

Übertragbarkeit der objektbasierten Analyse bei der Gewinnung von GIS-Daten aus Satelliten- bildern mittlerer Auflösung

Kristin Leukert

Vollständiger Abdruck der von der Fakultät für Bauingenieur- und Vermessungswesen der Universität der Bundeswehr München zur Erlangung des akademischen Grades eines Doktor-Ingenieurs (Dr.-Ing.) genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr.-Ing. Wilhelm Caspary
1. Berichterstatter: Univ.-Prof. Dr.-Ing. Wolfgang Reinhardt
2. Berichterstatter: Univ.-Prof. Dr.-Ing. Helmut Mayer

Diese Dissertation wurde am 3. Juni 2005 bei der Universität der Bundeswehr München eingereicht.

Tag der mündlichen Prüfung: 5. August 2005

INHALTSVERZEICHNIS

1	EINLEITUNG	1
1.1	MOTIVATION	1
1.2	AUFBAU DER ARBEIT	2
2	OBJEKTEXTRAKTION AUS FERNERKUNDUNGSDATEN	3
2.1	GRUNDLAGEN DER BILDANALYSE	3
2.1.1	<i>Bilderzeugung und Vorverarbeitung</i>	3
2.1.2	<i>Segmentierung</i>	7
2.1.3	<i>Texturmaße</i>	8
2.1.4	<i>Multispektralklassifizierung</i>	13
2.1.5	<i>Wissensbasierte Bildanalyse</i>	14
2.1.6	<i>Objektbasierte Bildanalyse</i>	15
2.1.7	<i>Fuzzy-Klassifizierung</i>	16
2.2	GIS-DATENERFASSUNG AUS BILDDATEN	17
2.3	EVALUIERUNG	21
2.3.1	<i>Evaluierung der Segmentierung</i>	21
2.3.2	<i>Evaluierung der Klassifizierung</i>	23
2.4	STAND DER WISSENSCHAFT	25
2.4.1	<i>Anwendungen auf Basis klassischer Klassifizierungsverfahren</i>	25
2.4.2	<i>Wissensbasierte Verfahren</i>	26
2.4.3	<i>Vergleich pixelbasierter mit objektbasierten Verfahren</i>	28
2.4.4	<i>Übertragung der Objektextraktion</i>	28
2.5	ZIELSETZUNG DER ARBEIT	30
3	OBJEKTBASIERTE ANALYSE	32
3.1	SEGMENTIERUNG	32
3.1.1	<i>Segmentierung künstlicher Bilder</i>	35
3.1.2	<i>Angepasste Segmentierungen für unterschiedliche Objektklassen</i>	39
3.2	FUZZY-KLASSIFIZIERUNG AUF GRUNDLAGE VON ZUGEHÖRIGKEITSFUNKTIONEN	41
3.3	BILDDATEN	43
3.4	MODELL	45
3.4.1	<i>Modellierung</i>	45
3.4.2	<i>Modell für Satellitenbilder mittlerer Auflösung von Nordafrika</i>	48
3.5	STRATEGIE UND ABLAUF DER OBJEKTBASIERTEN ANALYSE	53
4	EXPERIMENTE OHNE MODELLIERUNG DER ÜBERTRAGBARKEIT	56
4.1	ÜBERTRAGUNG INNERHALB EINER GEOGRAPHISCHEN REGION	56
4.2	ÜBERTRAGUNG INNERHALB EINES SATELLITENBILDSTREIFENS	61
4.3	ÜBERTRAGUNG ZWISCHEN UNTERSCHIEDLICHEN SATELLITENBILDSTREIFEN	63
5	MODELLIERUNG DER ÜBERTRAGBARKEIT	65
5.1	ÜBERTRAGBARKEIT DER SEGMENTIERUNG	65
5.2	ÜBERTRAGBARKEIT DER KLASSIFIZIERUNG	67
5.3	ÜBERTRAGBARKEIT VON BASIS-REGELSÄTZEN	72
5.3.1	<i>Segmentierungsparameter</i>	72
5.3.2	<i>Klassifizierungsparameter</i>	73
5.3.2.1	<i>Geographische Region Küste</i>	74
5.3.2.2	<i>Geographische Region Wüste</i>	76
5.3.2.3	<i>Vergleich der Regelsätze</i>	78
5.3.2.4	<i>Stabilität der Parameter</i>	79

6	EXPERIMENTE MIT MODELLIERUNG DER ÜBERTRAGBARKEIT	81
6.1	ERGEBNISSE	81
6.2	INDIVIDUELLE OBJEKTKLASSEN.....	87
6.3	ANWENDUNG DES BASIS-REGELSATZES AUF WEITERE TESTGEBIETE	91
6.4	VERGLEICH DER QUANTITATIVEN UND QUALITATIVEN EVALUIERUNG.....	95
6.5	DISKUSSION UND BEWERTUNG DER ÜBERTRAGBARKEIT	98
7	ZUSAMMENFASSUNG UND AUSBLICK.....	102
8	ANHANG	104
9	LITERATURVERZEICHNIS	106
	LEBENS LAUF.....	114
	DANK	114

1 Einleitung

1.1 Motivation

Eine stetig wachsende Zahl von Anwendungen aus verschiedensten Bereichen, wie Navigation, ortsbezogene Dienste, Telekommunikation, Umweltmanagement und Planung benötigt aktuelle Geodaten in digitaler Form, oft als (Geo-)Informationssysteme (GIS). Die manuelle Erfassung von Geodaten ist sehr zeitaufwändig und kostenintensiv. Es besteht daher großer Bedarf an wirtschaftlichen und effizienten Verfahren zur Datengewinnung. Digitale Fernerkundungsdaten sind aufgrund ihrer zeitnahen Verfügbarkeit für großflächige Gebiete eine wichtige Datenquelle. Die geometrische wie auch die spektrale Auflösung der Fernerkundungssensoren unterliegen einer stetigen Verbesserung. Stand der Technik sind beispielsweise Bilder des QuickBird-Satelliten mit einer Bodenauflösung von 61 cm im panchromatischen Kanal und 2,44 m in vier multispektralen Kanälen. Hyperspektrale Sensoren bilden die Erdoberfläche in bis zu mehreren Hundert Kanälen ab.

Mit der Verfügbarkeit immer besserer Datenquellen steigt die Nachfrage nach einer schnelleren und kostengünstigeren Datengewinnung. Trotz intensiver Forschungsaktivitäten im Bereich der automatisierten Objektextraktion gibt es heutzutage nur für spezielle Anwendungen praxisreife und kommerziell verfügbare Verfahren. Gründe hierfür sind vor allem die extrem hohe Komplexität der Aufgabenstellung, aber auch zu wenig empirische Vergleiche sowie fehlende Standards (GÜLCH et al. 2004). Prototypen aus Forschungsprojekten sind oft nicht in der Praxis einsetzbar, da sie unrealistische Anforderungen z.B. an die Verfügbarkeit oder Redundanz bestimmter Daten stellen, wie beispielsweise die Verwendung von a priori Information in Form bestehender, sehr spezieller Daten. Ein Großteil der Forschungsprojekte ist auf eine bestimmte Objektklasse wie Straße, Gebäude oder auf spezielle Bilddaten spezialisiert und es wird nur ein kleiner Teil der real vorkommenden Situationen behandelt. Die Zuverlässigkeit und Übertragung auf andere Eingabedaten ist somit nicht gewährleistet. Weitere Schwachstellen sind fehlende Editierwerkzeuge zur Nachbearbeitung sowie ein Mangel an ausreichend standardisierten Schnittstellen zum Datenaustausch.

Vollautomatische Verfahren zur Objektextraktion liefern oft unzureichende Ergebnisse und der Anwender bekommt meist keinerlei Hinweise, welche Objekte korrekt und welche fehlerhaft sind (BALTSAVIAS 2004). Verfahren für die Praxis sind auf absehbare Zeit nur inklusive Nutzerinteraktion vorstellbar (MAYER 2004). Durch die Ausweisung der extrahierten Objekte mittels Ampelfarben (*Traffic light*) könnte der Anwender nach dem automatischen Extraktionsprozess in einem Nachbearbeitungsschritt gezielt fehlerhafte Objekte korrigieren. Grün markierte Objekte sollten korrekt sein und keine Begutachtung durch den Anwender erfahren. Gelbe Objekte könnten korrekt sein, müssen aber überprüft werden. Hingegen weist die Farbe Rot ein Objekt als unkorrekt aus, das nicht weiter betrachtet werden sollte.

Neben der Entwicklung von vollautomatischen hin zu praktisch einsetzbaren Verfahren mit Integration der menschlichen Interaktion zeichnet sich in der Analyse von Fernerkundungsbildern ein Trend von rein multispektralen Methoden hin zur Strukturanalyse ab. Die Standardmethoden der multispektralen Klassifizierung sind in allen gängigen kommerziellen Softwarepaketen implementiert. Diese berücksichtigen ausschließlich die spektralen Eigenschaften der einzelnen Pixel. In hoch aufgelösten, komplexen Bilddaten sind einzelne Objektklassen aber oft spektral heterogen und die Standardmethoden der multispektralen Klassifizierung liefern nur unzureichende Ergebnisse.

Es wird angenommen, dass die menschliche Wahrnehmung ein Bild durch eine flächenhafte Gliederung in Einzelflächen bzw. Objekte strukturiert. Aufgrund von Kanten, Textur und Farben werden die Objekte abgegrenzt und ihre Interpretation erfolgt mit zusätzlicher Hilfe in Form von Vorwissen bzw. Erfahrungen. Wissensbasierte Verfahren der Bildanalyse versuchen das Wissen über die Objekte in Modellen abzubilden. Die Objekte der realen Welt werden unter Beachtung ihrer Objekteigenschaften, der Abbildung im Satellitenbild und ihrer gegenseitigen Beziehungen modelliert. Eine Spezialisierung der wissensbasierten Verfahren ist die objektbasierte Bildanalyse, wie sie in der in dieser Arbeit ver-

wendeten Software eCognition realisiert ist. Diese verwendet anstelle von einzelnen Pixeln Segmente, die durch Segmentierung des Bildes erzeugt werden. Das Wissen wird in Regelsätzen repräsentiert und die Klassifizierung der Segmente erfolgt anhand dieser Regelsätze. eCognition setzt vor der Klassifizierung die flächenhafte Segmentierung des gesamten Bildes voraus.

Diese Arbeit beschäftigt sich mit der objektbasierten Analyse von Fernerkundungsdaten und besonders mit der Übertragbarkeit der Regelsätze. Eine Grundprämisse dieser Arbeit ist die Beschleunigung des Auswerteprozesses um etwa Faktor 10 mit einer Abschätzung, welche Qualität mit dieser Vorgehensweise erzielt werden kann. Von großer Bedeutung für die Ergebnisse sind hierbei neben dem Segmentierungsverfahren und den Parametern für die Segmentierung der Bilddaten die Modellierung von Objekteigenschaften und deren Relationen, wobei Erstere radiometrische und geometrische Eigenschaften sowie den Bezug zum Maßstab umfassen. Für die Übertragbarkeit spielt die Generik, d.h. die Allgemeingültigkeit des verwendeten Wissens eine entscheidende Rolle. Die verschiedenen Einflüsse auf die Übertragung von Regelsätzen werden analysiert und durch umfassende praktische Experimente mit quantitativer Qualitätsbetrachtung wird die Robustheit des Modells und die Übertragbarkeit auf andere Gebiete untersucht und belegt. Für die Experimente in zwei geographischen Regionen in Nordafrika werden Satellitendaten mittlerer Auflösung eingesetzt (*pan-sharpened* IRS - *Indian Remote Sensing* Satellit in 5 m Auflösung mit drei multispektralen Kanälen Grün, Rot und Nahes Infrarot), da für größere Bereiche wie ganze Länder aus Kostengründen höher aufgelöste Bilddaten, wie Luftbilder oder QuickBird- und IKONOS-Satellitenbilddaten, zu kostenintensiv sind.

1.2 Aufbau der Arbeit

Kapitel 2 beschreibt Grundlagen der Bildanalyse. Neben Vorverarbeitungsschritten wie Segmentierung und Beschreibung von in der Arbeit verwendeten Texturmaßen wird die klassische Multispektralklassifizierung (Abschnitt 2.1.4), die wissensbasierte bzw. objektbasierte Bildanalyse (Abschnitt 2.1.5 bzw. 2.1.6) sowie die *Fuzzy*-Klassifizierung (Abschnitt 2.1.7) vorgestellt. Nach einem Unterkapitel über die Evaluierung von Segmentierung und Klassifizierung wird in Kapitel 2.4 der Stand der Wissenschaft dargestellt. Die Zielsetzung der Arbeit wird im letzten Abschnitt von Kapitel 2 noch einmal detailliert erläutert.

Am Anfang von Kapitel 3 wird der verwendete Segmentierungsalgorithmus vorgestellt und anhand eines Testbildes die Wirkung unterschiedlicher Parametereinstellungen demonstriert. Anschließend wird die Klassifizierung auf Grundlage von Zugehörigkeitsfunktionen beschrieben. Nach Vorstellung der in den Experimenten verwendeten Bilddaten werden nach einem einführenden Abschnitt in die Modellierung (Abschnitt 3.4.1) Modelle zur objektbasierten Bildanalyse für zwei geographische Regionen in Nordafrika aufgestellt (Abschnitt 3.4.2) sowie die gewählte Strategie und der Ablauf geschildert.

Kapitel 4 beschreibt Experimente zur Übertragbarkeit individueller Regelsätze. Es wird zwischen Übertragungen innerhalb einer geographischen Region, innerhalb eines Satellitenbildstreifens und zwischen unterschiedlichen Satellitenbildstreifen unterschieden.

In Kapitel 5 wird die Übertragbarkeit der Segmentierung und der wissensbasierten Klassifizierung diskutiert. Mögliche Einflüsse auf die verschiedenen Arten von Merkmalen werden beleuchtet. Für die zwei geographischen Regionen *Küste* und *Wüste* in Nordafrika werden einheitliche Segmentierungsparameter und möglichst allgemein gültige Basis-Regelsätze aufgestellt.

Praktische Experimente zur Übertragbarkeit von Basis-Regelsätzen werden in Kapitel 6 vorgestellt. Die Ergebnisse der Qualitätsbetrachtung bei Anwendung der Basis-Regelsätze auf verschiedene Testgebiete werden anschaulich dargestellt. Eine Diskussion und die Bewertung der Übertragbarkeit runden diesen Abschnitt ab.

Vor dem Anhang und dem Literaturverzeichnis fasst Kapitel 7 inklusive einem Ausblick die Arbeit zusammen.

2 Objektextraktion aus Fernerkundungsdaten

2.1 Grundlagen der Bildanalyse

Dieser Abschnitt gibt eine Einführung in Grundlagen der Bildanalyse. ROSENFELD (1982) definiert Bildanalyse als die „automatische Generierung einer sinnvollen Beschreibung für eine in Bildern dargestellte Objektraumscene“. Die Erkennung von Objekten in Bildern setzt deren Definition voraus. Hierfür werden Objektmodelle verwendet, die dem Rechner in einer entsprechenden formalisierten Sprache zur Verfügung gestellt werden müssen. Die Beschreibung der Objekte kann durch Angabe radiometrischer (Farbe, Textur) und geometrischer Eigenschaften (Form, Größe), Maßstabsraumverhalten und Relationen zu anderen Objekten erfolgen. Die Bildanalyse lässt sich in die vier Ebenen Bilderzeugung, Vorverarbeitung, Segmentierung und Interpretation gliedern (siehe Abbildung 1):




Abbildung 1: Ebenen der Bildanalyse (nach MAYER 1994)

Die Bilderzeugung ist die unterste Ebene der Bildanalyse. Mit Szene ist hier der Ausschnitt der realen Welt gemeint, der im digitalen Bild festgehalten wird. Jedes Pixel (Bildelement) eines digitalen Bildes besitzt einen Intensitäts-/Grauwert, welcher mit der auf der am Boden entsprechenden Fläche gemessenen spektralen Reflexion korreliert ist. Die *low-level* Ebene beschäftigt sich mit der Vorverarbeitung der Bilddaten, wie z.B. radiometrische und geometrische Korrekturen. In der *mid-level* Ebene werden durch Segmentierung einzelne Pixel zu primitiven Objekten zusammengefasst. Diese „Segmente“ können durch verschiedene Eigenschaften, wie Grauwert, Textur und Form charakterisiert werden. Zusätzlich sollen diese Segmente den Zielobjekten der Anwendung bzw. Teilen von diesen entsprechen. Bei der Interpretation (*high-level*) werden mit Hilfe von Vorwissen die primitiven Objekte in Objekte der Anwendung überführt und z.T. zusammengefasst. Die Qualität des Bildanalyseergebnisses hängt von der Qualität des Modellwissens ab. Es können nur Objekte erkannt werden, die vorher modelliert wurden. Das Modellwissen wird praktisch immer in Zusammenhang mit einer bestimmten Anwendung zusammengestellt und formalisiert. Die nachfolgenden Abschnitte beschreiben die hier angesprochenen Ebenen der Bildanalyse in größerem Detail.

2.1.1 Bilderzeugung und Vorverarbeitung

Passive Satellitensensoren, wie der indische IRS-Satellit, dessen Bilder in den später beschriebenen praktischen Arbeiten verwendet werden, zeichnen die von der Erdoberfläche reflektierte elektromagnetische Strahlung einer natürlichen Quelle (Sonne) auf. Maßgeblich für die zurückgeworfene Strahlung ist die Beleuchtung des Geländes und die Reflexionseigenschaften der Objekte der realen Welt. Bei aktiven Satellitensystemen, wie z.B. Radarsystemen, wird die Erdoberfläche mit einer Energiequelle künstlich bestrahlt und die reflektierte Strahlung wird als Bild aufgezeichnet. Im Folgenden findet eine Beschränkung auf passive Satellitensysteme statt.

Elektromagnetische Strahlung transportiert elektrische und magnetische Energie in Wellenform. Das elektromagnetische Spektrum wird je nach Art der Entstehung und Wirkung der Strahlung in verschiedene Bereiche eingeteilt, die keine scharfen Grenzen aufweisen. Abbildung 2 veranschaulicht das elektromagnetische Spektrum mit den in der Fernerkundung benutzten „atmosphärischen Fenstern“. Letztere sind Teilbereiche, in denen die Atmosphäre eine weitgehende Durchlässigkeit für elektromagnetische Strahlung aufweist. Das sichtbare Licht besitzt eine Wellenlänge zwischen 0,4 und 0,7 μm . Der Infrarotbereich mit dem nahen, mittleren und fernen (thermalen) Infrarot weist deutlich größere Wellenlängen bis zu 1 mm auf. Daran anschließend gibt es noch Mikro- und Radiowellen mit Wellenlängen bis zu mehreren Kilometern.




Abbildung 2: Das elektromagnetische Spektrum (aus ALBERTZ 2001)

Die von einem Objekt auf der Erdoberfläche reflektierte Strahlung durchläuft zum Objekt und auf dem Weg zum Sensor die Atmosphäre. Daher kommen für die Fernerkundung nur die für elektromagnetische Strahlung durchlässigen „atmosphärischen Fenster“ in Betracht. Für fernerkundliche Aufnahmen spielt die Refraktion (atmosphärische Strahlenbrechung) infolge von Dichteänderungen der Luft keine entscheidende Rolle. Absorption und Streuung sind demgegenüber nicht zu vernachlässigen. Unter Absorption wird eine Energieumwandlung verstanden, bei der elektromagnetische Strahlung zum Teil in Wärme oder andere Energieformen umgewandelt wird. Durch kleine Materieteilchen in der Atmosphäre wie Dunst, Staub und Wassertröpfchen (Aerosole) wird je nach Art und Größe eine Streuung der Strahlung in alle Richtungen bewirkt. Die elektromagnetische Strahlung wird durch Absorption und Streuung insgesamt abgeschwächt.

Die auf ein Objekt fallende Strahlung ist hinsichtlich Intensität und spektraler Zusammensetzung abhängig vom Sonnenstand, der Trübung der Atmosphäre, von der Exposition des Objektes (Neigung und Neigungsrichtung) sowie von der Geländehöhe über Normalnull. Neben ihrem Einfluss auf die Beleuchtung des Geländes hat die Atmosphäre auch Einfluss auf die reflektierte Strahlung. Es erfolgt eine Überlagerung der reflektierten Strahlung mit einem Teil der Himmelsstrahlung, dem so genannten „Luftlicht“. Dies kann zu einer Kontrastverminderung führen. Ein weiterer wichtiger Einfluss ist die Bewölkung. Für Aufnahmen im sichtbaren Licht und im Nahen sowie Thermal-Infrarot wird ein wolkenfreier Himmel benötigt, sonst treten Verdeckungen auf.

Reflexionseigenschaften

Eine Grundvoraussetzung für die thematische Auswertung von Fernerkundungsdaten sind in den meisten Fällen die unterschiedlichen Reflexionseigenschaften von Objekten auf der Erdoberfläche, die von einer Reihe von Faktoren abhängen. Diese sind das Material des Objektes, der physikalische Zustand (z.B. trocken, feucht), die Oberflächenrauigkeit und geometrische Gegebenheiten wie der Einfallswinkel.

kel der Sonnenstrahlung und die Beobachtungsrichtung. Tabelle 1 listet beispielhaft für die drei Geländetypen Wasser, Boden und Vegetation Faktoren auf, welche die Reflexion beeinflussen. Es ist erkennbar, dass insbesondere natürliche topographische Objekte eine nahezu unendliche Vielzahl an möglichen Erscheinungsformen und damit unterschiedliche Abbildungen im Sensor aufweisen können.

Tabelle 1: Reflexionsbeeinflussende Faktoren für Wasser, Boden und Vegetation

Reflexionsbeeinflussende Faktoren		
Wasser	Boden	Vegetation
<ul style="list-style-type: none"> - Konzentration von organischem und anorganischem Material, - Tiefe des Wasserkörpers, - Rauigkeit der Wasseroberfläche 	<ul style="list-style-type: none"> - Wassergehalt, - Textur (Anteil von Sand, Schluff, Ton; Korngröße, Krümelung), - Art und Anteil von organischem Material, - Rauigkeit, - chemische Zusammensetzung der mineralischen Bodenbestandteile (z.B. Eisenoxid) 	<ul style="list-style-type: none"> - Phänologischer Zustand, - Bestandsdichte, - Artenzusammensetzung, - Alter, - Wassergehalt, - Homogenität, - Oberflächeneigenschaften der Blattoorgane, - Flächige Pflanzenschäden

Neben den spektralen Werten eines Bildkanals können auch Verhältnisse von Bildkanälen zur Unterscheidung von Objekten, d.h. zur Klassifizierung verwendet werden. Der *Normalized Difference Vegetation Index (NDVI)* wird z.B. aus den beiden Kanälen Rot und Nahes Infrarot berechnet und zur Detektion von Vegetation eingesetzt. Er kombiniert zwei Effekte: Gesunde Pflanzenzellen besitzen eine hohe Reflexion im Nahen Infrarot (NIR)-Kanal und durch die Chlorophyll-Absorption eine geringe Reflexion im roten Kanal. Daraus resultiert folgende Formel zur Berechnung des *NDVI*:

$$NDVI = \frac{NIR - Rot}{NIR + Rot}, \text{ mit } NIR: \text{ Grauwert im NIR-Kanal und } Rot: \text{ Grauwert im Rot-Kanal}$$

Der *NDVI* kann Werte von -1 bis +1 annehmen. Er wird als relativ unempfindlich gegenüber äußeren Strahlungsbedingungen angesehen, da er aus Verhältnissen von Reflexionsgraden gebildet wird (LILLESAND, KIEFER 2000, S. 513).

Objekte mit einer ausgeprägten räumlichen Oberflächenstruktur weisen je nach Beleuchtung und Beobachtungsrichtung stark unterschiedliche Helligkeits-, Farb- und Kontrastwerte auf. Exemplarisch zeigt Abbildung 3 Ausschnitte aus drei aufeinander folgenden Farbinfrarotluftbildern. Die dreidimensionalen Strukturen der Ackerflächen, hervorgerufen durch Ackerfurchen, Bewuchs und Unebenheiten des Bodens, bedingen im Bild nicht aufgelöste, sehr kleine Schattenflächen und damit das unterschiedliche Erscheinungsbild in den Aufnahmen. Wenn diese 3D-Strukturen wie hier in den Luftbildern zu klein für eine Sensorauflösung sind, dann spiegeln sich die dadurch hervorgerufenen Schatteneffekte als Reflexionseffekte wider.




Abbildung 3: Zusammenwirken von schräg einfallender Beleuchtung und Beobachtungsrichtung (Mitlichtbereich (links), Bildmitte (Mitte) und Gegenlichtbereich (rechts), Daten: Farbinfrarotluftbilder, aus ALBERTZ 2001)

Maßstabsverhalten

Objekte bilden sich in verschiedenen Sensoren unterschiedlich ab, da jeweils unterschiedliche Eigenschaften der Objekte aufgezeichnet werden (z.B. thermale und radiometrische Eigenschaften). Aber auch die geometrische Auflösung der Sensoren kann das Abbild der Objekte z.T. maßgeblich beeinflussen. Linienförmige Objekte, wie Straßen und Flüsse, werden in hoch aufgelösten Bilddaten als Flächen und in Bildern niedriger Auflösung als Linien abgebildet. Bei flächenhaften Objekten wie Wald sind in hoch aufgelösten Bildern einzelne Bäume oder sogar Äste und Blätter zu erkennen. Diese Einzelobjekte verschmelzen in niedrigen Auflösungen zu einer homogenen Fläche mit charakteristischer Radiometrie bzw. Textur. Objekte weisen z.T. ein charakteristisches Maßstabsverhalten auf, das wertvolle Zusatzinformation für die Objektextraktion beisteuert. Bilder unterschiedlicher Auflösung werden meist durch die Generierung von Bildpyramiden bereitgestellt. Theoretisch werden Maßstäbe mittels der Maßstabsraum-Theorie untersucht. Ein Überblick über Eigenschaften von Maßstabsräumen und deren Eignung für die Objektextraktion wird in (MAYER 1998) gegeben.

Bildvorverarbeitung

Die Vorverarbeitung von Bilddaten kann in Bildverbesserung und Bildrestauration unterteilt werden. Letztere versucht die physikalische Bildqualität zu verbessern indem Störungen in den Bildern, wie z.B. Rauschen oder Streifen entfernt werden, wohingegen Erstere auf der Verbesserung der visuellen Qualität bei der Betrachtung durch den Menschen beschränkt ist. Für beide können neben Helligkeits- und Kontrastverbesserung, Histogrammanpassung und Filterung, geometrische und radiometrische Korrekturen verwendet werden. Die spektrale Signatur von Oberflächen in Fernerkundungsbildern wird durch die Oberflächenbedeckung bestimmt. Störeinflüsse, wie Atmosphäreneinflüsse bei der Aufnahme, Sonnenhöhe und Geländeform beeinträchtigen die Signatur. Durch radiometrische Bildrestauration mittels Korrektur können diese Störeinflüsse verringert werden. Radiometrische Korrekturen können die zur Aufnahmezeit herrschenden atmosphärischen Einflüsse berücksichtigen und geländebedingte Beleuchtungseffekte minimieren.

Ein Großteil der Verfahren zur radiometrischen Korrektur basiert auf physikalischen Modellen, welche das Zusammenspiel von Strahlung und Atmosphäre berücksichtigen. Diese Interaktion resultiert aus der Streuung und Absorption der Strahlung an Molekülen und Aerosolen. Für die radiometrischen Korrekturen werden die Strahlungsvorgänge, die zum Zeitpunkt der Bildaufnahme herrschten, quantitativ modelliert. Zur Aufstellung dieser Modelle sind detaillierte und flächendeckende meteorologische Daten erforderlich. Stehen diese nicht zur Verfügung, können die meteorologischen Parameter auch direkt aus dem Satellitenbild mit Hilfe von Objekten mit bekannten Reflexionseigenschaften geschätzt werden. SCHNEIDER (1999) beschreibt eine so genannte „radiometrische Selbstkalibrierung“, bei der die radiometrischen Modellparameter aus einem Vergleich zwischen Segmenten und Prototypobjekten in einer Wissensbasis gewonnen werden.

Eine einfache und gängige Methode zur Atmosphärenkorrektur ist die so genannte „Dunstkorrektur“, auch *Dark Target* Methode genannt. Diese basiert auf der Annahme, dass glatte Wasserflächen von tiefem, klarem Wasser oder Schlagschatten im sichtbaren und infraroten Bereich sehr wenig Licht reflektieren. Demnach sollte in jeder Aufnahme mindestens ein Pixel mit dem Grauwert 0 existieren. Die Differenz zwischen dem Grauwert 0 und dem kleinsten in der Aufnahme vorkommenden Grauwert wird als Atmosphäreneinfluss betrachtet. Unter der Annahme, dass dieser Atmosphäreneinfluss homogen über eine Aufnahme verteilt ist, werden die Verschiebungen der Grauwerte in jedem Bildkanal gleichförmig von allen Grauwerten des jeweiligen Kanals subtrahiert (ALBERTZ 2001, S. 105).

2.1.2 Segmentierung

Bei objektbasierten Verfahren der Bildauswertung werden nicht einzelne Pixel sondern Segmente betrachtet. Nach HILDEBRANDT (1996, S. 526) „...wird der Verarbeitungsschritt, der zu einer Gruppierung von Bildelementen nach bestimmten Einheitsprädikaten führt, als Segmentierung bezeichnet. Zur Klassifizierung ... wird eine Bild-Segmentierung durch Zuordnung sachlicher Attribute zu den entstandenen Segmenten.“ HARALICK, SHAPIRO (1992) ergänzen hierzu, dass eine Segmentierung das gesamte Bild in Segmente unterteilt, wobei sich die Segmente nicht überlappen dürfen und ihre Vereinigung wieder das Ursprungsbild ergeben muss. Die Segmente sollen im Hinblick auf eine bestimmte Anwendung aussagekräftig sein. Segmentierungsverfahren sind für viele Anwendungsgebiete der Bildanalyse entwickelt worden. Mögliche Einsatzgebiete sind z.B. die optische Zeichenerkennung, die Erkennung von Werkstücken durch Roboter, die Analyse von klinischen Aufnahmen im medizinischen Bereich sowie die Auswertung von Fernerkundungsdaten (MEYER-GRUHL 1993). Einen Überblick über Segmentierungsalgorithmen geben z.B. HARALICK, SHAPIRO (1985), PAL, PAL (1993), PINZ (1994) und FREIXENET et al. (2002), wobei die zuletzt genannte Veröffentlichung den Schwerpunkt auf Segmentierungsmethoden legt, die Kanten- und Regioneninformationen integrieren.

Segmentierungsverfahren können entsprechend (eCognition USER GUIDE 2004) in modell- (*top-down*) und datengetrieben (*bottom-up*) eingeteilt werden. Modellgetriebene auch wissensbasiert genannte Verfahren verwenden ein Objektmodell für die zu extrahierenden Objekte. Mit Hilfe des Objektmodells wird vom System nach einer geeigneten Methode gesucht, um die gewünschten Objekte zu segmentieren. Es werden folglich nur diejenigen Bereiche segmentiert, die zu dem Modell passen. Dahingegen wird bei datengetriebenen Verfahren das gesamte Bild aufgrund von vielfältigsten Methoden und Parametern segmentiert. Das Ergebnis sind hierbei Segmente, die noch nicht den Objekten der realen Welt entsprechen müssen. Ein Vergleich aktueller Segmentierungsprogramme für Fernerkundungsdaten ist in (MEINEL, NEUBERT 2004) gegeben.

Nachfolgend werden ausgewählte datengetriebene Segmentierungsmethoden erläutert. Die vorgestellten Verfahren können in punkt-, kanten- und regionenbasierte Verfahren gruppiert werden (JÄHNE 1993).

Punktbasierte Verfahren

Punktbasierte Verfahren betrachten bei der Zuordnung zu einem Objekt nur den Grauwert einzelner Pixel. Hierbei werden (häufig mit Hilfe des Histogramms) geeignete Schwellwerte bestimmt. Der spektrale Merkmalsraum wird beim pixelbasierten Schwellwertverfahren in Abschnitte unterteilt und aneinander grenzende Pixel, die sich innerhalb eines Grauwertabschnitts im Histogramm befinden, zusammengefügt. Die Segmentierungsergebnisse sind oft nicht überzeugend: Es treten häufig Über- und Untersegmentierungen auf. Bei Übersegmentierungen sind die gebildeten Segmente zu klein und bei Untersegmentierungen werden Regionen, die nicht zueinander gehören, zusammengefügt. Lokale Kontraste werden beim Schwellwertverfahren nicht berücksichtigt und die gebildeten Regionen können in der Größe stark differieren. Punktbasierte Verfahren eignen sich vor allem für die Dokumentanalyse (Separierung Text und Hintergrund) sowie für industrielle Anwendungen, bei denen Beleuchtung und Hintergrund frei gewählt werden können.

Kantenbasierte Verfahren

Kantenbasierte Verfahren nutzen zur Segmentierung die Begrenzungen der Segmente, d.h. Kanten. Einen Überblick über gängige Kantenoperatoren wird in PRATT (1991) gegeben. Die Wasserscheiden-Segmentierung (*Watershed Transformation*) ist ein Vertreter der kantenbasierten Verfahren. Nach der Berechnung des Gradientenbildes wird dieses Grauwertbild als topographische Oberfläche betrachtet, die ausgehend von den Minima „geflutet“ wird. Durch die Flutung entstehen Sammelbecken und Wasserscheiden. Während die Wasserscheiden die Konturen darstellen, repräsentieren die Becken homogene Regionen (VINCENT, SOILLE 1991).

Bei aktiven Konturmodellen (*Snakes*) werden gegebene initiale Konturen durch Minimierung eines Energiefunktions an Grauwertkanten bei gleichzeitiger Forcierung von Formbedingungen, wie z.B. Glattheit, angenähert (KASS et al. 1987). Ein semiautomatisches *Region Competition* Segmentierungsverfahren, welches Flächenwachstum und *Snakes* integriert, wird in (TORRE, RADEVA 2000) zur Segmentierung von landwirtschaftlichen Flächen aus monochromen Luftbildern vorgestellt. Der Operateur definiert interaktiv ein Polygon, welches zum einen die Grundlage für die Beschreibung der Homogenität der zu segmentierenden Fläche bildet und zum anderen als Anfangs-*Snake* dient. In einem iterativen Prozess nähert sich das Startpolygon der zu segmentierenden Fläche durch Energieminimierung. Als Abbruchkriterium wird unter anderem die Formkorrelation zwischen zwei aufeinander folgenden Iterationsschritten verwendet.

Regionenbasierte Verfahren

Die Trennung von Segmenten in Form von homogenen Flächen ist Ziel der regionenbasierten Segmentierung. Homogenität kann auf Grundlage von Grauwerten, aber auch auf Grundlage anderer Merkmale, wie z.B. Textur definiert werden. Das gängigste regionenbasierte Segmentierungsverfahren ist das Flächenwachstum (*Region Growing*). Es besteht aus zwei Schritten: dem Initialisierungsschritt und dem Ausführungsschritt. Im Initialisierungsschritt wird der Startpunkt (sog. „Saatzellen“) gegeben, von dem aus im Ausführungsschritt Pixel zu Regionen (*Clustern*) zusammengefasst werden. Flächenwachstumsalgorithmen benötigen die Angabe der Startpunkte oder Algorithmen für deren Bestimmung und ein Abbruchkriterium für die Zusammenfassung von Pixeln bzw. Regionen.

Beim Flächenwachstum findet eine „*Merge*“- , d.h. Zusammenfassungs-Strategie Anwendung. Die „*Split*“-Vorgehensweise hingegen geht von einer groben Segmentierung des Bildes in große Bildbereiche aus und versucht eine Verbesserung dieser Bereiche durch Aufteilung (*split*) zu erzielen. Beim „*Split and Merge*“ Verfahren werden die beiden Strategien kombiniert. Oft beginnt man mit dem ganzen Bild und untersucht dieses auf Homogenität. Ist diese nicht gegeben, wird das Bild in vier Quadranten aufgeteilt, die wieder auf Homogenität untersucht werden. Die Viertelung führt hierbei zu einem so genannten „*Quad-Tree*“.

In Abschnitt 3.1 wird das in dieser Arbeit eingesetzte Segmentierungsverfahren von eCognition vorgestellt. Es handelt sich hierbei um ein *Bottom-up region merging*.

2.1.3 Texturmaße

Mittels Texturanalyse können für texturierte Objekte virtuelle Kanäle für die Bildklassifizierung erzeugt werden. Bei der objektbasierten Analyse können für die Segmente Texturmaße berechnet und zur Klassifizierung herangezogen werden. Texturmaße beschreiben die räumliche Anordnung der Grauwerte von Pixeln eines Bildsegmentes (IEEE STD 610.4 1990). Es gibt u.a. die folgenden Ansätze zur Beschreibung von Texturen:

- statistische (*Grey Level Co-Occurrence Matrix* GLCM, HARALICK et al. 1973)
- modellbasierte (z.B. *Markov Random Fields* MRF, CHELLAPPA, CHATTERJEE 1985)
- frequenzbasierte (z.B. *Wavelet* Filter, MALLAT 1989)

Die GLCM ist weit verbreitet in der Fernerkundung. Sie enthält die relativen Häufigkeiten C_{ij} der Kombinationen von Grauwerten bestimmter Pixelpaare innerhalb eines Bildausschnittes. Die Anzahl der Grauwerte G bestimmt die Größe der Matrix $N = G \times G$. Die relative Lage der beiden Pixel wird durch zwei Parameter definiert: der Abstand d und die Orientierung θ . Für jedes Parameterpaar (d, θ) wird die GLCM folgendermaßen berechnet:

$$C_{ij} = \frac{P_{ij}}{\sum_{i,j=1}^G P_{ij}}$$

P_{ij} steht für die absolute Häufigkeit des Auftretens der Grauwerte i und j . Aus der GLCM werden zur Beschreibung der Textur statistische Informationen abgeleitet. Die Informationen sollten invariant bezüglich einer Verschiebung des mittleren Grauwertes und einer Änderung des Kontrastes sein. In der Regel werden die vier Orientierungen $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$ benutzt, da aus Symmetriegründen nicht alle acht möglichen Nachbarn betrachtet werden müssen. Mit 0° wird die vertikale und mit 90° die horizontale Richtung bezeichnet. Zur Verringerung der Abhängigkeit von der Rotation wird z.T. auch eine einzelne GLCM für alle Richtungen angegeben. Hierfür werden die einzelnen Matrizen der vier Orientierungen aufsummiert.

Abbildung 4 zeigt anhand einer einfachen Bildmatrix mit 4 Grauwerten ein Beispiel zur Berechnung der GLCM für die Orientierung 90° und einem Abstand d von einem Pixel. Die GLCM ist quadratisch und symmetrisch. Die Dimension der Matrix, also die Anzahl an Zeilen bzw. Spalten entspricht der Anzahl der im Bild vorkommenden Grauwerte. Die Lage der einzelnen Grauwerte ist in der GLCM nicht gespeichert, so dass aus ihr keine Rekonstruktion des ursprünglichen Bildes erfolgen kann. Das Matrizenelement an der Stelle $(2,1)$ lautet beispielsweise 6. Dies bedeutet, dass die Grauwertkombination 2 links neben 1 insgesamt sechs mal im Bild vorkommt. Eine stark besetzte Hauptdiagonale bedeutet keine bzw. geringe Grauwertunterschiede im Bild. Große Kontraste im Bild äußern sich durch Matrizeneinträge deutlich abseits der Hauptdiagonalen (STEINBRECHER 1993).




Abbildung 4: Beispiel zur Berechnung der GLCM für die Orientierung 90° und den Abstand ein Pixel

In der Fernerkundung gebräuchliche Bilddaten besitzen 8 bit, was 256 Grauwerten entspricht. Die Größe der dazugehörigen GLCM beträgt $256 * 256$ mit 65 536 Zellen, was eine erhebliche Rechenleistung bedeutet. Der Informationsgehalt der GLCM ist allerdings nicht entsprechend hoch, da viele Kombinationen von Grauwerten nicht vorkommen und die Matrix mit 0 besetzt ist. Daher wird zur

Berechnung der Texturmaße die Quantisierung oft auf 64 oder 32 Grauwerte erniedrigt. CLAUSI (2002) beschäftigt sich mit der Auswirkung der Quantisierung auf die zu berechnenden Texturmaße.

HARALICK et al. (1973) leiten aus der GLCM 14 Texturmaße ab. Tabelle 2 zeigt fünf ausgewählte Texturmaße. Nach GOTLIEB, KREYSZIG (1990) erfassen die HARALICK Texturmaße statistische und informationstheoretische Eigenschaften von Texturen und können in folgende Merkmalsklassen eingeteilt werden:

1. Merkmale, die visuelle Textureigenschaften ausdrücken: *Angular Second Moment* (Maß für die Homogenität), *Contrast*, *Correlation*
2. Merkmale, die sich auf statistische Eigenschaften gründen: *Inverse Difference Moment/Homogeneity*, *Variance*
3. Informationstheoretische Maße wie *Entropy*
4. Korrelationskoeffizient

Die folgenden Ausführungen interpretieren die Texturmaße hinsichtlich der menschlichen Wahrnehmung. Mit der Frage, was die Texturmaße eigentlich repräsentieren, beschäftigen sich bislang nur wenige Arbeiten. HARALICK et al. (1973) merken nur an, dass hier noch Forschungsbedarf besteht. Es wird betont, dass die Texturmaße zwar Informationen über die textuellen Eigenschaften eines Bildes beinhalten, es aber unklar ist, welche spezifische Eigenschaft das jeweilige Maß verdeutlicht.

Tabelle 2: Ausgewählte HARALICK Texturmaße

Texturmaß	Berechnungsvorschrift
<i>Entropy</i>	$\sum_{i,j=1}^G C_{ij} \log C_{ij}$
<i>Contrast</i>	$\sum_{i,j=1}^G C_{ij} (i - j)^2$
<i>Inverse Difference Moment (IDM) / Homogeneity</i>	$\sum_{i,j=1}^G \frac{C_{ij}}{1 + (i - j)^2}$
<i>Angular Second Moment (ASM)</i>	$\sum_{i,j=1}^G C_{ij}^2$
<i>Variance</i>	$\sigma_{i,j}^2 = \sum_{i,j=1}^G C_{ij} (i, j - \mu_{i,j})^2 \text{ mit } \mu_{i,j} = \frac{\sum_{i,j=1}^G C_{ij}}{G^2}$

Anhand von Beispielen werden nachfolgend verschiedene Texturmaße und ihr Verhalten für Segmente unterschiedlicher Objektklassen veranschaulicht. Abbildung 5 zeigt links einen Ausschnitt aus einem *pan-sharpened* IRS-Farbinfrarotbild aus Nordafrika und rechts die entsprechende Segmentierung. Die Segmente sind gemäß ihrer mittleren Grauwerte eingefärbt. Dieselbe Segmentierung liegt auch den Bildern B, C und D in Abbildung 6 zugrunde, da in eCognition nur von segmentierten Bildern Texturmaße berechnet werden können.




Abbildung 5: Ausschnitt aus *pan-sharpened* IRS-Farbinfrarotbild (links), segmentiertes Bild mit blauen Segmentgrenzen (rechts)

Abbildung 6 zeigt in A (links oben) das Testgebiet „Tipaza“. Es enthält im rechten oberen Teil Meer (dunkel abgebildet). Aktive Vegetation erscheint in Rot und die übrigen Flächen außerhalb bebauten Gebietes sind in Beige und Grautönen wiedergegeben. Die grauen, texturierten Flächen entsprechen Siedlungen.

Bild B (rechts oben) zeigt den Wert des Texturmaßes *ASM* im Nahen Infrarot (NIR). Die Segmentgrenzen sind zwecks Übersichtlichkeit nicht dargestellt. Helle Segmente besitzen einen großen Wert für *ASM* im NIR-Kanal. *ASM* ist ein Maß für die Homogenität. Das Meer weist wie erwartet ein hohes *ASM* und damit eine große Homogenität auf. Heterogene Siedlungsflächen besitzen dagegen ein niedriges *ASM*. Landwirtschaftlich genutzte Feldflächen, die an ihrer regulären Form erkennbar sind, weisen mittlere Werte des *ASM* auf. Vegetationsflächen sind ähnlich wie Siedlungen heterogen.

Das Texturmaß *Contrast* im Rot-Kanal ist in Bild C (links unten) graphisch veranschaulicht. Mittels *Contrast* werden die lokalen Variationen innerhalb eines Bildsegmentes beschrieben. Bis auf die Siedlungsgebiete weisen alle Flächen niedrige Werte für *Contrast* auf. Die heterogenen Siedlungen zeichnen sich dagegen durch hohe *Contrast*-Werte aus. DAVIS (1981) setzt die Besetzung der GLCM in Beziehung zur Struktur der Textur. Bei einer feinen Textur mit vielen größeren Grauwertunterschieden ist die GLCM abseits der Hauptdiagonalen stark besetzt. Aus der Formel $\sum_{i,j=1}^G C_{ij} (i - j)^2$ ergibt sich, dass für die Hauptdiagonalen, wo $i=j$ gilt, der Term gleich null ist.

Das Bild D (rechts unten) zeigt die *Homogeneity* im NIR-Kanal. Für heterogene Siedlungsgebiete sind niedrige *Homogeneity*-Werte charakteristisch und Vegetation kann auf Grundlage dieses Texturmaßes gut von Siedlungen getrennt werden. Beim *ASM NIR* sind beispielsweise die Werte für diese beiden Objektklassen ähnlich.

Die aufgeführten Beispiele zeigen, dass in der Regel mehrere Texturmaße zur Diskriminierung von Objektklassen notwendig sind. GOTLIEB, KREYSZIG (1990) zeigen in ihren Untersuchungen mit *Brodatz* Texturbildern, dass Kombinationen mehrerer Texturmaße bessere Ergebnisse liefern als die alleinige Verwendung eines Maßes.




