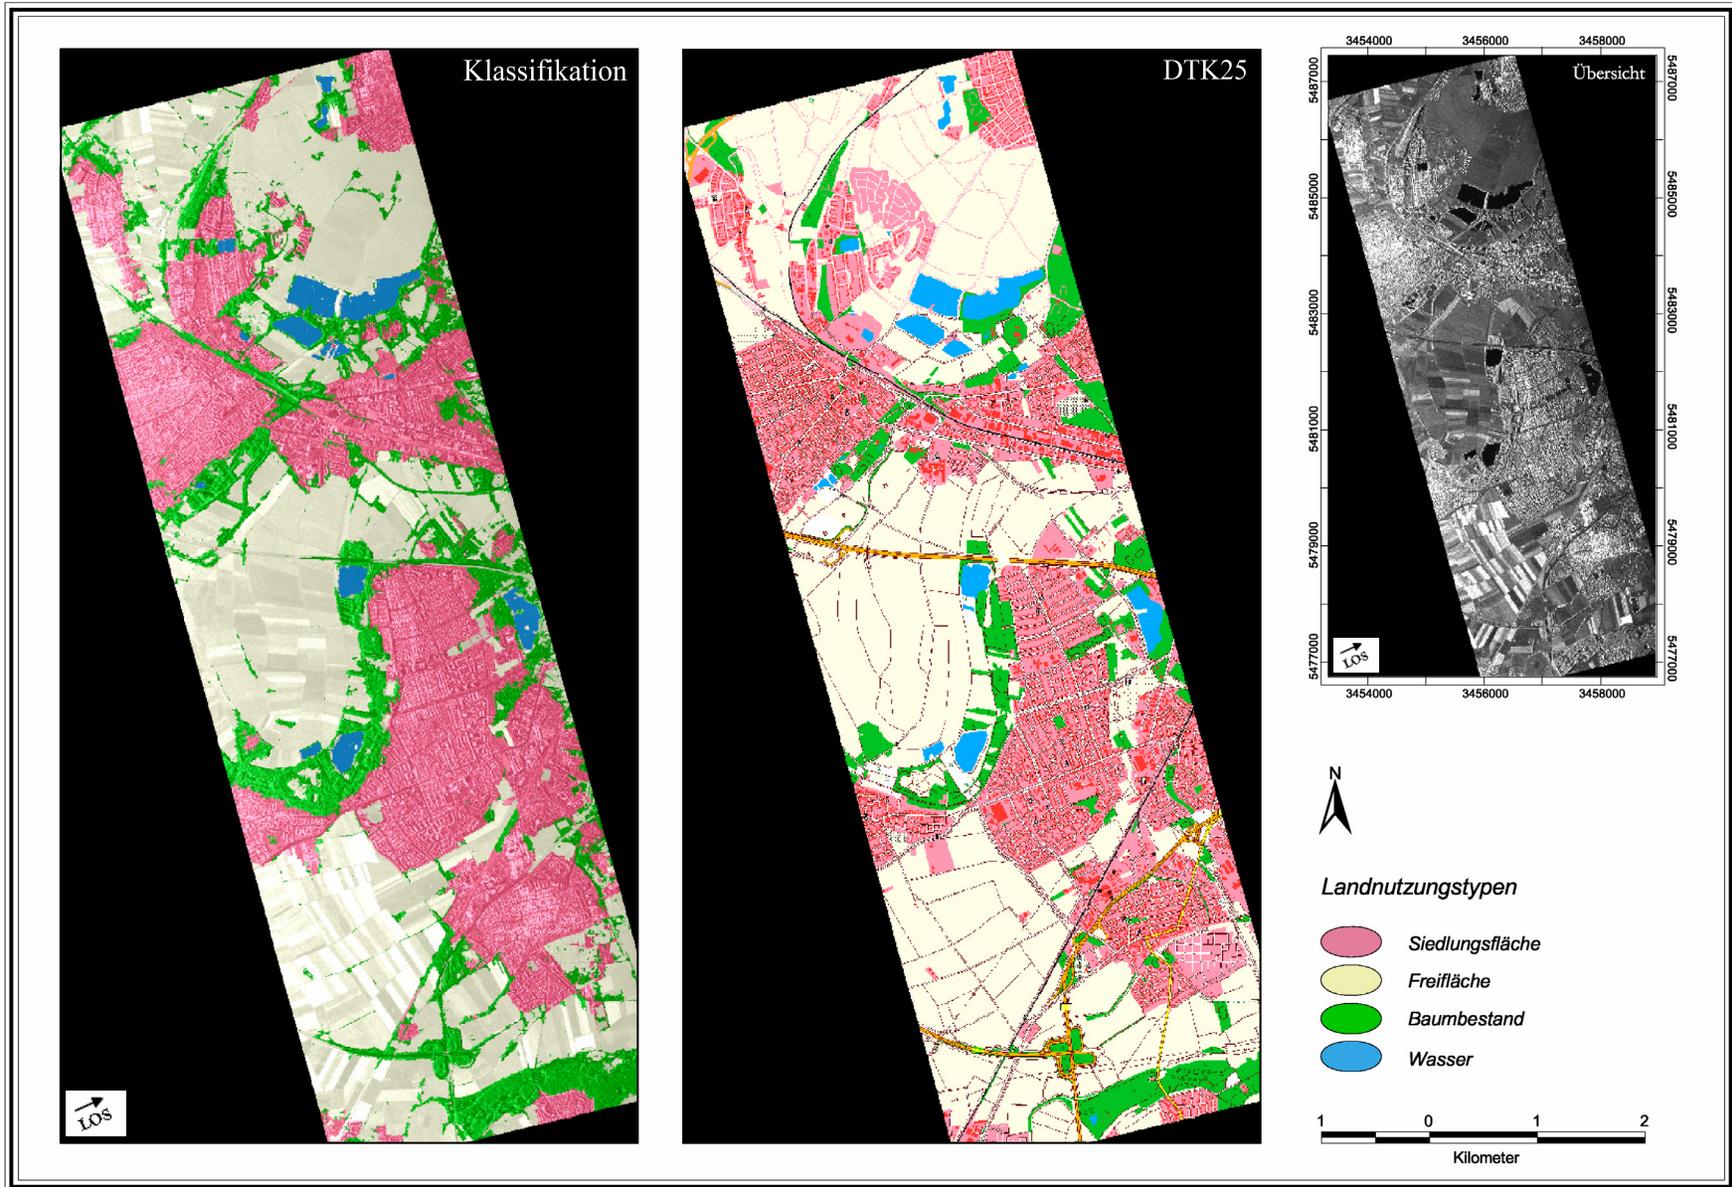


Abb. 4-26: Regionale Landnutzungs-klassifikation auf der Basis einer co-polarisierten X-Band Aufnahme im Vergleich zur DTK25 (Flugstreifen 1)

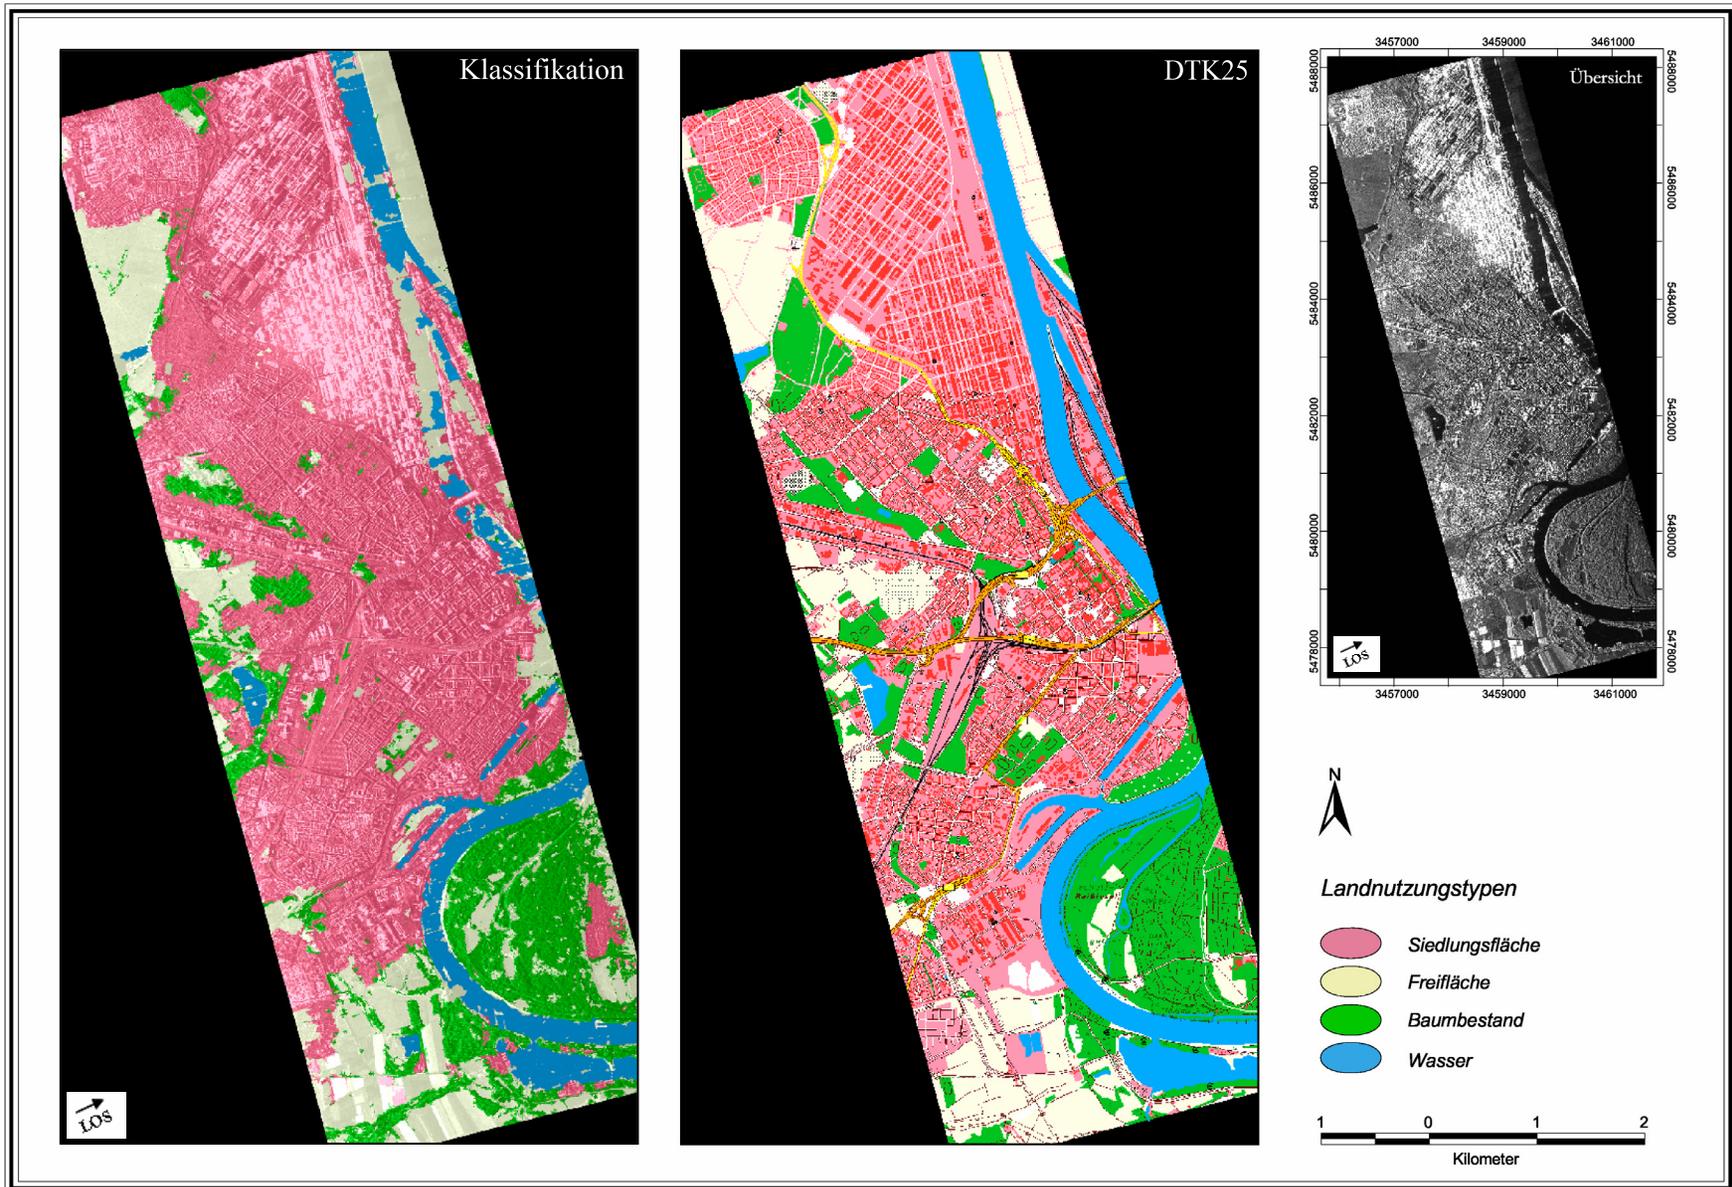


Abb. 4-27: Regionale Landnutzungsklassifikation auf der Basis einer co-polarisierten X-Band Aufnahme im Vergleich zur DTK25 (Flugstreifen 2)

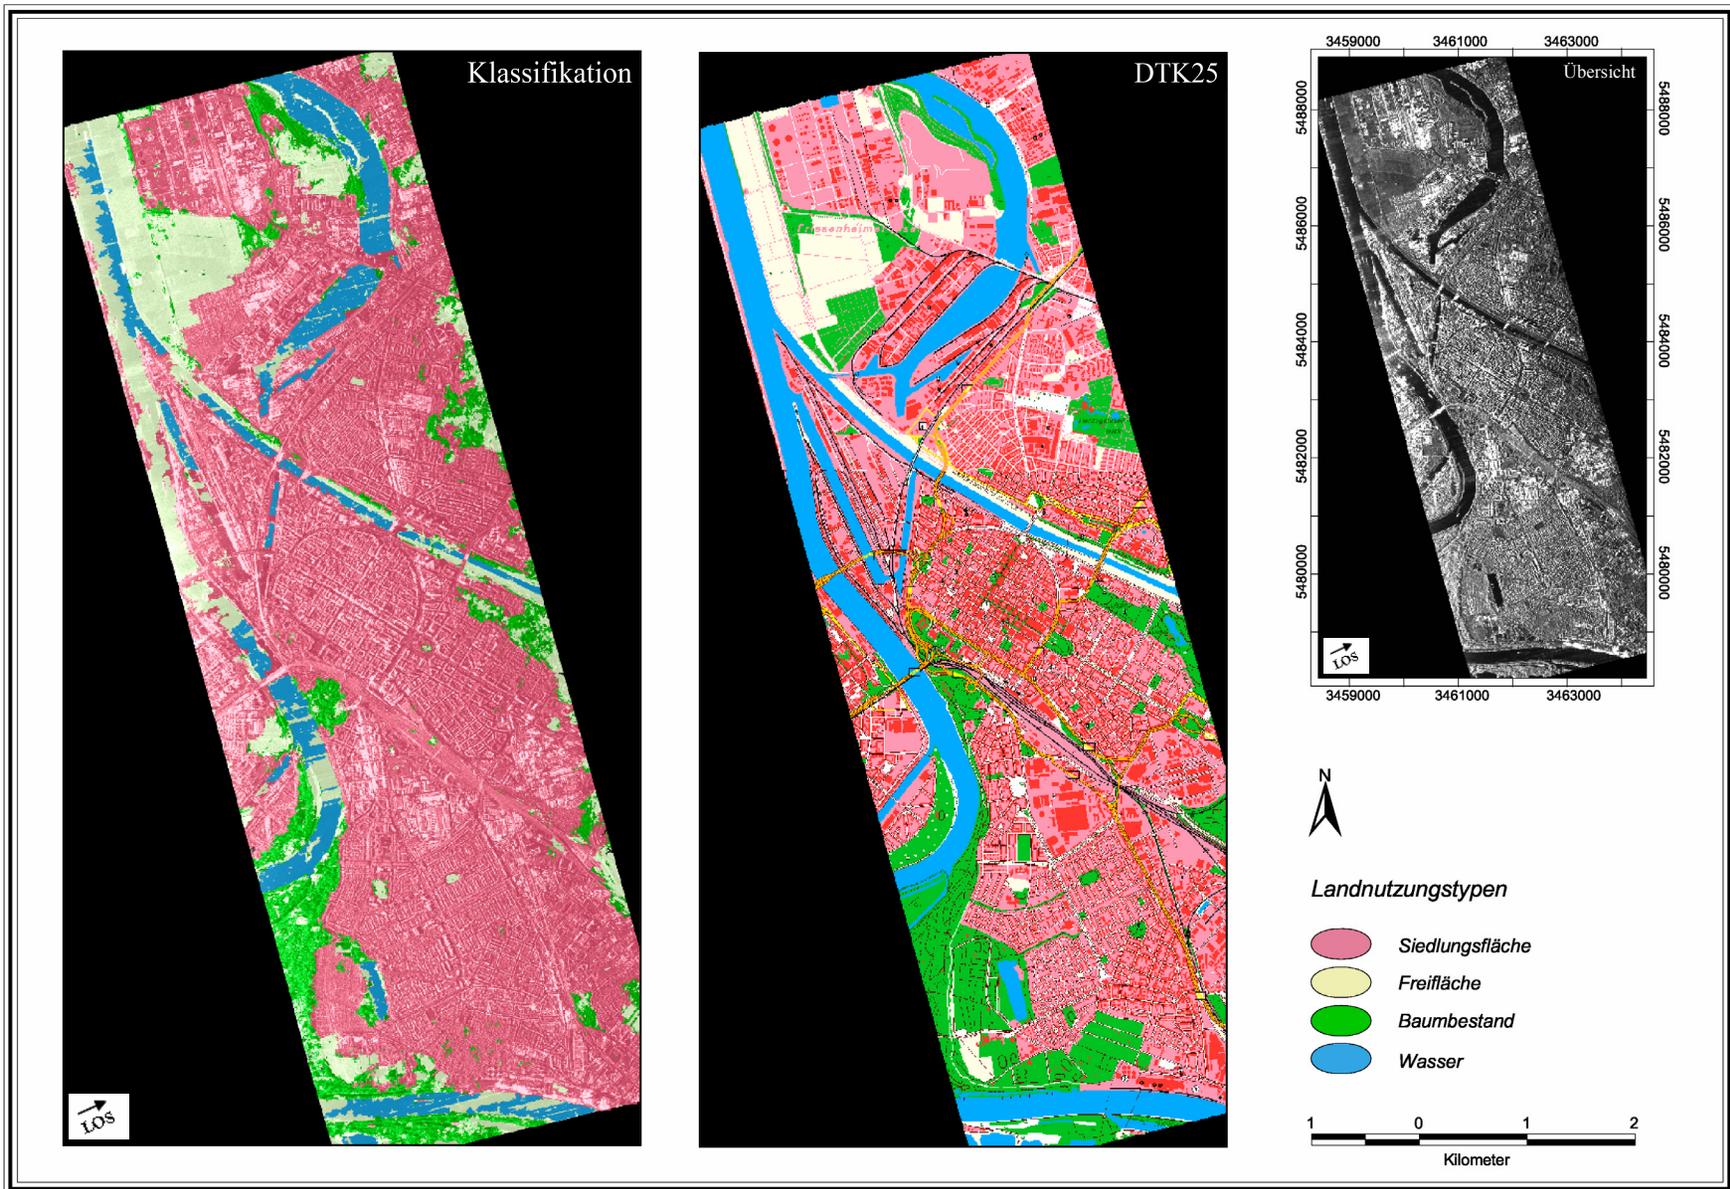


Abb. 4-28: Regionale Landnutzungsklassifikation auf der Basis einer co-polarisierten X-Band Aufnahme im Vergleich zur DTK25 (Flugstreifen 3)

Die Sichtbarkeit, Dichte sowie Verteilung der Lauben und Gartenhäuser können innerhalb einer Kleingartenanlage selbst lokal sehr stark variieren. Im Klassifikationsergebnis äußert sich dies mitunter in einem mehr oder minder stark ausgeprägten Wechsel zwischen den Klassen *Baumbestand* und *Siedlungsfläche*. Eine wesentliche Rolle spielt in diesem Zusammenhang der Depressionswinkel des SAR-Systems. Da die ausgesendete Radarstrahlung zur Far Range hin zunehmend flacher einfällt nimmt die Sichtbarkeit der einzelnen Strukturen signifikant ab. Damit gehen gleichsam eine Reduzierung der Double-Bounce-Effekte und ein deutlicher Anstieg der Schattenflächen einher. In der Folge werden Kleingartenanlagen mit zunehmender Entfernung zum Nadir vermehrt als *Baumbestand* ausgewiesen, während sie in Near Range häufig der Siedlungsfläche zugeordnet sind. Als Beispiel kann eine Anlage aufgeführt werden, die in ABBILDUNG 4-26 im Far-Range-Bereich liegt und zu variierenden Anteilen als *Baumbestand*, *Siedlung* und *Freifläche* ausgewiesen ist (nordöstlicher Bildrand in Nachbarschaft der Seeflächen). Demgegenüber wird die identische Fläche in ABBILDUNG 4-27 – nunmehr in der Near Range gelegen – nahezu vollständig als *Siedlungsfläche* klassifiziert. Vergleichbare Effekte sind zwischen ABBILDUNG 4-27 und 4-28 im südöstlichen bzw. südlichen Bildbereich zu erkennen. Im Hinblick auf Satellitendaten dürfte dieser Effekt jedoch kaum eine Rolle spielen, da derart geringe Depressionswinkel von 20 Grad bis 25 Grad in entsprechenden Aufnahmen nicht auftreten.

Dieses Phänomen zeichnet sich letztlich auch für die eingangs erwähnten Fehlzuweisungen in den Far-Range-Zonen der drei Testgebiete mitverantwortlich. So ist zu erkennen, dass dort bisweilen selbst in verhältnismäßig dicht bebauten Arealen *Baumbestand* oder *Freiflächen* ausgewiesen werden. Ursache dürfte einerseits wiederum der geringe Depressionswinkel in diesem Aufnahmebereich sein, der zu einem erhöhten Anteil an Schattenflächen beiträgt und gleichzeitig das Auftreten charakteristischer Double-Bounce-Reflektionen merklich einschränkt. Aufgrund der damit einhergehenden Reduzierung signifikanter Streuzentren sinkt die Wahrscheinlichkeit der Zuweisung zu einer der Siedlungsklassen. Diese Tendenz wird dadurch verstärkt, dass in den Randbereichen der Aufnahme bei einer Betrachtung der Nachbarschaft stets rund die Hälfte der betreffenden Fläche der Kategorie *keine Daten* angehört. Dadurch ist die theoretisch mögliche Anzahl an Punktstreuern und Schattenflächen in der Umgebung automatisch signifikant eingeschränkt.

Wie bereits zu Beginn dieses Kapitels erwähnt, unterliegt die Klassifizierung der Kategorie *Offenland* speziell im Hinblick auf die Aufnahmestreifen 2 und 3 einer gewissen Schwankung hinsichtlich ihrer Genauigkeit. Während sich die *Herstellergüte* konstant in Bereichen knapp unter bzw. über 90 Prozent bewegt, sackt die *Nutzergenauigkeit* von rund 95 Prozent im ersten Testgebiet über 79 Prozent für Flugstreifen 2 auf lediglich 62 Prozent im Falle des dritten Flugstreifens ab (VGL. TAB. 4-5). Dies bedeutet,

dass verstärkt Flächen als Offenland ausgewiesen werden, die tatsächlich jedoch einer anderen Klasse angehören. Gleichzeitig zeigt TABELLE 4-5, dass im Kontext der Kategorie *Wasser* ein nahezu identischer Trend zu verzeichnen ist – nur betrifft die Abnahme nunmehr die Herstellergenauigkeit, während die Nutzergüte bei nahezu 100 Prozent verbleibt. Es werden also zunehmend tatsächliche Wasserflächen einer anderen Klasse zugeordnet.

Folglich liegt die Vermutung nahe, dass in Flugstreifen 2 und 3 verstärkt reelle Wasserflächen als Offenland ausgewiesen sind. Dieser Eindruck wird durch einen Blick auf die Fehlermatrizen bestätigt (VGL. ANHANG D). So werden im Bereich des zweiten Flugstreifens insgesamt sechs von 25 Wassersegmenten fälschlicherweise als *Offenland* (5) bzw. *Siedlung* (1) klassifiziert, während im dritten Aufnahme­streifen sogar 16 von 34 Wasserflächen nicht korrekt identifiziert werden können. Dabei entfallen 11 Fehlzuweisungen auf die Klasse *Offenland* und fünf auf die Kategorie *Siedlung*. Beim Blick auf ABBILDUNG 4-30 wird deutlich, dass diese Fehlzuweisungen vornehmlich dort auftreten, wo eine Wasserfläche in unmittelbarer Nachbarschaft zu einer stark reflektierenden Raumeinheit liegt.

Wie zu erkennen, wirken speziell Industriekomplexe, Brücken und Gebäude mitunter als extrem starke Reflektionszentren, die nahezu die gesamte einfallende Strahlung in Richtung des Sensors zurückwerfen. Dadurch kommt es am Empfänger des Radarsystems zu Sättigungseffekten, die sich im SAR-Bild als geradlinige, parallel zur Aufnahme­richtung verlaufende Schlieren äußern. Aus ABBILDUNG 4-30 ist klar ersichtlich, dass solche Schlieren große Bereiche der abgebildeten Wasserflächen überlagern. In der Folge werden die Reflektionswerte der in aller Regel sehr dunklen Wassersegmente signifikant angehoben. Zudem ruft dieses Phänomen eine deutlich stärkere Untergliederung dieses ansonsten überaus homogenen Bedeckungstypen hervor. Daraus resultieren Objekteigenschaften, die nicht mehr denen einer charakteristischen Wasserfläche entsprechen. Folglich werden die betreffenden Areale nunmehr inkorrekt als *Offenland* klassifiziert.

Im Vergleich zu den übrigen Klassen ist jedoch gerade die Identifizierung des *Baumbestands* mit den größten Unsicherheiten behaftet (VGL. TAB. 4-5). Dies liegt insbesondere in der Tatsache begründet, dass unter dieser Kategorie letztlich alle hochstrukturierten Bildbereiche zusammengefasst werden, die nicht als heterogene Freiflächen oder Siedlungsareale klassifiziert sind. Ein genauerer Blick auf ABBILDUNG 4-29 offenbart jedoch, dass diese Auslegung offensichtlich eine zu starke Abstraktion der tatsächlichen Verhältnisse darstellt. So kommt es immer wieder zur Ausweisung von Baumbeständen in Bereichen, in denen tatsächlich andere Bedeckungstypen vorliegen. Dieser Umstand legt

nahe, dass die entsprechende Klassenbeschreibung bzw. Merkmalsdefinition weiter differenziert werden sollte, um auf diese Weise eine akkuratere Klassifikation zu gewährleisten.

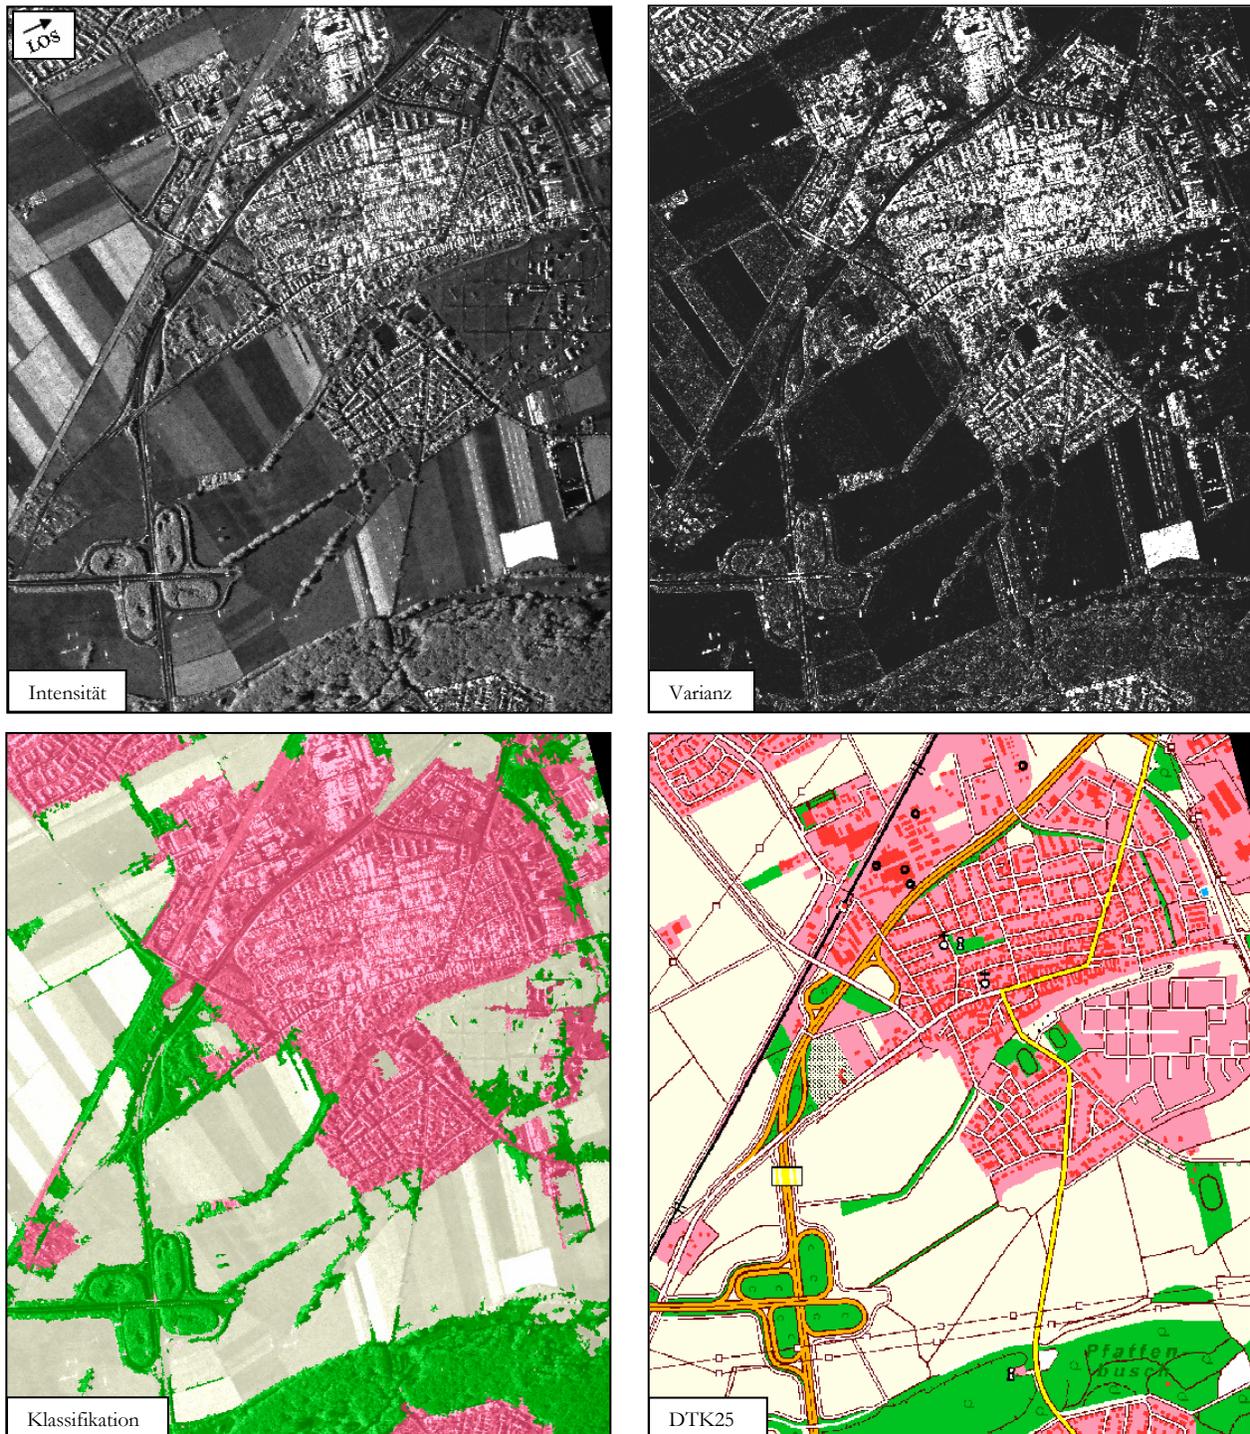


Abb. 4-29: Ausschnitt der regionalen Landnutzungsklassifikation auf Basis HH-polarisierter X-Band Daten – Abweichungen treten speziell im Kontext von Neubaugebieten (Mitte rechts) und Baumbeständen auf. Erstere werden in der Regel nur dort erfasst, wo bereits Gebäude errichtet wurden, während bei den Waldflächen vor allem der Strukturierungsgrad und Anteil an Schattenzonen entscheidend sind.

Im Anschluss an die Betrachtung der räumlichen Übertragbarkeit des entwickelten Regelwerks gilt es darüber hinaus, die *Stabilität des Klassifikationsschemas* gegenüber einer *Variation in der Frequenz* der genutzten Mikrowellenstrahlung zu evaluieren. Daher wurde die auf Basis des X-Band Ausschnitts erstellte Wissensbasis zusätzlich auf C- und L-Band Aufnahmen angewendet. Dabei ist lediglich eine Anpassung der in den Merkmalsdefinitionen genutzten Intensitäts- und Texturwerte vorgenommen worden, während alle weiteren Parameter unverändert geblieben sind. Ersteres ist unvermeidlich, da die Rückstreuquerschnitte identischer Oberflächen in Abhängigkeit der Wellenlänge zu sehr variieren als dass hier identische Werte genutzt werden könnten (VGL. KAP. 2.2.3).

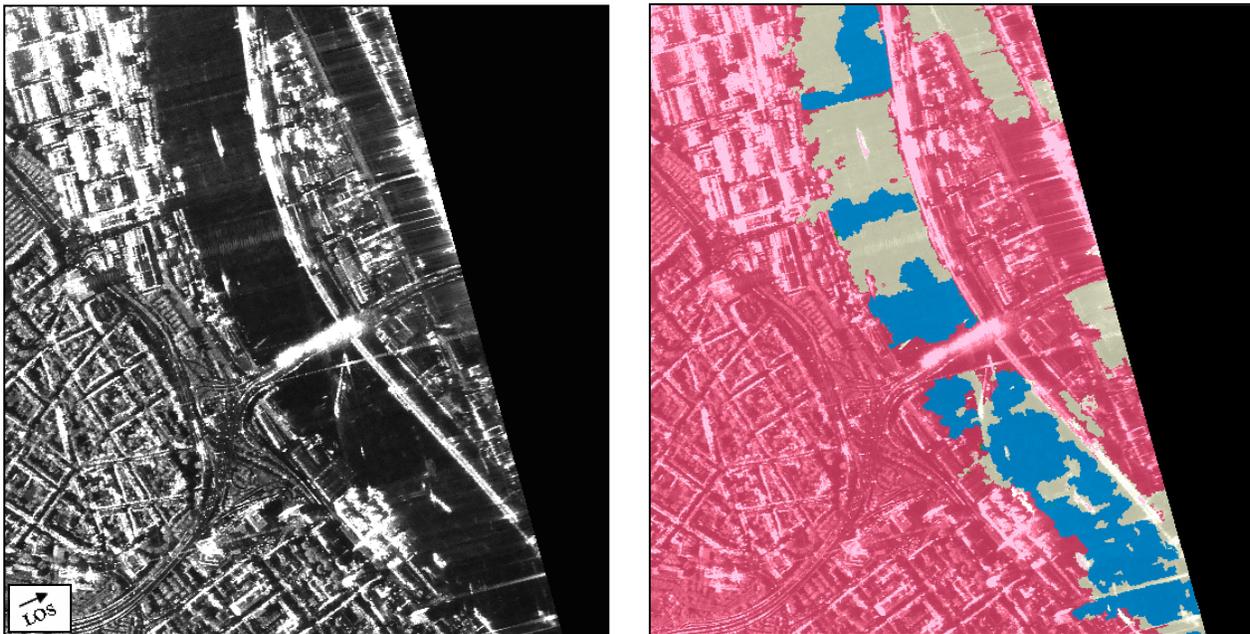


Abb. 4-30: Fehlerhafte Ausweisung von Offenland (beige) im Kontext von Wasserflächen (blau) aufgrund starker Überstrahlungseffekte durch benachbarte Corner-Reflektionen

Die Grundlage für die Untersuchung der Frequenzabhängigkeit bildet der erste Aufnahmestreifen, da dieser eine repräsentative Verteilung aller vier Landnutzungsklassen gewährleistet. In diesem Zusammenhang sei darauf hingewiesen, dass die räumliche Abdeckung des ersten Flugstreifens zwischen den einzelnen Frequenzen geringfügig variiert. So ist die im L-Band aufgezeichnete Szene etwas schmaler, beginnt weiter im Norden und endet im Süden entsprechend weiter nördlich.

Die in der jeweiligen Frequenz erzielte Genauigkeit der Landnutzungskartierung ist in TABELLE 4-6 zusammengefasst. Daraus wird ersichtlich, dass sowohl die *Exaktheit in der Siedlungserfassung* als auch die *Güte der Landnutzungsclassifizierung* bei wechselnder Frequenz lediglich in einer Größenordnung von *zwei bis drei Prozent variieren*. So werden besiedelte Areale im C- und L-Band weiterhin mit einer Genauigkeit von rund 90 Prozent identifiziert. Dabei zeigt ABBILDUNG 4-31, dass sich die im X- und

C-Band erzielten Ergebnisse stärker ähneln als die Resultate zwischen X- und L-Band bzw. C- und L-Band. Auch im Hinblick auf die Klassifikation der übrigen Landnutzungsklassen zeigen sich stärkere Unterschiede zwischen der Auswertung im L-Band und den entsprechenden Ergebnissen des X- und C-Bandes. Dieses Phänomen dürfte darauf zurückzuführen sein, dass die Wellenlängendifferenz und damit das Erscheinungsbild zwischen dem L-Band (23,5cm) und dem X- sowie L-Band und C-Band jeweils deutlich größer ist als die zwischen X- (3,1cm) und C-Band (5,6cm).

Tab. 4-6: Güte der Landnutzungskartierung basierend auf HH-polarisierten X-, C- und L-Band Daten

Klasse	X-Band (HH)		C-Band (HH)		L-Band (HH)	
	Hersteller*	Nutzer**	Hersteller*	Nutzer**	Hersteller*	Nutzer**
Siedlung	90,63%	93,55%	88,54%	90,43%	87,50%	92,31%
Offenland	89,83%	95,50%	93,22%	94,02%	88,22%	92,92%
Baumbestand	93,94%	72,09%	75,76%	69,44%	78,79%	60,47%
Wasser	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Gesamt	90,80 %		89,20 %		87,20 %	

* Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse eigentlich angehören

** Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse insgesamt zugewiesen wurden

Darüber hinaus ist insgesamt eine leicht abnehmende Qualität in der Landnutzungserhebung von 90 Prozent im X-Band, über 89 Prozent im C-Band auf 87 Prozent im L-Band zu verzeichnen. Dabei geht aus TABELLE 4-6 hervor, dass diese steigende Fehlerhaftigkeit maßgeblich aus einer signifikant verschlechterten Identifizierung der Klasse *Baumbestand* resultiert. Dies wird auch durch einen Blick auf die zugehörigen Fehlermatrizen bekräftigt (VGL. ANHANG D).

