

Automatisierte Klassifikation von Landnutzung durch Objekterkennung am Beispiel von CORINE Land Cover

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

vorgelegt von
Thilo Wehrmann
Dipl.-Geogr.

Würzburg, im Dezember 2006

Automatisierte Klassifikation von Landnutzung durch Objekterkennung am Beispiel von CORINE Land Cover

Eingereicht am: 15. Dezember 2006

Erstgutachter: Prof. Dr. Stefan Dech

Zweitgutachter: Prof. Dr. Christiane Schmullius

Erstprüfer: Prof. Dr. Stefan Dech

Zweitprüfer: Prof. Dr. Jürgen Rauh

Tag der Disputation: 11.7.2007

Doktururkunde ausgehändigt am: noch nicht bekannt

Danksagung

ZUM Gelingen und zur Durchführung dieser Arbeit haben viele Menschen beitragen. An erster Stelle möchte ich mich jedoch bei meinem Doktorvater Prof. Stefan Dech bedanken. Ohne ihn wäre die vorliegende Arbeit in dieser Form nicht möglich gewesen. Durch den Aufbau des Lehrstuhls in Würzburg wurden die Voraussetzungen für mich und meine Kollegen geschaffen, an unseren Themen mit allen Freiheiten und dem vollen Rückhalt zu arbeiten. Für die Übernahme des Zweitgutachtens und den vielen fruchtbaren Diskussionen zum Thema und darüber hinaus danke ich Prof. Rüdiger Glaser.

Diese Arbeit entstand größtenteils am Lehrstuhl für Fernerkundung in Würzburg am Geographischen Institut der Universität Würzburg. Beendet wurde diese Arbeit jedoch in der Abteilung Umwelt und Sicherheit (US) am Deutschen Fernerkundungsdatenzentrum (DFD) des Deutschen Zentrums für Luft- und Raumfahrt e.V. (DLR) unter der Leitung von Dr. Harald Mehl in Oberpfaffenhofen. Ihm und meinem Mentor für diese Arbeit, Dr. Günter Strunz gebührt der Dank für die Bereitstellung von Ressourcen und den fachlichen Beistand, um die Arbeit in dieser Form beenden zu können.

Der Dank gilt darüber hinaus meinen Kollegen in Würzburg und Oberpfaffenhofen für die angenehme Arbeitsatmosphäre und die zahlreichen fachlichen und privaten Diskussionen. Besonders möchte ich die hervorragende Zusammenarbeit mit Christopher Conrad und Martin Bachmann herausheben, die mit mir am Anfang gefochten haben, den Lehrstuhl aufzubauen. Ferner seien Erik Borg, Uta Heiden, René Colditz, Gunther Schorcht und Christoph Schultz für die unermüdliche Diskussionsbereitschaft und ihre Hilfe rund um diese Arbeit und den Ideen und Theorien dahinter gedankt.

Zum Schluss möchte ich mich bei meinen Eltern und natürlich meiner Gefährtin Anne-Marie Veith für ihren Rückhalt und Unterstützung danken.

Inhaltsverzeichnis

Danksagung	v
Abbildungsverzeichnis	ix
Tabellenverzeichnis	xi
Abkürzungsverzeichnis	xiii
Summary	xv
Zusammenfassung	xvii
1 Einleitung und Problemstellung	1
1.1 Problemstellung	2
1.2 Ziele	3
2 Grundlagen	5
2.1 Über die Unterschiede zwischen Landbedeckung und Landnutzung	6
2.2 CORINE Land Cover	7
2.2.1 Aufbau von CORINE Land Cover	9
2.2.2 Komponenten von CORINE Land Cover	11
2.2.3 Aktualisierung von CORINE Land Cover	12
2.3 Allgemeine Techniken zur Klassifikation von Landbedeckung	15
2.4 Grundlage der objektorientierten Klassifikation	26
2.4.1 Bildwahrnehmung und Fernerkundung	28
2.4.2 Objekterkennung	35
3 Entwickelte Methodik	47
3.1 Der Klassifikationsrahmen	49
3.2 Der Aufbau des Klassifikationsprozesses	56
3.3 Entwickelte Merkmale zur Identifikation von CLC Klassen	58
3.3.1 Diskrete spektrale Merkmale	59
3.3.2 Kontinuierliche spektrale Merkmale	65
3.3.3 Formmerkmale	72
3.3.4 Merkmale durch räumlichen Kontexteinbezug	74
3.3.5 Zeitliche Merkmale	76
3.4 Klassenmodellierung	85
3.4.1 Klassenkatalog für CLC 1xx – Bebaute Flächen	86
3.4.2 Klassenkatalog für CLC 2xx – Landwirtschaftliche Flächen	87
3.4.3 Klassenkatalog für CLC 3xx – Wälder und naturnahe Flächen	88
3.4.4 Klassenkatalog für CLC 4xx – Feuchtflächen	89
3.4.5 Klassenkatalog für CLC 5xx – Wasserflächen	90

3.4.6	Zusammenfassung	90
3.5	Technische Aspekte der Implementierung	93
3.5.1	Systemaufbau und Umsetzung	93
3.5.2	Datenkonzept	96
4	Ergebnisse und Diskussion	101
4.1	Validierung	101
4.2	Projektgebiete	102
4.3	Klassifikationsgüte	109
4.4	Einflussfaktoren auf Klassifikationsgüte	111
4.4.1	Fehlerbehaftete Repräsentation	111
4.4.2	Systematische Fehler	114
4.5	Zusammenfassung	116
5	Schlussfolgerung	121
5.1	Zukünftige Perspektiven	124
5.2	Abschließende Bemerkungen	126
	Literaturverzeichnis	127
A	Abbildungen	143
B	Technische Strukturen	147
B.1	gnosis	147
C	Tabellen	151
C.1	Datenspezifischer Teil	151

Abbildungsverzeichnis

2.1	Ausschnitt des CORINE Land Cover Datensatzes	8
2.2	Geometrische Erklärung für die lineare Klassifikation for SVM	18
2.3	Reflexionscharakteristik für bestimmte Klassen der Landbedeckung und Landnutzung	22
2.4	Mischpixelproblematik bei Fernerkundungssystemen	23
2.5	Schematische Darstellung des ROC Modells	30
2.6	Vergleich zwischen dem <i>Pandemonium</i> -Modell und dem COP-Modell	33
2.7	CORINE Objektrepräsentation durch Substrukturen	38
2.8	Unterschiedliche Repräsentationen des Objektes <i>Frankfurter Flughafen</i>	40
3.1	Schematischer Aufbau der CLC Klassifikation	50
3.2	Beispiel für einfache und komplexe CLC Klassen	52
3.3	Beispiel für die Funktionsweise des Gewichtungssystems	54
3.4	UML Schema des Datenmodells	56
3.5	Gegenüberstellung vom Bottom-Up Prinzip und Top-Down Prinzip	59
3.6	Aufbereitete Trainingsgebiete für den Stützvektorklassifikator	61
3.7	Anwendung von unscharfen Merkmalen	67
3.8	Fuzzy-Inferenzfunktion zur Bestimmung des Wasseranteils im Pixel	68
3.9	Fuzzy-Inferenzfunktion zur Bestimmung des Vegetationsanteils im Pixel	68
3.10	Fuzzy-Inferenzfunktion zur Bestimmung des Wasseranteils im Pixel	69
3.12	Fehlerbild des modellierten Versiegelungsgrades	70
3.11	Bestimmung des Versiegelungsgrades	71
3.13	Extraktion der internen Winkel	72
3.14	Kostenfunktion zur Ermittlung des Winkels	73
3.15	Formenschatz der Bildsegmente in der Landwirtschaft	74
3.16	Nachbarschaften und ihre Repräsentation durch Graphen	75
3.17	Erweiterte Nachbarschaft	77
3.18	Beispiel für die intra- und interannuelle Phänologie von zwei Landbedeckungen	77
3.19	Beispiel für harmonische Sinus-Schwingen	78
3.20	Der phänologischen Jahresgang von Ackerflächen im Verlauf von vier Jahren und die harmonischen Komponenten	79
3.21	Differenzierung der CLC Klassen durch temporale Merkmale	80
3.22	Klassifikation auf Basis der temporalen Variabilität	82
3.23	Beispiel für die Ableitung von Ackerflächen durch den Parameter <i>temporale Variabilität</i> in der Region Magdeburg	83
3.24	Klassifikation auf Basis der temporalen Intensität	83
3.25	Detailausschnitt für die CLC Klasse 231 zwischen Augsburg und München	84
3.26	Einfluss der anthropogenen Nutzung führt zur Änderung der Landnutzung	87
3.27	Phänologischer Verlauf von Ackerland und Weideland	88

3.28	Aufbau des abstrahierten Datenmodells	94
3.29	Beispiel für die relationale Repräsentation der Daten im Projekt	96
4.1	Untersuchungsgebiete für das gnosis Rahmenwerk	102
4.2	Ausschnitt des Testgebietes Rhein-Main-Gebiet	103
4.3	Ausschnitt des Testgebietes Berlin	106
4.4	Ausschnitt des Testgebietes Berlin	110
4.5	Beispiel für die geometrische Repräsentation	113
4.6	Beispiel für den Versiegelungsgrad	115
4.7	Beispiel für einige Geometrie Probleme bei CLC Objekten	116
5.1	Ausblick für den Einsatz von gnosisNET	125
A.1	Falsch klassifizierte CLC Objekte für das Gebiet Frankfurt	144
A.2	Nicht prozessierte CLC Objekte für das Gebiet Frankfurt	145
A.3	Legende für CORINE LC	146

Tabellenverzeichnis

2.1	CORINE Landcover Klassennomenklatur	9
2.2	Unterschiede zwischen CLC 1990, CLC 2000 und einer potentiellen Aktualisierung CLC 2006	13
2.3	Bodenbedeckungsklassen der LCMGB	14
2.4	Zusammenstellung der unterschiedlichen computerbasierten Klassifikationsverfahren	16
2.5	Physikalische Annahmen in der Bildwahrnehmung nach MARR	28
2.6	Basisphänomene der Objekterkennung nach BIEDERMAN	30
2.7	Eigene Erweiterungen der physikalischen Annahmen zur Klassifikation von CORINE Land Cover	35
2.8	Informationsebenen in Bildern	38
3.1	Grundannahmen der Objektrepräsentation	53
3.2	Implementierte Verarbeitungsschritte in gnosis; nicht implementierte Schritte sind <i>kursiv</i> geschrieben	56
3.3	Zeitlicher Aufbau der Trainingsdatenbank	62
3.4	Wahrheitsmatrix (<i>Confusion matrix</i>) nach Kreuzvalidation (10-fach gefaltet) für die verwendete Steuerdatei	63
3.5	CLC Klassenanalyse durch SVM Klassifikation im Testgebiet <i>Rhein-Main Gebiet</i>	65
3.6	CLC Klassen, die durch Nachbarschaften definiert werden	75
3.7	CLC Klassen, die durch ihre Struktur definiert sind	76
3.8	CLC Klassen mit temporalen Eigenschaften	81
3.9	Verwendete Parameter für die <i>z-Standardisierung</i> der einzelnen Jahre	84
3.10	Gruppierung der fünfzehn flächenhaft dominanten CORINE LC Klassen nach einfacher und komplexer Zusammensetzung	85
3.11	Klassenkatalog für CORINE LC Klassen	91
4.1	Ergebnis der geometrischen Repräsentation im Rhein-Main Gebiet	104
4.2	Ergebnis der semantischen Repräsentation im Rhein-Main Gebiet	105
4.3	Ergebnis der geometrischen Repräsentation für den Großraum Berlin	107
4.4	Ergebnis der semantischen Repräsentation für den Großraum Berlin	108
4.5	Ergebnis der geometrischen Repräsentation für den Raum Oldenburg	108
4.6	Ergebnis der semantischen Repräsentation für den Großraum Berlin	109
4.7	Grad der Automatisierung von CLC Klassen	118
C.1	Verteilung der Trainingsgebiete für die überwachte Klassifikation	152
C.2	Verwendete Gewichtungen zur Bestimmung der CLC Klassen	153
C.3	Verteilung der CORINE Land Cover Klassen für das Staatsgebiet der Bundesrepublik Deutschland	154
C.4	Wahrheitsmatrize für die verwendeten Trainingsgebiete	155