Abbildung 6: Pan-sharpened IRS-Farbinfrarotbild (A) und Texturmaße des segmentierten Bildes in verschiedenen spektralen Kanälen (B: *ASM NIR*, C: *Contrast Red*, D: *Homogeneity NIR*)

2.1.4 Multispektralklassifizierung

Unter Klassifizierung wird hier die Zuweisung von Objekten zu einer bestimmten Klasse gemäß einer Klassenbeschreibung verstanden. Die typischen Eigenschaften einer Klasse sind in der Klassenbeschreibung abgelegt und nur Objekte, die diese Eigenschaften aufweisen, werden der entsprechenden Klasse zugeteilt. Pixelbasierte Klassifizierungsverfahren verwenden standardmäßig nur die spektralen Informationen der einzelnen Bildelemente. Die gängigste Methode ist die Multispektralklassifizierung, bei der basierend auf meist statistischen Entscheidungsregeln ein Pixel entsprechend seiner spektralen Eigenschaften einer Landbedeckungsklasse zugeordnet wird. Als virtuelle Kanäle für die Klassifizierung können Textur- oder Hauptkomponentenbilder mit einbezogen werden. LILLESAND, KIEFER (2000) unterteilen die Multispektralklassifizierung in die drei Kategorien: überwachte Klassifizierung, unüberwachte Klassifizierung und hybride Klassifizierung. Weiterführende Informationen bezüglich der verschiedenen Klassifizierungsmethoden finden sich u.a. in HILDEBRANDT (1996) und BÄHR, VÖGTLE (1998).

Die Ergebnisse einer Multispektralklassifizierung besitzen oft ein heterogenes Erscheinungsbild. Dies wird z.T. *Salt & Pepper*-Effekt genannt und resultiert aus der pixelweisen Klassifizierung (Abbildung 7). Bei der Klassifizierung wird keine Kontextinformation berücksichtigt, d.h. benachbarte Bildelemente und deren Klassenzuweisung spielen bei der Klassifizierung keine Rolle.




Abbildung 7: Ausschnitt aus IRS-Farbinfrarotbild (links), Ergebnis einer pixelbasierten Klassifizierung - *Salt & Pepper*-Effekt (rechts)

Bei der **überwachten Multispektralklassifizierung** werden vom Anwender repräsentative Trainingsgebiete (*Samples*) für die zu extrahierenden Klassen definiert, welche die numerischen spektralen Merkmale der jeweiligen Klassen festlegen. Nach der Trainingsphase wird in der Klassifizierungsphase jedes Pixel anhand seiner spektralen Merkmale der wahrscheinlichsten Klasse zugeordnet. Hierfür gibt es zahlreiche Methoden, wie z.B. *Minimum-Distance-to-Means*, *Parallelepiped* und *Maximum Likelihood*. Die Auswahl und Güte der Trainingsgebiete ist erfahrungsgemäß mit der bedeutendste Schritt bei der überwachten Klassifizierung. Eine Schwierigkeit bei der Generierung von Trainingsgebieten resultiert z.B. aus einer zu geringen Auflösung räumlicher Objekte. In diesem Fall sind die spektralen Eigenschaften einzelner Pixel gemischt, es entstehen so genannte „Mischpixel“. Räumlich stark differenzierte, topographisch bedingte Beleuchtungsverhältnisse und Schattenwirkungen können sich negativ auf das Klassifizierungsergebnis auswirken, weil dadurch die Klassenbeschreibungen unspezifisch und damit schlechter trennbar werden.

Ebenso wie die überwachte Multispektralklassifizierung erfolgt die **unüberwachte Multispektralklassifizierung** in zwei Schritten. In einem ersten Schritt werden spektral ähnliche Pixel zu *Clustern* zusammengefasst. Nachfolgend nimmt der Operateur unter Verwendung von Referenzdaten eine Zuordnung dieser *Cluster* zu Landbedeckungsklassen vor.

Es existiert eine Vielzahl an **hybriden Klassifizierungsverfahren**. Eine Möglichkeit besteht darin, einer überwachten Klassifizierung eine unüberwachte Klassifizierung vorzuschalten. Mit Hilfe der unüberwachten Klassifizierung können die unterscheidbaren spektralen Klassen sowie geeignete Trainingsgebiete bestimmt werden. Die hybride Multispektralklassifizierung findet insbesondere in den Fällen Anwendung, bei denen eine hohe Variabilität in den spektralen Merkmalen der Klassen vorhanden ist, wie z.B. Biotopkartierung.

Pixelbasierte Verfahren, wie die Multispektralklassifizierung, stoßen insbesondere bei hoch aufgelösten Bilddaten schnell an ihre Grenzen. In diesen werden Objekte, wie beispielsweise Gebäude, in ihre Teilobjekte zerlegt, so dass keine typische spektrale Gesamtreflexion definiert werden kann. Die häufig verwendete *Maximum Likelihood*-Klassifizierung setzt eine Normalverteilung der Grauwerte in den Trainingsgebieten voraus. Für heterogene Objekte ist diese Voraussetzung nicht immer gegeben und somit können Probleme bei der Klassenzuweisung entstehen. Bei hoher räumlicher Auflösung besitzen Bilddaten zudem meist nur drei bis vier spektrale Kanäle, was im Vergleich z.B. zu Landsat, der als Standardsensor für die Multispektralklassifizierung verwendet wird, einen Verlust an spektraler Information bedeutet. Viele Objektklassen besitzen bei nur drei oder vier Kanälen spektral ähnliche Eigenschaften und überlagern sich im Merkmalsraum. Die Klassentrennung kann daher nur unter Einbeziehung weiterer Informationen wie z.B. räumliche Nachbarschaft, Form und Textur von Objekten, sicher erfolgen. Die aufgezeigten Grenzen der klassischen, pixelbasierten Klassifizierungsverfahren haben andere z.T. wissensbasiert genannte Verfahren motiviert, die Wissen über die zu extrahierenden Objekte modellieren.

2.1.5 Wissensbasierte Bildanalyse

Der Prozess der Bildinterpretation, bei dem signifikante Objekte im Bild erkannt und mit einer symbolischen Beschreibung ausgestattet werden, wird als Bildanalyse bezeichnet. Hierzu muss das menschliche Wissen über Objekte und Strukturen der realen Welt auf den Computer übertragen werden. Wissensbasierte Bildanalyse hat mit wissensbasierten Systemen die explizite Modellierung von Vorwissen gemein. Unterschiede gibt es in der Art der Wissensrepräsentation. Anwendung finden hier zum Beispiel Regeln (Wenn – Dann – Beziehung) und relationale Strukturen, wie z.B. semantische Netze. Zur Modellierung des Wissens werden Objektmodelle eingesetzt. Sie beschreiben die Eigenschaften der zu extrahierenden Objekte. Ein Modell kann u.a. folgende Eigenschaften beinhalten (MAYER 1998):

- Funktion der Objekte
- Geometrie (2D/3D) und Material
- Reflexionseigenschaften
- Maßstab und Aggregation
- Kontext

Die Vorgehensweise der Bildanalyse wird wie die in Abschnitt 2.1.2 beschriebenen Segmentierungsverfahren in datengetrieben (*bottom-up*) und modellgetrieben (*top-down*) unterteilt. Die *bottom-up* Methoden versuchen, aus den Bildern heraus Objekte zu extrahieren, denen anschließend eine Bedeutung zugewiesen wird. Im Gegensatz hierzu geht die *top-down* Vorgehensweise vom Objektmodell aus, um mit diesem Wissen im Bild passende Objekte zu finden. Die beiden genannten Vorgehensweisen werden meist kombiniert eingesetzt. In der so genannten „Strategie“ wird der Ablaufplan für die Bildanalyse festgelegt.

Semantische Netze bilden eine Möglichkeit, Wissen in einem für den Computer interpretierbaren Formalismus zu repräsentieren (BRACHMANN 1977). Ein semantisches Netz ist eine Graphstruktur aus

Knoten und Kanten. Die Knoten (Konzepte) repräsentieren beliebige Objekte, wie z.B. topographische Objekte. Die Attribute der Objekte können den Knoten zugeordnet werden und sie können auch Methoden zur Berechnung der Objekteigenschaften umfassen. Über Kanten, die Relationen zwischen den Knoten beschreiben, sind die einzelnen Objekte miteinander vernetzt. Relationen drücken meist Hierarchien und unterschiedliche Abstraktionsebenen aus. Im Folgenden sind Beispiele für bedeutende Relationen aufgeführt:

- *Is-a*: Diese Relation wird zur Darstellung von Klassenhierarchien genutzt. Über sie werden Eltern- und Kindklassen miteinander verknüpft. Die Elternklasse gibt eine allgemeine Beschreibung der Objektklasse und vererbt alle Eigenschaften an die speziellere Kindklasse. Z.T. wird diese Relation deswegen auch als Spezialisierungs- und ihre Umkehrung als Abstraktions-Relation bezeichnet.
- *Part-of*: Hiermit werden komplexe Objekte in ihre Bestandteile zerlegt (Teil-Relation). Für viele Fragestellungen erleichtert die Erkennung von Teilobjekten die Erkennung des Zielobjektes, das aus eben diesen Teilen besteht.

2.1.6 Objektbasierte Bildanalyse

Die objektbasierte Bildanalyse, wie sie in der Software eCognition realisiert ist, kann als eine spezielle Form der wissensbasierten Bildanalyse gesehen werden, die sich mit der Extraktion topographischer Objekte aus Daten mit einem hohen Informationsanteil im spektralen Bereich beschäftigt. In ihr werden in einem ersten Schritt die Bilddaten segmentiert, d.h. benachbarte Pixel nach bestimmten Homogenitätskriterien zu Segmenten zusammengefasst (siehe Abschnitt 3.1). Die Segmentierung kann hierbei auch als eine Generalisierung der Bilddaten aufgefasst werden. Die Klassifizierung der Segmente erfolgt in eCognition über eine Wissensbasis in Form von Regelsätzen, welche die Eigenschaften der gewünschten Objektklassen als *Fuzzy*-Zugehörigkeitsfunktionen (siehe Abschnitt 3.2) beschreiben. Die Segmente werden als Ganzes klassifiziert, wobei neben den spektralen Informationen auch Formeigenschaften, Textur und Kontextinformationen genutzt werden können.

eCognition wurde im Jahre 2000 von der Firma *Definiens* als erste kommerzielle Software im Bereich der objektbasierten Bildanalyse auf den Markt gebracht. Die Software kombiniert objektbasierte Bildanalyse mit der Segmentierung in mehreren Maßstabsebenen bzw. *Leveln*. Es können Luftbilder, Satellitenbild- und Radardaten kombiniert mit GIS- und Höhendaten verarbeitet werden. Dies zeigt z.B. die Kombination von hoch aufgelösten HRSC-A-Daten und Digitalem Oberflächenmodell in (HOFFMANN et al. 2000). Ein anderes Beispiel ist die Analyse hyperspektraler Bilddaten zur Landnutzungs-klassifizierung und zur Schätzung von biophysikalischen und -chemischen Eigenschaften von heterogenen Vegetationsflächen in (ECKERT, KNEUBÜHLER 2004).

Für eine Integration rasterbasierter Klassifizierungsergebnisse in vektorbasierte GIS-Applikationen sind objektbezogene Informationen erforderlich (BLASCHKE 2000). Objektbasierte Bildanalyse kann diesen Objektbezug liefern. Allerdings setzt dies eine korrekte Segmentierung voraus. Vorhandene GIS-Daten können zur Segmentierung hinzugezogen werden und bieten so dem Anwender neue Möglichkeiten im Bereich des *Monitoring* oder bei *Change Detection* Untersuchungen.

Bedingt durch die Auflösung sind in den Daten, die für diese Arbeit von Interesse sind, wie z.B. IRS, viele Einzelobjekte, wie z.B. Gebäudekomplexe, abgebildet. Allein durch spektrale Merkmale können diese Objekte z.T. nicht differenziert werden. Zum Beispiel besitzen graue Hausdächer und Straßen, wenn sie aus dem selben Material bestehen, die gleichen spektralen Eigenschaften. Hier kann die Form der Segmente wichtige Zusatzinformationen für die Klassifizierung liefern.

In dieser Arbeit werden die Segmente mit Hilfe von *Fuzzy*-Zugehörigkeitsfunktionen klassifiziert. Der folgende Abschnitt beschreibt die *Fuzzy*-Klassifizierung.

2.1.7 Fuzzy-Klassifizierung

Traditionelle Klassifizierungsalgorithmen, wie *Maximum Likelihood*, werden oft als so genannte *harte* Klassifikatoren verwendet, wobei die Zugehörigkeit zu einer Klasse binär, also 1 (zugehörig) oder 0 (nicht zugehörig) angegeben wird, obwohl Wahrscheinlichkeiten (oder wahrscheinlichkeitsähnliche Funktionen) zur Berechnung verwendet werden. Im Gegensatz dazu werden bei *weichen* Klassifikatoren, hier werden oft *Fuzzy-Systeme* und *Bayes-Klassifikatoren* genannt, Wahrscheinlichkeiten der Zugehörigkeit direkt angegeben. Der Grad der Erfüllung von Objekteigenschaften bestimmt die Wahrscheinlichkeit der Zugehörigkeit. Dies hat den Vorteil, dass Unsicherheiten berücksichtigt werden und trägt der Tatsache Rechnung, dass ein Objekt mehreren Objektklassen mit unterschiedlichen Wahrscheinlichkeiten angehören kann.

In dieser Arbeit wird ein *Fuzzy-Klassifizierungsansatz* verwendet. *Fuzzy Logic* („Unschärfe Logik“) ist ein mathematisches Konzept zur Beschreibung logischer Zusammenhänge zwischen Datensätzen der realen Welt auf Basis typisch menschlicher Ausdrucksweisen, wie z.B. ziemlich groß, vernachlässigbar wenig. Basierend auf der Theorie der unscharfen Mengen (*Fuzzy set theory*) ist *Fuzzy Logic* ein formales Werkzeug für den Umgang mit dem Phänomen der Unschärfe. ZADEH (1965) führte die *Fuzzy Sets* als Erweiterung der gewöhnlichen Mengenlehre zur Beschreibung und Verknüpfung unscharfer Mengen ein. In der klassischen Mengenlehre werden Aussagen über die Zugehörigkeit von Elementen x zu einer Menge A nur in boolescher Form getroffen:

$$x \in A \text{ oder } x \notin A$$

In der *Fuzzy Logic* wird jedem Element x ein bestimmter Grad der Zugehörigkeit zu einer Menge A zugewiesen. Der Grad kann Werte aus dem Intervall von 0 (keine Zugehörigkeit) bis 1 (volle Zugehörigkeit) annehmen. Ist X eine Menge von Objekten x , so heißt

$$A := \{(x, \mu_A(x)); x \in X\}$$

eine unscharfe Menge aus X . $\mu_A : X \rightarrow \mathcal{R}$ ist eine Funktion, die alle Elemente von X auf eine reelle Zahl abbildet. $\mu_A(x)$ wird als Zugehörigkeitsfunktion bezeichnet. Eine unscharfe Menge ist die Menge aller Zugehörigkeitsfunktionen $\mu_A(x)$ in einem Definitionsbereich. Neben der Beschreibung der Elemente werden in der Theorie der *Fuzzy Sets* auch Operatoren definiert, die auf diese Mengen angewendet werden können. Elementare Operatoren sind UND, ODER und NICHT. Zusätzlich stehen WENN und DANN zur Regelerstellung zur Verfügung.

Fuzzy Logic findet in wissensbasierten Systemen weit verbreitet Anwendung. Unschärfe Mengen werden hierbei zur Abbildung von Wissen verwendet. Das menschliche, mit Unschärfe behaftete Wissen wird in ein *Fuzzy System* implementiert und kann durch den Computer interpretiert werden. Oft liegt das Wissen als Menge von Regeln der Form WENN <Bedingung> DANN <Schlussfolgerung> vor. In der Bildklassifizierung könnte eine Regel folgendermaßen definiert werden: WENN eine spezielle Objekteigenschaft kleiner ist als ein bestimmter Wert, DANN wird das Objekt der Klasse *Siedlung* zugewiesen. Zur Festlegung der Objekteigenschaften werden die oben erläuterten Zugehörigkeitsfunktionen verwendet. Üblicherweise beschränkt man sich auf einfache Formen von Zugehörigkeitsfunktionen wie Dreiecks-, Trapez- oder Gaußfunktionen, die sich mit wenigen Parametern festlegen lassen. Zwei Beispiele für *Fuzzy-Zugehörigkeitsfunktionen* sind in Abbildung 18 dargestellt (siehe Abschnitt 3.2).

2.2 GIS-Datenerfassung aus Bilddaten

Die Erfassung und Aktualisierung von GIS-Daten ist eine zeitaufwändige und kostenintensive Aufgabe. Neben Standardverfahren der Datengewinnung für topographische Objekte, wie z.B. terrestrische Aufnahmen, *Mobile Mapping*, Digitalisierung analoger Karten oder Photogrammetrie, werden zur Kostensenkung bei nicht allzu hohen Anforderungen an Detaillierungsgrad und geometrischer Genauigkeit auch Verfahren der Fernerkundung eingesetzt. Dort stehen immer höher auflösende Sensoren zur Verfügung. So sind z.B. IKONOS-Daten in Auflösungen von 1 m panchromatisch und 4 m multispektral und QuickBird-Daten mit 61 cm bzw. 2,44 m Auflösung verfügbar. Die Bildauswertung mit klassischen pixelbasierten Verfahren, wie der überwachten Multispektralklassifizierung, liefert für hoch aufgelöste Bilddaten, die homogene, integrierte Aussagen über Objekte in ihre inhomogenen Bestandteile auflösen, zumeist unzureichende Ergebnisse. Objektbasierte Bildanalyseansätze fassen Pixel homogener Gebiete zu Segmenten zusammen. Dies bietet vielfältige erweiterte Möglichkeiten, auch Kontext oder andere zusätzliche Informationen, wie z.B. Digitale Oberflächenmodelle (DOM) oder vorhandene GIS-Daten mit in die Klassifizierung einzubeziehen. Beispiele zur Nutzung von GIS-Daten für die Objektextraktion sind z.B. in LEUKERT (2002a) beschrieben.

Bilddaten liefern ein Abbild der realen Welt und stellen aufgrund ihrer möglichen Aktualität und breiten Verfügbarkeit eine geeignete Erfassungsquelle für GIS-Daten dar. Schwierigkeiten bei der Automatisierung der Objektextraktion aus Bilddaten resultieren aus dem vielfältigen Erscheinungsbild der Objekte sowie ihrer spektralen Ähnlichkeiten (siehe Abschnitt 2.1.1). Zahlreiche Forschungseinrichtungen beschäftigen sich mit automatisierter Objektextraktion aus Bilddaten, da insbesondere mit der Verfügbarkeit kommerzieller, hoch auflösender Bilddaten auch die Nachfrage nach adäquaten Algorithmen zur Bildanalyse gestiegen ist. Diese Untersuchungen beschränken sich meist auf ein oder wenige Objektklassen, wie zum Beispiel die Extraktion von *man-made* Objekten wie Straßen (BAUMGARTNER et al. 1999), Gebäude (NIEDERÖST 2000) oder auf die Extraktion flächenhafter Objekte (HEIPKE, STRAUB 1999). Dabei handelt es sich meist um Forschungsprojekte, die von einer Praxisreife noch deutlich entfernt sind. Bislang erfolgt zum Großteil eine manuelle Auswertung, da die automatischen Verfahren noch nicht zuverlässig genug sind. Die manuelle Berichtigung von fehlerhaften Ergebnissen nicht ausgereifter automatischer Verfahren kann einen enormen Zeitaufwand darstellen, der die Vorteile der Automatisierung deutlich übersteigen kann (PAKZAD 2001).

GIS-Daten werden meist in Form von Objekten eines Datenmodells in Objektartenkatalogen (OK) definiert und beschrieben. In den Erläuterungen zum ATKIS-Objektartenkatalog Basis-DLM (ADV 2002), ist z.B. über den Zweck, Aufbau und Inhalt Folgendes geschrieben:

„Der Objektartenkatalog (ATKIS-OK) des Amtlichen Topographisch-Kartographischen Informationssystems ATKIS hat die Aufgabe, die Landschaft nach vornehmlich topographischen Gesichtspunkten zu gliedern, die topographischen Erscheinungsformen und Sachverhalte der Landschaft (Landschaftsobjekte; im Folgenden kurz *Objekte* genannt) zu klassifizieren und damit den Inhalt der Digitalen Landschaftsmodelle (DLM) festzulegen sowie die für den Aufbau der DLM erforderlichen Modellierungsvorschriften bereitzustellen. ... Der ATKIS-OK ist attributorientiert aufgebaut. Danach wird die Landschaft nach Objektarten grob und mit Hilfe von Attributen fein gegliedert. ... Um das Auffinden der Objektarten im ATKIS-OK zu unterstützen, ist der Katalog in Objektbereiche und Objektgruppen gegliedert, die die Objektarten nach sachlogischen Gesichtspunkten ordnen.“

Neben den Datenmodellen für amtliche deutsche Informationssysteme, wie z.B. ATKIS und die Automatisierte Liegenschaftskarte (ALK), gibt es eine Reihe anderer digitaler Grunddatenbestände. Stellvertretend seien genannt: Straßendaten zur Navigation, wie z.B. GDF-Daten (*Geographic Data Format*), europaweite Landnutzungsdaten *Corine Landcover* (KIEFL et al. 2003) und militärische Datenbestände wie *VMap Level 1*.

Objektartenkatalog *VMap Level 1*

Im Rahmen dieser Arbeit sollen Objektklassen aus dem OK *VMap Level 1* aus Bilddaten extrahiert werden. Die *Vector Smart Map Level 1* ist ein weltweiter vektorbasierter digitaler Datenbestand mit topographischem Inhalt, dessen Aufbau im Jahre 2004 abgeschlossen wurde. *VMap Level 1* stellt eine topographische Datenbasis mittlerer Auflösung zur Verfügung und wurde in Gemeinschaftsproduktion verschiedener Staaten erstellt. Der Abstraktionsgrad von *VMap Level 1* entspricht dem Maßstab 1 : 250 000. Der globale Datenbestand dient vor allem der Unterstützung von GIS-Anwendungen im Rahmen der kleinmaßstäbigen Visualisierung und Orientierung. Die wichtigste Datenquelle sind die verschiedenen Ausgaben der Kartenserie *Joint Operations Graphics (JOG)* 1 : 250 000 der NATO. Durch die Digitalisierung der *JOG*-Karten, die bis zu 40 Jahre alt sein können, wird deren Generalisierung in den *VMap Level 1*-Datenbestand übernommen. Die Fortführung der *VMap Level 1*-Daten erfolgt jedoch mit aktuelleren Datenquellen, wie z.B. IRS-Satellitenbildern.

Der *VMap Level 1*-OK umfasst 170 Objektklassen, die zum Teil parallel punkt-, linien- und flächenhaft vorkommen können. Die Datenbasis ist thematisch in Ebenen getrennt. Es sind zehn Ebenen (*Coverages*) inklusive ihres topographischen Inhalts definiert:

- *Boundary*
- *Data Quality (Informationen über die verwendeten Datenquellen)*
- *Elevation*
- *Hydrography*
- *Industry*
- *Physiography*
- *Population*
- *Transportation*
- *Utilities*
- *Vegetation*

Zahlreiche Klassen des Objektartenkataloges können nicht aus Bilddaten extrahiert werden. Hierzu zählen u.a. administrative Objekte, wie Staatsgebiet oder -grenze, Waffenstillstandslinie, entmilitarisierte Zone sowie Fährlinie. Die Anzahl der aus Bilddaten automatisiert extrahierbaren Objektklassen hängt von den Eigenschaften des verwendeten Bildmaterials ab. Wichtige Einflussgrößen sind die geometrische und radiometrische Auflösung der Daten und verfügbare Zusatzdaten. OHLHOF et al. (2000) untersuchen, wie viele Objekte des OK *VMap Level 1* in verschiedenen Arten von Satellitenbilddaten überhaupt sichtbar sind. Die Anzahl der sichtbaren Objekte vergrößert sich mit zunehmender geometrischer Auflösung der Bilddaten.

Tabelle 3 zeigt einen Ausschnitt aus dem *VMap Level 1 FACS/FACC Extraction Guide* (VMAP 1997) samt Erfassungskriterien und den zu erfassenden Attributen. In der ersten Spalte ist die Abkürzung der thematischen *Coverage* gegeben, nachfolgend der Name der Objektklasse (*Feature name*), der Code (*FCode*) gemäß *Feature and Attribute Coding Catalog (FACC)*, der Objekttyp (*Type*) und eine Anleitung zur Erfassung des Objektes und seiner Attribute (*Guidance*). Einige der Objektklassen werden je nach Form oder Mindestgröße als Linie oder als Fläche erfasst. Ein Fluss (*River/Stream*) z.B. ist ein linienförmiges Objekt, wenn er schmaler als 125 Meter ist, sonst muss er als flächenhaftes Objekt erfasst werden. Flüsse unter einer Länge von 3.125 m werden nicht erfasst. Für die Objektextraktion spielen diese Unterscheidungen zunächst keine Rolle. In einem zusätzlichen Bearbeitungsschritt nach der Klassifizierung können die extrahierten Daten gemäß der Spezifizierung im Objektartenkatalog aufbereitet werden. Des Weiteren ist aus Tabelle 3 ersichtlich, dass ein Großteil der Attribute nicht aus Bilddaten erfasst werden kann, z.B. das Attribut *NAM (Name)*. Hierfür sind zusätzliche Daten, wie z.B. Karten mit Bezeichnungen der Flüsse erforderlich.

Tabelle 3: Extraction Guide für VMap Level 1

<i>Coverage</i>	<i>Feature Name</i>	<i>FCode</i>	<i>Type</i>	<i>Guidance</i>
HYDRO	River/Stream	BH140	Line	<p>Do not collect if < 3125 meters long; collect as a River/Stream area if >= 125 meters wide.</p> <p>HYC Hydrological Category 0 Unknown 3 Dry 6 Non-Perennial/Intermittent/Fluctuating 8 Perennial / Permanent NAM Name Character text string "UNK" (No entry present for feature) TID Tidal/Non-Tidal Category 0 Unknown 1 Non-Tidal 2 Tidal/Tidal Fluctuation</p>
HYDRO	River/Stream	BH140	Area	<p>Collect as a River/Stream line feature if width < 125 meters.</p> <p>Same attributes like BH140 Line.</p>

Bei der Gewinnung von GIS-Daten aus Luft- oder Fernerkundungsbildern treten einige grundsätzliche Schwierigkeiten auf, die bei der Objektextraktion berücksichtigt werden müssen. Diese Schwierigkeiten beruhen auf dem Unterschied zwischen den Definitionen der GIS-Objekte in den Objektartenkatalogen und den in der Aufnahme abgebildeten Objekten (LEUKERT 2002a). Nachfolgend werden diese Schwierigkeiten erläutert:

- Objekte einer Objektklasse besitzen in der Natur und somit auch in der Aufnahme ein vielfältiges Erscheinungsbild. Abbildung 8 zeigt einen Ausschnitt aus einem DPA¹-Bild mit Hausdächern mit verschiedenen Dachformen und -farben.



Abbildung 8: Vielfältiges Erscheinungsbild einer Objektklasse (Hausdächer: verschiedene Dachformen und -farben)

- Es besteht eine spektrale Konfusion zwischen Objektklassen. D.h., Klassen lassen sich im Merkmalsraum nicht eindeutig voneinander trennen (z.B. Straßen und Dächer).
- Bestimmte Objektklassen und Attribute sind aus dem Bild nicht extrahierbar – Zusatzinformationen sind notwendig (z.B. administrative Grenze, Tunnel und Name von Siedlung).

¹ DPA: Digitale Photogrammetrische Ausstattung (digitales Kamerasystem auf einer Flugzeugplattform, Beschreibung siehe (FRITSCH 1997))

- Gewünschte Objektklassen sind nicht identisch mit Reflexionsklassen. Das Objekt *Kläranlage* erscheint z.B. links in Abbildung 9 als Ansammlung vieler Einzelobjekte, die jeweils verschiedene spektrale Eigenschaften besitzen. Das Objekt *Ackerland* weist in Abbildung 9 rechts viele Reflexionsklassen sowie unterschiedliche Texturen auf.
- Spektral ähnliche Objekte gehören je nach Umgebung/Nachbarschaft zu unterschiedlichen Objektklassen. Ausschließlich anhand ihrer spektralen Merkmale können Bäume in Gärten oder Parkanlagen und Bäume im Wald nicht voneinander unterschieden werden. Diese Trennung kann nur unter Hinzunahme von Kontextinformation erfolgen.



Abbildung 9: Objekt *Kläranlage* (links) und *Ackerland* (rechts)

Die oben aufgelisteten Schwierigkeiten können durch Hinzunahme von Zusatzinformationen und die Wahl spektraler Reflexionsklassen, die nach der Klassifizierung zu Objektklassen gemäß eines gewählten Objektartenkatalogs u.U. unter Zuhilfenahme von räumlicher Nähe, d.h. Kontextinformation zusammengefasst werden, teilweise behoben werden.

Geometrische Mindestauflösung

Die erforderliche minimale Pixelgröße oder geometrische Auflösung eines Bildes hängt von der Anwendung ab, welche die zu extrahierenden Zielobjekte festlegt. Für großflächige Objekte, wie z.B. Wälder reicht eine geringere Auflösung, während kleine und linienförmige Objekte, wie beispielsweise Gebäude und Straßen, deutlich höher aufgelöste Bilddaten benötigen.

In der NATO STANAG 3769 AIR Standard 80/15 *Minimum Resolved Object Sizes and Scales for Imagery Interpretation* sind geometrische Mindestauflösungen für militärische und zivile Objekte, wie z.B. Straße, Eisenbahn und urbane Fläche definiert. Es wird unterschieden zwischen: Entdeckung (*Detection*), Erkennung (*Recognition*), Identifizierung (*Identification*) und Technische Beschreibung (*Technical description*) von Objekten, wobei letztgenannte Kategorie eher für militärische Anwendungen von Bedeutung ist. Die Angaben der geometrischen Mindestauflösungen sind ohne Berücksichtigung anderer Bildeigenschaften wie radiometrische Auflösung aufgeführt. Dennoch können die Angaben als Anhaltspunkte dienen, welche Details in einem Bild mit entsprechender geometrischer Auflösung erwartet werden können. Tabelle 4 listet für die Objekte *Eisenbahn*, *Straße* und *urbane Fläche* die erforderlichen geometrischen Auflösungen auf.

Tabelle 4: Erforderliche geometrische Auflösung für die optische Bildinterpretation nach STANAG 3769

Objekt	<i>Detection</i>	<i>Recognition</i>	<i>Identification</i>	<i>Technical Description</i>
Eisenbahn	15 m	4,5 m	1,5 m	0,38 m
Straße	6 m	4,5 m	1,5 m	0,38 m
Urbane Fläche	60 m	15 m	3 m	0,75 m

JENSEN, COWEN (1999) betrachten neben der geometrischen Auflösung auch temporale und spektrale Aspekte zur Extraktion urbaner Objekte. Die temporale Auflösung gibt an, in welchen zeitlichen Abständen die aus den Bilddaten gewonnenen Informationen benötigt werden. Zusätzlich werden die minimal notwendigen spektralen Kanäle spezifiziert.

Auch hier ist der Zusammenhang der spektralen Eigenschaften eines Objektes mit der räumlichen Auflösung des aufzeichnenden Sensors (PRICE 1997) von Bedeutung. Die Auflösung bestimmt, ob die spektrale Information eines Pixels von einer homogenen Landbedeckungsfläche herrührt und somit spektral rein ist, oder ob mehrere Landbedeckungen innerhalb eines Pixels liegen und es zu Mischpixeln kommt (siehe Abschnitt 2.1.4). Bei einer sehr hohen Auflösung kann z.B. ein Objekt, welches bei mittlerer Auflösung homogen erscheint, heterogen abgebildet werden: Ein Maisfeld kann z.B. in hoher Auflösung aus Boden- und Maispixeln bestehen.

Aufgrund der Komplexität und Vielfalt topographischer Objekte und ihrer Relationen ist eine automatisierte Bildanalyse nur eingeschränkt möglich. Trotz aller Fortschritte in den Bereichen Psychologie, Kognitionswissenschaft und Computer Sehen gibt es keine fundierte Theorie der menschlichen Wahrnehmung. Ein Forschungsschwerpunkt der Arbeiten im Bereich der automatisierten Bildanalyse von Luft- und Satellitenbildern liegt auf der Extraktion von *man-made features* wie Gebäude und Straßen. Ein zuverlässiges, vollautomatisches Gesamtsystem zur Interpretation einer kompletten Szene ist in diesem Bereich derzeit nicht realisiert und auch in naher Zukunft nicht absehbar.

2.3 Evaluierung

In den folgenden zwei Abschnitten wird die Evaluierung der Segmentierung und Klassifizierung beschrieben. Neben rein visuellen Bewertungen werden nachfolgend auch Methoden beschrieben, die quantitative Qualitätsmaße liefern. Hierfür sind in der Regel Referenzdaten, d.h. *Ground Truth*, notwendig, welche meist nicht flächendeckend verfügbar sind oder aufwändig erzeugt werden müssen.

2.3.1 Evaluierung der Segmentierung

Zahlreiche Segmentierungsalgorithmen eignen sich jeweils für bestimmte Arten von Anwendungen und Daten. Bei der Wahl eines geeigneten Segmentierungsalgorithmus und optimaler Parameter für eine Segmentierung spielt neben Faktoren wie Anwenderfreundlichkeit, Schnelligkeit und Verfügbarkeit die Güte des Segmentierungsergebnisses für die spezielle Anwendung die entscheidende Rolle. In der objektbasierten Bildanalyse beeinflusst die Segmentierung in hohem Maße die nachfolgende Klassifizierung.

Im Bereich der Fernerkundung aber auch der Bildanalyse gibt es bislang keine Standardmethode zur Evaluierung von Segmentierungsergebnissen. Zumeist erfolgt eine visuelle Kontrolle des segmentierten Bildes. Für eine Verfahrensautomatisierung sind jedoch quantitative Gütemaße wünschenswert, z.T. auch notwendig, um eine Beurteilung der Zuverlässigkeit der Segmentierung zu bekommen. In (HARALICK, SHAPIRO 1985, S. 100) wird eine qualitative Beschreibung einer „guten“ Segmentierung gegeben:

„What should be a good image segmentation? Regions of an image segmentation should be uniform and homogeneous with respect to some characteristic such as gray tone or texture. Region interiors should be simple and without many holes. Adjacent regions of a segmentation should have significantly different values with respect to the characteristic on which they are uniform. Boundaries of each segment should be simple, not ragged, and must be spatially accurate.“

Eine "gute" Segmentierung zeichnet sich demnach durch folgende Kriterien aus:

- homogene Segmente
- wenig Löcher in den Segmenten
- angrenzende Segmente sollten sich hinsichtlich der Homogenitätskriterien deutlich unterscheiden
- Segmentgrenzen sollten nicht ausgefranst und geometrisch korrekt sein.

Zusätzlich hängt die Güte einer Segmentierung von den Anforderungen der speziellen Anwendung ab.

Visuelle Bewertung von Segmentierungen

„... a human being is the ultimate judge to make an evaluation of the (segmentation – Anm. d. Verf.) result.“ (PAL, PAL 1993)

Oft erfolgt eine visuelle Beurteilung des Segmentierungsergebnisses. Selbst wenn quantitative Maße auf eine gute Segmentierung hindeuten, kann der Mensch eine Segmentierung als unzureichend empfinden. Ein optisch zufrieden stellender Eindruck wird oftmals erreicht, indem lokale Kontraste sowie die Forderungen nach etwa gleich großen Segmenten und nicht ausgefranst Segmenträndern berücksichtigt werden (eCognition USER GUIDE 2004). Insbesondere bei topographischen Objekten in Fernerkundungs- und Luftbildern zeigt die Erfahrung, dass verschiedene Auswerter Segmente unterschiedlich abgrenzen, da oftmals keine klaren Grenzen zwischen benachbarten Objekten erkennbar sind (zum Beispiel bei texturierten Objekten wie Wald). Dies erschwert die manuelle Erstellung einer Referenzsegmentierung, die zur quantitativen Evaluierung des Segmentierungsergebnisses herangezogen werden kann.

Bewertung von Segmentierungen mit Qualitätsmaßen

Quantitative Evaluierungsmethoden für Segmentierungen können nach YANG et al. (1995) in zwei Kategorien unterteilt werden: überwachte und unüberwachte. Bei einer **unüberwachten Evaluierung** werden aus dem segmentierten Bild quantitative Maße, wie z.B. *Region uniformity*, *Region contrast*, *Line contrast* und *Line connectivity* (LEVINE, NAZIF 1985) berechnet, die Aussagen über die Güte einer Segmentierung geben sollen. *Region uniformity* und *Region contrast* beruhen z.B. auf der Annahme, dass Eigenschaften innerhalb eines Segments einheitlich und zwischen benachbarten Segmenten unterschiedlich sein sollten.

Bei einer **überwachten Evaluierung** wird hingegen die Differenz zwischen einer (in der Regel manuell erzeugten) Referenzsegmentierung und dem Segmentierungsergebnis berechnet und bewertet. Gängige Maße sind: *Probability of error*, *Pixel distance error* (hierbei wird die Position der falsch segmentierten Pixel mit in Betracht gezogen) und *Ultimate measurement accuracy* (UMA). Das Maß *Probability of error* kann zusätzlich noch in einen Über- und einen Untersegmentierungsfehler unterteilt werden.

Einen weiteren Überblick über Methoden zur Evaluierung von Segmentierungen gibt ZHANG (1996). Die Evaluierungsmethoden werden dort in zwei Kategorien unterteilt: analytisch und empirisch. Bei der **analytischen Methode** wird direkt der Segmentierungsalgorithmus mit seinen Prinzipien und Eigenschaften untersucht. Hingegen wird bei den **empirischen Methoden** die Qualität des Segmentierungsergebnisses bewertet. Es folgt eine weitere Unterteilung der empirischen Methoden in *Goodness* und *Discrepancy* Methoden. Die *Goodness* Methoden entsprechen einer unüberwachten Evaluierung in (YANG et al. 1995), mit Maßen wie *Region uniformity* (z.B. Varianz eines Merkmals), *Contrast* und *Region shape*. Für die empirischen *Discrepancy* Methoden ist eine Referenzsegmentierung notwendig. Sie entsprechen bei YANG et al. (1995) einer überwachten Evaluierung. Bewertungsmaße können sein: Prozentzahl der falsch segmentierten Pixel, relative Position der falsch segmentierten Pixel, Anzahl der Objekte im Bild, *Feature values* von segmentierten Objekten, wie z.B. geometrische Eigenschaften (Fläche, Formeigenschaften und Umfang).

Die **Evaluierungsfunktion** von LIU, YANG (1994) berücksichtigt direkt oder indirekt die ersten drei der vier heuristischen Kriterien von HARALICK, SHAPIRO (1985), die eingangs dieses Abschnitts aufgelistet sind. Die empirische Definition der Evaluierungsfunktion enthält neben der Bildgröße in Pixeln, die Anzahl der Segmente sowie die Fläche und einen so genannten „mittleren Farbfehler“ für jedes Segment. BORSOTTI et al. (1998) untersuchen verschiedene Segmentierungsalgorithmen und berechnen jeweils die Evaluierungsfunktion von LIU, YANG (1994) für das segmentierte Bild. Besonders bei verrauschten Bildern erweist sich diese Evaluierungsfunktion als nicht brauchbar. Nach einer kritischen Analyse der Stärken und Schwächen der Evaluierungsfunktion von LIU, YANG (1994) werden in (BORSOTTI et al. 1998) zwei modifizierte Funktionen vorgestellt, welche zum einen die Stärken der Evaluierungsfunktion beibehalten und zum anderen die Schwächen minimieren.

Bei den Untersuchungen von Bewertungsmaßen zur Evaluierung von Segmentierungsergebnissen werden in der Regel künstliche Bilder (z.B. SCHOUTEN, GEBBINCK 1995, ZHANG 1996, PAL, PAL 1993), medizinische Aufnahmen (z.B. YANG et al. 1995) oder Testbilder aus Datenbanken, wie z.B. Gebäudeaufnahmen oder Bilder von Paprikaschoten (z.B. HUANG, DOM 1995, BORSOTTI et al. 1998, FREIXENET et al. 2002, LEVINE, NAZIF 1985) verwendet. HOOVER et al. (1996) stellen ein Rahmenwerk zur Evaluierung von Segmentierungsalgorithmen für Tiefenbilder vor. Untersuchungen zur Evaluierung von segmentierten Fernerkundungsbildern, einem Ziel dieser Arbeit, fehlen. Die Erstellung einer Referenzsegmentierung ist vor allem wegen des großen Aufwandes für diese nur in Ausnahmefällen zu Testzwecken möglich. Die aufgeführten quantitativen Evaluierungsmaße, die keine Referenzsegmentierung erfordern, besitzen folgende Schwachpunkte: Sie liefern zumeist einen einzigen, globalen Wert für die Segmentierung. Alle Segmente werden gleich behandelt, es wird nicht zwischen unterschiedlichen Objektklassen unterschieden. Dies wäre aber bei einer Evaluierung der Segmentierung von topographischen Objekten hilfreich, da das Erscheinungsbild zwischen verschiedenen Objektklassen stark variieren kann. Neben der Form der zu extrahierenden Objekte spielt auch die Textur eines Objektes eine entscheidende Rolle für die Bewertung der Segmentierung. Das führt zu der in dieser Arbeit verwendeten praktischen Vorgehensweise, nicht die Segmentierung für sich zu beurteilen, sondern den Gesamtprozess Segmentierung und Klassifizierung zu evaluieren.

2.3.2 Evaluierung der Klassifizierung

Die folgenden Abschnitte stellen Verfahren zur Evaluierung von Multispektralklassifizierung sowie objektbasierter Klassifizierung vor.

Accuracy Assessment bei Multispektralklassifizierung

Ein Standardwerkzeug zur Beurteilung der Qualität einer Klassifizierung ist die so genannte „Konfusions-“, oder „Fehlermatrix“. In einer tabellarischen Auflistung werden - meist zufällig ausgewählte Pixel - ihrer Klassenzugehörigkeit aus *Ground Truth* oder Referenzdaten gegenübergestellt. Die Anzahl der Referenzpixel richtet sich nach dem Umfang der klassifizierten Daten, es können auch alle Pixel als Referenz verwendet werden. Der Aufwand hierfür wäre allerdings enorm. Eine Faustregel besagt, dass pro Landbedeckungsklasse ein Minimum von 50 Referenzpixeln zur Verfügung stehen sollte. Aus der Konfusionsmatrix (Abbildung 10) können weitere Maße abgeleitet werden, wie z.B. die *Overall Accuracy (OA)*. Sie gibt die Prozentzahl der korrekt klassifizierten Pixel an und berechnet sich aus der Summe der Hauptdiagonalen (korrekt klassifizierte Pixel) dividiert durch die Gesamtanzahl der ausgewählten Referenzpixel n . Jedoch gibt die *OA* keinerlei Informationen über die Qualität der einzelnen Klassen k . Für eine detailliertere Qualitätsbeschreibung der einzelnen Objektklassen können neben dem *Kappa Index* (siehe nächster Absatz) aus der Matrix die *User's* und *Producer's Accuracy* berechnet werden. Die *User's Accuracy (UA)* gibt die Wahrscheinlichkeit an, mit der ein klassifiziertes Pixel derselben Klasse in den Referenzdaten entspricht. Dagegen entspricht die *Producer's Accuracy (PA)* der Wahrscheinlichkeit, mit der ein Pixel der Referenzklasse j korrekt klassifiziert wurde. Der Name „Herstellergenauigkeit“ rührt daher, dass dieses Maß aussagt, wie gut die Klassifizierung mit den Referenzdaten übereinstimmt. Die *UA* gibt dem Anwender die wichtige Informati-

on, wie sicher ein als Klasse i klassifiziertes Pixel auch wirklich der gleichen Klasse in den Referenzdaten entspricht (CONGALTON, GREEN 1999).

Der *Kappa Index* (KI) verbindet PA und UA und berechnet sich aus der Differenz zwischen der tatsächlichen Übereinstimmung der Klassifizierung mit der Referenz (d.h. korrekt klassifizierte Pixel der Hauptdiagonalen der Konfusionsmatrix) und einer inkorrekten Übereinstimmung, die durch die Zeilen- und Spaltensummen (Werte abseits der Hauptdiagonalen) gekennzeichnet ist. Bei einer perfekten Übereinstimmung zwischen Klassifizierung und Referenzdaten ist der Wert des *Kappa Index* gleich eins, bei gleichen Anteilen von korrekten und inkorrekten Übereinstimmungen null und bei keinerlei Übereinstimmung minus eins. Der KI kann auch für einzelne Klassen der Konfusionsmatrix berechnet werden. Den nachfolgenden Formeln zur Berechnung der verschiedenen Qualitätsmaße ist zu entnehmen, dass der KI im Gegensatz zu OA , UA und PA alle Elemente der Konfusionsmatrix zur Berechnung verwendet. Der Wert des KI ist entsprechend der Berechnungsformel immer kleiner gleich der OA . LANDIS, KOCH (1977) gruppieren die Übereinstimmung einer Klassifizierung mit den Referenzdaten gemäß dem Wert für KI in sechs Kategorien. Die drei höchsten Kategorien lauten: *moderate* (0,41-0,6), *substantial* (0,61-0,8) und *almost perfect* (0,81-1).