Die stete Verschlechterung in der Erfassung des *Baumbestands* mit abnehmender Frequenz ist zum einen auf die zunehmende Durchdringung der Vegetationsdecke mit steigender Wellenlänge zurückzuführen. Dadurch wird der Strukturierungsgrad von Waldflächen erheblich herabgesetzt und die charakteristische Textur dieser Flächen sinkt stark ab. Folglich heben sich Waldareale immer weniger von Ackerflächen ab. Zugleich sind die im X-Band deutlich erkennbaren Schattenflächen innerhalb bewaldeter Areale erheblich abgeschwächt (VGL. ABB. 4-32). Die reduzierte Kleinteiligkeit von Waldflächen wird zum anderen durch den Umstand gefördert, dass das räumliche Auflösungsvermögen im L-Band lediglich 2 x 3 Meter beträgt, während sie im X-Band bei rund 2 x 1,8 Metern liegt. In der Summe dieser Effekte wird die Differenzierbarkeit zwischen den Klassen *Offenland* und *Baumbestand* dadurch beträchtlich erschwert, woraus schließlich die steigende Anzahl an Fehlzuweisungen resultiert.

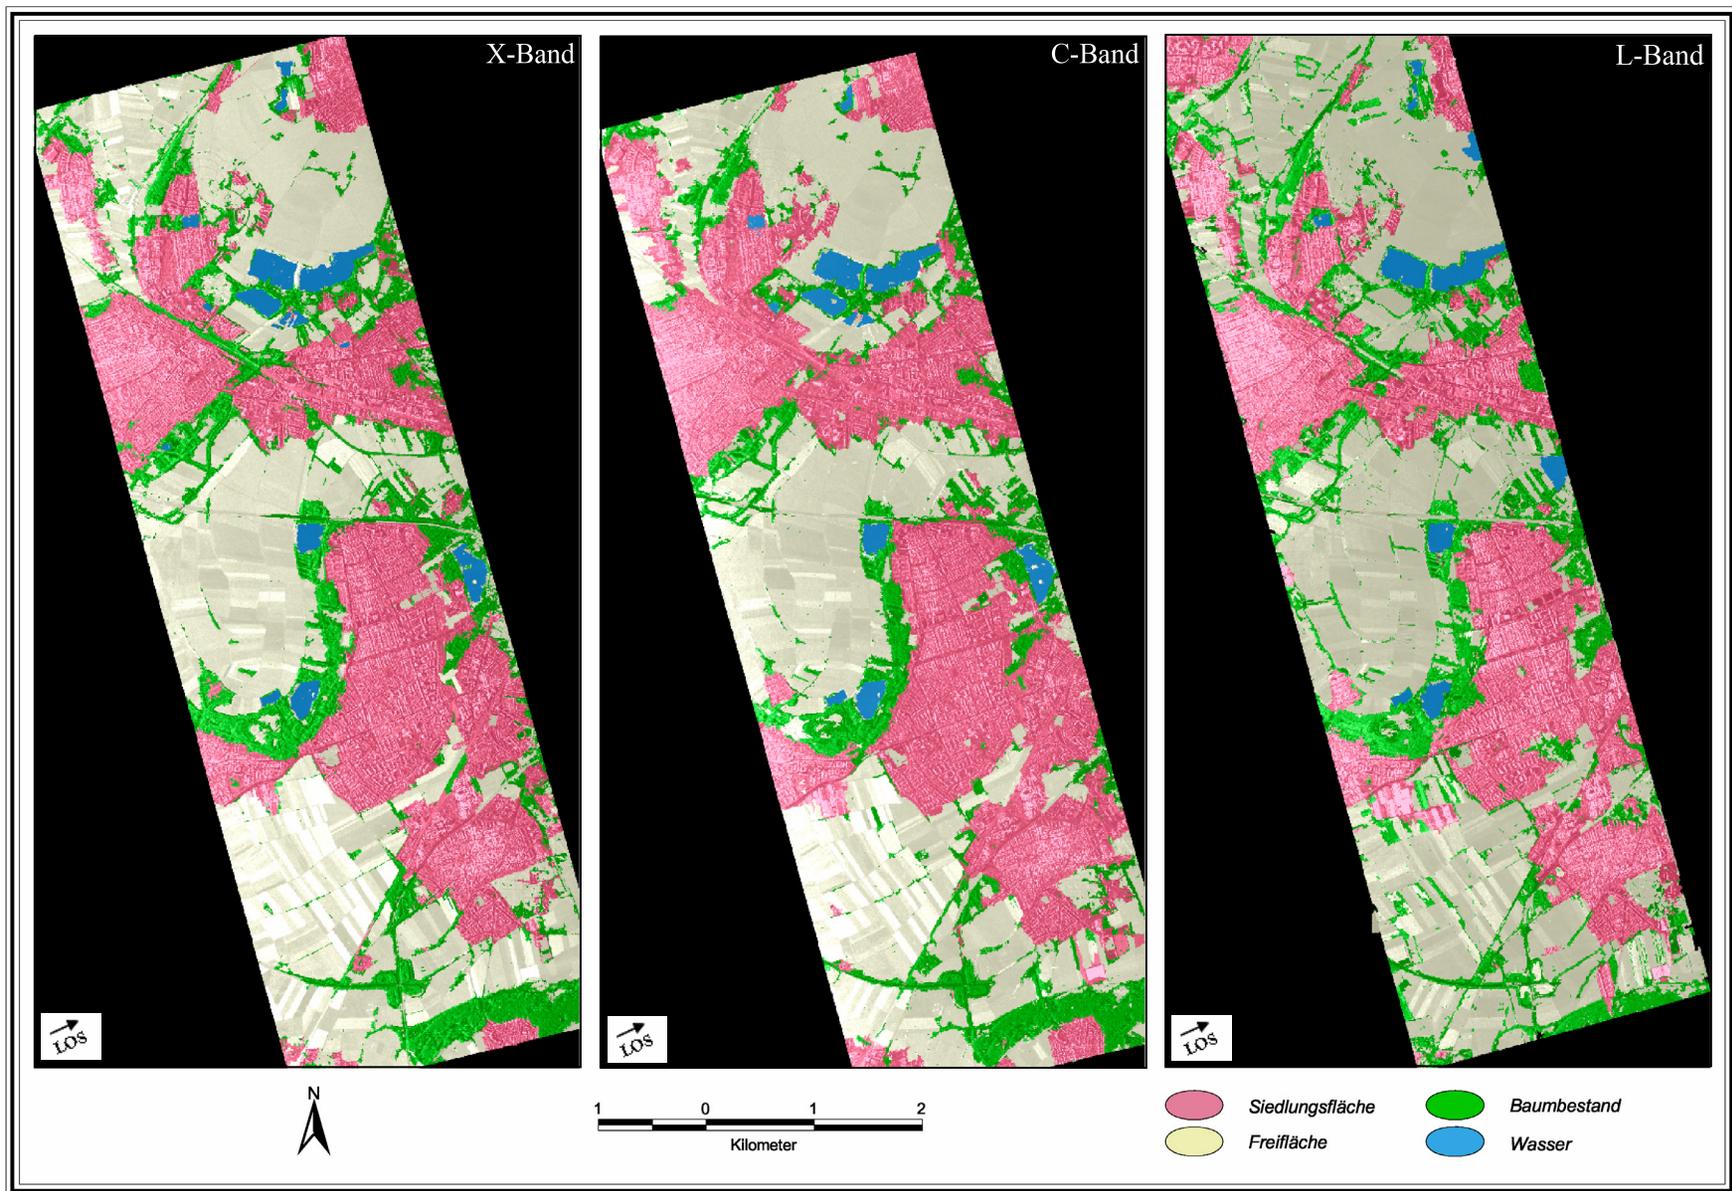


Abb. 4-31: Gegenüberstellung der regionalen Landnutzungsklassifikation basierend auf X-, C- und L-Band Daten

Die mit einer erhöhten Wellenlänge der eingesetzten Radarstrahlung einhergehende stärkere Durchdringung vegetationsbedeckter Oberflächen hat allerdings noch weitere Auswirkungen auf die Klassifizierung der betrachteten Landnutzungskategorien. Einerseits führt ABBILDUNG 4-32 vor Augen, dass die Rückstreucharakteristik im L-Band verstärkt von Strukturen unterhalb der Vegetationsdecke dominiert wird. So ist eine im X-Band vergleichsweise homogen beschaffene Ackerfläche im L-Band von zahlreichen parallel verlaufenden Reihen starker Rückstreuung durchzogen (VGL. ABB. 4-32, rechter Bildrand). In der Folge wird dieses Areal im L-Band als *Siedlungsfläche* ausgewiesen, während das identische Areal auf der Basis der X-Band Aufnahme als *Offenland* klassifiziert ist. Wie aus zeitgleich aufgenommenen, hochaufgelösten Luftbildern hervorgeht, handelt es bei jener Fläche um einen bewässerten, in Reihen mit Nutzpflanzen besetzten Acker. Dabei wird die Reflektionscharakteristik im X-Band offensichtlich weitestgehend vom Blattwerk der Vegetationsdecke bestimmt, wobei die einzelnen Bepflanzungsreihen aufgrund der Schrägsicht und begrenzten Auflösung des Systems nicht in Erscheinung treten. Demgegenüber durchdringt die Strahlung des L-Bands offensichtlich das Blattwerk, so dass die darunter liegenden Ackerfurchen oder Bewässerungsrohre maßgeblich zur Rückstreuung beitragen und letztlich zur fälschlichen Ausweisung einer Siedlungsfläche führen (VGL. ABB. 4-32). Hinzu kommt, dass zudem die Identifizierung von Schattenflächen deutlich erschwert ist, da im L-Band selbst Wiesen- oder Rasenflächen bereits glatt wirken und die Rückstreuwerte daher im Bereich von Schattenflächen liegen.

Ein vergleichbarer Effekt tritt am südlichen Bildrand auf, wo eine im X-Band korrekt klassifizierte Waldfläche im L-Band als Siedlung gekennzeichnet wird. Auch hier kann die langwellige Strahlung des L-Bands offensichtlich in tiefere Schichten eindringen, wo sie durch Reflektion an Baumstämmen oder anderen verdeckten Objekten teilweise stark reflektiert wird. Die daraus resultierenden, punktförmigen Zentren heller Rückstreuung sind schließlich ausschlaggebend für die ebenfalls fehlerhafte Ausweisung einer Siedlungsfläche (VGL. ABB. 4-32).

Obwohl diese Eigenschaft langwelliger Radarstrahlung im Kontext der entwickelten Landnutzungskartierung nachweislich Schwierigkeiten bereitet, können die daraus resultierenden Effekte jedoch auch durchaus einen positiven Einfluss auf die Klassifizierung ausüben. Diesbezüglich sei wiederum auf ABBILDUNG 4-32 verwiesen. Dort ist im oberen Bildbereich zu erkennen, dass eine Kleingartensiedlung auf der Basis der L-Band Aufnahme deutlich akkurater identifiziert wird als dies auf Grundlage der X-Band Daten der Fall ist. Das bessere Resultat im Kontext der Verwendung langwelliger Strahlung ist dabei vor allem auf den verminderten Einfluss der Vegetationsbedeckung zurückzuführen. So befinden sich zwischen den einzelnen Lauben der Kleingartenanlage zahlreiche

Bäume und Büsche (VGL. ABB. 4-23). Diese führen im X-Band dazu, dass ein großer Teil der emittierten Strahlung nicht bis zu den Gebäuden gelangt, sondern zuvor an den Hecken und Bäumen mehr oder minder diffus zurückgeworfen wird. Im Gegensatz dazu kann die langwellige L-Band Strahlung in wesentlich größerem Umfang durch die Vegetation transmittieren, wobei sie dann auf die Gartenlauben trifft und dort durch Double-Bounce-Effekte direkt zum Sensor reflektiert wird (VGL. ABB. 4-23). Folglich treten im L-Band innerhalb der Kleingartenanlage wesentlich mehr Punktstreuer in Erscheinung, die darüber hinaus gleichmäßig über die gesamte Fläche verteilt sind. Somit wird letztlich die gesamte Anlage als bebautes Areal identifiziert, was im X-Band nicht der Fall ist.

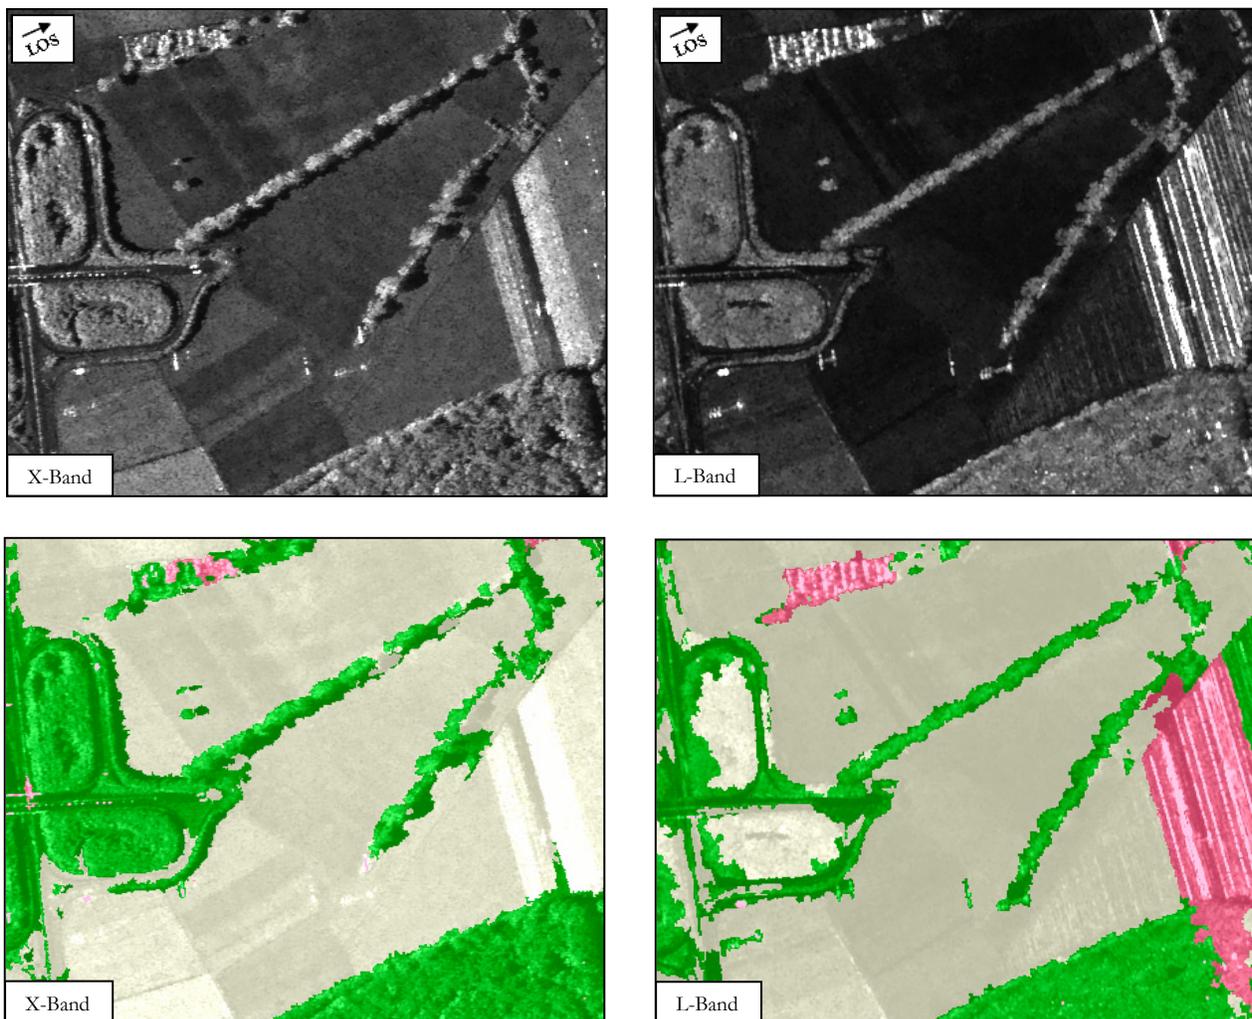


Abb. 4-32: Gegenüberstellung der regionalen Landnutzungsklassifikation im X- und L-Band – Aufgrund der erhöhten Durchdringung von Vegetation mit zunehmender Wellenlänge kann die mit Sträuchern und Bäumen durchsetzte Kleingartenanlage am oberen Bildrand im L-Band akkurater klassifiziert werden. Gleichsam führt dieser Effekt im Kontext von Ackerflächen (u. r.) jedoch dazu, dass die Bodenstruktur (hier: Ackerfurchen oder Bewässerungsrohre) stärker zum Tragen kommt und dabei mitunter siedlungstypische Texturen hervorruft, die zur fehlerhaften Ausweisung bebauter Areale (rot) führen.

4.2.3.2 Dual-polarisierte SAR-Daten

Die Auswertung dual-polarisierter Radaraufnahmen ist insbesondere im Hinblick auf die Fähigkeit des zukünftigen TerraSAR-X Systems zur standardmäßigen Bereitstellung co- und cross-polarisierter SAR-Daten von besonderem Interesse. Daher wurde das vorhandene Regelwerk so modifiziert, dass die ursprüngliche Klassenkennzeichnung auf der Basis gleich-polarisierter Aufnahmen möglichst nutzbringend durch Merkmale der Kreuz-Polarisation (HV) ergänzt werden kann (VGL. KAP. 4.2.2.2). Zur Quantifizierung eines gegebenenfalls mit diesem Schritt einhergehenden Informationsgewinns sollen nachfolgend die Ergebnisse zweier Landnutzungsklassifizierungen verglichen werden, die jeweils auf Basis einer einfach- bzw. einer dual-polarisierten C-Band Aufnahme gewonnen wurden. Leider war es aufgrund eines deutlich verschlechterten Signal-zu-Rausch-Verhältnisses der cross-polarisierten Aufnahme nicht möglich, die Landnutzungsklassifizierung zusätzlich einzig auf Basis der Kreuz-Polarisation durchzuführen, was einen direkten Vergleich zwischen Gleich- und Kreuz-Polarisation ermöglicht hätte. So hat das hohe Rauschlevel die Grauwerte in dunklen Bildbereichen signifikant angehoben, was gerade die Identifizierung von Schattenflächen und die Charakterisierung der ansonsten starken Variation der Rückstreuung in bebauten Arealen signifikant behindert hat.

Die thematische Genauigkeit der Landnutzungsklassifizierung auf Basis der co- bzw. cross-polarisierten Daten ist in TABELLE 4-7 aufgeführt. Daraus geht hervor, dass die Güte der Auswertung durch die Verwendung einer *dual-polarisierten Aufnahme* um *rund 1,6 Prozent von 89,2 Prozent auf 90,8 Prozent gesteigert* wird. An dieser Stelle sei darauf verwiesen, dass die Modifizierung der Klassenbeschreibungen ausschließlich auf jene Unterklassen fokussiert war, die zur Identifizierung der Siedlungsflächen erforderlich sind (VGL. KAP. 4.2.2.2). Folglich zeigt ein Blick auf die entsprechenden Fehlermatrizen, dass die verbesserte Qualität auf eine optimierte Abgrenzung der *Siedlungsflächen* gegenüber den Klassen *Baumbestand* beziehungsweise *Offenland* zurückzuführen ist (VGL. ANHANG D).

So wird auf der Basis der HH-polarisierten Aufnahme jeweils ein Baumbestand- und Offenland-Referenzpunkt fälschlicherweise als Siedlung klassifiziert, während beide Areale auf der Grundlage der dual-polarisierten Daten (HH+HV) der korrekten Klasse zugewiesen werden. Dieser Trend spiegelt sich auch in den ABBILDUNGEN 4-33 und 4-34 wider. Darüber hinaus zeigen die Fehlermatrizen, dass die Integration der Kreuz-Polarisation keine Attribute bereitstellen kann, die eine genauere Erfassung der tatsächlichen Siedlungsflächen ermöglichen (VGL. ANHANG D). Somit wird zwar letztlich die Nutzergenauigkeit im Kontext der Siedlungserfassung um knapp zwei Prozent von 90,43 Prozent auf 92,39 Prozent gesteigert, die Herstellergenauigkeit liegt jedoch weiterhin unverändert bei 88,54 Prozent.

Tab. 4-7: Güte der regionalen Landnutzungserfassung mittels einfach- bzw. dual-polarisierter C-Band Daten

Klasse	C-Band (HH)		C-Band (HH+HV)	
	Hersteller*	Nutzer**	Hersteller*	Nutzer**
Siedlung	88,54%	90,43%	88,54%	92,39%
Offenland	93,22%	94,02%	95,76%	94,17%
Baumbestand	75,76%	69,44%	78,79%	74,29%
Wasser	100,00%	100,00%	100,00%	100,00%
Gesamt	89,20 %		90,80 %	

* Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse eigentlich angehören

** Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse insgesamt zugewiesen wurden

Infolge der optimierten Abgrenzung zwischen der *Siedlung* und den beiden Klassen *Baumbestand* bzw. *Offenland* wird gleichsam die Güte dieser Kategorien signifikant verbessert (VGL. TAB. 4-7). So kann die Herstellergenauigkeit für die Klasse *Offenland* von 93,22 Prozent auf 95,76 Prozent erhöht werden, während die Nutzergüte von 94,02 Prozent leicht auf 94,17 Prozent zunimmt. Gleichzeitig wachsen die Hersteller- und Nutzergenauigkeit der Klasse *Baumbestand* von 75,76 Prozent auf 78,78 Prozent bzw. 69,44 Prozent auf 74,29 Prozent.

Zu diesem verbesserten Ergebnis trägt die optimierte Trennung zwischen homogenen und heterogenen Bildarealen bei. So wird durch die Integration der Kreuz-Polarisation offensichtlich eine akkuratere Identifizierung der *hochstrukturierten Areale* gewährleistet, was im weiteren Verlauf der hierarchisch aufgebauten Klassifizierung zu einer verbesserten Differenzierung zwischen hochstrukturierten Freiflächen und Waldgebieten führt. Letztlich bleibt zu erwähnen, dass sich im Hinblick auf die Erfassung von Wasserflächen keine Unterschiede ergeben. Hier verbleiben sowohl Hersteller- als auch Nutzergenauigkeit bei 100 Prozent.

Wie bereits zu Beginn dieses Unterkapitels erwähnt, ist die reduzierte Fehlerhaftigkeit im Kontext der Auswertung dual-polarisierter SAR-Aufnahmen auf eine verbesserte Abgrenzung zwischen *Baumbestand*, *Offenland* und *Siedlungsfläche* zurückzuführen. So zeigt ein Blick auf ABBILDUNG 4-34, dass durch die Integration der Kreuz-Polarisation speziell im nordöstlichen und südöstlichen Bereich des SAR-Bildes ehemals großflächig falsch ausgewiesene Siedlungsflächen nunmehr korrekt als *Offenland* klassifiziert werden.

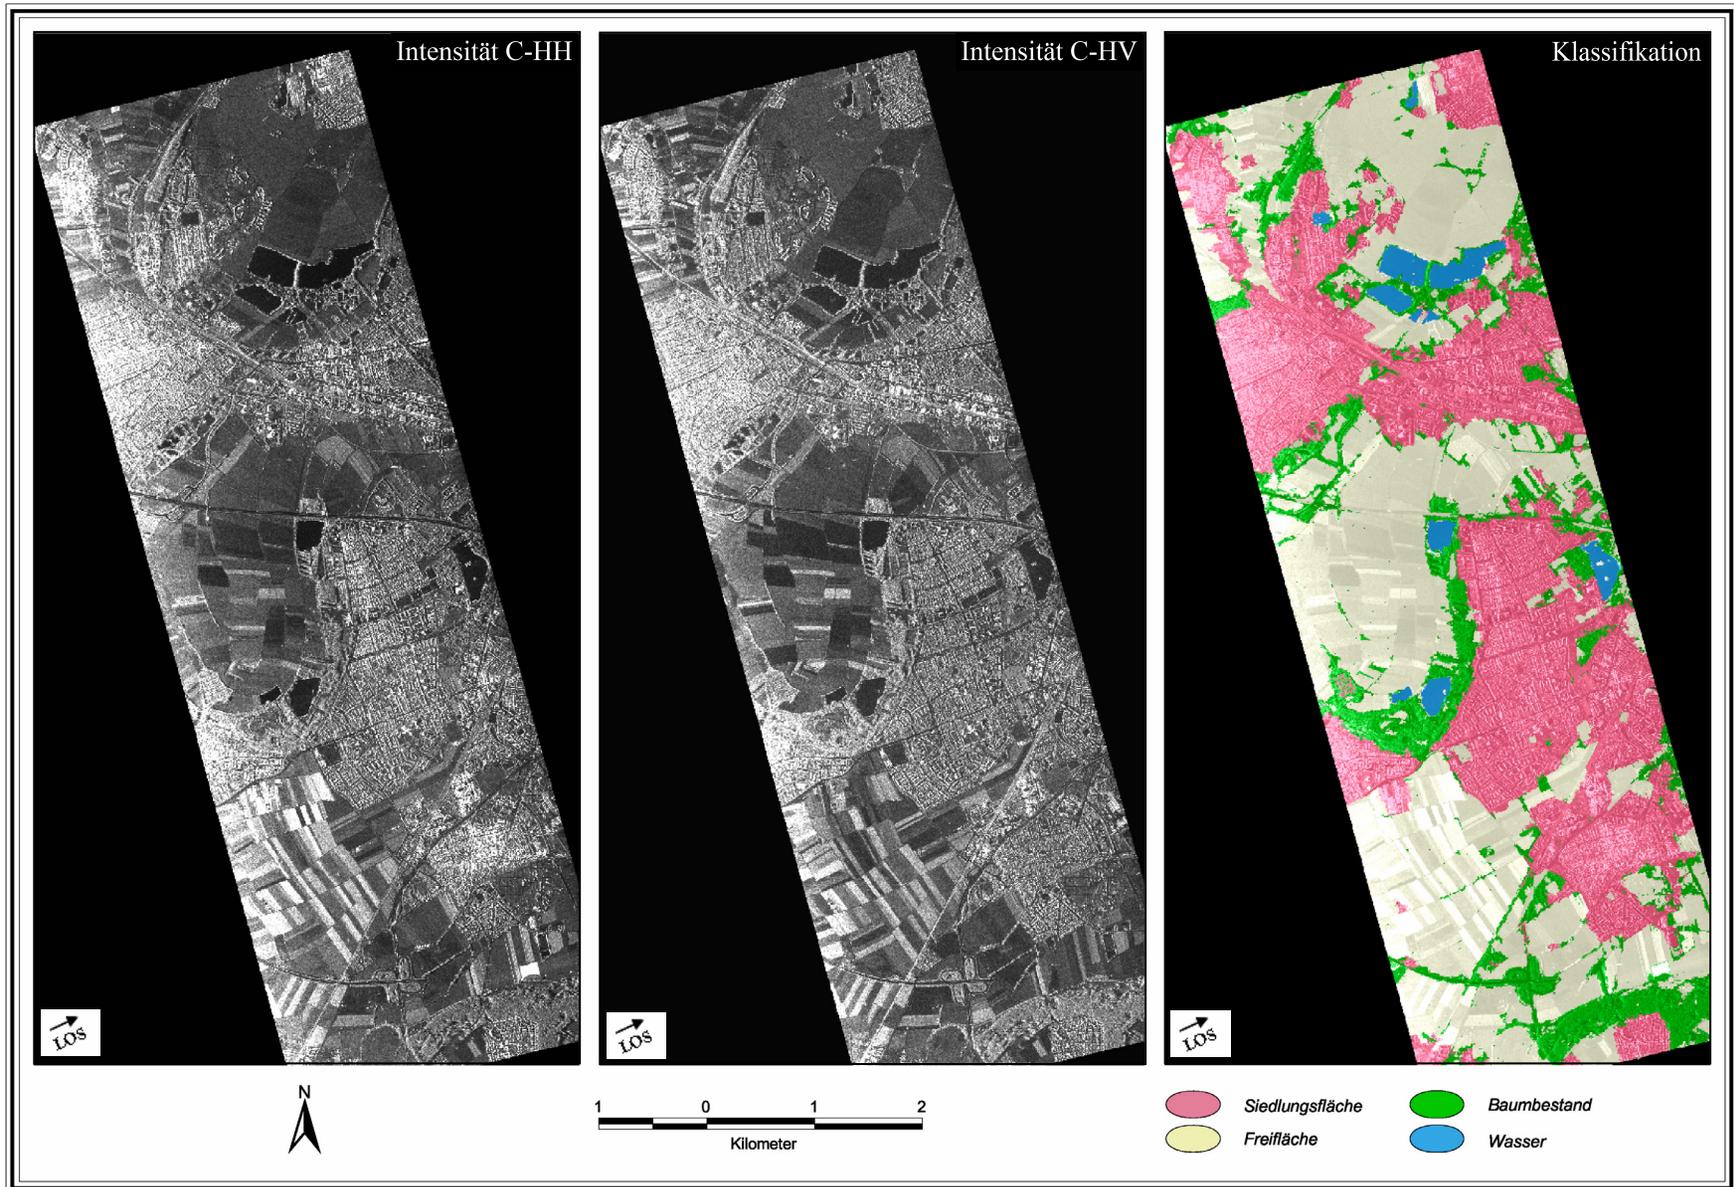


Abb. 4-33: Resultat der regionalen Landnutzungsklassifizierung basierend auf der Auswertung einer dual-polarisierten C-Band Aufnahme (HH,HV)

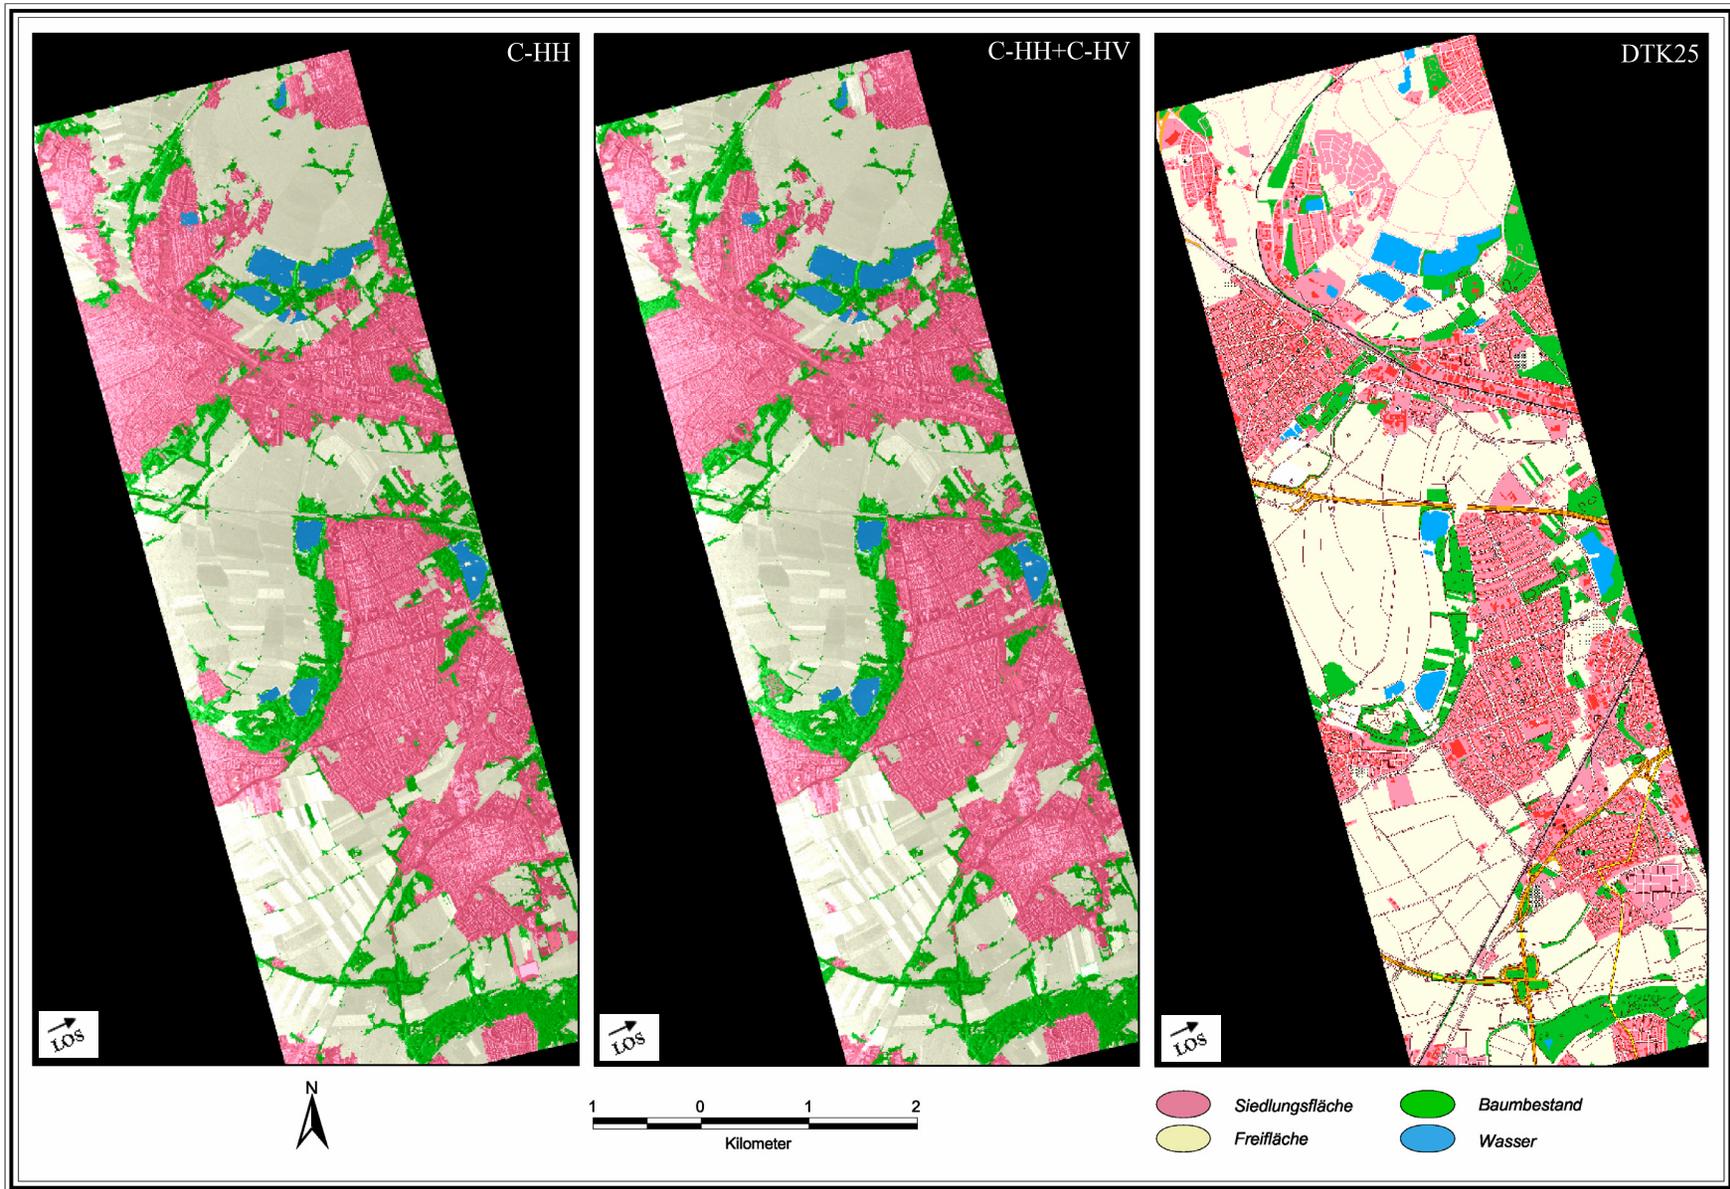


Abb. 4-34: Regionale Landnutzungsklassifikation basierend auf single-polarisierter (HH) bzw. dual-polarisierter (HH,HV) C-Band Datenbasis

Dabei handelt es sich stets um hochstrukturierte Ackerflächen, die erst mit Hilfe der cross-polarisierten Bildinformation eindeutig von einer typischen Siedlungsfläche abgegrenzt werden können. Eines dieser Areale zeigt ABBILDUNG 4-35. Diese Fläche repräsentiert ein von oberirdischen Bewässerungsrohren durchzogenes, ackerbaulich genutztes Areal. Dabei weist diese Fläche in der HH-Polarisation aufgrund des bereits in KAPITEL 4.2.2 angesprochenen Effektes der Dipol-Streuung an den metallischen Wasserleitungen eine außergewöhnlich hohe Textur auf. Zudem befinden sich sowohl in unmittelbarer Umgebung als auch direkt am Rand des betreffenden Areals mehrere Schattenflächen. Folglich wird dieser Bereich auf der Basis der co-polarisierten Aufnahme als *Siedlung* klassifiziert. Demgegenüber entfallen im Kontext der Kreuz-Polarisation jene störenden Reflektionen, die zuvor in erheblichem Umfang zur fälschlichen Ausweisung der Siedlungsflächen beigetragen haben. Daher lässt sich diese Fläche über das Regelwerk zur kombinierten Auswertung der Co- und Cross-Polarisation nunmehr eindeutig als *Offenland* identifizieren.



Abb. 4-35: Verbesserte Abgrenzung bebauter Areale gegenüber bewässerten Ackerflächen durch kombinierte Analyse der Co- und Cross-Polarisation – Die metallenen Bewässerungsrohre bilden in der HH-Polarisation aufgrund direkter Dipolstreuung Zentren intensiver Rückstreuung aus (Pfeile), was mitunter zur fehlerhaften Ausweisung von Siedlungsflächen (rot) führt. In der Kreuz-Polarisation treten diese Streuer hingegen aufgrund fehlender, diffuser Streukomponente nicht mehr in Erscheinung. Folglich kann die zuvor erwähnte Fehlzueweisung durch die kombinierte Auswertung von Gleich- und Kreuz-Polarisation vermeiden.

4.2.3.3 Bifrequente SAR-Daten

Die Unterschiede zwischen der Landnutzungserfassung im X- bzw. L-Band wurden bereits in KAPITEL 4.2.3.1 eingehend dargelegt. Im Gegensatz dazu soll im Rahmen dieses Kapitels die Güte einer *kombinierten Auswertung beider Frequenzen* bewertet werden. Grundlage der entsprechenden Klassifikation ist das Regelwerk zur Analyse einfach-polarisierter X-Band Daten, das durch nutzbringende Merkmale des L-Bands ergänzt wird (VGL. KAP. 4.2.2.2). Auch diese Untersuchung basiert auf den Aufnahmen des ersten Flugstreifens. Aufgrund der variierenden räumlichen Abdeckung des X- bzw. L-Bands wurden die korrespondierenden Datensätze allerdings zuvor so angepasst, dass sie ausschließlich jene Bereiche abdecken, die von beiden Aufnahmen erfasst werden.

Um die Effekte der durch das L-Band bereitgestellten, zusätzlichen Attribute beurteilen zu können, wird das Ergebnis dieses modifizierten Ansatzes in TABELLE 4-8 mit dem der isolierten Auswertung einer co-polarisierten X-Band Aufnahme verglichen. Zudem ist die Güte der entsprechenden L-Band Auswertung aufgeführt. Hinsichtlich der Gegenüberstellung von isolierter L-Band Analyse und bifrequenter Auswertung ist jedoch anzumerken, dass ein solcher direkter Vergleich nur eingeschränkt möglich ist. So beruht die Wissensbasis zur bifrequenten Klassifizierung grundsätzlich auf dem Regelwerk zur Analyse von X-Band Daten, das lediglich durch Merkmale der L-Band Aufnahme ergänzt wurde. Folglich wird die Information beider Datensätze nicht gleichteilig kombiniert. Allerdings sind die Regelwerke zur Auswertung des X- bzw. L-Bandes in ihrem Aufbau völlig identisch. Dies gilt auch für das Gros der Zuweisungsfunktionen, die lediglich hinsichtlich der Schwellwerte im Kontext textur- und intensitätsbezogener Merkmale variieren (VGL. KAP. 4.2.2.2). Vor diesem Hintergrund kann daher davon ausgegangen werden, dass sich die Güte einer L-Band basierten Auswertung durch eine entsprechende Integration von X-Band Merkmalen durchaus in einer Größenordnung bewegen dürfte, die jenen Werten nahe kommt, die aus der direkten Gegenüberstellung in TABELLE 4-8 hervorgehen.