C.5 Fehlermatrize für den Untersuchungsraum <i>Frankfurt am Main</i>	156
C.6 Fehlermatrize für den Untersuchungsraum <i>Berlin</i>	157
C.7 Fehlermatrize für den Untersuchungsraum <i>Oldenburg</i>	158
C.8 Zusammenfassung des CLC Datensatzes auf Objektebene	159

Abkürzungsverzeichnis

Abkürzung	Bedeutung
Abb	Abbildung
AVHRR	Advanced Very High Resolution Radiometer
CORINE	Coordination of information on the environment
CLC	CORINE Land Cover
DFD	Deutsches Datenfernerkundungszentrum
DLR	Deutsches Zentrum für Luft- und Raumfahrt e.V.
EEA	European Environment Agency
ESA	European Space Agency
ETM+	Enhanced Thematic Mapper plus
FAO	Food and Agriculture Organization
FE	Fernerkundung
GIS	Geographisches Informationssystem
GLC2000	Global Land Cover 2000
GLCC	Global Land Cover Characterization
GMES	Global Monitoring for Environment and Security
IGBP	International Geosphere-Biosphere Programme
IRS	Indian Remote Sensing Satellite
ISODATA	Iterative Self-Organizing Data Analysis Technique
JRC	Joint Research Centre in Ispra / Italien
LC	Land Cover
LU	Land Use
LUCAS	Land Use/Cover Area Frane Statistical Survey
MERIS	Medium Resolution Imaging Spectrometer Instrument
MODIS	Moderate Resolution Imaging Spectroradiometer
NASA	National Aeronautics and Space Administration
NDVI	Normalisierter differenzierter Vegetationsindex (Merkmal)
NOAA	National Oceanic and Atmospheric Administration

continued on next page

Abkürzung (cont.)	Bedeutung (cont.)
PAN	Panchromatischer Kanal (520 nm – 900 nm)
RGB	Farbraum mit den Grundfarben Rot, Grün und Blau
ROC	<i>Recognition-by-Components</i>
NIR	Nahinfrarot (760 nm – 900 nm)
UNL	University of Nebraska-Lincoln
R	Rot Kanal (630 nm – 690 nm)
SPOT	System Probatoire d'Observation de la Terre
SRTM	Shuttle Radar Topography Mission
SWIR	<i>short wave infrared</i>
TIR	Thermales Infrarot (10,4 μm – 12,5 μm)
USGS	Unites States Geological Survey

Summary

LAND COVER and land use classifications provide significant information for politics, economy and science. CORINE Land Cover (CLC) represents a harmonised Pan-European land cover dataset utilised by many European and national institutions. The mapping product comprising 44 classes of land cover and land use, is well documented. At the same time it is periodically updated in intervals of 10 years. Mainly due to the complexity of the CORINE nomenclature, generating and updating of this product has ever since been solely based on computer-aided manual image interpretation. To this date, manual interpretation being the backbone of CORINE actualisation has not been replaced by computer aided approaches.

As a consequence, this study aims at developing a semi-automated methodology to derive CORINE Land Cover from optical remotely sensed data. The methodology presented, is based upon the former **CLC 1990** classification and the Landsat ETM+ based **Image 2000** while reference and validation is realised utilising the **CLC 2000** data set. Implementation of the presented approach is realised by the software package *gnosis* combining object oriented classification paradigms with theories related to human image perception.

Human image perception itself is known to be a process of information engineering including three sub-processes as follows: *image segmentation*, *feature generation*, and *class assignment*. With regard to image segmentation, meaningful image segments are generated based upon the most simple image primitives, the pixels. Resulting image segments consist of a wide range of invariant image features describing actual CLC classes. However, precise knowledge about land cover is the uttermost important information for any further processing steps presented in this work. Therefore, ten baseline land cover classes are extracted from multi spectral **image 2000** data sets using a novel supervised classification approach of support vector machines. In order to estimate the anthropogenic impact affecting some CORINE classes, the phenological characteristics are analysed and processed. Thus temporal parameters like *temporal variability* and *temporal intensity* are used for the delineation of *pastures* and *arable land*. Conjointly with these vegetation features, neighbourhood analysis is used to derive functionality or heterogeneity of complex classes. At last, additional error reduction and further specification is addressed by the extraction of fuzzy features.

Based on these features sets, CLC classes are represented abstractly stored within a class catalogue i.e. an *a-priori* knowledge base. Class assignment itself is based on the representation of CORINE objects by its integral parts. In the following this sub-process, representing the final step of image perception, is used to compare the extracted structures with the prototypical classes of the knowledge base. On one hand homogeneous classes, consisting

of a single land cover type of baseline classes like forests and pastures, are identified with a *bottom-up* approach. This is based on the assumption that any superior CLC object is composed of and therefore directly linked to its components and consecutively assigned to a specific CLC class. On the other hand heterogeneous classes, consisting of multiple cover types like complex cultivation patterns, can be validated by comparing its components to the knowledge base, i.e. a *top-down* approach. However, the *a-priori* geometry provided by a former classification is essential for this type of object recognition. The analysis of test sites located in the vicinities of Frankfurt, Berlin, and Oldenburg indicates that 13 CLC classes can be identified automatically while a second set of 14 CLC classes can be validated. On the contrary, ten classes can not be acquired by the presented approach due to the lack of required features or missing ancillary information. Thus the overall accuracy of the automated classification of the test sites ranges between 70 % and 80 %. In addition it increases to more than 90 % as observation is limited to classes with intrinsic prototypical description and distinct features like settlement, forest, and water.

As a result of this thesis the software package gnosis will provide a fundamental service and support for the forthcoming CORINE update. By means of the software, 13 identifiable classes can be processed automatically based on the *bottom-up* approach. In regards to the set of 14 CLC classes derived from the *top-down* approach, distinct class definition will rely on the trained interpreters selecting from a given set of potential classes. This decision making process can also be facilitated by existing feature sets describing temporal characteristics and impervious cover fraction. As a consequence both automated and semi-automated processes presented in this thesis can be considered a good advancement of the existing compilation and updating procedures of the CORINE land cover project.

Zusammenfassung

INFORMATIONEN über die *Landbedeckung* und die mit der anthropogenen Komponente verbundenen *Landnutzung* sind elementare Bestandteile für viele Bereiche der Politik, Wirtschaft und Wissenschaft. Darunter fallen beispielsweise die Strukturentwicklungsprogramme der EU, die Schadensregulierung im Versicherungswesen und die Modellierung von Stoffkreisläufen. *CORINE Land Cover (CLC)* wurde infolge eines erweiterten Bedarfs an einem europaweit harmonisierten Datensatz der Landoberfläche erstellt. Das CORINE Projekt weist für diese Arbeit eine hohe Relevanz durch die regelmäßigen Aktualisierungen von 10 Jahren, dem Einsatz der Daten in vielen europäischen und nationalen Institutionen und der guten Dokumentation der CORINE Nomenklatur auf. Die Erstellung der Daten basiert auf der computergestützten manuellen Interpretation, da automatische Verfahren durch die Komplexität der Aufgabenstellung und Thematik nicht in der Lage waren, den menschlichen Interpreten zu ersetzen.

In dieser Arbeit wird eine Methodik vorgestellt, um CORINE Land Cover aus optischen Fernerkundungsdaten für eine kommende Aktualisierung abzuleiten. Hierzu dienen die Daten von **CLC 1990** und der Fernerkundungsdatensatz *Image 2000* als Grundlage, sowie die **CLC 2000** Klassifikation als Referenz. Die entwickelte und in dem Softwarepaket *gnosis* implementierte Methodik wendet die objektorientierte Klassifikation in Kombination mit Theorien aus der menschlichen Bildwahrnehmung an. In diesen Theorien wird die Bildwahrnehmung als informationstechnischer Prozess gesehen, der den Klassifikationsprozess in die drei folgenden Subprozesse unterteilt: *Bildsegmentierung*, *Merkmalsgenerierung* und *Klassenzuweisung*. Die Bildsegmentierung generiert aus den untersten Bildprimitiven (Pixeln) bedeutungsvolle Bildsegmente. Diesen Bildsegmenten wird eine Anzahl von bildinvarianten Merkmalen aus den Fernerkundungsdaten für die Bestimmung der CLC Klasse zugewiesen. Dabei liegt die wichtigste Information in der Ableitung der Landbedeckung durch den überwachten *Stützvektor-Klassifikator*. Die Landoberfläche wird hierzu in zehn Basisklassen untergliedert, um weiteren Merkmalen einen semantischen Unterbau zu geben. Zur Bestimmung der anthropogenen Komponente von ausgewählten Landnutzungsklassen, wie beispielsweise Ackerland und Grünland, wird der phänologische Verlauf der Vegetation durch die Parameter *temporale Variabilität* und *temporale Intensität* beschrieben. Neben dem jahreszeitlichen Verlauf der Vegetation können Nachbarschaftsbeziehungen untersucht werden, um weitere anthropogene Klassen und heterogen aufgebaute Sammelklassen beschreiben zu können. Der Versiegelungsgrad als Beispiel für eine Reihe von unscharfen Merkmalen dient der weiteren Differenzierung der verschiedenen Siedlungsklassen aus CORINE LC.

Mit Hilfe dieser Merkmale werden die CLC Klassen in abstrakter Form im *Klassenkatalog (a-priori Wissensbasis)* als Protoklassen beschrieben. Die eigentliche Objekterkennung basiert auf der Repräsentation der CORINE Objekte durch ihre einzelnen Bestandteile und

vergleicht die gefundenen Strukturen mit der Wissensbasis. Semantisch homogen aufgebaute Klassen, wie *Wälder* und *Siedlungen* oder Protoklassen mit eindeutigen Merkmalen, beispielsweise zur Bestimmung von *Grünland* durch die Phänologie, können durch den *bottom-up* Ansatz *identifiziert* werden. Das übergeordnete CLC Objekt kann direkt aus den Bestandteilen zusammengebaut und einer Klasse zugewiesen werden. Semantisch heterogene Klassen, wie zum Beispiel bestimmte Sammelklassen (*Komplexe Parzellenstruktur*), können durch ihre Bestandteile *validiert* werden, indem die Bestandteile eines existierenden CLC Objektes mit der Wissensbasis auf Konsistenz untersucht werden (*top-down* Ansatz). Eine *a-priori* Datengrundlage ist für die Erkennung dieser Klassen essentiell. Die Untersuchung der drei Testgebiete (Frankfurt, Berlin, Oldenburg) zeigte, dass von der CORINE LC Nomenklatur 13 Klassen identifiziert und weiteren 14 Klassen validiert werden können. Zehn Klassen können durch diese Methodik aufgrund fehlender Merkmale oder Zusatzdaten nicht klassifiziert werden. Die Gesamtgenauigkeit der automatisierten Klassifikation für die Testgebiete beträgt zwischen 70 % und 80 % für die umgesetzten Klassen. Betrachtet man davon einzelne Klassen, wie Siedlungs-, Wald- oder Wasserklassen, wird aufgrund der verwendeten Merkmale eine Klassifikationsgenauigkeit von über 90 % erreicht.

Ein möglicher Einsatz der entwickelten Software *gnosis* liegt in der Unterstützung einer kommenden CORINE Aktualisierung durch die Prozessierung der identifizierbaren Klassen. Diese CLC Klassen müssen vom Interpreten nicht mehr überprüft werden. Für bestimmte CLC Klassen aus dem *Top-down* Ansatz wird der Interpret die letzte Entscheidung aus einer Auswahl von Klassen treffen müssen. Weiterhin können die berechneten Merkmale, wie die temporalen Eigenschaften und der Versiegelungsgrad dem Bearbeiter als Entscheidungsgrundlage zur Verfügung gestellt werden. Der Einsatz dieser neu entwickelten Methode führt zu einer Optimierung des bestehenden Aufnahmeverfahrens durch die Integration von semi-automatisierten Prozessen.