		Referenz (Spalten)				Zeilen- summe n_{i+}
		1	2	3	k	
Klassifizierung (Zeilen)	1	n_{11}	n_{12}	n_{13}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{23}	n_{2k}	n_{2+}
	3	n_{31}	n_{32}	n_{33}	n_{3k}	n_{3+}
	k	n_{k1}	n_{k2}	n_{k3}	n_{kk}	n_{k+}
Spalten- summe n_{+j}		n_{+1}	n_{+2}	n_{+3}	n_{+k}	n

Abbildung 10: Konfusionsmatrix

$$\text{Overall Accuracy} = \frac{\sum_{i=1}^k n_{ii}}{n} \cdot 100,$$

n_{ii} = Elemente der Hauptdiagonalen,
 n = Anzahl der Referenzpixel

$$\text{User's Accuracy} = \frac{n_{ii}}{n_{i+}},$$

n_{ii} = korrekt klassifizierte Pixel der Klasse i ,
 n_{i+} = Zeilensumme der Klasse i

$$\text{Producer's Accuracy} = \frac{n_{jj}}{n_{+j}},$$

n_{jj} = korrekt klassifizierte Pixel der Referenz j ,
 n_{+j} = Spaltensumme der Referenz j

$$\text{Kappa Index} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}}, \quad k = \text{Anzahl der Klassen}, \quad n = \text{Anzahl der Referenzpixel}$$

Zur Beurteilung der Qualität von Klassifizierungen genügt laut STEHMAN (1997) in der Regel kein einzelnes Qualitätsmaß. Mehrere Qualitätsmaße können jedoch zu widersprüchlichen Aussagen führen, da sie unterschiedliche Aspekte der Qualität repräsentieren (Nutzung verschiedener Informationen der Konfusionsmatrix).

Die Konfusionsmatrix hat sich weitgehend als Standard zur Qualitätsbeschreibung von Klassifizierungen durchgesetzt, da sie die Übereinstimmung der Klassifizierung mit Referenzdaten oder *Ground Truth* belegt. Es sei jedoch angemerkt, dass es eine Reihe von Einflussfaktoren auf die Qualitätsmaße gibt. Die Referenzdaten werden als fehlerfrei angenommen, was sicherlich nur für synthetische Daten zutrifft. Die Erfassung von Referenz- und Bilddaten kann zu unterschiedlichen Zeiten erfolgt sein, was zu Änderungen geführt haben kann. Des Weiteren können Fehler durch unzureichende Registrierung

von Bild- und Referenzdaten auftreten. Eine weitere, meist nicht zutreffende Annahme ist das Vorliegen reiner Pixel. In der Realität gibt es aber neben Pixeln, die eindeutig einer Klasse zugeordnet werden können, auch Mischpixel. Diese Pixel, die mehrere Klassen beinhalten, sind ein generelles Problem bei der Bildklassifizierung (siehe Abschnitt 2.1.4). Ferner treffen die Konfusionsmatrix und die aus ihr abgeleiteten Fehlermaße keinerlei Aussagen über die räumliche Verteilung der Klassifizierungsfehler (FOODY 2002).

Accuracy Assessment bei objektbasierter Klassifizierung

Die oben aufgeführten Standardmaße zur Qualitätsbetrachtung bei pixelbasierter Klassifizierung können auch für objektbasierte Klassifizierungsergebnisse angewandt werden. Allerdings werden in diesem Fall nur einzelne Pixel betrachtet, die Objektinformation bleibt unberücksichtigt. Derzeit mangelt es an Standardmaßen zur Qualitätsbetrachtung bei objektbasierter Klassifizierung. Es gibt Ansätze, zusätzliche Objektmerkmale zur Evaluierung hinzuzuziehen. ZHAN et al. (2003) schlagen für die Qualitätsbetrachtung von Gebäuden aus objektbasierter Extraktion im Vergleich zu Referenzdaten folgende Maße vor:

- Anzahl der Gebäudeobjekte (in Extraktion und Referenz)
- Vergleich der Objektgröße
- Vergleich der Lage (Abstand zwischen den Schwerpunkten)

Aus der Anzahl der Gebäudeobjekte kann die so genannte „Konsistenz“ und die Vollständigkeit berechnet werden. Konsistenz bezeichnet hier das Verhältnis der Anzahl korrekt klassifizierter Gebäudeobjekte zur Anzahl der als Gebäude klassifizierten Objekte. Vollständigkeit beschreibt das Verhältnis der Anzahl der korrekt klassifizierten Gebäudeobjekte zur Anzahl der Gebäude im Referenzdatensatz. Bei *man-made features* wie Gebäuden ist die Definition eines Objektes offensichtlich. Bei topographischen Objekten, wie Wald und Felder, ist oft keine eindeutige Objektbildung möglich und somit bleibt die automatische objektbasierte Qualitätsbetrachtung bisher weitgehend ungelöst.

2.4 Stand der Wissenschaft

2.4.1 Anwendungen auf Basis klassischer Klassifizierungsverfahren

Alle gängigen, kommerziell verfügbaren Bildverarbeitungsprogramme aus dem Bereich Fernerkundung, wie z.B. ERDAS Imagine, beinhalten als Kernbestandteil multispektrale Klassifizierungsverfahren. Diese klassischen, pixelbasiert arbeitenden Verfahren werden hauptsächlich zur Landbedeckungs- und Landnutzungskartierung eingesetzt. Multispektrale Bilddaten mittlerer bis grober Auflösung finden in zahlreichen Projekten Anwendung. Verfahren der Multispektralklassifizierung eignen sich nicht für höher aufgelöste Bilddaten, da diese eine hohe Komplexität aufweisen und Objekte nicht allein aufgrund spektraler Merkmale trennbar sind. Typische Anwendungen der Multispektralklassifizierung sind großflächiger Natur und kommen aus den Bereichen Beobachtung von Naturkatastrophen, Waldflächeninventur, Erfassung von Grünflächen oder Stadtwärmeinseln, Versiegelungsanalyse und viele mehr. Nachfolgend sind ausgewählte Projekte beschrieben, welche die Multispektralklassifizierung mit verschiedenen Erweiterungen verwenden.

Die Trainingsgebiete stellen bei der überwachten Multispektralklassifizierung die Stichprobe für die spätere statistische Auswertung dar. Sie werden in der Regel manuell durch Zeichnen eines Polygons oder durch *Region Growing* Algorithmen (siehe Abschnitt 2.1.2) festgelegt. Die Definition von Trainingsgebieten kann unter Verwendung vorhandener GIS-Daten automatisiert werden, so dass ein Zeitgewinn gegenüber einer manuellen Auswahl erreicht wird. Insbesondere zur Datenaktualisierung werden bestehende GIS-Daten als Vorwissen für die Klassifizierung eingebracht.

WALTER (1998) stellt ein vollautomatisches Verfahren zur Verifizierung von ATKIS-Daten mit DPA-Bildern vor. In einem ersten Schritt wird eine überwachte *Maximum Likelihood*-Klassifizierung durchgeführt. Die Trainingsgebiete dafür werden automatisch aus vorhandenen GIS-Daten generiert.

WALTER (1998) trifft die Annahme, dass Anzahl und Fläche der falsch erfassten GIS-Objekte und der Änderungen in der realen Welt klein gegenüber Anzahl und Fläche aller GIS-Objekte eines Datensatzes sind. Werden Trainingsgebiete aus vorhandenen GIS-Daten generiert, so erzielt man eine hohe Quantität aber schlechtere Qualität der Trainingsgebiete. Problematisch beim Kombinieren von GIS- und Bilddaten ist die geometrische Übereinstimmung. Daher werden die automatisch generierten Trainingsgebiete durch Berechnung eines Puffers um die GIS-Objekte verkleinert. Mit diesem Verfahren konnten Inkonsistenzen zwischen den ATKIS- und DPA-Daten aufgedeckt werden.

In (HEIPKE, STRAUB 1999) wird ein Verfahren zur automatischen Aktualisierung von Vegetationsflächen im ATKIS Basis-DLM unter Nutzung der DLM-Daten als Vorwissen vorgestellt. Mit Hilfe der DLM-Daten werden automatisch aus IRS-Satellitenbildern spektrale Signaturen für Vegetationsflächen generiert. In (ARMENAKIS 2000) wird ein Verfahren zur Aktualisierung von GIS-Daten vorgestellt, das fusionierte panchromatische und multispektrale IRS-Bilddaten sowie bestehende GIS-Daten kombiniert. Zur Definition der Trainingsgebiete werden die GIS-Daten dem Satellitenbild visuell überlagert und erleichtern so die Auswahl geeigneter Trainingsgebiete. Nach einer überwachten *Maximum Likelihood*-Klassifizierung werden durch den manuellen Vergleich der Kartendaten mit der Klassifizierung Änderungen aufgedeckt.

Vegetationskartierung basierend auf multitemporalen Landsat TM-Daten und topographischen Kartendaten stellt BRONGE (1999) vor. Aus den topographischen Karten werden sechs verschiedene digitale Masken für eine schrittweise Klassifizierung erzeugt. Während eines *Maximum Likelihood*-Klassifizierungsschrittes ist nur eine begrenzte Anzahl relevanter Klassen erlaubt. Mit Hilfe dieser Maskierungstechnik werden Fehlklassifizierungen verringert.

Ein Verfahren zur Detektion von bebautem Gebiet aus panchromatischen SPOT- und IRS-Daten wird in (BUSCH 1998) präsentiert. Hierbei wird die Eigenschaft ausgenutzt, dass die Dichte an linienhaften und kurzen Merkmalsstrukturen in bebauten Gebieten höher als in anderen Objektklassen ist. Vorhandene GIS-Daten werden als Trainingsgebiete für die zwei Objektklassen *Bebautes Gebiet* und *Nicht bebautes Gebiet* aufbereitet. Auch in (STEINNOCHER 1997) wird Texturinformation zur Klassifizierung von Siedlungen in panchromatischen IRS-Satellitenbilddaten genutzt. Das *Inverse Difference Moment* (siehe Tabelle 2, Abschnitt 2.1.3) wurde als Texturmerkmal verwendet. Die beiden ausgewählten Veröffentlichungen zeigen, dass für einige Anwendungen die Kombination von Klassifizierungsverfahren mit Texturinformation gute Ergebnisse liefert.

SINDHUBER (1998) stellt ein Klassifizierungsverfahren vor, welches die *Maximum Likelihood*-Klassifizierung erweitert. Zusätzlich zu den Klassen mit der größten Wahrscheinlichkeitsdichte werden auch die Klassen mit der zweitgrößten Wahrscheinlichkeitsdichte mit in die Auswertung einbezogen. Auf Grundlage des Vergleichs der Wahrscheinlichkeitsdichten können Aussagen über die Eindeutigkeit der multispektral zugewiesenen Klasse getroffen werden. Die Resultate der Multispektralklassifizierung (Landsat TM) werden mit Texturdaten aus panchromatischen Bilddaten (IRS und SPOT) sowie Informationen aus dem digitalen Landschaftsmodell des österreichischen Bundesamtes für Eich- und Vermessungswesen mit Hilfe eines hierarchischen Regelwerkes kombiniert. Das Verfahren wurde erfolgreich anhand der Erstellung von GIS-Daten für das DLM demonstriert.

2.4.2 Wissensbasierte Verfahren

Im Folgenden werden ausgewählte Arbeiten aus dem Bereich der wissensbasierten Objektextraktion vorgestellt. Die Verfahren sind in der Regel auf eine oder wenige Objektklassen spezialisiert. Wissensbasierte Verfahren verwenden bislang hauptsächlich höher aufgelöste Bilddaten.

MAYER (1999) gibt einen breiten Überblick über Verfahren der automatischen Gebäudeextraktion aus Luftbildern, ein Thema, mit dem sich auch zahlreiche Dissertationen beschäftigen, u.a. AMERI (2000), BRENNER (2000), BRUNN (2001), KOLBE (2000), LANG (1999) und NIEDERÖST (2003). Alle diese Arbeiten verwenden Bilddaten von weit unter einem halben Meter Auflösung und benötigen zwei-

oder mehrfache Überdeckung für eine 3D-Rekonstruktion. Deshalb wird auf diese Arbeiten nicht näher eingegangen.

Ein Überblick über Verfahren zur Extraktion von Straßen aus optischen Luft- und Satellitenbilddaten wird in (WIEDEMANN 2001) gegeben. Auch MAYER (1998) beschäftigt sich schwerpunktmäßig mit Ansätzen zur Straßenextraktion. Der Großteil der Verfahren zur Straßenextraktion nutzt hoch aufgelöste Luftbilder. Ansätze mit Satellitenbilddaten sind selten, da bis zum Aufkommen der neuen Generation hoch auflösender Satelliten nicht die für die automatische Straßenextraktion erforderliche geometrische Auflösung vorhanden war. Ein Verfahren zur automatischen Extraktion von Straßen aus digitalen Luftbildern wird in (BAUMGARTNER et al. 1999) vorgestellt. Grundlage bilden verschiedene Auflösungsstufen der Bilddaten, Netzbildung der Straßen und Hinzunahme von Kontext. Es wird zwischen lokalem und globalem Kontext unterschieden. Ersterer kann z.B. in dem Schattenwurf von Bäumen auf Straßenstücke bestehen, während der globale Kontext verschiedene Typen von Landschaft beschreibt, z.B. offene Landschaft, Wald und Siedlung. Der Ansatz von BACHER, MAYER (2004) zur Extraktion von Straßen in Gebieten Nordafrikas aus IRS-Satellitenbilddaten nutzt ebenfalls globalen Kontext. Die Landschaft wird hierbei in die Typen *Wüste*, *Gebirge* und *landwirtschaftlich genutzte Gebiete* eingeteilt. Für die Straßenextraktion werden für den jeweiligen Landschaftstyp unterschiedliche Strategien eingesetzt. Die Extraktion in der *Wüste* und im *Gebirge* beruht in erster Linie auf der Linienextraktion mit unterschiedlichen Parametern. In *landwirtschaftlichen Gebieten* erscheinen Straßen nicht nur als Linien, sondern häufig als Feldgrenzen. Letzteres wird durch die zusätzliche Extraktion von Kanten sowie deren Verfolgung mittels *Snakes* berücksichtigt.

PAKZAD (2001) stellt ein automatisches Verfahren zur wissensbasierten Interpretation von industriell genutzten Moorflächen aus multitemporalen Fernerkundungsdaten vor. Die in der Landschaft vorkommenden Objektarten werden in Abhängigkeit von den charakteristischen Eigenschaften in unterschiedliche Kategorien eingruppiert. Für jede Kategorie werden separate Interpretationsstrategien vorgeschlagen, die ihren Niederschlag im Aufbau des verwendeten semantischen Netzes als auch der Erstellung spezieller Bildverarbeitungsoperatoren finden. Die Interpretation der Moorflächen geht von mittels einem GIS vorgegebenen Segmentgrenzen aus und innerhalb dieser Grenzen wird nach charakteristischen Strukturen gesucht und deren Verhalten über die Zeit betrachtet. Das Verfahren wurde erfolgreich mit Farbinfrarotluftbildern getestet.

KUNZ et al. (1998, S. 220ff.) beschreiben eine integrierte Verarbeitung von Satellitenbild und GIS-Information. Daten des Digitalen Landschaftsmodells DLM200 werden zur Abgrenzung der Trainingsgebiete in Landsat TM-Daten eingesetzt. Nach einer wissensbasierten Segmentierung werden die Merkmalsausprägungen der Segmente bestimmt. Mögliche Merkmale sind neben spektraler Signatur und Textur auch Größe, Form und Nachbarschaft. Das Wissen wird im *Erlanger Semantischen Netzwerksystem* (ERNEST, NIEMANN et al. 1990) abgelegt. In (QUINT 1997) wird Wissen aus topographischen Karten mit ERNEST modelliert und vom System verwendet, um automatisch eine Beschreibung komplexer urbaner Szenen zu erstellen. Es kommen großmaßstäbige Farbluftbilder mit einer Auflösung von 0,3 m und die Deutsche Grundkarte (DGK) 1 : 5 000 zum Einsatz. Zielobjekte der wissensbasierten Interpretation sind die Objekte *Gebäude*, *Grünflächen*, *Parkplätze* und *Kraftfahrzeuge*.

In (GROWE 2001) wird in einem generischen Szenenmodell in Form eines semantischen Netzes allgemein gültiges Wissen über die Objekte in Form von Informationen über Sensorabbildung und über zeitliche Veränderungen der Objekte abgelegt. Darüber hinaus werden im vorgestellten System „AIDA“ GIS-Daten als szenenspezifisches Vorwissen zur Auswertung multitemporaler Luftbilder genutzt. GIS-Daten dienen zur Ableitung von Hypothesen über die Existenz und Lage von Szenenobjekten. Auch das Vorwissen wird explizit im semantischen Netz abgelegt. Beispielhaft werden die Objekte *Straße* und *Messegelände* behandelt. Das System „AIDA“ wurde bereits in (TÖNJES 1999) zur wissensbasierten Interpretation und 3D-Rekonstruktion von Landschaftsszenen aus Luftbildern genutzt.

2.4.3 Vergleich pixelbasierter mit objektbasierten Verfahren

Zahlreiche Publikationen beschäftigen sich mit dem Vergleich von pixelbasierten Verfahren (Multi-spektralklassifizierung) und objektbasierter Bildanalyse. Zur Waldklassifizierung verwenden KOCH et al. (2003) eine pixelbasierte Klassifizierung von fusionierten Landsat TM und panchromatischen IRS-Bildern im Vergleich sowie zur Ergänzung zum objektbasierten Verfahren. Die beste Gesamtgenauigkeit der Klassifizierungen in *Nadel-, Misch-, Laubwald* und *offenen Wald* wird mit dem objektbasierten Verfahren erzielt. FLANDERS et al. (2003) kommen für eine Forstanwendung mit Landsat TM-Bildern zu demselben Schluss. MEINEL et al. (2001) vergleichen anhand von IKONOS-Daten ein pixelbasiertes Verfahren mit einem objektbasierten Ansatz. Die Autoren folgern aus ihren Ergebnissen, dass die Hinzunahme weiterer Objektinformationen, wie Form und Nachbarschaftsbeziehungen, bei dem objektbasierten Ansatz differenziertere Klassifizierungsschlüssel als bei den pixelbasierten Standardklassifizierungsverfahren zulässt. Diese Erkenntnis wird auch in (DARWISH et al. 2003) für IRS- und Landsat TM-Daten sowie in (KIRSTEIN, LINDE 2004) für IKONOS-Daten bestätigt.

SHACKELFORD und DAVIS (2003) verwenden einen kombinierten pixel- und objektbasierten Ansatz zur *Fuzzy*-Klassifizierung von städtischer Landbedeckung in IKONOS-Bildern. Aufbauend auf der hierarchischen, pixelbasierten Klassifizierung wird eine objektbasierte Klassifizierung durchgeführt, um bestehende Objektklassen in spezifischere Klassen einzugruppieren. Die Klassifizierungsergebnisse zur Diskriminierung von Gebäuden und anderen versiegelten Flächen bei unterschiedlichen Kombinationen von Objekteigenschaften werden gegenübergestellt. Die besten Resultate werden bei Kombination spektraler Merkmale, Formeigenschaften und Nachbarschaft zu Schattenflächen erzielt. Eine hierarchische, pixelbasierte *Fuzzy*-Klassifizierung, die neben spektralen auch räumliche Informationen, wie Textur sowie Länge und Breite von spektral ähnlichen, benachbarten Pixelgruppen berücksichtigt, ergibt eine Genauigkeitssteigerung im Vergleich zu einer klassischen Multispektralklassifizierung.

In (SCHERER, MEININGER 2002) wird ein Verfahren zur objektbasierten Klassifizierung von Rasterdaten unter Verwendung pixelbasierter Klassifikatoren vorgestellt, welches durch die Kombination die Vorteile objekt- und pixelbasierter Algorithmen zur Klassifizierung von Rasterdaten verbindet. In einem ersten Schritt werden die Bilddaten pixelweise klassifiziert. Die Segmentierung der Rasterdaten erfolgt in einem zweiten Schritt und es werden die Häufigkeiten der jeweiligen Klassen in den Segmenten berechnet. Alle Pixel innerhalb eines Segmentes werden der Klasse mit der größten Häufigkeit zugewiesen. Das Verfahren wird anhand von Landsat TM-Daten mit gutem Erfolg beispielhaft demonstriert.

2.4.4 Übertragung der Objektextraktion

Übertragung pixelbasierter Klassifizierung

Bei überwachter, pixelbasierter Klassifizierung werden die Klassenbeschreibungen aus Trainingsgebieten gewonnen (siehe Abschnitt 2.1.4). Durch statistische Analyse dieser Trainingsgebiete werden spektrale Signaturen abgeleitet und die Bildelemente aufgrund ihrer Ähnlichkeit mit diesen Signaturen klassifiziert. Die Definition der Trainingsgebiete ist bislang eine interaktive und somit zeit- und kostenintensive Arbeit. Für eine Automatisierung der Klassifizierung ist die Übertragung der aus Trainingsgebieten gewonnenen spektralen Signaturen vorstellbar. Hinderlich sind hierbei aber Unterschiede in den Bildern, die durch atmosphärische Einflüsse sowie Beleuchtungs- und Abschattungseffekte hervorgerufen werden. Für die Übertragung spektraler Signaturen aus Trainingsgebieten auf multitemporale Daten oder andere Gebiete ist nach SONG et al. (2001) für Bildklassifizierung und *Change Detection* Methoden eine atmosphärische Korrektur unumgänglich.

RHEIN (1999) umgeht das Problem der spektralen Variabilität zwischen Szenen desselben Gebiets zu unterschiedlichen Zeitpunkten, indem die spektralen Signaturen nicht direkt übertragen werden. Die

Trainingsgebiete werden in einer Datenbank gespeichert. Sie liegen als ATKIS-Daten, topographische Karten oder *Ground Truth* Daten vor und können auch zur Evaluation der Ergebnisse herangezogen werden. Diejenigen Daten werden als Trainingsgebiete verwendet, die räumlich und zeitlich am Besten zu den zu klassifizierenden Bilddaten passen. Es werden nicht die spektralen Signaturen an sich übertragen, sondern die Trainingsgebietsgrenzen. Innerhalb eines Trainingsgebietes erfolgt eine Neuberechnung der spektralen Signatur mit anschließender Kontrolle des Histogramms auf Normalverteilung. Zur *Change Detection* von ATKIS-Daten verwendet WALTER (1998) ebenfalls eine überwachte Multispektralklassifizierung. Die erforderlichen Trainingsgebiete werden automatisch aus vorhandenen ATKIS-Daten erzeugt. Wie bei RHEIN (1999) erfolgt die Berechnung der spektralen Signaturen aus dem aktuell zu untersuchenden Bild. Diese Verfahren funktionieren nur für Gebiete, in denen GIS-Daten oder Trainingsgebiete vorhanden sind. Die Übertragbarkeit auf andere Gebiete ohne bereits existierende Daten ist nicht möglich.

Zur Speicherung und Wiederverwendung spektraler Signaturen gibt es zahlreiche Spektralbibliotheken, wie z.B. die *ASTER Spectral Library*. Es handelt sich hierbei um eine Sammlung von ca. 2000 Spektren, die aus drei Quellen (Johns Hopkins University (JHU), Jet Propulsion Laboratory (JPL) und U.S. Geological Survey (USGS)) zusammengestellt ist (<http://speclib.jpl.nasa.gov>). Die spektralen Eigenschaften verschiedenster Materialien aus Kategorien wie Mineralien, Flüssigkeiten, *man-made* Materialien und Vegetation sind in der Bibliothek abgelegt. Eine weitere Sammlung mit mehr als 800 Spektren ist MedSpec (http://www.landwatermed.net/cameleo/uk/res_medspec.html). Die Spektren stammen aus Testgebieten in den Ländern Marokko, Algerien, Tunesien und Ägypten und sind speziell für Anwendungen im Bereich Desertifikation/Devastierung gedacht. Zur Nutzung der spektralen Signaturen aus Bibliotheken müssen die Bilder zuvor radiometrisch und topographisch korrigiert werden. Üblicherweise sind die spektralen Informationen nur für Materialien verfügbar, nicht aber für komplexe, semantische Objekte, wie Daten eines GIS (beispielsweise Objektklasse *Siedlung*, *landwirtschaftliche Fläche*).

Übertragung objektbasierter Analyse

Unter Übertragung objektbasierter Analyse versteht man im Weiteren die Anwendung von Regelsätzen auf Bilder, für welche die Regelsätze nicht optimiert wurden. Nachfolgend werden ausgewählte Arbeiten auf diesem Gebiet vorgestellt.

KRESSLER et al. (2003b) testen anhand zweier panchromatischer Bilder unterschiedlicher Sensoren die Übertragung eines für ein Bild optimierten Regelsatzes zur Waldextraktion. Beide Bilder decken das identische Testgebiet ab. Sie besitzen die gleiche spektrale, aber eine unterschiedliche geometrische Auflösung (KOMPSAT-1: 6,6 m und SPOT-5: 2,5 m Pixelgröße). Der Regelsatz für die Klassen *Waldlichtungen*, *Wald*, *landwirtschaftliche Flächen*, *urbane Flächen* und *Hauptstraßen* wurde anhand des KOMPSAT-1-Bildes entwickelt und dann auf die SPOT-Szene angewendet. Zur Überprüfung der Robustheit des Regelsatzes wurden aufgrund der in Abschnitt 2.1.1 beschriebenen Einflüsse nur spektrale Merkmale im Regelsatz angepasst. Es werden keine Aussagen zur Übertragbarkeit der anderen Merkmale gemacht. Beide Klassifizierungen erreichten *Overall Accuracies* von mindestens 86%.

Ein Verfahren zur Abgrenzung einzelner Bäume aus Laserdaten und multispektralen Bildern mit e-Cognition ist in (TIEDE et al. 2004) beschrieben. Das Ergebnis ist ein Regelsatz, welcher mit geringen Anpassungen für verschiedene Arten von Baumbeständen getestet wurde. Ein semiautomatisches Verfahren zur Baumabgrenzung kann hierdurch realisiert werden. Je nach Komplexität des Baumbestandes (Alter, Dichte, Zusammensetzung) variiert die Qualität der Klassifizierung bei den gezeigten Beispielen stark.

ESCH et al. (2003) untersuchen das Potenzial einer objektbasierten Analyse von radiometrisch korrigierten Landsat TM-Daten für die Regionalplanung. Das Klassifizierungsmodell wird sowohl räumlich als auch zeitlich übertragen, wobei Ersteres zufrieden stellende Resultate liefert. Die Übertragung auf einen temporalen Datensatz scheiterte aufgrund von Unterschieden in der Prozessierung der Landsat Szenen, da diese von verschiedenen Datenprovidern stammen, und weil sie unterschiedliche Texturen aufweisen. Im Hinblick auf die Übertragbarkeit des Modells wird die Forderung nach allgemein

gültigeren Klassenbeschreibungen gestellt. Die Erhebung der Landnutzung mit objektbasierter Analyse aus Echtfarben-Orthophotos wird in (KRESSLER et al. 2003a) untersucht. Das Klassifizierungsergebnis wird mit einer österreichischen Digitalen Katastralmappe (DKM) verglichen und vier Fälle unterschieden: korrekt, wahrscheinlich korrekt, mögliche Abweichung von der DKM und Abweichung von der DKM. Somit können nicht nur Änderungen im Datenbestand hervorgehoben werden, sondern auch Aussagen über die Art der Änderungen geliefert und Unsicherheiten aufgezeigt werden. Es wird angeführt, dass die Übertragbarkeit des erstellten Modells gegeben sei, es werden aber keinerlei quantitative Ergebnisse diesbezüglich aufgeführt.

MITRI, GITAS (2002) stellen ein objektbasiertes Modell zur Kartierung von Bränden im Mittelmeerraum aus Landsat TM-Daten vor. Das Modell wurde für ein Testgebiet in Griechenland aufgestellt und zur Überprüfung der Übertragbarkeit auf ein vier Jahre älteres Bild desselben Gebietes sowie auf ein weiteres Gebiet in Spanien angewendet. Die Landsat-Szenen wurden vor der Klassifizierung atmosphärisch, geometrisch und topographisch korrigiert. Die Übertragung des Modells liefert sehr gute Ergebnisse (*Overall Accuracy* 98%). In der Veröffentlichung wird nicht näher auf die verwendeten Objektmerkmale eingegangen.

In (ANDRESEN 2004) werden Strategien zur wissensbasierten Bildanalyse hoch auflösender Fernerkundungsdatensätze für das Monitoring gewässernaher Feuchtgebiete vorgestellt. Anhand von IKONOS, hyperspektralen CASI-Daten sowie Orthophotos wurden Regelsätze zur objektbasierten Klassifizierung entwickelt und auf multisaisonale Daten derselben Bildtypen übertragen. Aufgrund des phänologischen Erscheinungsbildes von Vegetation waren bei der Übertragung Anpassungen der Regelsätze erforderlich. Die Struktur der Klassenhierarchie konnte erhalten bleiben, während die Anpassung der Wertebereiche insbesondere bei den Spektralparametern unabdingbar war.

Eine der wenigen Veröffentlichungen, die explizit auf übertragbare Objektmerkmale eingehen, ist (DE KOK, WEVER 2002). Am Beispiel urbaner Bereiche wurden szenenunabhängige Klassifizierungsparameter gesucht, die auch in großflächigen Satellitenbildmosaiken stabil sind. Die Ergebnisse zeigen die Eignung von Texturmerkmalen zur Erfassung urbaner Bereiche. Diese Merkmale haben sich als stabil erwiesen und werden nur gering von der Radiometrie beeinflusst.

2.5 Zielsetzung der Arbeit

Wissensbasierte Verfahren werden bislang hauptsächlich für die Objektextraktion aus hoch aufgelösten Luftbildern eingesetzt, da bis vor kurzem Satellitenbilder aufgrund ihrer deutlich schlechteren geometrischen Auflösung für die entsprechenden Anwendungen nicht geeignet waren. Trotz der jetzt zur Verfügung stehenden hoch aufgelösten Satellitenbilddaten, werden in dieser Arbeit Bilddaten mittlerer Auflösung genutzt. Für großflächige Anwendungen wie die Kartierung Nordafrikas ist der Einsatz hoch aufgelöster Satellitenbilddaten zu teuer. Daher ist ein Ziel dieser Arbeit die Abschätzung des Potenzials der wissens- bzw. objektbasierten Interpretation von Satellitenbilddaten mittlerer Auflösung. Zahlreiche Ansätze zur Objektextraktion verwenden als Vorwissen existierende GIS- oder Kartendaten, um beispielsweise spektrale Signaturen automatisch aus dem Bild zu generieren. In Entwicklungsländern und in dem hier betrachteten Gebiet in Nordafrika stehen keine geeigneten GIS-Daten zur Verfügung. *VMap Level 1*-Daten sind aufgrund ihrer Generalisierung und des z.T. hohen Alters der für die Erfassung verwendeten Daten als a priori Daten ungeeignet.

Der Stand der Wissenschaft bezüglich der Übertragbarkeit der objektbasierten Analyse kann folgendermaßen zusammengefasst werden: Bislang werden objektbasierte Modelle meist nur für ein spezifisches Testgebiet aufgestellt. Die Anwendung des Modells auf ein anderes Gebiet wird selten in den wissenschaftlichen Veröffentlichungen erwähnt. Darüber hinaus sind die in der Wissensbasis verwendeten Objekteigenschaften, die sich als stabil, d.h. übertragbar erwiesen, nicht aufgeführt und es fehlen häufig quantitative, vergleichbare Bewertungen der Klassifizierungsergebnisse sowie Zeitangaben bezüglich des Auswerteprozesses. In den Studien finden fast ausschließlich radiometrisch korrigierte Bilddaten Anwendung. In dieser Arbeit sollen radiometrisch unkorrigierte Daten verwendet werden,

um im Hinblick auf eine Operationalisierung des Verfahrens keine Korrekturen als Bildvorverarbeitungsschritte zu benötigen. Die Standardbildprodukte der Datenprovider sollen direkt für die Bildinterpretation eingesetzt werden. Der hier vorgestellte Ansatz könnte jedoch auch korrigierte Bilddaten verwenden. Basierend auf den Defiziten der vorgestellten Ansätze können als Grundvoraussetzungen für diese Arbeit folgende Schwerpunkte festgehalten werden:

- Verwendung von Satellitenbilddaten mittlerer Auflösung (radiometrisch unkorrigiert)
- Keine Nutzung von Vorwissen in Form von GIS-Daten
- Aufzeigen der prinzipiellen Übertragbarkeit von Regelsätzen
- Entwicklung eines Basis-Regelsatzes für größere Gebiete (keine Optimierung für nur ein Bild)
- Umfassende quantitative Evaluierung

3 Objektbasierte Analyse

Die beiden ersten Abschnitte geben einen Überblick über die grundlegenden Arbeitsschritte Segmentierung und *Fuzzy*-Klassifizierung der objektbasierten Analyse. Anschließend werden die in dieser Arbeit verwendeten Bilddaten vorgestellt. Deren Kenntnis ist wichtig für das Verständnis des in Abschnitt 3.4.2 beschriebenen Modells für eben diese Satellitenbilddaten mittlerer Auflösung. Abschließend werden die Strategie und der Ablauf der objektbasierten Analyse erläutert.

3.1 Segmentierung

Vor einer Klassifizierung (siehe Abschnitt 3.2) mit eCognition werden die Bilddaten segmentiert. Eine der grundlegenden Annahmen von eCognition ist, dass jede Anwendung einen speziellen Auswertemaßstab benötigt: kleine Objekte erfordern eine feinere Segmentierung als große, flächenhafte Objekte. Die *Multiresolution Segmentation* von eCognition erlaubt eine Segmentierung der Bilddaten in mehreren Abstraktions-/Maßstabsebenen, den so genannten *Levels*. eCognition verwendet mit der *Multiresolution Segmentation* ein patentiertes Segmentierungsverfahren, das unter Berücksichtigung lokaler Kontraste eine weitgehend anwendungsfreie Extraktion von homogenen Segmentprimitiven in einer beliebigen Auflösung ermöglicht. Das Segmentierungsverfahren bedient sich einer *Bottom-up region merging* Technik (siehe Abschnitt 2.1.2):

Zu Beginn der Segmentierung repräsentiert jedes einzelne Pixel ein Segment (*Region*; siehe Abbildung 11). Schrittweise wird dann jeweils ein Paar von Segmenten zu einem größeren Segment zusammengefügt (*Merging*). Die Entscheidung für das Verschmelzen beruht auf lokalen Homogenitäts- bzw. Heterogenitätskriterien, bzw. auf Kriterien für die Änderung von Homogenität/Heterogenität, welche die Ähnlichkeit von angrenzenden Segmenten beschreiben. Werden nur geringe Änderungen der Homogenität zugelassen, so resultieren weniger Verschmelzungen als bei Verwendung eines größeren Schwellwerts. Folglich wächst die Größe der resultierenden Segmente mit einem höheren Schwellwert tendenziell. Aufgrund dieser Eigenschaft wird dieser Schwellwert *Scale Parameter* genannt. Er steht indirekt in Beziehung mit der Größe der gebildeten Segmente. Man erhält bei gleichem *Scale Parameter* in einem heterogenen Bild kleinere Segmente als in einem homogenen Bild (BAATZ, SCHÄPE 2000). Durch die Segmentierung in mehreren Maßstabsebenen entsteht ein hierarchisches Netz von Segmenten. Die Daten werden in verschiedenen Auflösungen repräsentiert. Feinstrukturierte Objekte sind im hierarchischen Netz Unterobjekte von größeren Strukturen (siehe Abbildung 11). Die gebildeten Objekte bzw. Segmente sind zudem nachbarschaftlich miteinander vernetzt. Jedes Segment „kennt“ damit seine räumlichen Nachbar-, Ober- und Überobjekte (*Super- und Subobjects*).




Abbildung 11: Hierarchisches Netz von Segmenten (nach eCognition USER GUIDE 2004)

Zur Beschreibung der spektralen bzw. Farbhomogenität wird in eCognition die Summe der Standardabweichungen σ_c der spektralen Werte in jedem *Layer* c (Bildkanal) gewichtet mit dem Gewicht des jeweiligen *Layers* w_c verwendet:

Farbhomogenität:
$$h_{color} = \sum_c w_c \cdot \sigma_c$$

Eine Segmentierung, die ausschließlich auf spektralen Merkmalen basiert, würde z.T. sehr unregelmäßig geformte und evtl. fraktal ausgefranste Segmente erzeugen. Dieser Effekt wirkt sich insbesondere in stark texturierten Daten, wie Luftbilder mit Wald oder Radardaten negativ aus. Daher ist es sinnvoll, neben der spektralen Homogenität auch eine Formhomogenität in den Segmentierungsprozess einzubeziehen, um damit die Abweichung von einer kompakten Segmentform zu verringern. Die Kompaktheit (*Compactness*) eines Segments kann durch das Verhältnis der Umrisslänge l und der Quadratwurzel der Fläche, d.h. der Anzahl der Pixel n , die das Segment bilden, beschrieben werden:

Kompaktheit:
$$h_{cmpct} = \frac{l}{\sqrt{n}}$$

Neben der Kompaktheit kann mittels der Glattheit (*Smoothness*) die Formhomogenität eines extrahierten Segments beeinflusst werden. Durch das Verhältnis der Umrisslänge l zur kürzest möglichen Umrisslänge b , die durch die *Bounding Box* (kleinstes umschreibendes Rechteck) des Segments parallel zum Raster des Bildes beschrieben wird, kann die Glattheit folgendermaßen definiert werden:

Glattheit:
$$h_{smooth} = \frac{l}{b}$$

Gemäß der Gewichtungen w_{cmpct} und w_{smooth} , wobei Letztere als $1 - w_{cmpct}$ definiert ist, werden Kompaktheit und Glattheit zur Formhomogenität h_{shape} zusammengefasst:

Formhomogenität:
$$h_{shape} = w_{cmpct} \cdot h_{cmpct} + (1 - w_{cmpct}) \cdot h_{smooth}$$

Während der Segmentierung wird ein Fusionswert für eine mögliche Verschmelzung zweier benachbarter Segmente berechnet, der mit dem *Scale Parameter* verglichen wird. Der *Scale Parameter* dient als Abbruchkriterium. Der Fusionswert setzt sich aus der Farbhomogenität h_{color} und der Formhomogenität h_{shape} wie folgt zusammen:

Fusionswert:
$$f = w \cdot h_{color} + (1 - w) \cdot h_{shape}$$

Der Gewichtungsfaktor w ist das nutzerdefinierte Gewicht von Farb- und Formhomogenität mit $0 \leq w \leq 1$.

Die Standardabweichungen ihrerseits werden mit der Segmentgröße n gewichtet.

Formhomogenität beim Verschmelzen:

$$dh_{color} = \sum_c w_c \cdot (n_{Merge} \cdot \sigma_c^{Merge} - (n_{Obj1} \cdot \sigma_c^{Obj1} + n_{Obj2} \cdot \sigma_c^{Obj2}))$$

Die Änderung der Farb- und Formhomogenität wird aus der Differenz der Homogenitäten vor und nach einer potenziellen Verschmelzung zweier benachbarter Objekte berechnet. Für die Glattheit wird folgende Berechnung durchgeführt. Analog wird für die Kompaktheit verfahren.

Glattheit beim Verschmelzen:

$$dh_{smooth} = n_{Merge} \cdot \frac{l_{Merge}}{b_{Merge}} - (n_{Obj1} \cdot \frac{l_{Obj1}}{b_{Obj1}} + n_{Obj2} \cdot \frac{l_{Obj2}}{b_{Obj2}})$$

Die Entscheidung zwei angrenzende Segmente miteinander zu verschmelzen beruht auf der Methode des *Local mutual best fitting*. Für ein beliebiges Segment A soll sein Nachbarsegment B, mit dem das Homogenitätskriterium am Besten erfüllt wird, d.h. die minimale Änderung der Homogenität, gefunden werden. Finde für B sein Nachbarsegment C, mit dem B das Homogenitätskriterium am Besten erfüllt. Bestätige, dass das Homogenitätskriterium gegenseitig am Besten erfüllt wird (C=A). Falls nicht, wird die Schleife wiederholt, indem B statt A und C statt B genommen wird. Diese Heuristik erlaubt die Suche nach dem geeignetsten Segmentpaar in der lokalen Umgebung von A, dem Gradient des Grad des „*Fitting*“ (bzw. der Homogenität) folgend.

Das Verfahren benötigt einen Startpunkt A, von dem aus die Suche nach dem Verschmelzungspaar beginnt. Um eine ähnliche Größe für alle Segmente zu erreichen, ist ein simultanes Wachstum erforderlich. Dies wird erreicht, indem die Reihenfolge der Startpunkte folgende zwei Bedingungen einhalten (für jedes in Betracht gezogene Segment führt das Verfahren eine Verschmelzung durch):

- Jedes Segment wird einmal pro Durchlauf betrachtet.
- Nachfolgende Verschmelzungen werden so weit wie möglich voneinander entfernt über das gesamte Bild verteilt.

Das Verfahren beginnt an jedem Punkt des Bildes mit Segmenten, die genau aus einem Pixel bestehen. Die Bearbeitungsreihenfolge beruht auf einem binären Zähler, der eine gleichmäßige räumliche Verteilung der behandelten Objekte gewährleistet (BAATZ, SCHÄPE 2000).

Neben der oben beschriebenen Standard-Segmentierung von eCognition, die auf Änderungen der Farb- und Formhomogenität beruht, gibt es die Segmentierung im *Spectral Difference* Modus. Hierbei werden angrenzende Segmente entsprechend ihren Grauwertdifferenzen miteinander verschmolzen. In diesem Modus steht der *Scale Parameter* für die maximal erlaubte Grauwertdifferenz zweier Segmente. Ist die Grauwertdifferenz kleiner als der *Scale Parameter*, so erfolgt die Verschmelzung der Segmente. Der einzige vom Operateur zu setzende Parameter ist der *Scale Parameter*. Die Segmentierung im *Spectral Difference* Modus kann nur auf einem mit der Standard-Segmentierung von eCognition erzeugten *Level* erfolgen.

Zur Steuerung der Segmentierung in eCognition müssen verschiedene Parameterwerte gesetzt werden (siehe Tabelle 5). Neben der Gewichtung der einzelnen Bildkanäle wird für die Erzeugung einer Segmentierungsebene der *Scale Parameter* sowie die Gewichtung der Form- und Farbhomogenität spezifiziert. Dem Anwender werden in eCognition Standardwerte für die Segmentierungsparameter vorgegeben. Je nach verwendeten Bilddaten und Zielklassen führen jedoch andere Parameter zu einem z.T. deutlich besseren Ergebnis. Bislang muss der Operator zeitaufwändig nach dem *Trial and Error*-Prinzip geeignete Segmentierungsparameter herausfinden (LEUKERT 2002b). Im Hinblick auf automatisierte und operationelle Systeme zur Extraktion von GIS-Daten ist jedoch die Vorgabe zweckmäßiger Parameter für bestimmte Arten von Bilddaten und Objektklassen das Ziel.

Tabelle 5: Einzustellende Parameter bei Segmentierung in eCognition

Standard-Segmentierung	<i>Spectral Difference</i> -Segmentierung
<ul style="list-style-type: none"> - Gewicht w_c pro Bildkanal - <i>Scale Parameter</i> - Gewicht w für Farb- und Formhomogenität - Gewicht $w_{compact}$ für Kompaktheit vs. Glattheit 	<ul style="list-style-type: none"> - Gewicht w_c pro Bildkanal - <i>Scale Parameter</i> (= max. Grauwertdifferenz)

3.1.1 Segmentierung künstlicher Bilder

Zur Verdeutlichung der Einflüsse der verschiedenen Segmentierungsparameter von eCognition wird im Folgenden ein künstliches Testbild mit unterschiedlichen Parameterwerten segmentiert. Abbildung 12 zeigt dieses Farbttestbild mit stilisierten topographischen Objekten, die einer Straße (grau mit gestrichelter Mittellinie), Gebäuden (schwarz, braun und gestreift), Einzelbäumen (grün), einem See (blau) und einer Grasfläche (Grüntöne) entsprechen sollen. Die Objekte besitzen unterschiedliche Farbwerte, Größen, Formen und sind zum Teil texturiert. Das Testbild umfasst knapp 2 Millionen Pixel (1445 x 1318 Pixel).




Abbildung 12: Testbild

In einem ersten Schritt erfolgt eine Segmentierung des Testbildes nur basierend auf der Farbhomogenität. Der Einfluss der Form wird durch das Gewicht 0 unwirksam. Eine zweite Segmentierung gewichtet mit 90% fast ausschließlich die Form. Das komplette Weglassen des Farbkriteriums ist in eCognition nicht möglich. Die Farbgewichtung besitzt ein Mindestgewicht von 10%. Abbildung 13 zeigt links das exklusiv mit Farbe segmentierte Bild und rechts das Segmentierungsergebnis mit fast ausschließlicher Formgewichtung bei einem *Scale Parameter* von 50. Die blauen Linien stellen die Segmentgrenzen dar. Im linken Bild sind fraktale, ausgefranste Segmente erkennbar, die in der Größe beträchtliche Unterschiede aufweisen. Der Segmentierungsalgorithmus strebt bei ausschließlicher Farbgewichtung nichts als die Bildung möglichst homogener Objekte an. Der See ist in einem Segment erfasst. Die Segmentierung rechts zeigt deutlich kompaktere und an den Grenzen glattere Segmente, deren Größe ähnlich ist. Größere, homogene Objekte, wie z.B. der See, werden hier in mehrere kompakte Segmente unterteilt und heterogene/texturierte aber kompakte Objekte, wie z.B. das rechte

untere Haus, werden als ein Segment segmentiert. Diese beiden extremen Beispiele zeigen, dass für eine erfolgreiche Segmentierung in vielen Fällen sowohl Farbe als auch Form gewichtet werden sollte.