TABELLE 4-8 zeigt, dass die Landnutzung auf Basis der X- bzw. L-Band Aufnahme mit einer Güte von 90,8 Prozent bzw. 87,2 Prozent bestimmt werden kann. Demgegenüber wird über die *verknüpfte Auswertung beider Frequenzen* eine Genauigkeit von 94,8 Prozent erzielt. Durch die Berücksichtigung der langwelligen Information profitiert die Auswertung im X-Band dabei einerseits von einer akkurateren Erfassung der Siedlungsflächen (VGL. ABB. 4-36 und ABB. 4-37). Ein Blick auf die zugehörigen Fehlermatrizen zeigt, dass die Anzahl der korrekt identifizierten Referenzpunkte von 87 auf 91 gesteigert werden kann, während sich die Anzahl der fehlerhaft als Siedlung ausgewie-

senen Referenzen von sechs auf vier reduziert (VGL. ANHANG D). Diese Verbesserung resultiert vor allem aus der akkurateren Abgrenzung gegenüber den Klassen *Baumbestand* sowie *Offenland*, deren Nutzer- und Herstellergüte ebenfalls signifikant ansteigen (VGL. TAB. 4-8).

Tab. 4-8: Güte der regionalen Landnutzungskartierung auf Basis HH-polarisierter X- und L-Band Daten sowie einer kombinierten Auswertung beider Frequenzen

Klasse	X-Band (HH)		L-Band (HH)		X- und L-Band (HH)	
	Hersteller*	Nutzer**	Hersteller*	Nutzer**	Hersteller*	Nutzer**
Siedlung	90,63%	93,55%	87,50%	92,31%	94,79%	95,79%
Offenland	89,83%	95,50%	88,22%	92,92%	94,92%	97,39%
Baumbestand	93,94%	72,09%	78,79%	60,47%	93,94%	83,78%
Wasser	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Gesamt	90,80 %		87,20 %		94,80 %	

* Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse eigentlich angehören

** Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse insgesamt zugewiesen wurden

Im Hinblick auf eine verbesserte Auswertung von L-Band Aufnahmen führt ABBILDUNG 4-36 vor Augen, dass über eine Kombination mit hochfrequenten X-Band Informationen insbesondere die Erfassung der *Baumbestände* optimiert werden kann. So beläuft sich die Herstellergenauigkeit im Kontext der alleinigen Auswertung des L-Bands laut TABELLE 4-8 auf 78,79 Prozent, während über den bifrequenten Ansatz ein Wert von 90,91 Prozent erreicht wird. Im Hinblick auf die Nutzergüte liegt die bifrequente Auswertung mit 83,33 Prozent sogar um mehr als 20 Prozent über der Genauigkeit von 60,47 Prozent beim L-Band-basierten Ansatz. Ein Vergleich der Fehlermatrizen legt nahe, dass diese Tendenz zu etwa gleichen Teilen aus einer verminderten Anzahl an Fehlzuweisung zu den Klassen *Offenland* und *Siedlung* resultiert (VGL. ANHANG D).

Dass sich sowohl die Auswertung von X-Band Aufnahmen als auch die Analyse von L-Band Daten prinzipiell über eine Kombination beider Frequenzen deutlich verbessern lässt, führt ABBILDUNG 4-38 vor Augen. Im Hinblick auf die bifrequente Auswertung ist dabei unter anderem ein künstlich erzeugtes Intensitätsbild abgebildet, das die Informationen der X- und L-Band Aufnahme kombiniert. Dieser Datensatz dient lediglich zu Illustrationszwecken und wurde nicht im Rahmen der Auswertungen eingesetzt. Die in den beiden oberen Zeilen der ABBILDUNG 4-38 dargestellten Klassifikationsergebnisse wurden bereits in KAPITEL 4.2.3.1 vorgestellt und umfassend erläutert. Aus diesem Grunde sollen nunmehr ausschließlich die mit der kombinierten Analyse einhergehenden Veränderungen gegenüber diesen Klassifikationen erörtert werden.

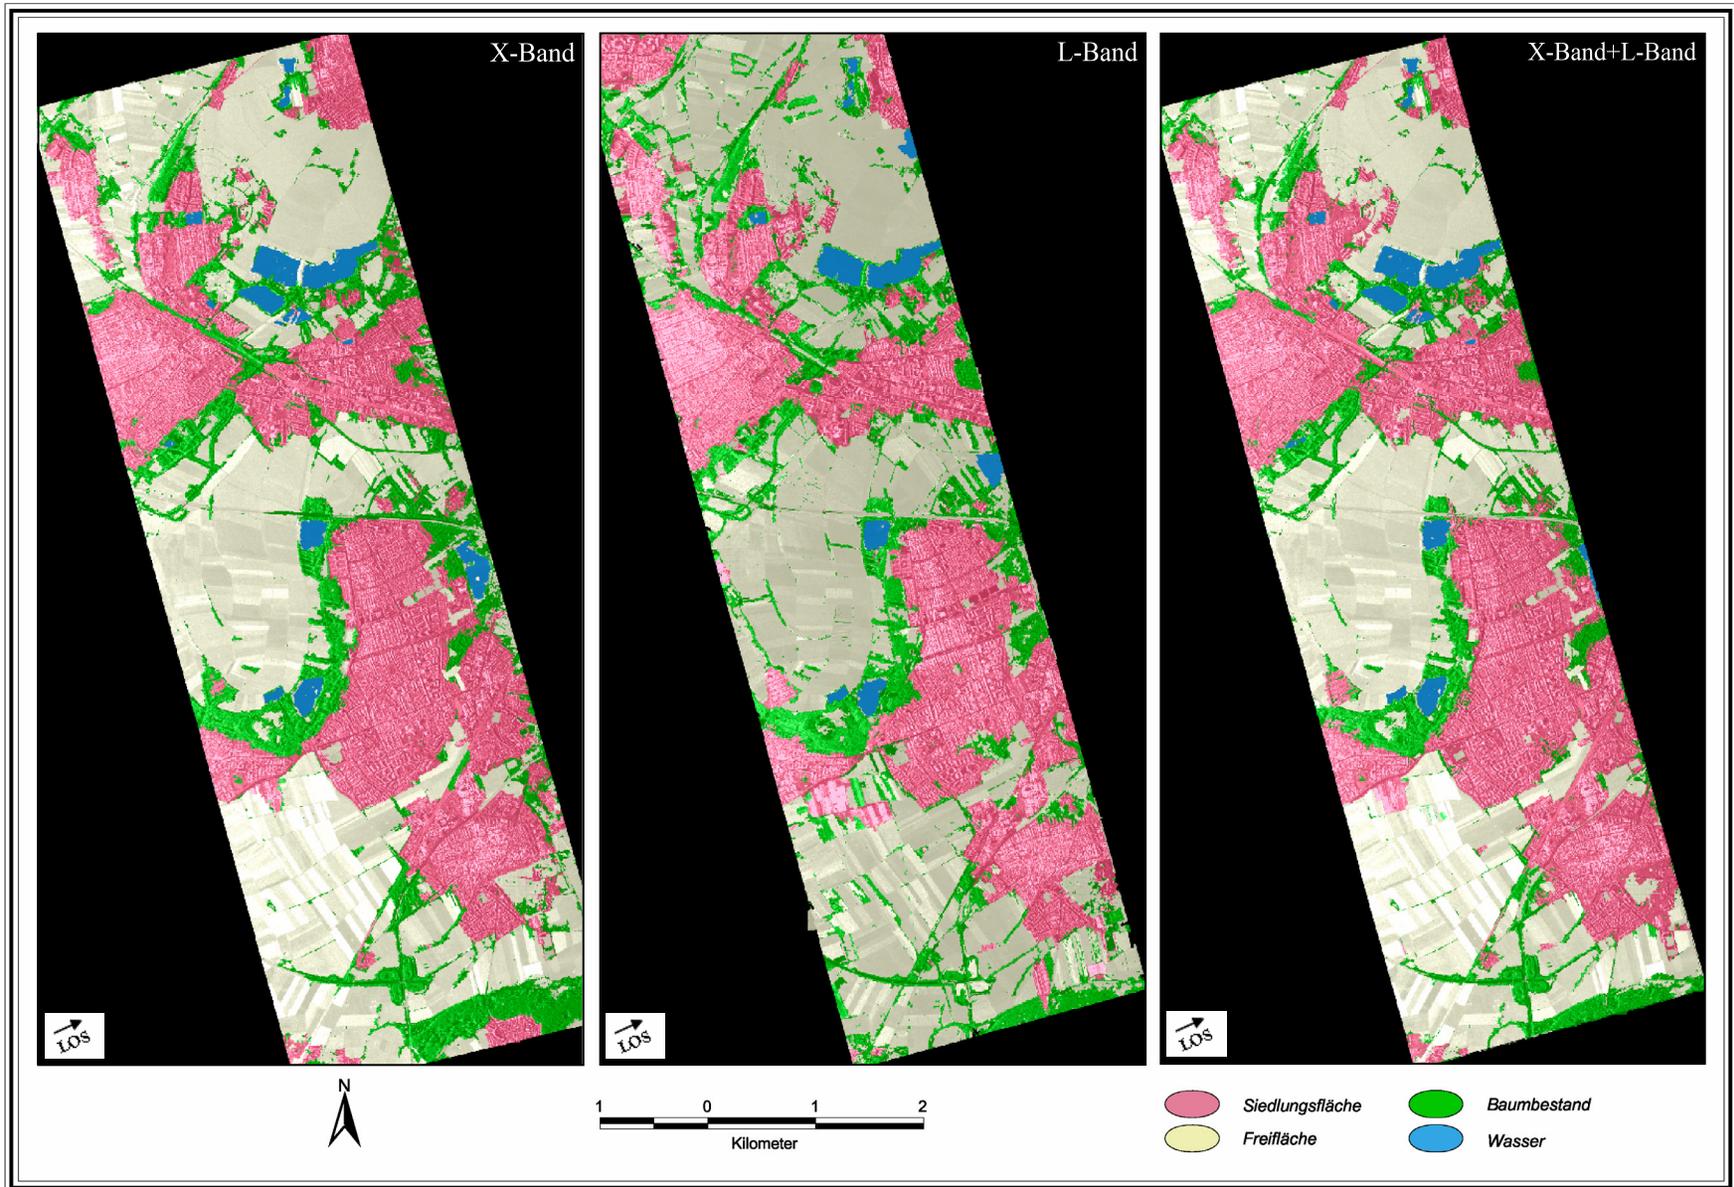


Abb. 4-36: Regionale Landnutzungsklassifikation basierend auf X-Band (HH), L-Band (HH) sowie kombinierter Analyse beider Datensätze

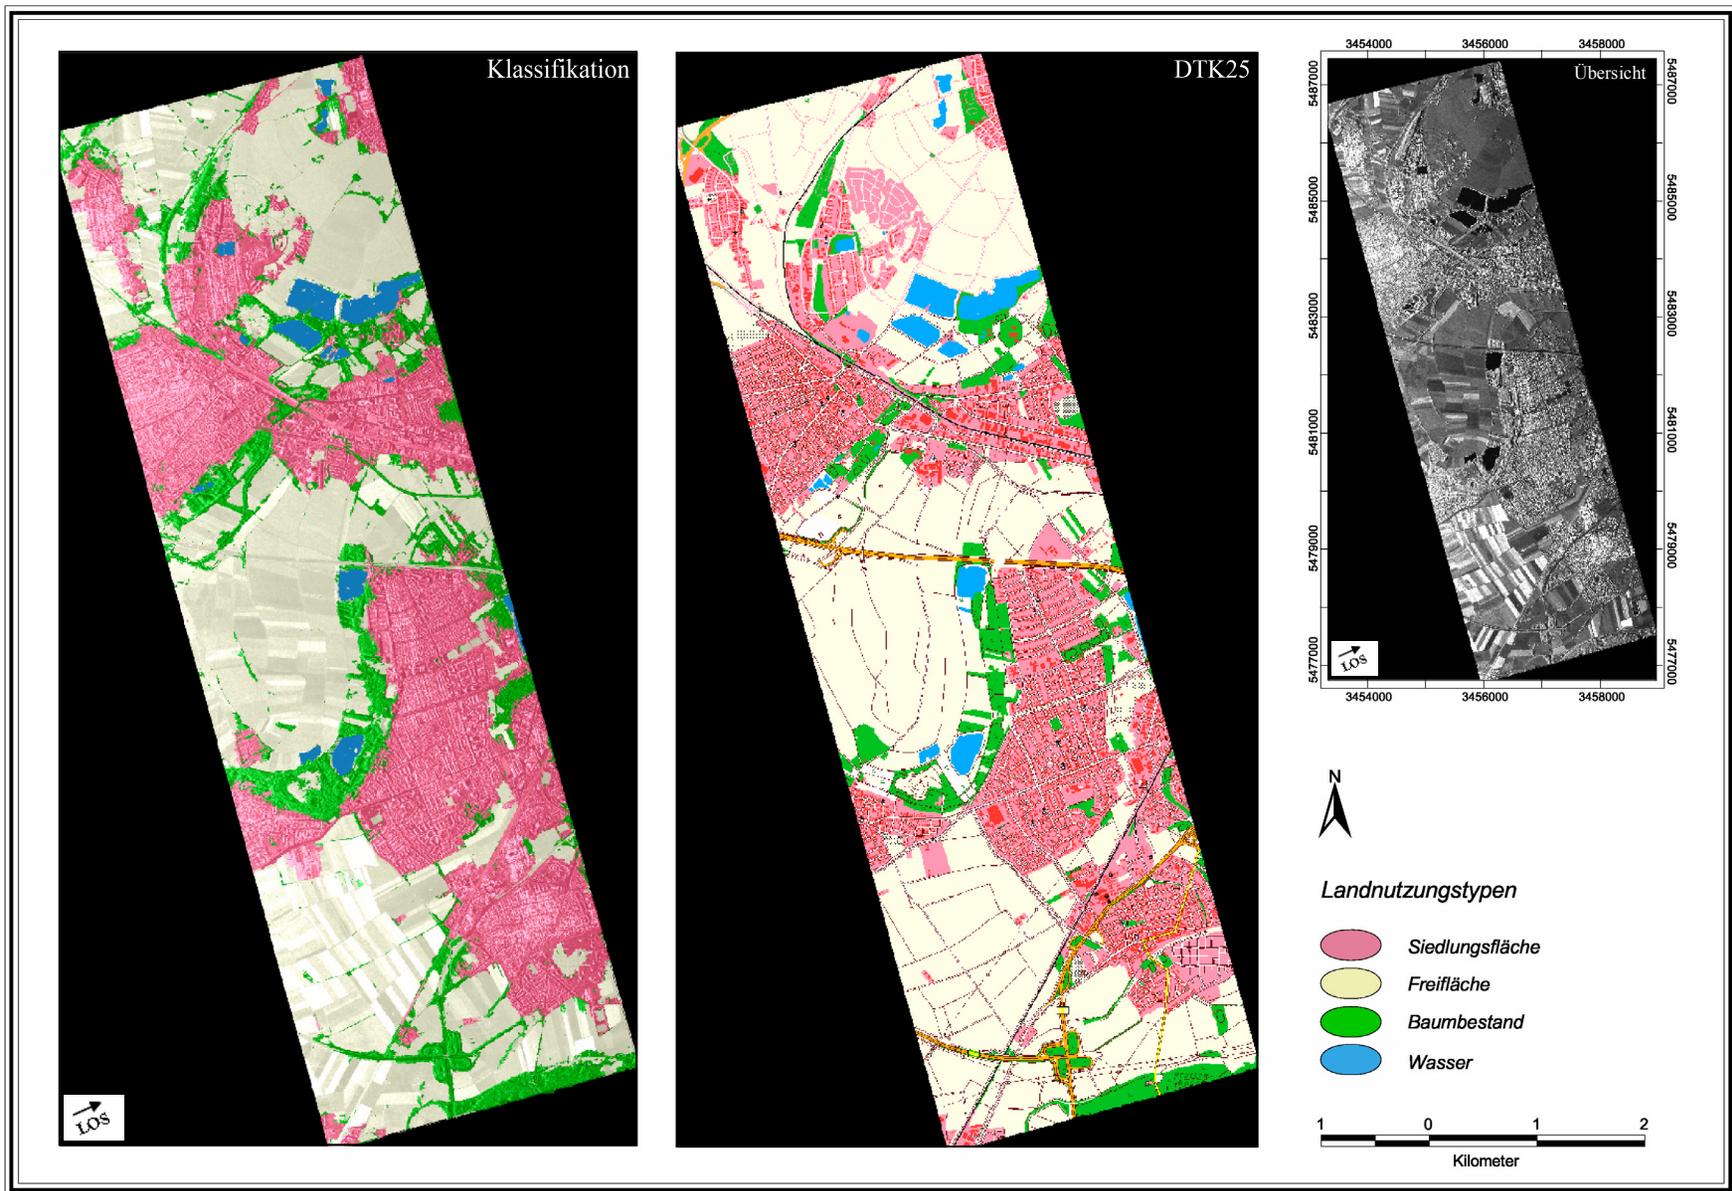


Abb. 4-37: Regionale Landnutzungsklassifikation auf der Basis einer bifrequenten Auswertung im Vergleich zur DTK25

Im Vergleich zur isolierten Auswertung eines X-Band Datensatzes verdeutlicht ABBILDUNG 4-38, dass die Integration von Merkmalen des L-Bands eine akkuratere Erfassung von Siedlungsflächen ermöglicht. Als Beispiel dient die im nördlichen Bildbereich abgebildete Kleingartenanlage. Der Grund für die offensichtlich exaktere Klassifizierung dieser Fläche im Kontext des modifizierten Ansatzes liegt darin begründet, dass die charakteristischen Double-Bounce-Effekte an den Lauben der Kleingartenanlage im langwelligen L-Band wesentlich besser zu Geltung kommen als dies im X-Band der Fall ist (VGL. KAP. 4.2.3.1). Daher sind die definierten Merkmale zur Identifizierung der Klassen *urbaner Punktstreuer* bzw. *Siedlungsfläche sicher* sowie *Siedlungsfläche wahrscheinlich* auf der Grundlage der L-Band Daten erfüllt, während dies bei der isolierten Betrachtung des X-Bands nicht der Fall ist. Da jedoch zugleich die Textur im X-Band sehr hoch ist, kann die gesamte Fläche letztlich vollständig als *Siedlung* identifiziert werden (VGL. KAP. 4.2.2.2).

Wozu diese Koppelung der alternativen L-Band Merkmale an die Textur des X-Band Datensatzes notwendig ist, zeigt das Beispiel einer Ackerfläche im zentralen rechten Bildbereich. Diese wird auf der Basis ihrer Charakteristik in der L-Band Aufnahme als Siedlungsfläche ausgewiesen, während sie im Zuge der bifrequenten Auswertung weiterhin als *Offenland* klassifiziert wird. Der Grund liegt darin, dass in diesem Bereich – im Gegensatz zur Kleingartenanlage – die Textur im X-Band zu gering ist. Daher sind die alternativen Merkmale zur Kennzeichnung einer Siedlungsfläche in diesem Fall nicht hinreichend stark ausgeprägt. Gleiches gilt im Übrigen für die auf Basis der L-Band Aufnahme fehlerhaft als *Siedlung* ausgewiesene Waldfläche am unteren, rechten Bildrand, die im Kontext der kombinierten Auswertung ebenfalls korrekt klassifiziert wird (VGL. ABB. 4-38).

Eine weitere Verbesserung gegenüber dem auf der Grundlage der L-Band Aufnahme erzielten Klassifikationsergebnis tritt im Zusammenhang mit der Erfassung von *Baumbeständen* in Erscheinung. Wie am zentralen, linken Bildrand zu erkennen, werden die Bäume und Sträucher im Bereich des dort erfassten Autobahnkreuzes im X-Band korrekt klassifiziert, während sie auf Grundlage der L-Band Aufnahme fehlerhaft als *Offenland* ausgewiesen sind. Letzteres wird durch die im L-Band fehlende Strukturierung der Waldflächen verursacht, so dass diese Areale bereits zu Beginn der Auswertung als *homogene Areale* klassifiziert werden. Wie ABBILDUNG 4-38 nahe legt, lässt sich diese Ungenauigkeit jedoch über eine Kombination mit den hochfrequenten X-Band Daten grundlegend beheben. So erscheinen die betreffenden Areale im X-Band als wesentlich heterogenere Flächen und garantieren dadurch letztlich die korrekte Einstufung als *stark strukturiertes Areal*.

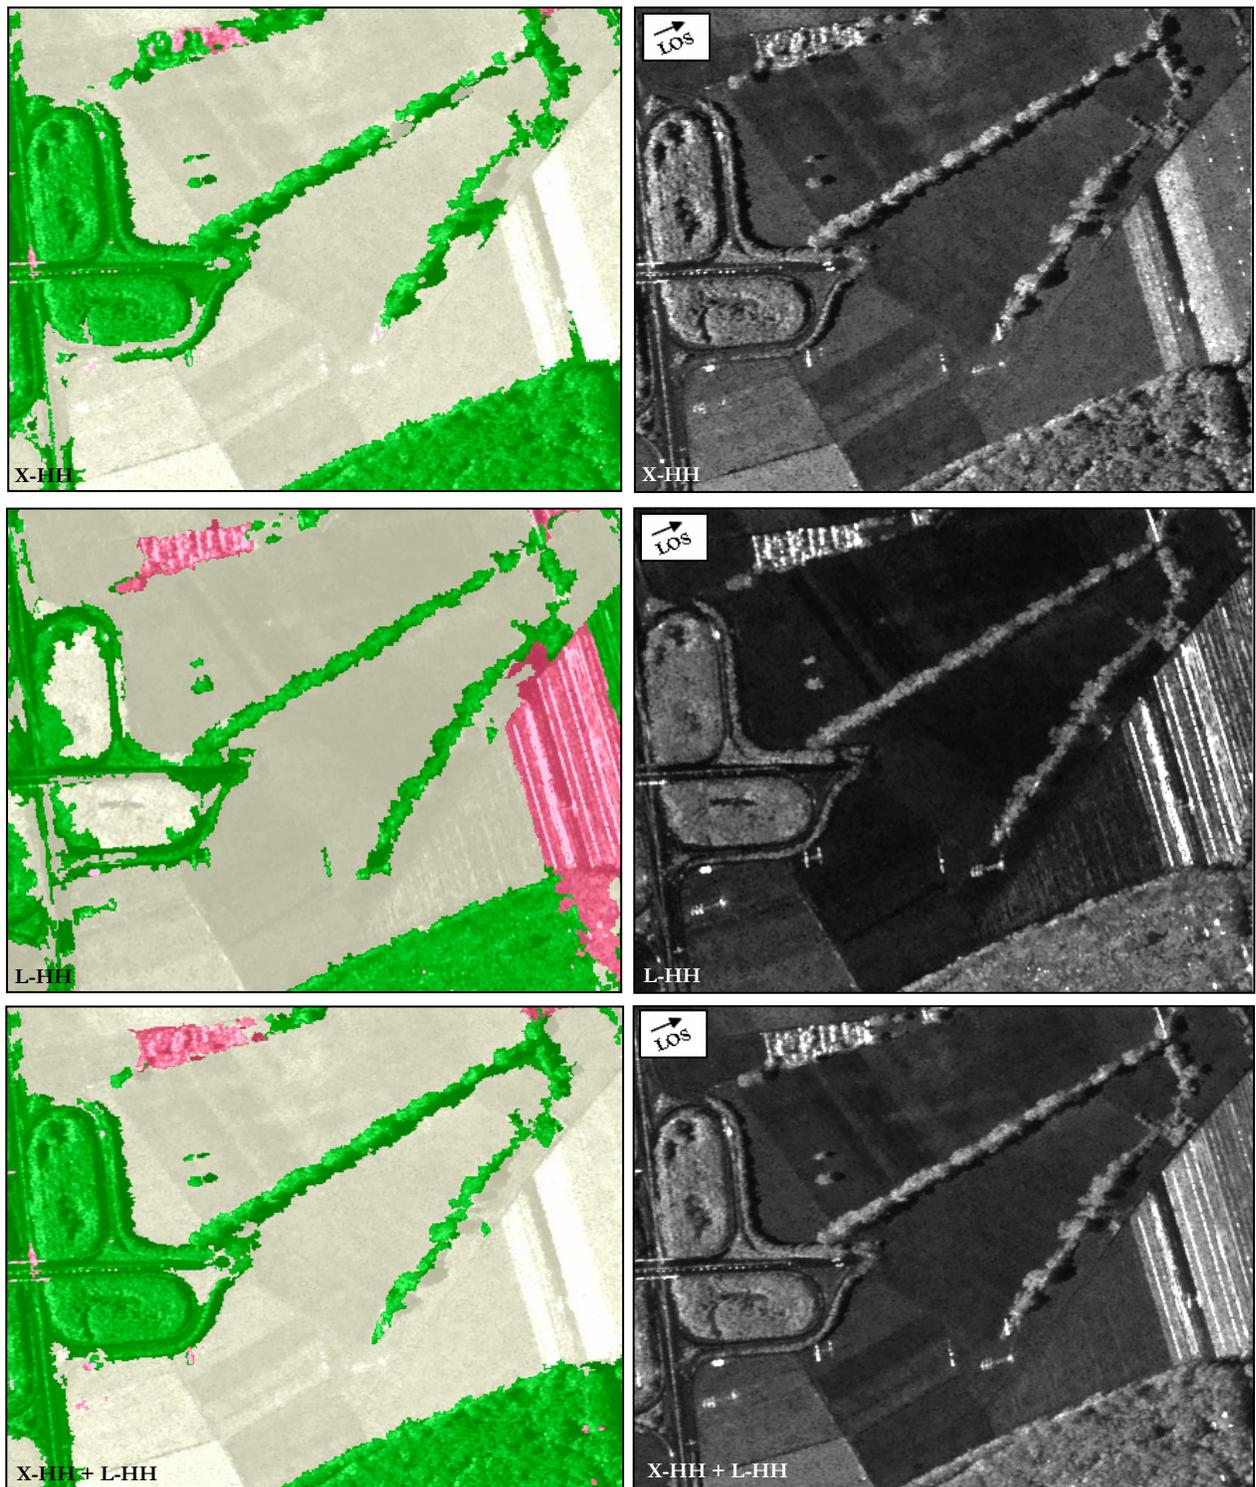


Abb. 4-38: Vergleichende Betrachtung der regionalen Landnutzungsklassifikation auf der Grundlage einer isolierten Analyse des X- und L-Bandes sowie einer kombinierten Auswertung beider Frequenzen – Aus der Abbildung geht eindeutig hervor, dass sich die Schwierigkeiten im Hinblick auf eine isolierte Auswertung von X-HH- bzw. L-HH-Daten durch eine Kombination beider Frequenzen gezielt reduzieren lassen. So kann gegenüber der isolierten Auswertung des X-Bandes die Kleingartenanlage am oberen Bildrand akkurater erfasst werden, während sich bezüglich des L-Bandes vor allem Fehlzweisungen im Zusammenhang mit Acker- und Waldflächen kompensieren lassen.

Abschließend bleibt anzumerken, dass sich leichte Variationen in den Klassifikationsergebnissen darüber hinaus aus den zwangsläufig leicht unterschiedlichen Segmentierungen der jeweiligen Datengrundlagen ergeben können. Diese Effekte sind jedoch im Allgemeinen lokal sehr begrenzt, so dass sie sich im Hinblick auf die Fehlerstatistik kaum auswirken.

4.2.3.4 Kombinierte Datenbasis aus optischer und SAR-basierter Aufnahme

Aufgrund der komplementären Eigenschaften optischer und SAR-basierter Aufnahmen bietet der synergetische Einsatz beider Datentypen eine vielversprechende Möglichkeit zur Präzisierung der thematischen Auswertung beider Datentypen. Dabei profitiert die SAR-basierte Analyse insbesondere von der bedeutend umfassenderen Spektralinformation der optischen Daten, während die Auswertung eines mittelaufgelösten optischen Satellitenbilds durch die Möglichkeit zur differenzierteren Charakterisierung der struktur- und texturbezogenen Eigenschaften von Objekten und Flächen begünstigt wird. Im Rahmen dieser Arbeit liegt der Fokus dabei einzig auf der Bewertung des Potentials zur Verbesserung einer rein radarbasierten Bildauswertung.

Wie bereits in KAPITEL 4.2.2 beschrieben, wurde vor diesem Hintergrund das Regelwerk zur Analyse co-polarisierter X-Band Daten so modifiziert, dass es die Berücksichtigung von Attributen einer optischen IRS-Aufnahme ermöglicht (VGL. KAP. 4.2.2.2). Die Ergänzung einer räumlich hochaufgelösten X-Band Aufnahme durch einen optischen Datensatz des IRS-Satelliten ist gerade im Hinblick auf die Eigenschaften der zukünftigen Sensoren TerraSAR-X und RapidEye von besonderem Interesse. Die Güte dieser ebenfalls auf Grundlage des ersten Flugstreifens bewerteten Analyse wird in TABELLE 4-9 der isolierten Auswertung einer X-Band Aufnahme gegenübergestellt. Aus Zeitgründen war es leider nicht möglich, im Rahmen dieser Dissertation ein Regelwerk zur Ableitung adäquater Landnutzungsklassen aus IRS-Daten zu entwickeln. Folglich kann der Nutzen der kombinierten Auswertung für die Analyse solcher Aufnahmen nicht direkt quantifiziert werden. Aus Studien geht jedoch hervor, dass Siedlungsflächen auf Basis von IRS-Daten grundsätzlich mit einer Genauigkeit von maximal 85-90 Prozent erfasst werden können (DE KOK ET AL., 2003; MEINEL ET AL., 2000).

Wie TABELLE 4-9 illustriert, kann die Güte der *Landnutzungsklassifizierung* von 90,8 Prozent für die rein radarbasierte Auswertung durch die synergetische Analyse auf eine *Gesamtgüte* von 96,0 Prozent gesteigert werden. Diese Tendenz wird durch einen Blick auf ABBILDUNG 4-39 bekräftigt. Ein Vergleich der Fehlermatrizen verdeutlicht, dass die Identifizierung der Siedlungsflächen gerade von der verbesserten Abgrenzung gegenüber der Kategorie *Baumbestand* profitiert (VGL. ANHANG D).

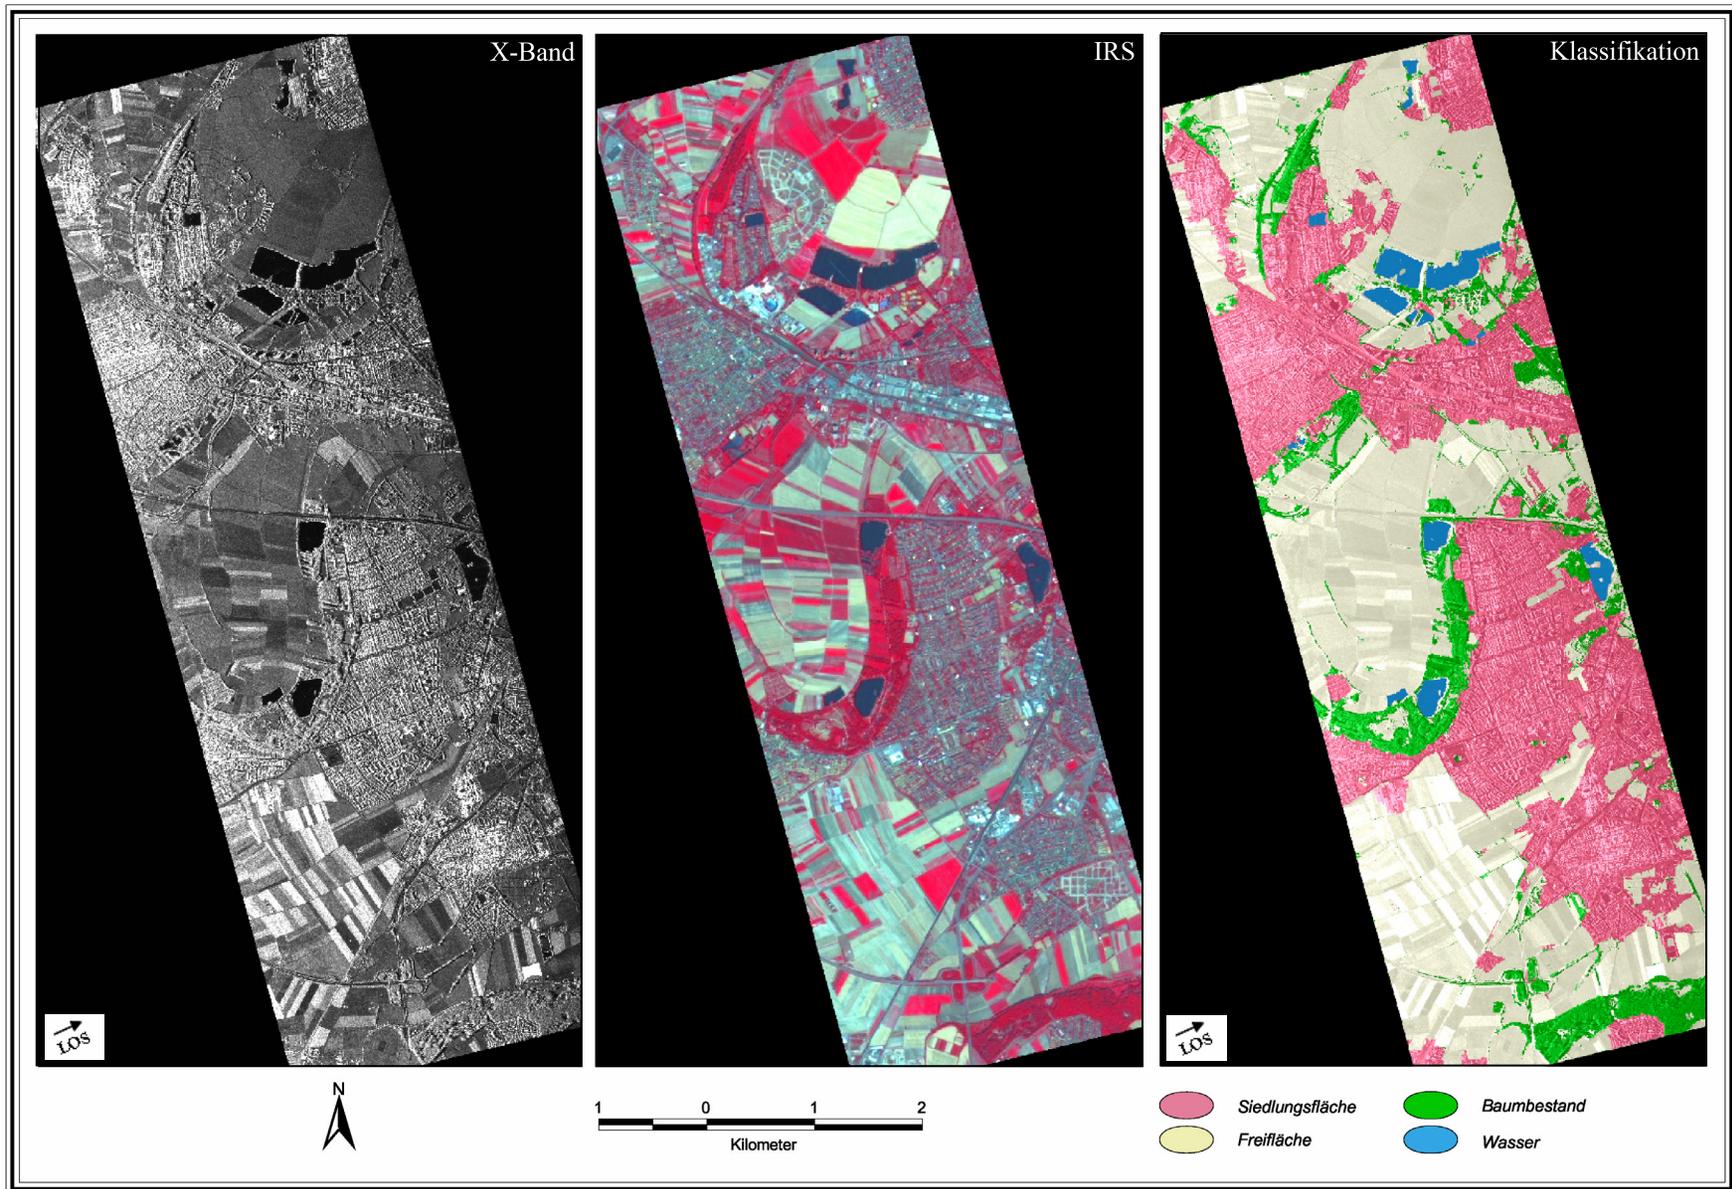


Abb. 4-39: Ergebnis der Landnutzungsklassifizierung basierend auf der synergetischen Auswertung eines X-Band Datensatzes und einer IRS-Aufnahme

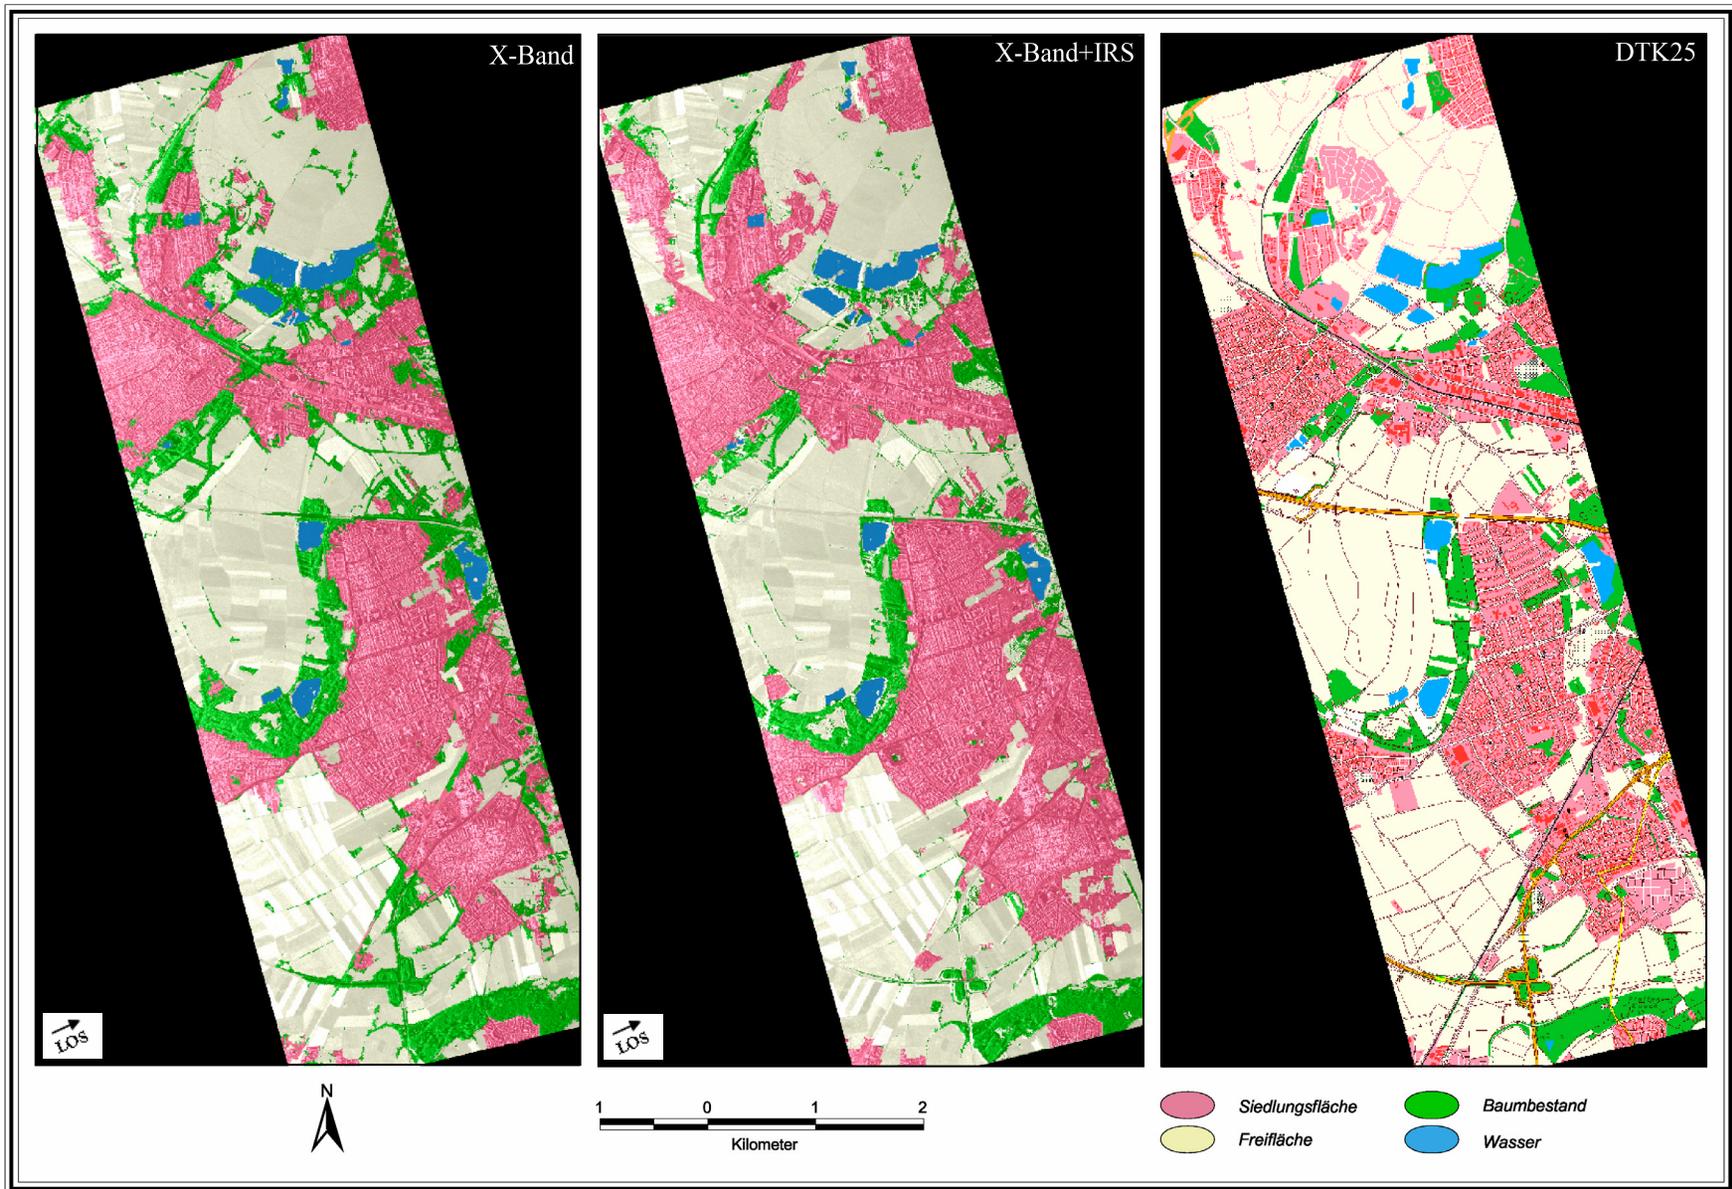


Abb. 4-40: Landnutzung abgeleitet aus X-Band Datensatz bzw. kombinierter Auswertung von X-Band und IRS-Aufnahme im Vergleich zur DTK25

Gleichsam ist erkennbar, dass auch die Differenzierung zwischen *Siedlung* und *Offenland* von der Berücksichtigung der IRS-Attribute profitiert (VGL. ABB. 4-40). Zwei der fünf zuvor als *Siedlung* ausgewiesenen *Offenland*-Referenzpunkte werden nun der richtigen Klasse zugeordnet. Zugleich kann die Zahl der als *Offenland* klassifizierten Siedlungsflächen von vier auf drei reduziert werden (VGL. ANHANG D). Eine genaue Betrachtung der Klassenzuweisungen zeigt, dass diese Verbesserungen offensichtlich aus der Verwendung des NDVI resultieren. Dieser erlaubt eine wesentlich akkuratere Identifizierung solcher Vegetationsflächen, die im SAR-Bild hochstrukturiert erscheinen und daher auf der Grundlage der Radaraufnahme mitunter nur schwer von bebautem Gebiet zu differenzieren sind.