1

Einleitung und Problemstellung

DER ehemalige US-amerikanische Vizepräsident AL GORE hat in seiner berühmten Rede *The Digital Earth – Understanding our planet in the 21st Century* schon 1998 darauf hingewiesen, dass die größte Herausforderung des Geo-Informationszeitalters in der Aufbereitung und Nutzung von räumlichen Daten liegt (GORE, 1998). In den letzten Jahrzehnten sind zahlreiche nationale und globale Datenbanken in den Forschungsinstituten aufgebaut und erweitert worden. Viele dieser Datensätze waren von außen nicht erreichbar bzw. für den Interessierten nicht einsetzbar wegen mangelnder Transparenz und benutzerunfreundlichen Datenformaten. Um diese Herausforderung anzunehmen, wurde die *National Digital Earth Initiative* gegründet. Das Ziel war deshalb die Verknüpfung von bestehenden Datenquellen mit georeferenzierten Informationen und deren Öffnung für die Öffentlichkeit. Noch im gleichen Jahr gründete die Europäische Kommission zusammen mit der Europäischen Weltraumbehörde (ESA) die Initiative *Global Monitoring for Environment and Security – GMES* (BRE-

GER *et al.*, 2005). Diese sollte zum einen Daten aus der Erdbeobachtung sammeln und bestmöglich nutzen und zum anderen der Öffentlichkeit zur Verfügung stellen. Dazu sollten Datenverteilungssysteme oder *Service-Elemente* entwickelt und Dienstleistungen für Behörden, humanitäre Organisationen sowie Privatunternehmen aufgebaut werden. Nach einer umfangreichen Vorbereitungsphase (2002–2008) soll GMES anschließend starten.

Komplementär zu diesen programmatischen Initiativen lieferten auf der einen Seite in den letzten Jahren bestehende und neue Sensoren ein umfassenderes Bild der Erde. Beispiele dafür sind das Landsat-Programm zur Kartierung von natürlichen Ressourcen (seit 1972), die SRTM-Space Shuttle Mission (Erstellung einer hochaufgelösten Topographie) und globale „Umwelt“-Plattformen der amerikanischen und europäischen Weltraumagenturen, wie Aqua, Terra und Envisat. Auf der anderen Seite war der Bedarf an diesen Informationen durch globale Herausforderungen, wie der Klimawandel, der Schutz der Artenvielfalt, Umweltkatastrophen und der Gefahr durch den Terrorismus noch nie so hoch wie heute. Dennoch werden nicht alle bereitgestellten Daten thematisch ausgewertet, um die gestellten Fragen zu beantworten, da der Aufwand, Rohdaten in thematische Informationen umzuwandeln, immer noch sehr hoch ist.

Es existieren eine Reihe von automatischen Verfahren zur Weiterverarbeitung dieser Datensätze (Umrechnung in physikalische Größen, Bildung von Indizes und Diskretisierung der Landoberfläche in Landbede-

ckungsklassen). Viele dieser Verfahren basieren auf Datensätze mit einer räumlichen Auflösung von 0.5 km bis 5 km pro Aufnahmeeinheit (Maßstab von 1:1 000.000 und größer). Diese Methoden können für höher aufgelöste Daten aufgrund der zunehmenden Komplexität der Prozesse in der Atmosphäre bzw. auf der Landoberfläche nicht eingesetzt werden. Es ist absehbar, dass in naher Zukunft die Datenmenge — und damit das Potential an Informationen — durch geplante Programme weiter zunehmen wird (SCHREIER UND DECH, 2005). Kommende Missionen, wie beispielsweise *Rapideye* mit 5 m räumlicher Auflösung sorgen dafür, dass neue Methoden entwickelt werden müssen, um hochaufgelösten multispektrale Fernerkundungsdaten möglichst automatisiert auszuwerten, um daraus zeitgleich Produkte generieren zu können. Das Programm soll 2007 starten.

Zusätzlich werden globale Fernerkundungsdatensätze, die um Systeme wie Landsat, Terra oder Envisat aufgebaut wurden, der Öffentlichkeit frei zur Verfügung gestellt. Diese Datensätze können im großen Stil nur automatisiert in thematisch nutzbare Informationen umgewandelt und damit erschlossen werden.

1.1 Problemstellung

Durch das CORINE Land Cover Projekt (*Coordination of Information on the Environment*) der europäischen Umweltagentur EEA dokumentiert die Europäische Kommission den erhöhten Bedarf an aktualisierten Bodenbedeckungsinformationen. Die erste Erhebung für das Jahr 1990 wurde

mittels visueller Photointerpretation von Satellitendaten auf der Basis von *Landsat 5 TM* durchgeführt. Die Aktualisierung, das *Image & CORINE Land Cover 2000* Projekt (I&CLC2000) kostete ca. 12 Millionen Euro und wurde in 28 europäischen Ländern umgesetzt (DE LIMA, 2005). Aufgrund des Mangels an automatisierten Verfahren zur Extraktion dieser Informationen wurden in fast allen Ländern die Daten erneut manuell interpretiert. Um die Aktualisierungszeiten zu verkürzen, den thematischen Detailgrad zu erhöhen und die Kosten für die Bearbeitung zu minimieren, müssen daher Systeme entwickelt werden, die in der Lage sind, weitgehend automatisch die gewünschten Informationen zu gewinnen.

Die bisherigen automatisierten Verfahren zur Klassifikation von Landbedeckung haben sich nur bei der Erstellung von globalen Datensätzen mit räumlich niedrig aufgelösten Sensoren und wenigen thematischen Klassen durchgesetzt. Beispiele dafür sind Landbedeckungskarten im Quadratkilometerbereich. Zu dieser Kategorie gehört die *Global Land Cover Characterization – GLCC* als Gemeinschaftsprodukt vom USGS / UNL und dem JRC, welche aus AVHRR-Daten (*Advanced Very High Resolution Radiometer*) von 1992/1993 abgeleitet wurde (DEFRIES UND TOWNSEND, 1994). Eine weitere globale Kartierung ist das europäische *Global Land Cover GLC2000*-Produkt vom *Joint Research Center* der ESA (BARTHOLOMÉ UND BELWARD, 2005) basierend auf SPOT *Vegetation* Daten. Das MODIS Produkt MOD12Q1 aus dem *International Geosphere-Biosphere Programme* (IGBP) der amerikanischen Behörde USGS – *United States Geological Survey* ist Bestandteil einer umfangreichen Pro-

zessierungskette der TERRA und AQUA Plattform (BELWARD *et al.*, 1999; SCEPAN, 1999). Beide Klassifikationen werden mit Datensätzen von 1 km geometrischer Auflösung erstellt. Neben der Klassifikation von Landbedeckung existieren eine Reihe von automatischen und halbautomatischen Verfahren zur Objektextraktion (BALTSAVIAS, 2003). Sie sind thematisch stark eingeschränkt, beispielsweise zur Extraktion von Straßen und basieren hauptsächlich auf höchst aufgelösten Daten mit einer geometrischen Auflösung von kleiner 5 m.

Da zur Zeit weder *einheitliche Konzepte* zur Klassifikation von umfangreichen hochaufgelösten Satellitendaten existieren, noch *automatisierte Methoden* zur Extraktion von Landbedeckung und Landnutzung zur Verfügung stehen, steigt der Bedarf an einer automatisierten Auswertung von Fernerkundungsdaten mit der verfügbaren Datenmenge.

1.2 Ziele

Der Fortschritt in den informationstechnischen Bereichen, wie beispielsweise die wachsende Rechen- und Speicherkapazität und die Einführung der objektorientierten Modellierung ermöglicht die Adaption von Theorien aus den Bereich der menschlichen Bildwahrnehmung für die Entwicklung eines automatisierten Klassifikationsverfahrens.

Das Ziel dieser Arbeit ist, eine Methodik auf Grundlage dieser Möglichkeiten zu entwickeln, um eine weitgehend automatisierte Ableitung von CORINE Land Cover

Klassen aus Fernerkundungsdaten zu ermöglichen. Aus diesen Zielen bilden sich zwei Komponenten heraus:

- I) die Erstellung eines übertragbaren Konzeptes zur automatisierten bzw. semi-automatisierten Klassifikation von Landbedeckung und Landnutzung aus optischen Fernerkundungsdaten und
- II) die Implementierung eines Programms basierend auf diesem Konzept, das die Klassenhierarchie der CORINE Landcover Klassifikation verwendet.

Als Datengrundlage für die Prozessierung dient der offizielle Datensatz *Image 2000* des Joint Research Centre (JRC), welcher ebenfalls für die Aktualisierung von CORINE Land Cover genutzt wurde. Zusätzlich fließt der überarbeitete Vektordatensatz CORINE LC 1990 ein. Darüber hinaus werden noch weitere Datensätze aus der Fernerkundung (digitales Geländemodell und multitemporale Satellitendaten) in diesem Ansatz verwendet.

Wissenschaftliche Zielsetzung

1. Weitgehend autonome Prozessierung basierend auf *a-priori* Wissen
2. Aufbau eines Kataloges zur Repräsentation der CLC Klassen
3. Klassifikation von CLC Landnutzungsklassen

In dieser Arbeit wird eine neue Methodik vorgestellt, welche die Voraussetzung bildet, um Landbedeckung und Landnutzung von CORINE LC großflächig, beispielsweise für das deutsche Staatsgebiet

automatisiert klassifizieren zu können. Der CORINE Land Cover Klassifikationsschlüssel dient dabei aufgrund seiner Komplexität (Kombination aus Landbedeckung und Landnutzung), der umfangreichen Definition (eindeutige Abgrenzung der Klassen untereinander) und Relevanz (laufendes paneuropäisches Projekt mit festen Aktualisierungszyklen) als Grundlage. Auf diese Weise soll gezeigt werden, dass ein automatisierter Klassifikationsprozess möglich ist, um weitere Aktualisierungen von CORINE zu optimieren. Basierend auf der objektorientierten Klassifikation müssen dazu relevante Merkmale aus den Fernerkundungsdaten extrahiert werden, um sowohl Landbedeckung, als auch Landnutzung identifizieren zu können. Aus diesen Merkmalen wird in der Folge eine *a-priori* Wissensbasis aufgebaut, welche die Basis für eine übertragbare Klassifikation darstellt.

Technische Zielsetzung

1. Automatisierung der Prozessierung
2. Skalierbarkeit der Prozesse
3. Einfache Bedienung der Software

Die technische Umsetzung soll zeigen, dass das entworfene Konzept umgesetzt und damit ein automatisierter Klassifikationsprozess realisiert werden kann. Dazu dient die Entwicklung eines Softwarepaketes, welches das entworfene Konzept der objektorientierten Klassifikation in der Programmiersprache *Python* umsetzt. Mit Hilfe dieses Paketes werden exemplarisch drei Testgebiete klassifiziert und validiert, um die Potentiale des Konzeptes zu verdeutlichen und Probleme zu diskutieren. Die für den Klassenkatalog benötigten Merkmale werden implementiert und in einem Daten-

banksystem abgelegt, um eine parallele Prozessierung zu ermöglichen. Das Softwarepaket ist vollständig modular aufgebaut, um Anpassungen an weitere Sensoren, Klassifikationstechniken und Datenquellen zu gewährleisten. Die manuellen Eingriffsmöglichkeiten für die Prozessierung ist minimal gehalten worden.

Im folgenden Kapitel wird der Hintergrund zur Klassifikation von Landbedeckung und dem CORINE Programm gegeben. Neben dem Stand der Forschung im Bereich der objektorientierten Klassifikation erfolgt ein kurzer Einblick in die Bereiche *computer vision* und Wissensrepräsentation. Auf dieser Basis wird die neu entwickelte Methodik zur Identifikation und Validation von CLC Klassen in Kapitel 3 vorgestellt. Dazu wird der Klassifikationsrahmen definiert und die einzelnen Schritte des objektorientierten Klassifikationsprozesses genannt. Anschließend werden die notwendigen Merkmale für die Beschreibung der implementierten CLC Klassen im CLC Klassenkatalog beschrieben. Das Kapitel endet mit technischen Aspekten der Implementierung, um ein besseres Verständnis von den Möglichkeiten des Softwarepaketes zu bekommen. Kapitel 4 diskutiert die Ergebnisse der Klassifikation auf Basis von drei Testgebieten. Dabei wird auf die verschiedenen Fehlerquellen eingegangen. Das letzte Kapitel fasst die Arbeit kurz zusammen und wirft einen Blick auf interessante Fragestellungen, die sich in Konsequenz dieser Arbeit ergeben.