Abbildung 13: Segmentierung nur mit Farbe (links) und vor allem mit Form (rechts) bei *Scale Parameter* 50 - Segmentgrenzen in Blau

Abbildung 14 zeigt die Anzahl der gebildeten Segmente der beiden Segmentierungen in Abhängigkeit vom *Scale Parameter* (*SP*). Je größer *SP* gewählt wird, desto weniger Segmente werden gebildet, da der Segmentierungsalgorithmus einen Anstieg der Farb- bzw. Formhomogenität zulässt. Mit steigendem *SP* nimmt auch die Größe der gebildeten Segmente zu. Daher ist es in eCognition möglich, einen heterogenen Bereich wie eine Siedlung in einem hoch aufgelösten Bild in ein großes Segment (großer *SP*) und in viele kleine Teilobjekte (kleiner *SP*) zu segmentieren und Informationen über das charakteristische Maßstabsverhalten für die Objektextraktion zu nutzen. Abbildung 14 verdeutlicht zudem, dass das Verhältnis der Anzahl der Segmente bei Segmentierung mit und ohne Formgewichtung in unterschiedlichen Maßstäben ähnlich ist. LANG (2002) und HOFFMANN (2001) beschreiben vergleichbare Resultate bei der Segmentierung mit eCognition unter Verwendung von natürlichen Bildern.




Abbildung 14: Anzahl der Segmente bei Segmentierung mit und ohne Formgewichtung

Die Segmentierung in mehreren Maßstabsebenen und mit einer kombinierten Gewichtung von Farbe und Form veranschaulicht Abbildung 15. Das Testbild wurde mit den SP 10, 30 und 50 mit der Gewichtung 0,6 für Farbe und 0,4 für Form (*Smoothness* 0,8 und *Compactness* 0,2) segmentiert. Die Segmentierung mit SP 10 zeigt sehr kleine Segmente und homogene Objekte wie der See sind unterteilt. Die Segmentierungsprozedur bildet bei allen Maßstäben (SP) ungefähr gleich große Segmente. In der Segmentierung mit SP 30 ist eine deutliche Reduzierung der Anzahl der Segmente zu erkennen. Der größere SP setzt die Grenze für die erlaubte Heterogenität eines Segmentes höher. Basierend auf der Segmentierungsebene mit SP 50 ist eine weitere Ebene mit Grauwert-Differenz (*Spectral Difference*-Modus mit SP 7) segmentiert. Dies lässt große homogene Objekte als ein Segment zu. Gleichzeitig können aber auch kleine Segmente vorkommen, wie im Testbild für das rechte untere Haus mit dem gestreiften Dach. Hier sind die Grauwertunterschiede höher als der Schwellwert und es erfolgt keine Verschmelzung der Segmente.

Die zwei Segmentierungsmodi und die große Zahl an Möglichkeiten zur Variation der Parameter bieten vielfältige Möglichkeiten zur Segmentierung von unterschiedlichsten Daten. Diese Vielfalt an Möglichkeiten stellt allerdings große Anforderungen an den Anwender. Dieser muss geeignete Segmentierungsparameter für seine Anwendung finden. Bislang wird von Standardeinstellungen und Erfahrungswerten ausgegangen. Sind für eine bestimmte Anwendung geeignete Segmentierungsparameter bekannt, so können diese meist auf andere Bilder desselben Sensors übertragen werden. Eine Kontrolle der Segmentierung wird in der Regel visuell durchgeführt. Es gibt derzeit keine automatischen Standardverfahren zur Beurteilung der Segmentierung von Fernerkundungsdaten (siehe Abschnitt 2.3.1).




Abbildung 15: Segmentierung eines Testbildes in mehreren Maßstabsebenen mit unterschiedlichen Parametern für Homogenität (SP) bzw. Grauwertdifferenz (Spectr. Diff.)

3.1.2 Angepasste Segmentierungen für unterschiedliche Objektklassen

An die Segmentierung von Bilddaten werden abhängig von den für eine Anwendung zu erfassenden Objektklassen unterschiedliche Anforderungen gestellt. Linienförmige Objekte wie Straßen und Flüsse implizieren lang gestreckte Segmente. Zur Extraktion flächenhafter Objekte sind hingegen kompakte Segmente geeigneter. Für eine optimale Erfassung der zu extrahierenden Objekte ist neben der Form der Segmente die räumliche Ausdehnung entscheidend. Zur Extraktion flächenhafter Objekte genügt in der Regel eine niedrigere Auflösung als für linienförmige Objektklassen, da die Ausdehnung für Letztere senkrecht zur Linienrichtung oft sehr begrenzt ist. Durch Reduzierung der Auflösung werden z.T. heterogene Flächen wie Waldobjekte homogener. Für Objekte mit einer bestimmten geometrischen Form wie rechteckige Gebäude oder Felder ist ein Segmentierungsalgorithmus vorteilhaft, der diese Vorinformation bereits zur Segmentierung nutzen kann.

Nachfolgend werden verschiedene Objektklassen hinsichtlich ihrer Segmentierung mit eCognition beleuchtet. Die Segmentierung hat unmittelbar Einfluss auf die nachfolgende Klassifizierung, da die Segmente Grundlage der Klassifizierung sind. Die Objektklassen *Meer* und *See* bilden sich in den verwendeten Bilddaten mittlerer Auflösung als flächenförmige, homogene Objekte ab (siehe Abbildung 16 a und Abbildung 24). Die Segmente können sehr groß sein und besitzen keine spezifische geometrische Form. Störungen in Form von Schiffen oder hellen Wellenkämmen verschwinden bei einer entsprechend groben Segmentierung.




Abbildung 16: Segmentierung für *Meer* (a), *landwirtschaftliche Fläche* (b), *Straße in Bebautes Gebiet* (c) und *Straße neben Wald* (d)

Bei der Klasse *Bebautes Gebiet* (siehe Abbildung 21) handelt es sich ebenfalls um flächenförmige Objekte. Aufgrund der vielen Einzelobjekte, aus denen *Bebautes Gebiet* besteht, ist diese Objektklasse sehr heterogen. Eine Nutzung verschiedener Maßstabsebenen kann wertvolle Informationen zur Objektextraktion liefern. In einer feinen Segmentierungsebene können Einzelobjekte, wie Gebäude(komplexe), Schattenbereiche und Straßen erfasst werden, während eine übergeordnete Ebene größere Flächen (z.B. Straßenblöcke) aggregiert. Aufgrund der Subobjekte im feineren *Level* können die größeren Flächen klassifiziert werden. Die aggregierten Segmente weisen in der Regel unregelmäßige geometrische Formen auf (siehe Abbildung 16 c).

Bei der Segmentierung von *Nicht bebautes Gebiet* (siehe Abbildung 22), worunter z.B. landwirtschaftliche Flächen fallen, spielt der Kontrast an den Feldkanten eine entscheidende Rolle. Zwischen bewirtschafteten Flächen befindet sich häufig linienförmiger Bewuchs, der als Segmentgrenze auftritt. Die Segmente weisen eine Mischung von rechtwinkligen und unregelmäßigen Formen auf (siehe Abbildung 16 b). Spektrale Unterschiede innerhalb eines Feldes unterteilen das Objekt z.T. in mehrere Segmente. Die Objektklasse *Wald* besitzt ebenfalls unregelmäßige geometrische Formen. Schneisen, Waldwege, Änderungen der Baumart und der Bewuchsdichte bilden Segmentgrenzen (siehe Abbildung 16 d).

Im Gegensatz zu den bereits aufgezählten flächenförmigen Objektklassen stellen *Straße* und *Fluss* linienförmige Objekte dar. Zu deren Extraktion sind die hier verwendeten Satellitenbilddaten mit einer Auflösung von 5 m nur z.T. geeignet, da Straßen und kleinere Flüsse sich überwiegend in der Breite von 1 bis 2 Pixeln abbilden. Ein Großteil der Ansätze zur automatischen Straßenextraktion (siehe Abschnitt 2.4.2) arbeitet mit Luftbildern in Auflösungen zwischen 20 und 50 cm. Neuere Ansätze verwenden auch hoch aufgelöste Satellitenbilddaten mit 1 m Auflösung oder kleiner, da die Multispektralinformationen dieser Bilder wichtige Zusatzinformationen zur Straßenextraktion liefert. Der Segmentierungsalgorithmus von eCognition ist nicht für linienförmige Objekte spezialisiert. Es besteht aber die Möglichkeit, anstelle einer Vierer- eine Achter-Nachbarschaft zur Segmentierung zu verwenden (siehe Abbildung 17). Bei einer 4er-Nachbarschaft werden zwei Objekte, die sich diagonal in einem Pixel berühren, als zwei Segmente gebildet. Wird hingegen eine 8er-Nachbarschaft verwendet, so resultiert ein zusammenhängendes Segment.

Insbesondere bei Straßen innerhalb von bebautem Gebiet kann es zu ausgefranst Segmenten kommen, da Kontraste fehlen und Verdeckungen auftreten (siehe Abbildung 16 c). Schatten und Verdeckungen in Waldgebieten oder Baumalleen parallel zu Straßen oder Flüssen lassen dagegen oft nur eine unterbrochene, stückweise Segmentierung von linienförmigen Objekten zu. Straßen in Nordafrika sind teilweise deutlich schwieriger zu extrahieren als z.B. in Mitteleuropa. Es handelt sich oft um schmale, unbefestigte Straßen oder Pisten, deren Baumaterial aus der unmittelbaren Umgebung stammt. Somit fehlen Kontraste. Zusätzlich ist darauf zu achten, dass nicht zu kleine Segmente gebildet werden, da diese keine aussagekräftigen Merkmale bezüglich Standardabweichung des Grauwerts oder z.T. auch der Form besitzen.




Abbildung 17: Segmentbildung bei 4er-Nachbarschaft (links) und 8er-Nachbarschaft (rechts) (eCognition USER GUIDE 2004)

3.2 Fuzzy-Klassifizierung auf Grundlage von Zugehörigkeitsfunktionen

Die Klassifizierung der Segmente (siehe Abschnitt 3.1) erfolgt in eCognition über eine Wissensbasis in Form von Regeln, welche die Eigenschaften der gewünschten Objektklassen als *Fuzzy-Zugehörigkeitsfunktionen* (siehe Abschnitt 2.1.7) beschreiben. Die Beschreibungen der Objektklassen können neben spektralen Eigenschaften auch Form und Größencharakteristika, Kontext und Texturinformationen umfassen. Innerhalb der Wissensbasis, die als Klassenhierarchie aufgebaut ist, können Eigenschaften von einer Elternklasse an Kindklassen vererbt und Gruppen von Klassen semantisch zusammengefasst werden. Zusätzliche Informationen wie GIS-Daten oder Digitale Oberflächenmodelle (DOM) können in die Klassifizierung integriert werden.

Abbildung 18 zeigt beispielhaft die Definition zweier Zugehörigkeitsfunktionen für die Objekteigenschaft *Grauwert* einer Objektklasse. Die obere Zugehörigkeitsfunktion beschreibt eine *größer als* Funktion. Alle Segmente mit einem mittleren Grauwert kleiner als 120 bekommen den Zugehörigkeitswert 0, was bedeutet, dass sie dieser Klasse nicht angehören. Der Zugehörigkeitswert für Grauwerte größer als 140 beträgt 1. Damit ist eine 100%ige Zuweisung zur Klasse gegeben. Grauwerte zwischen 120 und 140 erhalten einen Zugehörigkeitswert entsprechend der dargestellten Funktion. Der Grauwert 134 gehört z.B. zu 50% der Klasse an. Die untere abgebildete Zugehörigkeitsfunktion definiert einen Grauwertbereich. Mittlere Grauwerte zwischen 105 und 135 besitzen den Zugehörigkeitswert 1 und Grauwerte kleiner als 80 oder größer als 160 besitzen keine Klassenzugehörigkeit.

Je höher ein Zugehörigkeitswert ist, desto zuverlässiger ist die Klassenzuweisung. Ein Segment wird der Klasse zugewiesen, zu der es den höchsten Zugehörigkeitswert besitzt (siehe auch Abbildung 27). Die Form der Zugehörigkeitsfunktion fällt je nach Objekteigenschaft sehr unterschiedlich aus. Neben *kleiner* bzw. *größer als* können die Funktionen auch Wertebereiche (zwischen x und y), Einzelwerte oder harte Grenzen definieren, bei denen die Zugehörigkeitswerte nur 0 oder 1 annehmen können.




Abbildung 18: Fuzzy-Zugehörigkeitsfunktionen

Zur Beschreibung einer Klasse müssen in der Regel mehrere Merkmale verwendet werden. Jedes Merkmal wird über eine Zugehörigkeitsfunktion beschrieben und mit Hilfe von *Fuzzy*-Operatoren können die Zugehörigkeitsfunktionen einer Klasse kombiniert werden. Die in eCognition verfügbaren *Fuzzy*-Operatoren sind in Tabelle 6 aufgelistet. Bei einer *and(min)* Verknüpfung wird beispielsweise der kleinste Zugehörigkeitswert aller Zugehörigkeitsfunktionen dem Segment zugewiesen. Bei einer *or(max)* Verknüpfung gewinnt der größte Zugehörigkeitswert und bei *mean(arithm.)* ist das arithmetische Mittel aller Zugehörigkeitswerte der endgültige Wert.

Tabelle 6: *Fuzzy*-Operatoren in eCognition

<i>Fuzzy</i>-Operator	Beschreibung
<i>and(min)</i>	Der Kleinste aller Zugehörigkeitswerte
<i>and(*)</i>	Das Produkt der Zugehörigkeitswerte
<i>or(max)</i>	Der Größte aller Zugehörigkeitswerte
<i>mean(arithm.)</i>	Arithmetisches Mittel der Zugehörigkeitswerte
<i>mean(geo.)</i>	Geometrisches Mittel der Zugehörigkeitswerte

eCognition bietet zahlreiche **Merkmale** zum Aufstellen der Regelsätze für die Wissensbasis. Die Merkmale können in zwei große Gruppen zusammengefasst werden: *Objektmerkmale* können direkt aus den Objekten oder aus ihrer Einbettung in der Objekthierarchie berechnet werden. *Klassenbezogene Merkmale* beziehen sich auf andere klassifizierte Objekte, welche die Klassifizierung des Interessensobjekts beeinflussen.

Objektmerkmale umfassen folgende Gruppen:

- *Layer values*
- *Shape*
- *Texture*
- *Hierarchy*
- *Thematic attributes* (z.B. GIS-Daten oder DGM)

Layer values sind die Eigenschaften der das Objekt repräsentierenden Pixel in einem bestimmten Bildkanal, wie z.B. mittlerer Grauwert, Standardabweichung und maximale Differenz. Mit Hilfe der *Shape* Merkmale kann die Form der zu klassifizierenden Objekte beschrieben werden. Nützliche Merkmale sind u.a. die Größe eines Objektes, das Längen- zu Breitenverhältnis, Länge, Breite und Kompaktheit. Texturmerkmale können auf zweierlei Arten berechnet werden. Zum einen liefern Subobjekte in einem feiner segmentierten *Level* die Texturinformation basierend auf spektralen oder formbeschreibenden Eigenschaften der Segmente. Die andere Möglichkeit ist die Berechnung der Texturmerkmale eines Segmentes mit Hilfe der *Grey Level Co-Occurrence Matrix* (GLCM) nach HARALICK (siehe Abschnitt 2.1.3). *Hierarchy* Merkmale liefern Informationen über die Einbettung eines Objektes in die bestehende Segmenthierarchie. Bei Verwendung von Zusatzdaten, wie GIS-Daten oder ein DGM, können thematische Attribute in die Klassifizierung einbezogen werden.

Klassenbezogene Merkmale sind folgendermaßen aufgegliedert:

- *Relations to neighbor objects*
- *Relations to sub-objects*
- *Relations to super-objects*
- *Membership to*
- *Classified as*
- *Classification value of*

In die Regelsätze können Beziehungen zu räumlich benachbarten Objekten, zu Überobjekten in einem gröber segmentierten *Level* oder zu Unterobjekten in einem feineren *Level* eingebaut werden. Beispiel hierfür ist das Grenzlängenverhältnis zu Nachbarobjekten einer bestimmten Klasse, dessen Wert sich aus der Länge der Grenze zu diesen spezifisch klassifizierten Objekten im Verhältnis zur Objektlängenslänge bestimmt. Für manche Fragestellungen bieten sich auch Merkmale wie der minimale oder durchschnittliche Abstand zu Objekten einer bestimmten Klasse oder deren Existenz in einem gewissen Abstand von gegebenen Objekten an.

Unter Verwendung der vorhandenen Merkmale können neue, so genannte maßgeschneiderte Merkmale, gebildet werden. So kann beispielsweise der *NDVI* (siehe Abschnitt 2.1.1) auf diese Weise zu den Merkmalen hinzugefügt werden.

3.3 Bilddaten

Die indischen Satelliten IRS-1C und IRS-1D (IRS = *Indian Remote Sensing*) wurden im Dezember 1995 bzw. September 1997 gestartet. Sie besitzen einen panchromatischen (*PAN*), einen multispektralen (*Linear Imaging and Self-Scanning Sensor LISS-III*) und einen hier nicht verwendeten *Wide Field (WiFS)* Sensor. Die technischen Daten des panchromatischen und des multispektralen Sensors (grün, rot und NIR) sind in Tabelle 7 aufgelistet. Die Auflösung des panchromatischen Kanals beträgt 5,8 m und die der multispektralen Kanäle 23,5 m. Der panchromatische Kanal besitzt eine radiometrische Auflösung von 6 bit (64 Grauwerte) und die multispektralen Kanäle von 7 bit (128 Grauwerte). Die geographische Abdeckung des IRS-Satelliten umfasst nahezu die gesamte Erde. Aufnahmen sind im Bereich von 81° nördlicher bis 81° südlicher Breite möglich. Die IRS-Endprodukte werden in 8 bit abgegeben. Neben panchromatischen oder multispektralen Bildern werden auch *PAN-LISS gemergte* Bilder vertrieben. Für diese werden der panchromatische Kanal und die drei multispektralen Bänder verschnitten.

Tabelle 7: Technische Daten IRS PAN- und LISS-III-Sensor

Parameter	Spezifikation (<i>PAN</i>)	Spezifikation (<i>LISS-III</i>)
Kanäle (µm)	0,50 - 0,75	0,52 - 0,59 (Grün) 0,62 - 0,68 (Rot) 0,77 - 0,86 (NIR)
Geometrische Auflösung (m)	5,8	23,5
Radiometrische Auflösung	6 bit (64 Grauwerte)	7 bit (128 Grauwerte)
Größe einer Szene (km ²)	70 x 70	141 x 141
Flughöhe (km)	817	
Orbit	Sonnensynchron mit Inklination von 98,69°	
Wiederholzyklus (Tage)	5 (bei geneigter Aufnahme)	24

Die in dieser Arbeit verwendeten Bilddaten liegen in drei Kanälen als *gemergte, pan-sharpened* Bilder in einer Auflösung von 5 m vor und besitzen eine Georeferenzierung in UTM Zone 31 mit dem Bezugssystem WGS 84. Die Bilddaten sind nicht radiometrisch und topographisch korrigiert. Es stehen keine geeigneten Höhenmodelle zur Verfügung und der Bezug von Atmosphärendaten für Algerien zum Zeitpunkt der Satellitenbildaufnahmen für detaillierte Atmosphärenmodelle ist schwierig. Einfache Korrekturmöglichkeiten, wie *Dark Target* Ansätze (siehe Abschnitt 2.1.1), sind z.B. in Wüstengebieten aufgrund fehlenden Wassers nicht immer durchführbar. Das hier verwendete objektbasierte

Verfahren wird direkt mit dem Standardbilddatenprodukt *PAN-LISS Merge* der Datenprovider getestet. Es erfolgt keinerlei Vorverarbeitung der Bilddaten.

Testgebiete

Die verwendeten Testgebiete liegen in einem Kulturkreis in zwei unterschiedlichen geographischen Regionen in Algerien, die im Weiteren *Küste* und *Wüste* genannt werden. Beide geographischen Regionen umfassen insgesamt acht Testgebiete. Auf Grundlage von jeweils vier Testgebieten (*Küste I* bzw. *Wüste I*) wurden die Experimente ohne Modellierung der Übertragbarkeit durchgeführt und der Basis-Regelsatz für die jeweilige geographische Region aufgestellt. Die anderen acht Testgebiete (*Küste II* bzw. *Wüste II*) dienen zur Evaluierung des Basis-Regelsatzes. Abbildung 19 zeigt die Lage der Testgebiete in Algerien. Die Testgebiete *Küste I* bzw. *Wüste I* sind als rote Rechtecke dargestellt, *Küste II* bzw. *Wüste II* in schwarz. Die maximale Entfernung zwischen zwei Testgebieten in der geographischen Region *Küste* beträgt 530 km, in der Region *Wüste* 440 km. Zwei Wüstentestgebiete („Ouargla“ bzw. „Wargla“ und „N'Goussa“) liegen in einem Satellitenbildstreifen, die Testgebiete „Ouargla“ und „Nordöstlich von Ouargla“ befinden sich in benachbarten Bildstreifen und überlappen sich teilweise. Die übrigen Testgebiete stammen aus unterschiedlichen Bildstreifen.




Abbildung 19: Testgebiete in Algerien (I in rot und II in schwarz)

Die acht Testgebiete der geographischen Region *Küste* liegen an der algerischen Mittelmeerküste. Die Größe der Testgebiete reicht von 7 x 6 km bis 38 x 19 km (siehe Tabellen 8 und 9). Die Aufnahmezeitpunkte erstrecken sich von November 1999 bis September 2000. An der algerischen Küste herrscht mediterranes Klima mit Winterregen und die Jahreszeiten sind nicht so ausgeprägt wie in Mitteleuropa. Daher können für die Untersuchungen zur Übertragbarkeit in dieser Region Bilder aus verschiedenen Jahreszeiten hergenommen werden.

Charakteristisch für die Testgebiete in der geographischen Region *Küste* sind größere Siedlungen am Mittelmeer oder in dessen Nähe, zum Teil mit bedeutenden Hafenanlagen. Meer bedeckt in den Testgebieten bis zu einem Viertel des jeweiligen Bildes. Vereinzelt treten kleinere Seen und Flüsse auf. Die Siedlungen weisen unterschiedliche Strukturen auf. Es finden sich sowohl eng bebaute Altstadtbereiche als auch Gebiete mit größeren Industriebauten. Innerhalb der Siedlungen tritt häufig Schattenwurf durch Gebäude auf. Der ländliche Bereich besitzt ein sehr vielfältiges Erscheinungsbild. Es gibt größere, zusammenhängende landwirtschaftlich genutzte Bereiche mit aktiver Vegetation aber auch Flächen ohne Bewuchs. Einige Felder sind durch Gehölzriegel abgegrenzt und z.T. treten terrassenförmige Anbauflächen und verbuschtes sowie bewaldetes Gebiet auf. Insbesondere in Hangbereichen sind Erosionsflächen vorhanden, die ähnliche Objekteigenschaften wie Siedlungsbereiche besitzen. In

einigen Testgebieten befinden sich Flughäfen. Neben kleineren Regionalflughäfen gibt es im Testgebiet „Algier“ auch einen internationalen Flughafen. Das Straßennetz besteht sowohl aus überörtlichen als auch schmalen, örtlichen Straßen, die in der Regel befestigt sind.

Tabelle 8: Testgebiete Küste I

Testgebiet Küste I	„Mostaganem“	„Algier“	„Jijel“	„Mandoura“
Aufnahmezeitpunkt	25.11.1999	30.01.2000	11.03.2000	14.08.2000
Ausdehnung [km]	11 x 10	38 x 19	17 x 10	7 x 6

Tabelle 9: Testgebiete Küste II

Testgebiet Küste II	„Ténès“	„Tipaza“	„Kolea“	„Bejaïa“
Aufnahmezeitpunkt	05.02.2000	14.09.2000	30.01.2000	31.05.2000
Ausdehnung [km]	8 x 8	10 x 13	13 x 10	10 x 9

Die Testgebiete der Wüstenregion (siehe Tabellen 10 und 11) beinhalten kleinere bis mittlere Siedlungen in der Wüste. Kleinere Siedlungen weisen oft viele einzeln stehende Gebäude auf. Innerhalb von Siedlungen und in der näheren Umgebung prägen Palmenhaine und kreisrunde Bewässerungsanlagen das Erscheinungsbild. Ein Großteil der Bilder ist von Wüste bedeckt, wobei größere spektrale Unterschiede und Höhenunterschiede in Form von Reliefstufen auftreten. Im Bereich von Dünenstrukturen und Reliefstufen gibt es häufig Schattenflächen. Das Straßennetz ist sehr dünn. Oftmals durchzieht nur eine größere Straße das Testgebiet. Vereinzelt sind Wasserflächen und kleine Wasserläufe sichtbar.

Tabelle 10: Testgebiete Wüste I

Testgebiet Wüste I	„Hassi-El-Frid“	„Ouargla“	„N’Goussa“	„Nordöstlich von Ouargla“
Aufnahmezeitpunkt	25.12.1998	19.12.2000	19.12.2000	06.12.1998
Ausdehnung [km]	7 x 10	21 x 16	8 x 5	12 x 15

Tabelle 11: Testgebiete Wüste II

Testgebiet Wüste II	„El Meniaa“	„Ghardaïa“	„Guerara“	„Djamaa“
Aufnahmezeitpunkt	26.11.1998	11.08.2000	02.02.2001	06.12.1998
Ausdehnung [km]	9 x 11	10 x 10	10 x 10	12 x 10

3.4 Modell

3.4.1 Modellierung

Das nachfolgende Modell kann als ein semantisches Netz auf der epistemologischen Ebene (BRACHMANN 1977) gesehen werden. *Konzepte* stellen eine generische Beschreibung der Objekte dar. Die Verbindungen zwischen übereinander liegenden *Konzepten* besteht in einer *Teil-Relation* (siehe Abschnitt 2.1.5). Das Prinzip der Vererbung wird über die *Spezialisierungs-Relation* realisiert. Die symbolische Beschreibung der zu interpretierenden Landschaft kann nach TÖNJES (1996) in unterschiedlichen horizontalen Ebenen erfolgen. Innerhalb einer horizontalen Ebene besitzen Objekte die gleiche Konkretisierungsstufe, können aber eine unterschiedliche Detaillierungsstufe haben. Der Grad der Konkretisierung der Objekte nimmt von der oberen zur unteren Ebene zu. Zwischen zwei horizontalen Ebenen sind nur *Konkretisierungs-Relationen* erlaubt.

In dieser Arbeit werden drei horizontale Ebenen verwendet (siehe Abbildung 20). Die obere horizontale Ebene entspricht dem Modell der „Realen Welt“. In ihr werden die zu erkennenden semantischen Objekte formuliert. Darunter befindet sich die „Geometrie und Material“-Ebene, welche die physikali-

sehen Eigenschaften der Objekte beschreibt. Bei Verwendung mehrerer Sensoren empfiehlt sich eine Georeferenzierung der Aufnahmen oder eine Entzerrung aufeinander, um klare geometrische Beziehungen zwischen den Bildern zu gewährleisten. Die unterste Ebene ist mit „Bild (mittlere Auflösung)“ bezeichnet. Hier werden die Eigenschaften der Objekte im Bild spezifiziert. In dieser Arbeit wird praktisch nur eine Auflösungsstufe (5 m) verwendet, d.h. alle Objekte werden in dieser Auflösung klassifiziert.




Abbildung 20: Beschreibungsebenen

Objekte können aus mehreren anderen Objekten aufgebaut sein, die wiederum aus Objekten bestehen, etc. Die Auflösung der Bilddaten begrenzt die Bildung der Teilobjekte. Die Objekte im Bild müssen im Verhältnis zur Auflösung groß genug sein, um sicher erkannt zu werden. Die Auswahl der Objekte wird zum einen bestimmt durch die vom Anwender vorgegebenen Zielobjekte und zum anderen, ob geeignete Zwischenobjekte den Interpretationsprozess unterstützen. Diese Zwischenobjekte können entweder direkt aus den Daten gewonnen werden oder sie sind hilfreich bei der Bildung neuer Objekte als Teil eines Objektes oder als Kontext. Bei der Auswahl der Objekte muss darauf geachtet werden, dass deren spezifizierte Eigenschaften mit den zur Verfügung stehenden Bildverarbeitungsoperatoren im Rasterbild überprüft werden können. Die Objekte im Bild können angelehnt an PAKZAD (2001) verschiedene Ausprägungen besitzen:

- Flächen-, linien- und punktförmige Objekte
- Objekte mit vorgegebener Form und Größe
- Objekte mit vorgegebener Radiometrie oder Textur
- Objekte mit vorgegebenem Muster und charakteristischen Merkmalen
- Räumliche Relationen

Flächen-, linien- und punktförmige Objekte

Flächenförmige Objekte decken den Großteil einer Szene ab. Beispiele sind Siedlungen, landwirtschaftliche Flächen und stehende Gewässer. Als linienförmig werden lange, aber schmale Objekte bezeichnet, wie sie abgesehen von Flüssen hauptsächlich in Kulturlandschaften vorkommen (Straßen, Eisenbahnen, Gräben u.ä.). Bei ausreichendem Kontrast werden linienförmige Objekte in niedrig aufgelösten Bilddaten als Linien abgebildet. Bedingt durch die schmale Objektbreite sind linienförmige Objekte aufgrund von Verdeckungen, Schattenwurf oder fehlender Kontraste häufig unterbrochen. In höheren Auflösungen werden linienförmige Objekte als lang gestreckte Flächen abgebildet. Für ihre Detektion können parallele Kanten und eine konstante Breite angenommen werden, was aber insbe-

sondere für natürliche linienförmige Objekte wie Flüsse nicht immer zutrifft. Punktförmige Objekte, wie z.B. Masten und Silos bilden sich z.T. in Satellitenbildern auch flächenförmig ab. Ein einzelnes Pixel reicht meist nicht zur Objekterkennung aus.

Objekte mit vorgegebener Form und Größe

Künstliche Objekte wie Fußballstadien, Hallen oder Schwimmbäder weisen eine bekannte einfache geometrische Form auf. Im Gegensatz hierzu ist die Form von natürlichen Objekten im Vorhinein oft nicht genau genug bekannt. Um ein Objekt ausschließlich anhand der Form erkennen zu können, muss eine klare Abgrenzung zur Umgebung des Objekts gegeben sein, die z.B. aus unterschiedlicher Radiometrie oder Textur resultiert. Bei Verwendung von Segmentierungsverfahren wird nach der flächenhaften Segmentierung des Rasterbildes nach Segmenten mit entsprechenden Formeigenschaften gesucht. Bestimmte Objekte lassen sich über ihre charakteristische Größe definieren. So besitzen z.B. Straßen in der Regel eine spezifische Breite.

Objekte mit vorgegebener Radiometrie/Textur

Insbesondere natürliche Objekte, wie Wald und Gewässer, besitzen keine im Vorhinein bekannte einfache Form, aber eine charakteristische Radiometrie bzw. Textur. Stehende Gewässer können in der Regel anhand ihrer Farbe und Homogenität gut erkannt werden. Bei Waldobjekten liefern Farbe und Textur zuverlässige Hinweise zur Objekterkennung. Die Verwendung radiometrischer Eigenschaften besitzt den Nachteil, dass diese aufgrund von atmosphärischen und topographischen Einflüssen sowie den Beleuchtungsbedingungen zwischen verschiedenen Bildstreifen und auch innerhalb einer Aufnahme stark variieren können. In bewegtem Gelände können überstrahlte Flächen und Schattenwurf auftreten. Daher ist die Vorhersage bestimmter radiometrischer Wertebereiche unsicher. Eine Lösung wäre das Trainieren der Parameter aus dem Bild, was aber Wissen über die Lage der Objekte voraussetzt. Die Lageinformation könnte über vorhandene GIS-Daten gewonnen werden. Dies setzt jedoch deren Aktualität zum Aufnahmezeitpunkt sowie eine geeignete geometrische Registrierung der Bild-daten voraus. Dies eignet sich besonders für Objekte, die keiner zeitlich schnellen Veränderung unterworfen sind (z.B. große stehende Gewässer).

Objekte mit vorgegebenem Muster/charakteristischen Merkmalen

Künstliche Objekte weisen zum Teil ein vorgegebenes Muster auf. Beispielsweise sind Hubschrauberlandeplätze in der Regel anhand des Buchstabens „H“ und einem umgebenden Kreis erkennbar. Mit Hilfe von Mustervorlagen kann direkt nach solchen Objekten gesucht werden. Einige Objekte zeichnen sich durch das Auftreten verschiedener Merkmale innerhalb des Objektes aus. Diese charakteristischen Merkmale können z.B. bestimmte Strukturen wie Fahrspuren einer landwirtschaftlichen Fläche, Pflanzreihen und Ent-/Bewässerungsgräben sein. Sie müssen das Zielobjekt nicht flächenhaft ausfüllen.

Räumliche Relationen

Objekte, die durch ihre spektralen, textuellen oder geometrischen Eigenschaften eindeutig erkennbar sind, können isoliert von anderen Objekten extrahiert werden. Bei Verdeckungen von Objekten oder Schattenwurf ist die Objekterkennung erschwert und bestimmte Objektklassen können z.T. nur aufgrund ihrer Umgebung, d.h. ihres Kontextes voneinander unterschieden werden. Auch bei Objekten, deren Teile oder Eigenschaften eine hohe Variabilität aufweisen und die damit für sich alleine nicht erkennbar wären, können räumliche Relationen, die den Kontext definieren, als Zusatzinformation die Objektextraktion dennoch ermöglichen. Eine Kläranlage ist z.B. als ein Objekt nicht extrahierbar, da sie keine allgemein gültige Form oder Radiometrie aufweist. Charakteristische Einzelobjekte, wie runde Klärbecken und deren räumliche Beziehungen zu anderen Objekten wie Gebäuden, können die Extraktion dennoch ermöglichen. Beispiele für räumliche Relationen sind:

- *In der Nähe* (Beschreibung einer indirekten Nachbarschaft oft ohne Berührung der Objekte mit Angabe einer Entfernung oder eines Einflussbereiches.)

- *Benachbart* (Beschreibung einer direkten Nachbarschaft mit Berührung der Objekte. Bei Bildern vorherige Festlegung einer Vierer- oder Achternachbarschaft.)
- *Innerhalb von/beinhaltet* (Ein Objekt befindet sich (vollständig) innerhalb eines anderen Objektes.)
- *Über/unter* (Beschreibung von Verdeckungen eines Objektes. Hierfür ist 3D-Information oder anderes Vorwissen nötig, da sonst keine Unterscheidung zur Relation *Benachbart* möglich ist.)

Kontext kann in globalen und lokalen Kontext unterteilt werden (siehe Abschnitt 2.4.2 und MAYER 1998). Der lokale Kontext bezieht sich auf die nähere Umgebung eines Objektes und die Anordnung von benachbarten Objekten. Ein Haus kann z.B. über die Nähe zu bzw. die Verbindung mit einer Straße definiert werden. Globaler Kontext hingegen unterteilt die zu interpretierende Szene in verschiedene Regionen, wie offene Landschaft, Wald und Siedlung. Für jede Region können unterschiedliche Methoden für die Objektextraktion und unterschiedliche Parametereinstellungen verwendet werden. Straßen bilden sich zum Beispiel in offener Landschaft anders ab als in Siedlungsbereichen und auch die lokalen Kontexte können differieren (z.B. wenig Schatten in offener Landschaft, aber viel Schatten in Siedlungsbereichen).

3.4.2 Modell für Satellitenbilder mittlerer Auflösung von Nordafrika

Mit Hilfe der im vorherigen Abschnitt dargelegten Beschreibungsebenen (siehe Abbildung 20) werden die Modelle zur Extraktion verschiedener Objektklassen aus Satellitenbildern mittlerer Auflösung von Nordafrika aufgestellt. Die Beschreibung der Eigenschaften der zu extrahierenden Objekte dient als Basis für die Auswahl der Parameter, welche in Abschnitt 5.3 im Rahmen der Experimente mit generischen Regelsätzen vorgestellt werden.

Wie in Abschnitt 5.2 eingehend erläutert wird, muss eine Wissensbasis zur Objektextraktion räumlich (und z.T. auch zeitlich) verortet werden. Daher werden in dieser Arbeit für Algerien (Nordafrika) zwei geographische Regionen definiert (siehe Abschnitt 3.3). Die eine Region wird *Küste* genannt. Sie umfasst Städte entlang der Mittelmeerküste und das Hinterland mit landwirtschaftlicher Nutzung und Waldflächen. Die zweite Region ist die *Wüste* und beinhaltet große Wüstenbereiche mit vereinzelt Siedlungen und Vegetation. Nach einer visuellen Analyse der zur Verfügung stehenden Bilddaten in Algerien wurden folgende Zielobjekte für die objektbasierte Analyse festgelegt:

- *Bebautes Gebiet*
- *Nicht bebautes Gebiet (Vegetation, landwirtschaftliche Fläche und Wüste)*
- *Straße*
- *Wasser (Meer, See, Fluss)*

Tabelle 12 listet diese Zielobjekte mit ihren jeweiligen Eigenschaften bezüglich der Abbildung in ein Satellitenbild mittlerer Auflösung auf. Die Eigenschaften der Objekte sind unterteilt in spektrale Merkmale, Textur- und Formeigenschaften, Maßstabsverhalten und weitere Eigenschaften, wie z.B. Kontext. Beim Maßstabsverhalten wird zwischen der Originalauflösung (mittlere Auflösung) und einer verringerten, d.h. schlechteren Auflösung unterschieden.

Bebautes Gebiet bildet sich im Satellitenbild mittlerer Auflösung sehr heterogen ab. Die spektralen Merkmale reichen von sehr hell für überstrahlte Dachflächen bis hin zu schwarz für Schattenbereiche von Gebäudekomplexen und in Häuserschluchten. Bedingt durch die Einzelobjekte, wie Gebäudekomplexe, Straßen, Parkflächen, Plätze, Grünflächen und Schattenbereiche und deren Relationen weist *Bebautes Gebiet* eine charakteristische Textur auf. Die Form der Segmente ist unregelmäßig aber oft rechtwinklig. Einzelobjekte wie Gebäudekomplexe können jedoch eine auffällige Form besitzen.

Landwirtschaftlich genutzte Flächen mit Bewuchs besitzen einen charakteristisch hohen *NDVI*-Wert (siehe Abschnitt 2.1.1). Felder erscheinen in niedrigen Auflösungen meist homogen und können paral-

lele Feldkanten aufweisen. *Wald* wird ebenfalls durch einen hohen *NDVI*-Wert charakterisiert, hat aber im Gegensatz zu Feldern ein heterogenes Erscheinungsbild und eher unregelmäßige Segmentformen. Zumeist bilden sich Wüstengebiete als homogene Fläche mit niedrigem *NDVI* im Satellitenbild ab. Linienförmige Dünenstrukturen und schattenwerfende Reliefstufen können die Extraktion allerdings erheblich erschweren.

Je nach Straßenbelag, Beleuchtung und Beschattung besitzt das Objekt *Straße* unterschiedliche radiometrische Merkmale. Die Straßenoberfläche erscheint meist homogen und die Segmente weisen eine lang gestreckte Form mit einer gewissen Breite auf.

Alle Wasserobjekte besitzen einen niedrigen Wert im Nahen Infrarot (NIR) sowie eine homogene Textur. Störungen z.B. durch Schiffe können in verringerter Auflösung verschwinden. Die Unterscheidung zwischen *Meer* und *See* kann z.T. anhand der Größe der gebildeten Segmente und mit Hilfe von Kontext, wie „*See* ist umgeben von Landklassen“ getroffen werden. Die Klasse *Fluss* kann von anderen Wasserobjekten z.T. mittels ihrer Langgestrecktheit differenziert werden.

Tabelle 12: Eigenschaften ausgewählter Objekte in einem Satellitenbild mittl. Auflösung von Nordafrika

Objekt		Spektrale Merkmale	Texturmerkmale	Formmerkmale	Maßstabsverhalten	Weitere Eigenschaften
Bebautes Gebiet		Verschiedene Farbtöne (überstrahlt weiß bis Schwarz), <i>NDVI</i> : niedriger Wert	heterogen	Unregelmäßig; Einzelobjekte wie Gebäudekomplexe: rechteckig	Originalauflösung: viele unterschiedliche Einzelobjekte; Verringerte Auflösung: homogenere Objekte (Textur)	
Nicht bebautes Gebiet	Landwirtschaftliche Flächen	<i>NDVI</i> : hoher Wert	homogen	Meist kompakt, rechteckig; parallele Feldkanten	„Störende“ Texturen verschwinden in verringerter Auflösung	
	Wald	<i>NDVI</i> : hoher Wert	heterogen	unregelmäßig	Originalauflösung: Baumgruppen; Verringerte Auflösung: homogenere Objekte	
	Wüste	<i>NDVI</i> : niedriger Wert	meist homogen	unregelmäßig	Verringerte Auflösung: homogenere Objekte	
Straße		Meist hell (je nach Straßenbelag, Beleuchtung)	homogen	Lang gestreckt, Breite: 3-20 m	-	Netzbildung, lokaler Kontext
Wasser	Meer	NIR: niedriger Wert	homogen	große Segmente	„Störobjekte“ wie Schiffe verschwinden in verringerter Auflösung	Relativ „sicher“ zu extrahieren
	See	NIR: niedriger Wert	homogen	-	-	Lokaler Kontext: See ist umgeben von Land
	Fluss	NIR: niedriger Wert	homogen	linienförmig	-	

Geographische Region Küste

Abbildung 21 zeigt das Modell für *Bebautes Gebiet* in der geographischen Region *Küste*. Das Modell gliedert sich in die drei Ebenen: „Reale Welt“, „Geometrie und Material“ sowie „Bild (mittlere Auflösung)“. *Bebautes Gebiet* setzt sich in der „Realen Welt“ aus den Einzelobjekten Schatten, Gebäudekomplex, Straße und Parkfläche/Platz zusammen. Beispielhafte Relationen zwischen den Objekten sind im Modell für *Bebautes Gebiet* beschrieben. Aufgrund der begrenzten geometrischen Auflösung der verwendeten Bilddaten werden die Objekte nur in 2D und nicht in 3D modelliert. Daher kann auch Schatten als Objekt im Modell der „Realen Welt“ definiert werden. In einem dreidimensionalen Modell wäre Schatten das Ergebnis von Geometrie und Sonnenstand (siehe MAYER 1998). Gebäudekomplexe können beispielsweise Schatten auf Straße und Parkfläche/Platz werfen. In der „Geometrie und Material“-Ebene wird die Form und der charakteristische Baustoff dargestellt. Schatten beispielsweise erhält seine Form je nach Schatten werfendem Objekt und Schatten kann auf alle Materialien, d.h. auf alle anderen Objekte, fallen. Die unterste Ebene „Bild“ beschreibt das Aussehen des entsprechenden Objektes im Satellitenbild mit 5 m Auflösung. Die Einzelobjekte sind meist nicht mehr voneinander trennbar. Gebäude verschmelzen beispielsweise zu Gebäudekomplexen oder bilden zusammen mit Straßenabschnitten oder Parkplätzen unregelmäßig geformte Segmente. *Bebautes Gebiet* bildet sich in der Fernerkundungsszene somit mit einer charakteristischen, zum Teil gerichteten (anisotropen) Textur ab.




Abbildung 21: Modell für *Bebautes Gebiet* in der geographischen Region *Küste*

Das Modell für *Nicht bebautes Gebiet* in der geographischen Region *Küste* (siehe Abbildung 22) besteht aus den ausgewählten Objekten der „Realen Welt“ landwirtschaftliche Fläche, Erosions- und Brachflächen sowie Wald. Schatten kann ebenfalls auftreten, wurde aber aus Gründen der Übersichtlichkeit weggelassen. Landwirtschaftliche Flächen erscheinen oft als rechtwinklige, kompakte Fläche mit Bewuchs während Erosionsflächen eher eine lang gestreckte Form ohne Bewuchs besitzen. Brachflächen und Wald zeichnen sich durch unregelmäßige Formen aus. Alle Objekte können anhand der Textur und des *NDVI* klassifiziert werden.




Abbildung 22: Modell für Nicht bebautes Gebiet in der geographischen Region Küste

Straße wird im Modell für die geographische Region *Küste* in Straßenabschnitte unterteilt (siehe Abbildung 23). Diese besitzen eine lang gestreckte Form und sind typischerweise aus Asphalt oder Beton gebaut. Im Satellitenbild mittlerer Auflösung bilden sich die Straßenabschnitte meist als helle Linien ab. *Wasser* gliedert sich in der „Realen Welt“ in die Objekte *Fluss*, *See* und *Meer* (siehe Abbildung 24). Durch die *Spezialisierungs*-Relation erben die drei letztgenannten Objekte die Eigenschaften von *Wasser*. Flüsse sind linienförmig ausgeprägt und mäandrierende Flüsse weisen starke Krümmungen auf. Meer und Seen sind hingegen unregelmäßig geformte Wasserflächen, die an Land grenzen bzw. davon umgeben sind. Im Satellitenbild erscheinen alle Wasserklassen dunkel und besitzen eine homogene Oberfläche. Ebenfalls charakteristisch ist ein niedriger Wert im *NIR*-Kanal.