Tab. 4-9: Genauigkeit der regionalen Landnutzungserfassung auf der Basis kombiniert ausgewerteter optischer und SAR-basierter Daten

Klasse	X-Band (HH)		X-Band (HH) + IRS (G-R-NIR)	
	Hersteller*	Nutzer**	Hersteller*	Nutzer**
Siedlung	90,63%	93,55%	96,88%	96,88%
Offenland	89,83%	95,50%	94,92%	96,55%
Baumbestand	93,94%	72,09%	96,97%	91,43%
Wasser	100,00%	100,00%	100,00%	100,00%
Gesamt	90,80 %		96,00 %	

* Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse eigentlich angehören

** Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse insgesamt zugewiesen wurden

Die zuvor beschriebenen Effekte können am Beispiel von ABBILDUNG 4-41 ausführlicher dargelegt werden. Diese stellt die auf der Grundlage der radarbasierten Auswertung erzielte Landnutzungs-klassifikationen dem Resultat der kombinierten Auswertung von X-Band und IRS-Aufnahme gegenüber. Dabei ist eindeutig zu erkennen, dass über den synergetischen Ansatz eine akkuratere Abgrenzung der einzelnen Landnutzungs-klassen erzielt werden kann. Dies ist auf zwei Aspekte zurückzuführen.

Zum einen werden zur Generierung der Texturebene ausschließlich die optischen Kanäle der IRS-Aufnahme genutzt. Dadurch werden die großflächigen Raumeinheiten gegenüber der SAR-basierten Segmentierung akkurater erfasst (VGL. KAP. 4.2.2.1). Daraus resultieren in der Klassifikation wiederum bedeutend homogenere und in ihrem Verlauf realitätsgetreuere Grenzen zwischen den jeweiligen Landnutzungseinheiten (VGL. ABB. 4-41). Zum anderen trägt der Einsatz des NDVI zu einer verbesserten Abgrenzung der einzelnen Landnutzungs-klassen bei. Als Beispiel kann der zentrale untere Bereich der beiden Klassifizierungen herangezogen werden (VGL. ABB. 4-41). Dort ist ein klarer Unterschied hinsichtlich der Abgrenzung einer Siedlungsfläche und eines angrenzenden Wald- bzw. Baumstreifens zu erkennen. Auf der Grundlage der X-Band Aufnahme wird der Verlauf der tatsächlichen

Grenzlinie zwischen den Landnutzungsklassen *Siedlung* und *Baumbestand* im Vergleich recht ungenau wiedergegeben. Ursache ist, dass die Auswertung im Kontext der rein SAR-basierten Analyse vornehmlich auf kontext- und texturbezogenen Merkmalen basiert. Solche Attribute sind hier jedoch nur in begrenztem Umfang zur Differenzierung beider Landnutzungstypen dienlich.

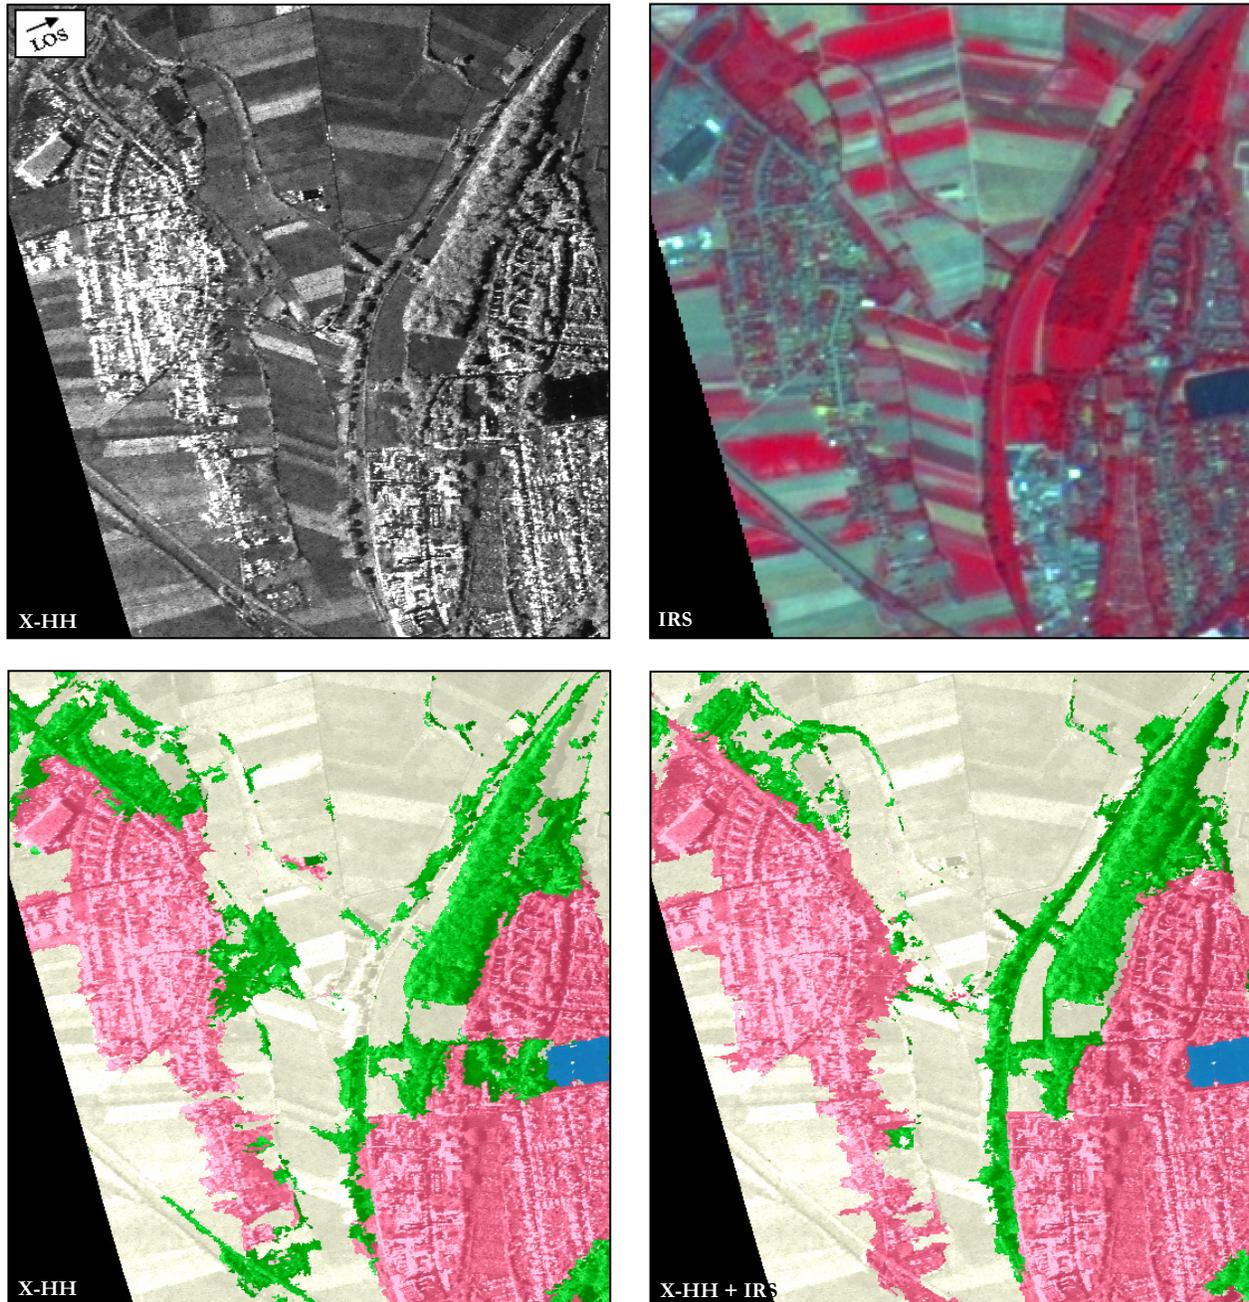


Abb. 4-41: Landnutzungsklassifikation auf der Basis einer isolierten Analyse des X-Bands und der synergetischen Auswertung von X-Band und IRS-Datensatz – Von der Berücksichtigung optischer Merkmale profitiert die radarbasierte Auswertung insbesondere im Hinblick auf die akkurate Abgrenzung der Siedlungsflächen und die exaktere Identifizierung von Baumbeständen und Heckenreihen.

Im Gegensatz zur SAR-Aufnahme zeichnet sich beim Blick auf die IRS-Szene eine wesentlich signifikantere Grenzlinie zwischen der Siedlung und der angrenzenden Waldfläche ab. Diese klare Trennbarkeit resultiert vor allem aus dem enormen Reflektionsunterschied beider Landbedeckungstypen im Nah-Infrarot. Da sich diese Differenz wiederum in einer eindeutigen Abweichung der NDVI-Werte widerspiegelt – im Falle der Waldfläche ist dieser sehr hoch, während die Siedlung überaus geringe Werte aufweist –, wird die Grenzlinie beider Landnutzungen auf Basis der kombinierten Auswertung letztlich erheblich zutreffender klassifiziert (VGL. ABB. 4-41).

Durch die zuvor beschriebenen Verbesserungen kann letztlich eine räumlich differenzierte Identifizierung der einzelnen Landnutzungsklassen gewährleistet werden, was sich in ABBILDUNG 4-41 speziell im Hinblick auf die Klasse *Baumbestand* äußert. Indem die nachbarschaftsbezogenen Merkmale der rein SAR-basierten Auswertung im Kontext der kombinierten Analyse mit Attributen der optischen Aufnahme gekoppelt sind, wird die fehlerhafte Eingliederung umliegender Segmente eingedämmt und die Klassifizierung damit zutreffender.

4.2.4 Zusammenfassung

In KAPITEL 4.2 wurde eine Methodik vorgestellt, mit deren Hilfe Siedlungsflächen und einfache Landnutzungstypen aus hochaufgelösten Radaraufnahmen extrahiert werden können. Im Mittelpunkt standen dabei die *Entwicklung und Anwendung eines Klassifikationsschemas* zur automatisierten und thematisch sowie räumlich robusten Klassifizierung der Bildinhalte auf der Grundlage einer *einfach-polarisierten Radaraufnahme*. Basierend auf diesem Regelwerk wurden anschließend *Erweiterungen* entwickelt, die eine Analyse *dual-polarisierter, bifrequenter* oder *kombinierter optischer und SAR-basierter Aufnahmen* gestatten. Aufgrund der Zielsetzung dieser Arbeit umfassten diese Modifikationen jedoch ausschließlich jene Klassen, die zur Identifizierung der Siedlungsflächen erforderlich sind.

Prinzipiell ist das entwickelte Klassifikationsschema stets in zwei Schritte unterteilt: die Generierung einer aus drei unterschiedlich skalierten Objektebenen bestehenden *Bildsegmentierung* und der anschließenden *Klassifizierung* der Bildinhalte auf Basis eines hierarchisch aufgebauten Regelwerks.

Im Kontext der *Bildsegmentierung* wird zunächst über die in KAPITEL 4.1.2 vorgestellte Technik zur Segmentoptimierung ein Objektlevel erstellt, dessen Segmente die entscheidende Grundlage für die spätere Klassifikation bilden. Zur verbesserten Bereitstellung von Texturmerkmalen sowie hierarchiebezogenen Attributen wird diese *Optimierungsebene* durch ein übergeordnetes Objektlevel mit

großflächigen Segmenten ergänzt – der so genannten *Texturebene*. Abschließend wird unterhalb des optimierten Levels mit der *Korrekturebene* ein drittes Segmentierungsniveau generiert, welches aus kleinräumigen Objekten besteht. Diese Ebene dient im Rahmen der nachfolgenden Klassifizierung zur Korrektur und thematischen Erweiterung der zuvor auf der Optimierungsebene erstellten Klassifikation.

Im Anschluss an die Segmentierung erfolgt die eigentliche *Klassifizierung* der Bilddaten auf der Grundlage einer hierarchisch aufgebauten Wissensbasis. Der Klassifikationsablauf beginnt auf der *Optimierungsebene (Level 2)* mit der *Erfassung von Siedlungsflächen*. Dazu werden zu Beginn der Auswertung sämtliche *hochstrukturierten Areale* extrahiert, um anschließend innerhalb dieser Flächen potentielle *Schattenflächen* und *Punktstreuer* zu identifizieren. Als entscheidendes Kriterium zur eigentlichen Ausweisung der besiedelten Areale dient schließlich die Dichte und Verteilung der zuvor identifizierten Schattenflächen und Punktstreuer. Vereinfacht werden dabei all jene Segmente als Siedlungsflächen klassifiziert, die in einer definierten Nachbarschaft gleichzeitig eine hohe Anzahl an Schattenbereichen und hellen Streuzentren aufweisen. Nach Abschluss der Identifizierung besiedelter Areale auf der Optimierungsebene erfolgt auf der *Korrekturebene (Level 1)* ein zweiter Klassifizierungsdurchlauf. Dabei wird die zuvor auf dem übergeordneten Level erstellte Klassifikation grundsätzlich übernommen, jedoch gegebenenfalls auf Basis der nunmehr kleinräumigeren Objekte räumlich und inhaltlich korrigiert. Gleichsam umfasst dieser zweite Klassifizierungsablauf die thematische Erweiterung des Regelwerks auf insgesamt *vier einfache Landnutzungsklassen*. Dabei wird die bereits vorhandene Kategorie *Siedlung* um die Klassen *Offenland*, *Baumbestand* und *Wasser* ergänzt. Aus dem beschriebenen Klassifikationsablauf geht hervor, dass die Objekte der *Texturebene (Level 3)* nicht klassifiziert werden. Sie dienen ausschließlich der Bereitstellung textur- und hierarchiebezogener Merkmale, die im Rahmen der Klassifizierung der Optimierungs- und Korrekturebene Verwendung finden.

Um die Übertragbarkeit der verwendeten Regelwerke zu gewährleisten, beruht die zu Grunde liegende Klassenbeschreibung bzw. Merkmalsdefinition auf Attributen, die in ihren Eigenschaften lediglich geringen räumlichen und zeitlichen Schwankungen unterliegen. Dazu zählen neben den bereits erwähnten *klassenbasierten Merkmalen* vor allem *textur-, kontext- und hierarchiebezogene Attribute*, die grundsätzlich auf eine Beschreibung struktureller Charakteristika abzielen. Im Hinblick auf die erweiterten Regelwerke zur Analyse *dual-polarisierter, bifrequenter* oder *kombinierter optischer und SAR-basierter Daten* wird diese Wissensbasis entsprechend um spezifische Attribute der jeweiligen Datensätze ergänzt. Über den zusätzlich bereitgestellten Informationsgehalt können diese Merkmale einerseits zur verbesserten Identifizierung der einzelnen Klassen eingesetzt werden. Darüber hinaus ist es möglich,

mehrere Merkmale der ursprünglichen Klassenkennzeichnung durch ein einziges, nunmehr aussagekräftigeres Attribut der neuen Informationsebene zu ersetzen.

Die Resultate der jeweiligen Klassifikationsansätze sind in TABELLE 4-10 zusammengefasst. Die Gegenüberstellung belegt, dass sowohl die Erfassung von Siedlungsflächen als auch die Ableitung einfacher Landnutzungsklassen auf der Basis hochaufgelöster Radardaten sehr genaue Ergebnisse liefert. Demnach ist auf der Basis *einfach-polarisierter SAR-Aufnahmen* sowohl die Erfassung von Siedlungsflächen als auch die Ableitung der Landnutzung mit einer thematischen Güte von rund 90 Prozent möglich. Während sich diese Genauigkeit durch die Verwendung einer *dual-polarisierten Datenbasis* nur *geringfügig verbessern* lässt, ermöglichen die *Kombination zweier Frequenzen* bzw. die *integrierte Auswertung optischer und SAR-basierter Daten* eine Steigerung der Qualität auf Werte von 95 Prozent bzw. 96 Prozent.

Tab. 4-10: Übersicht der Genauigkeiten in der Siedlungserfassung und regionalen Landnutzungsklassifizierung

Klasse		X-HH	C-HH	L-HH	C-HH+ C-HV	X-HH+ L-HH	X-HH+ IRS
Siedlung	Hersteller	90,63%	88,54%	87,50%	88,54%	94,79%	96,88%
	Nutzer	93,55%	90,43%	92,31%	92,39%	95,79%	96,88%
Offenland	Hersteller	89,83%	93,22%	88,22%	95,76%	94,92%	94,92%
	Nutzer	95,50%	94,02%	92,92%	94,17%	97,39%	96,55%
Baumbestand	Hersteller	93,94%	75,76%	78,79%	78,79%	93,94%	96,97%
	Nutzer	72,09%	69,44%	60,47%	74,29%	83,78%	91,43%
Wasser	Hersteller	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
	Nutzer	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Gesamt		90,80 %	89,20 %	87,20 %	90,80	94,80	96,00 %

* Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse eigentlich angehören

** Anzahl korrekt klassifizierter Referenzpunkte dividiert durch Summe aller Referenzpunkte, die der betrachteten Klasse insgesamt zugewiesen wurden

4.3 Charakterisierung der lokalen Siedlungsstruktur

Im vorherigen Kapitel wurde eine Methodik zur automatisierten Erfassung von Siedlungsflächen vorgestellt. Ergänzend dazu zielt der folgende Arbeitsschwerpunkt auf eine *differenzierte Analyse der Oberflächen- bzw. Nutzungstypen innerhalb bebauter Areale* ab. Grundsätzlich bedürfen die Kleinteiligkeit und Heterogenität urbaner Strukturen dabei eines enormen räumlichen und spektralen Detaillierungsgrades (VGL. KAP. 1.2). Im Rahmen dieser Arbeit hat sich in zahlreichen Versuchen gezeigt, dass diesen Anforderungen einzig auf der Basis von Radardaten selbst bei einer sehr hohen räumlichen

Auflösung oder der Kombination unterschiedlicher Frequenzen und Polarisierungen kaum Genüge geleistet werden kann (VGL. KAP. 1.2). Dabei haben sich vor allem der limitierte spektrale Informationsgehalt sowie die mitunter nicht aufzulösende Mehrdeutigkeit des Radarsignals als entscheidende Limitierungen erwiesen. Auch das Gros optischer Satellitenaufnahmen ist nur begrenzt für die Erfassung der innerstädtischen Landnutzung geeignet, da es den Sensoren in der Regel am notwendigen geometrischen Auflösungsvermögen mangelt. So ist zur Erfassung kleinteiliger Siedlungsstrukturen ein räumlicher Detaillierungsgrad erforderlich, der ausschließlich von höchstaflösenden Satellitensystemen der neuesten Generation (IKONOS, QuickBird) erreicht wird (VGL. KAP. 1.2).

Vor diesem Hintergrund soll nun der Nutzen eines synergetischen Einsatzes radarbasierter und optischer Daten untersucht werden. Angesichts der hohen geometrischen und spektralen Auflösung von Systemen wie IKONOS oder QuickBird können selbst höchstaflösende Radaraufnahmen jedoch nur noch sehr begrenzt zur Erweiterung des Informationsspektrums beitragen. Daher erscheint die synergetische Auswertung einer hochauflösenden Radaraufnahme und eines geometrisch geringer aufgelösten, optischen Datensatzes als sinnvoller, denn in diesem Fall kann auch die optische Aufnahme umfassend von der kombinierten Auswertung profitieren. Ein solches Szenario ist zudem mit Blick auf die deutschen Missionen TerraSAR-X (Radar) und RapidEye (Optik) von besonderem Interesse. So reicht das räumliche Auflösungsvermögen des RapidEye-Systems nicht für differenzierte urbane Anwendungen aus, während im Kontext des TerraSAR-X-Satelliten die bedingt aussagekräftige Spektralinformation der E-SAR Daten den limitierenden Faktor darstellen dürfte. Daher erscheint eine thematisch und räumlich detaillierte Analyse der urbanen Umwelt mittels dieser Datentypen einzig über den synergetischen Einsatz der beiden komplementären Systeme möglich zu sein.

Aus diesem Grunde wird nachfolgend untersucht, ob sich der Informationsgehalt einer räumlich hochauflösenden Radaraufnahme mit der spektralen Vielfalt eines geometrisch geringer aufgelösten, multispektralen Datensatzes kombinieren lässt, um auf diese Weise die sensorspezifischen Limitierungen beider Systemtypen reduzieren zu können. Dabei wird zunächst ein *Segmentierungskonzept* vorgestellt, das eine optimale Auswertung auf der Basis einer Datengrundlage aus SAR-basierter und optischer Aufnahme gewährleisten soll. Im Anschluss daran steht die Entwicklung eines *Regelwerkes* im Vordergrund, welches die synergetische Klassifizierung beider Datenquellen ermöglicht. Das Ziel liegt in der Erfassung und Abgrenzung von *Gebäuden*, *versiegelten Freiflächen*, *unversiegelten Freiflächen* und *Baumbeständen*. Abschließend werden die erzielten Resultate quantitativ und qualitativ beschrieben. Darüber hinaus wird auf der Basis repräsentativer Baublöcke ein visueller Abgleich zwischen den klassifizierten Raumeinheiten und der tatsächlichen Siedlungsstruktur vorgenommen.

Das Kapitel schließt mit einer Zusammenfassung der wichtigsten Erkenntnisse zur Analyse der lokalen Siedlungsstruktur auf der Basis der synergetischen Auswertung.

Als Grundlage dieser Untersuchung dienen eine co-polarisierte X-Band Aufnahme des E-SAR-Systems sowie ein multispektraler Datensatz des IRS-Satelliten (VGL. KAP. 3.2). Im Kontext der Segmentierung werden ferner Straßen-Vektordaten berücksichtigt, um auf dieser Grundlage Baublöcke abgrenzen zu können, die später zur vergleichenden Analyse der extrahierten Siedlungsstrukturen herangezogen werden. Als Testgebiet ist ein Ausschnitt innerhalb des ersten Flugstreifens definiert, der eine hohe Variation urbaner Struktur- bzw. Nutzungstypen abdeckt (VGL. KAP. 3.1).

4.3.1 Segmentierung

Vergleichbar des Konzepts zur Erfassung der Siedlungsflächen werden auch im Hinblick auf die Ableitung der urbanen Landnutzung wiederum drei Objektebenen generiert (VGL. TAB. 4-11). Dabei entspricht der technische Ablauf zur Segmentierung grundlegend dem bereits in KAPITEL 4.2.1.1 bzw. KAPITEL 4.2.2.1 vorgestellten Ansatz. Daher wird an dieser Stelle auf eine erneute Erörterung des zu Grunde liegenden Konzepts verzichtet. Vielmehr sollen im Folgenden die entscheidenden inhaltlichen Charakteristika der erstellten Segmentierung erläutert werden (VGL. TAB. 4-11).

An dieser Stelle sei darauf hingewiesen, dass der exakten Ko-Registrierung zwischen optischer und SAR-basierter Aufnahme im Kontext der lokalen Analyse besondere Bedeutung zukommt. So verkippen im Radarbild speziell hohe Bauwerke oder Bäume recht stark zum Sensor, weshalb die Lage der entsprechenden Strukturen zwischen SAR-Aufnahme und optischem Datensatz zwangsläufig differiert. In Ermangelung eines hochaufgelösten Geländemodells zur Korrektur dieser Lagefehler ist daher sowohl im Hinblick auf die Segmentierung als auch im Kontext der Klassifizierung mit Ungenauigkeiten und Fehlzusweisungen aufgrund dieser Problematik zu rechnen.

Wie aus TABELLE 4-11 hervorgeht, beginnt die Segmentierung mit der Erstellung einer so genannten *Baublockebene*. Die Generierung dieses Levels basiert auf der herkömmlichen Multiresolution Segmentierung und greift ausschließlich auf einen Vektordatensatz zurück, der das Straßennetz innerhalb des Untersuchungsgebietes repräsentiert. Die Berücksichtigung dieser Vektordaten ist notwendig, um die Erstellung von Objekten zu gewährleisten, die eine exakte Abgrenzung der Baublöcke innerhalb des betrachteten Testgebietes ermöglichen (VGL. ABB. 4-42). Auf der Grundlage der vorliegenden fernerkundlichen Bilddaten lässt sich eine solche Abgrenzung nicht realisieren, da die Grenzen zwischen

den einzelnen Baublöcken für den Segmentierungsalgorithmus nicht hinreichend genau nachvollziehbar sind. Dies liegt maßgeblich darin begründet, dass sich die Übergänge vor allem durch einen Wechsel in der strukturellen Komposition der stadtstrukturellen Grundeinheiten auszeichnen und weniger über eine Änderung der spektralen- bzw. reflektionsbezogenen Eigenschaften, auf die der Segmentierungsalgorithmus anspricht. An dieser Stelle sei allerdings nochmals erwähnt, dass die dritte Ebene – also jene, die auf der Basis der Vektordaten erstellt wird –, im Rahmen der Landnutzungs-klassifizierung keine Rolle spielt, sondern einzig im Hinblick auf die abschließende, baublockbezogene Evaluierung der Ergebnisse Verwendung findet.

Tab. 4-11: Segmentierungsparameter zur urbanen Analyse auf der Grundlage einer kombinierten Datenbasis aus X-Band Aufnahme und IRS-Datensatz

Segmentierungsablauf*			Layer** (Gewichtung)	Scale Parameter	Shape	Compactness	
Level 3 (Baublockebene)			Straßen-Vektorlayer (1)	20	0,9	0,5	
Level 2 (Klassifizierungsebene 1)	Optimierung Regelwerk X-Band	1. Iteration	BL	Int_filt (1)	10	0,8	0,5
			OL	Int_filt (1)	20	0,8	0,5
		2. Iteration (OL)		Int_filt (1)	40	0,8	0,5
		3. Iteration (OL)		Int_filt (4) Int_filt_tex (1)	60	0,8	0,5
		4. Iteration (OL)		Int_filt (3) Int_filt_tex (1)	80	0,8	0,5
		5. Iteration (OL)		Int_filt (2) Int_filt_tex (1)	120	0,8	0,5
	6. Iteration (OL)		Int_filt (1) Int_filt_tex (1)	180	0,8	0,5	
	Optimierung Regelwerk IRS	1. Iteration (BL)		G; R; NIR (1,1,1)	5	0,8	0,5
		2. Iteration (BL)		G; R; NIR (1,1,1)	15	0,8	0,5
		3. Iteration (BL)		G; R; NIR (1,1,1)	30	0,8	0,5
		4. Iteration (BL)		G; R; NIR (1,1,1)	60	0,8	0,5
		5. Iteration (BL)		G; R; NIR (1,1,1)	80	0,8	0,5
	Level 1 (Klassifizierungsebene 2)			Int_filt (1) Int_filt_tex (1)	40	0,8	0,5

* : BL = Basislevel; OL = Optimierungslevel
 ** : Int_filt: geglättetes Intensitätsbild; Int_filt_tex: Texturbild (Varianz 7x7), berechnet auf Basis von gefilterter Intensität
 : IRS-Aufnahmekanäle: G = Grün (Band 1); R = Rot (Band 2); NIR = Nah-Infrarot (Band 3)

Im Anschluss daran wird mit der *Klassifizierungsebene 1* – dem späteren Level 2 – ein weiteres Segmentierungsniveau erstellt (VGL. ABB. 4-42). Dieses wird mit Hilfe der bereits ausführlich dargelegten Optimierungsprozedur generiert, wobei der Ablauf insgesamt zwei Durchläufe umfasst (VGL. TAB. 4-11).

Dabei ist der Scale Parameter der einleitenden Segmentierung jeweils etwas kleiner angesetzt als dies im Kontext der Erfassung der Siedlungsflächen der Fall war. Der Grund ist, dass zur Ableitung der urbanen Landnutzung auch lokale Details von Bedeutung sind, deren Erfassung mitunter sehr kleiner Objekte bedarf. Schließlich endet die Segmentierung mit der Generierung eines dritten Objektlevels – der *Klassifizierungsebene 2* –, welches unterhalb der beiden zuvor angelegten Objektlevel angeordnet ist und dabei deutlich kleinere Segmente aufweist (VGL. TAB. 4-11).

Auf welche Weise die beiden definierten Klassifizierungslevel letztlich zur Auswertung beitragen, wird im folgenden Unterkapitel vorgestellt.

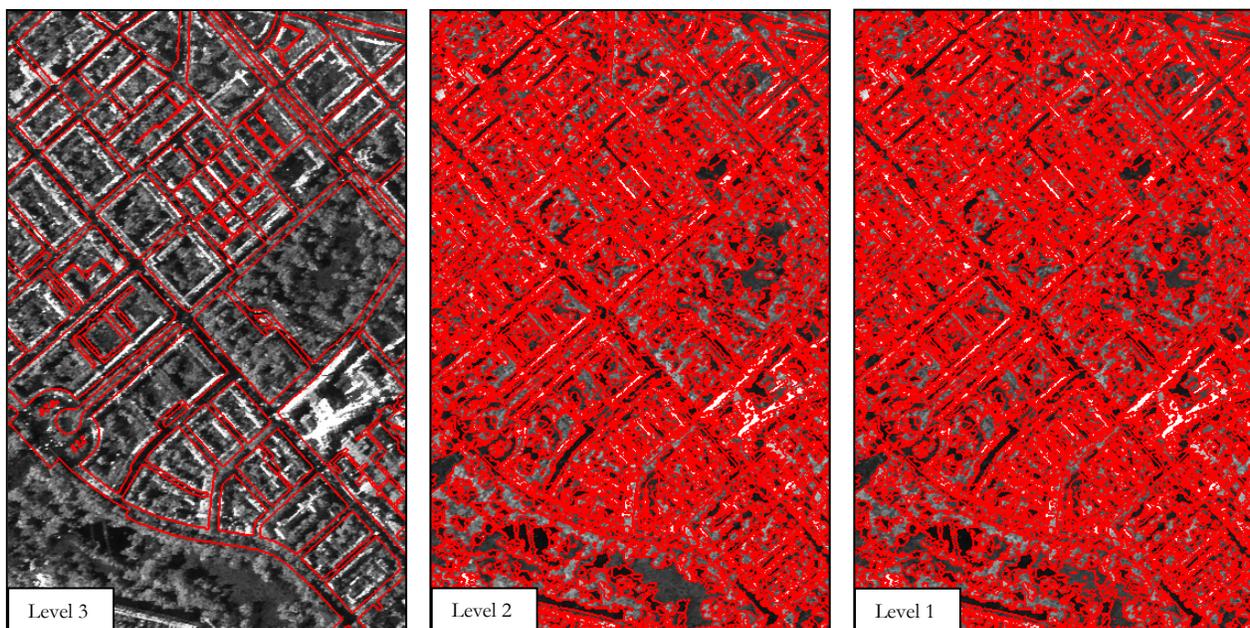


Abb. 4-42: Segmentierungsebenen zur Ableitung der urbanen Landnutzung – Die Segmentierung umfasst eine Baublockebene (Level 3) sowie die Klassifizierungsebene 1 (Level 2) und Klassifizierungsebene 2 (Level 1). Letztere dienen als Grundlage für den Klassifikationsprozess, während die Baublockebene lediglich im Rahmen der Evaluierung der Ergebnisse Verwendung findet.

4.3.2 Ableitung urbaner Strukturen

Im einleitenden Text zu diesem Kapitel wurde darauf hingewiesen, dass eine räumlich und thematisch detaillierte Analyse der urbanen Landnutzung nur in sehr begrenztem Umfang über eine SAR-gestützte Auswertung zu realisieren ist. So zeigt die künstliche Überlagerung der X-Band Szene und der IRS-Aufnahme in ABBILDUNG 4-43, dass eine Kombination des komplementären Informationsgehalts beider Datentypen eine aussagekräftige Informationsbasis darstellt, die sowohl die strukturel-

len als auch die spektralen Charakteristika bebauter Areale charakterisiert. Wie ABBILDUNG 4-43 illustriert, lässt sich mittels hochauflösender Radaraufnahmen trotz der erwähnten Limitierungen die Topografie der urbanen Strukturen recht anschaulich nachvollziehen. Diese Eigenschaft rührt daher, dass die Rückstreucharakteristik des Radarsignals im urbanen Kontext maßgeblich von der mesoskaligen Rauigkeit geprägt wird, die wiederum direkt aus der Größe und geometrischen Beschaffenheit der städtischen Strukturen resultiert.

Die weitere Spezifizierung der einzelnen Objekte ist allerdings aufgrund der begrenzten Aussagekraft des gestreuten Signals mit entsprechenden Schwierigkeiten bzw. Ungenauigkeiten verbunden (VGL. ABB. 4-43). Ein Blick auf den ebenfalls in ABBILDUNG 4-43 aufgeführten Ausschnitt eines IRS-Datensatzes verdeutlicht, dass hier ein entscheidender Vorteil optischer Daten liegt. Obwohl sich im Gegensatz zur wesentlich höher aufgelösten E-SAR Aufnahme kaum individuelle Strukturen oder Objekte identifizieren lassen, ermöglicht die höhere spektrale Bandbreite des optischen Datensatzes dennoch eine recht differenzierte Charakterisierung der erfassten Bedeckungsarten. Dabei lässt sich insbesondere die Verteilung vegetationsbedeckter Flächen gut nachvollziehen.

Vor diesem Hintergrund wird ein *Regelwerk* vorgestellt, das auf die *synergetische Nutzung optischer und SAR-basierter Aufnahmen* abzielt. Auf diese Weise sollen die systembedingten Limitierungen beider Datentypen im Hinblick auf eine räumlich und thematisch differenzierte Charakterisierung urbaner Räume reduziert werden, um somit gegebenenfalls ein Anwendungsspektrum zu erschließen, das bisher ausschließlich höchstauflösenden optischen Daten zugänglich ist. Dabei soll auf der Basis des *hohen räumlichen Detaillierungsgrades der SAR-Aufnahme* eine Erfassung und Abgrenzung der einzelnen *strukturellen Raumeinheiten* vorgenommen werden, während zur anschließenden *thematischen Differenzierung der extrahierten Strukturen* verstärkt Attribute des optischen Datensatzes zur Anwendung kommen. Ziel der Auswertung ist letztlich die Klassifikation der urbanen Oberflächen- bzw. Nutzungstypen *Gebäude, versiegelte Freifläche, unversiegelte Freifläche* und *Baumbestand* (VGL. ABB. 4-44).

Grundsätzlich basiert die Ableitung der urbanen Landnutzung auf Merkmalen der geglätteten 8-bit-Intensitätsaufnahme, des daraus abgeleiteten Texturlayers, des ursprünglichen 16-bit Intensitätsbildes sowie den drei spektralen Bändern der IRS-Aufnahme. Zur Ausweisung der Straßenzüge wird zudem ein entsprechender Vektordatensatz eingebunden. In diesem Zusammenhang sei nochmals darauf hingewiesen, dass hinsichtlich der nachfolgend beschriebenen Analysen zur Ableitung der städtischen Landnutzung weder Merkmale genutzt werden, die über den Straßenlayer bereitgestellt, noch auf Basis von Segmenten der damit erstellten Baublockebene berechnet werden.