2

Grundlagen

DIE Gewinnung von Informationen über die Landbedeckung und Landnutzung der Erdoberfläche ist eine der frühesten und wichtigsten Anwendungen der Fernerkundung (CIHLAR, 2000). Neben der berührungslosen Ableitung von biophysikalischen Parametern, der Messung von atmosphärischen Spurengasen und der Beobachtung der Weltmeere hat die Kartierung der Landoberfläche in der heutigen Zeit ihren Stellenwert nicht eingebüßt. Die Daten eignen sich zur kosteneffizienten, flächenhaften Auswertung aufgrund ihrer Aktualität und ihren gleichbleibenden Eigenschaften. Aus diesem Grund existieren eine Reihe von unterschiedlichen Methoden zu deren Auswertung. Landoberflächen können in diskrete Klassen eingeteilt oder klassifiziert werden, da die verschiedenen Oberflächentypen unterschiedliche Reflexionseigenschaften der elektromagnetischen Strahlung im Spektrum haben. Diese Eigenschaften werden von der computerbasierten Analyse statistisch ausgewertet und für eine Klassifikation genutzt. *Funktionalität und Intensität der anthropogenen Nutzung zur Differenzierung der Landnutzung hingegen werden durch die Sensoren nicht direkt aufgenommen.* Informati-

onstechnische Verfahren dienen dazu, aus den Daten Informationen über die Landbedeckung computerbasiert zu extrahieren (LILLESAND UND KIEFER, 2000). Limitationen entstehen durch den komplexen Aufbau der Landoberfläche, den daraus entstehenden Kombinationen resp. Variationen in der Landbedeckung und der fehlenden kognitiven Fähigkeiten des Auswertesystems zur Bestimmung der Landnutzung. Durch manuelle Interpretation werden Aussagen über die Landnutzung getroffen, komplexe Strukturen mit Hintergrundwissen identifiziert und großräumige Daten durch Abstraktion und Generalisierungsfähigkeiten ausgewertet. Aus diesem Grund besitzt die manuelle Bildinterpretation immer noch einen hohen Stellenwert in der fernerkundlichen Datenauswertung. Um bestehende Auswerteverfahren für eine automatisierte Prozessierung zu optimieren, müssen neue Paradigmen in der Bildauswertung eingeführt und angewendet werden. Dazu können Erkenntnisse aus der menschlichen Bildwahrnehmung helfen, bestehende Verfahren zu adaptieren. Dazu zählen Eigenschaften der objektorientierten Klassifikation, die Objektzerlegung in ihre Primitiven, Merkmals-Transformation und die prototypenhafte Repräsentation der CORINE Land Cover Klassen.

In dem nun folgenden Kapiteln werden Klassennamen *kursiv* dargestellt. CORINE Land Cover Klassen werden in einer speziellen Form geschrieben. Ein Beispiel für die erste Siedlungsklasse lautet CLC 111: *Durchgängig städtische Prägung*. Bei der Auflistung von mehreren Klassen wird der Klassenname weggelassen. Eine Übersicht aller CLC Klassen ist in Tabelle 2.1 zu-

sammengestellt. Die farbliche Kodierung der CLC Klassen befindet sich im Anhang (Abbildung A.3). Für die Namen von Programm-Modulen, Datenbanktabellen und anderen technischen wird die Schreibmaschinenschrift verwendet.

2.1 Über die Unterschiede zwischen Landbedeckung und Landnutzung

In vielen Informationssystemen werden Klassen aus den Bereich der Landbedeckung und Landnutzung zusammen verwendet. Die Nomenklatur von CORINE LC ist ein solches Beispiel für die Kombination von Landbedeckung und -nutzung. Einzelne Klassen, wie natürliche oder seminaturliche Vegetation werden der Bodenbedeckung zugeschrieben; landwirtschaftliche und urbane Flächen hingegen zur Landnutzung gezählt. Problematisch ist diese Kombination bei der Harmonisierung, dem Vergleich und der Verknüpfung von verschiedenen Informationssystemen (MEINEL UND HENNERSDORF, 2002A). Zusätzlich erschwert es die eindeutige Zuordnung von Klassen, die für eine automatisierte Klassifikation essentiell ist.

Die Landbedeckung wird nach DI GREGORIO UND JANSEN (1997) *durch die verschiedenen (bio-) physikalischen Materialien der Erdoberfläche beschrieben*. Dabei werden grundsätzlich folgende Kategorien unterschieden: Vegetationsflächen, unkultivierte Flächen, harte Oberflächen, Feuchtgebiete und Wasserkörper. BASTIAN UND SCHREIBER (1999) geben eine Mindestanzahl von Klassen vor, um ökologische

Aussagen über eine Landschaft zu treffen. Dazu gehört der Wald (unterteilt in Nadelwald, Laubwald und Mischwald), Grünland, Sonderkulturen, Ackerflächen (Grünbrache, Schwarzbrache), Gewässer, Siedlungen und Ödland (Feuchtgebiete, Trocken- und Heidebiotope). Diese Klassen finden sich ebenfalls in der CLC Klassenhierarchie wieder. Durch die unterschiedlichen Reflektionseigenschaften dieser Oberflächen kann die Landbedeckung durch fernerkundliche Sensoren direkt detektiert und identifiziert werden.

Die Landnutzung fügt der Landbedeckung eine funktionale Komponente hinzu, die durch die anthropogene Verwendung einer bestimmten Oberfläche entsteht. Vegetationsflächen differenzieren sich in landwirtschaftliche Ackerflächen, Weideland und extensive Grünflächen je nach Funktion und Intensität der Nutzung. Direkt können diese Aspekte fernerkundlich nicht beobachtet werden. Jedoch kann die anthropogene Funktion resp. Intensität die (bio-)physikalische Oberfläche beeinflussen. Dieser Einfluss kann nach DUHAMEL UND VIDAL (1999) genutzt werden, um funktionale Klassen zu bestimmen. Die Nutzungsüberlagerung kann besonders durch eine zeitliche Dimension, z.B. über die phänologische Dynamik der Vegetation, weiter differenziert werden (BASTIAN UND SCHREIBER, 1999).

Einteilung der Klassifikationssysteme

Der thematische Inhalt dieser Informationssysteme richtet sich nach den jeweiligen Anforderungen bzw. den zur Verfügung stehenden Ausgangsdaten. Systematisch können sie durch ihre Klassen-

Nomenklatur in verschiedene Klassifikationssysteme gruppiert werden. Vereinfacht lassen sie sich nach MEINEL UND HENNERSDORF (2002A) unterteilen in

- Listenhafte Nomenklatur (GLCC: *Global Land Cover Characterization*)
- Hierarchische Nomenklatur (CLC: *CORINE Land Cover*, LULCS: *Land Use Land Cover System* der USGS von ANDERSON *et al.* (1976))
- Modulare Nomenklatur (FAO Landcover Classification System)
- Trennung von Landbedeckung und Landnutzung (TER-UTI aus dem französischen Landwirtschaftsprogramm und der europäische Nachfolger LUCAS: *Land Use/Cover Area Frame Statistical Survey*)

Um die verschiedenen Klassifikationen wieder verwendbar und übertragbar zu gestalten, gibt es Bemühungen um Standardisierungen. Beispiele dafür sind das universell anwendbare LCCS (Land Cover Classification System) der FAO von GREGORIO UND JANSEN (2000) im Rahmen des AFRICOVER-Projektes (FAO, 2002), das globale Land Cover-Produkt des Internationalen Geosphären-Biosphären Programmes IGBP (BELWARD *et al.*, 1999) und das CORINE-Programm (*Coordination of Information on the Environment*) der Europäischen Kommission (EU, 1994). Je nach Einsatzgebiet müssen die verwendeten Nomenklaturen unterschiedliche Eigenschaften erfüllen (MEINEL UND HENNERSDORF, 2002B). Dazu zählen räumliche und zeitliche Konsistenz, Unabhängigkeit von der Datenquelle, Maßstabkonsistenz, Vollständigkeit, Überschneidungsfreiheit, definiertes Regelwerk, Kompati-

bilität bzw. Übertragbarkeit und einen Mehrfachnutzung bringen. Die Ableitung der Landbedeckungs- resp. Landnutzungsinformationen kann durch unterschiedliche Datenquellen erfolgen (Extraktion aus statistischen und administrativen Registern, Fernerkundungsdatensätzen und durch die Erhebung von Stichproben). Auf der nationalen Ebene existiert eine Vielzahl von Erhebungsprogrammen. Eine Übersicht der europäischen Programme ist in MEINEL UND HENNERSDORF (2002B) zusammengestellt.

2.2 CORINE Land Cover

Der CORINE Land Cover (CLC) Datensatz ist Bestandteil des CORINE-Projektes des Europäischen Ministerrates aus dem Jahr 1985. Ziel des Projektes ist die europaweite Sammlung von Informationen über den Zustand der Umwelt, die auf einer konsistenten und einheitlichen Nomenklatur basiert. Dazu sollen nationale Initiativen der Mitgliedsländer koordiniert werden, um einen homogenen Datenbestand zu garantieren. Der Haupteinsatz des Datensatzes liegt in den Bereichen Bodenmanagement, Naturschutz und Wassermanagement. Die Bodenbedeckungsinformationen dienen unter anderem der Europäischen Umweltagentur (EEA) zur Unterstützung in laufenden Projekten, wie Natura 2000, der Wasserrahmenrichtlinie, dem integrierten Küstenzonen-Management und der Ermittlung von potentiellen CO₂-Senken (*Kyoto-Protokoll*). Weiterhin nehmen nach FERANEC *et al.* (2005) die Informationen Einfluss auf kommende EU Initiativen. Ein weiteres Anwendungsgebiet liegt nach

STEENMANS UND GHEORGHE (2000) in der sektoralen Analysen in der Land- und Forstwirtschaft, der Raumplanung und im Transport- und Tourismusmanagement zustande.




Abbildung 2.1: Der CLC 1990 Datensatz war die erste harmonisierte, paneuropäische Landbedeckungskarte für die Mitgliedsstaaten. Die Legende mit der Farbbelegung befindet sich im Anhang im Abschnitt A.3 auf Seite 146.

Der Referenzzeitraum für die erste Erfassung war 1990 und wird daher CORINE Land Cover 1990 oder **CLC1990** genannt. Grundlage für die erste Erstellung bildeten hauptsächlich Fernerkundungsdaten (Landsat 5 TM) aus der Zeitspanne zwischen 1989 und 1992, topographische Karten im Maßstab von 1:25.000 und im Ein-

zelfall Luftbilder. Komplementiert wurde die Aufnahme mit Feldbegehungen. Angedacht war eine Aktualisierungszeitraum von 10 Jahren. Das Ziel des Projektes war die Kartierung der Landbedeckung und -nutzung von Flächen mit einer Größe über 25 ha nach dem CORINE-Schlüssel (siehe Tabelle 2.1 und die Legende A.3 im Anhang) für das komplette europäische Gebiet (siehe Abbildung 2.1). Die CORINE Objekte wurden manuell auf den photo-technisch reproduzierten Fernerkundungsdaten aufgezeichnet und anschließend digitalisiert. Bei der Aktualisierung des **CLC 1990** Datensatzes im Jahr 2000 wurden zahlreiche Änderungen eingeführt (EEA und ETC-TE, 2002), um technische Weiterentwicklungen in der Datenverarbeitung einfließen zu lassen. Darunter fallen thematische Ergänzungen, wie die Einordnung von funktionalen Siedlungsformen (Schulen, Krankenhäuser, etc.) in die CLC Klasse 121: *Industrie- und Gewerbeflächen* und geometrische Neuerungen, wie die Aggregation von Straßendörfern. Das daraus resultierende *I&CLC2000* Projekt hatte zum Ziel, neben einen konsistenten, paneuropäischen Datensatz über die **Landbedeckung** resp. **-nutzung** auch einen Datensatz der **Veränderungsflächen** aufzubauen. Das *I&CLC2000*-Projekt beinhaltet zwei Kernkomponenten:

- **Image 2000** (zugrunde liegender Bilddatensatz)
- und **CLC 2000** (Vektordatensatz der Landbedeckung)

2.2.1 Aufbau von CORINE Land Cover

Das CORINE Land Cover System ist ein hierarchischer Klassifikationsschlüssel vergleichbar zum *USGS Landcover Classification scheme* von ANDERSON *et al.* (1976). Es besteht aus 44 Klassen, welche in drei Ebenen unterteilt sind. In Deutschland kommen davon 37 Klassen zur Anwendung. Die fünf Hauptklassen sind unterteilt in:

- I) Bebaute Flächen,
- II) Landwirtschaftliche Flächen,
- III) Wälder und naturnahe Flächen,
- IV) Feuchtflächen
- V) und Wasserflächen.