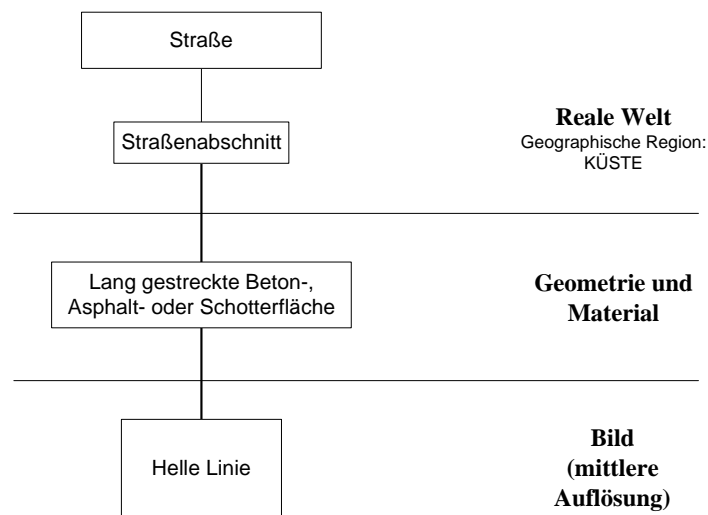


Abbildung 23: Modell für Straße in der geographischen Region Küste




Abbildung 24: Modell für Wasser in der geographischen Region Küste

Geographische Region Wüste

Die Modelle für die geographische Region *Wüste* sind z.T. ähnlich wie die der Küstenregion. Unterschiede gibt es insbesondere bei der Objektklasse *Dünen*, die in der Region *Wüste* zusätzlich auftritt. Abbildung 25 zeigt die topographischen Objekte der Wüstenregion. Die Zielklassen der Klassifizierung sind *Bebautes Gebiet*, *Nicht bebautes Gebiet*, *Straße*, sowie die Wasserklassen *See* und *Fluss*. *Nicht bebautes Gebiet* kann weiter in *Dünen flächenförmig* und *linienförmig*, *Nicht bebaut* und *Vegetation* unterteilt werden. Die beiden Klassen *Dünen & Bebaut* und *Straßen & Dünen* wurden aufgrund der Ähnlichkeiten der jeweiligen Objekte im Bild eingeführt. *Straße* und *linienförmige Dünen* besitzen eine ähnliche Form. In einem ersten Schritt werden Segmente, welche die Eigenschaften von *Straßen & Dünen* oder *Dünen & Bebaut* erfüllen, als eine Klasse extrahiert und in einem zweiten Schritt aufgrund zusätzlicher Forminformation voneinander getrennt.

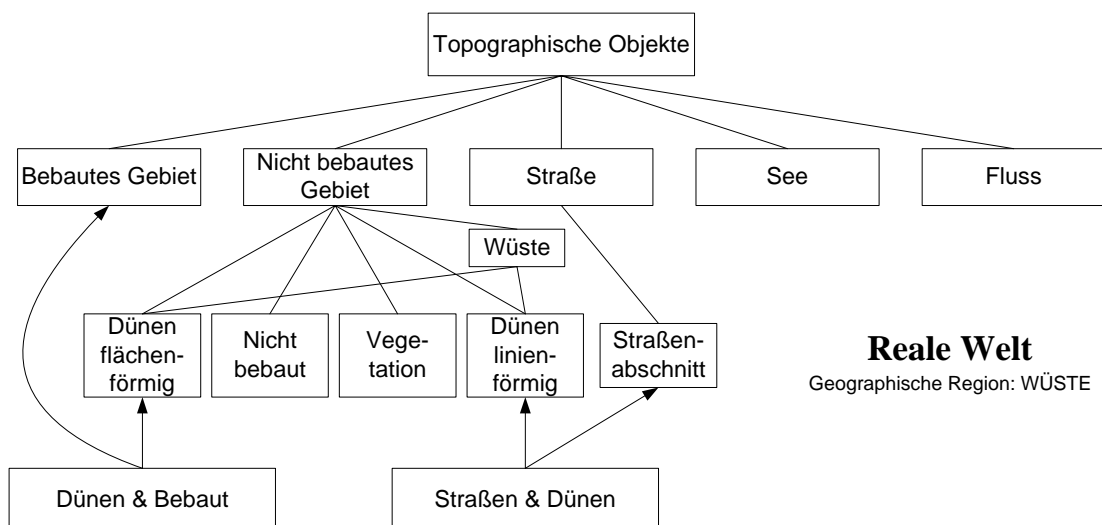


Abbildung 25: Topographische Objekte in der geographischen Region Wüste

Das gesamte Modell für die Wüstenregion stellt Abbildung 26 dar. In der oberen Ebene sind die semantischen Objekte aufgeführt. Diese beinhalten die Objekte der „Realen Welt“ und die extraktionsunterstützenden Klassen *Dünen & Bebaut* und *Straßen & Dünen*. Die spezifischen Eigenschaften der Objekte in den beiden unteren Ebenen „Geometrie und Material“ sowie „Bild (mittlere Auflösung)“ sind ähnlich wie in der Küstenregion. Die Wüstenfläche besitzt eine unregelmäßige Form, besteht aus Sand und Steinen und bildet sich im Bild als homogene Fläche und je nach Material in unterschiedlichen Farben ab. Bei Dünenstrukturen handelt es sich um lang gestreckte, erhöhte Sandstrukturen, die durch Wind erzeugt sind. Die Abbildung im Satellitenbild erfolgt als helle Linie, oft mit einem parallelen, dunklen Schattenbereich.

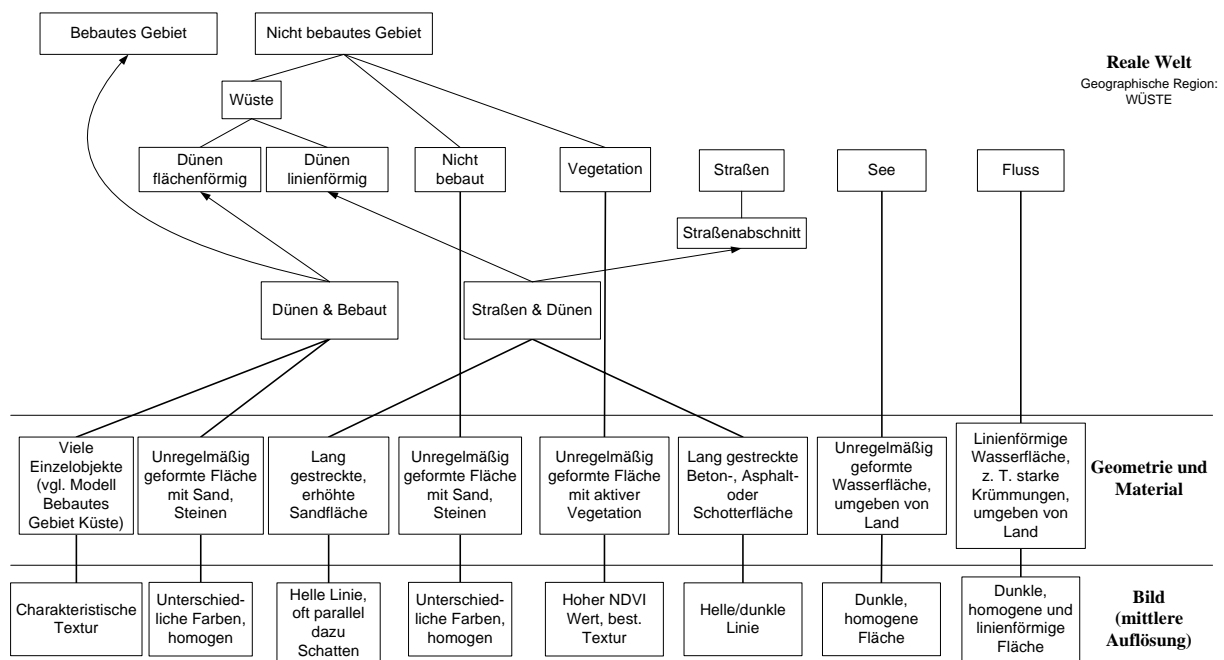


Abbildung 26: Modell für die geographische Region Wüste

3.5 Strategie und Ablauf der objektbasierten Analyse

Eine Strategie gibt einen Plan zur Erkennung der Objekte in den Bildern vor. Die Erkennung erfolgt durch Zuordnung der Daten zum Modell unter Nutzung verschiedener Methoden. Viele Strategien kombinieren zu Beginn der Extraktion unterschiedliche Arten von Informationen und Algorithmen, um Hinweise auf die gesuchten Objekte zu erhalten. So kann in bestimmten Auflösungsstufen nach „sicheren“ Objekten gesucht werden, die dann als Vorwissen in anderen Auflösungen den Suchraum einschränken. Durch Gruppierung kann ebenfalls eine Einschränkung des Suchraumes erfolgen, indem z.B. aufgrund der Nähe von Objekten oder der Gleichheit, Symmetrie, Kontinuität und Geschlossenheit Objekte zusammengefasst werden.

Die Kontrolle der Extraktion kann datengetrieben (*bottom-up*) oder modellgetrieben (*top-down*) erfolgen. Häufig werden beide Vorgehensweisen zu einer gemischten Kontrolle kombiniert (MAYER 1998). Die hier verwendete Kontrolle ist gemischt. Einerseits werden die Schritte Segmentierung und objektbasierte Analyse nacheinander durchlaufen (datengetrieben), andererseits wird das Wissen über die Objekte mit Hilfe der Regelsätze den Daten zugeordnet (modellgetrieben). Schließlich benötigt die wissensbasierte Bildanalyse noch ein Bewertungsverfahren. In diesem hier entwickelten Verfahren zur objektbasierten Analyse findet *Fuzzy Logic* Anwendung (siehe Abschnitt 2.1.7).

Zur praktischen Durchführung des in dieser Arbeit vorgestellten objektbasierten Ansatzes wird die Software eCognition eingesetzt. Die objektbasierte Analyse beginnt mit der Segmentierung (siehe Abbildung 27). Die Bilder können in einem oder mehreren *Levels* segmentiert werden. In einem ersten Schritt findet eine feine Segmentierung statt (feiner *Level*). Basierend auf der feinen Segmentierung werden die Segmente zu größeren Segmenten zusammengefasst (grober *Level*). Innerhalb eines *Levels* besitzen die Segmente in etwa die gleiche Größe. Die Objekte werden auf Grundlage der groben Segmentierung klassifiziert (siehe Abschnitt 3.2), wobei Objekteigenschaften der feineren Segmentierung genutzt werden. In einem Regelsatz sind für jede zu klassifizierende Objektklasse Zugehörigkeitsfunktionen definiert. Für jedes Segment werden die Zugehörigkeitswerte für alle Zugehörigkeitsfunktionen einer Objektklasse berechnet und zu einem Zugehörigkeitswert kombiniert. Die Kombination der Zugehörigkeitswerte erfolgt mit Hilfe der im Regelsatz spezifizierten *Fuzzy*-Operatoren *and(min)* oder *mean(arithm.)*. Die Zugehörigkeitswerte eines Segmentes werden mit einem Schwellwert verglichen. Sind alle Zugehörigkeitswerte kleiner als der Schwellwert, so wird das Segment als unklassifiziert ausgewiesen. Ansonsten wird das Segment der Objektklasse mit dem höchsten Zugehörigkeitswert zugewiesen. Der Schwellwert legt einen Mindestzugehörigkeitswert fest, ab dem eine Klassifizierung signifikant ist. Das Ergebnis der *Fuzzy*-Klassifizierung ist ein klassifiziertes Bild der Segmente. Jedes Segment besitzt als Attribute neben der zugewiesenen Objektklasse auch die Zugehörigkeitswerte der zweit- und drittbesten Klassenzuweisung. Diese Information kann zur Bewertung der Zuverlässigkeit der Klassifizierung genutzt werden. Wenn bei einem Segment zwischen der besten und zweitbesten Klasse nur ein geringer Unterschied der Zugehörigkeitswerte auftritt, dann ist die Zuverlässigkeit des klassifizierten Segmentes nicht sehr hoch.

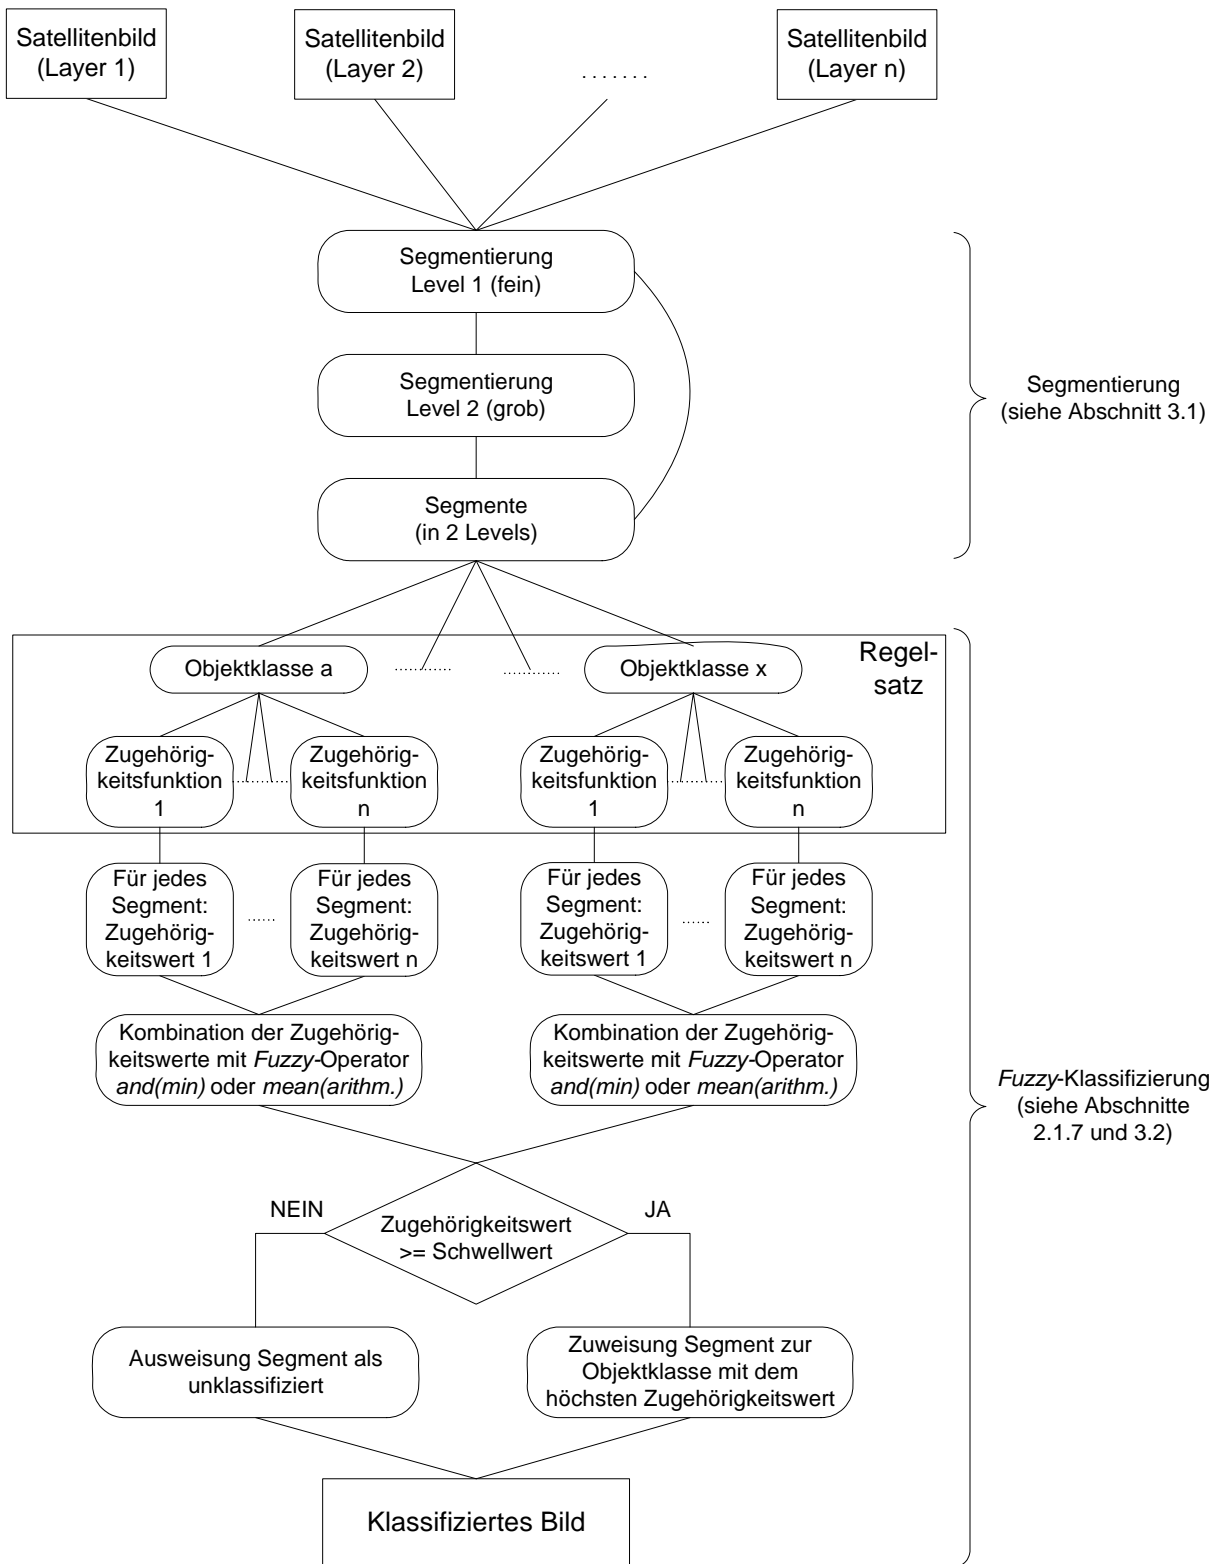


Abbildung 27: Ablauf der objektbasierten Analyse

4 Experimente ohne Modellierung der Übertragbarkeit

Das Modell für die objektbasierte Bildanalyse wurde in Abschnitt 3.4 vorgestellt. Jede Bildszene besitzt aufgrund vielfältiger Einflüsse, wie Aufnahmezeitpunkt, Beleuchtung und Atmosphärenzustand verschiedene radiometrische Merkmale. Diese Einflüsse implizieren unterschiedliche Parameterwerte für das Modell. Auch andere Segmentmerkmale wie Form und Textur können wegen unterschiedlichen geographischen Charakteristiken zwischen Bildszenen variieren. Für einen operationellen Einsatz zur Bildanalyse stellt sich damit die Frage, inwieweit das vorgestellte Modell allgemein gültig, d.h. auf andere Bildszenen übertragbar, ist. Durch Verwendung bestehender Segmentierungsparameter und Regelsätze, sowie die Anpassung letzterer, soll im Vergleich zu einer individuellen Festlegung dieser Parameter für jedes neue Bild der Auswerteprozess deutlich verkürzt werden. Die Definition eines individuellen Regelsatzes für ein Bild kann je nach Bildinhalt und zu extrahierenden Objekten für erfahrene Nutzer eine Woche oder sogar länger in Anspruch nehmen. Im Gegensatz dazu beschränkte sich bei den durchgeführten Untersuchungen der zeitliche Aufwand zur Anpassung vorhandener Regelsätze auf ca. eine bis fünf Stunden. Der Aufwand der Anpassung könnte beliebig ausgedehnt werden. **Ziel** war es, den Auswerteprozess auf etwa 10% der ursprünglichen Zeit zu verkürzen und abzuschätzen, welche Qualität mit dieser Vorgehensweise erzielt werden kann.

Nachfolgend werden Untersuchungen beschrieben, welche die prinzipielle Möglichkeit der Übertragung von Regelsätzen aus eCognition auf andere Bilder ähnlicher Charakteristik zeigen. Die Untersuchungen wurden mit „Experimente ohne Modellierung der Übertragbarkeit“ betitelt, da Regelsätze für individuelle Bilder übertragen werden. Im Gegensatz hierzu werden in Kapitel 6 Experimente mit Modellierung der Übertragbarkeit vorgestellt, wobei ein möglichst allgemein gültiger, so genannter „Basis-Regelsatz“ verwendet wird.

4.1 Übertragung innerhalb einer geographischen Region

Die prinzipielle Möglichkeit der Übertragung von Regelsätzen aus eCognition auf andere Bilder ähnlicher Charakteristik wurde anhand von acht Testgebieten untersucht. Da eine Übertragung von Regelsätzen zwischen zwei unterschiedlichen geographischen Regionen aufgrund unterschiedlichen Bildinhaltes, wie Vorkommen anderer Objekte oder verschiedenartige Ausprägungen von Objekten, nicht sinnvoll ist, wurden nur Regelsätze innerhalb einer geographischen Region (innerhalb eines Kulturkreises) übertragen. Hierzu wurden die beiden geographischen Regionen *Küste I* und *Wüste I* in Algerien definiert (siehe Abschnitt 3.3), die je vier Testgebiete umfassen. Die möglichen Einflüsse auf die Übertragbarkeit von Regelsätzen werden in Abschnitt 5.2 diskutiert. Zusätzlich zu den Regelsätzen wurden auch Segmentierungsparameter übertragen.

Für jedes Testgebiet in den beiden geographischen Regionen wurde je ein individueller Regelsatz erstellt. Die Regelsätze enthalten sowohl spektrale als auch Textur- und Forminformationen sowie Kontext. Entscheidungskriterium zur Auswahl eines Merkmals oder der Kombination von Merkmalen ist eine verbesserte Trennbarkeit von Objektklassen. Es wurden Merkmale ausgewählt, die für die Klassifizierung eines bestimmten Bildes als bedeutend erachtet wurden. Die mögliche Übertragbarkeit der Merkmale auf andere Bilder wurde zunächst außer Acht gelassen. Die Segmentierungsparameter wurden ebenfalls speziell für die individuellen Bilder gewählt.

Abbildung 28 verdeutlicht das Ablaufschema der Experimente ohne Modellierung der Übertragbarkeit für Segmentierungsparameter und Regelsätze. In einem ersten Schritt werden für jedes Bild geeignete Segmentierungsparameter und Regelsätze zur Klassifizierung aufgestellt. Die Ergebnisse dieser so genannten „Originalklassifizierung“ werden mit Hilfe der Konfusionsmatrix evaluiert (*Accuracy Assessment*; siehe Abschnitt 2.3.2). Zur Beurteilung der Qualität können Referenzdaten herangezogen werden. Idealerweise liegen diese für eine objektbasierte Klassifizierung in Form von Objekten vor. Sind keine objektbasierten Referenzdaten vorhanden, so können mit Hilfe von Referenzpixeln und der in der Fernerkundung üblichen Konfusionsmatrix Qualitätsmaße für die Güte der Klassifizierung berechnet werden. Zur Berechnung der Konfusionsmatrix wurden in ERDAS Imagine basierend auf der

Klassifizierung 512 Referenzpixel zufällig ausgewählt, wobei jede Klasse durch mindestens 50 Referenzpunkte repräsentiert wird. Die Referenzpixel wurden mangels *Ground Truths* durch eine visuelle Interpretation der vorliegenden IRS-Bilddaten gewonnen. Der Aufwand für die Gewinnung der Referenzdaten ist sehr hoch, da jedes der 512 Referenzpixel im Bild identifiziert werden muss. Problematisch sind Mischpixel, die nicht eindeutig einer Klasse zugewiesen werden können. Außerdem können bei im Bild selten vorkommenden Klassen, wie z.B. *Straße*, nur die Hälfte der entsprechenden Referenzpixel auch tatsächlich der Klasse *Straße* zugehören.

Innerhalb der jeweiligen geographischen Region *Küste I* bzw. *Wüste I* werden die originalen Segmentierungsparameter und Regelsätze auf die anderen drei Testgebiete übertragen. Sowohl das Klassifizierungsergebnis des übertragenen Regelsatzes als auch das Resultat des an das neue Bild angepassten Regelsatzes werden quantitativ evaluiert und mit den jeweiligen originalen Klassifizierungen verglichen. Ein Regelsatz wird beispielsweise durch Änderung der Wertebereiche von Objekteigenschaften angepasst oder durch die Definition neuer Objektklassen, die im neuen Testgebiet auftreten aber nicht im Regelsatz enthalten sind. Die Veränderung von Wertebereichen ist vor allem aufgrund atmosphärischer Einflüsse und unterschiedlicher Beleuchtungen notwendig (siehe Abschnitt 2.1.1). Die übertragenen Segmentierungen blieben unverändert. Insgesamt wurden bei den Experimenten ohne Modellierung der Übertragbarkeit acht Originalklassifizierungen und 24 übertragene und angepasste Klassifizierungen erstellt.

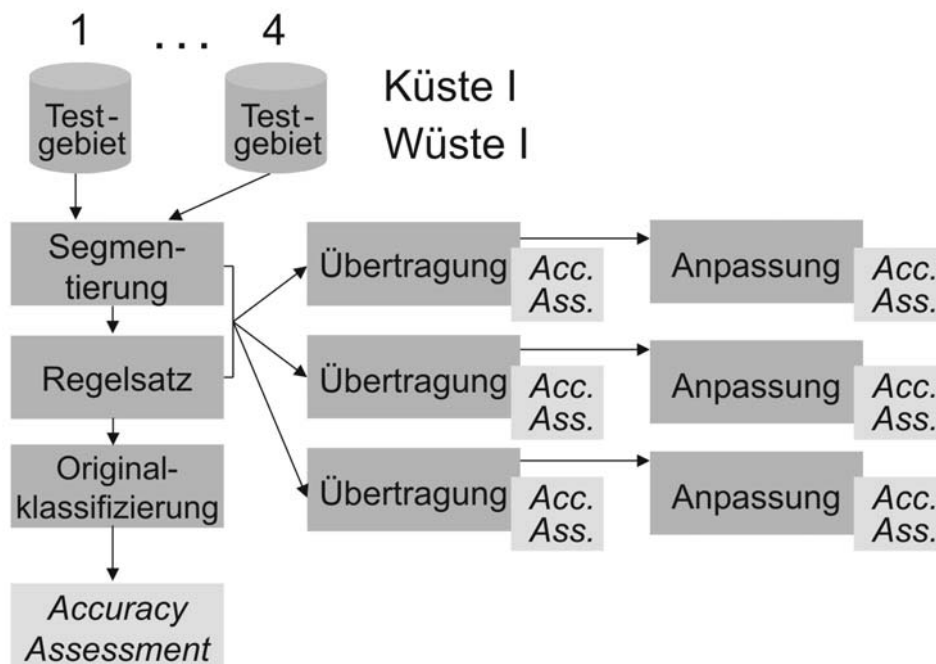


Abbildung 28: Ablaufschema der Experimente ohne Modellierung der Übertragbarkeit von Segmentierungsparametern und Regelsätzen

Tabelle 13 listet die durchschnittliche Qualität der Ergebnisse der jeweils vier Testgebiete der beiden geographischen Regionen *Küste I* und *Wüste I* auf. Es wurden jeweils die vier Basisklassen *Wasser*, *Bebautes Gebiet*, *Nicht bebautes Gebiet* und *Straße* klassifiziert. Die *Overall Accuracy (OA)* der originalen Klassifizierungen beträgt für beide Regionen 89%. Der *Kappa Index (KI)* ist für die Küstengebiete mit 0,83 deutlich besser als in den Wüstengebieten (0,66). Eine Erklärung hierfür ist, dass insbesondere Siedlungsgebiete in der Wüste oftmals nur in Form von zerstreuten Einzelgebäuden vorkommen, die schwieriger zu klassifizieren sind als große, zusammenhängende bebaute Gebiete der Küstenregion. Die Qualitätsmaße für das Ergebnis des übertragenen Regelsatzes fallen im Vergleich zur originalen Klassifizierung deutlich schlechter aus (z.B. *OA Küste*: 74% zu 89%). Durch eine Anpassung des Regelsatzes an die Besonderheiten des neuen Bildes kann eine Steigerung sowohl der *OA* als auch des *KI* erreicht werden. Die Qualität der angepassten Klassifizierungen erreichen jedoch aufgrund der

eingeschränkten Zeitvorgaben nicht ganz die Werte der Originalklassifizierungen. In *Wüste I* wird mit einer OA von 86% für die angepasste Klassifizierung nahezu der Wert der originalen Klassifizierung von 89% erreicht. Etwas schlechter sieht das Ergebnis für *Küste I* aus. Statt einer originalen OA von 89% kommt die angepasste Klassifizierung nur auf 78%.

Tabelle 13: Qualität der originalen, übertragenen und angepassten Klassifizierung

	<i>Küste I</i>			<i>Wüste I</i>		
	Original	Übertragen	Angepasst	Original	Übertragen	Angepasst
Overall Accuracy	89 %	74 %	78 %	89 %	82 %	86 %
Kappa Index	0,83	0,57	0,65	0,66	0,27	0,56

Neben der Klassifizierung der vier Basisklassen *Wasser*, *Bebautes Gebiet*, *Nicht bebautes Gebiet* und *Straße* wurden auch detailliertere Klassifizierungen durchgeführt. Je nach Auftreten bestimmter Objektklassen wurden z.B. die Klasse *Wasser* in *Meer*, *See* und *Fluss* und *Bebautes Gebiet* in *hohe* und *niedrige Dichte* differenziert. Die detaillierten Klassifizierungen umfassen bis zu acht Objektklassen. Beim Vergleich der OA der Basisklassifizierung und der detaillierten Klassifizierung zeigt sich, dass die Basisklassifizierung mit vier Klassen eine gleiche oder höhere Qualität aufweist. Detailliertere Klassen haben einerseits den Vorteil, dass Objekte, die zuvor als z.T. der einen und z.T. der anderen Basisklasse zugehörig waren, nun ihre eigene angepasste Beschreibung bekommen. Andererseits können um so mehr Fehler gemacht werden, je mehr Klassen es gibt, da die Klassen sehr speziell sind.

Zu den individuellen Objektklassen ist festzustellen, dass die Klasse *Wasser* eine ähnliche Qualität bei den originalen sowie den übertragenen und angepassten Klassifizierungen aufweist und damit auf eine gute Übertragbarkeit geschlossen werden kann. Bei der Klasse *Bebautes Gebiet* und *Nicht bebautes Gebiet* wird durch Anpassung der Regelsätze eine deutliche Qualitätssteigerung erreicht. Für *Straße* kann keine eindeutige Aussage getroffen werden. In der geographischen Region *Küste I* sind die Ergebnisse der angepassten Klassifizierung deutlich schlechter als die der übertragenen, gegensätzliches gilt für die Region *Wüste I*. In der Region *Küste I* sind in der übertragenen Klassifizierung nur wenige, vor allem breite Straßen extrahiert. Durch Anpassung des Regelsatzes werden deutlich mehr Straßen, darunter auch schmalere Straßen, extrahiert. Die Anzahl der als *Straße* fehlklassifizierten Segmente stieg jedoch und führte zu einer Verschlechterung des *Kappa Index*. Diese Problematik wird anhand eines Beispiels verdeutlicht.

Abbildung 29 zeigt die Übertragung und Anpassung des für das Testgebiet „Mostaganem“ optimierten Regelsatzes. Links ist ein Ausschnitt des IRS-Bildes vom Testgebiet „Jijel“ dargestellt. In der Mitte ist das dazugehörige Ergebnis der übertragenen Klassifizierung abgebildet und rechts das des angepassten Regelsatzes. Im übertragenen Regelsatz gibt es nur eine Wasserklasse, da im Testgebiet „Mostaganem“, für welches der Regelsatz ursprünglich aufgestellt worden war, nur Meer vorkam. In der übertragenen Klassifizierung wurden das Meer und ein See korrekt der Klasse *Wasser* zugewiesen (dunkelblau). Der Fluss wurde bis auf den Mündungsabschnitt nicht erkannt. Beim Anpassen des Regelsatzes an das Testgebiet „Jijel“ wurden die Klassen *See* und *Fluss* hinzugefügt. Im Ergebnis der angepassten Klassifizierung rechts ist erkennbar, dass die beiden Seen korrekt detektiert wurden (hellblau). Die Trennung der spektral ähnlichen Klassen *Meer* und *See* erfolgt über Kontextinformation. Die Klasse *See* weist eine bestimmte Nachbarschaft zu bzw. ist umgeben von Landklassen auf. Auch der Fluss wurde größtenteils korrekt klassifiziert.




Abbildung 29: IRS-Bild „Jijel“ (links), übertragene Klassifizierung (Mitte) und angepasste Klassifizierung (rechts) - Bebautes Gebiet: rot, Nicht bebautes Gebiet: grün, Straße: gelb, Wasser: dunkel- bzw. hellblau

Die Ergebnisse der Qualitätsbetrachtung zur Übertragung und Anpassung des Regelsatzes von „Mostaganem“ auf „Jijel“ (vier Basisklassen *Wasser*, *Bebautes Gebiet*, *Nicht bebautes Gebiet* und *Straße*) sind in Tabelle 14 aufgeführt. Sowohl die *OA* als auch der *KI* des Ergebnisses des übertragenen Regelsatzes liegen deutlich unter den Werten für die originale Klassifizierung des Testgebietes „Jijel“ und dem Ergebnis für den angepassten Regelsatz. Durch die Anpassung wird das Klassifizierungsergebnis enorm verbessert und in diesem Beispiel sogar die Qualität der originalen Klassifizierung erreicht.

Tabelle 14: Qualität der übertragenen und angepassten Klassifizierung von „Mostaganem“ auf „Jijel“

	Übertragung von „Mostaganem“ auf „Jijel“		
	Original „Jijel“	Übertragen	Angepasst
Overall Accuracy	87 %	80 %	87 %
Kappa Index	0,8	0,69	0,8

Tabelle 15 zeigt die Qualität für die Ergebnisse individueller Klassen bei Übertragung des Regelsatzes von „Mostaganem“ auf „Jijel“. Die linke Tabelle zeigt die *KI* der Klassifizierung der vier Basisklassen *Wasser*, *Bebautes Gebiet*, *Nicht bebautes Gebiet* und *Straße*. Die Klassen *Bebautes Gebiet* und *Nicht bebautes Gebiet* werden durch die Anpassung des Regelsatzes erheblich verbessert. *Wasser* erfährt eine geringfügige Verschlechterung. Im übertragenen Regelsatz von „Mostaganem“ ist nur die Klasse *Meer* definiert. Bei der Anpassung des Regelsatzes an „Jijel“ müssen Regeln für die Klassen *See* und *Fluss* hinzugefügt werden. Bei der detaillierten Klassifizierung (rechte Tabelle) ist erkennbar, dass die flächenförmigen Wasserklassen *Meer* und *See* sehr gut zu klassifizieren sind (*KI* 1,0), während der linienförmige *Fluss* Probleme bereitet (*KI* 0,46). Der mäandrierende Fluss ist an zahlreichen Stellen relativ schmal, enthält Sandbänke und weist nur wenig Kontrast zur Umgebung auf. Die Anpassung des Regelsatzes für die Klasse *Straße* überrascht durch eine Verschlechterung des *KI* (von übertragen 0,62 auf 0,45 angepasst). Wie bereits erläutert, stieg mit der Anpassung die Zahl der korrekt klassifizierten Straßen aber auch die der fehlklassifizierten Segmente, was sich negativ im *KI* ausdrückt.

Tabelle 15: Qualität individueller Klassen bei Übertragung des Regelsatzes von „Mostaganem“ auf „Jijel“

Übertragung von „Mostaganem“ auf „Jijel“	<i>Kappa Index</i>			<i>Kappa Index</i>
	Übertragen	Angepasst		
Wasser	0,99	0,93	Meer	1,0
Bebautes Gebiet	0,59	0,74	See	1,0
Nicht bebautes Gebiet	0,56	0,76	Fluss	0,46
Straße	0,62	0,45		

Segmentierung

Nachfolgend werden die Segmentierungsparameter der einzelnen Testgebiete miteinander verglichen und eine Aussage zu deren Übertragbarkeit auf andere Bilder getroffen. Dies ist wichtig im Hinblick auf die Festlegung einheitlicher Segmentierungsparameter für eine geographische Region. Wie für die originale Klassifizierung wurden auch für die originale Segmentierung für jedes Testgebiet in *Küste I* und *Wüste I* individuelle Parameter verwendet. Die Wahl der Segmentierungsparameter beruht zum Teil auf Erfahrungswerten, aber auch auf Tests mit unterschiedlichen plausiblen Werten. Die Beurteilung der Güte der Segmentierung erfolgte rein visuell. Tabelle 16 zeigt die originalen Segmentierungsparameter für *Küste I* und *Wüste I*. In der Küstenregion stimmen die *Scale Parameter (SP)* gut überein, nur das Testgebiet „Mandoura“ fällt aus der Reihe. Betrachtet man dieses Testgebiet, so erklären die weit zerstreuten und kleinflächigen Siedlungen und nur sehr schmalen Straßen die Verwendung eines kleineren *SP*, um feinere Segmente zu erhalten. Die Gewichtungen von Farbe und Form sind für alle Testgebiete ähnlich. Geringe Abweichungen in der Gewichtung von beispielsweise Glattheit und Kompaktheit sind z.T. visuell nicht signifikant. Größere Unterschiede im *SP* sind bei den Wüstenregionen anzutreffen. Zwei Testgebiete wurden mit größeren *SP* (26 und 36) segmentiert, wohingegen die anderen beiden Bilder mit einem relativ kleinen *SP* von 15 bearbeitet wurden. Letztere, d.h. „Hassi-El-Frid“ und „Nordöstlich von Ouargla“ enthalten im Gegensatz zu den anderen Testgebieten nur sehr spärliche Siedlungsbereiche mit vielen Einzelhäusern.

Tabelle 16: Segmentierungsparameter für *Küste I* und *Wüste I*

Segmentierungsparameter	Testgebiete <i>Küste I</i>			
	„Algier“	„Mostaganem“	„Jijel“	„Mandoura“
<i>Scale Parameter</i>	25	26	26	15
Farbe	0,8	0,7	0,7	0,8
Form	0,2	0,3	0,3	0,2
Glattheit	0,6	0,6	0,6	0,6
Kompaktheit	0,4	0,4	0,4	0,4

Segmentierungsparameter	Testgebiete <i>Wüste I</i>			
	„Ouargla“	„Hassi-El-Frid“	„Nordöstlich von Ouargla“	„N’Goussa“
<i>Scale Parameter</i>	36	15	15	26
Farbe	0,7	0,8	0,8	0,8
Form	0,3	0,2	0,2	0,2
Glattheit	0,6	0,9	0,6	0,8
Kompaktheit	0,4	0,1	0,4	0,2

Die Ergebnisse der Experimente zeigen durchweg, dass die Segmentierungsparameter auf Bilder ähnlicher Charakteristik übertragbar sind. Geringfügige Änderungen des *SP* haben keine sichtbaren Auswirkungen auf die Segmentierung. Lediglich bei linienförmigen Objekten wie Straßen und Flüssen ist die Segmentierung mit den übertragenen Parametern nicht immer zufrieden stellend. Werden durch eine Segmentierung die zu klassifizierenden Segmente nicht optimal abgebildet, so resultieren Fehlklassifizierungen, da die für eine Objektklasse typischen Merkmale nicht vorliegen. So können Straßenstücke mit umgebenden spektral ähnlichen Segmenten verschmelzen und besitzen dann keine linienhafte Form, die z.B. als Klassifizierungsmerkmal für Straßen genutzt wird. Eine Änderung der Objektmerkmale nützt in einem solchen Fall wenig, da dann die Übertragbarkeit nicht mehr gegeben ist.

Zusammenfassend zeigen die Ergebnisse der Übertragung, dass Segmentierungsparameter und Regelsätze, die für ein Bild entwickelt wurden, auf andere Bilder desselben Sensors mit ähnlichem geographischen Inhalt übertragbar sind. Die Qualität für die Ergebnisse der Übertragung ohne Anpassung an die Eigenheiten des neuen Bildes ist aufgrund der dargestellten vielfältigen Einflüsse deutlich niedriger als die der Originalklassifizierungen. Durch Anpassung der Regelsätze kann aber unter vergleichsweise geringem Aufwand trotz nicht durchgeführter radiometrischer und topographischer Korrekturen sowie unterschiedlicher Aufnahmezeitpunkte eine Verbesserung der *Overall Accuracy* und auch des *Kappa Index* auf akzeptable Werte erzielt werden.

4.2 Übertragung innerhalb eines Satellitenbildstreifens

Die beiden Wüstentestgebiete „Ouargla“ und „N’Goussa“ liegen im gleichen Satellitenbildstreifen. Die Ergebnisse werden im Weiteren dahin gehend analysiert, ob die Übertragbarkeit innerhalb des gleichen Streifens einfacher vonstatten geht, d.h. mit weniger Anpassungen des Regelsatzes, als die Übertragung zwischen unterschiedlichen Streifen.

Tabelle 17 zeigt die Ergebnisse der Klassifizierungen mit übertragenem und angepasstem Regelsatz von „Ouargla“ nach „N’Goussa“ und umgekehrt. Die Übertragung des Regelsatzes von „Ouargla“ auf „N’Goussa“ liefert mit einer *OA* von 92,2% sehr gute Ergebnisse. Durch Anpassung des Regelsatzes wird sogar ein *KI* von 0,81 erreicht, der höher als der *KI* der originalen Klassifizierung ist (0,74). Hingegen bringt die Anwendung des Regelsatzes von „N’Goussa“ auf „Ouargla“ sehr schlechte Ergebnisse mit einem *KI* von 0,04. Durch Anpassung des Regelsatzes kann der *KI* auf 0,68 verbessert werden, was allerdings immer noch deutlich schlechter ist als der originale *KI* von 0,76. Gründe für die schlechte Übertragbarkeit des Regelsatzes von „N’Goussa“ auf „Ouargla“ sind folgende:

Der Regelsatz von „N’Goussa“ beinhaltet keine Objektklasse *Wasser*. Im Testgebiet „Ouargla“ ist allerdings Wasser vorhanden, welches daher fehlklassifiziert wird. Des Weiteren werden bei den Klassen *Bebautes Gebiet* und *Straße* Kontextmerkmale verwendet, die in „Ouargla“ nicht erfüllt sind. Dieses Beispiel zeigt, dass Kontext, wie Nachbarschaft zu einer anderen Objektklasse oft nur innerhalb eines geographisch homogenen Gebietes, nicht aber innerhalb eines Bildstreifens stabil ist. Die Definition allgemein gültigen Kontexts ist sehr schwierig. Der besser übertragbare Regelsatz von „Ouargla“ beinhaltet keine Kontextmerkmale. Anpassungen mussten für einige spektrale Merkmale sowie für ein

Texturmerkmal erfolgen. Obwohl sich beide Testgebiete innerhalb eines Bildstreifens befinden, ist aufgrund des vielfältigen Erscheinungsbildes der topographischen Objekte eine Anpassung des Regelsatzes notwendig, um ein akzeptables Klassifizierungsergebnis zu erhalten. Abbildung 30 zeigt Ausschnitte mit Wüste aus beiden Testgebieten und verdeutlicht die große Vielfalt der zu klassifizierenden Objektklassen. Manche Wüstengebiete weisen linienförmige Dünenstrukturen auf, andere hingegen Geländekanten mit Schattenwurf und je nach vorherrschendem Material unterscheiden sich Wüstenabschnitte auch spektral sehr stark. Der Aufwand für die Anpassung innerhalb eines Bildstreifens ist in der Tendenz aber geringer als zwischen unterschiedlichen Bildstreifen.

Tabelle 17: Qualität bei Übertragung des Regelsatzes von „Ouargla“ auf „N’Goussa“ und vice versa

	„Ouargla“ Originalklassifizierung	Übertragen auf „N’Goussa“	Angepasst für „N’Goussa“	„N’Goussa“ Originalklassifizierung
<i>OA</i>	86,7 %	92,2 %	95,7 %	92,2 %
<i>KI</i>	0,76	0,64	0,81	0,74

	„N’Goussa“ Originalklassifizierung	Übertragen auf „Ouargla“	Angepasst für „Ouargla“	„Ouargla“ Originalklassifizierung
<i>OA</i>	92,2 %	63,5 %	83,8 %	86,7 %
<i>KI</i>	0,74	0,04	0,68	0,76




Abbildung 30: Vielfältiges Erscheinungsbild der Objektklasse *Wüste* in den beiden Testgebieten „Ouargla“ und „N’Goussa“

4.3 Übertragung zwischen unterschiedlichen Satellitenbildstreifen

Anhand der beiden überlappenden Testgebiete „Ouargla“ und „Nordöstlich von Ouargla“ aus zwei unterschiedlichen Bildstreifen werden Einflussfaktoren veranschaulicht, welche die Übertragbarkeit von Regelsätzen erschweren können. Abbildung 31 zeigt links einen Ausschnitt aus dem Testgebiet „Ouargla“ und rechts den entsprechenden Bereich aus „Nordöstlich von Ouargla“. Im rechten Ausschnitt erscheint die Vegetation in sehr dunklem Rot (Farbinfrarotbild) und das bebaute Gebiet ist ebenfalls sehr dunkel. Das linke, insgesamt hellere Bild, ist optisch viel besser interpretierbar. Die helleren Bereiche weisen bessere Kontraste auf als im dunkleren Bild, wo z.B. nur schwer zwischen Wasser- und Vegetationsflächen unterschieden werden kann und einzelne Häuser zu Blöcken verschmelzen.

Bei der Anpassung der Regelsätze an das neue Testgebiet reichte es zum großen Teil aus, die Wertebereiche bestehender Objektmerkmale anzupassen. Die Anpassungen erfolgen für die nachfolgend aufgeführten Merkmale: spektrale Merkmale, Textur, Kontext und Form. Die meisten Änderungen müssen für die spektralen Merkmale durchgeführt werden, während Formeigenschaften sich als relativ stabil erweisen. Nur in wenigen Fällen ist es zur Klassifizierung einer Objektklasse nötig, neue Objektmerkmale in den Regelsatz einzuführen und/oder bestehende Merkmale zu löschen. In der Regel kann also die Struktur eines Regelsatzes für ein anderes Bild hergenommen werden, lediglich die Parameterwerte müssen angepasst werden.

Tabelle 18 führt die Werte der Qualitätsbetrachtung auf. Der Regelsatz von „Ouargla“ liefert bei der Übertragung bessere Ergebnisse als der von „Nordöstlich von Ouargla“. Grund hierfür ist die schlechte Qualität des Bildes „Nordöstlich von Ouargla“, wodurch spezielle Merkmale erforderlich sind.