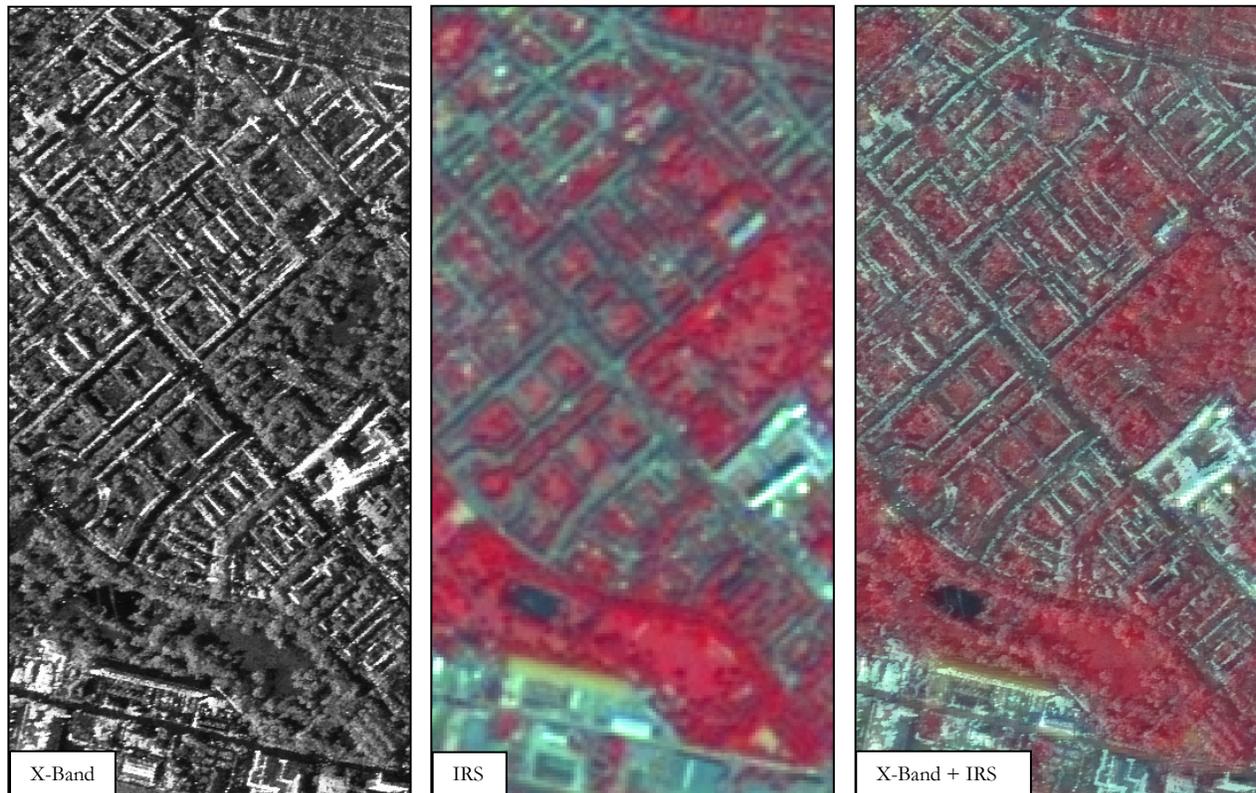


Abb. 4-43: Erscheinungsbild einer Siedlungsfläche in höchstauflösenden SAR-Daten (X-Band, 2m), geringer aufgelöster optischer Aufnahme (IRS, 5.8m) sowie Überlagerung beider Datensätze – Im Hinblick auf die SAR-Aufnahme limitiert vor allem der eingeschränkte spektrale Informationsgehalt die Analyse der urbanen Strukturen, während es der IRS-Aufnahme an der notwendigen geometrischen Auflösung mangelt. Die Fusion beider Datensätze illustriert den potentiellen Nutzen einer synergetischen Auswertung der komplementären Bildinformation beider Datentypen.

Wie die in ABBILDUNG 4-44 dargestellte Klassenhierarchie zeigt, beginnt die Auswertung jeweils mit der Abgrenzung jener Bildbereiche, die *keine Daten* enthalten. Im Anschluss wird im Kontext eines *ersten Klassifikationsschrittes* auf Basis der *Klassifizierungsebene 1* (Level 2) versucht, die *lokale Topografie* der siedlungsstrukturellen Grundeinheiten zu extrahieren. Zu diesem Zweck erfolgt dort eine Abgrenzung zwischen planen Oberflächen und Objekten mit vertikaler Komponente (VGL. ABB. 4-44). Die Trennung beider Strukturtypen basiert auf der Identifizierung *ebener Areale*, wobei sämtliche Objekte, die nicht dieser Klasse angehören, automatisch als *vertikale Struktur* ausgewiesen werden. Zur Klassifizierung der *ebenen Flächen* wird vereinfacht davon ausgegangen, dass die entsprechenden Segmente als Regionen in Erscheinung treten, deren angrenzende Nachbarobjekte sowohl im Hinblick auf die lokale Textur als auch bezüglich der Intensität deutlich höhere Werte aufweisen (VGL. ABB. 4-45).

Im Anschluss an die Ausweisung *ebener Areale* und *vertikaler Strukturen* folgt der *zweite Klassifizierungsdurchlauf* auf Basis der *Klassifizierungsebene 2* (Level 1). Dort beginnt die Auswertung wiederum mit der grundlegenden Ausgrenzung jener Bildbereiche, die *keine Daten* enthalten. Nachfolgend werden über eine Auswertung des integrierten Vektordatensatzes jene Segmente identifiziert, die *Straßenflächen* repräsentieren (VGL. ABB. 4-44). Die Klassifizierung erfolgt dabei über die zugehörige Attributtabelle der Vektordaten. Bevor schließlich die Ableitung der urbanen Landnutzung beginnt, werden abermals die *ebenen Areale* und *vertikalen Strukturen* extrahiert (VGL. ABB. 4-44). Zu diesem Zweck finden klassenbezogene Merkmale Verwendung, die sich auf das Klassifikationsergebnis der übergeordneten Ebene beziehen.

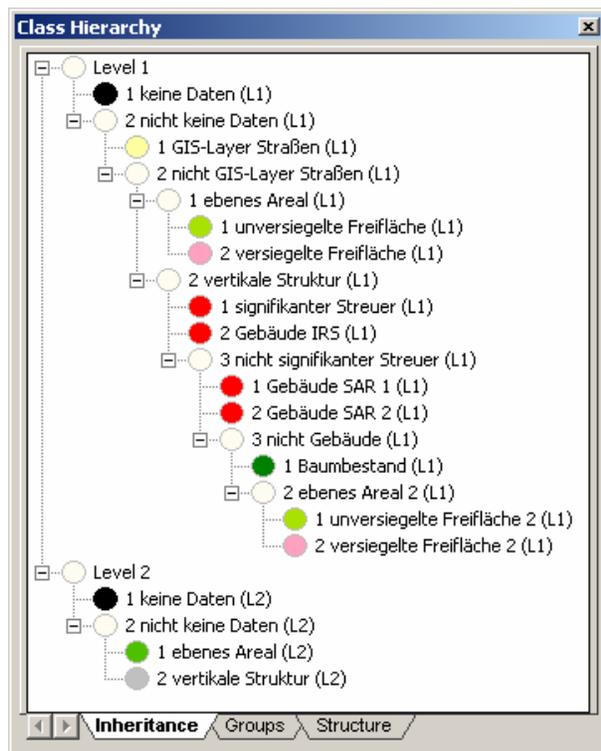


Abb. 4-44: Klassenhierarchie zur Erfassung der urbanen Landnutzung

Anschließend wird innerhalb der als *vertikale Strukturen* ausgewiesenen Bildbereiche nach *signifikanten Streuern* und *Gebäuden IRS* gesucht (VGL. ABB. 4-46). Erstere sind vorwiegend im Zusammenhang mit von Menschenhand geschaffenen Strukturen wie Gebäuden, Brücken, Geländern oder Masten in den Radaraufnahmen zu finden (VGL. KAP. 2.2.4). Zur Klassifizierung der entsprechenden Objekte müssen eine sehr hohe lokale Varianz und Intensität in der Rückstreuung gegeben sein. Wie der Name bereits andeutet, bezieht sich die Klasse *Gebäude IRS* ausschließlich auf Bauwerke, die in der IRS-Szene eindeutig als solche identifiziert werden können. Dabei handelt es sich überwiegend um große Gebäudekomplexe, die als überaus helle Objekte in Erscheinung treten (VGL. ABB. 4-43). Zur Erfassung dieser Segmente werden die Helligkeit, gemittelt über alle drei Aufnahmekanäle sowie die Ratios zwischen Kanal 1 und Kanal 2 bzw. Kanal 2 und Kanal 3 verwendet.

Auf der Basis der verbleibenden *nicht signifikanten Streuer* wird im Anschluss daran nach potentiellen Gebäuden gesucht (VGL. ABB. 4-44). Dabei wird grundsätzlich davon ausgegangen, dass Bauwerke im SAR-Bild zumindest in Teilbereichen Double-Bounce-Reflektionen hervorrufen. Daher müssen Objekte der Klassen *Gebäude SAR 1* bzw. *Gebäude SAR 2* zum einen an mehrere *signifikante Streuer* angrenzen oder zumindest mehrere solcher Streuzentren in ihrer unmittelbaren Umgebung aufweisen.

Gleichsam ist definiert, dass sich Bauwerke in Relation zu ihrer Umgebung durch eine hohe lokale Textur und Intensität kennzeichnen und dabei einen niedrigen NDVI-Wert aufweisen. Segmente, die jener Merkmalskennzeichnung entsprechen, werden als *Gebäude SAR 1* klassifiziert.

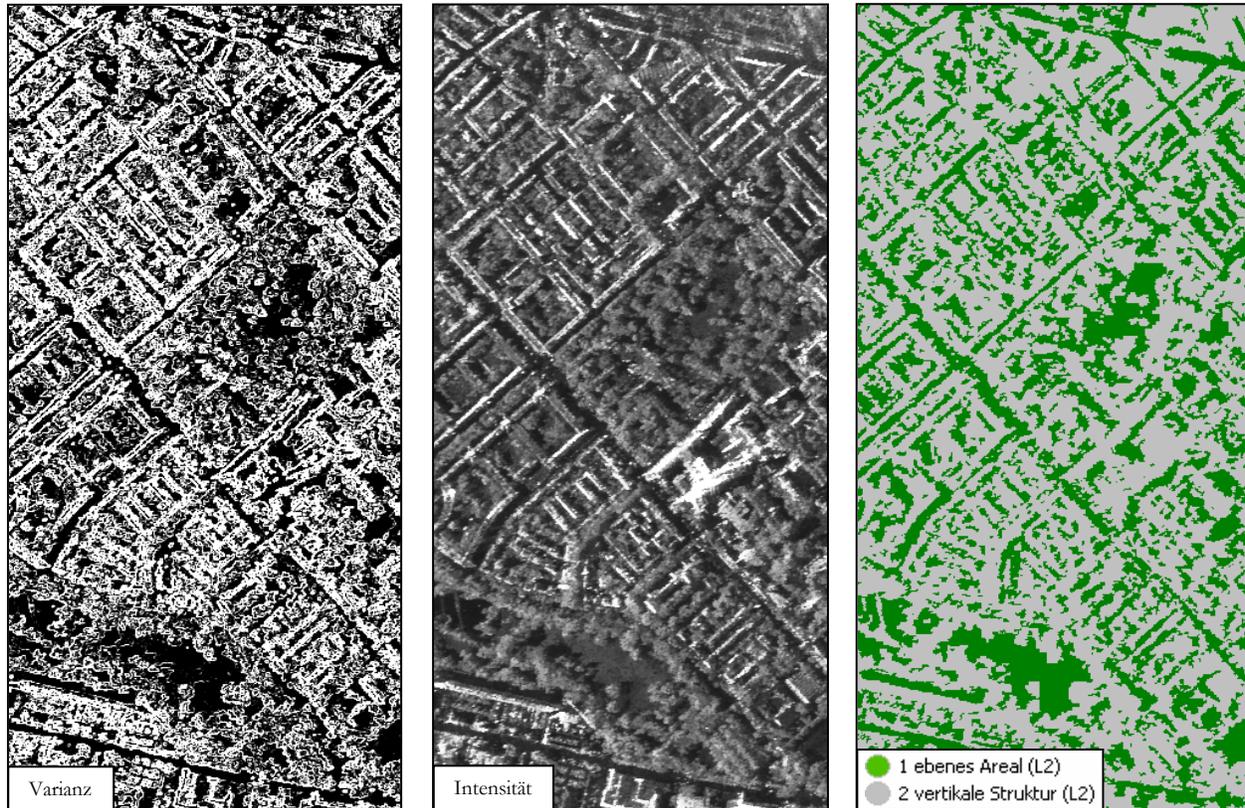


Abb. 4-45: Differenzierung zwischen ebenen und vertikalen Raumstrukturen auf Basis von Radardaten – Als Kriterien zur Identifizierung der betreffenden Bildareale dienen die lokale Varianz und Intensität des empfangenen Radarsignals. Dabei zeichnen sich ebene Flächen dadurch aus, dass sie von Objekten umgeben sind, die im Hinblick auf die Varianz und Intensität signifikant höhere Werte aufweisen.

Die Kategorie *Gebäude SAR 2* folgt ebenfalls dieser Merkmalskennzeichnung, allerdings sind die Attribute etwas weiter gefasst. Zusätzlich wird eine Merkmalskombination ergänzt, die nur dann eine Ausweisung der Klasse *Gebäude SAR 2* zulässt, wenn das betreffende Segment eine hohe relative Grenze zu Objekten der Kategorie *Gebäude SAR 1* aufweist. Durch die Definition der zweiten Gebäudeklasse kann die Grundstruktur von Bauwerken insgesamt adäquater nachgebildet werden, da es immer wieder Bereiche gibt, die eine vergleichsweise geringe Rückstreuung bzw. Textur aufweisen, aber dennoch Teile eines Gebäudekomplexes repräsentieren (VGL. ABB. 4-43).

Sämtliche Objekte, die keiner der beiden Gebäudeklassen zugeordnet werden, fallen der Kategorie *nicht Gebäude* zu. Innerhalb dieser Flächen wird nun der *Baumbestand* extrahiert. Dieser definiert sich über eine signifikant ausgeprägte Intensität und Textur, eine hohe relative Grenzfläche zu dunkleren

Nachbarobjekten – ebenfalls bezogen auf die lokale Varianz und Intensität – und natürlich einen für vegetationsbedeckte Areale hohen Wert des NDVI. Die letztlich verbleibenden Segmente gelten als Objekte, die zuvor fälschlicherweise der Kategorie *vertikale Struktur* zugewiesen wurden. Sie werden daher als *ebenes Areal 2* gekennzeichnet und wie die bereits identifizierten Freiflächen der Klasse *ebenes Areal* in die Kategorien *versiegelte Freifläche* und *unversiegelte Freifläche* unterteilt (vgl. Abb. 4-44).

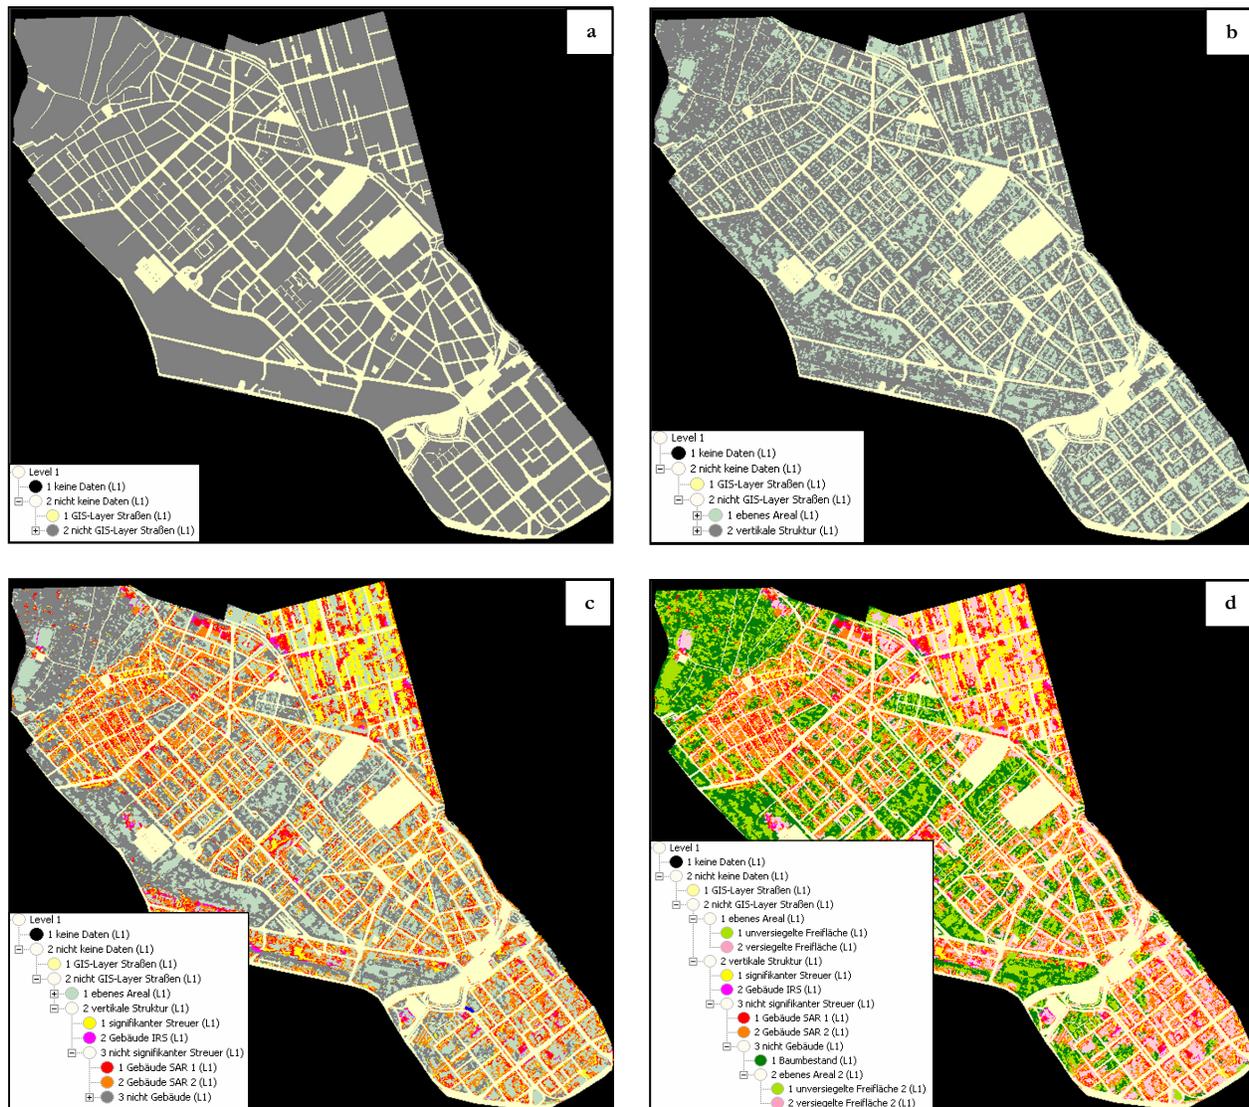


Abb. 4-46: Klassifikationsablauf zur Erfassung der urbanen Landnutzung – Nach Ausweisung der Straßenflächen mittels eines entsprechenden Vektordatensatzes (a) wird zunächst die urbane Topografie analysiert (b) bevor abschließend die Ausweisung von potentiellen Gebäuden (c) sowie Baumbeständen und versiegelten bzw. unversiegelten Freiflächen erfolgt (d).

Da die Merkmalskennzeichnung der *ebenen Areale* und *ebenen Areale 2* identisch ist, kann sie nachfolgend stellvertretend für beide Kategorien erörtert werden. Grundsätzlich erfolgt die Differenzierung zwischen versiegelten und unversiegelten Freiflächen über eine Auswertung des NDVI. Dabei setzen

sich *unversiegelte Freiflächen* entweder aus reiner Vegetation, unbedecktem Boden oder einer Mischung aus beiden Bedeckungstypen zusammen. Erstere definieren sich über extrem hohe NDVI-Werte und eine insgesamt hohe Helligkeit, gemittelt über alle drei Aufnahmekanäle. Unbedeckte Böden hingegen zeigen überaus niedrige Werte für den NDVI, da sie keinerlei Vegetationsbedeckung aufweisen. Im Gegensatz zu asphaltierten oder betonierten Oberflächen – für die ebenfalls ein niedriger NDVI charakteristisch ist – erscheinen sie jedoch im Allgemeinen etwas heller. Daher kommt auch hier neben dem NDVI die gemittelte Helligkeit als Merkmal zum Tragen. Gemischte Flächen aus unbedecktem Boden und Vegetation werden durch mittlere NDVI-Werte bei gleichzeitig hoher Helligkeit gekennzeichnet.

Sämtliche Segmente, die nicht der Klasse *unversiegelte Freiflächen* zuzuordnen sind, werden letztlich als *versiegelte Freiflächen* klassifiziert, womit die automatisierte Analyse abgeschlossen ist.

4.3.3 Diskussion der Ergebnisse

Die Resultate der *synergetischen Auswertung* beider Datentypen zeigen, dass dieser Ansatz grundsätzlich die Möglichkeit einer thematisch und räumlich differenzierten Ableitung einfacher urbaner Nutzungsarten eröffnet. So lassen sich in hoher räumlicher Detaillierung insgesamt *vier urbane Bedeckungstypen* unterscheiden, die sich in die Klassen *Gebäude*, *versiegelte Freifläche*, *unversiegelte Freifläche* und *Baumbestand* untergliedern (VGL. ABB. 4-47). Dabei konnte auf der Grundlage von 220 Referenzpunkten – wiederum gestützt auf Luftbildaufnahmen – eine *Gesamtgüte* von rund *65 Prozent* ermittelt werden (VGL. TAB. 4-11). Eine zu Vergleichszwecken durchgeführte, automatisierte Auswertung basierend auf einem Luftbild (1m Bodenauflösung) ergab demgegenüber eine Genauigkeit von 81 Prozent (VGL. ABB. 4-48).

ABBILDUNG 4-48 verdeutlicht zugleich, dass mittels der synergetischen Auswertung gegenüber einer rein radarbasierten Analyse eine erweiterte Basis thematischer Klassen erfasst werden kann, während sich im Vergleich zu einer IRS-gestützten Auswertung speziell der räumliche Detaillierungsgrad signifikant steigern lässt. Eine genauere Aufschlüsselung der klassenbezogenen Hersteller- sowie Nutzergüte findet sich in TABELLE 4-11. Demnach können *Gebäude* durchschnittlich mit einer Hersteller- und Nutzergenauigkeit von rund *72 Prozent* identifiziert werden. Ein Blick auf die zugehörige Fehlermatrix zeigt, dass inkorrekte Zuweisungen vor allem im Zusammenhang mit versiegelten und unversiegelten Freiflächen auftreten.

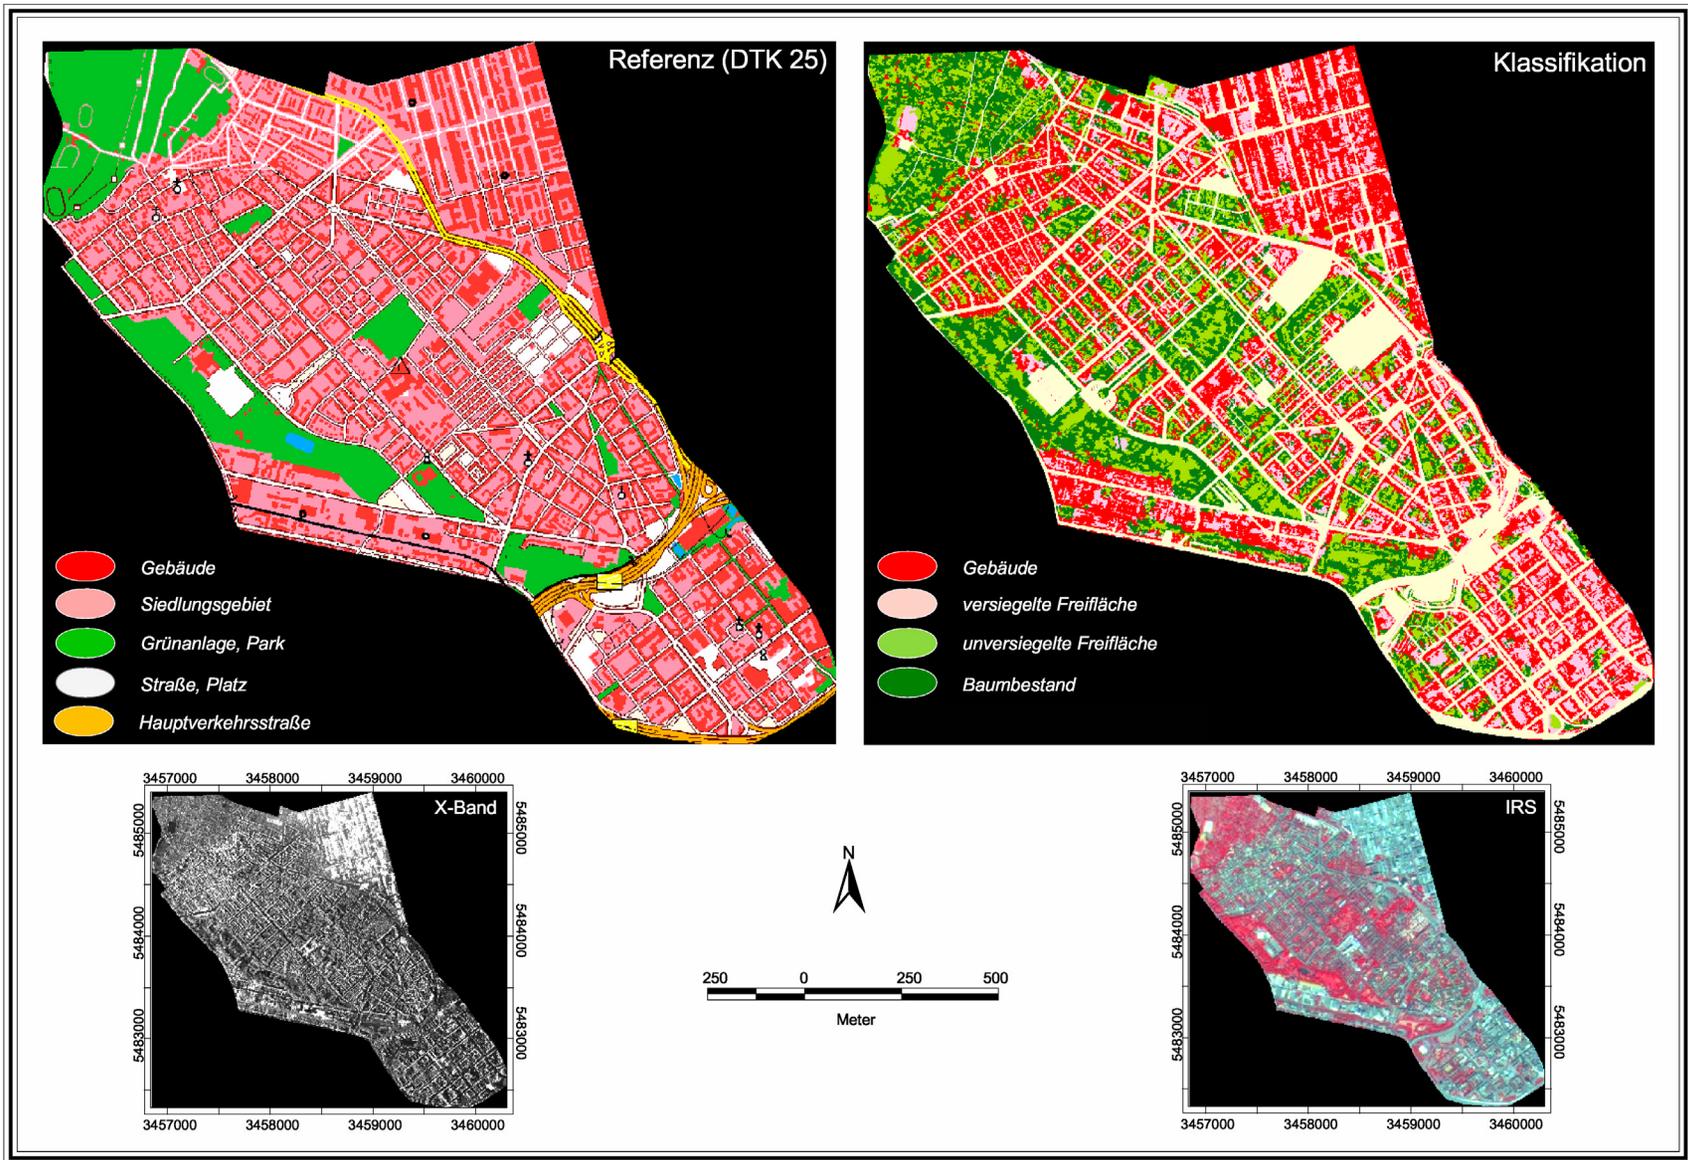


Abb. 4-47: Ergebnis der urbanen Landnutzungsklassifizierung basierend auf der synergetischen Auswertung von X-Band und IRS-Datensatz

Ein wesentlicher Grund für diese Abweichungen liegt im höhenbedingten Lageversatz der Gebäude, infolge dessen es beim direkten Abgleich von Referenzpunkten automatisch zu Differenzen zwischen Referenzdatensatz und Radaraufnahme kommt. In wie weit die Form und Verteilung der Strukturen – und weniger deren exakte Position – mit der Realität übereinstimmen, soll daher am Ende dieses Kapitels durch eine baublockbezogene Betrachtung der abgeleiteten Nutzungstypen erörtert werden.

Die ebenfalls auftretenden Verwechslungen mit *Baumbeständen* rühren vor allem daher, dass gerade einzelne Bäume oder kleine Baumgruppen in der IRS-Aufnahme nicht hinreichend genau erkennbar sind. Daher werden Einzelbäume in der Nähe von Bauwerken – speziell im Innenbereich von Baublocken – oftmals als Gebäude klassifiziert. Umgekehrt treten Gebäude, die mehrere Bäume in ihrer unmittelbaren Umgebung aufweisen, sowohl in der SAR-Aufnahme als auch im IRS-Bild kaum in Erscheinung und werden somit bisweilen als Baumbestand ausgewiesen.

Tab. 4-12: Güte der urbanen Landnutzungserfassung auf Basis einer kombinierten Analyse optischer und SAR-basierter Daten

Klasse	X-Band (HH) + IRS (G-R-NIR)	
	Hersteller*	Nutzer**
Gebäude	71,91%	72,73%
Versiegelte Freifläche	72,73%	40,00%
Unversiegelte Freifläche	54,17%	65,00%
Baumbestand	62,30%	73,08%
Gesamt	65,45 %	

* Anzahl korrekt klassifizierter Referenzen dividiert durch Summe aller Referenzen, die der betrachteten Klasse eigentlich angehören

** Anzahl korrekt klassifizierter Referenzen dividiert durch Summe aller Referenzen, die betrachteter Klasse zugeordnet wurden

Versiegelte Freiflächen können ebenfalls mit einer *Herstellergüte* von rund 72 Prozent erfasst werden, während sich die *Nutzergenauigkeit* auf lediglich 40 Prozent beläuft. Dieser niedrige Wert rührt von einer hohen Anzahl an Gebäude-Objekten, die fälschlicherweise als *versiegelte Freifläche* deklariert wurden. Die Gründe dieser Fehlklassifikation wurden zuvor bereits im Kontext der Ausführungen zur Klasse *Gebäude* dargelegt. Darüber hinaus werden einige *Baumbestände* als *versiegelte Areale* erfasst. Ähnlich wie im Falle der Gebäude handelt es sich dabei vorwiegend um Einzelbäume, die aufgrund ihrer geringen räumlichen Ausdehnung in der IRS-Aufnahme nicht erkennbar sind. Ähnlich den Gebäuden spielen darüber hinaus wiederum Layover-Effekte eine Rolle. So kippen auch Bäume im Radarbild je nach Höhe mehr oder minder stark in Richtung des Sensors auf die vor ihnen liegenden Freiflächen, so

dass es sowohl im Hinblick auf die korrespondierende Fläche im IRS-Bild als auch den direkten, lagebezogenen Abgleich der Referenzpunkte zu Abweichungen kommt.

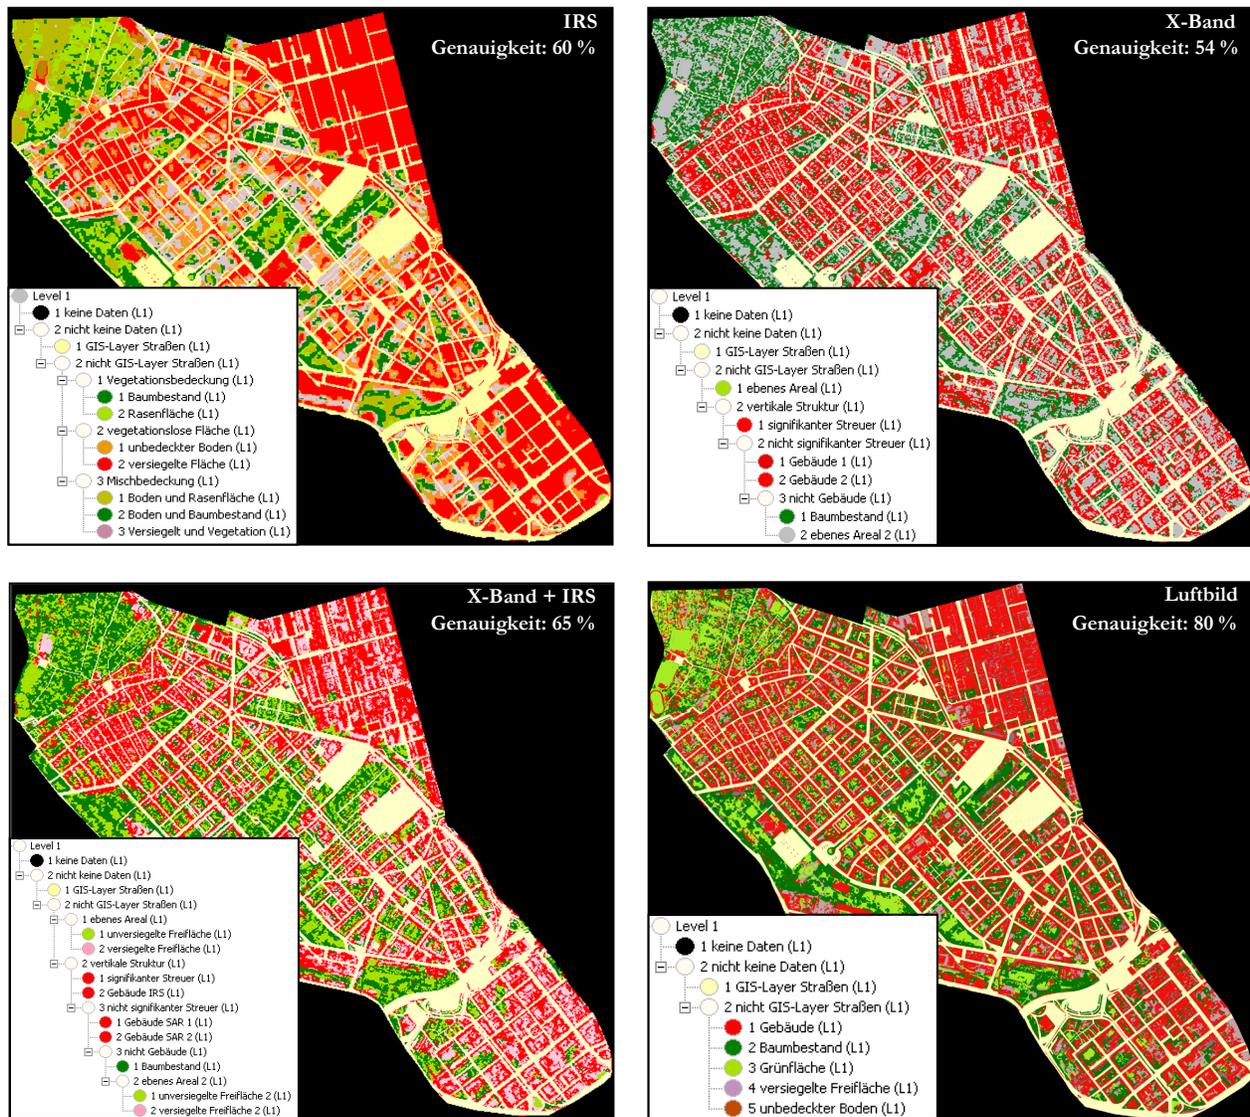


Abb. 4-48: Vergleich des Detaillierungsgrads einer urbanen Landnutzungskartierung basierend auf X-Band Datensatz, IRS-Aufnahme, Kombination beider Datentypen sowie Luftbild

Die Klassifizierung der *unversiegelten Freiflächen* ist mit höheren Fehlern behaftet. So beträgt die *Herstellergenauigkeit* lediglich 54 Prozent und die *Nutzergüte* ebenfalls recht geringe 65 Prozent. Dabei resultieren diese niedrigen Werte überwiegend aus fehlerhaften Zuweisungen unversiegelter Freiflächen zu den Klassen *Gebäude* und *Baumbestand*. Ein genauer Blick auf die entsprechenden Referenzpunkte offenbart zwei grundlegende Fehlerquellen. Zum einen verursachen wiederum die im Zusammenhang mit vertikalen Strukturen wie Bauwerken und Bäumen auftretenden Verkippungseffekte zahlreiche Fehler. Andererseits ist jedoch auch zu erkennen, dass speziell im Kontext von dichtem Baumbestand

Schattenwurf auftritt, der von höheren Exemplaren auf benachbarte, niedrigere Bäume fällt. Da Schattenflächen in der SAR-Aufnahme als ebene Areale erfasst werden, kommt es aufgrund des hohen NDVI-Werts im IRS-Bild letztlich zur Ausweisung von *unversiegelten Freiflächen*.

Die Kategorie *Baumbestand* lässt sich mit einer *Herstellergenauigkeit* von 62 Prozent und einer *Nutzergüte* von 73 Prozent identifizieren. Die geringe Genauigkeit hinsichtlich einer vollständigen Erfassung aller Referenzpunkte dieser Klasse ergibt sich aus der in der Summe relativ hohen Anzahl an den bereits erläuterten Fehlzuweisungen im Kontext der Klassen *unversiegelte Freifläche*, *Gebäude* und *versiegelte Freifläche*. Demgegenüber ist die Menge der fälschlicherweise als *Baumbestand* ausgewiesenen Objekte recht gering und verteilt sich zu gleichen Teilen auf die *Gebäude* sowie *unversiegelten Freiflächen*.

Zum Abschluss dieses Kapitels soll auf der Grundlage repräsentativer Baublöcke die Güte des entwickelten Ansatzes hinsichtlich der Charakterisierung der Siedlungsstruktur eingehender erörtert werden. Dazu werden zunächst in leicht generalisierter Form die Strukturen innerhalb ausgewählter Baublöcke auf der Basis von Luftbildern abdigitalisiert und zu den im Rahmen der fernerkundlichen Auswertung verwendeten Kategorien zusammengefasst. Anschließend wird jeder Nutzungsklasse in der Referenz und im Klassifikationsergebnis ein fiktiver Höhenwert zugewiesen. Dieser beträgt bei *Gebäuden* 20 Meter, bei *Baumbeständen* 10 Meter und bei *versiegelten* sowie *unversiegelten Freiflächen* einen Meter. Somit können die jeweiligen Areale in dreidimensionaler Form visualisiert und einander gegenübergestellt werden. Entsprechende Beispiele sind in ABBILDUNG 4-49 aufgeführt.

ABBILDUNG 4-49A verdeutlicht die Schwierigkeiten im Hinblick auf eine exakte Identifizierung von *Gebäuden*. So ist in den Ausschnitten A1 und A5 zu erkennen, dass es sich bei dem betrachteten Areal um eine gewerblich genutzte Fläche handelt, an deren Außengrenzen umlaufend mehrere Gebäudekomplexe angeordnet sind. Darüber hinaus befindet sich ein weiteres Bauwerk im zentralen Bereich des betrachteten Baublocks. Ferner dominieren zwei asphaltierte Freiflächen.