Die zweite Ebene mit fünfzehn Klassen und die dritte Ebene mit vierundvierzig Klassen haben eine deutlich höhere naturschutzpolitische Relevanz (siehe Tabelle 2.1). Neben thematisch homogen aufgebauten Klassen, bestehend aus einer Landbedeckungskategorie wie zum Beispiel Laubwald, gibt es eine Reihe von Klas-

sen mit thematisch heterogenen Strukturen. Bei der Interpretation von CORINE LC werden Bodenbedeckungseinheiten zusammengefasst, die kleiner als 25 ha sind. Flächen mit einer ähnlichen Charakteristik werden einer CORINE Klasse zugeordnet. Ein Beispiel dafür ist die CLC Klasse 242: *Komplexe Parzellenstruktur*, welche landwirtschaftliche Strukturen mit einem Flächenanteil von größer 75 % zusammenfasst. Zusätzlich dürfen davon thematisch unterschiedliche Klassen, wie beispielsweise Siedlungen, Grünland und Wälder vertreten sein.

CORINE Objekte sind generalisierte Flächen auf der Erdoberfläche, die durch ihre jeweilige Bedeckung bzw. Nutzung einer CLC Klasse zugewiesen wurden. Eine Generalisierungsvorschrift definiert die Geometrie und Semantik dieser Flächen. Objekte weisen eine Mindestgröße von 25 ha auf. Lineare Objekte haben eine Mindestbreite von 100 m. Der semantische Inhalt wird durch einen Interpretationskatalog (EEA, 1997) vorgegeben.

Tabelle 2.1: Hierarchische CLC Klassennomenklatur der Bodenbedeckungen für Europa - die in Deutschland nicht vertretenen Klassen sind *kursiv* hervorgehoben.

Ebene 1	Ebene 2	Ebene 3
1 Bebaute Flächen	11 Städtisch geprägte Flächen	111 durchgängig städtische Prägung
		112 nicht durchgängig städtische Prägung
12 Industrie-, Gewerbe- und Verkehrsflächen	121 Industrie- und Gewerbeflächen	122 Straßen und Eisenbahnnetze, funktionell zugeordnete Flächen
		123 Hafengebiete
		124 Flughäfen
		131 Abbauflächen
13 Abbauflächen, Deponien und Baustellen		

Weiterführung auf der nächsten Seite...

2 Grundlagen

Ebene 1	Ebene 2	Ebene 3
		132 Deponien, Abraumhalden 133 Baustellen
	14 Künstlich angelegte, nicht landwirtschaftlich genutzte Grünflächen	141 Städtische Grünflächen 142 Sport- und Freizeitanlagen
2 Landwirtschaft- liche Flächen	21 Ackerflächen	211 Nicht bewässertes Ackerland 212 <i>Regelmäßig bewässertes Ackerland</i> 213 <i>Reisfelder</i>
	22 Dauerkulturen	221 Weinbauflächen 222 Obst/- und Beerenobstbestände 223 <i>Olivenhaine</i>
	23 Grünland	231 Wiesen und Weiden
	24 Landwirtschaftliche Flächen heterogener Struktur	241 <i>Einjähr. Kulturen in Verbindung mit Dau- erkulturen</i> 242 Komplexe Parzellenstruktur 243 Landwirtschaftlich genutztes Land mit Flächen natürlicher Vegetation von si- gnifikanter Größe 244 <i>Land-/Forstwirtschaftliche Flächen</i>
3 Wälder und natur- nahe Flächen	31 Wälder	311 Laubwälder 312 Nadelwälder 313 Mischwälder
	32 Strauch- und Krautvege- tation	321 Natürliches Grünland 322 Heiden und Moorheiden 323 <i>Hartlaubbewuchs</i> 324 Wald-/Strauchübergangsstadien
		331 Strände, Dünen, Sandflächen 332 Felsflächen ohne Vegetation 333 Flächen mit spärlicher Vegetation 334 Brandflächen 335 Gletscher/ und Dauerschneegebiet
4 Feuchtflächen	41 Feuchtflächen im Landes- inneren	411 Sümpfe 412 Torfmoore
	42 Feuchtflächen an der Küs- te	421 Salzwiesen 422 <i>Salinen</i>

Weiterführung auf der nächsten Seite...

Ebene 1	Ebene 2	Ebene 3
		423 In der Gezeitenzone liegende Flächen
5 Wasserflächen	51 Wasserflächen im Landesinneren	511 Gewässerläufe
		512 Wasserflächen
	52 Meeresgewässer	521 Lagunen
		522 Mündungsgebiete
		523 Meer und Ozean

2.2.2 Komponenten von CORINE Land Cover

Image 2000

Ein entscheidender Vorteil gegenüber der **CLC 1990** Klassifikation war die Schaffung eines konsistenten Mosaiks aus Fernerkundungsdaten. Im Auftrag der Europäischen Kommission wurde vom *Joint Research Centre* (JRC) der ESA dieses Datenmosaik im **Image 2000** Projekt erstellt und den beteiligten Ländern in den jeweiligen Projektionen zur Verfügung gestellt. Als Grundlage wurden dazu Daten vom Landsat 7 ETM+ Sensor aus den Jahren 1999, 2000 und 2001 während der Vegetationsperiode verwendet. Für die Abdeckung des Bundesgebietes waren 31 Landsat-Szenen notwendig, von denen über die Hälfte im Jahr 2000 akquiriert wurde. Die einzelnen Szenen wurden radiometrisch korrigiert und für die manuelle Auswertung optimiert. Eine Atmosphärenkorrektur wurde nicht durchgeführt. Weitere Details über die Vorverarbeitung des **Image 2000** Datensatzes können aus DE LIMA (2005) entnommen werden. Um eine hohe geometrische Lagegenauigkeit, vor allem in bergigen Regionen zu erzielen, wurden die Da-

ten mit Bodenkontrollpunkten und einem digitalen Höhenmodell (DHM) orthorektifiziert. Für Deutschland ist hierzu ein DHM mit der räumlichen Auflösung von 3 Bogensekunden (ca. 90 m) verwendet worden. Es zeigte sich, dass der bestehende **CLC 1990** Datensatz (sowohl Satellitendaten, als auch die Geometrie der Vektordaten) an das **Image 2000** Produkt angepasst werden musste, da bei der ersten CLC Bearbeitung keine Geländekorrekturen der Bilddaten bei der Vorverarbeitung der Satellitendaten vorgenommen wurde (KEIL *et al.*, 2005)). Neben dieser geometrischen Anpassung haben sich die Objektgrenzen nicht geändert.

CLC 2000

Um eine größtmögliche Übertragbarkeit der Daten von **CLC 1990** zu erreichen, wurden die thematischen Klassen, sowie der Erfassungsmaßstab und die Mindesterfassungsgröße beibehalten. Um Änderungen sensitiv erfassen zu können, wurde die Mindesterfassungsgröße einer Änderungsfläche auf 5 ha herabgesetzt. Das **CLC 2000** Projekt wird in Deutschland als Teilprojekt vom Umweltbundesamt (UBA) geleitet. Die Koordination und das Projektma-

nagement ist dem Deutschen Fernerkundungsdatenzentrum (DFD) des DLR (Deutsches Zentrum für Luft- und Raumfahrt e.V.) übergeben worden. Das Projekt umfasste folgende Punkte: Vorverarbeitung der CLC 1990 Daten, Auswahl von Szenen für den **Image 2000** Datensatz, die Interpretation bzw. Kartierung der CLC2000 Bodenbedeckung und mögliche Veränderungen zu CLC 1990, der Integration bzw. Verifizierung der Daten, die Aufbereitung der Metadaten und die Veröffentlichung der CLC Daten. Die Tabelle 2.2 stellt die wichtigsten Unterschiede zwischen den Projekten von 1990 und 2000 und einer möglichen kommenden Aktualisierung zusammen.

2.2.3 Aktualisierung von CORINE Land Cover

Fast alle beteiligten Länder verwendeten die vorgeschlagene Methodik der **computergestützten manuellen Interpretation** der Satellitendaten. Die skandinavischen Länder und England entwickelten auf Grundlage einer umfangreichen Geodatenbasis einen Ansatz, der mit Hilfe von bestehenden Daten versucht, die CORINE Daten ableitet.

Manuelle Interpretation

Umfangreiche technische Dokumentationen, darunter EEA (1997); EEA und ETC-TE (2002); EU (1994), geben klare Handlungsvorgaben zur Erstellung des aktualisierten CORINE Datensatzes. Definiert wurden die Nomenklatur, Generalisierungsvorschriften und die Validierung

der Objekte. Computer wurden zur Visualisierung der Fernerkundungs- und Zusatzdaten genutzt. Nach der manuellen Interpretation einer möglichen Veränderung wurden die CORINE Flächen am Bildschirm digitalisiert (KEIL *et al.*, 2005).

Ableitung aus bestehenden Datenbanken

Schon nach der ersten CORINE Durchführung in den Neunziger Jahren wurden Studien unternommen, um einen automatischen Ansatz für die Durchführung von CORINE zu entwickeln (FULLER UND BROWN, 1996). Eine Reihe von Ländern — Schweden, Finnland, Luxemburg, Großbritannien und die Niederlande — leiteten Landbedeckungskarten aus Fernerkundungsdaten ab. In diesen Fällen wurden multitemporale Datensätze und Zusatzinformationen, wie Bodenkarten und Informationen über die Landnutzung verwendet (DE ZEEUW UND HAZEU, 2001; ENGBERG, 2005A; FULLER UND BROWN, 1996), um die gewünschten CORINE Objekte abzuleiten.

Beispiel Großbritannien

Am *Institute of Terrestrial Ecology* (ITE) wurde eine Methodik entwickelt, die auf einer Degradierung und Generalisierung der bestehenden *Land Cover Map of Great Britain* (LCMGB) basiert. Die Landcover Karte beinhaltet 25 Klassen und hat eine Mindestauflösung von 0.125 ha (25 mx 50 m). Die durchschnittliche Genauigkeit liegt bei ein bis zwei Hektar. Sie basiert auf einer *Maximum Likelihood* Klassifikation von Land-

Tabelle 2.2: Zusammenstellung der wichtigsten Unterschiede zwischen CORINE 1990, CORINE 2000 und der potentiellen CLC Aktualisierung für 2006 (verändert nach HAZEU (2003))

Eigenschaften	CORINE 1990	CORINE 2000	CORINE 2006
Datenakquisition	1986 – 1995	1999–2001	2005/06
Datengenerierung	Abpausen	Bildschirm- digitalisierung	Bildschirm- digitalisierung
Geometrische Auflösung	25 m	25 bzw. 15 m	20 m
Geometrische Genauigkeit	50 m	25 m	20 m
Thematische Genauigkeit		85 %	
Kleinstes Objekt		25 ha	
Kleinstes Objekt bei Veränderungen	—	5 ha	5 ha
Projektdauer	10 Jahre	3 Jahre	1 Jahre
Herstellungskosten	6 € pro km ²	3 € pro km ²	1 € pro km ²
Datendokumentation	unvollständige Metadaten	standardisierte Metadaten	

sat TM Szenen von Großbritannien (FULLER *et al.*, 1994). Um die Klassifikationsgenauigkeit der einzelnen Klassen zu verbessern, wurden Sommer- und Winterszenen verwendet FULLER UND BROWN (1996). Das LCMGB Produkt hatte eine Gesamtgenauigkeit von 67% im Vergleich zu Felddaten. Die Umwandlung der LCMGB 1990 ins CORINE Format endete im Januar 2000. Die Tabelle 2.3 listet die dazu verwendeten Klassen auf.

Für die Erstellung des CORINE Datensatzes wurden folgende Raster- und Vektoroperationen durchgeführt:

- Filterung der LC Daten mit festem Kernfenster
- Vektorisierung
- Eliminierung der Polygone unter 2 ha
- Verschmelzung und Generalisierung der Polygongrenzen
- Klassifikation der Kompositpolygone

- Einbindung von Zusatzdaten zur Erzeugung der restlichen CORINE Klassen
- Glättung der Polygongrenzen

Es wurde ein Umwandlungskatalog entwickelt, der die 33 in Großbritannien vorkommenden CORINE Klassen auf die 25 Klassen der LCMGB abbildet. Neben der Anwendung von Zusatzinformationen zur Identifikation von Flughäfen, Hafenanlagen, Freizeit- und Industrieflächen wurden zusätzlich bestimmte Klassen manuell zugewiesen. Nach einem Vergleich zwischen dieser generalisierten Landbedeckungskarte und einem CORINE Beispielprodukt wurde das Ergebnis als Alternative zur konventionellen CORINE Interpretation erachtet. Die Klassifikationsgenauigkeit lag zwischen 65 % und 90 %. Unterschiede ergaben sich sowohl durch Fehler in der Generalisierung, als auch durch Klassifikationsfehler in der LCMGB. Die errechnete Kostenersparnis durch die Umwandlung der LCMGB im Vergleich zur manuellen

Tabelle 2.3: Die verwendeten Bodenbedeckungsklassen der *Land Cover Map of Great Britain* (LCMGB) dienten als Grundlage der von Fuller entwickelten automatisierten Generalisierung.