Abbildung 31: Radiometrische Unterschiede zwischen zwei überlappenden Testgebieten (links: „Ouargla“, rechts: „Nordöstlich von Ouargla“)

Tabelle 18: Qualität bei Übertragung des Regelsatzes von „Ouargla“ auf „Nordöstlich von Ouargla“ und vice versa

	„Ouargla“ Originalklassifizierung	Übertragen auf „Nordöstlich von Ouargla“	Angepasst für „Nordöstlich von Ouargla“
<i>OA</i>	86,7 %	89,9 %	93,9 %
<i>KI</i>	0,76	0,37	0,71

	„Nordöstlich von Ouargla“ Originalklassifizierung	Übertragen auf „Ouargla“	Angepasst für „Ouargla“
<i>OA</i>	90,6 %	72,7 %	69,9 %
<i>KI</i>	0,67	0,15	0,53

5 Modellierung der Übertragbarkeit

Im Weiteren wird unter Modellierung der Übertragbarkeit verstanden, dass in den Regelsätzen zur Klassifizierung möglichst nur allgemein gültige, d.h. übertragbare, und stabile Segmentmerkmale, die nur wenig angepasst werden müssen, verwendet werden. Im Gegensatz dazu wurden bei der Übertragung ohne Modellierung in Kapitel 4 Regelsätze, die für einzelne Bilder optimiert waren, übertragen. Die nächsten Abschnitte beschäftigen sich mit der Übertragbarkeit der Segmentierung sowie der Klassifizierung. Auf die potenziellen Einflussfaktoren für die Übertragbarkeit wird ausführlich eingegangen.

5.1 Übertragbarkeit der Segmentierung

Unterschiedliche Arten von Objekten, besonders linien- und flächenförmige, können verschiedene Segmentierungen erfordern. Zum einen variiert die Form der Segmente zwischen lang gestreckt und kompakt, und zum anderen kann die Größe der gebildeten Segmente sehr unterschiedlich sein. Zur Extraktion linienförmiger Segmente ist eine höhere Auflösung als für flächenhafte Objekte nötig. Bei letzteren kann eine schlechtere Auflösung die Erkennung unter Umständen sogar verbessern, da „störende“ Details vor allem in Form von Texturen verschwinden.

Die Bildung von Segmenten sowie die Übertragbarkeit von Segmentierungsparametern hängt bei der hier angewendeten Segmentierungsmethode des *Region Mergings* stark von der Homogenität der Bilddaten und von lokalen Kontrasten ab. Der Bildinhalt kann außer der Beschränkung auf eine bestimmte geographische Region nicht beeinflusst werden. Durch Verfahren der Bildvorverarbeitung, wie z.B. atmosphärische Korrekturen, kann der Kontrast eines Bildes verbessert werden. Die Übertragbarkeit einer Segmentierung auf ein anderes Gebiet ähnlicher Charakteristik kann visuell überprüft werden und/oder durch Evaluation der anschließenden Klassifizierung, die auf den gebildeten Segmenten basiert. Zusätzlich kann als Anhaltspunkt für die Übertragbarkeit der Segmentierungsparameter ein Vergleich der durchschnittlichen Segmentgrößen und Zahl der Segmente dienen. In Tabelle 19 sind die durchschnittlichen Segmentgrößen in Pixel bei Übertragung der Segmentierungsparameter vom Testgebiet „Mostaganem“ auf drei andere Testgebiete in der Region *Küste I* angegeben. Die Testgebiete liegen in unterschiedlichen Szenen und weisen verschiedene Aufnahmezeitpunkte auf. In der Tabelle wird zwischen Segmentierungsebene *Level 2 (SP 15)* und *Level 3 (SP 26)* unterschieden. Die Durchschnittsgröße der gebildeten Segmente in den vier Testgebieten ist in diesem Fall vergleichbar.

Tabelle 19: Durchschnittliche Segmentgröße in Pixel bei Übertragung der Segmentierungsparameter von „Mostaganem“ auf drei andere Testgebiete

	„Mostaganem“	„Algier“	„Jijel“	„Mandoura“
<i>Level 2 (SP 15)</i>	184	180	173	223
<i>Level 3 (SP 26)</i>	467	477	443	574

Die Übertragung der Segmentierung für flächenförmige Objekte ist in der Regel unproblematisch. Bei linienförmigen Objekten können hingegen bei ungeeigneter Wahl des *Scale Parameters* für die Klassifizierung ungeeignete Segmente entstehen. Insbesondere bei schmalen, linienförmigen Objekten spielt der Kontrast zur Umgebung eine große Rolle. Bei schwachem Kontrast verschmelzen linienförmige Segmente bei sehr hohem *SP* mit angrenzenden Flächen. Abbildung 32 zeigt anhand von zwei Beispielen aus der *Wüste* ungünstig geformte Straßensegmente. Die für Straßen charakteristische lang gestreckte Form der Segmente ist dadurch nicht mehr gegeben und typische Objektmerkmale wie Längen- zu Breitenverhältnis und eine geringe Kompaktheit treffen nicht zu. Die Ausprägung der Objekte hat einen ebenso starken Einfluss auf die Übertragbarkeit von Segmentierungsparametern. Während in einem Gebiet breite, befestigte und gut erkennbare Straßen vorkommen, können in anderen

Gebieten schmale und unbefestigte Verkehrswege vorherrschen. Für die Extraktion linienförmiger Objekte wird insgesamt die Erzeugung kleinerer Segmente bevorzugt.




Abbildung 32: Ungünstig geformte Straßensegmente aufgrund zu schwachen Kontrasts (Region *Wüste*)

5.2 Übertragbarkeit der Klassifizierung

Der Aufbau einer Wissensbasis bzw. von Regelsätzen in eCognition zur Interpretation eines Bildes ist zeitaufwändig. Für eine operationelle und automatisierte Nutzung ist die Allgemeingültigkeit (Generik) der Regelsätze eine Grundvoraussetzung. Um dies zu gewährleisten, müssen für die Beschreibung einer Objektklasse übertragbare Merkmale und Kontext gefunden werden, die in mehreren Bildszenen eines spezifischen Sensors die Objektklasse zuverlässig beschreiben. Zahlreiche Einflussgrößen beeinträchtigen die Übertragung von Regeln zwischen unterschiedlichen Bildern.

Tabelle 20 listet potenzielle Einflüsse auf die Übertragung von Regelsätzen auf. Bedingt durch unterschiedliche Beobachtungs- und Beleuchtungsrichtungen können Helligkeit, Farbe und Kontrast der Objekte in zwei Bildern stark variieren (siehe Abbildung 3). Die Feuchtigkeit der Materialien und die atmosphärischen Einflüsse haben ebenfalls Auswirkungen auf die spektralen Eigenschaften der abgebildeten Objekte. Die atmosphärischen Einflüsse können außerdem eine Kontrastverminderung bewirken. Der Aufnahmezeitpunkt ist besonders bei Vegetation in Regionen mit ausgeprägten Jahreszeiten kritisch (z.B. Laubbäume mit bzw. ohne Belaubung). Andere spezielle Situationen, wie z.B. Schneebedeckung, werden in dieser Arbeit nicht berücksichtigt. Topographische Geländeerhebungen, Gebäude oder Bäume können Schatten werfen, was die spektralen Eigenschaften der beschatteten Objekte stark beeinflusst, da im Schatten vor allem diffuses blaues Licht des Himmels, aber evtl. auch farbiges Licht sonnenbeleuchteter benachbarter Objekte vorherrscht. Zusätzlich können Objekte auch noch verdeckt werden. Bilder aus zwei vollkommen verschiedenen geographischen Regionen weisen unterschiedliche Bildinhalte auf. Es treten andere Objekte auf und ähnliche Objekte können in gänzlich unterschiedlichen Ausprägungen vorkommen.

Tabelle 20: Einflüsse auf die Übertragung

Einfluss	Auswirkung (auf)
Beobachtungsrichtung	Helligkeit, Farbe, Kontrast
Feuchtigkeit der Materialien	Spektrale Eigenschaften
Atmosphärische Einflüsse	Kontrastverminderung → Spektrale Eigenschaften
Aufnahmezeitpunkt (Sonnenstand, Jahreszeit)	Beleuchtungsrichtung → Spektrale Eigenschaften, Schatten; phänologisches Erscheinungsbild von Vegetation
Geländere relief, Gebäude, Bäume	Schatten → Spektrale Eigenschaften; zum Teil Informationsverlust durch Verdeckungen
Geographische Region	Bildinhalt, vorkommende Objekte in unterschiedlichen Ausprägungen

Die folgenden zwei Abschnitte beschreiben mögliche Maßnahmen zur Reduzierung der erwähnten Einflüsse auf die Übertragbarkeit einer Wissensbasis bzw. eines Regelsatzes.

Räumliche und zeitliche Festlegung der Wissensbasis/Regelsatz

Aufgrund des vielfältigen Erscheinungsbildes topographischer und auch *man-made* Objekte kann sicherlich kein allgemein gültiges, globales Wissen aufgestellt werden. Siedlungen besitzen z.B. ein gänzlich anderes Erscheinungsbild in Afrika als in Mitteleuropa und ein tropischer Regenwald weist andere Charakteristiken auf als ein mitteleuropäischer Wald. Daher muss eine Wissensbasis für eine

bestimmte geographische Region, wie beispielsweise Wüsten- oder Küstengebiete in Nordafrika, angepasst werden oder es gibt eine allgemeine Wissensbasis, die mit verschiedenen Parametern für eine Region spezialisiert wird. Vegetation weist je nach geographischer Lage ein jahreszeitenabhängiges Erscheinungsbild (z.B. spektrale Reflexion) auf. Innerhalb einer (Vegetations-)Objektklasse können abhängig vom Gesundheitszustand, der Artenzusammensetzung, Bestockungsdichte, Richtungsverteilung der Beleuchtung und Blickrichtung Variationen auftreten (HILDEBRANDT 1996). In Gebieten mit ausgeprägten Jahreszeiten, wie in Mitteleuropa, kann eine Wissensbasis nur für eine bestimmte Jahreszeit (z.B. Sommer oder Winter) definiert werden. Eine Wissensbasis bzw. Regelsatz sollte demnach für eine bestimmte geographische Region und bei ausgeprägten Jahreszeiten für eine eingeschränkte Zeit des Jahres definiert werden.

Radiometrische und topographische Korrekturen

Atmosphärische und topographische Einflüsse erschweren die Übertragbarkeit der Wissensbasis. Die am Sensor ankommende und aufgezeichnete Strahlung ist durch die Atmosphäre verändert. Die Variationen der Atmosphäre können zeitlich und örtlich schwanken, so dass dieselben Objekte in Daten unterschiedlicher Aufnahmezeitpunkte verschiedene Wertebereiche von Eigenschaften aufweisen können. Mit Hilfe von Korrekturen können Atmosphäreinflüsse und reliefbedingte Helligkeitsunterschiede vermindert werden. Radiometrische Korrekturen erfordern allerdings zuverlässige und detaillierte Atmosphärendaten zum Aufnahmezeitpunkt. Für eine topographische Korrektur ist ein Digitales Geländemodell oder Oberflächenmodell entsprechender Genauigkeit unerlässlich. Je nach geographischer Region und Zeitpunkt kann die Beschaffung dieser Daten problematisch sein (siehe Abschnitt 3.3).

Übertragbarkeit von Merkmalen

Ein übertragbarer Regelsatz muss aus invarianten, d.h. in mehreren Bildszenen stabilen Eigenschaften, bestehen. Tabelle 21 stellt die Abhängigkeiten der Merkmalsgruppen Radiometrie, Textur, Form und Kontext vom Sensor und vom geographischen Gebiet dar. Ein „x“ bedeutet die Abhängigkeit von Sensor bzw. Gebiet und ein „-“ steht für Unabhängigkeit, d.h. das entsprechende Merkmal ist in Bildern verschiedener Sensoren oder in anderen geographischen Gebieten stabil. Der Sensor wird sowohl hinsichtlich seiner radiometrischen als auch geometrischen Auflösung betrachtet.

Tabelle 21: Abhängigkeit der Merkmale von Sensor und Gebiet

Abhängig von		Merkmalsgruppe			
		Radiometrie	Textur	Form	Kontext
Sensor	Radiometrische Auflösung	x	-	-	-
	Geometrische Auflösung	x	x	x	x
Gebiet		x	x	x	-

Die Radiometrie von Segmenten wird vom Sensor und vom Gebiet beeinflusst. Siedlungen in verschiedenen geographischen Regionen können zum Beispiel aufgrund unterschiedlicher Baumaterialien und Bauweisen völlig ungleiche spektrale Eigenschaften besitzen. Formmerkmale sind ebenso wie Textur und Kontext von den radiometrischen Eigenschaften des verwendeten Sensors unabhängig. Die geometrische Auflösung beeinflusst insofern die Formmerkmale, als sich beispielsweise linienförmige Objekte in hoher Auflösung flächenförmig abbilden, während sie in niedriger Auflösung linienförmig erscheinen oder sogar verschwinden. Beschreibende Formmerkmale, wie Langgestrecktheit und Rechtwinkligkeit bleiben aber in verschiedenen Auflösungen erhalten und können zur Objektextraktion verwendet werden. Zwischen verschiedenen geographischen Regionen kann die Form von Objek-

ten variieren (rechtwinklige Häuser versus runde Hütten). Kontext ist von der geometrischen Auflösung abhängig, da alle für die Relation relevanten Objekte im Bild in ausreichender räumlicher Ausdehnung vorhanden sein müssen. Allgemein gültiger Kontext ist von der geographischen Region relativ unabhängig.

Radiometrische Merkmale werden durch die bereits erwähnten atmosphärischen Einflüsse und das jahreszeitenabhängige Erscheinungsbild von Vegetation erheblich beeinflusst, so dass keine direkte Übertragbarkeit gegeben ist. Auch unterschiedliche Beleuchtungsrichtungen erzeugen Helligkeitsunterschiede oder rufen Schatten hervor. In extremen Fällen werden Objekte überstrahlt abgebildet. Die Bildung von Teilobjekten wie *Dach bestrahlt* und *Dach beschattet* kann bei entsprechend hoher geometrischer Bildauflösung Abhilfe schaffen. Trotz dieser Einflüsse sind spektrale Merkmale für bestimmte Zielobjekte charakteristisch. Die Wertebereiche können jedoch je nach Szene unterschiedlich sein. Abbildung 33 zeigt Ausschnitte aus zwei unterschiedlichen *pan-sharpened* IRS-Bildern (Farbinfarotbild). Das Meer sowie die Hafen- und Stadtgebiete weisen deutliche Unterschiede in der Radiometrie auf. Im linken Ausschnitt ist an einer Geländekante im oberen Bildteil Schatten zu erkennen. Rechts sind einige Gebäude überstrahlt.



Abbildung 33: Unterschiede in der Radiometrie zweier *pan-sharpened* IRS-Szenen

Abbildung 34 zeigt die vier Testgebiete „Mostaganem“, „Jijel“, „Mandoura“ und „Algier“ in der geographischen Region *Küste I*. Dargestellt ist das *Ratio NIR*, wobei ein heller Grauwert einen großen Wert des *Ratio NIR* bedeutet. Das *Ratio r* eines Bildkanals *K* wird berechnet aus dem mittleren Grauwert eines Segmentes im entsprechenden Kanal $\bar{c}_{K,Objekt}$ geteilt durch die Summe der Mittelwerte aller spektraler Bildkanäle *n* des Segmentes:

$$r_K = \frac{\bar{c}_{K,Objekt}}{\sum_{k=1}^n \bar{c}_{k,Objekt}} \quad , \quad 0 \leq r_K \leq 1$$

Die grün eingefärbten Flächen besitzen einen *Ratio NIR* kleiner als 0,26. In den Testgebieten „Mostaganem“, „Jijel“ und „Algier“ werden die Meeresflächen und einige Seen (z.B. in „Jijel“) durch dieses Prädikat charakterisiert. In „Algier“ und „Mandoura“ erfüllen auch andere Segmente das Prädikat. So würden bei einer Klassifizierung nur anhand dieses Prädikat auch Schattenbereiche innerhalb der Stadt in „Algier“ und küstennahe Bereiche in „Mandoura“ als *Wasser* fehlklassifiziert. D.h., dieses Prädikat allein eignet sich nur bedingt zur Übertragung.




Abbildung 34: Vier Testgebiete Küste I: Ratio NIR mit Ratio NIR < 0,26 dargestellt in grün

Strukturbeschreibende **Texturmerkmale** sind für atmosphärische Einflüsse weniger anfällig als spektrale Merkmale, da nicht die absoluten Grauwerte sondern in erster Linie die relativen Grauwertunterschiede von Bedeutung sind. Beispiel für ein einfaches Texturmerkmal ist die Varianz der mittleren Grauwerte innerhalb eines Segmentes. HARALICK Texturmaße (siehe Abschnitt 2.1.3) auf Basis von Segmenten werden von DE KOK et al. (2003) zur Extraktion von Siedlungsflächen in flächenmäßig sehr großen Datensätzen (so genannte „Megadatensätze“) eingesetzt. Bei der Übertragung hat sich besonders das Texturmerkmal *IDM* (*Inverse Difference Moment*; siehe Tabelle 2, Abschnitt 2.1.3) für Siedlungen als stabil und übertragbar erwiesen. Abbildung 35 veranschaulicht das *IDM* im grünen Kanal in zwei segmentierten Bildern. Die bebauten Bereiche weisen niedrige *IDM*-Werte auf (dunkle Segmente). Dieses Texturmerkmal eignet sich somit sehr gut zur Differenzierung von Siedlungen zu anderen Objektklassen, relativ unabhängig von Radiometrie des Sensors und geographischer Region.

Besonders bei *man-made* Objekten wie Gebäuden und Straßen spielen **Formeigenschaften** eine bedeutende Rolle. Straßensegmente weisen eine charakteristische lang gestreckte Form auf. Es ist zu erwarten, dass sich geometrische Merkmale wie Längen- zu Breitenverhältnis gut übertragen lassen. Abbildung 36 zeigt im Testgebiet „Algier“ das Längen- zu Breitenverhältnis von Segmenten. Hell eingefärbte Segmente besitzen ein großes Längen- zu Breitenverhältnis. Nur dieses Merkmal alleine genügt nicht für die Klassifizierung von Straßen, da z.B. Feldkanten ebenfalls ein großes Längen- zu Breitenverhältnis besitzen. Somit sind weitere Merkmale, wie die Länge der Segmente und auch spektrale Eigenschaften erforderlich.




Abbildung 35: *Inverse Difference Moment (IDM)* Texturmerkmal im grünen Kanal zweier *pan-sharpened* IRS-Szenen




Abbildung 36: Längen- zu Breitenverhältnis von Segmenten (links) und dazugehöriger Ausschnitt aus Testgebiet „Algier“ als Farbinfrarotbild (rechts)

Relationen zwischen Objekten müssen allgemein gültig sein, um eine Übertragbarkeit zu gewährleisten. Baumalleen parallel zu linienförmigen Objekten sind Hinweise auf Straßen oder Flüsse, aber sie begleiten diese nicht notwendigerweise. Eine allgemein gültige Aussage ist zum Beispiel, dass ein See komplett von Landklassen umgeben sein muss. Schwierigkeiten können jedoch auftreten, wenn im Bild nur ein Teilbereich eines Sees abgebildet ist, da sich der See z.B. am Szenenrand befindet. Die Definition von Relationen in Bilddaten mittlerer Auflösung ist schwierig, da eher großflächige Objekte extrahiert werden. In höher aufgelösten Bilddaten können mehr Objekte differenziert werden, die dann in Beziehung gesetzt werden können (z.B. Gebäude, Zufahrt, Straße oder Straßenabschnitt, Straßenmarkierungen, Autos).

Zusammenfassend ist festzuhalten, dass für die Erstellung übertragbarer Regelsätze so wenig spektrale Merkmale wie notwendig verwendet werden sollten, da diese besonders stark durch zahlreiche Größen beeinflusst werden. Besser geeignet scheinen aufgrund ihrer zu erwartenden Stabilität in unterschiedlichen Bildszenen Texturmerkmale und insbesondere Formmerkmale. Relationen bzw. Kontext werden für Bilddaten mittlerer Auflösung nicht angewendet, da diese sich auf viel feinere Objektdefinitionen beziehen. Es ist zu erwarten, dass Regelsätze, welche diese Erkenntnisse befolgen, zu einem gewissen Grad übertragbar sind. Bestimmte Parameterwerte vor allem abhängig von der Radiometrie aber z.T. auch von der geographischen Region müssen angepasst werden, aber die Gesamtstruktur des Regelsatzes sollte in der Regel unverändert bleiben können.

5.3 Übertragbarkeit von Basis-Regelsätzen

Nach den theoretischen Überlegungen für die Übertragung von Regelsätzen wird in den folgenden Abschnitten versucht, die aufgestellten Theorien anhand von praktischen Experimenten zu verifizieren. In den zwei geographischen Regionen *Küste* und *Wüste* in Algerien soll die Landbedeckung aus IRS-Bilddaten mittlerer Auflösung extrahiert werden. Für beide geographische Regionen wurden spezielle Segmentierungsparameter und ein so genannter „Basis-Regelsatz“ in eCognition aufgestellt. Der Basis-Regelsatz soll möglichst allgemein gültig sein. Die Übertragbarkeit wird anhand von insgesamt 16 Testgebieten (siehe Abschnitt 3.3) überprüft und die Klassifizierungsergebnisse quantitativ evaluiert. Wie bereits in Kapitel 4 ist auch bei den Experimenten mit Basis-Regelsätzen eine Prämisse der Zeit- und Automationsgewinn gegenüber einer individuellen Regelsatzerstellung. Der Aufwand für die Anpassung des Basis-Regelsatzes wird so beschränkt, dass der Auswerteprozess auf etwa 10% der ursprünglich benötigten Zeit verkürzt wird und es wird abgeschätzt, welche Qualität mit dieser Vorgehensweise erzielt werden kann.

5.3.1 Segmentierungsparameter

Die im Rahmen der Experimente zur Übertragung individueller Regelsätze (siehe Abschnitt 4.1) für die jeweiligen Testgebiete verwendeten Segmentierungsparameter wurden miteinander verglichen (siehe auch Abschnitt 5.1) und für jeweils eine geographische Region wurden gemeinsame Segmentierungsparameter aufgestellt. Die Unterschiede zwischen den Parametern (siehe Tabelle 22) zur Segmentierung von *pan-sharpened* IRS-Daten mit Auflösung 5 m liegen weniger in der Gewichtung von Farbe und Formeigenschaften als viel mehr im *Scale Parameter (SP)*, welcher indirekt die Größe der gebildeten Segmente steuert.

Je nach Bildinhalt werden unterschiedliche Segmentgrößen gebildet. Treten in einem Testgebiet vermehrt sehr schmale Straßen und Streusiedlungen auf, so werden kleinere Segmente bevorzugt. Der Operateur erreicht dies durch die Wahl eines kleinen *SP*. Für städtische Bereiche mit großen zusammenhängenden Siedlungsbereichen und breiten Straßen können die Segmente größer sein (größerer *SP*). Erfahrene Anwender haben Standardparameter für die unterschiedlichen Bildsensoren als Anhaltspunkte parat und testen zuerst diese Parameter auf ihre Tauglichkeit in einem neuen Untersuchungsgebiet.

Während in der Küstenregion eine einzige Segmentierungsebene verwendet wird, werden in der Region *Wüste* zwei Ebenen mit unterschiedlichem *SP* verwendet. Die Klassifizierung erfolgt in der gröber segmentierten Ebene mit dem *SP 20*. Die feiner segmentierte Ebene stellt zusätzliche Objektmerkmale zur Verfügung, wie z.B. *Length/Width (Line so) (l)*. Dieses Merkmal beschreibt das Längen- zu Breitenverhältnis der Subobjekte in der feiner segmentierten Ebene.

Tabelle 22: Segmentierungsparameter für die geographischen Regionen *Küste* und *Wüste*

Segmentierungsparameter	<i>Küste</i>	<i>Wüste</i>	
Segmentierungsebene	<i>Level 1</i>	<i>Level 1</i>	<i>Level 2</i>
<i>Scale Parameter</i>	25	10	20
Farbe	0,8	0,8	0,8
Form	0,2	0,2	0,2
	Glattheit	0,6	0,7
	Kompaktheit	0,4	0,3

Die Parameterwerte unterscheiden sich zwischen *Küste* und *Wüste* nicht wesentlich. In der Küstenregion ist der *SP* höher als in der *Wüste*, so dass größere Segmente gebildet werden. Dies kann mit der Ausprägung der in den Regionen üblicherweise vorkommenden topographischen Objekte begründet werden. Im Küstenbereich herrschen größere zusammenhängende Siedlungen vor, während in Wüstengegenden vermehrt Einzelhäuser auftreten. Die Gewichtung der Farb- und Formeigenschaften der Segmente ist nahezu identisch. In der *Wüste* wird zur verbesserten Extraktion der Straßen die Kompaktheit etwas schwächer gewichtet. Aufgrund fehlender Referenzsegmentierungen erfolgt die Bewertung der Segmentierung rein qualitativ (visuell) und indirekt geht die Segmentierung in die quantitative Qualitätsbetrachtung des Klassifizierungsergebnisses auf Grundlage der Konfusionsmatrix ein (siehe Kapitel 6).

5.3.2 Klassifizierungsparameter

Dieser Abschnitt beschreibt die Verwendung von Basis-Regelsätzen innerhalb der zwei geographischen Regionen *Küste* und *Wüste*.

Um eine möglichst gute Allgemeingültigkeit des Regelsatzes zu gewährleisten, werden nur Basisklassen extrahiert. In der geographischen Region *Küste* sind dies:

- *Bebautes Gebiet*
- *Nicht bebautes Gebiet*
- *Straße*
- *Meer*
- *See*
- *Fluss*

Der Regelsatz für die Region *Wüste* enthält keine Objektklasse *Meer*, stattdessen wird die Klasse *Nicht bebautes Gebiet* über die zusätzlichen Unterklassen *Vegetation* und *Wüste* definiert.

Unterschiedliche Kombinationen von Segmenteigenschaften und Regeln können vergleichbare Klassifizierungsergebnisse liefern. Bei der Implementierung der Modelle wurde viel Wert auf die Transparenz und Einfachheit der Regeln gelegt. Eine Objektklasse wird mit möglichst wenigen Regeln beschrieben, nach dem Leitsatz: nur so viel wie nötig und nicht so viel wie möglich.

Bei der Übertragung der Regelsätze können mehrere Fälle von Inkonsistenzen zwischen Modell und Bildinhalt auftreten, die im Folgenden näher erläutert werden. Es kann beispielsweise im Bild eine neue Objektklasse auftreten, die nicht modelliert ist. Die entsprechenden Segmente werden der Klasse zugewiesen, deren Eigenschaften ähnlich sind oder sie bleiben unklassifiziert, wenn die Zugehörigkeitswerte unterhalb eines spezifizierten Schwellwertes liegen (siehe Abbildung 27, Abschnitt 3.5). Andererseits müssen modellierte Objektklassen nicht im Bild vorhanden sein. Dann werden in der Regel keine oder nur wenige Segmente dieser Klasse zugewiesen. Unklassifizierte Objekte treten auf, wenn Segmente ausschließlich Zugehörigkeitswerte aufweisen, die kleiner sind als der definierte Schwellwert. Wenn Segmente die Eigenschaften mehrerer Klassen besitzen, so ist der höchste Zugehörigkeitswert für die Klassifizierung ausschlaggebend. Bei einem geringen Unterschied zwischen dem höchsten und dem zweitbesten Zugehörigkeitswert kann die Zuverlässigkeit des klassifizierten Segmentes in Frage gestellt werden. Sind die beiden höchsten Zugehörigkeitswerte gleich groß, so weist eCognition das Segment zufällig einer der beiden in Frage kommenden Objektklassen zu.

In Abschnitt 3.4.2 wurden die Modelle für die objektbasierte Analyse vorgestellt. Für die Implementierung der Modelle in Form von Regelsätzen ist wie gehabt die obere Ebene das Modell der „Realen Welt“. Die Modellebene „Bild (mittlere Auflösung)“, welche die Abbildung der Objekte aus der „Realen Welt“ ins Bild darstellt, wird durch die Ebene „Segmentiertes Bild (mittlere Auflösung)“ ersetzt. Diese Ebene enthält die spezifischen Merkmale, anhand derer die Klassifizierung erfolgt. Die Merkmale ergeben sich aus den Eigenschaften der abgebildeten Objekte und wurden durch praktische Un-

tersuchungen bestätigt. Die folgenden zwei Abschnitte beschreiben für die beiden geographischen Regionen die Implementierung der Modelle. Die Regelsätze enthalten neben spektralen Merkmalen auch Textur- und Formeigenschaften aber keine Kontextmerkmale. Auf diese wurde verzichtet, da die Experimente zeigten, dass keine Allgemeingültigkeit gegeben ist (siehe Abschnitt 5.2). In den Regelsätzen werden bei Verwendung spektraler Merkmale häufig Verhältnisse, wie *Ratio NIR* oder *NDVI*, eingesetzt. Sämtliche Texturmerkmale basieren auf HARALICK (siehe Abschnitt 2.1.3).

5.3.2.1 Geographische Region Küste

Abbildung 37 zeigt das Modell für *Bebautes Gebiet* in der geographischen Region *Küste*. Im Bild mittlerer Auflösung bilden sich Siedlungsflächen mit einer charakteristischen Textur ab (siehe auch Abbildung 21). Mit Hilfe von HARALICK Texturmaßen (siehe Tabelle 2, Abschnitt 2.1.3) und einem spektralen Merkmal (mittlerer Grauwert im Grün-Kanal) werden die Segmente im segmentierten Bild klassifiziert.

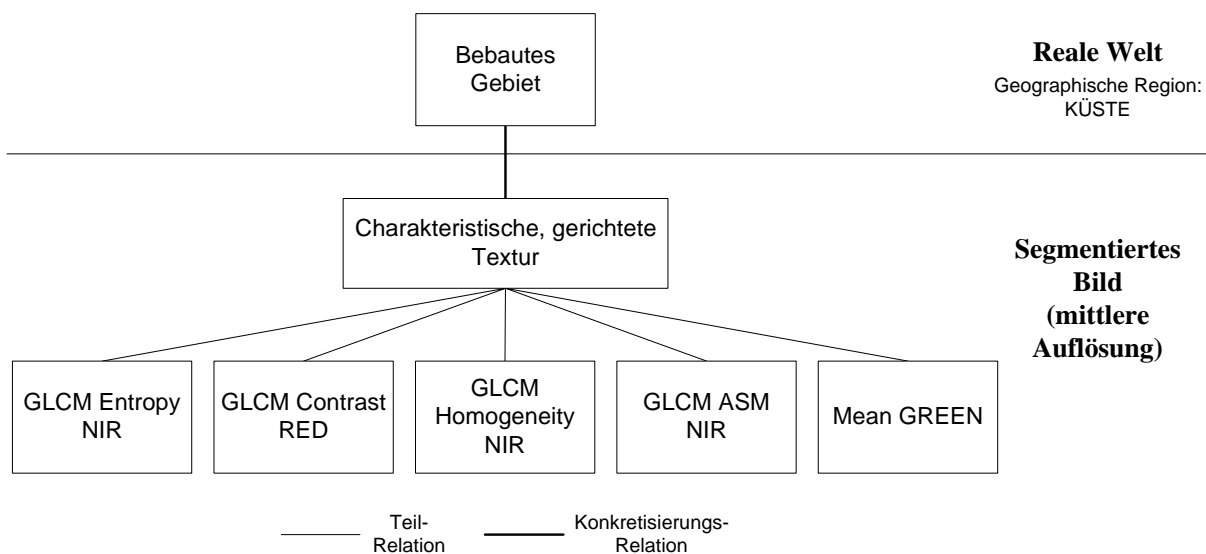


Abbildung 37: Implementiertes Modell für *Bebautes Gebiet*

Nicht bebautes Gebiet (siehe Abbildung 38), wie landwirtschaftliche Flächen und Wald, weist in der Regel charakteristische *NDVI*-Werte und typische Texturen auf. Im segmentierten Bild wird daher nach Segmenten gesucht, welche gewisse *NDVI*-Werte besitzen und den Wertebereich für das Varianzen-Texturmaß nach HARALICK im Nahen Infrarot erfüllen.

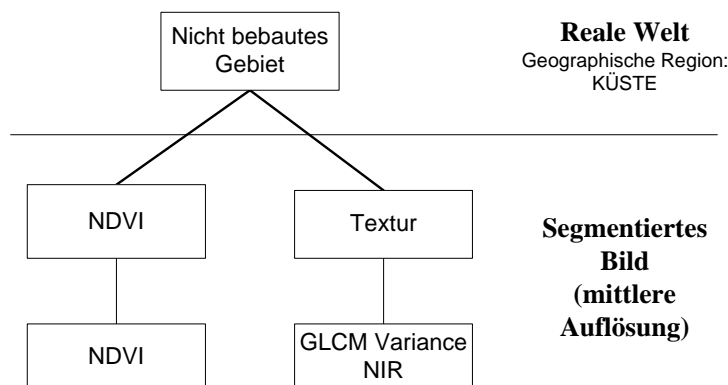


Abbildung 38: Implementiertes Modell für *Nicht bebautes Gebiet*

Straßen erscheinen im Bild mittlerer Auflösung meistens als helle Linien (siehe Abbildung 39). Linienförmige Objekte werden im segmentierten Bild über das Längen- zu Breitenverhältnis (*Length/Width*) und eine geringe Kompaktheit (*Compactness*, *Density*) klassifiziert. Der mittlere Grauwert im NIR-Kanal (*Mean NIR*) beschreibt die Radiometrie der *Straße*.




Abbildung 39: Implementiertes Modell für *Straße*

Die Wasserklassen *Fluss*, *See* und *Meer* (siehe Abbildung 40) zeichnen sich als dunkle, homogene Flächen mit niedrigem Wert im NIR-Kanal aus. Flüsse sind linienförmig während See und Meer flächenhafte Objekte darstellen. Zur Beschreibung im segmentierten Bild werden für die Objektklasse *Fluss* neben dem Wert im NIR-Kanal hauptsächlich folgende Formmerkmale verwendet: Längen- zu Breitenverhältnis, Beschreibung der Glattheit des Segmentes durch den *Shape index* und Berücksichtigung der durchschnittlichen Länge der Polygone des vektorisierten Segmentes mittels *Average length of edges (polygon)*. *See* und *Meer* sind Spezialisierungen von *Wasser* und erben das *Ratio* im NIR-Kanal. Weiterhin erfolgt zur Unterscheidung von *Meer* eine Spezifizierung der Fläche und Länge sowie des *Ratio NIR* der Segmente für die Objektklasse *See*. Da die in den Testgebieten vorkommenden Seen relativ klein sind, zeichnen sich *See*-Segmente im Gegensatz zu *Meer*-Segmenten durch kleinere und kürzere Segmente aus.




Abbildung 40: Implementiertes Modell für *Wasser*

5.3.2.2 Geographische Region Wüste

Bebautes Gebiet in der *Wüste* ist eine Spezialisierung der Klasse *Dünen & Bebaut* (siehe Abbildung 41). Diese wird durch ein Texturmerkmal (GLCM *Homogeneity Green*) und ein Formmerkmal (Längen- zu Breitenverhältnis der Subobjekte in der darunter liegenden Segmentierungsebene) beschrieben. Die Segmente, welche die Eigenschaften der Klasse *Dünen & Bebaut* erfüllen, können aufgrund ihrer charakteristischen Textur (GLCM *Contrast NIR*) und des *Ratios* im Rot-Kanal der Klasse *Bebautes Gebiet* zugewiesen werden.

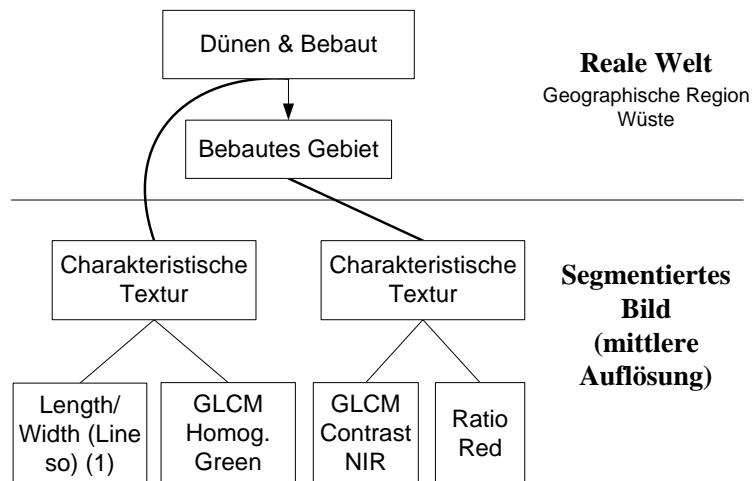


Abbildung 41: Implementiertes Modell für *Bebautes Gebiet*

Bei der Klassifizierung von *Nicht bebautes Gebiet* trennen die zwei Klassen *Dünen & Bebaut* sowie *Straßen & Dünen* flächen- und linienförmige Segmente voneinander (siehe Abbildung 42). Diese werden mit Hilfe der Kompaktheit der Segmente (*Density*) bzw. der Langgestrecktheit (durchschnittliche Polygonlänge der Segmentkanten) spezialisiert. Nach der Klassifizierung werden die zwei Arten von Dünen zur *Wüste* und die wiederum mit den Klassen *Vegetation* und *Nicht bebaut* zur Klasse *Nicht bebautes Gebiet* zusammengefasst. Die Beschreibungen der Klassen *Dünen & Bebaut* (siehe Abbildung 41) und *Straßen & Dünen* (siehe Abbildung 43) wurden aus Gründen der Übersichtlichkeit in Abbildung 42 weggelassen.

Die Klasse für linienförmige Segmente *Straßen & Dünen* (siehe Abbildung 43) dient zur Modellierung von *Straße* und *Dünen linienförmig* da beide Klassen sehr ähnliche Eigenschaften bezüglich Material und Form aufweisen. In Wüstengebieten bestehen Straßen oftmals aus dem umgebenden Material. Charakterisiert wird die Klasse *Straßen & Dünen* durch fünf Formmerkmale, wie Kompaktheit (*Density*) oder Breite der Subobjekte in der darunter liegenden Segmentierungsebene. Die Unterscheidung von *Straße* und *Dünen linienförmig* erfolgt auf Grundlage des Objektmerkmals der durchschnittlichen Polygonlänge der Segmentkanten.

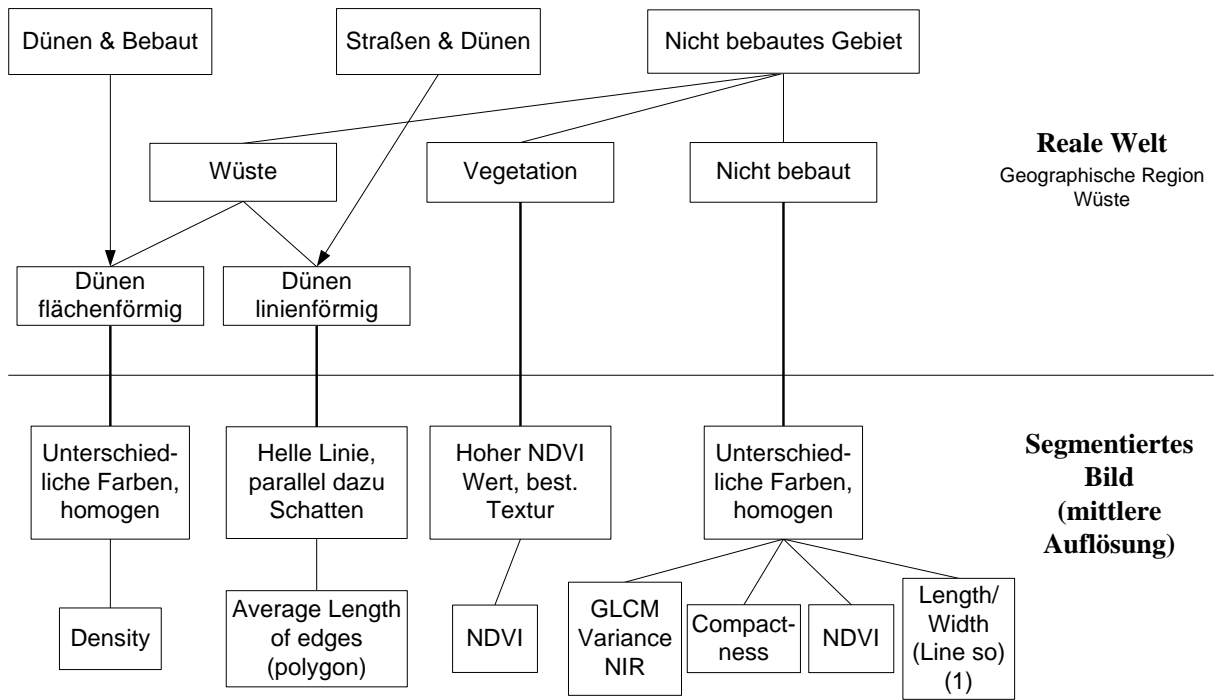


Abbildung 42: Implementiertes Modell für *Nicht bebautes Gebiet*




Abbildung 43: Implementiertes Modell für *Straße*

In der geographischen Region *Wüste* sind die zwei Wasserklassen *See* und *Fluss* spezifiziert (siehe Abbildung 44). Beide Klassen bilden sich im Satellitenbild dunkel und homogen ab. Eine Trennung kann nur über die Form der Segmente erfolgen. Die Klasse *See* wird über das spektrale Merkmal *Ratio* im Grün-Kanal definiert und der *Fluss* über den mittleren Grauwert im NIR-Kanal sowie das Formmerkmal Längen- zu Breitenverhältnis. Verschiedene Wassertiefen und Vegetationsanteil führen zu spektralen Unterschieden der Klassen *See* und *Fluss*.




Abbildung 44: Implementiertes Modell für *Wasser*

5.3.2.3 Vergleich der Regelsätze

Nach Vorstellung der Regelsätze in Form von Modellen für die geographischen Regionen *Küste* und *Wüste* werden diese verglichen. Tabelle 23 zeigt die in beiden Regelsätzen vorkommenden identischen Merkmale zur Klassifizierung einer Objektklasse wobei zwischen spektralen, Textur- und Formmerkmalen unterschieden wird und führt Besonderheiten auf, die z.B. aufgrund bestimmter topographischer Gegebenheiten in einer Region auftreten. Die vollständigen Basis-Regelsätze sind im Anhang abgedruckt (siehe Tabellen 27 und 28).

Das unterschiedliche Erscheinungsbild von *Bebautes Gebiet* in *Wüste* und *Küste* mit zerstreuten Siedlungen und vielen einzeln stehenden Gebäuden bzw. großflächigen Siedlungen spiegelt sich in den Basis-Regelsätzen wider. Die beiden Basis-Regelsätze zur Klassifizierung von *Bebautes Gebiet* enthalten keine identischen Objektmerkmale. Es werden allerdings in beiden geographischen Regionen überwiegend Texturmerkmale verwendet. Die HARALICK Texturmerkmale *Homogeneity* und *Contrast* werden in beiden Regionen mit unterschiedlichen Bildkanälen verwendet. Die Klasse *Nicht bebaut*es Gebiet wird in beiden Regionen mit einem spektralen (*NDVI*) und einem texturbasierten Merkmal (*GLCM Variance NIR*) charakterisiert. Um auch lang gestreckte, linienförmige Dünenstrukturen zu erfassen, sind im Basis-Regelsatz *Wüste* noch zwei zusätzliche Formmerkmale definiert.

Straßen in der Region *Wüste* sind meist deutlich schmaler als in *Küste*. Bei ausreichendem Kontrast sind Straßensegmente in *Wüste* länger als in *Küste*, da sie weniger mit angrenzenden, spektral ähnlichen Flächen verschmelzen. Bedingt durch die Segmentierung in zwei *Leveln* werden in der *Wüste* Formmerkmale verwendet, die auf den feiner segmentierten *Level* zurückgreifen. Zur Extraktion von *Straße* werden in beiden Regelsätzen überwiegend Formmerkmale verwendet. Das Merkmal zur Beschreibung der Kompaktheit eines Segmentes *Density* kommt in beiden Regionen vor. In der *Küste* findet auch ein spektrales Merkmal (*Ratio NIR*) Anwendung. Die Objektklasse *Meer* gibt es nur im Regelsatz für *Küste*. *Fluss* wird in beiden Regionen über das spektrale Merkmal mittlerer Grauwert im NIR-Kanal und das Längen- zu Breitenverhältnis klassifiziert. Im Küstenregelsatz werden zusätzlich

noch zwei Formmerkmale eingesetzt. *Seen* werden in der Wüstenregion ausschließlich mittels des Merkmals *Ratio* im Grün-Kanal extrahiert, während in der Küstenregion aufgrund der Unterscheidung zur *Meerklasse* auch zwei Formmerkmale definiert sind.

Tabelle 23: Vergleich der Merkmale der Basis-Regelsätze zwischen den geographischen Regionen *Küste* und *Wüste*

Basisklasse	Objektklasse	Merkmalsart	Identische Merkmale	Bemerkungen
Bebautes Gebiet	Bebautes Gebiet	Spektral	-	
		Textur	-	Überwiegend Texturmerkmale (<i>Küste</i> und <i>Wüste</i>)
		Form	-	
Nicht bebautes Gebiet	Nicht bebautes Gebiet	Spektral	NDVI	
		Textur	GLCM Variance NIR	
		Form	-	<i>Wüste</i> : zwei zusätzliche Formmerkmale wegen linienförmigen Dünenstrukturen
Straße	Straße	Spektral	-	<i>Küste</i> : Mean NIR
		Textur	-	
		Form	Density	Überwiegend Formmerkmale (<i>Küste</i> und <i>Wüste</i>)
Wasser	Meer	Spektral	Nur in <i>Küste</i> definiert	Ratio NIR (<i>Küste</i>)
		Textur		
		Form		
	Fluss	Spektral	Mean NIR	
		Textur	-	
		Form	Length/Width	<i>Küste</i> : Shape Index, Aver. length of edges (polyg.)
	See	Spektral	-	Ratio NIR (<i>Küste</i>), Ratio GREEN (<i>Wüste</i>)
		Textur	-	
		Form	-	<i>Küste</i> : 2 Formmerkmale wegen Unterscheidung zu Meer (nicht nötig in <i>Wüste</i>)

5.3.2.4 Stabilität der Parameter

Die Parameterwerte der Basis-Regelsätze in der jeweiligen geographischen Region wurden auf Grundlage der Testgebiete *Küste I* und *Wüste I* aufgestellt und getestet (vorläufige Basis-Regelsätze). Danach erfolgte die Übertragung und Anpassung der Basis-Regelsätze in den Testgebieten der geographischen Regionen *Wüste II* und *Küste II*. Basierend auf diesen Ergebnissen wurden die Basis-Regelsätze geringfügig verändert zu „endgültigen“ Basis-Regelsätzen. Nachfolgend wird die Stabilität der Segmentmerkmale der beiden Basis-Regelsätze in den Testgebieten *Küste II* und *Wüste II* beleuchtet.