Mit Blick auf das Ergebnis der automatisierten Auswertung (A4) wird ersichtlich, dass die Anordnung der vorhandenen Gebäude grundsätzlich nachvollzogen wird, während hinsichtlich deren Form, Größe und Anzahl signifikante Abweichungen auftreten. Darüber hinaus sind mehrere Strukturen im zentralen Bereich des betrachteten Areals fälschlicherweise als *Gebäude* ausgewiesen.

Ein entscheidendes Problem bezüglich der korrekten Wiedergabe der Form eines Gebäudes liegt in der Tatsache, dass die einzelnen Flächenelemente der erfassten Bauwerke je nach Aufnahme- und Objektgeometrie auf sehr unterschiedliche Art und Weise zur Rückstreuung des Radarsignals beitra-

gen. So wird die im SAR-Bild als helles Band in Erscheinung tretende Reflektion an den peripher gelegenen Gebäuden nahezu ausschließlich durch die dem Sensor zugeneigten Bereiche der Dachflächen hervorgerufen. Dabei ist speziell am nordöstlichen Bildrand gut zu erkennen, dass die Position der Reflektionszentren aufgrund der relativen Höhe der Dachflächen zum Sensor hin verschoben ist.

Die großflächige Rückstreuung am Gebäude in der südöstlichen Ecke des betrachteten Baublocks resultiert aus zwei sich überlagernden Effekten. So verläuft das besagte Bauwerk im Gegensatz zu den umliegenden Häusern nahezu im rechten Winkel zur Blickrichtung des Sensors. In Kombination mit der vorgelagerten, glatten Freifläche führt diese Anordnung zu einer Double-Bounce-Reflektion am Fuße des Gebäudes (VGL. KAP. 2.2.5). Aufgrund der relativen Höhe ist zugleich die bereits erwähnte Streuung an der Dachfläche in Richtung des einfallenden Radarstrahls versetzt und liegt daher im Bild etwas links von der zuvor erwähnten Corner-Reflektion. Im Klassifizierungsergebnis (A4) ist dabei gut zu erkennen, dass diese beiden Streuzentren getrennt erfasst und klassifiziert werden.

Ein weiteres Problem besteht darin, dass die abgeschatteten Bereiche der Gebäude im Rahmen der Klassifikation nicht mehr dem Bauwerk zugeordnet sind. In der Folge werden die entsprechenden Areale als Freifläche ausgewiesen. Dies wird insbesondere im südwestlichen Winkel des betrachteten Ausschnitts deutlich, wo große Teile der Dachfläche des dortigen Gebäudes bogenförmig als *versiegelte Freifläche* klassifiziert sind (VGL. ABB. 4-49, A4).

Wie zuvor dargelegt, weisen Gebäude ein sehr heterogenes Reflektionsverhalten auf. Daher rufen lediglich Teilbereiche jene signifikanten Rückstreuquerschnitte hervor, die sich letztlich zur Identifizierung der Bauwerke nutzen lassen. Vor diesem Hintergrund erklärt sich, weshalb vermeintlich unscheinbare, reell sehr kleine Strukturen mitunter als Gebäude klassifiziert werden. Wie aus ABBILDUNG 4-49A ersichtlich, treten räumlich vergleichbar begrenzte Objekte wie Mauern, Masten, Geländer oder Bäume aufgrund von Double-Bounce-Effekten oder direkter Rückstreuung mitunter als signifikante Strukturen in Erscheinung, die hinsichtlich der Stärke des reflektierten Signals durchaus im Bereich von Gebäuden liegen. Befinden sich diese lokal begrenzten Streuzentren in unmittelbarer Nachbarschaft zueinander bzw. treten sie räumlich geballt auf, wird leicht das charakteristische Erscheinungsbild eines großen Bauwerks erreicht und es kann zu den eingangs erwähnten Fehlklassifikationen kommen. Dabei führt ein hoher NDVI – indirekt erkennbar an rötlich erscheinenden Flächen in der IRS-Aufnahme – zur fehlerhaften Ausweisung von *Baumbeständen*, während ein niedriger NDVI fälschlicherweise auf die Existenz eines *Gebäudes* schließen lässt (VGL. ABB. 4-49A).

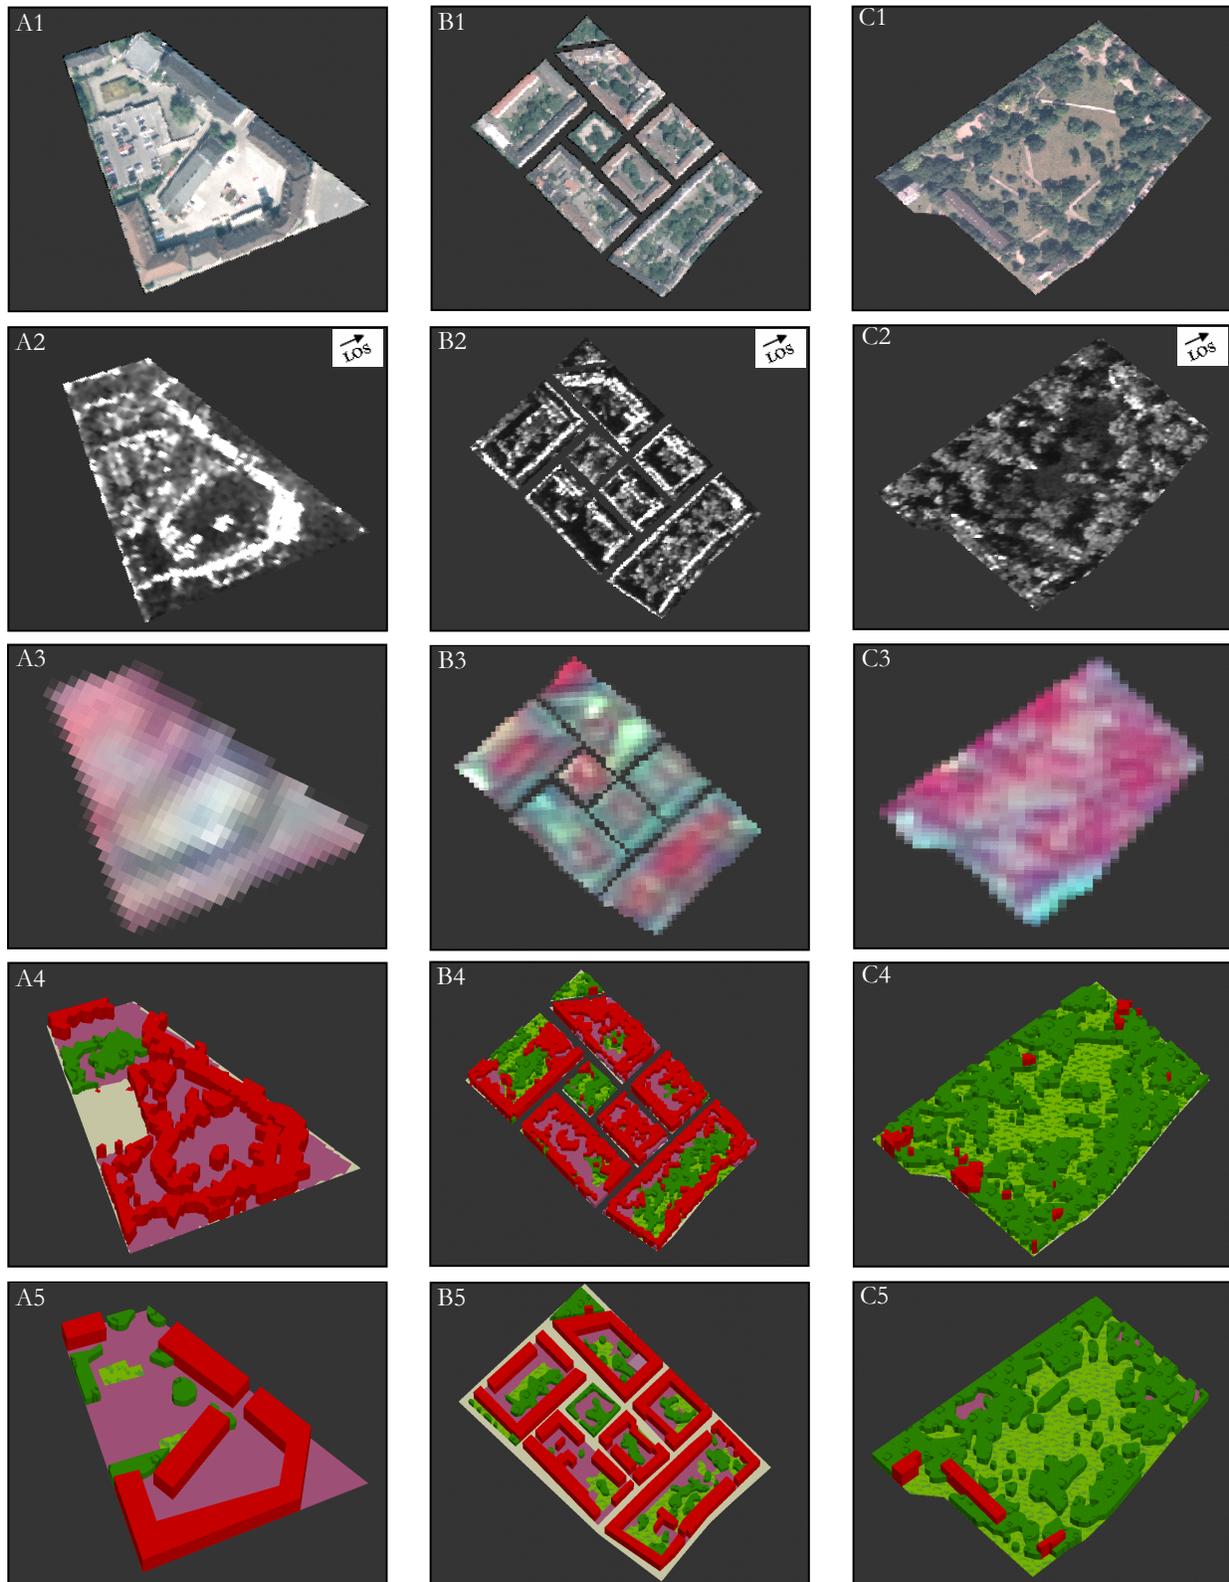


Abb. 4-49: Pseudo-3D-Darstellung der klassifizierten Strukturen am Beispiel repräsentativer Baublöcke – Während sich die Orientierung und Verteilung der großen Raumeinheiten innerhalb der Baublöcke recht zutreffend nachvollziehen lässt, können deren exakte Lage, Form und Beschaffenheit nur unzureichend beschrieben werden.

Aus ABBILDUNG 4-49B geht hervor, dass sich die Verteilung und Anordnung der Gebäude innerhalb eines Baublocks trotz der zuvor erwähnten Schwierigkeiten recht zutreffend nachvollziehen zulässt. Allerdings erweist sich die enorme Kleinteiligkeit der oftmals sehr heterogen gestalteten Innenhofbereiche auch hier als Problem hinsichtlich der Klassifizierung. So sind die einzelnen Objekte bzw. Bedeckungstypen selbst in der hochaufgelösten Radaraufnahme nicht mehr eindeutig zu differenzieren, weshalb bereits die Segmentierung dieser Areale von den tatsächlichen Begebenheiten abweicht. Darüber hinaus lassen sich dadurch im Kontext der thematischen Differenzierung weder die genaue Lage und Verteilung der einzelnen Strukturen nachbilden, noch können diese spektral hinreichend genau beschrieben werden. Folglich kommt es speziell im Innenbereich vermehrt zu Differenzen zwischen der realen Landnutzung und den klassifizierten Strukturen.

Ein abschließender Blick auf ABBILDUNG 4-49C zeigt am Beispiel einer Grün- bzw. Parkanlage, dass sich großflächige, geometrisch weniger komplex strukturierte Raumeinheiten im Vergleich zu den beiden vorangegangenen Exempeln bedeutend akkurater klassifizieren lassen. So stimmen die Form, der Verlauf und die Lage der unversiegelten Freiflächen bzw. Baumbestände – abgesehen von lokalen Abweichungen – grundsätzlich überein und ermöglichen damit prinzipiell eine recht akkurate Wiedergabe der realen Strukturierung bzw. Bedeckung des betreffenden Areals.

Deutliche Abweichungen ergeben sich allerdings im Zusammenhang mit der Ausweisung von Gebäude-Objekten. Dabei ist einerseits zu erkennen, dass die verhältnismäßig großen Häuser am südwestlichen Rand des dargestellten Ausschnitts nur in Teilen erfasst werden. Der Grund für die unvollständige Identifizierung liegt in der starken Abdeckung der betreffenden Gebäudekomplexe durch die umliegenden Baumgruppen. Somit heben sich die Bauwerke in der SAR-Aufnahme kaum von den angrenzenden Baumbeständen ab und werden daher nicht als eigenständige Objekte erkannt. Aufgrund der begrenzten Größe der Bauwerke in Verbindung mit dem hohen Vegetationsanteil in der Umgebung kann auch der IRS-Datensatz nicht zur Verbesserung der fehlerhaften Klassifikation beitragen. Neben der unvollständigen Erfassung kommt es darüber hinaus im nördlichen Bereich des betrachteten Areals zur fälschlichen Ausweisung von Gebäuden im Zusammenhang mit dem Auftreten starker Streuzentren, die auf einzelne Laternen sowie direkte Rückstreuung zurückzuführen sind.

Eine vollständige dreidimensionale Ansicht der abgeleiteten urbanen Strukturen im betrachteten Testgebiet ist in ABBILDUNG 4-50 dargestellt. Dabei vermittelt die Kartierung trotz der zuvor geschilderten Limitierungen einen plastischen Eindruck über die siedlungsstrukturellen Gegebenheiten.

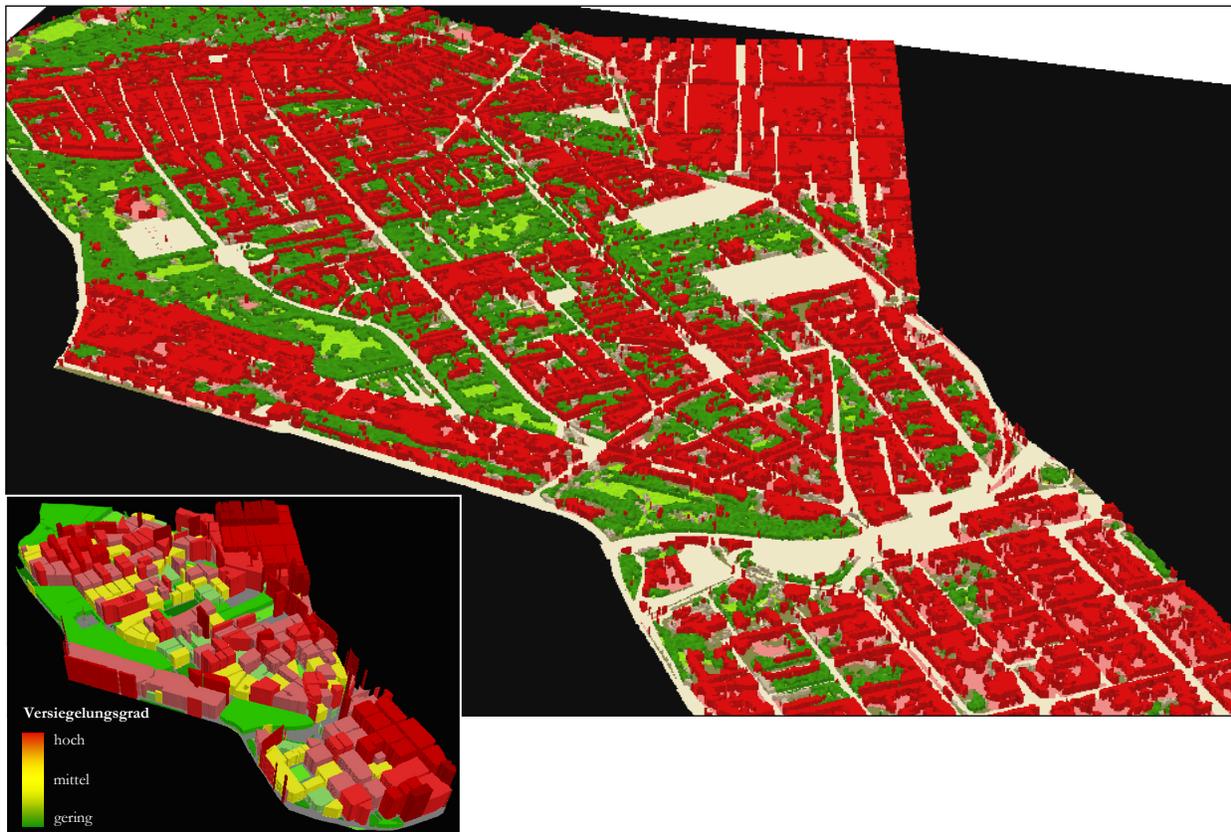


Abb. 4-50: Beispiel für pseudo-3D-Darstellung der klassifizierten Stadtstrukturen und darauf basierender Ableitung des Versiegelungsgrades – Wie die Abbildung vermittelt, kann die Strukturierung der Siedlungsfläche trotz der Schwierigkeiten im Hinblick auf die exakte Erfassung und Nachbildung der einzelnen Objekte recht anschaulich wiedergegeben werden.

So zeichnet sich die im äußersten Norden abgebildete Kleingartenanlage durch einen charakteristischen, kleinräumigen Wechsel von Baumbestand, unversiegelten Freiflächen und Gebäuden aus. Ebenfalls gut zu erkennen sind die dicht mit großflächigen Gebäudestrukturen belegten Industriekomplexe im Nordosten und Westen des betrachteten Testareals sowie die ausgedehnten Grünanlagen im westlichen und zentralen Bildbereich. Demgegenüber zeichnet sich die Innenstadt Ludwigshafens – im Südosten des Ausschnitts gelegen – durch umfassende Gebäudekomplexe in Verbindung mit ausgedehnten, versiegelten Freiflächen aus. Der zentrale Bildbereich wird vor allem durch Blockrandbebauung mit mehr oder minder ausgeprägtem Vegetationsbestand in der Innenzone der Baublöcke dominiert. Letztlich tritt im nördlichen Abschnitt eine sehr kleinteilige, geschlossene oder offenen Blockrandbebauung in Erscheinung. Als Charakteristikum ist dabei der hohe Bebauungsgrad in Verbindung mit einem Fehlen großflächiger Freiflächen zu nennen. Letzteres ist ein bedeutendes Unterscheidungskriterium im Hinblick auf die Abgrenzung zu den ebenfalls intensiv bebauten Industrie- oder Innenstadtbereichen. Dort rufen die bedeutend größeren Gebäudekomplexe flächende-

ckende Schatten hervor, die im Rahmen der Klassifizierung automatisch als raumgreifende Freiflächen in Erscheinung treten (VGL. ABB. 4-50).

Basierend auf dieser Information könnten in nachfolgenden Analyseschritten für jeden Baublock verschiedene Indikatoren zur weiteren Spezifizierung der siedlungsstrukturellen Charakteristika abgeleitet werden. Als Beispiel ist in ABBILDUNG 4-50 das Ergebnis einer Erhebung des Versiegelungsgrades abgebildet. Aus zeitlichen Gründen konnten der Ausbau dieses Ansatzes und dessen Evaluierung im Rahmen der vorliegenden Arbeit jedoch leider nicht weiter vorangetrieben werden.

4.3.4 Zusammenfassung

Nach der Entwicklung einer Methodik zur automatisierten Erfassung von Siedlungsflächen im vorangegangenen Abschnitt widmete sich das KAPITEL 4.3 einem Ansatz zur thematisch *differenzierten Analyse bebauter Areale*. Ziel war die *Ableitung vereinfachter Landnutzungsklassen*, um auf diesem Wege die siedlungsstrukturellen Charakteristika urban geprägter Räume zu beschreiben. Aufgrund der enormen Heterogenität und Kleinteiligkeit der städtischen Nutzungstypen bedurfte die entsprechende Auswertung dabei eines spektralen und räumlichen Detaillierungsgrades, der sich nur bedingt mittels SAR-basierter oder optischer Fernerkundungsdaten bereitstellen ließ.

Daher wurde im Rahmen dieses Kapitels ein *synergetischer Ansatz* vorgestellt, der den *räumlichen Detaillierungsgrad einer hochauflösenden Radaraufnahme* mit der *spektralen Bandbreite eines geometrisch geringer aufgelösten, optischen Satellitenbildes* kombiniert, um somit die *sensorspezifischen Limitierungen* beider Datentypen so weit wie möglich *zu kompensieren*. Als Grundlage dieser Untersuchung dienten ein co-polarisierter X-Band Datensatz des E-SAR-Systems sowie eine Multispektralaufnahme des IRS-Satelliten.

Das *Konzept zur Segmentierung* der Datengrundlage aus optischer und SAR-basierter Aufnahme sieht zunächst die Erstellung einer *Baublockebene* vor. Die Generierung der entsprechenden Segmente basiert auf einem Vektordatensatz, der das Straßennetz innerhalb des betrachteten Areals beschreibt. Diese Ebene dient einzig zur späteren, baublockbezogenen Betrachtung der abgeleiteten städtischen Nutzungsstrukturen und spielt im Kontext der Nutzungskartierung keine Rolle. Im Anschluss wird mit Hilfe des in KAPITEL 4.1.2 vorgestellten Verfahrens zur klassenbasierten Segmentoptimierung ein untergeordnetes Level – die *Klassifizierungsebene 1* – generiert. Die Segmentierung basiert dabei auf dem SAR-Datensatz und der optischen Aufnahme. Letztlich wird auf der Grundlage der hochauflösten Radaraufnahme ein drittes Objektlevel mit nochmals deutlich kleineren Segmenten erstellt –

die *Klassifizierungsebene 2*. Beide Klassifizierungslevel dienen als Grundlage für die anschließende Ableitung der urbanen Landnutzung.

Das *Regelwerk zur synergetischen Auswertung* einer Datengrundlage aus optischer und SAR-basierter Aufnahme zielt darauf ab, die *spezifischen Vorzüge beider Datentypen so zu kombinieren*, dass eine *räumlich und thematisch differenzierte Analyse bebauter Areale* ermöglicht wird. Der Klassifikationsprozess beginnt zunächst auf der *Klassifizierungsebene 1 (Level 2)* mit einer SAR-basierten *Extraktion der urbanen Topografie*. Auf diese Weise werden die siedlungsstrukturellen Raumeinheiten in *ebene Areale* und *vertikale Strukturen* untergliedert. Dabei hat sich der hohe räumliche Detaillierungsgrad der Radaraufnahme in Verbindung mit der daraus resultierenden Möglichkeit zur Beschreibung der mesoskaligen Rauigkeit als überaus nützlich erwiesen.

Im Anschluss daran erfolgt auf der *Klassifizierungsebene 2 (Level 1)* eine weitere *thematische Differenzierung* der identifizierten *ebenen* und *vertikalen Struktureinheiten* in die urbanen Nutzungstypen *Gebäude*, *versiegelte Freifläche*, *unversiegelte Freifläche* und *Baumbestand*. Zu diesem Zweck werden die Merkmale der SAR-Aufnahme durch Attribute des optischen Datensatzes ergänzt. Dabei unterteilt sich die Auswertung grundsätzlich in *zwei Abschnitte*. Einerseits die weitere Untergliederung der *vertikalen Strukturen* und andererseits die Differenzierung der *ebenen Areale*.

Im Hinblick auf die *vertikalen Strukturen* werden zunächst *signifikante Streuer (SAR)* und *Gebäude IRS (Optik)* ausgewiesen. Die dabei identifizierten Objekte repräsentieren mit hoher Wahrscheinlichkeit Elemente eines Gebäudekomplexes. Daher wird nachfolgend in deren unmittelbarer Umgebung eingehender nach weiteren, weniger eindeutig ausgeprägten Gebäudestrukturen gesucht, um diese gegebenenfalls der Kategorie Gebäude zuzuordnen. Sämtliche vertikalen Strukturen, die keiner der definierten Gebäudeklassen zugewiesen werden, repräsentieren entweder *Baumbestand* oder Segmente, die zu Beginn der Auswertung fälschlicherweise als *vertikale Struktur* klassifiziert wurden und eigentlich flache Areale darstellen. Dabei werden die verbleibenden Segmente als *Baumbestand* klassifiziert, wenn sich die Objekte durch eine(n) hohe(n) Intensität (SAR), Textur (SAR), relative Grenzfläche zu dunkleren Nachbarobjekten (SAR) und NDVI (Optik) kennzeichnen. Alle übrigen Strukturen gelten als *ebene Freiflächen*.

Diese Segmente werden schließlich ebenso wie die zu Beginn der Auswertung extrahierten *ebenen Areale* in die Kategorien *versiegelte Freifläche* und *unversiegelte Freifläche* unterteilt. Dabei stellt der NDVI das entscheidende Kriterium zur Differenzierung dar. Vereinfacht gesagt, impliziert ein hoher NDVI

eine geringe bis fehlende Versiegelung, während niedrige Werte – abgesehen von Schotter- oder Sandflächen – prinzipiell für eine stärkere Versiegelung stehen.

Die *Resultate* der synergetischen Auswertung zeigen, dass sich durch die Kombination von geometrisch hochauflösender Radaraufnahme und räumlich weniger detailliertem optischen Datensatz in gewissem Umfang eine räumlich und thematisch differenzierte Analyse urbaner Strukturen realisieren lässt. So kann mittels einer kombinierten Auswertung beider Datensätze grundlegend zwischen den vier urbanen Nutzungs- bzw. Strukturtypen *Gebäude*, *versiegelte Freifläche*, *unversiegelte Freifläche* und *Baumbestand* unterschieden werden. Dabei liegt die Güte der Klassifikation bei 65 Prozent. Allerdings hat sich trotz dieser begrenzten Genauigkeit gezeigt, dass speziell hinsichtlich der Erfassung von *Gebäuden* recht zuverlässige Resultate erzielt werden. So können diesbezüglich jeweils Werte von rund 72 Prozent für die Hersteller- und Nutzergenauigkeit erreicht werden. *Baumbestände* lassen sich mit Genauigkeiten von 62 Prozent bzw. 73 Prozent für die Hersteller- bzw. Nutzergüte etwas weniger akkurat identifizieren. Die größten Schwierigkeiten treten im Zusammenhang mit der Erfassung *versiegelter* bzw. *unversiegelter Freiflächen* auf. Dies liegt maßgeblich darin begründet, dass die Differenzierung vornehmlich auf Attributen des IRS-Datensatzes beruht, da die Radardaten in diesem Kontext kaum nutzbringende Informationen bereitstellen können. Aufgrund der stark limitierten Bodenauflösung des IRS-Systems ist die Aussagekraft der Daten jedoch gerade im kleinräumigen urbanen Umfeld oftmals zu begrenzt.

Ein abschließender Abgleich zwischen den fernerkundlich extrahierten Struktureinheiten und der tatsächlichen strukturellen Beschaffenheit repräsentativer Baublöcke verdeutlicht die Schwierigkeit einer korrekten Charakterisierung der urbanen Nutzungs- und Strukturtypen. So liegt ein entscheidendes Problem hinsichtlich der akkuraten Erfassung von Gebäuden im überaus heterogenen Rückstreuverhalten der einzelnen Gebäudeelemente. Zudem können vermeintlich unscheinbare Strukturelemente wie Mauern, Geländer, Autos oder Bäume bei entsprechender Objekt- und Aufnahmegeometrie Streusignaturen ausbilden, die hinsichtlich ihrer Stärke und räumlichen Ausprägung durchaus im Bereich von Gebäuden liegen. Besondere Schwierigkeiten ergeben sich im Kontext der kleinteiligen und oftmals heterogen genutzten Innenbereiche der Baublöcke. Dort können die einzelnen Objekte bzw. Bedeckungstypen selbst in der detaillierten Radaraufnahme nicht mehr eindeutig aufgelöst werden, weshalb es gerade hier zu hohen Abweichungen kommt. Im Gegensatz dazu können großflächige, geometrisch weniger komplex strukturierte Raumeinheiten wie Grün- oder Parkanlagen bedeutend akkurater erfasst und klassifiziert werden.

Kapitel 5

Fazit

Auf der Basis der zuvor gewonnen Erkenntnisse sollen im Rahmen dieses Kapitels abschließend die Potentiale und Limitierungen hinsichtlich des siedlungsbezogenen Einsatzspektrums höchstauflösender Radaraufnahmen dargelegt werden. Darüber hinaus gilt es, auf Grundlage der durchgeführten Studien den weiterführenden Forschungsbedarf in der urbanen Radarfernerkundung zu skizzieren.

5.1 Potentiale und Limitierungen der urbanen Radarfernerkundung

Grundsätzlich bietet die Radarfernerkundung den Vorteil, dass die Fähigkeit zur wetter- und tageslichtunabhängigen Datenaufzeichnung eine Konstanz, Verlässlichkeit und Flexibilität in der Erdbeobachtung gewährleistet, die mittels optischer Sensoren nicht realisierbar ist. Im Hinblick auf

- die Erdbeobachtung in Regionen mit hohem Wolkenbedeckungsgrad (z.B. tropische Zonen),
- multitemporale Analysen in konstanten Zeitabständen,
- die Überwachung zeitlich oder räumlich dynamischer Phänomene,
- die Erfassung (über-)regionaler Raumeinheiten innerhalb eines eng definierten Zeitintervalls,
- kurzfristige oder unvorhersehbare Ereignisse (z.B. Katastrophen- oder Krisenfälle),

ist die Radartechnik daher ein besonders zuverlässiges Werkzeug zur fernerkundlichen Informationserhebung. Allerdings haben die Ausführungen im Kontext dieser Arbeit gezeigt, dass es zur Erschließung dieses Potentials der verstärkten *Entwicklung nutzerorientierter Ansätze zur operationellen Ableitung von Geoinformationsprodukten aus Radaraufnahmen* bedarf. Dies ist eine zwingende Voraussetzung, um über gesenkte Produktionskosten, flexiblere Fortschreibungsintervalle und adäquate Qualitätsstandards die Akzeptanz der Radartechnik im kommerziellen und planerischen Umfeld zu fördern.

Vor diesem Hintergrund war es das primäre Ziel dieser Dissertation, auf der Grundlage einer *robusten und praxisnahen Methodik* das Potential hochauflösender SAR-Daten hinsichtlich einer *operationellen Erfassung und Analyse von Siedlungsflächen* zu untersuchen. Diesbezüglich haben die Resultate der durchgeführten Studien gezeigt, dass eine automatisierte Analyse hochauflösender Radaraufnahmen

- nur bedingt zur Charakterisierung der lokalen Siedlungsstruktur eingesetzt werden kann.
- sehr gut zur regionalen Erfassung der Siedlungsflächen und Flächennutzung geeignet ist.

Die *Erfassung der lokalen Siedlungsstruktur* konnte lediglich über die synergetische Auswertung einer Radaraufnahme und eines optischen Datensatzes annähernd erfolgreich umgesetzt werden. Dabei hat sich gezeigt, dass hochaufgelöste SAR-Daten vornehmlich zur Erfassung der urbanen Topografie – sprich der Anordnung und Ausrichtung der siedlungsstrukturellen Grundeinheiten – geeignet sind, während zur detaillierteren Charakterisierung einzelner Objekte umfassendere Spektralinformationen eines optischen Datensatzes notwendig sind. Trotz der kombinierten Auswertung lag die Gesamtgenauigkeit dennoch bei vergleichbar geringen 65 Prozent (VGL. KAP. 4.3.3). Dabei konnten Gebäude mit einer Güte von 72 Prozent recht zuverlässig identifiziert werden. Die Erfassung von Baumbeständen sowie versiegelten und unversiegelten Freiflächen hingegen unterlag bei Genauigkeiten zwischen 40 Prozent bis 70 Prozent bedeutend höheren Unsicherheiten. Auf Grundlage der gewonnenen Erkenntnisse lässt sich im Hinblick auf die Schwierigkeiten bezüglich einer *Betrachtung der lokalen Siedlungsstruktur auf der Basis von SAR-Daten* resümieren, dass

- zur detaillierten Analyse von Siedlungsflächen eine geometrische Auflösung erforderlich ist, die gegenwärtig selbst von flugzeuggetragenen Systemen kaum bereitgestellt werden kann.
- der Bildinhalt der SAR-Daten durch physikalische Objekteigenschaften bestimmt wird, die mitunter keine Relevanz hinsichtlich der erwünschten thematischen Information aufweisen.
- der Informationsgehalt hochaufgelöster Radaraufnahmen für thematisch differenzierte Analysen der städtischen Umgebung oftmals nicht ausreichend ist.
- das Erscheinungsbild der urbanen Strukturen im SAR-Bild je nach Beschaffenheit der system- und objektspezifischen Aufnahmebedingungen enorm variiert.
- in den geometrisch komplexen urbanen Szenarien verstärkt Verzerrungs- und Abschattungseffekte auftreten, die eine eindeutige Identifizierung der Strukturen im Radarbild erschweren.
- mittelaufgelöste, optische Daten eine SAR-basierte Analyse nur bedingt unterstützen können.
- eine geometrisch exakte Überlagerung von Radaraufnahmen und optischen Daten im lokal stark reliefierten, urbanen Raum nur eingeschränkt möglich ist.

Im Rahmen der *regionalen Analysen* zur Klassifizierung der *Landnutzung* und *Identifizierung von Siedlungsflächen* konnten weitaus überzeugendere Ergebnisse erzielt werden. So ließen sich bereits auf der Basis einfach-polarisierter SAR-Aufnahmen Genauigkeiten von rund 90 Prozent erreichen. Durch die Integration weiterer Polarisationen, Frequenzen oder optischer Daten konnte die Güte der Klassifizierung dabei nochmals um ein Prozent, fünf Prozent bzw. sechs Prozent gesteigert werden (VGL. KAP. 4.2.3). Die überzeugendsten Ergebnisse lieferte die Kombination von Radar und Optik, da sich die aussagekräftigeren Textur- und Strukturmerkmale des Radarbildes optimal mit der umfassenderen Spektralinformation des optischen Datensatzes ergänzen. Vor diesem Hintergrund könnte sich die synergetische Nutzung zukünftiger Systeme wie TerraSAR-X und RapidEye als vielversprechende Option zur Ausweitung des Anwendungsspektrums dieser beiden Sensortypen erweisen.

Neben den zuvor dargelegten Schlussfolgerungen konnten im Rahmen der durchgeführten Untersuchungen ferner wichtige Erkenntnisse im Hinblick auf den Einfluss der system- und objektspezifischen Abbildungsparameter gesammelt werden. Diese sind in TABELLE 5-1 zusammengefasst.

Im Hinblick auf die Möglichkeiten zur *Erschließung des Informationsgehalts* höchstauflösender Radaraufnahmen über ein bereits *etabliertes Verfahren der digitalen Bildauswertung* hat sich die objektorientierte Software eCognition als sehr flexibles und effektives Werkzeug erwiesen (VGL. KAP. 3.3). Gerade im Kontext des begrenzten spektralen Informationsgehalts von SAR-Daten und des mitunter sehr heterogenen Erscheinungsbilds bestimmter Objektarten in Radaraufnahmen (z.B. Gebäude) hat sich die umfangreiche Funktionalität zur Berücksichtigung form-, textur-, kontext- und hierarchiebezogener Charakteristika als entscheidende Größe zur robusten und gleichsam akkuraten Analyse erwiesen. Dadurch konnte die Auswertung gezielt auf strukturelle Merkmale fokussiert werden, die in wesentlich geringerem Umfang störenden Variationen unterliegen.

Limitierungen der Software eCognition wie die fehlende Möglichkeit zur texturbasierten Segmentierung oder Defizite im Hinblick auf die Übertragbarkeit und Güte der Bildsegmentierung bzw. die zweckmäßige Bestimmung der optimalen Segmentierungsparameter konnten durch die Entwicklung spezifischer Verbesserungsansätze reduziert werden. In diesem Zusammenhang wurde ein neues Filterverfahren konzipiert, dessen Algorithmus gegenüber den etablierten Techniken eine konsequentere Reduzierung des störenden SAR-Speckle in homogenen Bildarealen gewährleistet, während die hochfrequente Information in hochstrukturierten Aufnahmebereichen bedeutend besser erhalten bleibt (VGL. KAP. 4.1.1.2).

Tab. 5-1: Einfluss system- und objektspezifischer Aufnahmeparameter im Rahmen der Analyse urbaner Räume

Systemparameter		Vorteil	Nachteil
Wellenlänge	X-Band	<ul style="list-style-type: none"> Hohe Azimuth-Auflösung aufgrund geringer Wellenlänge Differenzierung von Flächentypen aufgrund der Rauigkeit Detaillierte Erfassung und Wiedergabe der Zielobjekte 	<ul style="list-style-type: none"> Signifikanter Einfluss des SAR-Speckle Geringerer Kontrastunterschied zwischen bebauten und unbebauten Arealen Raue Freiflächen erreichen mitunter siedlungs-ähnliche Intensitäten
	C-Band	<i>Ähneln in seinen Eigenschaften stark dem X-Band, jedoch</i> <ul style="list-style-type: none"> Geringere Azimuth-Auflösung Verminderter Kontrast durch geringeren Einfluss der mikroskaligen Rauigkeit Stärkere Durchdringung des Blattwerks von Vegetation 	
	L-Band	<ul style="list-style-type: none"> Hoher Kontrastunterschied zwischen bebauten Arealen und Frei- bzw. Waldflächen Verminderter Einfluss der Vegetation erhöht Sichtbarkeit von Bauwerken Geringerer Einfluss des Bildrauschens und lokaler Details 	<ul style="list-style-type: none"> Vergleichsweise geringe Azimuth-Auflösung Zunahme spiegelnd reflektierender Oberflächen erschwert Identifizierung von Schattenzonen Verminderter Einfluss der mikroskaligen Rauigkeit erschwert Differenzierung von Oberflächenbelägen (z.B. Rasen, Asphalt)
Polarisation	Co-Pol.	<ul style="list-style-type: none"> Markante Ausprägung der für Bauwerke charakteristischen di- und trihedralen Reflexionen 	
	Cross-Pol.	<ul style="list-style-type: none"> Klare Abgrenzung zwischen Ackerflächen mit hohem Anteil direkter oder dihedraler Rückstreuung und Siedlungsflächen Stärkerer Kontrastunterschied zwischen bebauten Arealen und Frei- bzw. Waldflächen 	<ul style="list-style-type: none"> Schlechteres Signal-zu-Rausch-Verhältnis (SNR) Ungünstiges SNR verringert Kontrastunterschiede und erschwert Erfassung von Schatten
	Dual-Pol. (HH+HV)	<ul style="list-style-type: none"> Differenzierung zwischen Oberflächen- und Volumenstreuung (z.B. Ratio HH/HV) Verbesserte Diskriminierung zwischen bebauten Arealen und Frei- bzw. Waldflächen 	
Einfallswinkel	Gering (20°)	<ul style="list-style-type: none"> Reduzierte(r) Abdeckung und Schattenwurf Erhöhte Kontrastunterschiede innerhalb bebauter Flächen Verstärktes Auftreten von Double-Bounce-Reflexionen 	<ul style="list-style-type: none"> Reduzierte Bodenaufklärung Vermeehrt Layover- und Überstrahleffekte Reduzierter Kontrastunterschied zwischen bebauten und unbebauten Arealen Mitunter enorme Streuwerte auf Acker- und Waldflächen
	Mittel (40°)	<i>Mittlere Einfallswinkel (35°-45°) bieten besten Kompromiss zwischen positiven und negativen Effekten</i>	
	Hoch (60°)	<ul style="list-style-type: none"> Erhöhte Bodenaufklärung Minimierung von Layover- und Überstrahleffekten 	<ul style="list-style-type: none"> Verringerter Kontrast innerhalb bebauter Areale Hoher Schatten- und Abdeckungsanteil Reduzierung der Double-Bounce-Reflexionen
Objektparameter		Effekt	
Objektgeometrie		<ul style="list-style-type: none"> Beziehung zwischen Blickrichtung des SAR (LOS) und Ausrichtung der Zielobjekte hat im Vergleich zu übrigen System- und Objektparametern den größten Einfluss auf Erscheinungsbild und Erkennbarkeit urbaner Strukturen Corner-Reflexionen an Hauswänden oder direkte Rückstreuung von geneigten Hausdächern tritt ausschließlich bei geringer Abweichung von Orthogonalität zwischen LOS und Ausrichtung der betreffenden Flächen auf Sichtbarkeit von Straßen hängt maßgeblich von ihrem Verlauf relativ zur LOS ab Orthogonale Orientierung von Ackerfurchen relativ zur LOS führt bei unbedeckten Ackerflächen zu signifikantem Anstieg der Rückstreuung und Textur 	
Oberflächenrauigkeit		<ul style="list-style-type: none"> Rückstreuung rauer Flächen auch unter variierenden Depressionswinkeln und Blickrichtungen etwa konstant Dachflächen wirken je nach Material und Orientierung als spiegelnde Reflektoren oder diffuse Streuer <i>Vgl. Ausführungen zu Einfallswinkel</i> 	
Dielektrische Eigenschaften		<ul style="list-style-type: none"> Kleine Metallobjekte, feuchte Böden oder vitale Vegetationsflächen rufen mitunter Signalstärken in Größenordnung von Bauwerken hervor 	

Die Stabilität und Steuerung der Bildsegmentierung konnte darüber hinaus durch den Entwurf eines klassenbasierten Ansatzes zur Segmentoptimierung verbessert werden. Dieses Verfahren erhöht einerseits die Übertragbarkeit und Güte der Segmentierung und erleichtert gleichsam die Bestimmung der optimalen Segmentierungsparameter (VGL. KAP. 4.1.2).