21	suburbaner / ländliche Entwicklung	9	Heidegrass
20	geschlossene Bebauung	10	Offene Strauchheide
22	Offener Boden	11	Dichte Strauchheide
18	Bestelltes Land	13	Dichte Strauchheide
6	Mahd / Weideland	25	Offene Strauchheide
7	Weideland	14	Büsche / Strebergärten
15	Laubwald	4	Salzmarsch
16	Nadelwald	3	Strand
5	Grassheide	17	Hochlandmoor
8	Marschland	24	Tiefelandmoor
19	Ruderalpflazen	2	Inlandwasser
23	Kahlschlagflächen	1	Meer / Estuar
12	Farnkraut		

Photo-Interpretation wurde mit 23 % angegeben.

Parallel zur CORINE Aktualisierung im Jahr 2000 wurde auch die LCMGB neu erstellt. Dafür wurden multitemporale Datensätze aus den Jahren 1997 und 1998 von ETM+ und IRS verwendet. Um den typischen *Salz-und-Pfeffer Effekt* der pixelbasierten Klassifikation zu umgehen und die Klassifikationsgenauigkeit zu erhöhen, wurde ein segmentbasiertes Klassifikationsverfahren angewendet (FULLER *et al.*, 2002; SMITH UND FULLER, 2001). Diese Methode (*Classification of the Environment with Vector- and Raster-mapping (CLEVER)*) wurde als BNSC (British National Space Centre) EO LINK-Projekt zwischen der Universität Cambridge, der Firma *Laser-Scan Ltd.* und dem Ordnance Survey entwickelt. Dazu ist die Szene durch digitale Flurgrenzen vorsegmentiert worden. Auf Basis der spektralen Charakteristik wurde für jedes Segment eine Statistik gerechnet, die durch vorhandene Trainingsgebiete

überwacht (*Maximum Likelihood Verfahren*) klassifiziert wurden. Neben spektralen Informationen flossen Höhen- und Bodeninformationen in die Klassifikation ein. Dieser Datensatz wurde als Grundlage für die Aktualisierung des CORINE Produktes für Großbritannien verwendet [Brown *et al.* (2002)].

Beispiel Schweden

In Schweden wurde neben dem SCLC-Produkt (*Swedish CORINE Land Cover*) zusätzlich ein SMD (*Svenska Marktäckedata 2000*) Datensatz erstellt. Der hierarchische Datensatz mit sechs Ebenen umfasst 58 Klassen in einer geometrischen Auflösung von 1 bis 25 ha und basiert auf dem **Image 2000** Daten. Neben fernerkundungsbasierten Daten wurden unter anderem statistische Daten und Vegetationskarten eingesetzt (ENGBERG (2005B) oder BRONGE UND NÄSLUND-LANDENMARK (2002)). Dabei wurden verschiedene Klassifikationsmethoden, wie z. B. Interpreta-

tion, semi-automatisierte Verfahren durch Schwellenwertklassifikation und automatische Verfahren kombiniert. Der hierarchische Aufbau erlaubte die Aggregation aller 35 vorhandenen CORINE Klassen.

In beiden Fällen erfolgte die Ableitung der CLC Klassen und die Generalisierung der CLC Objekte nicht ohne manuelle Eingriffe. Die Ableitung von CORINE LC aus existierenden Basisdatensätzen verringert jedoch die Bearbeitungszeit und kombiniert die Erstellung einer nationaler Datenbasis mit dem europaweiten CLC Programm.

2.3 Allgemeine Techniken zur Klassifikation von Landbedeckung

Unter der Klassifikation versteht man das Einteilen von Daten in Gruppen, Klassen, Ordnungen, Familien usw. nach gemeinsamen Ähnlichkeitsmerkmalen oder Verwandtschaften. Die Klassifikation der Landbedeckung basiert auf der Tatsache, dass die Charakteristik von einer Klasse auf alle Klassenmitglieder übertragen werden können. Diese Eigenschaften können bei fernerkundlich gewonnenen Daten nach LILLESAND UND KIEFER (2000) in drei Merkmalsbereiche untergegliedert werden:

- spektrale,
- räumliche und
- zeitliche Muster.

Unter dem Begriff des *Merkmals* wird in dieser Arbeit eine Eigenschaft verstanden, die eine Klasse in einem bestimmten Merk-

malsbereich beschreibt und zu ihrer Abgrenzung zu anderen Klassen verwendet werden kann. Um den spektralen Informationsgehalt auszuwerten und in diskrete Klassen einteilen zu können, gibt es eine Reihe von Verfahren, die in etablierten Softwarepaketen implementiert wurden. Diese pixelbasierten Methoden stützen sich auf bildpunktbasierter Auswertung der multispektralen Daten. Räumliche Muster, darunter die Textur und Nachbarschaften, werden durch statische Verfahren, basierend auf quadratische Pixelfenster analysiert und parametrisiert (HARALICK UND SHAPIRO, 1985). CIHLAR (2000) gibt einen guten Überblick über notwendige Vorverarbeitungsstufen und verschiedene Klassifikationstechniken für großräumige Prozessierungen.

Im Gegensatz zu den oben genannten Bildinformationen, die für eine computerbasierte Klassifikation genutzt werden können, verwendet der menschliche Interpret nach LILLESAND UND KIEFER (2000) folgende Merkmale für die Bildauswertung:

- Form,
- Größe,
- Muster,
- Farbton,
- Textur,
- Lage,
- Kontext und
- Auflösung.

Durch die Verknüpfung dieser Elemente, der Einbeziehung von zusätzlichen Informationsebenen und der Möglichkeit des Lernens ist der Mensch in Vergleich zur algorithmenbasierten Klassifikation in der Lage, Bildinhalte flexibler und robuster zu erkennen.

Zahlreiche Techniken wurden in der Satellitenbildklassifikation seit den 1970igern entwickelt, um computerbasiert die Daten auswerten zu können. Einen allgemeinen Überblick bieten die Arbeiten von JENSEN (1996), RICHARDS (1999) und QUINLAN (1993). Generell können Klassifikationsverfahren in zwei Gruppen unterteilt werden.

1. Bei den **unüberwachten** Verfahren (z.B. ISODATA- und *k*-means) gruppiert ein Algorithmus iterativ die Daten in Abhängigkeit der Abstände zu möglichen Cluster-Schwerpunkten, die anschließend vom Menschen auf Basis von Feldbegehungen zu thematisch relevanten Klassen aggregiert werden.
2. Die **überwachte** Klassifikation (LOVELAND UND BELWARD, 1997; LOVELAND *et al.*, 1991) basiert auf *a-priori* Wissen über alle vorkommenden Landbedeckungsklassen in der Szene. Dieses Wissen wird in Form von spektralen Signaturen durch Trainingsdaten dem Algorithmus zur Verfügung gestellt. Aus den vorgegebenen Trainingsdaten werden die Klassen statistisch beschrieben. Unbekannte Pixel werden derjenigen Klasse zugewiesen, die am ähnlichsten oder wahrscheinlichsten ist. Die Ähn-

lichkeit wird durch die Wahrscheinlichkeit (*Maximum Likelihood*), einem Ähnlichkeitsmaß (beispielsweise die *Mahalanobisdistanz*) oder dem Abstand (*Parallelepipedon*, *Nearest Neighbour*) im Merkmalsraum definiert (siehe Tabelle 2.4).

In beiden Fällen ist demnach ein manueller Eingriff vom Anwender notwendig, um einen Datensatz zu prozessieren. Die Verfahren können durch eine weitere Eigenschaft unterteilt werden (Abb. 2.4). Diese Einteilung basiert auf der Kenntnis, wie die Klassen im Merkmalsraum statistisch verteilt sind. Die **parametrischen Verfahren**, wie zum Beispiel die *Maximum Likelihood* Klassifikation stützt sich auf der Annahme, dass die Klassenverteilung bekannt ist (DEFRIES UND TOWNSHEND, 1994; TUCKER *et al.*, 1985). Aus den Trainingsdaten kann damit der Mittelwert, die Standardabweichung und Kovarianz eine Klasse beschreiben, wenn die Funktion der Wahrscheinlichkeitsdichte (*Probability Distribution Function* PDF) einer Gausschen Normalverteilung entspricht. Probleme treten auf, wenn die Verteilung der Klassen im Merkmalsraum unbekannt ist oder statistisch nicht exakt beschrieben werden kann DATCU *et al.* (2002). Der Vorteil gegenüber den nicht-parametrischen Verfahren

Tabelle 2.4: Oft verwendete überwachte Klassifikationsverfahren in der Fernerkundung

Pixel basierte Techniken	<i>parametrisch</i>	<i>Maximum Likelihood</i> (ML) <i>Nearest Neighbor</i> (NN)
	<i>nicht parammetrisch</i>	Neuronale Netzwerke Hierarchische Klassifikation Stützvektor-Klassifikator (SVM)
Objekt-orientierte Techniken		eCognition weitere experimentelle Ansätze

liegt in der vergleichsweise einfachen Prozessierung und der mathematisch fundierten Grundlage durch die Anwendung der Wahrscheinlichkeitsdichtefunktion.

Nicht-parametrische Methoden suchen in den Daten, unabhängig von der statistischen Verteilung, nach Mustern und Gesetzmäßigkeiten, um diese einteilen zu können. Diese Gruppe wird durch eine Vielzahl von unterschiedlichen Methoden vertreten, wie beispielsweise Neuronale Netze (GOPAL *et al.*, 1996), Entscheidungsbäumen (FRIEDL *et al.*, 1999; QUINLAN, 1996) und den Stützvektorklassifikator (CAMPS-VALLS *et al.*, 2004; FOODY UND MATHUR, 2004A; ZHU UND BLUMBERG, 2002). Die verschiedenen Klassifikationsverfahren können zusätzlich miteinander zur hybriden Klassifikation kombiniert werden, um Nachteile gegenseitig auszugleichen (z. B. überwacht – unüberwachte Trainingsgebiet-Methode nach BAUER *et al.* (1994)). Überwachte Klassifikationsverfahren sind zu bevorzugen, wenn *a-priori* Wissen über die Klassen existiert. Die unüberwachten Methoden dienen zur spektralen Datenanalyse und bei unbekanntem Datensätzen (CIHLAR, 2000). Für die CORINE LC Klassifikation können überwachte Verfahren eingesetzt werden, da eine umfangreiche Vorklassifikation im Form des CLC 1990 Datensatzes zur Verfügung steht.

Die Übertragbarkeit der Klassifikationsergebnisse auf nicht trainierte Räume wird von der Fähigkeit der Methodik zur Generalisierung und von der Klassifikationscharakteristik bestimmt. Wenn Klassen durch einzelne Merkmale eindeutig (durch Kreuzklassifikation) abgeleitet werden können, produzieren alle genannten

Verfahren übertragbare Ergebnisse (Rinne, 2003). In vielen Fällen können Klassen jedoch nicht durch Kreuzklassifikation bestimmt werden, da die Merkmale die räumliche Variabilität nur unzureichend beschreiben können oder die thematische Definition der Klassen eine eindeutige Zuordnung verhindert. In diesem Fall können hierarchische Klassifikationsverfahren angewendet werden. Zu diesen Verfahren zählen die bestimmte Typen von neuronalen Netzen, wie selbst organisierende Karten (SOM) von KOHONEN (1990) und die Klassifikation durch Entscheidungsbäume.

Stützvektor Klassifikator

Der Stützvektoralgorithmus (engl. *support vector machine* oder SVM) gehört zu den überwachten Klassifikationsverfahren und basiert auf der empirischen Risikominimierung. Die Methode wurde im Bereich der Mathematik von VAPNIK (1995) und anderen entwickelt und wird in vielen Bereichen der Mustererkennung erfolgreich angewendet.