In den Testgebieten *Küste II* gilt für die Anpassung der spektralen Merkmale Folgendes: Bei der Objektklasse *Nicht bebautes Gebiet* muss der Wertebereich für den *NDVI* geringfügig angepasst werden. Das *Ratio NIR* für die Klassifizierung von *Wasser* und *Meer* muss minimal geändert werden. Gründe hierfür sind u.a. atmosphärische Einflüsse und verschiedene Beleuchtung. Das spektrale Merkmal *Mean NIR* für *Straße* muss in allen vier Testgebieten stark angepasst werden, da die Straßen unterschiedliche Helligkeiten aufweisen.

Alle anderen Parameter, d.h. die für Form- und Textureigenschaften, sind weitgehend stabil und erfordern nur in wenigen Fällen einfache Anpassungen der Wertebereiche. Im Regelfall reicht es aus, die bestehenden Parameterwerte an das neue Bild anzupassen. Nur in seltenen Fällen müssen dem Regelsatz gänzlich neue Regeln hinzugefügt werden. Dies ist zum Beispiel der Fall, wenn viele Segmente den gleichen höchsten Zugehörigkeitswert zu mehreren Klassen aufweisen und dadurch eine zufällige Klassenzuweisung erfolgt. Abhilfe können hier Regeln mit der in eCognition so genannten „invertierten Ähnlichkeit“, wie das Merkmal *nicht Straße* bei *Nicht bebautes Gebiet* und *Bebautes Gebiet*, schaffen. Besitzt z.B. ein Segment zur Klasse *Straße* den Zugehörigkeitswert 0,7, dann resultiert für das Merkmal „invertierte Ähnlichkeit“ *nicht Straße* ein Zugehörigkeitswert von 0,3, welcher sich aus $1 - 0,7$ errechnet. In einem Testgebiet verbessert die Regel *nicht Meer* die Klassifizierung der Klasse *Fluss*.

In den Testgebieten von *Wüste II* war bei den Objektklassen *Dünen linienförmig* und *Straße* jeweils die Anpassung des Formmerkmals *Average length of edges (polygon)* notwendig. Die Ausprägung der linienförmigen Objekte und der vorhandene Kontrast beeinflussen die Segmentierung und dadurch auch die Formeigenschaften der Segmente. Die Werte für das HARALICK Texturmaß *GLCM Contrast NIR* und für das spektrale Merkmal *Ratio RED* mussten für die Klasse *Bebautes Gebiet* deutlich modifiziert werden. Das vielfältige Erscheinungsbild von Siedlungen, unterschiedliche Beleuchtungen sowie atmosphärische Einflüsse beeinflussen diese Merkmale. Wie für die Region *Küste* gilt auch in der *Wüste*, dass die meisten Parameter weitgehend stabil sind und nur in wenigen Fällen einfache Anpassungen der Wertebereiche erfolgen müssen, z.T. wurden aber auch neue Regeln hinzugefügt. Es handelt sich hierbei um die zusätzliche Regel *nicht Straße* bei den Objektklassen *Vegetation*, *Dünen* und *Bebautes Gebiet*. Nur in einem Testgebiet musste zur Verbesserung des Klassifizierungsergebnisses ein zusätzliches spektrales Merkmal, nämlich *Mean GREEN*, bei der Klasse *Bebautes Gebiet* hinzugefügt werden.

Bezüglich Übertragung und Anpassung der Basis-Regelsätze innerhalb der jeweiligen geographischen Regionen kann zusammengefasst werden, dass sich die meisten der in den Regelsätzen verwendeten Segmentmerkmale als stabil erweisen. Es müssen meist lediglich geringe Änderungen der Wertebereiche vorgenommen werden. Insbesondere spektrale Merkmale erfordern z.T. aber auch größere Anpassungen. Als neue Regeln wurden fast ausschließlich invertierte Ähnlichkeiten zu anderen Klassen (*nicht Klasse x*) eingeführt. Insgesamt zeigt dies die prinzipielle Übertragbarkeit der aufgestellten Basis-Regelsätze innerhalb einer spezifischen geographischen Region sowie die relativ einfache Anpassung der Regelsätze an neue Gebiete innerhalb einer Region.

6 Experimente mit Modellierung der Übertragbarkeit

In diesem Kapitel werden für die Experimente mit Modellierung der Übertragbarkeit die quantitativen Ergebnisse der Qualitätsbetrachtung mit der Konfusionsmatrix (*Accuracy Assessment*) zusammengefasst und der qualitativen (visuellen) Bewertung gegenübergestellt. Alle Testgebiete wurden mit einheitlichen Parametern segmentiert (siehe Abschnitt 5.3.1, Tabelle 22). Die Parameterwerte für den Regelsatz wurden auf Basis der acht Testgebiete aus den geographischen Regionen *Küste I* und *Wüste I* aufgestellt und getestet (Basis-Regelsatz, siehe Abbildung 45). Für jedes Testgebiet wurde versucht, durch Modifizierung der Wertebereiche der Segmenteigenschaften ein besseres Klassifizierungsergebnis zu erreichen (Angepasster Regelsatz). In einem letzten Schritt wurden neue Regeln für das spezielle Testgebiet hinzugefügt (Erweiterter Regelsatz). Nach jedem Verarbeitungsschritt (Anpassung und Erweiterung) wurde die Qualität bestimmt. Die Testgebiete der Regionen *Küste II* und *Wüste II* zeigen die Übertragbarkeit der Regelsätze auf Bilder, die nicht zur Festlegung der Parameterwerte verwendet wurden.

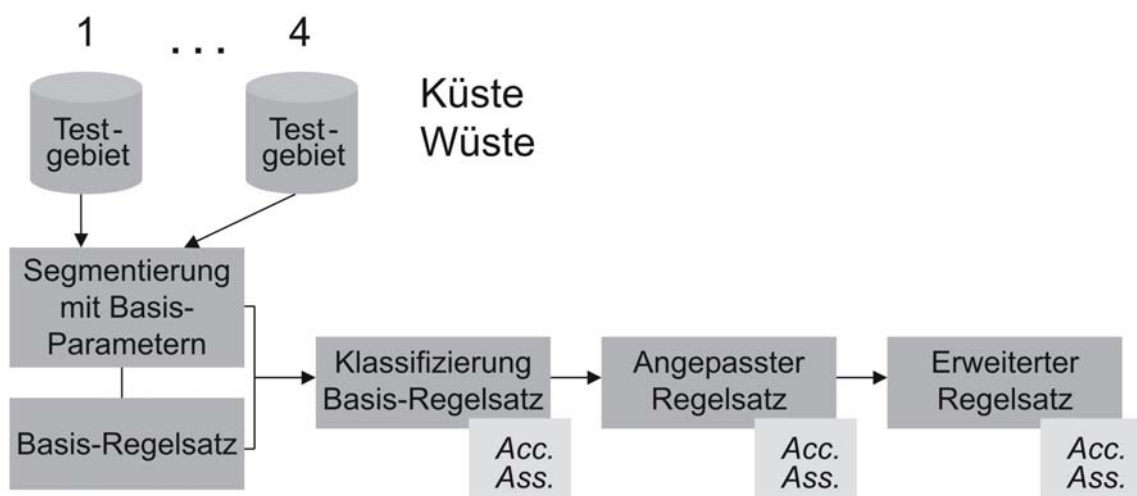


Abbildung 45: Ablaufschema der Experimente mit Modellierung der Übertragbarkeit von Basis-Segmentierungsparametern und Basis-Regelsätzen

Der nächste Abschnitt stellt die Resultate der Evaluierung der Klassifizierungsergebnisse der einzelnen Testgebiete mit den Gesamtqualitätsmaßen der Konfusionsmatrix dar. Danach erfolgt eine Betrachtung der Qualität einzelner Objektklassen. Abschließend werden quantitative und qualitative Qualitätsbetrachtung gegenübergestellt.

6.1 Ergebnisse

Die Regelsätze des implementierten Modells für die geographischen Regionen *Küste* und *Wüste* wurden auf die jeweiligen Testgebiete übertragen. Mit Hilfe der Gesamtqualitätsmaße, die sich aus der Konfusionsmatrix berechnen lassen, werden die resultierenden Klassifizierungsergebnisse für die einzelnen Testgebiete charakterisiert. Abbildung 46 zeigt den *Kappa Index (KI)* für die vier Testgebiete in der Region *Küste I*. Die Verwendung des Basis-Regelsatzes für die vier Testgebiete ergibt einen durchschnittlichen *KI* von 0,67 (Minimum 0,57, Maximum 0,76). Nach Anpassung der Wertebereiche an das neue Bild wird ein mittlerer *KI* von 0,69 erzielt. Durch das Hinzufügen neuer Objektmerkmale erhöht sich der *KI* auf 0,71, was allerdings deutlich niedriger als der durchschnittliche *KI* von 0,83 der originalen, individuellen Klassifizierungen ist.

Das Testgebiet „Algier“ weist mit Abstand die schlechtesten *KI* für die verschiedenen Klassifizierungen und die geringsten Verbesserungen durch Anpassung auf. Ein Grund hierfür ist die Größe des Testgebietes. Mit 722 km² ist „Algier“ bei weitem das größte Testgebiet in der Küstenregion. Die anderen Gebiete sind maximal 170 km² groß. Je größer das zu klassifizierende Gebiet, desto unterschiedlicher können die Objektklassen ausgeprägt sein.




Abbildung 46: *Kappa Index* für die vier Testgebiete Küste I

Der *Kappa Index* für die vier Testgebiete in der Region *Wüste I* ist in Abbildung 47 graphisch dargestellt. Die Anwendung des Regelsatzes auf die vier Testgebiete ergibt einen durchschnittlichen *KI* von 0,49. Die Werte des *KI* bewegen sich zwischen 0,26 und 0,7. Die Anpassung der Wertebereiche verringert den mittleren *KI* geringfügig auf 0,48. Eine mögliche Erklärung hierfür liefert Abbildung 53, in der die *KI* für individuelle Objektklassen dargestellt sind. Die Qualität für *Wasser* bleibt gleich bei der Klassifizierung mit Basis-, angepasstem und erweitertem Regelsatz. *Straße* verbessert sich durch die Anpassung deutlich, während die Klassen *Nicht bebautes Gebiet* und *Bebautes Gebiet* sich verschlechtern. Die beiden letztgenannten Klassen stellen den Großteil der Referenzpixel bei der Qualitätsbetrachtung dar und bedingen den schlechteren *KI* bei der angepassten Klassifizierung. Das Hinzufügen neuer Regeln bringt eine Verbesserung des *KI* auf 0,52. Genau wie in der Küstenregion weisen in der Wüstenregion die originalen Klassifizierungen den höchsten durchschnittlichen *KI* auf (0,66).




Abbildung 47: Kappa Index für die vier Testgebiete Wüste I

Bei der *Overall Accuracy (OA)* zeigen sich ähnliche Tendenzen (siehe Abbildungen 48 und 49). Nach Anwendung des Basis-Regelsatzes wird eine durchschnittliche *OA* von 79% (*Küste I*) bzw. 85,6% (*Wüste I*) erreicht. Im Folgenden werden *Küste I* und *Wüste I* mit K bzw. W abgekürzt. Die *OA* verbessert sich geringfügig nach Anpassung der Wertebereiche auf 81% (K), 86,7% (W) und auf 82% (K) und 87% (W) nach Hinzufügen neuer Regeln. Die durchschnittliche *OA* der originalen Klassifizierungen beträgt 89% (*Küste I* und *Wüste I*). Dies zeigt, dass diese Qualität mit einem Basis-Regelsatz auch inklusive Anpassung und Erweiterung nicht erzielt wird. Bei Klassifizierung mit einem Basis-Regelsatz verringert sich der *KI* um 19% (K) bzw. 26% (W) und die *OA* um 11% (K) und 4% (W). Nach Anpassung und Hinzufügen neuer Regeln beträgt die Verschlechterung noch -14% (K) bzw. -21% (W) für *KI* und -8% (K) bzw. -2% (W) für *OA* im Vergleich zur originalen Klassifizierung. Trotz der insbesondere beim *KI* deutlichen Verschlechterung zeigen die Werte eine akzeptable bis gute Übereinstimmung mit den Referenzdaten. Die beiden Qualitätsmaße *OA* und *KI* zeigen tendenziell das gleiche Verhalten für die Bewertung der Klassifizierung mit Basis-Regelsatz, angepasstem und erweitertem Regelsatz.

Die Anpassung der Basis-Regelsätze an ein neues Bild bringt also keine signifikanten Verbesserungen der Bildklassifizierung. Auf den ersten Blick mag dieser Sachverhalt überraschen, da im Vergleich dazu die Experimente ohne Modellierung der Übertragbarkeit (siehe Kapitel 4) durch eine Anpassung deutlich verbessert wurden. Der Grund hierfür liegt in den Regelsätzen und den darin verwendeten Objektmerkmalen. Während die Regelsätze der Experimente ohne Modellierung der Übertragbarkeit für ein spezielles Bild optimiert wurden, werden in einem Basis-Regelsatz nur Objektmerkmale eingesetzt, die in vielen Bildern einer geographischen Region stabil sind. Daher bringt eine Anpassung dieser Objektmerkmale auch nur geringe Verbesserungen. Gleiches gilt auch aufgrund der zeitlichen Beschränkung für die Erweiterung des Basis-Regelsatzes.




Abbildung 48: Overall Accuracy für die vier Testgebiete Küste I





Abbildung 49: Overall Accuracy für die vier Testgebiete Wüste I

Ein Beispiel für die Ergebnisse der unterschiedlichen Varianten der Klassifizierungen zeigt Abbildung 50. Der Bildausschnitt aus der Region *Wüste I* umfasst einen kleinen Bereich im Norden von „Ouargla“. In der individuellen Klassifizierung, bei der das Modell zum Teil durch spezifische Eigenschaften des Testgebietes erweitert wurde, sind die Vegetationsflächen sehr gut erfasst. Einige Wüstensegmente sind als *Bebautes Gebiet* fehlklassifiziert. Die größeren Straßen wurde weitgehend extrahiert. Aufgrund der ab und zu auftretenden unzureichenden Segmentierung für Straßen erscheinen Straßenabschnitte mal breiter, mal sehr schmal oder besitzen kleine Auswüchse. Am oberen Bildbereich ist mittig eine linienförmige Düne als *Straße* fehlklassifiziert. Ähnliche Fehlzugeweisungen tauchen in der Klassifizierung mit dem Basis-Regelsatz für die Region *Wüste* häufiger auf. Kleine Nebenwege sind zum Teil als *Straße* extrahiert und zahlreiche graue Wüstenbereiche als *Bebautes Gebiet* fehlklassifiziert. Die Anpassung der Wertebereiche für die einzelnen Parameter an das Testgebiet kann die Fehlzugeweisungen zum Teil verringern, allerdings leidet die Klassifizierung von *Bebautes Gebiet* darunter. Andererseits werden Teile von Siedlungen als *Wüste* klassifiziert. Durch Hinzufügen neuer Regeln kann hier weitgehend Abhilfe geschaffen werden. *Vegetation* wird in allen Klassifizierungen sehr gut extrahiert.

Die Qualitätsmaße *OA* und *KI* für das gesamte Testgebiet „Ouargla“ sind in Tabelle 24 wiedergegeben. Die individuelle Klassifizierung weist mit fast 87% für *OA* und 0,76 für *KI* die höchste Qualität auf. Die anderen Klassifizierungen unterscheiden sich von den Qualitätsmaßen her nicht signifikant. Der visuelle Eindruck der im Verhältnis zu den anderen Klassifizierungsergebnissen deutlich besseren individuellen Klassifizierungsergebnisse wird also nur zum Teil bestätigt.

Tabelle 24: Qualität für Testgebiet „Ouargla“ (*Wüste I*)


	Testgebiet „Ouargla“			
	Originale, individuelle Klassifizierung	Klassifizierung mit Basis-Regelsatz	Klassifizierung mit angepasstem Regelsatz	Klassifizierung mit erweitertem Regelsatz
<i>Overall Accuracy</i>	86,7 %	84 %	85 %	83,6 %
<i>Kappa Index</i>	0,76	0,70	0,73	0,71




**Originale, individuelle
Klassifizierung**




**Bildausschnitt
(Testgebiet „Ouargla“,
Region *Wüste I*)**



**Klassifizierung mit
Basis-Regelsatz**



**Klassifizierung mit
angepasstem Regelsatz**



**Klassifizierung mit
erweitertem Regelsatz**

Abbildung 50: Verschiedene Klassifizierungen des Bildausschnitts „Ouargla“ - *Bebautes Gebiet*: rot, *Straße*: schwarz, *Wüste*: gelb, *Vegetation*: grün, *See*: blau

Vergleich der Qualitätsmaße zwischen *Küste I* und *Wüste I*

Beim Vergleich der Qualitätsmaße zwischen *Küste I* und *Wüste I* ist zuerst festzuhalten, dass die durchschnittlichen *Overall Accuracies* der Ergebnisse von Basis-, angepasstem und erweitertem Regelsatz der Region *Wüste I* geringfügig besser sind als die der *Küste I*. Zwischen den einzelnen Klassifizierungsschritten (Basis-, angepasster und erweiterter Regelsatz) sind in beiden Regionen nur geringe Unterschiede in der Tendenz der *OA* erkennbar. Bei den individuellen Klassifizierungen sind die *OA* beider Regionen jedoch mit 89% gleich gut. Die *KI* weisen im Vergleich zur *OA* ein gegensätzliches Verhalten auf. Die *KI* sind in der Küstenregion I deutlich besser als in den Wüstengebieten I (z.B. Durchschnitt angepasster Regelsatz: *KI Küste I*: 0,69, *KI Wüste I*: 0,48). Wie für die *OA* gilt, dass sich in beiden Regionen die durchschnittlichen *KI* des Basis-, angepassten und erweiterten Regelsatzes nur geringfügig voneinander unterscheiden. Im Durchschnitt sind die Ergebnisse des erweiterten Regelsatzes etwas besser als die des Basis- und angepassten Regelsatzes. Wie bereits in Abschnitt 2.3.2 erläutert, sollten zu Qualitätsbetrachtung mehrere Maße verwendet werden, um verschiedene Aspekte der Qualität abzudecken. Jedoch können diese Maße auch widersprüchliche Ergebnisse liefern, da verschiedene Informationen der Konfusionsmatrix zur Berechnung genutzt werden. Daher ist es nicht sinnvoll, ausschließlich ein bestimmtes Maß zu optimieren.




Abbildung 51: Vergleich der Qualität zwischen *Küste I* und *Wüste I*

6.2 Individuelle Objektklassen

Im Folgenden wird die Qualität individueller Objektklassen der Klassifizierungen in den geographischen Testgebietsregionen *Küste I* und *Wüste I* mit Basis-, angepasstem und erweitertem Regelsatz aufgeführt und mit den originalen, individuellen Klassifizierungen verglichen. Die durchschnittlichen *KI* der Klassifizierung individueller Objektklassen sind in den Abbildungen 52 und 53 zusammengefasst. In der Region *Küste I* weisen mit Ausnahme der Klasse *Wasser* die originalen *KI* die höchste

Qualität auf. Dahingegen wird in der Region *Wüste I* bei der Klasse *Straße* überraschenderweise der originale *KI* von den Klassifizierungen basierend auf dem Basis-Regelsatz übertroffen.

Straße liefert in der Küstenregion I die schlechteste Qualität mit einem maximalen mittleren *KI* von 0,39 für die Basis- und die erweiterte Klassifizierung. Die Qualität der originalen Straßenklassifizierung ist mit einem *KI* von 0,42 allerdings auch nicht viel besser. Die Klassifizierung dieser linienförmigen Objekte ist aus unterschiedlichen Gründen schwierig: Der Segmentierungsalgorithmus ist nicht für linienförmige Objekte optimiert. Die verwendete Bildauflösung von 5 m lässt bei unzureichenden Kontrasten Straßenabschnitte mit angrenzenden Flächen verschmelzen und es treten viele Mischpixel auf. Zudem weisen Straßen z.T. recht unterschiedliche spektrale Eigenschaften auf. Innerhalb von bebautem Gebiet gibt es außerdem Störungen in Form von Verdeckungen und Schattenwurf. In der Wüstenregion I wird *Straße* mit einem durchschnittlichen *KI* von bis zu 0,61 (Basis- und erweiterter Regelsatz) extrahiert. Gründe für die bessere Extraktion von Straßen in Wüstengebieten sind der bessere Kontrast zum homogenen Wüstenhintergrund und nahezu keine Verdeckungen. In der Wüste können Fehlklassifizierungen in Form von linienförmigen Dünenstrukturen auftreten, während in der Küstenregion Feldgrenzen oder kleine, bewachsene Bachläufe fehlerhaft als *Straße* klassifiziert werden. Zur Unterscheidung von *Straße* und *Dünen linienförmig* wurde in den Wüstentestgebieten eine Regel hinzugefügt, die auf einem Formmerkmal von vektorisierten Segmenten basiert (*Average length of edges (polygon)*, siehe Abbildung 43). Der *KI* für *Straße* steigt nach dem Hinzufügen der neuen Regel deutlich (z.B. Testgebiet „Hassi-El-Frid“, Objektklasse *Straße*, *KI* Basis 0,31, angepasst 0,48, erweitert 0,59).

In beiden geographischen Regionen *Wüste I* und *Küste I* ist die Qualität der Basis-, angepassten und originalen Klassifizierungen der Klasse *Wasser* nahezu gleich und der *KI* beträgt im Schnitt 0,96 (K). In den vier Testgebieten *Wüste I* kommt nur in einem Testgebiet Wasser vor. Die Qualität der angepassten Klassifizierungen der Objektklassen *Nicht bebautes Gebiet* und *Bebautes Gebiet* (0,7 bzw. 0,55 (K), 0,58 bzw. 0,39 (W)) sind beträchtlich niedriger als die *KI* der originalen Klassifizierungen (0,96 bzw. 0,8 (K), 0,9 bzw. 0,61 (W)). Ein Grund hierfür könnte sein, dass die Klassen *Nicht bebautes Gebiet* und *Bebautes Gebiet* ein sehr vielfältiges Erscheinungsbild aufweisen. In individuellen Klassifizierungen wird daher *Bebautes Gebiet* häufig in mehrere Unterklassen geteilt, wie *dichte* und *lockere Bebauung* und *Schatten*. Im Basis-Regelsatz ist nur eine Klasse für *Bebautes Gebiet* definiert, die nicht die gesamte Bandbreite der Erscheinungsformen abdeckt.




Abbildung 52: Durchschnittliche KI für individuelle Objektklassen (Küste I)

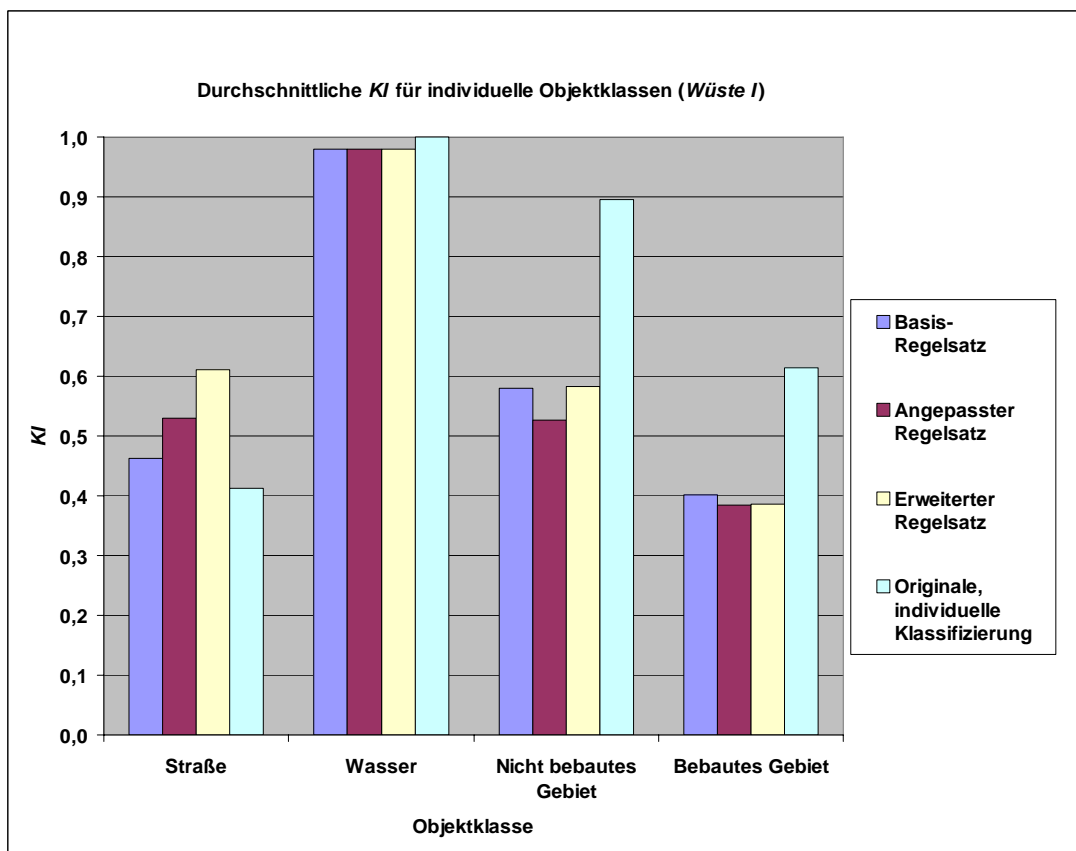



Abbildung 53: Durchschnittliche KI für individuelle Objektklassen (Wüste I)

Zur Veranschaulichung der Ausprägung der Qualitätsmaße für individuelle Objektklassen ist in Abbildung 54 ein Ausschnitt aus dem Küstentestgebiet „Mostaganem“ dargestellt. Der Bildausschnitt enthält eine diagonal verlaufende Straße, deren Begrenzungen z.T. nur sehr undeutlich erkennbar sind. Kleine, bebaute Gebiete befinden sich überwiegend entlang der Straße und die übrigen Bildbereiche bedecken Felder mit und ohne Vegetation. Bebaute Gebiete sind in der originalen Klassifizierung gut extrahiert, während die Straße nicht durchgängig klassifiziert jedoch einige Feldgrenzen und Feldwege fälschlicherweise der Klasse *Straße* zugewiesen wurden.

Die Klassifizierung mit dem Basis-Regelsatz weist die komplette Straße der Klasse *Bebautes Gebiet* zu. Lediglich kleine Seitenstraßen und Feldgrenzen sind als *Straße* klassifiziert. Neben den zusammenhängenden Siedlungsbereichen sind auch viele Einzelgebäude und bewachsene Feldgrenzen als *Bebautes Gebiet* extrahiert. Die Klassifizierung der Straße wird durch den angepassten und erweiterten Regelsatz klar verbessert, so dass zuletzt fast die gesamte Straße korrekt erkannt ist. Allerdings treten auch hier noch fehlklassifizierte Feldkanten auf. *Bebautes Gebiet* und *Nicht bebautes Gebiet* weisen keine erheblichen Unterschiede zwischen den verschiedenen Klassifizierungen auf.




**Originale, individuelle
Klassifizierung**




**Bildausschnitt
(Testgebiet „Mostaganem“, Region *Küste I*)**



**Klassifizierung mit Basis-
Regelsatz**



**Klassifizierung mit angepasstem
Regelsatz**



**Klassifizierung mit erweitertem
Regelsatz**

Abbildung 54: Verschiedene Klassifizierungen des Bildausschnitts „Mostaganem“ - *Bebautes Gebiet*: rot, *Nicht bebautes Gebiet*: hellgrün, *Straße*: schwarz

Tabelle 25 listet die Qualitätswerte für die einzelnen Objektklassen im Testgebiet „Mostaganem“ auf. Die *KI* der originalen Klassifizierung weisen bei allen vier Objektklassen den jeweils höchsten Wert auf. *Bebautes Gebiet* sowie *Straße* weisen von der Klassifizierung mit dem Basis- bis hin zum erweiterten Regelsatz eine kontinuierliche Verbesserung auf. Die Qualitätswerte für *Nicht bebautes Gebiet* bleiben in einer Größenordnung von rund 0,95 für *KI*. Die Klasse *Wasser* wird mit allen Regelsätzen perfekt klassifiziert.

Tabelle 25: Qualität für das Testgebiet „Mostaganem“ (*Küste I*)

Klassifizierung mit Regelsatz	Testgebiet „Mostaganem“ – <i>Kappa Index</i>			
	Bebautes Gebiet	Nicht bebautes Gebiet	Wasser	Straße
Original, individuell	0,79	0,97	1	0,51
Basis	0,48	0,95	1	0,21
Angepasst	0,53	0,95	1	0,31
Erweitert	0,58	0,93	1	0,39

6.3 Anwendung des Basis-Regelsatzes auf weitere Testgebiete

Der vorläufige Basis-Regelsatz (siehe Abschnitt 5.3.2.4) wurde auf die Testgebiete von *Küste II* und *Wüste II*, für die er nicht optimiert worden war, übertragen und evaluiert. Wie bereits in vorangegangenen Untersuchungen wurde der Regelsatz in einem ersten Verfahrensschritt unverändert angewendet und in einem nächsten Schritt an das neue Bild angepasst, aber nicht erweitert. Abbildung 55 vergleicht die Qualitätsmaße *Overall Accuracy* und *Kappa Index* als Mittel der jeweils vier Testgebiete einer geographischen Region. Wie in den Regionen *Küste I* und *Wüste I* sind die *OA Wüste II* höher als die von *Küste II*. Für die *KI* gilt wiederum das Gegenteil. Die Testgebiete von *Küste II* und *Wüste II* sind nur zur Evaluierung der jeweiligen Basis-Regelsätze vorgesehen, daher gibt es keine individuellen Klassifizierungen zum Vergleich. Die *OA* des angewendeten Basis-Regelsatzes erreichen im Schnitt 76% (K) und 86% (W). Durch Anpassung der Regelsätze kann eine Verbesserung der *OA* um 3% (K) bzw. 4% (W) erzielt werden. Deutlichere Verbesserungen werden beim *KI* erreicht: 9% (K) und 13% (W). Die *KI* der angepassten Regelsätze bewegen sich im Schnitt bei 0,69 (K) und 0,61 (W).

Im Vergleich zu *Küste I* weist die Region *Küste II* beim Basis-Regelsatz und beim angepassten Regelsatz im Durchschnitt geringfügig schlechtere Werte für die *OA* als auch für den *KI* auf. Dieses Ergebnis war zu erwarten, da die Testgebiete der Region *Küste I* zur Erstellung des Basis-Regelsatzes verwendet wurden. Überraschenderweise sind die Qualitätsmaße für *Wüste II* besser als die von *Wüste I*. Eine mögliche Erklärung liegt in unterschiedlichen Bildinhalten zwischen beiden Wüstenregionen. Während in *Wüste I* mit Ausnahme des Testgebiets „Ouargla“ überwiegend sehr kleine Siedlungen vorkommen, enthalten alle Testgebiete von *Wüste II* große Siedlungen, für welche der Regelsatz deutlich besser angepasst werden kann (siehe Abbildungen 53 und 57).




Abbildung 55: Vergleich der Qualität zwischen *Küste II* und *Wüste II*

Betrachtung individueller Objektklassen

Die durchschnittlichen *KI* für die individuellen Objektklassen in *Küste II* und *Wüste II* für den Basis- und den angepassten Regelsatz sind in den Abbildungen 56 und 57 aufgeführt. In der Küstenregion II werden durch die Anpassung des Basis-Regelsatzes die *KI* der Objektklassen *Bebautes Gebiet*, *Nicht bebautes Gebiet* und *Straße* deutlich verbessert. Die Klasse *Wasser* erfährt eine geringfügige, aber nicht signifikante Verschlechterung. Hingegen werden in *Wüste II* durch die Anpassung nur die Klassen *Bebautes Gebiet* und *Straße* verbessert. Die Klasse *Wasser* wird zwar verschlechtert, sie kommt aber nur in zwei von vier Testgebieten von *Wüste II* kleinflächig vor. Die *KI* der Objektklassen in *Küste II* sind im Schnitt besser als in *Wüste II*. Die Klassen *Nicht bebautes Gebiet* und *Wasser* besitzen sehr gute *KI* in *Küste II* mit 0,88 bzw. 0,9. Den schlechtesten *KI* liefert *Straße* in *Küste II* mit 0,31 nach Anpassung des Basis-Regelsatzes. In der geographischen Region *Wüste II* wird immerhin ein *KI* von 0,49 für *Straße* erzielt.




Abbildung 56: Durchschnittliche KI für individuelle Objektklassen Küste II




Abbildung 57: Durchschnittliche KI für individuelle Objektklassen Wüste II

Abbildung 58 stellt die *KI* individueller Objektklassen aus den Regionen *Küste I* und *Küste II* gegenüber. *Bebautes Gebiet* weist in beiden Regionen vergleichbare Ergebnisse auf. Der *KI* wird durch die Anpassung des Regelsatzes auf 0,56 erhöht. *Nicht bebautes Gebiet* zeigt bis auf den angepassten Regelsatz in *Küste II*, der einen sehr guten *KI* von 0,88 besitzt, vergleichbare Ergebnisse. Mögliche Erklärung ist das homogenere Erscheinungsbild von *Nicht bebautes Gebiet* in *Küste II* und die daraus resultierende bessere Anpassung. Bei der Klasse *Straße* fällt auf, dass die Klassifizierung mit Basis-Regelsatz in *Küste II* einen sehr schlechten *KI* von 0,07 aufweist. Durch Anpassung wird aber annähernd die Qualität wie in *Küste I* erzielt. Es ist erkennbar, dass die *KI* individueller Objektklassen der Klassifizierung mit Basis-Regelsatz in *Küste II* etwas schlechter als die von *Küste I* sind. Grund hierfür ist die Erstellung des Basis-Regelsatzes anhand der Testgebiete von Region I. Durch die Anpassung erreichen die *KI* von *Küste II* allerdings vergleichbare Qualität.




Abbildung 58: Vergleich individueller Objektklassen zwischen *Küste I* und *Küste II*

Ein ähnliches Bild zeigt sich auch für die Regionen *Wüste I* und *Wüste II* (siehe Abbildung 59). Die Klassifizierungen mit Basis-Regelsatz für *Bebautes Gebiet*, *Wasser* und *Straße* sind in *Wüste II* geringfügig schlechter als in *Wüste I*. Die Klasse *Nicht bebautes Gebiet* ist in *Wüste II* besser. Auch hier könnte das homogenere Erscheinungsbild dieser Region eine Erklärung sein. Die Ergebnisse für die Klasse *Wasser* sind nicht aussagekräftig, da sie nur in drei der acht Testgebiete vorkommt.




Abbildung 59: Vergleich individueller Objektklassen zwischen Wüste I und Wüste II

6.4 Vergleich der quantitativen und qualitativen Evaluierung

Es wurden Untersuchungen durchgeführt, welche die Ergebnisse der pixelbasierten, quantitativen Qualitätsbetrachtung mit einer qualitativen, d.h. visuellen Beurteilung vergleichen. In den Testgebieten *Küste I* und *Wüste I* wurden jeweils die Klassifizierungen mit erweitertem Regelsatz die der originalen, individuellen Klassifizierung gegenübergestellt.

In der Region *Wüste I* wird die Klasse *Wasser* nicht betrachtet, da sie nur in einem der vier Testgebiete vorkommt. Für die Klassen *Bebautes Gebiet* und *Nicht bebautes Gebiet* entsprechen die Ergebnisse der quantitativen Bewertung der visuellen Beurteilung. Unstimmigkeiten zwischen Bewertung und visueller Beurteilung treten bei der Klasse *Straße* auf. Entsprechend der Qualitätsbetrachtung besitzt *Straße* in der Klassifizierung mit erweitertem Regelsatz einen höheren *KI* als in der originalen, individuellen Klassifizierung. Visuell kommt man zu einem entgegengesetzten Ergebnis. In der originalen, individuellen Klassifizierung sind große Teile des Straßennetzes korrekt klassifiziert, während in der Klassifizierung mit erweitertem Regelsatz neben dem Straßennetz auch viele andere linienförmige Objekte als *Straße* fehlklassifiziert sind. Im Wüstengebiet I sind dies insbesondere Dünenstrukturen, deren Segmente denen der *Straße* ähnlich sind. Beispielhaft sind in Tabelle 26 die Qualitätsmaße für *Straße* im Testgebiet „Nordöstlich von Ouargla“ für die verschiedenen Klassifizierungen aufgeführt. Der erweiterte Regelsatz erzielt den höchsten *KI* von 0,81 für *Straße*. Die individuelle Klassifizierung erreicht einen *KI* von 0,62. Abbildung 60 zeigt die Ergebnisse der originalen Klassifizierung (links) und die des erweiterten Regelsatzes (rechts). In der Klassifizierung mit erweitertem Regelsatz sind mehr Segmente als *Straße* klassifiziert. Neben dem Straßennetz gehören dazu aber auch die Begrenzungen der kreisrunden Bewässerungssysteme und linienförmige Dünenstrukturen, d.h. die Anzahl der als *Straße* fehlklassifizierten Segmente ist deutlich höher als in der originalen Klassifizierung. Bei einer qualitativen, visuellen Beurteilung der extrahierten Straßen wird das Ergebnis der Klassifizierung mit erweitertem Regelsatz deswegen nicht so viel deutlich besser beurteilt werden als dies bei der quantitativen Analyse der Fall ist. Sowohl bei der Klasse *Straße* als auch *Bebautes Gebiet* entsprechen


deutlich weniger als die 50 zufällig ausgewählten Referenzpixel auch tatsächlich diesen Klassen. Bei *Straße* sind es 40 und bei *Bebautes Gebiet* nur 24 Referenzpixel. Die damit fehlende statistische Repräsentativität der Stichprobe ist wahrscheinlich im Falle der *Straße* der Grund für Widersprüche mit der visuellen Beurteilung.

Tabelle 26: Qualität für *Straße* im Testgebiet „Nordöstlich von Ouargla“ (*Wüste I*)


Objektklasse Straße	Originale, individuelle Klassifizierung	Klassifizierung mit Basis- Regelsatz	Klassifizierung mit angepasstem Regelsatz	Klassifizierung mit erweitertem Regelsatz
<i>Kappa Index</i>	0,62	0,75	0,71	0,81

In der Küstenregion I stimmen die visuellen Beurteilungen zum überwiegenden Teil mit den Ergebnissen der quantitativen Qualitätsbetrachtung überein.

Zusammenfassend kann festgehalten werden, dass die verwendete quantitative Qualitätsbetrachtung auf Grundlage der Konfusionsmatrix unter Nutzung von Referenzpixeln zumeist mit der qualitativen (visuellen) Beurteilung übereinstimmt.



Originale, individuelle Klassifizierung



Klassifizierung mit erweitertem Regelsatz



Testgebiet „Nordöstlich von Ouargla“, Region *Wüste I*

Abbildung 60: Testgebiet „Nordöstlich von Ouargla“, individueller und erweiterter Regelsatz, Klassifizierung von *Straße* (schwarz)

6.5 Diskussion und Bewertung der Übertragbarkeit

Die vorhergehenden Abschnitte haben die Ergebnisse der Qualitätsbetrachtung von Experimenten in zwei geographischen Regionen in Nordafrika dargelegt. Die aus den Modellen für *Küste* und *Wüste* abgeleiteten Regelsätze wurden auf insgesamt 16 Testgebiete angewandt. Wie bereits eingangs von Kapitel 4 erläutert wurde, ist die Grundprämisse dieser Arbeit den Auswerteprozess auf etwa 10% der ursprünglich benötigten Zeit zu verkürzen und abzuschätzen, welche Qualität hiermit erzielt werden kann. Grundlage der Experimente war die Frage, ob es für praktische Anwendungen möglich ist, einen allgemein gültigen und somit gut übertragbaren Basis-Regelsatz für eine bestimmte geographische Region zu entwickeln. Im Folgenden werden die erzielten Ergebnisse sowie die Stärken und Schwächen des Ansatzes diskutiert.

Die praktischen Experimente demonstrieren, dass die Übertragung von Regelsätzen prinzipiell möglich ist. In Kapitel 4 wurde gezeigt, dass sogar Regelsätze, die individuell auf ein Bild abgestimmt sind, bis zu einem gewissen Grad übertragbar sind. Des Weiteren wird durch die Experimente bestätigt, dass die Definition eigener Regelsätze für verschiedene geographische Regionen sinnvoll ist und eine deutliche Verbesserung gegenüber der Übertragung individueller, für ein Bild abgestimmter Regelsätze ergeben. Die verschiedenen Charakteristika von Objektklassen, wie beispielsweise, dass *Bebautes Gebiet* in der *Wüste* aus vielen Einzelhäusern, in der Küstenregion dagegen aus dichter Bebauung und größeren Häuserblöcken besteht, spiegeln sich in unterschiedlichen relevanten Segmentmerkmalen für die geographischen Regionen wider. Neben den verschiedenen Ausprägungen gleicher Objektklassen ist das unterschiedliche Vorkommen von Objekten (z.B. kein Meer und wenig Seen in der *Wüste*) ein Grund für regionenspezifische Regelsätze. Vergleicht man die Regelsätze der Regionen, so fällt auf, dass überwiegend ähnliche Segmentmerkmale verwendet sind, wie zum Beispiel Formmerkmale bei der Objektklasse *Straße*. Allerdings sind die Parameterwerte aufgrund der andersartigen Charakteristika verschieden.

In Kapitel 5 wurde zunächst die Übertragbarkeit der Segmentierung und einiger Segmentmerkmale untersucht. Bei der Segmentierung wurde wie erwartet festgestellt, dass bei flächenförmigen Objekten keine Schwierigkeiten auftreten, während bei linienförmigen Objekten zum Teil ungünstige Segmente entstehen können. Diese hängen von der Ausprägung der Straßen und dem vorherrschendem Kontrast zur Umgebung ab. Generell haben die Experimente gezeigt, dass die vorgeschlagenen Segmentierungsparameter für die jeweilige geographische Region passend und ausreichend sind. Die Segmentierungsergebnisse wurden visuell begutachtet und in keinem Fall war eine Änderung der Parameter notwendig. Die Angabe spezifischer Segmentierungsparameter für einen bestimmten Sensor und eine Region ist demnach zumindest unter den in dieser Arbeit vorliegenden Bedingungen machbar. Dies stellt für den Anwender eine große Erleichterung dar, da das Austesten verschiedener Parameter entfällt.

Bei den Segmentmerkmalen wurden radiometrische Eigenschaften, Texturmaße, Formmerkmale und Relationen, d.h. Kontext, in Hinblick auf ihre Übertragbarkeit untersucht. In der Regel war es wegen unterschiedlicher Beleuchtung, Atmosphäreneigenschaften und Ausprägung der Objekte nötig, die Wertebereiche spektraler Merkmale an das neue Bild anzupassen. Beispiele hierzu sind der *NDVI* und der mittlere Grauwert eines Segmentes in einem bestimmten Bildkanal. Texturmaße mussten hingegen seltener angepasst werden, da sie Aussagen über Grauwertunterschiede und nicht über die absoluten Grauwerte machen. Formmerkmale werden hauptsächlich zur Charakterisierung von linienförmigen Objekten wie *Straße* und *Fluss* eingesetzt. Im Großen und Ganzen sind formbeschreibende Merkmale übertragbar. Einige, wenige Änderungen der Wertebereiche waren nötig, um ein besseres Klassifizierungsergebnis zu erreichen. So werden Straßen, wenn sie wegen ihrer Materialeigenschaften einen schlechten Kontrast zur Umgebung aufweisen, oft mit angrenzenden, spektral ähnlichen Flächen zu einem Segment verschmolzen, was sich wiederum in den Formparametern widerspiegelt. Relationen wurden bei den in dieser Arbeit verwendeten Satellitenbilddaten mittlerer Auflösung nicht eingesetzt, da diese sich auf feinere Objektdefinitionen beziehen. Gemäß den in Abschnitt 3.4.2 aufgestellten Modellen eignen sich zur Extraktion der Objektklasse *Bebautes Gebiet* überwiegend Texturmerkmale. Die Klasse *Nicht bebautes Gebiet* wird hauptsächlich mit Hilfe des *NDVI* und Texturmaßen übertrag-

bar beschrieben. Zur objektbasierten Analyse von Wasserklassen werden überwiegend Eigenschaften des NIR-Kanals verwendet (*Ratio* oder mittlerer Grauwert). Die Unterscheidung von *Meer* und *See* gelingt mit Formmerkmalen. Auch bei der Klasse *Fluss* werden neben Regeln mit spektralen Eigenschaften auch solche mit Formmerkmalen eingesetzt, die die Langgestrecktheit beschreiben.

Die Struktur der Regelsätze wurde bei fast allen durchgeführten Experimenten unverändert beibehalten. Nur in Ausnahmefällen, bei denen z.B. eine Objektklasse eine sehr spezielle Ausprägung besitzt, mussten neue Regeln hinzugefügt werden. Ansonsten reichte die Anpassung einzelner Wertebereiche aus, um ein zufrieden stellendes Klassifizierungsergebnis zu erzielen.