In Bezug auf das *Potential der Software eCognition zur Operationalisierung der Bildauswertung* haben die Arbeiten gezeigt, dass weiterhin Optimierungsbedarf bezüglich der Modifizierung erstellter Protokolle und den bislang erheblichen Prozessierungszeiten bei der Verarbeitung großer Datenmengen besteht. Eine abschließende Bewertung der identifizierten Vorzüge und Limitierungen der Bildanalysesoftware eCognition findet sich in TABELLE 5-2.

Tab. 5-2: Bewertung der Software eCognition 3.2

Funktionalität	Vorteil	Nachteil	Verbesserungspotential
Segmentierung	<ul style="list-style-type: none"> ▪ Akkurate Bildsegmentierung ▪ Flexible Steuerung der Objekteigenschaften durch multiskaligen Ansatz ▪ Potential zur Data Fusion 	<ul style="list-style-type: none"> ▪ Trial-and-Error-Vorgehen ▪ Hoher Zeitaufwand für ungeübten Nutzer ▪ Hohe Prozessierungsdauer bei großen Bildausschnitten ▪ Texturbasierte Segmentierung nur bedingt möglich 	<ul style="list-style-type: none"> ▪ Trial-and-Error-Vorgehen ▪ Option zur Verarbeitung komplexer SAR-Daten ▪ Unterstützende Funktionen zur Ermittlung der geeigneten Parameter ▪ Polarimetrische Segmentierung
Klassifizierung	<ul style="list-style-type: none"> ▪ Aussagekräftige Bildprimitive ▪ Umfassender Merkmalskatalog ▪ Enorme Flexibilität ▪ Modellierung räumlicher und funktionaler Beziehungen ▪ Data Fusion Funktionalität ▪ Fuzzy Logic 	<ul style="list-style-type: none"> ▪ Komplexität des Regelwerks beliebig skalierbar ▪ Zeitaufwand zur Erstellung der Wissensbasis schlecht abschätzbar ▪ Erstellung des Regelwerks erfordert erfahrenen Nutzer 	<ul style="list-style-type: none"> ▪ Funktionalität zur Vorverarbeitung der Daten (z.B. Filterung) ▪ Attribute und Funktionalität zur polarimetrischen Analyse ▪ Auswertung komplexer SAR-Daten
Operationalisierung	<ul style="list-style-type: none"> ▪ Protokollfunktion 	<ul style="list-style-type: none"> ▪ Eingeschränkte Editierbarkeit erstellter Protokolle ▪ Lange Prozessierungsdauer für umfangreiche Datensätze 	<ul style="list-style-type: none"> ▪ Unterstützung von Multiprocessor-Umgebung ▪ Verbesserte Batch-Funktionalität

5.2 Zukünftiger Forschungsbedarf

Bisher können hochauflösende SAR-Aufnahmen – wie sie für eine differenzierte Analyse urbaner Räume benötigt werden – ausschließlich über flugzeuggetragene Systeme erhoben werden. In der Folge sind entsprechende Forschungsarbeiten stets auf geringe Datenmengen und räumlich begrenzte Testgebiete beschränkt. Mit dem *Start neuer SAR-Satellitenmissionen* wie dem deutschen TerraSAR-X, dem kanadischen Radarsat-2 oder dem japanischen ALOS-PalSAR werden jedoch erstmals Radaraufnahmen mit einem räumlichen Auflösungsvermögen von wenigen Metern und einer flexiblen

Konfigurationen der Polarisierungen bzw. Frequenzen auf einer operationellen Basis zur Verfügung stehen (ICHITSUBO ET AL., 2003; ROTH, 2005; MDA, 2006). Mit Blick auf die verbesserten Leistungsmerkmale dieser SAR-Systeme erschließen sich der Radarfernerkundung daher im urbanen Kontext völlig neue Perspektiven. Basierend auf den Erkenntnissen dieser Dissertation werden daher im Folgenden innovative Auswertetechniken und Nutzungsszenarien vorgestellt, die aus Sicht dieser Arbeit als wichtiger Baustein auf dem Weg zur operationellen Ableitung nutzerorientierter Geoinformationsprodukte dienen könnten:

Data Fusion / Sensor Integration

Die Kombination unterschiedlicher Frequenzen oder Datentypen kann erheblich zur Verbesserung einer SAR-basierten Auswertung beitragen (DELL'ACQUA ET AL., 2002; HAACK & HEROLD, 2002; FATONE ET AL., 2001). Wie unter anderem die vorliegende Arbeit gezeigt hat, hängt die Effizienz einer solchen synergetischen Auswertung jedoch maßgeblich von einer exakten räumlichen Überlagerung bzw. Fusion der genutzten Datensätze ab. Daher kommt der Entwicklung von Verfahren zur *automatisierten Orthorektifizierung*, *Ko-Registrierung* und *Fusion* höchstauflösender Radaraufnahmen – bzw. optischer Daten und SAR-Aufnahmen – eine hohe Bedeutung zu. Darüber hinaus gewinnt die Integration von Vektorinformationen (z.B. Gebäudegrundrisse, Straßennetz) oder hochauflösenden Geländemodellen (z.B. Laser-Scanning) zur Optimierung einer SAR-basierten Analyse an Relevanz.

Kohärenzanalysen (SAR Interferometrie)

In Zukunft sollte eingehender erforscht werden, in welchem Umfang *Kohärenzanalysen auf der Basis höchstauflösender SAR-Daten* zur verbesserten *Differenzierung der lokalen Siedlungsstrukturen* eingesetzt werden können. So zeigen Studien auf der Grundlage mittelaufgelöster Radardaten – beispielsweise von STROZZI & WEGMÜLLER (1998) –, dass interferometrische Prozessierungstechniken zur effizienten Erfassung von Siedlungsflächen eingesetzt werden können, während HOFFMANN ET AL. (2004) diese Verfahren zur Kartierung von Veränderungen im Kontext von Schadenskartierungen einsetzen. Ferner bietet das von MERCER & GILL (1998) oder STILLA ET AL. (2002) beschriebene Potential zur Generierung detaillierter, urbaner Geländemodelle auf der Grundlage höchstauflösender Radardaten interessante Möglichkeiten im Hinblick auf die Klassifizierung urbaner Szenerien.

SAR-Polarimetrie / PolInSAR

Auch die *polarimetrische Analyse der städtischen Umwelt* sollte zukünftig verstärkt in den Fokus der Forschung gerückt werden. Mit der Bereitstellung von vier Aufnahmekonfigurationen erlauben vollpolarisierte Radaraufnahmen eine bedeutend exaktere Charakterisierung des Streuverhaltens der erfassten Oberflächen und Objekte als dies bei konventionellen dual- oder einfach-polarisierten SAR-Daten der Fall ist (ULABY & ELACHI, 1990; CLOUDE & POTTIER, 1996). Vielversprechende Studien zur differenzierten Charakterisierung urbaner Bedeckungstypen wurden unter anderem von AOKI ET AL. (1999) und PELLIZERI (2003) durchgeführt. Untersuchungen von FERRO-FAMIL ET AL. (2002) zeigen, dass sich darüber hinaus durch die Kombination polarimetrischer und interferometrischer Ansätze (*PolInSAR*) die Klassifizierung der Landbedeckung gegenüber einer isolierten Anwendung beider Techniken signifikant verbessern lässt. Daher sollten diesbezügliche Verfahren speziell im Hinblick auf ihren Nutzen für einen Einsatz im urbanen Kontext getestet werden.

Radarspezifische Filter- und Segmentierungsverfahren

Die Entwicklung *effizienter Verfahren zur Bildglättung und Segmentierung* spielt gerade im Hinblick auf die automatisierte Auswertung von SAR-Daten eine besondere Rolle. Innovative Ansätze zur Filterung und Segmentierung werden unter anderem im Kontext der SAR-Polarimetrie erstellt (LEE ET AL., 2003; LEE ET AL., 1999; LOMBARDO ET AL., 2002). Ferner bietet die *multitemporale Filterung* neue Perspektiven im Hinblick auf die Glättung von Radaraufnahmen. Dies umfasst sowohl die direkte Fusion von SAR-Aufnahmen als auch die Definition von Kohärenz- oder Texturmerkmalen, die auf einer multitemporalen Datenbasis berechnet werden und zur Steuerung eines Glättungsalgorithmus dienen. Letzteres stellt eine bedeutende Option im Hinblick auf die Weiterentwicklung des im Rahmen dieser Arbeit erstellten Ansatzes zur Bildglättung dar. Darüber hinaus ist zudem die Entwicklung eines *texturbasierten Segmentierungsverfahrens* von zentralem Interesse. In diesem Kontext sollte auch untersucht werden, in welchem Umfang der im Rahmen dieser Arbeit entwickelte Ansatz zur klassenbasierten Segmentoptimierung unter eCognition durch die Integration texturbezogener Ähnlichkeitsmaße um diese Funktionalität erweitert werden kann.

Modellierung der urbanen Reflektionscharakteristik

Umfassende Untersuchungen zur Interaktion zwischen elektromagnetischer Strahlung und urbaner Umwelt sind speziell im siedlungsbezogenen Umfeld relevant, da gerade im komplex strukturierten, städtischen Raum das Wirkungsgefüge von system- und objektspezifischen Aufnahmeparametern weiterhin nicht vollständig nachvollzogen werden kann. Daher gilt es, über systematische Modellie-

rungen gezielt die Wirkungszusammenhänge zwischen elektromagnetischer Strahlung und urbanen Strukturen bzw. Oberflächentypen nachzuvollziehen. Auf dieser Grundlage könnten die Einflüsse und Effekte variierender Aufnahmeparameter (z.B. multi-look-direction, multi-incidence-angles) simuliert und optimierte Aufnahmekonstellationen oder Auswertetechniken bezüglich der Analyse urbaner Räume erarbeitet werden. Erste Forschungsansätze zu dieser Thematik präsentieren FRANCESCHETTI ET AL. (2002) sowie SOERGEL ET AL. (2003).

Nutzungsszenarien

Speziell mit Blick auf die zukünftige Entwicklung auf dem Sektor der satellitengestützten Fernerkundung gewinnt die Definition neuer Anwendungsszenarien zur synergetischen Auswertung optischer und/oder SAR-basierter Datengrundlagen zunehmend an Relevanz. So könnten optische Daten im Rahmen einer kombinierten Auswertung mit SAR-Aufnahmen zur exakten Identifizierung und Verortung der erfassten Objekte eingesetzt werden, während Radardaten zusätzliche Informationen – beispielsweise über die Höhe von Strukturen, abgeleitet aus Layover und Schatten – beisteuern. Diesbezüglich sei auf eine Studie von TUPIN & ROUX (2003) verwiesen. Ferner bietet sich der Einsatz von SAR-Aufnahmen zur Überbrückung zeitlicher Lücken in der Beobachtung mit optischen Sensoren an. Ein weiteres, interessantes Szenario besteht darin, SAR-Daten flächendeckend und zeitlich nahezu beliebig auflösbar zur Detektierung von Veränderungen einzusetzen, während die qualitative und quantitative Charakteristik der identifizierten Veränderung über einen zielgerichteten Einsatz optischer Daten bestimmt wird.

Am Ende der Dissertation angelangt, bleibt mir nunmehr zu wünschen übrig, dass die Erkenntnisse aus dieser Arbeit einen fundierten und umfassenden Einblick in die Potentiale und Limitierungen der urbanen Radarfernerkundung gewähren und darüber hinaus einen nutzbringenden Beitrag für zukünftige Entwicklungen im Kontext der Fernerkundung leisten können.

Anhang A

Literaturverzeichnis

A

ACQUA, F. D., GAMBA, P. AND G. LISINI (2002). Extraction and fusion of street networks from fine resolution SAR data. In: Proceedings of IGARSS'02, 24.-28. June, Toronto, Canada, CD-ROM.

AOKI, H., MATSUOKA, M., YAMAZAKI, F., URATSUKA, S., KOBAYASHI, T. AND M. SATAKE (1999). Backscattering characteristics of airborne SAR images for seismic vulnerability assessment in urban areas. In: Proceedings of 20th Asian Conference on Remote Sensing (ACRS'99), November 1999, Hong Kong, China, S. 22-25.

ATKINSON, P.M. AND P. LEWIS (2000). Geostatistical classification for remote sensing: an introduction. In: Computers & Geosciences 26, 2000, S. 361-371.

B

BAATZ, M. AND A. SCHÄPE (2000). Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation. In Strobl, J. et al. (Hrsg.): Angewandte Geographische Informationsverarbeitung XII. Wichmann, S.12-23.

BARNESLEY, M. AND S. BARR (1997). A graph-based structural pattern recognition system to infer land use from fine spatial resolution land cover data. In: Computers, Environment and Urban Systems, Vol. 21, 1997, S. 209-225.

BAUER, T. AND K. STEINNOCHER (2000). Objektbasierte Auswertung von hochauflösenden Fernerkundungsdaten in urbanen Räumen. In: STROBL, J. et al. (Hrsg.): Angewandte Geographische Informationsverarbeitung XII, Beiträge zum AGIT-Symposium Salzburg 2000, Karlsruhe, Herbert Wichmann Verlag, S. 30–38.

BENZ, U., HOFMANN, P., WILHAUCK, G., LINGENFELDER, I. AND 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, 2004, S. 239-258.

BLASCHKE, T., LANG, S., LORUP, E., STROBL, J. AND P. ZEIL (2000). Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental

applications. In: Umweltinformation für Planung, Politik und Öffentlichkeit (edited by A. Cremers & K. Greve), Marburg, Metropolis Verlag, Vol. 2, 2000. S. 555-570.

BLASCHKE, T. AND J. STROBL (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. In: *GeoBIT/GIS* 6, 2001, S. 12-17.

BMU (1992). Konferenz der Vereinten Nationen für Umwelt und Entwicklung (Juni 1992 in Rio de Janeiro). In: *Umweltpolitik. Dokumente zur o.a. Konferenz: AGENDA 21* (Hrsg.): Bundesministerium für Umwelt, Naturschutz und Reaktorsicherheit, Bonn, 1992.

BRAUN, M. AND M. HEROLD (2003). Mapping imperviousness using NDVI and linear spectral unmixing of ASTER data in the Cologne-Bonn region (Germany). In: *Proceedings of SPIE 10th International Symposium on Remote Sensing*, 8-12 September 2003, Barcelona, Spain, CD-ROM.

C

CABLK, M. E. AND T. B. MINOR (2003). Detecting and discriminating impervious cover with high-resolution IKONOS data using principal component analysis and morphological operators. *International Journal of Remote Sensing*, Vol. 24, No. 23, S. 4627–4645.

CETIN, H. (2004). Comparison of Spaceborne and Airborne Hyperspectral Imaging Systems for Environmental Mapping. In: *Proceedings of ISPRS 2004*, 12 – 23 July, 2004, Istanbul, Turkey, CD-ROM.

CORR, D. G., BENZ, U., LINGENFELDER, I., WALKER, A. AND A. RODRIGUEZ (2003). Classification of urban SAR imagery using object oriented techniques. In: *Proceedings of IGARSS 2003 IEEE*, July 2003, Toulouse, CD-ROM.

D

DECH, S.W. (1997). Anwendung der Satellitenfernerkundung. Von der geowissenschaftlichen Forschung zum operationellen Einsatz. DLR-Forschungsbericht 97(52), Köln, Habilitationsschrift zur Erlangung der Venia Legendi für Geographie an der Geowissenschaftlichen Fakultät der Universität Würzburg, 319 S.

DECH, S.W., GÜLS, I. AND G. STRUNZ (1997). Kartierung der thermischen Belastungsgebiete in Rheinland-Pfalz mit NOAA-AVHRR-Fernerkundungsdaten. Projektabschlussbericht im Auftrag des Ministeriums für Umwelt und Forsten, Rheinland-Pfalz, 12 S. und Anlagen, DLR-interner Abschlussbericht.

DECH, S.W. AND G. SCHREIER (2004). Earth Observation in Europe – Status Quo and Future Prospects. In: *Proceedings of 12th Australasian Remote Sensing and Photogrammetry Conference*, Keynote Presentation, Freemantle, Australia, Spatial Sciences Institute, ISBN 0-9581366-1-0.

DECH, S.W. (2005). The Earth Surface. In: Feuerbacher, B. and H. Stoewer (Eds.): *Utilization of Space*, Springer-Verlag, Hamburg, S. 51-90.

DE JONG, S.M., BAGRE, A., VAN TEEFFELEN P.B.M. AND W.P.A. VAN DEURSEN (2000). Monitoring Trends in Urban Growth and Surveying City Quarters in Ouagadougou, Burkina Faso Using SPOT-XS. *Geocarto International*, Vol. 15, No. 2, 2000, S. 23-28.

DE KOK, R., WEVER, T. AND R. FOCKELMANN (2003). Analysis of urban structure and development applying procedures for automatic mapping of large area data. In: Carstens, J. (Ed.): Remote Sensing of Urban Areas, 2003, S. 41-46.

DOBSON, J.E., BRIGHT, E.A., COLEMAN, P.R., DURFEE, R.C. AND B.A. WORLEY (2000). Land-Scan: A global population database for estimating populations at risk. In: Photogrammetric Engineering & Remote Sensing, 66, 2000, S. 849–857.

DONG Y., FORSTER B. AND C. TICEHURST (1997). Radar Backscatter Analysis for Urban Environments. In: Int. Journal of Remote Sensing, 18(6), 1997, S. 1351-1364.

DONNAY, J.-P. (1999). Use of remote sensing information in planning. In: Stillwell, J., Geertman, S. and S. Openshaw (Eds.): Geographical Information and Planning, Berlin, Springer-Verlag, 1999, S. 242-260.

E

EHLERS, M. AND S. KLONUS (2004). Erhalt der spektralen Charakteristika bei der Bildfusion durch FFT basierte Filterung. Photogrammetrie-Fernerkundung-Geoinformation (PFG) 6/2004, S. 495-506.

F

FATONE, L., MAPONI, P. AND F. ZIRILLI (2001). Fusion of SAR/optical images to detect urban areas. In: Proceedings of IEEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, Rome, 2001, S. 217-221.

FERRETTI, A., PRATI, C. AND F. ROCCA (2001). Permanent Scatterers in SAR Interferometry. IEEE TGARS, Vol. 39, No. 1, 2001, S. 8-20.

FORSTER, B.C. AND C. TICEHURST (1994). Urban Morphology Measures from Optical and RADAR Remotely Sensed Data – Some Preliminary Results. In: Proceedings of ISPRS Commission VII Symp., Sept. 26-30, Rio de Janeiro, Brazil, Vol. 30, Part 7b, S. 291-296.

FRANCESCHETTI, G., IODICE, A. AND D. RICCIO (2002). A canonical problem in electromagnetic backscattering from buildings. IEEE Trans. Geosc. Remote Sensing, Vol. 40, 2002, S. 1787-1801.

FROST, V.S., STILES, J.A., SHANMUGAN, K.S. AND J.C. HOLTZMAN (1982). A Model for Radar Images and Its Application to Adaptive Digital Filtering for Multiplicative Noise, PAMI(4), No. 2, March 1982, S. 157-166.

G

GAMBA, P., HOUSHMAND, B. AND M. SACCANI (2000). Detection and extraction of buildings from interferometric SAR data. IEEE Transactions on Geoscience and Remote Sensing 38(1), 2000, S. 611–618.

GOUINAUD, C., TUPIN, F. AND H. MAITRE (1996). Potential and use of radar images for characterization and detection of urban areas. In: Proceedings of IGARSS 1996, Lincoln, Nebraska, Vol. 1, S. 474-476.

H

HAGG, W. AND M. STIES (1996). Bundesweite Landnutzungskartierung mit ERS-1 SAR-Bilddaten, Abschlußbericht, Universität Karlsruhe.

HEIDEN, U., SEGL, K., ROESSNER, S. AND H. KAUFMANN (2003). Ecological evaluation of urban biotope types using airborne hyperspectral HyMap data. In: Proceedings of 2nd GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, Berlin, S. 18-22.

HEIKKONEN, J., KANELLOPOULOS, I., VARFIS, A., STEEL, A. AND K. FULLERTON (1997). Urban land use mapping with multi-spectral and SAR satellite data using neural networks. In: Proceedings of IGARSS 1997, Singapore, August 1997, Vol. 4, S. 1660-1662.

HENDERSON, F.M. AND Z.G. XIA (1998). Radar Applications in Urban Analysis, Settlement Detection and Population Analysis. In: Henderson, F.M. and A.J. Lewis (Eds.): Principles and Applications of Imaging Radar, Chapter 15. New York, S. 733-768.

HOFFMANN, J., ROTH, A. AND S. VOIGT (2004). Interferometric displacement and damage assessment for the 2003 Bam earthquake. In: Proceedings of ENVISAT Symposium 2004, Salzburg, Austria, September 6-10, CD-ROM.

HOFMANN, P. (2001). Detecting urban features from IKONOS data using an object-oriented approach. In: Proceedings of First Annual Conference of the Remote Sensing & Photogrammetry Society 12-14 September 2001, S. 28-33.

HOUSHMAND, B. AND P. GAMBA (1999). Three-dimensional road network by fusion of polarimetric and interferometric SAR data. In: Proceedings of IGARSS 1999, 28. June - 2. July 1999, Hamburg, Germany, Vol. 1, S. 302-304, 1999.

I

ICHITSUBO, D., OSAWA, Y., HAMAZAKI, T. AND A. MATSUMOTO (2003). Development Status for the Advanced Land Observing Satellite. International Archives of Photogrammetry, Remote Sensing and Spatial Information Science, Vol. XXXIV, Part. 7/W14, 2003, S. 632-638.

J

JENSEN, J.R. (2000). Remote sensing of the environment – an earth resource perspective. Prentice Hall, New Jersey.

JENSEN, J. R. AND D.C. COWEN (1999). Remote sensing of urban/suburban infrastructure and socio-economic attributes. In: Photogrammetric Engineering and Remote Sensing, 65, 5, 1999, S. 611-622.

JOHANSSON, K. (1994). Segment-based land use classification from SPOT satellite data. In: Photogrammetric Engineering & Remote Sensing, Vol. 60, No. 1, 1994, S. 47-53.

K

KEIL, M., MOHAUPT-JAHR, B., KIEFL, R. AND G. STRUNZ (2003). Update of the CORINE Land Cover Data Base in Germany. In: C. Jürgens (Ed.): Proceedings of ISPRS WG VII/4 Symposium on Remote Sensing of Urban Areas, Regensburg, 27-29 June 2003, ISSN 1682-1777, S. 72-77.

KRUSE, F.A., BOARDMAN, J.W., LEFKO, A.B., YOUNG, J.M., KIEREIN-YOUNG, K.S., COCKS, T.D., JENSSEN, R. AND P.A. COCKS (2000). HyMap: An australian hyperspectral sensor solving global problems - results from USA HyMap data acquisitions. In: Proceedings of 10th Australasian Remote Sensing and Photogrammetry Conference in Adelaide, Australia, CD-ROM.

KUAN, D. T., SAWCHUK, A. A., STRAND, T. C. AND P. CHAVEL (1987). Adaptive restoration of images with speckle. IEEE Transactions on Acoustics, Speech, and Signal Processing, 35, 1987, S. 373–383.

L

LAVALLE, C., EHRLICH, D. AND A. ANNONI (1998). Sustainable urban development: the MURBANDY project of the Centre for Earth Observation (CEO). In: Proceedings of Geoscience and Remote Sensing Symposium, IGARSS 1998, 6-10 July, Volume 5, S. 2571– 2573.

LEE, J.S. (1981). Speckle Analysis and Smoothing of Synthetic Aperture Radar Images. In: CGIP(17), No. 1, September 1981, S. 24-32.

LEE, J.S. (1983). A Simple Speckle Smoothing Algorithm for Synthetic Aperture Radar Images. In: SMC(13), 1983, S. 85-89.

LEE, J.S., GRUNES, M.R. AND G. DE GRANDI (1999). Polarimetric SAR Speckle Filtering and Its Implication for Classification. In: GeoRS(37), No. 5, 1999, S. 2363.

LEE, J.S., CLOUDE, S.R., PAPATHANASSIOU, K.P., GRUNES, M.R. AND I.H. WOODHOUSE (2003). Speckle filtering and coherence estimation of polarimetric SAR interferometry data for forest applications. In: GeoRS(41), No. 10, 2003, S. 2254-2263.

LO, C.P. (2001). Modeling the population of China using DMSP operational Linescan system nighttime data. In: Photogrammetric Engineering & Remote Sensing, No. 67, 2001, S. 1037–1047.

LOMBARDO, P., MACRÝ, T., PELLIZZERI, T.M. AND A. TOMASUOLO (2001). Classification of polarimetric SAR images of suburban areas using joint annealed segmentation and “H/A/a” decomposition. In: Proceedings of IEEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, 8– 9 November Rome, Italy, S. 117– 121.

LOPEZ-MARTINEZ, C. AND X. FABREGAS (2003). Polarimetric SAR Speckle Noise Model. In: GeoRS(41), No. 10, 2003, S. 2232-2242.

M

MASEK J., LINSDAY, F. AND S. GOWARD (2000). Dynamics of Urban Growth in the Washington DC metropolitan area, 1973-1996, from Landsat observations. In: International Journal of Remote Sensing, 21(18), 2000, S. 3473-3486.

MEINEL, G. AND A. HERNIG (2005). Survey on the basis of the ATKIS basic DLM – feasibilities and limits. In: Schrenck, Manfred (Ed.): Proceedings of Corp 2005 & Geomultimedia05, CD-ROM.

MEINEL, G. AND R. LIPPOLD (1999). Zum Einsatz neuer Informationstechnologien in Raumplanung und Umweltschutz – Auswertung einer deutschlandweiten Befragung. In: Tagungsband Computergestützte Raumplanung CORP'99, Wien 2/99, S. 87-92

MEINEL, G. AND M. NEUBERT (2004). A comparison of segmentation programs for high resolution remote sensing data. In: Proceedings of ISRPS 2004 Annual Conference, Istanbul, Turkey. July 19 – 23, CD-ROM.

MEINEL, G. AND M. WINKLER (2004). Long term investigation of urban sprawl on the basis of remote sensing data - results of an international city comparison. In: Proceedings of 24th EARSeL-Symposium, 2004, Dubrovnik, CD-ROM.

MERCER, J.B. AND M. GILL (1998). Radar-derived DEMs for urban areas. In: IAPRS, Vol. 32, Part 4, 1998, S. 382-388.

MÖLLER, M.S. (2005). Remote sensing for the monitoring of urban growth patterns. In: Proceedings of URBAN 2005 & URS 2005, March 14 – 16, Tempe, USA, CD-ROM.

MÜLLER, A., RICHTER, R., HABERMEYER, M., MEHL, H., DECH, S., KAUFMANN, H., SEGL, K., HASCHBERGER, P. AND P. STROBL (2003). ARES: A new reflective / emissive Imaging Spectrometer for Terrestrial Applications. In: DLR-DFD (Hrsg.): 20. DFD-Nutzerseminar, 6.-8.10.2003, Neustrelitz, CD-ROM.

N

NETZBAND, M., REDMAN, C.L. AND W.L. STEFANOV (2005). Challenges for applied Remote Sensing Science in the urban environment. In: Proceedings of URBAN 2005 & URS 2005, March 14 – 16, Tempe, AZ, USA, CD-ROM.

P

PALER, K., CRENNELL, K.M., KITTLER, J.V., DOBBINS, B.N., BUTTON, B.L. AND C. WYKES (1987). Identification of Fringe Minima in Electronic Speckle Pattern Images. In: PRL (6), 1987, S. 33-44.

PALUBINSKAS, G., MEYER, F.J., RUNGE, H., REINARTZ, P., SCHEIBER, R. AND R. BAMLER (2005). Estimation of along-track velocity of road vehicles in SAR data. In: Proceedings of SPIE 2005, 19-22 Sept., Bruges, Belgium, S. 1– 9.

PELLIZERI, T. M. (2003). Classification of polarimetric SAR images of suburban areas using joint annealed segmentation and “H/A/á” polarimetric decomposition. In: ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 58, No. 1-2, 2003, S. 55-70.

R

RANCHIN, T., WALD, L. AND M. MANGOLINI (2001). Improving spatial resolution of remotely-sensed images by means of sensor fusion: a general solution using ARSIS methods. In: Donnay, J. P.,

Barnsley, M. J. and P. A. Longley (Eds.): Remote sensing and urban analysis. Taylor and Francis, London and New York, S. 21-37.

RIDD, M. K. (1995). Exploring a VIS (vegetation-impervioussurface-soil) model for urban ecosystem analysis through remote sensing: comparative anatomy for cities. In: International Journal of Remote Sensing, 16, 12, 1995, S. 2165-2185.

ROTH, A., HOFFMANN, J. AND T. ESCH (2005). TerraSAR-X: How can high resolution SAR data support the observation of urban areas? In: Proceedings of URBAN 2005 & URS 2005, March 14 – 16, Tempe, AZ, USA, CD-ROM.

S

SCHREIER, G. AND S. DECH (2005). High resolution earth observation satellites and services in the next decade – a European perspective. In: Acta Astronautica 57, 2005.

SEGL, K., ROESSNER, S., HEIDEN, U. KAUFMANN, H. (2003). Fusion of spectral and shape features for identification of urban surface cover types using reflective and thermal hyperspectral data. In: ISPRS Journal of Photogrammetry & Remote Sensing, Vol. 58, S. 99– 112.

SEILER, U., NEUBERT, M. AND G. MEINEL (2004). Automatisierte Erfassung von Biotop- und Nutzungstypen am Beispiel der segmentbasierten Klassifikation von IKONOS-Satellitenbilddaten. In: Naturschutz und Landschaftsplanung (NuL) 4/2004, S. 101-106.

SHINOZUKA, M., GHANEM, R., HOUSHMAND, B. AND B. MANSURI (2000). Damage Detection in Urban Areas by SAR Imagery. In: Journal of Engineering Mechanics, Vol. 126, No. 7, 2000, S. 769-777.

SMALL, C. (2003). High spatial resolution spectral mixture analysis of urban reflectance. In: Remote Sensing of Environment, 88(1-2), 2003, S. 170–186.

SMITS, P.C. AND A. ANNONI (1999). Updating land-cover maps by using texture information from very high-resolution space-borne imagery. In: IEEE Trans. on Geoscience and Remote Sensing, Vol. 37, No. 3, May 1999, S. 1244-1254.

SOERGEL, U., SCHULZ, K., THOENNESSEN, U. AND U. STILLA (2003). Event-driven SAR Data Acquisition in Urban Areas Using GIS. In: GeoBIT/GIS Journal for spatial information and decision making (12), 2003, S. 32-37.

SOLBERG, A. H. S., JAIN, A. K. AND T. TAXT (1994). Multisource classification of remotely sensed data: Fusion of Landsat TM and SAR images. In: IEEE Transactions on Geoscience and Remote Sensing, 4, 1994, S. 768-778.

STEINNOCHER, K. (1997). Texturanalyse zur Detektion von Siedlungsgebieten in hochauflösenden panchromatischen Satellitenbilddaten. In Dollinger, F. und Strobl, J. (Hrsg.): Angewandte Geographische Informationsverarbeitung IX, Salzburger Geographische Materialien, Bd. 26, S. 143-152.

STEINNOCHER, K., PETRINI-MONTEFERRI, F., TÖTZER, T. AND J. WEICHSELBAUM (2005). Räumliche Disaggregation von sozio-ökonomischen Daten. In: Strobl, J., Blaschke, T. und Griesebner, H. (Hrsg.): Angewandte Geoinformatik 2005. Beiträge zum 17. AGIT-Symposium Salzburg. Heidelberg 2005, CD-ROM.

STIES, M. AND W. HAGG (1999). Verarbeitung und Klassifizierung von SAR-Satellitenbilddaten. In: Albertz, J. and Dech, S. (Eds.): Proceedings der 18. Wissenschaftlich-Technischen Jahrestagung der DGPF, München, 1998, S. 409-418.

STILLA U, SOERGEL U AND U. THOENNESSEN (2003). Potential and Limits of InSAR Data for Building Reconstruction in Built-up Areas. In: ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 58, No. 1-2, 2003, S. 113-123.

STOW, D.A. AND D.M. CHEN (2002). Sensitivity of multitemporal NOAA AVHRR data of an urbanizing region to land-use/land-cover changes and misregistration. In: Remote Sensing of Environment, Vol. 80, 2002, S. 297-307.

STROZZI, T. AND U. WEGMÜLLER (1998). Delimitation of urban areas with SAR interferometry. In: Proceedings of IGARSS 1998, 6-10 July, Seattle, S. 1632-1634.

T

TAKEUCHI, S., SUGA, Y., YONEZAWA, C. AND C.H. CHEN (2000). Detection of urban disaster using InSAR - a case study for the 1999 great Taiwan earthquake. In: Proceedings of IGARSS 2000, July 24-28, Honolulu, USA, CD-ROM.

TANAKA, S. AND T. SUGIMURA (2001). A new frontier of remote sensing from IKONOS images,. In: International Journal of Remote Sensing, Vol. 22, 1, 2001, S. 1-5.

TUPIN, F., HOUSHMAND, B. AND M. DATCU (2002). Road detection in dense urban areas using SAR imagery and the usefulness of multiple views. In: IEEE Transactions on Geoscience and Remote Sensing, Vol. 44, No. 11, 2002, S. 2405-2414.

TUPIN, F. AND M. ROUX (2003). Detection of building outlines based on the fusion of SAR and optical features. In: ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 58, 2003, S. 71-82.

U

ULABY, F., PIERCE, L.E., DOBSON, M.C., CHACON, S. AND K. SARABANDI (1994). Land cover classification by SAR, Proc. of the 1994 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'94), Vol. 3, 1994, S. 1602-1604.

W

WALESSA, M. AND M. DATCU (2000). Model-Based Despeckling and Information Extraction from SAR Images. In: GeoRS(38), No. 5, September 2000, S. 2258-2269.

WEEKS, J.R., GADALLA, M.S., RASHED, T., STANFORTH, J. AND A.G. HILL(2000). Spatial variability in fertility in Menoufia, Egypt, assessed through the application of remote sensing and GIS technologies. In: Environment and Planning, Vol. 32, 2000, S. 695-714.

WESSEL, B., WIEDEMANN, C. AND H. EBNER (2003). The role of context for road extraction from SAR imagery. In: Proceedings of IGARSS 2003, 21.-25. July, Toulouse, France, CD-ROM.

WEYDHAL, D.J., BECQUEY, X. AND T. TOLLEFSEN (1995). Combining ERS1 SAR with optical satellite data over urban areas. In: Proceedings of IGARSS 1995, Florence, Italy, Vol. 3, S. 2461-2463.

WEYDAHL, D.J., BRETAR, F. AND P. BJERKE (2005). Comparison of RADARSAT-1 and IKONOS satellite images for urban features detection. In: Information Fusion 6, 2005, S. 243-249.

WILSON, J. S., CLAY, M., MARTIN., E., STUCKEY, D. AND K. VEDDER-RISCH (2003). Evaluating environmental influences of zoning in urban ecosystems with remote sensing. In: Remote Sensing of Environment 86, 2003, S. 303-321.

WORAWATTANAMATEEKUL, J., HOFFMANN J., ADAM N. AND B. KAMPES (2003). Urban deformation monitoring in Bangkok metropolitan (Thailand) using differential interferometry and the permanent scatterer technique. In: Proceedings of FRINGE 2003 workshop, Frascati, Italy, CD-ROM.

X

XIA, Z.-G. AND F.M. HENDERSON (1997). Understanding the relationship between radar response patterns and the bio- and geophysical parameters of urban areas. In: IEEE Transactions on Geoscience and Remote Sensing, Vol. 35, No. 1, 1997, S. 93-101.

XIAO, R., LESHER, C. AND B. WILSON (1998). Building detection and localization using a fusion of interferometric synthetic aperture radar and multispectral images. In: Proceedings of DARPA Image Understanding Workshop 1998, Monterey, USA, S. 583-588.

XIE, Z.-Y. AND M BRADY (1996). Texture segmentation using local energy in wavelet scale space. In: Proceedings of 4th European Conference on Computer Vision, April 15 – 18, Cambridge, UK, Vol. 1, S. 304-313.

Z

ZHANG, Y. (1999). A New Method for Merging Multispectral and Mutliresolution Satellite Data and Its Spectral and Spatial Effects. In: International Journal of Remote Sensing, Vol. 20, No. 10, 1999, S. 2003-2014.

ZHANG, Y. (2001). Detection of urban housing development by fusing multisensor satellite data and performing spatial feature post-classification. In: International Journal of Remote Sensing, Vol. 22, No. 17, 2001, S. 3339-3355.

ZHANG, Q. AND J. WANG (2001). Inferring urban land use from 1 meter resolution IKONOS imagery. In: Proceedings of 23rd Canadian Symposium on Remote Sensing, 21-25 Aug. 2001, Sainte-Foy, Ottawa, Canada, S. 173-181.

ZHANG, Q. AND J. WANG (2003). A rule-based urban land use inferring method for fine-resolution multispectral imagery. In: Canadian Journal Remote Sensing, Vol. 29, No. 1, 2003, S. 1-13.