In der Fernerkundung wurden *support vector machines* in den letzten Jahren bei der Klassifikation von Landsat TM (KEUCHEL *et al.*, 2003), Radar- (FUKUDA UND HIROSAWA, 2001) und ASTER Daten (MARÇAL *et al.*, 2005; ZHU UND BLUMBERG, 2002) und hyperspektralen Anwendungen (Melgani und Bruzzone, 2004) eingesetzt. Ein Vergleich der Ergebnisse zwischen den *Stützvektorklassifikator* und anderen Klassifikationsverfahren (künstliche neuronale Netze, *Maximum Likelihood*) wurde von PAL UND MATHER (2005) unternommen. Eine genauere Bewertung der Klassifikationser-

gebnisse bei gleichen Bedingungen (identische Trainingsgebiete) wurde von HUANG *et al.* (2002) durchgeführt. Dabei zeigte sich, dass die Klassifikationsergebnisse im Vergleich zu herkömmlichen überwachten Verfahren (Klassifikation mit *Maximum Likelihood*, Entscheidungsbäumen und Neuronalen Netzwerken) eine ähnliche Güte besitzen, aber stabilere Gesamtergebnisse bei einer unterschiedlichen Anzahl von Trainingsgebieten produziert. Dies wird mit dem höheren Generalisierungsvermögen des Verfahrens begründet.

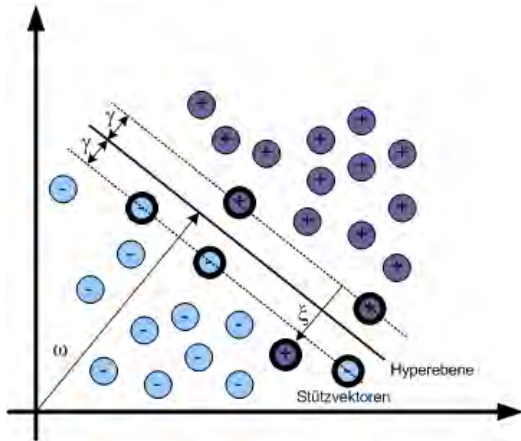


Abbildung 2.2: Geometrische Erklärung für die lineare Klassifikation for SVM

Das Verfahren ist ein *binärer Klassifikator*, d.h. unbekannte Objekte werden in zwei vorher definierte Klassen unterteilt. Dazu muss eine Menge von n Trainingsdaten vorliegen, die sich genau in zwei Klassen $\{-1, +1\}$ untergliedern lassen. Abweichungen innerhalb der Trainingsdaten können durch den *soft margin* Ansatz berücksichtigt werden. Die Trainingsmenge $x_i \in \mathcal{X}, \{i = 1, \dots, n\}$ und den Klassenbezeichnungen $y_i \in \mathcal{Y}$, wobei $\mathcal{X} = \mathbb{R}^N$ den Merkmalsraum und \mathcal{Y} den Klassenbezeich-

nugsraum beschreiben. Es wird angenommen, dass eine unbekannte Wahrscheinlichkeitsverteilung $\mathcal{P}(x, y)$ vorliegt. Im Idealfall gibt es einen deterministischen Zusammenhang $f(x) = y$. Das Ziel des Klassifikationsverfahren ist, eine Funktion zu finden, die diesen Zusammenhang am besten beschreiben kann, ohne eine Überanpassung durch die Trainingsdaten zu bekommen (*Generalisierungsfähigkeit*).

Die *empirische Risikominimierung* ist eine Methode, die auf dem erwarteten Fehler $\mathcal{R}_{emp}(\alpha)$ für einen trainierten Klassifikator basiert und diesen durch ein Optimierungsverfahren minimiert. Dabei gilt laut VAPNIK (1995):

$$\begin{aligned} \mathcal{R}(\alpha) &= \int \frac{1}{2} |y - f(x, \alpha)| d\mathcal{P}(x, y) \\ \mathcal{R}_{emp}(\alpha) &= \frac{1}{2n} \sum_{i=1}^n |y_i - f(x_i, \alpha)| \\ \mathcal{L} &= \sqrt{\frac{h(\log(2n/h) + 1 - \log(\eta/4))}{n}} \\ \mathcal{R}(\alpha) &\leq \mathcal{R}_{emp}(\alpha) + \mathcal{L} \end{aligned} \quad (2.1)$$

Der rechte Teil der letzten Gleichung 2.1 wird als Risikobegrenzung bezeichnet. η ist die Wahrscheinlichkeit, dass die Gleichung nicht erfüllt wird, folglich ist $\mathcal{R}(\alpha)$ größer als die Risikobegrenzung. Die *Vapnik-Chervonenkis-Dimension* h aus \mathbb{N} beschreibt die Komplexität der Funktionsklasse $f(x, \alpha)$. Wenn mehrere Funktionen vorliegen, wird die Menge ausgewählt, welche die Risikominimierung am besten minimiert.

Die *lineare Stützvektorklassifikation* baut auf diesen Mechanismen auf, um den Klassifikator mit der größten Generalisierungsfähigkeit zu ermitteln. Dazu wird ein Poly-

nom ersten Grades (eine Gerade im zwei-dimensionalen Fall, ansonsten eine Hyperebene) gebildet, um beide Klassen zu trennen (siehe Abbildung 2.2). Die Hyperebene ist definiert durch den Normalenvektor ω und der Verschiebung b , demnach gilt $\mathfrak{H} = \{x | (\omega \cdot x) + b = 0\}$.

Durch die Entscheidungsfunktion

$$f(x) = \text{sgn}\left(\sum_{i=1}^n \alpha_i y_i (\omega \cdot x) + b\right) \quad (2.2)$$

wird der Raum in zwei Klassen unterteilt $\{-1, 1\}$. Bei nicht-trennbaren Trainingsdaten wird ein *Fehlergewicht* C eingeführt, um diese Hyperebene konstruieren zu können. Durch das Finden der maximalen Trennschnecke wird die bestmögliche trennende Hyperebene gefunden. Diese Hyperebene hat damit den größten Abstand zu allen vorgegebenen Trainingspunkten. Dazu wird der Abstand d vom Punkt x_i zur Hyperebene \mathfrak{H} durch die folgende Verlustfunktion berechnet:

$$d(\mathfrak{H}, x_i) = y_i \left(\frac{\omega}{\|\omega\|} \cdot x_i + \frac{b}{\|\omega\|} \right) \quad (2.3)$$

Nach einer Skalierung der Hyperebene (*kanonische Hyperebene*) findet eine Minimierung von $\|\omega\|^2$ über eine Optimierung (*Lagrange-Ansatz*) statt. Daraus entsteht das *duale Problem*:

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (2.4)$$

unter der Bedingung:

$$0 \leq \alpha_i \leq C, i = 1, \dots, n$$

$$\text{und } \sum_{i=1}^n \alpha_i y_i = 0$$

Die Proben, die der Hyperebene am nächsten sind, heißen Stützvektoren (oder *support vectors*).

Diese Stützvektoren bestimmen die Lage der Hyperebene und damit den Klassifikator. Sie werden definiert durch $\alpha \neq 0$.

Wichtig dabei ist, dass bei diesem Optimierungsproblem und der Entscheidungsfunktion

$$\begin{aligned} f(x_{neu}) &= \text{sgn}(\omega \cdot x_{neu} + b) \\ &= \text{sgn}\left(\sum_{i=1}^n \alpha_i y_i x_i \cdot x_{neu} + b\right) \end{aligned} \quad (2.5)$$

die Trainingsmenge x_i nur im Skalarprodukt auftaucht. Diese Eigenschaft kann ausgenutzt werden, um zusätzlich eine nicht-lineare Klassifikation durchzuführen (*Kerneltrick*).

Die Trennung findet indirekt in einem mehrdimensionalen euklidischen Raum (Hilbert-Raum \mathcal{H}) durch die Transformationsfunktion $\Phi : \mathbb{R}^N \rightarrow \mathcal{H}$ statt. Dieser Raum kann unendlich dimensional sein. Unter der Voraussetzung, dass nur das Skalarprodukt der Entscheidungsfunktion und einer Kernelfunktion Φ oder $k(x, y)$ (für die Transformation) gerechnet werden braucht, sei: $k(x, y) = \langle \Phi(x), \Phi(y) \rangle$ mit $x, y \in \mathbb{R}^N$ und $d \in \mathbb{N}$. Beispielsweise ist $\Phi : \mathbb{R}^2 \rightarrow G$ definiert durch $(x_1 \cdot x_2) \mapsto (x_1^2 \cdot \sqrt{2x_1x_2} \cdot x_2^2)$, dann gilt:

$$\begin{aligned} (\Phi(x)\Phi(y)) &= \\ &= (x_1^2 \cdot \sqrt{2x_1x_2} \cdot x_2^2)(y_1^2 \cdot \sqrt{2y_1y_2} \cdot y_2^2)^T \\ &= ((x_1 \cdot x_2)(y_1 \cdot y_2)^T)^2 \\ &= (xy)^2 \\ &= k(x, y) \end{aligned} \quad (2.6)$$

Eine Funktion kann als Kernelfunktion verwendet werden, wenn sie dem Theorem von MERCER entspricht. Folgende Kernelfunktionen werden auf diese Weise am häufigsten verwendet:

- *Linearer Kernel*: $k(x, y) = x \cdot y$
- *Polynomieller Kernel*: $k(x, y) = (\gamma x \cdot y + c_0)^d$
- *Gauss-Kernel*: $k(x, y) = e^{-\|x-y\|^2/2\delta^2}$
- *Radial Basis Funktion (RBF)*: $k(x, y) = \exp(-\gamma\|x - y\|^2)$ für $\gamma > 0$

Durch diesen *Kerneltrick* wird ein Raum konstruiert, der in der Lage ist, beide Klassen linear zu trennen. Dazu muss die eigentliche Projektion Φ nicht bekannt sein.

In BENNET UND CAMPBELL (2000) wird zusätzlich eine geometrische Erklärung zur Funktionsweise der *support vector machines* gegeben. Eine erweiterte Anleitung zur Nutzung von SVMs für die Mustererkennung liefert BURGESS (1998). FLACH (2001) gibt neben der SVM Methode einen guten Überblick der aktuellen Verfahren im Bereich des Maschinellen Lernens.

Viele Klassifikationsprobleme können durch eine binäre Unterteilung der Daten nicht gelöst werden. Aus diesem Grund wurde die Methodik um ein Multiklassen-Verfahren erweitert. Mehr als zwei Klassen ($k > 2$) können durch zwei Varianten klassifiziert werden:

- Jede Klasse gegen den Rest (k Durchgänge)
- Jede Klasse gegen jede andere ($\frac{k \cdot (k-1)}{2}$ Durchgänge)

Das Stützvektor-Verfahren basiert zusammenfassend auf der Berechnung einer Hyperebene mit maximaler Trennschere im Merkmalsraum. Diese Hyperebene wird im Spektral-Raum mit Hilfe einer Kernelfunktion basierend auf den gefundenen Stützvektoren rekonstruiert.

Das trainierte Modell besteht aus der Linearkombination von einigen Mustern der Trainingsmenge (Stützvektoren) und Koeffizienten zur Rekonstruktion des hochdimensionalen Merkmalsraums. Diese Eigenschaft kann man sich zunutze machen, um die Klassifikation zu optimieren (CAUWENBERGHS UND POGGIO, 2000). Durch das Verfahren des *inkrementellen Lernens* wird abhängig vom Klassifikationsergebnis eine neue Trainingsmenge gebildet, indem fehlklassifizierte Stichproben aussortiert und zu zusätzlichen Klassen aggregiert werden. Durch gezieltes Reduzieren von Stichproben kann ein existierendes Modell ebenfalls optimiert werden (*dekrementelles Lernen*).

Pixelbasierte Verfahren

Pixelbasierte Klassifikationsverfahren (sowohl parametrische und nicht-parametrische Methoden) weisen einzelnen Bildelementen (Pixel) aufgrund ihrer spektralen Charakteristik die jeweils ähnlichste Klasse zu. Fehlklassifikationen kommen zustande, wenn

- 1) die Klasse spektral durch die Trainingsgebiete nicht ausreichend beschrieben werden kann,
- 2) Klassen untereinander durch die Verfahren nicht trennbar sind und

3) das Bildelement aus unterschiedlichen Landbedeckungen zusammengesetzt ist (Mischpixel).