Stärken und Schwächen

Die folgenden Abschnitte beleuchten den entwickelten objektbasierten auf möglichst gute Übertragbarkeit abzielenden Ansatz zur Klassifizierung von Satellitenbilddaten im Hinblick auf seine Stärken und Schwächen.

Verfahren der objektbasierte Bildanalyse eignen sich tendenziell besser zur Datengewinnung für Geo-Informationssysteme als klassische pixelbasierte Methoden. In GIS-Objektartenkatalogen sowie in GIS-Systemen erfolgt die Modellierung der Geodaten in der Regel ebenfalls in Form von Objekten, so dass hier eine Verknüpfung besteht. Durch die vorgeschaltete Segmentierung der Bilddaten können auch komplexe Bilder prozessiert werden, für die keine direkte Zuordnung zwischen Pixeln und Klassen über eine spektrale Signatur gilt. Im Vergleich zu pixelbasierten Verfahren können für die Objektextraktion neben spektralen Merkmalen der Segmente auch zusätzliche Informationen wie Form genutzt werden. Die Tatsache, dass die Segmentierung die nachfolgende Klassifizierung beeinflusst, darf allerdings nicht unerwähnt bleiben. Die Klassifizierung kann ohne Resegmentierung nicht besser sein als die zugrunde liegende Segmentierung.

Trotz der zahlreichen Einflüsse bei der Übertragung von Regelsätzen und den mannigfaltigen Erscheinungsformen topographischer Objekte werden durch die Verwendung stabiler Segmentmerkmale in einem Basis-Regelsatz viel versprechende Ergebnisse erzielt. Der hier vorgestellte Ansatz ist nicht wie viele andere Arbeiten auf eine einzige Objektklasse beschränkt, sondern er kann auch relativ einfach für neue Objektklassen erweitert werden. Während in den praktischen Experimenten die Regelsätze auf zwei geographische Regionen in Algerien erfolgreich angewendet wurden, sollte wegen der ähnlichen Strukturen der Landschaft ihre Anwendung für größere Teile Nordafrikas zu brauchbaren Ergebnissen führen.

Da es sich beim gewählten Ansatz um ein semiautomatisches Verfahren handelt, welches keinerlei Vorinformationen in Form bestehender Geodaten benötigt, eignet er sich besonders für Entwicklungsländer, für die unzureichende Karten und Geodaten verfügbar sind. Beim Einsatz von Satellitendaten mittlerer Auflösung können kostengünstig großflächige Gebiete bearbeitet werden. Die Klassifizierungsergebnisse können als Grundlage für die Kartierung in den Maßstabsbereichen 1 : 100 000 - 250 000 dienen. Die Klassifizierung mit Zugehörigkeitsfunktionen macht das Ergebnis nachvollziehbar. Für jedes Segment können die entsprechenden Zugehörigkeitswerte zu verschiedenen Objektklassen ausgegeben und analysiert werden. Die Verfügbarkeit von Basis-Regelsätzen für bestimmte geographische Regionen verkürzt die notwendige Bearbeitungszeit stark. Die Notwendigkeit der aufwändigen Erstellung individueller Regelsätze für jedes einzelne Bild entfällt. Stattdessen wird der Basis-Regelsatz angepasst, was deutlich weniger zeitintensiv ist.

FÖRSTNER (1996) stellt an Verfahren zur automatischen Extraktion von Objekten die Forderung, dass die vom Nutzer einstellbaren Parameter in Bezug auf das zu extrahierende Objekt, d.h. eine semantisch, nachvollziehbare Bedeutung haben sollten. Die im Rahmen der vorliegenden Arbeit entwickelten Basis-Regelsätze erfüllen diese Forderung zumindest zum Teil. Der Anwender kann die in den Regelsätzen verwendeten charakteristische Merkmale der zu extrahierenden Objekte abgesehen von den spektralen und z.T. den Texturparametern ohne weiteres interpretieren.

Das verwendete Modell ist zur besseren Übertragbarkeit durch Verwendung weniger Objektklassen einfach gehalten. Manche topographischen Gegebenheiten einer Objektklasse sind damit anderen Objektklassen sehr ähnlich und erzeugen Fehlklassifizierungen. Abbildung 61 zeigt links im IRS-Farbinfrarotbild rote Vegetationsflächen mit grauen, kahlen Berghängen und im südöstlichen Bildausschnitt eine Siedlung. Die kahlen Berghänge erfüllen aufgrund von Material/Radiometrie und kleinräumiger Struktur/Textur oftmals nicht die Regeln für *Nicht bebautes Gebiet*, sondern werden fälschlicherweise der Klasse *Bebautes Gebiet* zugewiesen. Der rechte Bildausschnitt zeigt einen Küstenbereich mit Meeresbrandung an einem Strand. Die hellen Wellenkämme werden als einzelne Segmente segmentiert und erfüllen nicht die radiometrischen Eigenschaften von *Wasser*. Auch hier können Fehlklassifizierungen z.B. zur Klasse *Bebautes Gebiet* auftreten. Strandbereiche bilden sich als helle, lang gestreckte Segmente ab und werden häufig irrtümlicherweise als *Straße* extrahiert. Ein Modell, welches alle potenziellen topographischen Gegebenheiten in ihren verschiedenen Ausprägungen abbildet, wäre sehr komplex und dadurch nur schlecht übertragbar. Eine automatische, vollständige und korrekte Interpretation einer Bildszene ist daher in naher Zukunft nicht realisierbar. Die Ergebnisse automatischer Prozesse werden bis auf weiteres fehlerhaft sein und erfordern die Nachbearbeitung durch den Menschen.




Abbildung 61: Kahle Bergrücken (links) und Meeresbrandung (rechts) in pan-sharpened IRS-Farbinfrarotbild

Die Rahmenbedingungen für die vorliegende Arbeit legen die Verwendung von Satellitenbilddaten mittlerer Auflösung sowie den Verzicht auf Nutzung von a priori Informationen in Form von Karten oder GIS-Daten fest. Das Potenzial der objektbasierten Analyse kann bei hoch aufgelösten Bilddaten besser ausgeschöpft werden, da mehr Einzelobjekte und deren Beziehungen untereinander modelliert werden können. Auf die Nutzung und Modellierung von Kontext wurde verzichtet, da sich die Relationen zwischen den sehr allgemein gehaltenen Objektklassen als nicht übertragbar erwiesen. Auch hier bieten eventuell höher aufgelöste Bilddaten mit der entsprechend feineren Objektmodellierung mehr Möglichkeiten, um Kontextwissen zur Objektextraktion einzubringen. Bislang werden nur Bilddaten eines Sensors verwendet. Zusätzliche Daten, wie andere optische Satellitenbilddaten oder Digitale Geländemodelle könnten die Klassifizierung verbessern. Durch die Segmentierung der Bilddaten in unterschiedlichen Auflösungsstufen erfolgt eine Modellierung der Maßstabsabhängigkeit der Objekte. Einige Segmentmerkmale beziehen sich auf eine feiner segmentierte Auflösungsstufe (siehe Abschnitt 3.4.2 Modellierung *Wüste*).

Mögliche Erweiterungen

Der vorgestellte Ansatz zur Objektextraktion basierend auf der Anpassung von Basis-Regelsätzen könnte für beliebige Objektklassen, für andere Sensoren sowie für andere geographische Regionen erweitert werden. Die Grundidee der Übertragung von (Basis-)Regelsätzen kann auf die unterschiedlichsten Problemstellungen angewendet werden. Es muss lediglich eine Neudefinition oder, wenn die Unterschiede nicht sehr groß sind, eine noch weniger aufwändige Anpassung an neue Regionen und/oder Sensoren erfolgen. Eine Idee für einen verbesserten Basis-Regelsatz könnte sein, dass man für komplexe Klassen spezielle Klassen, wie z.B. *dichte* und *lockere Bebauung* oder *Schatten* einführt

und dann je nach Bildinhalt bei der Klassifizierung zu- oder ausschaltet. Das flächenmäßig größte Testgebiet Algier zeigt die schlechtesten *KI* bei der Klassifizierung mit Basis-, angepasstem und erweitertem Regelsatz (siehe Abschnitt 6.1). Daher ist eine Aufteilung großer Gebiete in kleinere Teilgebiete denkbar, welche separat klassifiziert und angepasst werden. Bei hoch aufgelösten Bilddaten kann eine Kontextmodellierung zusätzliche Informationen für die Objektextraktion liefern. Neben der kombinierten Auswertung verschiedener Sensoren dürfte die vermehrte Nutzung des Maßstabsverhaltens von Objekten in Form von unterschiedlich segmentierten Ebenen wertvolle Evidenz bereitstellen. Die größten Anpassungen beim Regelwerk müssen wahrscheinlich bei den radiometrischen Segmentmerkmalen vorgenommen werden. Hier wäre zu prüfen, inwieweit, wenn die entsprechenden Daten verfügbar sind, eine Vorverarbeitung der Bilddaten in Form von atmosphärischen und topographischen Korrekturen den Aufwand für die Anpassung reduzieren kann.

Im Hinblick auf einen operationellen Workflow ist folgender Ablauf vorstellbar: Zu Beginn der Objektextraktion spezifiziert der Nutzer die zu bearbeitende geographische Region. Das System zeigt daraufhin eine Liste mit möglichen Objektklassen, die in dieser Region vorkommen können. Nach Auswahl der zu extrahierenden Objektklassen wählt die Software geeignete verfügbare Sensordaten aus. Je nach Objektklassen können unterschiedliche Sensordaten eingesetzt werden, wie z.B. höher aufgelöste Bilddaten für Straßen und städtische Bereiche und Daten mittlerer Auflösung für ländliche Bereiche. Dann werden vom System passende Segmentierungsparameter und Regelsätze ausgesucht und die gewünschten Objektklassen extrahiert. Nach erfolgreicher Prozessierung werden die Ergebnisse dargestellt und der Nutzer entscheidet, ob er die Parameter(werte) anpassen will, und/oder zusätzliche Objekte definieren will, oder ob die Ergebnisse zur Fertigstellung interaktiv bearbeitet werden sollen.

Weiterer Forschungsbedarf besteht im Bereich der automatisierten Evaluierung von Segmentierungen und objektbasierten Klassifizierungsergebnissen. Beide Punkte erfordern bislang Referenzdaten, die in der Regel nicht vorliegen und deren Gewinnung sehr aufwändig ist. Bedeutende Fragen hierbei sind z.B., welche Indexe der pixelbasierten Evaluierung für objektbasierte Klassifizierungsergebnisse geeignet sind und warum. Die Faustregeln für die Anzahl der notwendigen Referenzpixel für eine zuverlässige Evaluierung und die Verteilung der Referenzpixel auf die verschiedenen Klassen sollten im Hinblick auf die objektbasierte Klassifizierung überprüft werden. Stehen Referenzdaten in Form von Objekten zur Verfügung, so sind geeignete Vergleichsmaße, wie z.B. Anzahl der Objekte, Form, Größe und Überlappung Referenz/Extraktion zu testen. Insbesondere für topographische Objekte müssen zweckmäßige Maße gefunden werden, da diese Objekte z.T. nicht eindeutig segmentiert werden und dadurch Diskrepanzen mit den Referenzdaten auftreten können. Neben der Evaluierung von Ergebnissen der Bildanalyse ist der Schritt hin zur inneren Bewertung der Zuverlässigkeit der extrahierten Objekte eine interessante Forschungsfragestellung.

7 Zusammenfassung und Ausblick

Der Bedarf an aktuellen Geodaten für die unterschiedlichsten Anwendungen wächst ständig. Fernerkundungsdaten haben sich als Datenquelle für Geodaten etabliert, da sie zeitnah und weltweit verfügbar sind. Im Bereich der Entwicklung von wirtschaftlichen Verfahren zur Datengewinnung aus Fernerkundungsdaten werden objektbasierte Bildanalysemethoden immer wichtiger.

Die Ausführungen der vorliegenden Arbeit konzentrieren sich auf die Übertragbarkeit der objektbasierten Analyse von Fernerkundungsdaten. Nach Darlegung von Grundlagen der Bildanalyse und Stand der Wissenschaft erfolgt die Einführung der objektbasierten Analyse. Das Modell für die einzelnen Landbedeckungsklassen betrachtet die Objekte in den drei Ebenen „Reale Welt“, „Material- und Geometrie“ sowie „Bild“. Als Grundlage für die Implementierung des Modells in Form von Regelsätzen wird die Segmentierung des Bildes und die Eigenschaften der Segmente vorgestellt. Für einen operationellen Einsatz stellt sich die Frage, ob es gelingt, allgemein gültige (Basis-)Regelsätze zu entwickeln, die innerhalb einer bestimmten geographischen Region für einen Sensor nach einer mäßig aufwändigen Anpassung zu akzeptablen Ergebnissen für die Anwendung führen. Zur Beantwortung dieser Frage werden potenzielle Einflussfaktoren, wie z.B. Atmosphäreneinflüsse, Beleuchtungsrichtung, sowie ihre Auswirkungen auf verschiedene Segmentmerkmale diskutiert.

Die Übertragbarkeit wurde in praktischen Experimenten mit den in Regelsätze umgesetzten Modellen in zwei in der Arbeit definierten geographischen Regionen (*Küste* und *Wüste*) in Algerien getestet. Die IRS-Satellitenbilder mittlerer Auflösung wurden keinerlei Vorverarbeitung unterzogen. Der erste Teil der praktischen Experimente beschäftigt sich mit der Übertragung individueller Regelsätze, d.h. für ein Bild optimierte Regelsätze wurden auf andere Testgebiete derselben geographischen Region angewendet und angepasst. Die Ergebnisse zeigen die prinzipielle Möglichkeit der Übertragung von Regelsätzen innerhalb einer Region.

In einem nächsten Schritt wurden basierend auf diesen Ergebnissen möglichst allgemein gültige Basis-Regelsätze für die beiden Regionen aufgestellt und in weiteren praktischen Experimenten untersucht. Die Ergebnisse zeigen, dass die verwendeten Regelsätze relativ gut übertragbar sind. Texturmaße und Formmerkmale haben sich bei der Übertragung als relativ stabil erwiesen. Bei radiometrischen Merkmalen ist allerdings zur Verbesserung des Klassifizierungsergebnisses eine Anpassung der Wertebereiche erforderlich, weil die Bilddaten wegen Nichtverfügbarkeit von geeigneten Atmosphärenparametern und Höhenmodellen nicht radiometrisch und topographisch korrigiert wurden. Die Grundstruktur der Regelsätze kann aber uneingeschränkt übernommen werden. Hierdurch wird eine große Zeiterparnis (ca. Faktor 10) gegenüber einer individuellen Regelsatzerstellung für jedes neue Bild erreicht.

In dieser Arbeit wurde gezeigt, dass die Übertragung von Regelsätzen Potenzial für ein effizientes semiautomatisches System zur Erfassung von GIS-Daten aus Fernerkundungsdaten mittlerer Auflösung besitzt. Für ein operationelles System müssten entsprechende Regelsätze für die jeweils relevanten Fernerkundungssensoren, Objektklassen und geographische Regionen entwickelt werden. Um beispielsweise die Datenerfassung für große Gebiete wie Nordafrika realisieren zu können, wäre folgende Aufteilung denkbar: In Stadtbereichen mit hohen Änderungsraten sollten hoch aufgelöste Satellitenbilder eingesetzt werden, welche die erforderliche Auflösung bieten. Für ländliche Regionen, wie die großen Wüstengebiete, genügen Satellitendaten mittlerer Auflösung, die um einiges kostengünstiger sind. Selten vorkommende komplexe topographische Objekte von großem Interesse, wie etwa Flughäfen, sollten manuell erfasst werden. Eine automatische Extraktion dieser besonderen Objekte ist zurzeit nicht zuverlässig genug und Überprüfung bzw. Nachbearbeitung wären zu aufwändig.

Im Hinblick auf die Nachbearbeitung der Klassifizierungsergebnisse zur Übernahme in ein GIS-System spielen zwei Faktoren eine entscheidende Rolle: Zum einen sollten die Ergebnisse möglichst korrekt und vollständig sein, damit der Aufwand für die Nachbearbeitung durch den Nutzer möglichst gering ist. Zum anderen könnte eine innere Bewertung der Zuverlässigkeit den Nutzer auf Objekte fokussieren, die wirklich nachbearbeitet werden müssen. Weitere wichtige und noch offene For-

schungsfragen sind die Führung des Nutzers durch den Workflow und generell Möglichkeiten zur Unterstützung der Interaktion mit dem System basierend auf den Ergebnissen der Objektextraktion.

8 Anhang

Tabelle 27: Basis-Regelsatz für Küste

Basisklasse	Objektklasse	Merkmal	Wertebereich	
Bebautes Gebiet	Bebautes Gebiet	GLCM ASM NIR	< 0,002	
		Mean Green	> 90	
		GLCM Homog. NIR	< 0,15	
		GLCM Contrast Red	> 90	
		GLCM Entropy NIR	> 6,2	
		Not Straße	-	
Nicht bebautes Gebiet	Nicht bebautes Gebiet	NDVI	> 0,1	
		GLCM Variance NIR	0 - 11	
		Not Straße	-	
Straße	Straße	Length/Width	> 2,3	
		Density	< 0,9	
		Mean NIR	> 80	
		Compactness	> 4,5	
-	Wasser	Ratio NIR	< 0,27	
Wasser	See (Kind von Wasser)	Area	> 6500 m ²	
		Length	< 310 m	
		Ratio NIR	0,19 - 0,24	
		Not Meer	-	
	Meer (Kind von Wasser)	Ratio NIR	< 0,24	
		Mean NIR	25 - 50	
	Fluss	Fluss	Length/Width	> 4
			Shape Index	3,2 - 3,8
			Average Length of Edges (polygon)	> 45 m

Spektrales Merkmal
Texturmerkmal
Formmerkmal

Tabelle 28: Basis-Regelsatz für *Wüste*

Basisklasse	Objektklasse	Merkmal	Wertebereich
-	Dünen & Bebaut	GLCM Homog. GREEN	0 - 0,17
		Length/Width (Line so) (1)	< 12
-	Straßen & Dünen	Border Length	< 1450 m
		Curvature/Length (Line so) (1)	> 0,4
		Density	< 0,9
		Length/Width (Line so) (1)	> 7
		Width (Line so) (1)	< 30 m
Bebautes Gebiet	Bebautes Gebiet (Kind von Dünen & Bebaut)	GLCM Contrast NIR	> 42
		Ratio Red	0,27 - 0,35
Nicht bebautes Gebiet	Nicht bebaut	Compactness	> 10
		GLCM Variance NIR	2 - 10
		Length/Width (Line so) (1)	< 9
		NDVI	-0,14 - (-0,01)
	Vegetation	NDVI	> 0
	Dünen flächenförmig (Kind von Dünen & Bebaut)	Density	0,75 - 1,95
	Dünen linienförmig (Kind von Straßen & Dünen)	Aver. Length of edges (polyg.)	< 33 m
Straße	Straße (Kind von Straßen & Dünen)	Aver. Length of edges (polyg.)	> 35 m
Wasser	See	Ratio GREEN	0,44 - 1
	Fluss	Mean NIR	24 - 51
		Length/Width	> 4

Spektrales Merkmal
Texturmerkmal
Formmerkmal

9 Literaturverzeichnis

Verwendete Abkürzungen:

AGIT	Angewandte Geographische Informationsverarbeitung
DGK	Deutsche Geodätische Kommission
IAPRS	International Archives of Photogrammetry and Remote Sensing
IAPRSSIS	International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences
PAMI	IEEE Transactions on Pattern Analysis and Machine Intelligence
PFG	Zeitschrift Photogrammetrie Fernerkundung Geoinformation

- ADV (2002): *ATKIS-Objektartenkatalog Basis-DLM*, Stand 1.3.2003, Version 3.1. <http://www.atkis.de> (30.05.2005)
- ALBERTZ, J. (2001): *Einführung in die Fernerkundung*. Wissenschaftliche Buchgesellschaft, Darmstadt.
- AMERI, B. (2000): *Automatic Recognition and 3D Reconstruction of Buildings through Computer Vision and Digital Photogrammetry*. Dissertation, Universität Stuttgart.
- ANDRESEN, T. (2004): *Strategien zur wissensbasierten Bildanalyse hoch auflösender Fernerkundungsdatensätze für das Monitoring gewässernaher Feuchtgebiete*. Dissertation, Technische Universität München.
- ARMENAKIS, C. (2000): *Differential Approach for Map Revision from New Multi-Resolution Satellite Imagery and Existing Topographic Data*. In: IAPRS, Vol. XXXIII, Part B4, S. 99-104.
- BAATZ, M., SCHÄPE, A. (2000): *Multiresolution Segmentation – an Optimization Approach for High Quality Multi-Scale Image Segmentation*. In: Strobl, J., Blaschke, T., Griesebner, G. (Hrsg.): AGIT XII, Wichmann Verlag Heidelberg, S. 12-23.
- BACHER, U., MAYER, H. (2004): *Automatic Road Extraction from IRS Satellite Images in Agricultural and Desert Areas*. In: IAPRSSIS, Vol. XXXV, Part B3, S. 1055-1060.
- BÄHR, H.-P., VÖGTLE, T. (1998): *Digitale Bildverarbeitung*. Wichmann Verlag Heidelberg.
- BALTSAVIAS, E. P. (2004): *Object Extraction and Revision by Image Analysis Using Existing Geodata and Knowledge: Current Status and Steps Towards Operational Systems*. In: ISPRS Journal of Photogrammetry & Remote Sensing, Vol. 58, S. 129-151.
- BAUMGARTNER, A., STEGER, C., MAYER, H., ECKSTEIN, W., EBNER, H. (1999): *Automatische Straßenextraktion auf Grundlage von verschiedenen Auflösungsstufen, Netzbildung und Kontext*. In: PFG, Nr. 1, S. 5-17.
- BLASCHKE, T. (2000): *Ohne Salz und Pfeffer – Objektorientierte Bildanalyse – eine Revolution in der Fernerkundung*. In: GeoBit, Nr. 2, S. 30-32.

- BORSOTTI, M., CAMPADELLI, P., SCETTINI, R. (1998): *Quantitative Evaluation of Color Image Segmentation Results*. In: Pattern Recognition Letters, Nr. 19, S. 741-747.
- BRACHMANN, R. J. (1977): *What's in a Concept: Structural Foundations for Semantic Networks*. In: International Journal of Man-Machine Studies, Vol. 9, S. 127-152.
- BRENNER, C. (2000): *Dreidimensionale Gebäuderekonstruktion aus digitalen Oberflächenmodellen und Grundrissen*. DGK Reihe C, Heft Nr. 530, Verlag der Bayerischen Akademie der Wissenschaften, München.
- BRONGE, L. B. (1999): *Mapping Boreal Vegetation Using Landsat-TM and Topographic Map Data in a Stratified Approach*. Canadian Journal of Remote Sensing, Vol. 25, No. 5, S. 460-474.
- BRUNN, A. (2001): *Semantik-basierte Gebäudeerfassung mit verkoppelten Markoff-Zufallfeldern*. Dissertation, Universität Bonn.
- BUSCH, A. (1998): *Revision of Built-up Areas in a GIS Using Satellite Imagery and GIS Data*. In: IAPRS, Vol. XXXII, Part 4, S. 91-98.
- CHELLAPPA R., CHATTERJEE, S. (1985): *Classification of Textures using Gaussian Markov Random Fields*. In: IEEE Transactions of Acoustics, Speech and Signal Processing, Vol. 33, Issue 4, S. 959-963.
- CLAUSI, D. (2002): *An Analysis of Co-Occurrence Texture Statistics as a Function of Grey Level Quantization*. In: Canadian Journal of Remote Sensing, Vol. 28, No. 1, S. 45-62.
- CONGALTON, R. G., GREEN, K. (1999): *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. Lewis Publishers, Boca Raton, Florida.
- DARWISH, A., LEUKERT, K., REINHARDT, W. (2003): *Urban Land-Cover Classification: An Object Based Perspective*. In: Proceedings of the 2nd GRSS/ISPRS Joint Workshop on Data Fusion and Remote Sensing over Urban Areas, Urban 2003, S. 278-282.
- DAVIS, L. S. (1981): *Image Texture Analysis Techniques – A Survey*. In: Simon, J. C., Haralick, R. M. (Eds.): Digital Image Processing, D. Reidel Publishing Company, Dordrecht, Holland, S. 189-201.
- DE KOK, R., WEVER, T. (2002): *Automatische Informationsgewinnung aus einheitlichen Megadaten-sätzen am Beispiel des IRS-1C/IRS-1D-Mosaiks von Deutschland*. In: Dech, S. et al. (Hrsg.): Tagungsband 19. DFD-Nutzerseminar, S. 105-112.
- DE KOK, R., WEVER, T., FOCKELMANN, R. (2003): *Analysis of Urban Structure and Development applying Procedures for Automatic Mapping of Large Area Data*. In: IAPRSSIS, Vol. XXXIV-7/W9, S. 41-45.
- ECKERT, S., KNEUBÜHLER, M. (2004): *Application of Hyperion Data to Agricultural Land Classification and Vegetation Properties Estimation in Switzerland*. In: IAPRSSIS, Vol. XXXV, Part B7, S. 866-871.

- eCognition USER GUIDE (2004): www.definiens-imaging.com/documents (30.05.2005)
- ESCH, T., ROTH, A., STRUNZ, G., DECH, S. (2003): *Object-oriented Classification of Landsat-7 Data for Regional Planning Purposes*. In: IAPRSSIS, Vol. XXXIV-7/W9, S. 50-55.
- FLANDERS, D., HALL-BEYER, M., PEREVERZOFF, J. (2003): *Preliminary Evaluation of eCognition Object-Based Software for Cut Block Delineation and Feature Extraction*. In: Canadian Journal of Remote Sensing, Vol. 29, No. 4, S. 441-452.
- FOODY, G. M. (2002): *Status of Land Cover Classification Accuracy Assessment*. In: Remote Sensing of Environment, Nr. 80, S. 185-201.
- FÖRSTNER, W. (1996): *10 Pros and Cons against Performance Characterization of Vision Algorithms*. In: Workshop on „Performance Characteristics of Vision Algorithms“, Cambridge, UK.
- FREIXENET, J., MUÑOZ, X., RABA, D., MARTÍ, J., CUFFÍ, X. (2002): *Yet Another Survey on Image Segmentation: Region and Boundary Information Integration*. In: A. Heyden et al. (Hrsg.): ECCV 2002, LNCS 2352, Springer Verlag Berlin, S. 408-422.
- FRITSCH, D. (1997): *Experiences with the airborne three-line camera system DPA*. In: Photogrammetric Week '97, Fritsch/Hobbie (Hrsg.), Wichmann Verlag Heidelberg, S. 63-74.
- GOTLIEB, C., KREYSZIG, H. (1990): *Texture Descriptors Based on Co-Occurrence Matrices*. In: Computer Vision, Graphics and Image Processing, Nr. 51, S. 70-86.
- GROWE, S. (2001): *Wissensbasierte Interpretation multitemporaler Luftbilder*. VDI-Fortschrittberichte Reihe 10, Nr. 656, VDI Verlag Düsseldorf.
- GÜLCH, E., MÜLLER, H., HAHN, M. (2004): *Semi-Automatic Object Extraction – Lessons Learned*. In: IAPRSSIS, Vol. XXXV, Part B2, S. 423-427.
- HARALICK, R. M., SHAPIRO, L. G. (1985): *Survey – Image Segmentation Techniques*. In: Computer Vision, Graphics, and Image Processing, Vol. 29, S. 100-132.
- HARALICK, R. M., SHAPIRO, L. G. (1992): *Computer and Robot Vision*, Vol. 2, Addison-Wesley.
- HARALICK, R. M., SHANMUGAM, K., DINSTEIN, I. (1973): *Textural Features for Image Classification*. In: Transactions on Systems, Man and Cybernetics, Vol. 3, Issue 6, S. 610-621.
- HEIPKE, CH., STRAUB, B.-M. (1999): *Towards the Automatic GIS Update of Vegetation Areas from Satellite Imagery Using Digital Landscape Model as Prior Information*. In: IAPRS, Vol. XXXII, Part 3-2W5, S. 167-174.
- HILDEBRANDT, G. (1996): *Fernerkundung und Luftbildmessung*. Wichmann Verlag Heidelberg.
- HILL, J., MEHL, W. (2003): *Geo- und radiometrische Aufbereitung multi- und hyperspektraler Daten zur Erzeugung langjähriger kalibrierter Zeitreihen*. In: PFG, Nr. 1, S. 7-14.
- HOFFMANN, A. (2001): *Neue Ansätze zur Auswertung und Klassifizierung von sehr hochauflösenden Daten: Methoden der Segmentierung, der hierarchischen Klassifizierung und der per-Parcel-*

Methode mit Daten der Digitalen Kamera HRSC-A und ihre Anwendbarkeit für die Aktualisierung topographischer Karten. Dissertation, Humboldt-Universität zu Berlin.

- HOFFMANN, A., VAN DER VEGT, J. W., LEHMANN, F. (2000): *Towards Automated Map Updating: Is it Feasible with New Digital Data-Acquisition and Processing Techniques?* In: IAPRS, Vol. XXXIII, Part B2, S. 295-302.
- HOOVER, A., JEAN-BAPTISTE, G., JIANG, X. ET AL. (1996) : *An Experimental Comparison of Range Image Segmentation Algorithms.* In: PAMI, Vol. 18, No. 7, S. 673-688.
- HUANG, Q., DOM, B. (1995): *Quantitative Methods of Evaluating Image Segmentation.* In: IEEE International Conference on Image Processing, Vol. III, S. 53-56.
- IEEE Std 610.4 (1990): *IEEE Standard Glossary of Image Processing and Pattern Recognition Terminology.* IEEE Press, New York.
- JÄHNE, B. (1993): *Digitale Bildverarbeitung.* Springer Verlag Berlin.
- JENSEN, J. R., COWEN, D. J. (1999): *Remote Sensing of Urban/Sub-urban Infrastructure and Socio-economic Attributes.* In: Photogrammetric Engineering & Remote Sensing, 65 (5), S. 611-622.
- KASS, M., WITKIN, A., TERZOPOULUS, D. (1987): *Snakes: Active Contour Models.* In: 1st International Conference on Computer Vision, IEEE Comp. Soc. Press, S. 259-268.
- KIEFL, R., KEIL, M., STRUNZ, G., MEHL, H., MOHAUPT-JAHR, B. (2003): *CORINE Land Cover 2000 – Stand des Teilprojektes in Deutschland.* In: Strobl, J., Blaschke, T., Griesebner, G. (Hrsg.): AGIT XV, Wichmann Verlag Heidelberg, S. 202-207.
- KIRSTEIN, W., LINDE, L. (2004): *Pixelorientierte versus objektorientierte Klassifikation eines hochauflösenden IKONOS-Satellitenbildes am Beispiel des Nordraumes der Stadt Leipzig.* UFZ-Umweltforschungszentrum Leipzig-Halle GmbH, Nr. 12.
- KOCH, B., JOCHUM, M., IVITS, E., DEES, M. (2003): *Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren.* In: PFG, Nr. 3, S. 195-204.
- KOLBE, T. H. (2000): *Identifikation und Rekonstruktion von Gebäuden in Luftbildern mittels unscharfer Constraints.* Shaker Verlag, Aachen, Reihe Informatik.
- KRESSLER, F., FRANZEN, M., STEINNOCHER, K. (2003a): *Automationsgestützte Erfassung der Landnutzung in Städten mittels objektorientierter Auswertung von Luftbildern.* In: Strobl, J., Blaschke, T., Griesebner, G. (Hrsg.): AGIT XV, Wichmann Verlag Heidelberg, S. 250-255.
- KRESSLER, F., KIM, Y., STEINNOCHER, K. (2003b): *Object-oriented Land Cover Classification of Panchromatic KOMPSAT-1 and SPOT-5 Data.* In: Proceedings of IGARSS 2003 IEEE, S. 3471-3473.

- KUNZ, D., VÖGTLE, T., SCHILLING, K.-J. (1998): *Integrierte Verarbeitung von Satellitenbild- und vektorieller Karteninformation*. In: Bähr/Vögtle (Hrsg.): *Digitale Bildverarbeitung*, Wichmann Verlag Heidelberg, S. 220-242.
- LANDIS, J. R., KOCH, G. G. (1977): *The Measurement of Observer Agreement for Categorical Data*. In: *Biometrics*, Vol. 33, S. 159-174.
- LANG, F. (1999): *Geometrische und semantische Rekonstruktion von Gebäuden durch Ableitung von 3D Gebäudeecken*. Shaker Verlag, Aachen, Reihe Informatik.
- LANG, S. (2002): *Zur Anwendung des Holarchiekonzeptes bei der Generierung regionalisierter Segmentierungsebenen in höchst-auflösenden Bilddaten*. In: Thomas Blaschke (Hrsg.): *Fernerkundung und GIS, Neue Sensoren – innovative Methoden*, Wichmann Verlag Heidelberg, S. 24-32.
- LEUKERT, K. (2002a): *Verwendung von GIS-Daten für die Objektextraktion*. In: Thomas Blaschke (Hrsg.): *Fernerkundung und GIS, Neue Sensoren – innovative Methoden*, Wichmann Verlag Heidelberg, S. 132-140.
- LEUKERT, K. (2002b): *Untersuchungen zur Segmentierung von Satellitenbilddaten für die Extraktion von GIS-Objekten*. Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung, Band 11, S. 237-244.
- LEVINE, M. D., NAZIF, A. M. (1985): *Dynamic Measurement of Computer Generated Image Segmentations*. In: *PAMI*, Vol. 7, No. 2, S. 155-164.
- LILLESAND, T., KIEFER, R. (2000): *Remote Sensing and Image Interpretation*. John Wiley & Sons, New York.
- LIU, J., YANG, Y. H. (1994) : *Multiresolution Color Image Segmentation*. In : *PAMI*, Vol. 16, No. 7, S. 689-700.
- MALLAT, S. G. (1989): *A Theory for Multiresolution Signal Decomposition: The Wavelet Representation*. In: *PAMI*, Vol. 11, No. 7, S. 674-693.
- MAYER, H. (1994): *Automatische wissensbasierte Extraktion von semantischer Information aus gescannten Karten*. DGK Reihe C, Heft Nr. 417, Verlag der Bayerischen Akademie der Wissenschaften, München.
- MAYER, H. (1998): *Automatische Objektextraktion aus digitalen Luftbildern*. DGK Reihe C, Heft Nr. 494, Verlag der Bayerischen Akademie der Wissenschaften, München.
- MAYER, H. (1999): *Automatic Object Extraction from Aerial Imagery – A Survey Focusing on Buildings*. In: *Computer Vision and Image Understanding*, Vol. 74, No. 2, S. 138-149.
- MAYER, H. (2004): *Object Extraction for Digital Photogrammetric Workstations*. In: *IAPRSSIS*, Vol. XXXV, Part B2, S. 414-422.

- MEINEL, G., NEUBERT, M. (2004): *A Comparison of Segmentation Programs for High Resolution Remote Sensing Data*. In: IAPRSSIS, Vol. XXXV, Part B4, S. 1097-1102.
- MEINEL, G., NEUBERT, M., REDER, J. (2001): *Pixelorientierte versus segmentorientierte Klassifikation von IKONOS-Satellitenbilddaten – ein Methodenvergleich*. In: PFG, Nr. 3, S. 157-170.
- MEYER-GRUHL, U. (1993): *Bildsegmentierung und Merkmalsextraktion*. In: B. Radig (Hrsg.): *Verarbeiten und Verstehen von Bildern*, R. Oldenbourg Verlag München, S. 165-184.
- MITRI, G. H., GITAS, I. Z. (2002): *The Development of an Object-Oriented Classification Model for Operational Burned Area mapping on the Mediterranean Island of Thasos Using Landsat TM Images*. In: Viegas, D.X. (Hrsg.): *Forest Fire Research & Wildland Fire Safety*, Millpress, Rotterdam, S. 79 (Abstract), Paper auf CD.
- NIEDERÖST, M. (2000): *Reliable reconstruction of buildings for digital map revision*. In: IAPRS, Vol. XXXIII, Part B3, S. 635-642.
- NIEDERÖST, M. (2003): *Detection and Reconstruction of Buildings for Automated Map Updating*. Dissertation, Institut für Geodäsie und Photogrammetrie, Eidgenössische Technische Hochschule Zürich, IGP Mitteilung Nr. 78.
- NIEMANN, H., SAGERER, G., SCHRÖDER, S., KUMMERT, F. (1990): *ERNEST: A Semantic Network System for Pattern Understanding*. In: PAMI, Vol. 12, No. 9, S. 883-905.
- OHLHOF, T., EMGE, T., REINHARDT, W., LEUKERT, K., HEIPKE, C., PAKZAD, K. (2000): *Generation and Update of VMap Data Using Satellite and Airborne Imagery*. In: IAPRS, Vol. XXXIII, Part B4, S. 762-768.
- PAKZAD, K. (2001): *Wissensbasierte Interpretation von Vegetationsflächen aus multitemporalen Fernerkundungsdaten*. DGK Reihe C, Heft Nr. 543, Verlag der Bayerischen Akademie der Wissenschaften, München.
- PAL, N. R., PAL, S. K. (1993): *A Review on Image Segmentation Techniques*. In: *Pattern Recognition*, Vol. 26, No. 9, S. 1277-1294.
- PINZ, A. (1994): *Bildverstehen*. Springer Verlag Wien.
- PRATT, P. (1991): *Digital Image Processing*. Wiley New York.
- PRICE, J. C. (1997): *Spectral Band Selection for Visible-Near Infrared Remote Sensing: Spectral-Spatial Resolution Tradeoffs*. In: *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 35, No. 5, S. 1277-1285.
- QUINT, F. (1997): *Kartengestützte Interpretation monokularer Luftbilder*. DGK Reihe C, Heft Nr. 477, Verlag der Bayerischen Akademie der Wissenschaften, München.

- RHEIN, U. (1999): *An Automated Approach for Training Data Selection Within an Integrated GIS and Remote Sensing Environment for Monitoring Temporal Changes*. In: IAPRS, Vol. XXXII, Part 7-4-3 W6, S. 154-159.
- ROSENFELD, A. (1982): *Computer Image Analysis: An Emerging Technology in the Service of Society*. Computer Science Technical Reports TR-1177, MCS-79-23422, University of Maryland.
- SCHERER, D., MEININGER, M. (2002): *Segmentbasierte Klassifikation von Rasterdaten unter Verwendung pixelbasierter Klassifikatoren*. In: Strobl, J., Blaschke, T., Griesebner, G. (Hrsg.): AGIT XIV, Wichmann Verlag Heidelberg, S. 475-484.
- SCHNEIDER, W. (1999): *Land Cover Mapping from Optical Satellite Images Employing Subpixel Segmentation and Radiometric Calibration*. In: Kanellopoulos, I., Wilkinson, G.G., Moons, T. (eds.): *Machine Vision and Advanced Image Processing in Remote Sensing*. Springer Verlag, Berlin, S. 229-237.
- SCHOUTEN, T. E., GEBBINCK, M. S. KLEIN (1995): *Quality Measures for Image Segmentation Using Generated Images*. In: Desachy, J. (Hrsg.): *Image and Signal Processing for Remote Sensing II*, Proceedings SPIE 2579, S. 411-422.
- SHACKELFORD, A. K., DAVIS, C. H. (2003): *A Combined Fuzzy Pixel-Based and Object-Based Approach for Classification of High-Resolution Multispectral Data over Urban Areas*. In: IEEE Transactions on Geoscience and Remote Sensing, Vol. 41, No. 10, S. 2354-2363.
- SINDHUBER, A. (1998): *Ergänzung und Fortführung eines digitalen Landschaftsmodelles mit multispektralen und hochauflösenden Fernerkundungsaufnahmen*. Geowissenschaftliche Mitteilungen der Studienrichtung Vermessungswesen, Heft 48, Technische Universität Wien.
- SONG, C., WOODCOCK, C., SETO, K., LENNEY, M., MACOMBER, S. (2001): *Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects?* In: *Remote Sensing of Environment*, Nr. 75, S. 230-244.
- STEHMAN, S. (1997): *Selecting and Interpreting Measures of Thematic Classification Accuracy*. In: *Remote Sensing of Environment*, Nr. 62, S. 77-89.
- STEINBRECHER, R. (1993): *Bildverarbeitung in der Praxis*. R. Oldenbourg Verlag München.
- STEINNOCHER, K. (1997): *Texturanalyse zur Detektion von Siedlungsgebieten in hochauflösenden panchromatischen Satellitenbilddaten*. In: Dollinger, F., Strobl, J. (Hrsg.): AGIT IX, Salzburger Geographische Materialien, Heft 26, Selbstverlag des Instituts für Geographie der Universität Salzburg, S. 143-152.
- TIEDE, D., BURNETT, CH., HEURICH, M. (2004): *Objekt-basierte Analyse von Laserscanner- und Multispektraldaten zur Einzelbaumdelineierung im Nationalpark Bayerischer Wald*. In: Strobl, J., Blaschke, T., Griesebner, G. (Hrsg.): AGIT XVI, Wichmann Verlag Heidelberg, S. 690-695.

- TÖNJES, R. (1996): *Knowledge Based Modelling of Landscapes*. In: IAPRS, Vol. XXXI, Part B3, S. 868-873.
- TÖNJES, R. (1999): *Wissensbasierte Interpretation und 3D-Rekonstruktion von Landschaftsszenen aus Luftbildern*. Fortschritt-Berichte VDI, Reihe 10, Nr. 575, VDI Verlag Düsseldorf.
- TORRE, M., RADEVA, P. (2000): *Agricultural Field Extraction from Aerial Images Using a Region Competition Algorithm*. In: IAPRS, Vol. XXXIII, Part B3, S. 889-896.
- VINCENT, L., SOILLE, P. (1991): *Watersheds in Digital Spaces: An Efficient Algorithm Based on Immersion Simulations*. In: PAMI, Vol. 13, No. 6, S. 583-598.
- VMAP (1997): *VMap Level 1 FACS/FACC Extraction Guide*. NIMA (jetzt NGA), www.nga.mil (30.05.2005)
- WALTER, V. (1998): *Automatic Classification of Remote Sensing Data for GIS Database Revision*. In: IAPRS, Vol. XXXII, Part 4, S. 641-648.
- WIEDEMANN, CH. (2001): *Extraktion von Straßennetzen aus optischen Satellitenbilddaten*. DGK Reihe C, Heft Nr. 551, Verlag der Bayerischen Akademie der Wissenschaften, München.
- YANG, L., ALBREGTSEN, F., LØNNESTAD, T., GRØTTUM, P. (1995): *A Supervised Approach to the Evaluation of Image Segmentation Methods*. In: Proceedings CAIP 1995, Lecture Notes in Computer Science, Vol. 970, Springer Verlag Berlin, S. 759-765.
- ZADEH, L. A. (1965): *Fuzzy Sets*. In: Information and Control. Vol. 8, S. 338-353.
- ZHAN, Q., MOLENAAR, M., TEMPFLI, K. (2003): *Uncertainty Assessment for Geo-Spatial Objects Derived from High-Resolution Airborne Imagery and Laser Data*. In: Shi, W., Goodchild, M., Fisher, P. (eds.): Proceedings of the 2nd International Symposium on Spatial Data Quality 2003, S. 79-88.
- ZHANG, Y. J. (1996): *A Survey on Evaluation Methods for Image Segmentation*. In: Pattern Recognition, Vol. 29, No. 8, S. 1335-1346.

Lebenslauf

	Kristin Leukert geboren am 2. Oktober 1971 in Urach (Württ.)
1977 - 1981	Grundschule in Bad Urach
1981 - 1990	Graf-Eberhard-Gymnasium in Bad Urach
1990 - 1996	Studium der Geodäsie an der Universität Karlsruhe (Technische Hochschule) Abschluss: Diplom Vermessungsingenieur
Juni - September 1996	GIS Consultant bei Geomatics International in Lahr
Oktober 1996 - September 1997	Vorbereitungsdienst für den höheren vermessungstechnischen Verwaltungsdienst in Baden-Württemberg
seit Oktober 1997	Wissenschaftliche Mitarbeiterin in der Arbeitsgemeinschaft Geoinformationssysteme (AGIS) an der Universität der Bundeswehr München

Dank

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftliche Mitarbeiterin in der AGIS an der Universität der Bundeswehr München.

Meinen beiden Berichterstattem Herrn Prof. Dr.-Ing. W. Reinhardt und Prof. Dr.-Ing. H. Mayer möchte ich für die gute Unterstützung danken. Zahlreiche fruchtbare Diskussionen und Anregungen haben wesentlich zum Gelingen der Arbeit beigetragen. Dem Vorsitzenden des Promotionsverfahrens, Herrn Prof. Dr.-Ing. W. Caspary, danke ich ebenfalls für die angenehme Zusammenarbeit in der AGIS.

Mein Dank geht auch an das Amt für Geoinformationswesen der Bundeswehr (AGeoBw), welches das Projekt „Verfahrensentwicklung zur automatisierten Objektextraktion aus hochauflösenden multispektralen Satellitenaufnahmen“ gefördert hat. Im Rahmen dieses Projektes konnten die praktischen Experimente mit den zur Verfügung gestellten Satellitenbilddaten durchgeführt werden. Die Ergebnisse des Projektes machen einen wesentlichen Teil der Dissertation aus.

Besonderer Dank geht an alle Korrekturleser und Kollegen, die mich unterstützt haben. Ich möchte allen meinen Kollegen in der AGIS und aus dem benachbarten Institut für Photogrammetrie für die angenehme Arbeitsatmosphäre und die gute Zusammenarbeit danken.

Zu guter Letzt möchte ich mich bei meiner Familie und bei allen Freunden für die Unterstützung und Ermutigungen bedanken, die zur Fertigstellung meiner Dissertation beitrugen.