Internetverzeichnis

D

DIGITALGLOBE (2006). QuickBird. Abrufbar unter: <http://digitalglobe.com>. *Stand: 20.05.2006.*

E

ESA (2006a). The ERS Missions. Abrufbar unter: <http://earth.esa.int/ers>. *Stand: 20.04.2006.*

ESA (2006b). Envisat Instruments. Abrufbar unter: <http://envisat.esa.int/instruments/asar>. *Stand: 20.04.2006.*

G

GMES (2006). Global Monitoring for Environment and Security. Abrufbar unter: <http://www.gmes.info>. *Stand: 20.05.2006.*

J

JAXA (2006). Japanese Earth Resources Satellite-1. Abrufbar unter: <http://.eorc.jaxa.jp/JERS-1>. *Stand 20.04.2006.*

JPL(2006). Advanced Spaceborne Thermal Emission and Reflection Radiometer. Abrufbar unter: <http://asterweb.jpl.nasa.gov>. *Stand: 20.04.2006.*

M

MDA (2006). Satellite Imagery Products. Abrufbar unter: <http://gs.mdacorporation.com>. *Stand: 20.04.2006.*

N

NASA (2006). MODIS Web. Abrufbar unter: <http://.modis.gsfc.nasa.gov>. *Stand: 20.04.06.*

NOAA (2006). NOAA Satellite and Information Service. Abrufbar unter: <http://noaasis.noaa.gov/NOAASIS/~ml/avhrr.htm>. *Stand: 20.04.2006.*

NRSA (2006). Data Reservoir for Planet Earth. Abrufbar unter: <http://.nrso.gov.in>. *Stand: 20.04.2006.*

S

SPACE IMAGING (2006). IKONOS. Abrufbar unter: <http://.spaceimaging.com/products/ikonos/index.htm>. *Stand: 20.05.2006.*

SPOT IMAGE (2006). SPOT Products and Services. Abrufbar unter: http://www.spotimage.fr/html/_167_171_.php. *Stand: 20.05.2006.*

U

UNPP (2006). World Population Prospects. The 2004 Revision, New York 2006. Abrufbar unter: <http://esa.un.org/unpp>. *Stand: 01.03.2006.*

USGS (2006). Landsat Web Site. Abrufbar unter: <http://landsat.usgs.gov>. *Stand: 20.04.2006.*

Anhang B

SelectiveMean-Filter

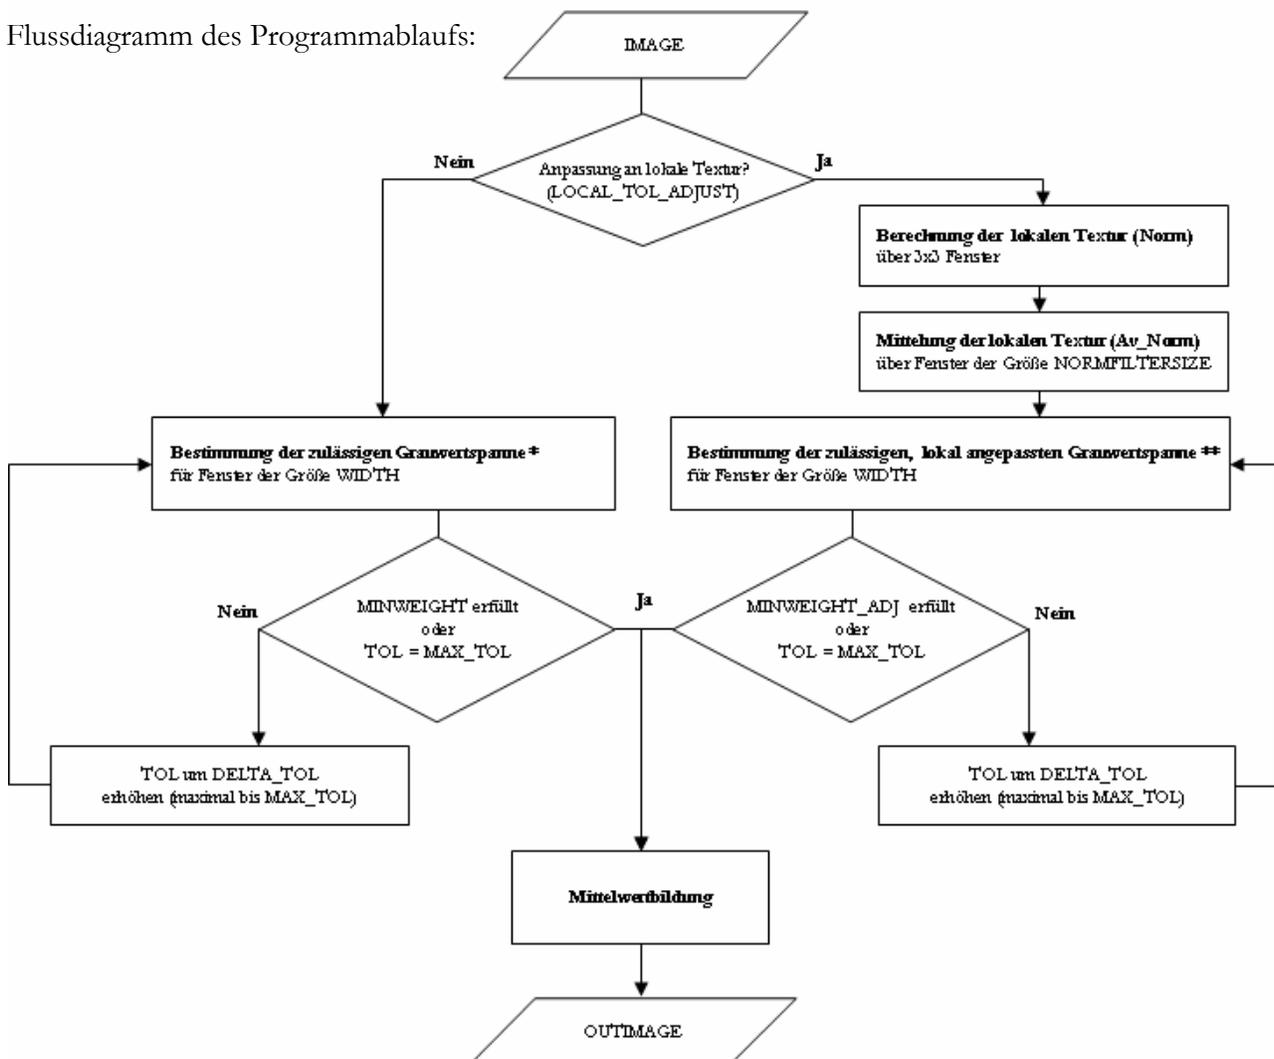
Beschreibung des SelectiveMean-Filteralgorithmus

Inputvariablen:

IMAGE	: Inputbild (1-Kanal Bild)
OUTIMAGE	: Outputbild
WIDTH	: Größe der Filterbox (bzw. des Filterkreises; siehe CIRCULAR)
TOL	: Toleranz-Faktor ; definiert, welche Grauwerte in die Mittelung einbezogen werden (Berechnung der Wertespanne: siehe KAP. 4.1.1.2)
MINWEIGHT	: Mindestanzahl an Pixeln, die innerhalb der zulässigen Grauwertespanne liegen
CIRCULAR	: Anstelle einer rechteckigen Filterbox wird kreisförmige Region mit Durchmesser WIDTH verwendet
TOL_OFFSET	: Wert [DN], um den zulässige Grauwertespanne erweitert werden kann; dient zur akkurateren Filterung in dunklen Bildbereichen
DELTA_TOL	: Betrag [DN], um den zulässige Grauwertespanne erweitert wird, wenn weniger als MINWEIGHT Pixel gefunden werden
MAX_TOL	: Maximalwert [DN], um den zulässige Grauwertespanne mittels DELTA_TOL erweitert wird, wenn weniger als MINWEIGHT Pixel gefunden werden
NORMEXP	: Grundlage zur Berechnung der lokalen Textur (1 = Coeff. of Variation; 2 = Varianz)

- LOCAL_TOL_ADJUST** : Definiert die Anpassung der Filterung an lokale Textur
- NORMTHRESH** : Schwellwert für gemittelte Norm (Coeff. of Variation, Varianz), ab der TOLERANCE modifiziert wird
- NORMFILTERSIZE** : Größe des Fensters, über das die lokale Textur (Kanteninformation) gemittelt wird, um Maß für Kantendichte zu berechnen
- MAX_DELTA_TOL** : Maximalwert [DN], um den zulässige Grauwertespanne im Rahmen der texturabhängigen Anpassung modifiziert wird
- MIN_TEX** : Minimum-Schwellwert, ab dem lineare Anpassung der anzusetzenden Grauwertespanne an gemittelte lokale Textur (Norm) beginnt
- MAX_TEX** : Maximum-Schwellwert, ab dem lineare Anpassung der anzusetzenden Grauwertespanne an gemittelte lokale Textur (Norm) endet
- MIN_WEIGHT_ADJ** : wenn LOCAL_TOL_ADJUST aktiv, dann Mindestanzahl an Pixeln, die > NORMTHRESH und innerhalb der zulässigen Grauwertespanne liegen.

Flussdiagramm des Programmablaufs:



$$* = x_0 - \text{Grauwertspanne} \leq \text{zulässig} \leq x_0 + \text{Grauwertspanne}$$

$$\text{Grauwertspanne} = ((x_0 \cdot TOL) + TOL_OFFSET)$$

$$** = x_0 - \text{Grauwertspanne} \leq \text{zulässig} \leq x_0 + \text{Grauwertspanne}$$

$$\text{Grauwertspanne} = ((x_0 \cdot TOL) + TOL_OFFSET) \quad \text{für } Av_Norm \leq MIN_TEX$$

$$\text{Grauwertspanne} = TOL - \frac{(AV_Norm - MIN_TEX)}{(MAX_TEX - MIN_TEX)} \cdot ((MAX_DELTA_TOL + TOL) - TOL)$$

für $MIN_TEX \leq Av_NORM \leq MAX_TEX$

$$\text{Grauwertspanne} = TOL - ((MAX_DELTA_TOL + TOL) + TOL) \quad \text{für } Av_NORM \geq MAX_TEX$$

Filterung von Beispieldaten:

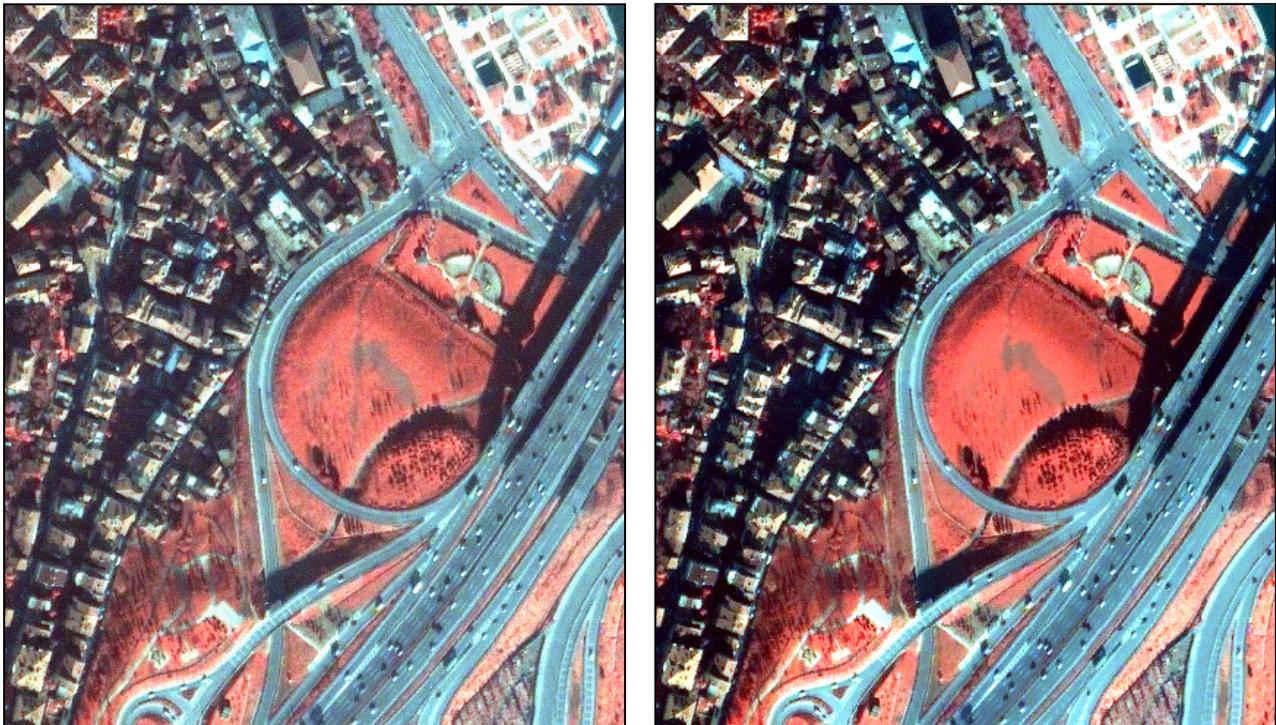


Abb. B-1: Filterung eines IKONOS-Bildes (pansharpened; Bodenauflösung: 1m; R = NIR, G = Grün, B = Blau)



Abb. B-2: Filterung einer SPOT-5 PAN Aufnahme (Bodenauflösung: 2,5 m)

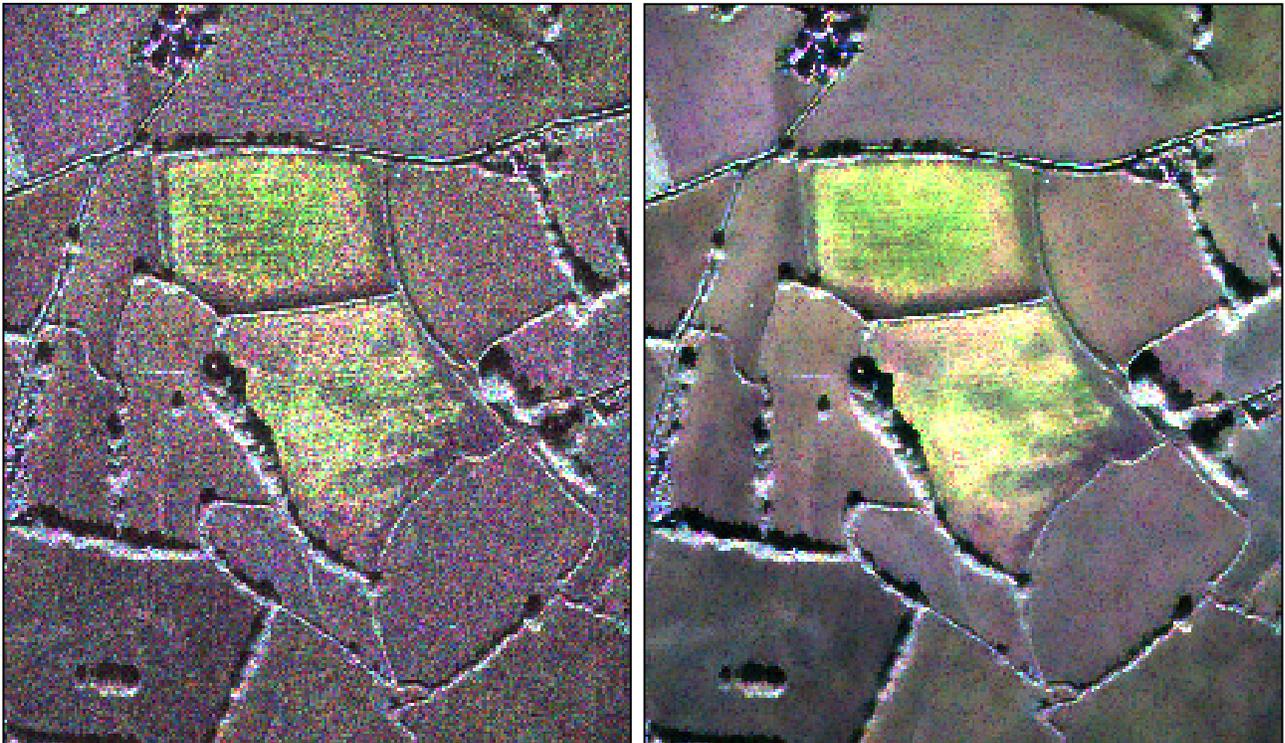


Abb. B-3: Glättung einer MicroSAR-Aufnahme (Bodenauflösung: 2m; R = HH, G = VV, B = (VH) + (HV))

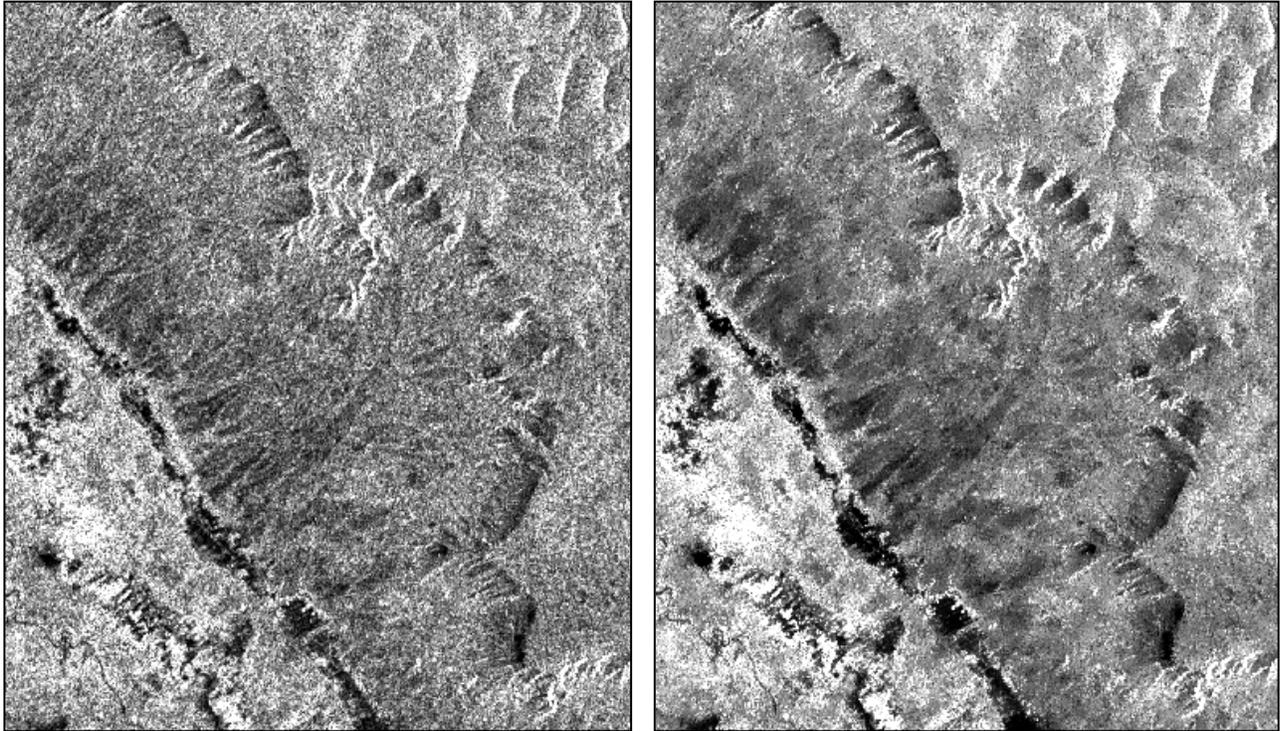


Abb. B-4: Filterung von RADARSAT-Daten (Bodenauflösung: 5 m; HH-Polarisation)

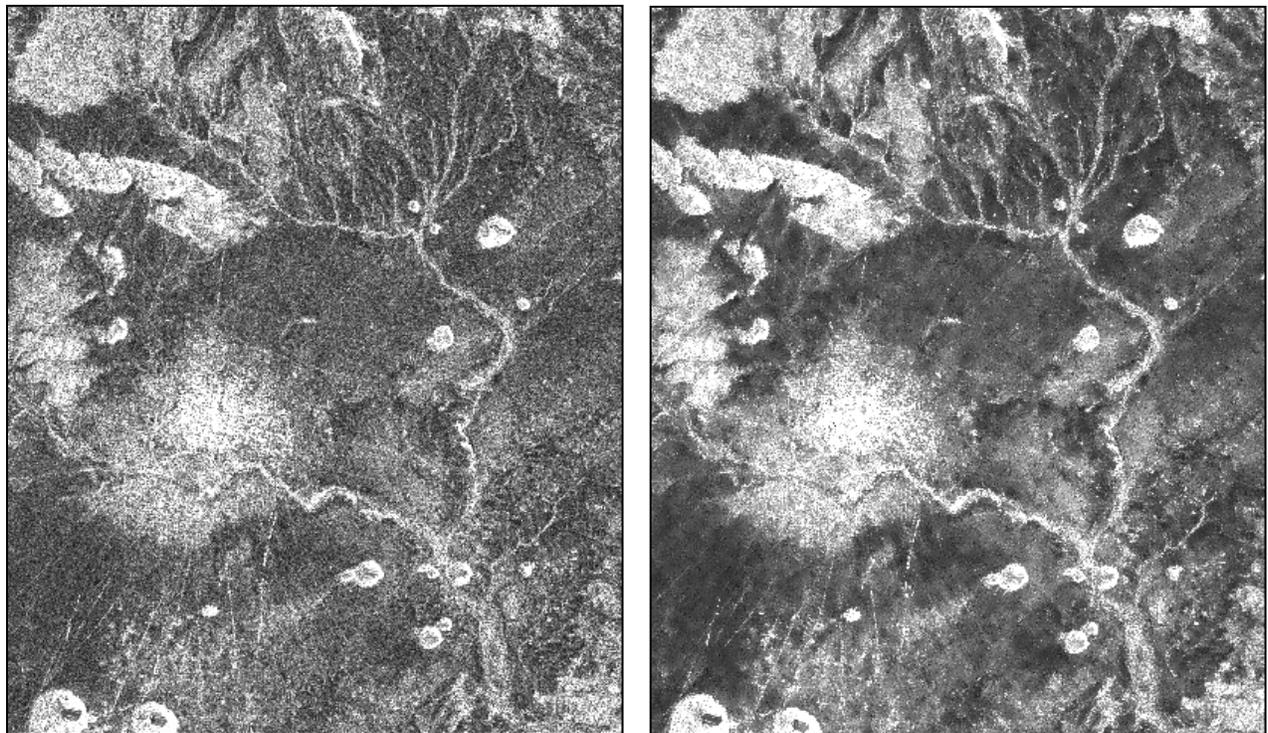
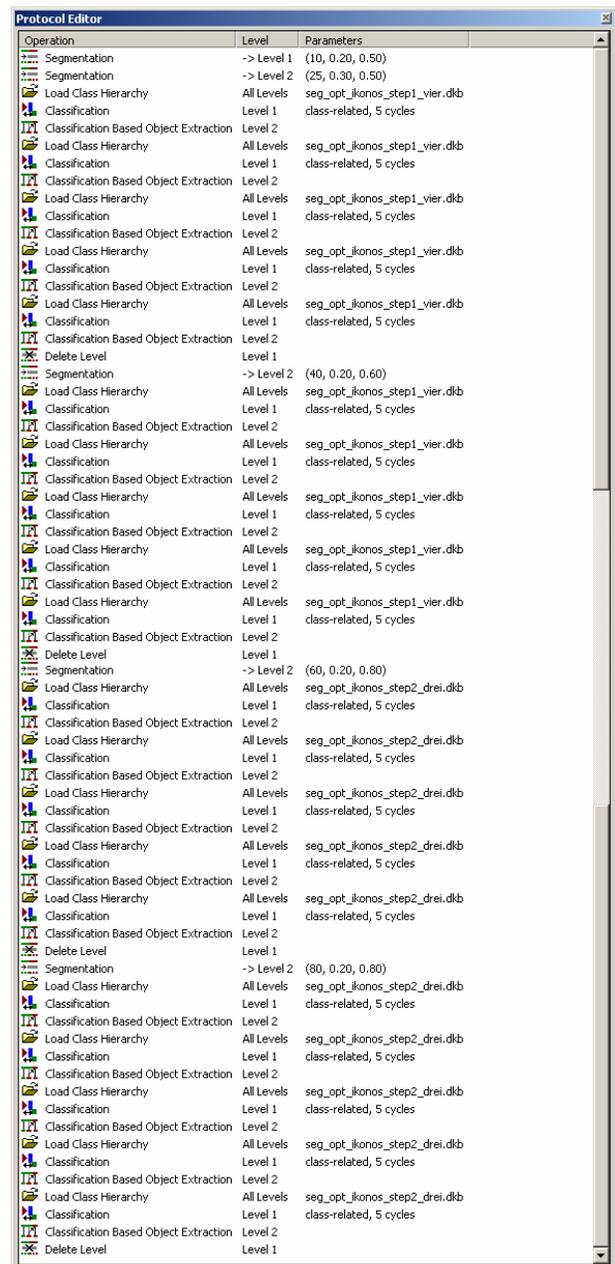


Abb. B-5: Filterung eines ENVISAT-ASAR-Datensatzes (Bodenauflösung: 25 m; HH-Polarisation)

Anhang C

Segmentoptimierung



The screenshot shows a window titled "Protocol Editor" containing a list of operations. Each row represents an operation with its level and parameters. The operations are organized into groups, with some operations being repeated. The parameters for the "Segmentation" operations are (10, 0.20, 0.50), (25, 0.30, 0.50), (40, 0.20, 0.60), (60, 0.20, 0.80), and (80, 0.20, 0.80). The "Load Class Hierarchy" operations are for files named "seg_opt_ikonos_step1_vier.dkb" and "seg_opt_ikonos_step2_drei.dkb". The "Classification" operations are for "class-related, 5 cycles". The "Classification Based Object Extraction" operations are for "Level 2". The "Delete Level" operations are for "Level 1".

Operation	Level	Parameters
Segmentation	-> Level 1	(10, 0.20, 0.50)
Segmentation	-> Level 2	(25, 0.30, 0.50)
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Delete Level	Level 1	
Segmentation	-> Level 2	(40, 0.20, 0.60)
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step1_vier.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Delete Level	Level 1	
Segmentation	-> Level 2	(60, 0.20, 0.80)
Load Class Hierarchy	All Levels	seg_opt_ikonos_step2_drei.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step2_drei.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step2_drei.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Delete Level	Level 1	
Segmentation	-> Level 2	(80, 0.20, 0.80)
Load Class Hierarchy	All Levels	seg_opt_ikonos_step2_drei.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step2_drei.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Load Class Hierarchy	All Levels	seg_opt_ikonos_step2_drei.dkb
Classification	Level 1	class-related, 5 cycles
Classification Based Object Extraction	Level 2	
Delete Level	Level 1	

Abb. C-1: Beispielprotokoll zur Segmentoptimierung auf Basis einer IKONOS-Aufnahme

Anhang D

Accuracy Assessment (regionale Analysen)

Tab. D-1: Fehlermatrix der regionalen Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten (Flugstreifen 1)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	3	0	0	0		3
	Siedlung	0	87	1	5		93
	Baumbestand	0	5	31	7		43
	Offenland	0	4	1	106		111
							250
Total		3	96	33	118		250

Tab. D-2: Hersteller- und Nutzergüte der regionalen Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten (Flugstreifen 1)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	3	3	3	100,00%	100,00%
Siedlung	96	93	87	90,63%	93,55%
Baumbestand	33	43	31	93,94%	72,09%
Offenland	118	111	106	89,83%	95,50%
			227	227/250 = 90,80 %	

Tab. D-3: Fehlermatrix der regionalen Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten (Flugstreifen 2)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	19	0	0	0		19
	Siedlung	1	156	1	2		160
	Baumbestand	0	7	18	3		28
	Offenland	5	0	4	34		43
							250
Total		25	163	23	39		250

Tab. D-4: Hersteller- und Nutzergüte der regionalen Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten (Flugstreifen 2)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	25	19	19	76,00%	100,00%
Siedlung	163	160	156	95,71%	97,50%
Baumbestand	23	28	18	78,26%	64,29%
Offenland	39	43	34	87,18%	79,07%
			227	227/250 = 90,80 %	

Tab. D-5: Fehlermatrix der regionalen Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten (Flugstreifen 3)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	18	1	0	0		19
	Siedlung	5	167	1	1		174
	Baumbestand	0	5	15	0		20
	Offenland	11	1	2	23		37
							250
Total		34	174	18	24		250

Tab. D-6: Hersteller- und Nutzergüte der regionalen Landnutzungskartierung basierend auf HH-polarisierten X-Band Daten (Flugstreifen 3)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	34	19	18	52,94%	94,74%
Siedlung	174	174	167	95,98%	95,98%
Baumbestand	18	20	15	83,33%	75,00%
Offenland	24	37	23	95,83%	62,16%
			223	223/250 = 89,20 %	

Tab. D-7: Fehlermatrix der regionalen Landnutzungskartierung basierend auf HH-polarisierten C-Band Daten (Flugstreifen 1)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	3	0	0	0		3
	Siedlung	0	85	6	3		94
	Baumbestand	0	6	25	5		36
	Offenland	0	5	2	110		117
							250
Total		3	96	33	118		250

Tab. D-8: Hersteller- und Nutzergüte der regionalen Landnutzungskartierung basierend auf HH-polarisierten C-Band Daten (Flugstreifen 1)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	3	3	3	100,00%	100,00%
Siedlung	96	94	85	88,54%	90,43%
Baumbestand	33	36	25	75,76%	69,44%
Offenland	118	117	110	93,22%	94,02%
			223	223/250 = 89,20 %	

Tab. D-9: Fehlermatrix der regionalen Landnutzungskartierung basierend auf HH-polarisierten L-Band Daten (Flugstreifen 1)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	3	0	0	0		3
	Siedlung	0	84	2	5		91
	Baumbestand	0	9	26	8		43
	Offenland	0	3	5	105		113
							250
Total		3	96	33	118		250

Tab. D-10: Hersteller- und Nutzergüte der regionalen Landnutzungskartierung basierend auf HH-polarisierten L-Band Daten (Flugstreifen 1)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	3	3	3	100,00%	100,00%
Siedlung	96	91	84	87,50%	92,31%
Baumbestand	33	43	26	78,79%	60,47%
Offenland	118	113	105	88,98%	92,92%
			218	218/250 = 87,20 %	

Tab. D-11: Fehlermatrix der regionalen Landnutzungskartierung basierend auf dual-polarisierten C-Band Daten (Flugstreifen 1)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	3	0	0	0		3
	Siedlung	0	85	5	2		92
	Baumbestand	0	6	26	3		35
	Offenland	0	5	2	113		120
							250
Total		3	96	33	118		250

Tab. D-12: Hersteller- und Nutzergüte der regionalen Landnutzungskartierung basierend auf dual-polarisierten C-Band Daten (Flugstreifen 1)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	3	3	3	100,00%	100,00%
Siedlung	96	92	85	88,54%	92,39%
Baumbestand	33	35	26	78,79%	74,29%
Offenland	118	120	113	95,76%	94,17%
			227	227/250 = 90,80 %	

Tab. D-13: Fehlermatrix der regionalen Landnutzungskartierung basierend auf kombinierter Auswertung von X- und L-Band Daten (Flugstreifen 1)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	3	0	0	0		3
	Siedlung	0	91	1	3		95
	Baumbestand	0	3	31	3		37
	Offenland	0	2	1	112		115
							250
	Total	3	96	33	118		250

Tab. D-14: Hersteller- und Nutzergüte der regionalen Landnutzungskartierung basierend auf kombinierter Auswertung von X- und L-Band Daten (Flugstreifen 1)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	3	3	3	100,00%	100,00%
Siedlung	96	95	91	94,79%	95,79%
Baumbestand	33	37	31	93,94%	83,78%
Offenland	118	115	112	94,92%	97,39%
			237	237/250 = 94,80 %	

Tab. D-15: Fehlermatrix der regionalen Landnutzungskartierung basierend auf kombinierter Auswertung von X-Band- und IRS-Daten (Flugstreifen 1)

		Referenz					Total
		Wasser	Siedlung	Baumbestand	Offenland		
Klassifikation	Wasser	3	0	0	0		3
	Siedlung	0	93	0	3		96
	Baumbestand	0	0	32	3		35
	Offenland	0	3	1	112		116
							250
Total		3	96	33	118		250

Tab. D-16: Hersteller- und Nutzgüte der regionalen Landnutzungskartierung basierend auf kombinierter Auswertung von X-Band- und IRS-Daten (Flugstreifen 1)

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Wasser	3	3	3	100,00%	100,00%
Siedlung	96	96	93	96,88%	96,88%
Baumbestand	33	35	32	96,97%	91,43%
Offenland	118	116	112	94,92%	96,55%
			240	240/250 = 96,00 %	

Anhang E

Accuracy Assessment (lokale Analysen)

Tab. E-1: Fehlermatrix der urbanen Landnutzungskartierung basierend auf kombinierter Auswertung von X-Band- und IRS-Daten

		Referenz				
		Gebäude	Unversiegelte Freifläche	Baumbestand	Versiegelte Freifläche	Total
Klassifikation	Gebäude	64	13	7	4	88
	Unversiegelte Freifläche	2	26	10	2	40
	Baumbestand	7	7	38	0	52
	Versiegelte Freifläche	16	2	6	16	40
						220
Total		89	48	61	22	220

Tab. E-2: Hersteller- und Nutzergüte der urbanen Landnutzungskartierung basierend auf kombinierter Auswertung von X-Band- und IRS-Daten

	Referenz	Klassifizierung	Anzahl korrekt	Hersteller	Nutzer
Gebäude	89	88	64	71,91%	72,73%
Unversiegelte Freifläche	48	40	26	54,17%	65,00%
Baumbestand	61	52	38	62,30%	73,08%
Versiegelte Freifläche	22	40	16	72,73%	40,00%
			144	144/220 = 65,45 %	

Eidesstattliche Erklärung

Hiermit erkläre ich, dass die von mir eingereichte Dissertation zum Thema „Automatisierte Analyse von Siedlungsflächen auf der Basis höchstauflösender Radardaten“ selbständig und nur unter Benutzung der in der Arbeit angegebenen Literatur und sonstigen Quellen angefertigt wurde. Indirekt übernommene Gedanken habe ich als solche kenntlich gemacht.

München, den 08.Mai 2006

Curriculum Vitae

PERSONALDATEN

Name	Esch
Vorname	Thomas
Geburtstag	07-08-1975
Geburtsort	Adenau
Nationalität	deutsch
Adresse	Bergstr. 97 82131 München-Stockdorf, Deutschland
E-mail	thomasesch75@hotmail.com, Thomas.Esch@dlr.de
Telefon	+49-89-74945984 / +49-160-96825401

AUSBILDUNG

1986-1995	Gymnasium: Geschwister-Scholl-Gymnasium, Daun Abschluss: Abitur
10/96-02/03	Universität Trier Studium der Angewandten Physischen Geographie Nebenfach Geologie Angewandte Geologie, Optimierung von Deponiebasis- und –oberflächen- abdichtungen, Schadstoffverlagerung und -festlegung im Untergrund Nebenfach Bodenkunde Bodenschutz, Hochwasserschutz, Bodenchemie, Bodenphysik, Bodenbiologie, Abfallwirtschaft Nebenfach Fernerkundung Digitale Bildverarbeitung, Fernerkundung und GIS, Hyperspektralfernerkun- dung, Desertification Mapping and Monitoring

- 09/00 – 07/01 **Auslandsstudium an der Universiteit Utrecht (Niederlande):** Faculty of Geosciences. Schwerpunkt: Geoinformation und GIS
- 02/02-01/03 **Diplomarbeit** am Deutschen Fernerkundungsdatenzentrum des Deutschen Zentrums für Luft- und Raumfahrt, Abteilung Umwelt und Geoinformation: *Eignung eines objektorientierten Klassifikationsverfahrens zur Gewinnung planungsrelevanter Informationen über urban geprägten Räumen*
- 02/03 **Abschluss des Diploms:** Mit Auszeichnung
- 02/03 – 05/06 **Dissertation** am Deutschen Fernerkundungsdatenzentrum des Deutschen Zentrums für Luft- und Raumfahrt, Abteilung Umwelt und Geoinformation: *Automatisierte Analyse von Siedlungsflächen auf der Basis höchstauflösender Radardaten*

PRAKTIKA UND STUDIENBEGLEITENDE TÄTIGKEITEN

- 11/98- 06/00 **Studentische Hilfskraft am Lehrstuhl für Bodenkunde der Universität Trier** (Prof. Dr. D. Schröder)
Unterstützung von Gelände- und Laborarbeiten zur Entwicklung verbesserter Konzepte zum Hochwasserschutz
- 09/99 – 10/99 **Praktikum am Soil Erosion Laboratory, Toronto University, Canada** (Prof. Dr. R.B. Bryan)
Durchführung von Beregnungsversuchen zur Erosionsforschung
- 02/00 – 04/00 **Praktikum bei der hortulus GmbH, Trier**
Datenaufbereitung und -auswertung sowie Erstellung thematischer Karten mit Hilfe von GIS
- 04/00 – 07/00 **Studienbezogene Nebenerwerbstätigkeit bei der hortulus GmbH, Trier**
GIS-gestützte Datenauswertung und Visualisierung
- 07/00 – 08/00 **Praktikum am Deutschen Fernerkundungsdatenzentrum, Oberpfaffenhofen**
Erstellung eines Satellitenbildmosaiks für das Gebiet Sibiriens

07/02 – 12/02	Studentische Hilfskraft am Lehrstuhl für Fernerkundung der Universität Trier, Sonderforschungsbereich 522, Umwelt und Region (Prof. Dr. J.Hill) Integration fernerkundlich erfasster, quantifizierter und modellierter Umweltindikatoren in ein Umweltinformationssystem
seit 02/03	Promotionsbegleitende Tätigkeiten am Deutschen Fernerkundungsdatenzentrum: - Betreuung von Diplomarbeiten und Praktikanten - Fachvorträge - Projektakquisition

AUSLANDSERFAHRUNG

Sommer 91/92	Sprachaufenthalte in Broadstairs, Großbritannien
08/99 – 10/99	Praktikum am Soil Erosion Laboratory, Toronto University, Kanada
09/00 – 07/01	Auslandsstudium an der Universität Utrecht, Niederlande

VERÖFFENTLICHUNGEN

2006	ESCH, T., ROTH, A. AND S. DECH (2006) . Analysis of Urban Land Use Pattern Based on High Resolution Radar Imagery. Akzeptiert für IGARSS Congress 2006, Denver, USA. TAUBENBÖCK, H., ESCH, T. AND 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: Proceedings of First Workshop of the EARSeL Special Interest Group on Urban Remote Sensing, 02.-03. March 2006, Berlin, CD-ROM.
2005	ESCH, T., ROTH, A. AND S. DECH (2005) . Robust approach towards an automated detection of built-up areas from high resolution radar imagery. In: Proceedings of the ISPRS WG VII/1 "Human Settlements and Impact Analysis" 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) and 5th International Symposium Remote Sensing of Urban Areas (URS 2005). Tempe, AZ, USA. March 14 - 16 2005, CD-ROM. ROTH, A., HOFFMANN, J. AND T. ESCH (2005) . TerraSAR-X: How can high resolution SAR data support the observation of urban areas? In: Proceedings

- of the ISPRS WG VII/1 "Human Settlements and Impact Analysis" 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) and 5th International Symposium Remote Sensing of Urban Areas (URS 2005). Tempe, AZ, USA. March 14 - 16 2005, CD-ROM.
- 2004 **ESCH, T. AND A. ROTH (2004)**. Semi-automated classification of urban areas by means of high resolution radar data. In: Proceedings of ISPRS 2004 Congress, Istanbul, 15-23 July, S.478-482
- ESCH, T., ROTH, A. AND G. STRUNZ (2004)**. Object-oriented approach towards a semi-automated classification of urban areas. In: Federal Environmental Agency (Ed.): Proceedings CORINE Land Cover 2000 Workshop, 20-21 January 2004, Berlin, Texte 04/04, ISSN 0722-186X, S. 260-264.
- 2003 **ESCH, T., ROTH, A., STRUNZ, G. AND S. DECH (2003)**. Object-oriented classification of Landsat-7 data for regional planning purposes. In: Carstens, J. (Ed.): Remote Sensing of Urban Areas 2003, S. 50-55.

SONSTIGES

Sprachen:

sehr gute Kenntnisse der englischen Sprache
 zufriedenstellende Kenntnisse der niederländischen Sprache
 Grundkenntnisse der französischen Sprache

EDV-Kenntnisse:

sehr gute Kenntnisse	eCognition, ERDAS Imagine, ArcView, Microsoft-Office-Anwendungen
gute Kenntnisse	ArcGIS, ArcInfo, IDRISI, UNIX
Grundkenntnisse	IDL/ENVI

Hobbys: Mountainbiken, Reisen, Freundeskreis, Theater, Lesen