Die **Mischpixel** entstehen durch die Aufnahmegeometrie des Sensors und die Datenspeicherung im Rasterformat (Abb. 2.4). Sie treten unabhängig von der geometrischen Auflösung auf. Je niedriger die räumliche Auflösung ist, desto höher wird der Mischpixelanteil im Pixel, da dieser eine größere Fläche mit variierender Landbedeckung abdeckt. Die Abbildung 2.4 zeigt vier Ausschnitte einer höchstauflösten IKONOS-Szene aus dem Raum Frankfurt mit 1 m geometrischer Auflösung. Die Gitterweite entspricht 25 m (analog zur Auflösung von Landsat oder des CLC Datensatzes). Aus diesem Grund kann die rasterzellenbasierte Ablegung von diskreten Informationen (Landbedeckung und -nutzung) nur angenäherungsweise korrekt sein. Zusätzlich kann es sensorbedingt zu Überstrahlungseffekten aus Nachbarpixeln kommen, die das Spektrum des Pixels beeinflussen (TOWNSHEND *et al.*, 2000).

Folgende Aspekte müssen bei der Anwendung von pixelbasierten Klassifikationsverfahren berücksichtigt werden, wenn die Klassenhierarchie von CORINE LC umgesetzt wird:

I) Die überwachte Klassifikation benötigt Trainingsgebiete aus den Bilddaten, um die Klassenstatistik berechnen zu können. Eine Lösung dafür könnte die automatische Generierung der Trainingsspektren sein, basierend auf einer vorhergehenden Klassifikation, in unserem Falle das **CLC 1990** Produkt.

II) Die Erweiterung auf die dritte Hierarchieebene würde die Trennbarkeit zwischen den Klassen verringern, da viele Klassen spektral ähnliche Oberflächen aufweisen und die spektrale Auflösung der *Image 2000* Daten mit sieben Kanälen für eine weitere Differenzierung nicht ausreichend ist.

III) Viele CLC Klassen im Bereich der Landnutzung können nicht allein durch ihre spektrale Charakteristik definiert werden, da weitere Merkmale für die Klassifikation notwendig sind. Darunter fallen Nachbarschaftsbeziehungen, räumliche Lage des CLC Objektes und die zeitliche Dynamik der Oberfläche.

IV) Die Geometrie und Topologie der CORINE Objekte entspricht nicht dem diskreten, quadratischen Pixel der Bildverarbeitung. Dies liegt an der menschliche Interpretation der CLC Objekte und der damit verbundenen flächenhaften Repräsentation, die durch die manuelle Digitalisierung von CLC 90 verursacht wurde.

Als Beispiel für die **spektrale Ähnlichkeit** der Oberflächen untereinander (Punkt II) und zwischen Landbedeckung und Landnutzung (Punkt III) verdeutlicht die Abbildung 2.3. Die mangelnde Trennbarkeit führt zur fehlerhaften Zuweisung von Datenpunkten.

Objektorientierte Klassifikation

Neben einer Erweiterung der pixelbasierten Klassifikationsverfahren (umfangreiche Postklassifikationsverfahren, Einbezug der Unschärfelogik, Optimierung durch neuronale Netze und genetische Algo-

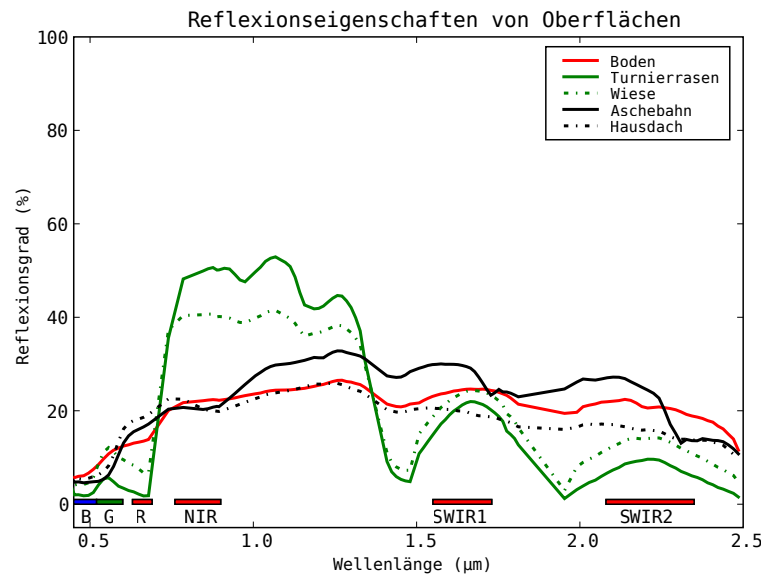




Abbildung 2.3: Der Reflexionsgrad von verschiedenen Oberflächen weist nur geringe Unterschiede zwischen Landbedeckung und -nutzung auf. Mögliche Unterschiede zwischen den Materialien können in den ETM+ Bändern jedoch nicht mehr zur weiteren Differenzierung verwendet werden.

rithmen) kam es zu einer Neuentwicklung (BALSAVIAS, 2003; BLASCHKE *et al.*, 2000) in der Auswertung von Fernerkundungsdaten. Die *objektbasierte* oder *objektorientierte Klassifikation* (EGENHOFER UND FRANK, 1992; PEDLEY UND CURRAN, 1991; WOODCOCK, 1992) wurde dazu aus anderen Bereichen der Bildauswertung (Medizin) adaptiert. Diese Verfahren bauen nicht mehr auf Pixel, sondern auf homogenen Bildsegmenten (so genannte Bildobjekte) oder vorgegebenen Grenzen (*per-parcel*) aus Zusatzdaten auf. Die Bildobjekte ermöglichen die Berechnung von weiteren Informationen aus dem Bild (Objektgröße, Objektform und Nachbarschaft). Dadurch ist es möglich, bestimmte Klassen der Landnutzung (Hafenanlagen, städtische Grünflächen usw.) zu klassifizie-


ren und die Klassifikationsgenauigkeit von bestehenden Landbedeckungsklassifikationen zu erhöhen. Komplexere Klassen können durch das Datenmodell beschrieben werden, da neben einer räumlichen Verschneidung der Informationsebenen auch thematische Verknüpfungen möglich sind. Mischpixel spielen, statistisch gesehen, eine untergeordnetere Rolle. Im Gegensatz zu der statischen Pixelmatrix besitzt die Topologie dieser neu gewonnenen Bildobjekte eine sinnvolle und unabhängige Informationsebene. Weiterhin können zusätzliche Informationen (aus weiteren FE Datensätzen oder Geographischen Informationssystemen) mit diesen Objekten assoziiert werden.




(a)



(b)



(c)



(d)

Abbildung 2.4: Es gibt verschiedene Formen der bei der Entstehung von Mischpixeln: Objekte im Subpixelbereich 2.4(a), Objektgrenzen durch unterschiedliche Landbedeckungen 2.4(b), graduelle Verläufe in einer Landbedeckung 2.4(c) und lineare Elemente im Subpixelbereich 2.4(d) führen zu Subpixelinformationen und erschweren die pixelweise Klassifikation.

Im Gegensatz zu rasterbasierten Verfahren versuchen objektbasierte und objektorientierte Ansätze, räumliche Muster und Abhängigkeiten zu klassifizieren (BLASCHKE UND STROBL, 2001; T. BLASCHKE UND PEKKARINEN, 2005). Dazu werden *disjunkte, zusammenhängende Bereiche* (CASTLEMAN, 1995) im Bild abgegrenzt und mit einer eindeutigen Identität in dem neuen Datenmodell abgelegt (EGENHOFER UND FRANK, 1992). Diese Informationsträger (Bildobjekte oder Bildsegmente) dienen als Basis für die Generierung der Eigenschaften für die Bildanalyse und der Klassifikation. Die Grundlage liegt in der Annahme, dass Pixel in einer zweidimensionalen Matrix nicht zufällig verteilt vorliegen. Räumlich benachbarte Pixel besitzen eine hohe Korrelation untereinander. Eine Reihe von Studien (MITRA, 2004; WOODCOCK, 1992) haben die Vorteile gegenüber der pixelbasierten Klassifikation herausgearbeitet. Diese liegen hauptsächlich in der Generierung von stabileren Merkmalen (z.B. gemittelte Spektren) und der Eliminierung von einzelnen fehlklassifizierten Bildelementen (*Salz und Pfeffer-Effekt* oder *Randpixelbereich*).

Der Unterschied zwischen einer objektbasierten und objektorientierten Klassifikation liegt in dem verwendeten Datenmodell. Der **objektbasierte Ansatz** nutzt die Bildsegmente zur Stabilisierung bzw. Verbesserung der Klassifikation, wie zum Beispiel in der *UK land cover map* von SMITH UND FULLER (2001) und FULLER *et al.* (2002) geschehen. Die **objektorientierte Klassifikation** hingegen kann als mehrstufiges Datensystem angesehen werden, um Informationen aus der abgebildeten Realität in komplexere, hierarchische Datenmo-

delle zu abstrahieren (EGENHOFER UND FRANK, 1989; MOLENAAR UND RICHARDSON, 1994). Das vollständige System besteht aus

1. der **Klassifikation**,
2. der **Klassengeneralisierung**,
3. der **Assoziation** und
4. der **Aggregation**.

Dabei wird unter dem Begriff der Klassifikation die Zuweisung von einem Objekt zu einer Basisklasse verstanden. Die Generalisierung fasst diese Basisklassen mit ähnlichen Eigenschaften zu *Überklassen* zusammen. Die Assoziation beziehungsweise die Aggregation ermöglicht die Kombination von verschiedenen Objekten zu einem *Überobjekt*. Im Falle einer CLC Klassifikation wird ein Objekt der Unterklasse *Wasserfläche* zugewiesen. Nach der Generalisierung gehört das Objekt der Klasse *Flusslauf* an, die alle linearen Wasserflächen im Inland gruppiert. *Siedlungsgebiete* können durch Aggregation von unterschiedlichen Objekttypen (Innenstadt, Grünfläche, Industriegebiet) gebildet werden.

Die Grundlage jeder objektbasierten und objektorientierten Klassifikation stellen Bildsegmente oder Bildobjekte dar, die durch eine Bildsegmentierung erzeugt werden. Es existieren unterschiedliche Verfahren zur Bildsegmentierung (HARALICK UND SHAPIRO, 1985; PAL UND PAL, 1993). Diese lassen sich grob in zwei Klassen unterteilen: kantenbasiert und regionenbasiert. Kantenbasierte Methoden extrahieren durch Filter Helligkeitsunterschiede aus dem Bild und rekonstruieren daraus die Objektgrenzen. Regionenbasierte Verfahren können sowohl top-down (1), als auch bottom-up (2) arbeiten, d.h. das

Bild wird in homogene Bereiche rekursiv zerlegt (1) oder von einzelnen Punkten ausgehend werden ähnliche Pixel zusammengefasst (2). Eine Kombination der beiden Verfahren wird ebenfalls angewendet. In beiden Fällen müssen zuerst charakteristische Eigenschaften aus dem Bild gewonnen werden, um zusammenhängende Bereiche ausweisen zu können. Im einfachsten Fall dient die lokale Verteilung der Spektren als Grundlage für die Segmentierung. Bei den fortgeschrittenen Verfahren werden räumliche Frequenzmuster, *Markov-Zufallsfelder*, *Co-occurrence Matrix*, *Wavelet-Koeffizienten* usw. genutzt. Diese werden im zweiten Schritt durch eine Abschätzungsfunktion, beispielsweise durch Minimierung einer Kostenfunktion verglichen.

Implementierungen der objektorientierten Klassifikation

Viele Konzepte existieren bis zu diesem Zeitpunkt nur in der Theorie (MOLENAAR UND RICHARDSON, 1994) oder sind nur teilweise implementiert (Segmentierungsalgorithmen ohne Klassifikationsteil). Das Programmpaket *eCognition* der Firma Definiens ist das erste kommerziell verfügbare Softwarepaket, das den Ansatz der objektorientierten Klassifikation umgesetzt hat (BENZ *et al.*, 2003). Eine Reihe von Arbeiten, darunter DESCLÉE *et al.* (2006); HAARMANN (2001), zeigen die Vorteile der objektorientierten Klassifikation in den Bereichen Klassifikation von höchst aufgelösten Fernerkundungsdaten, Identifikation von Landnutzungsklassen, Veränderungsdetektion (Willhauck *et al.*, 2000) und der automatisierten Klassifikation. Der Projektaufbau in *eCognition* gliedert sich in die

Bereiche: Segmentierung, der Auswahl von geeigneten Merkmalen und der Klassenbeschreibung (de Kok, 2001)

Trotz des objektorientierten Klassifikationskonzeptes konnte das Programm *eCognition 3* aus drei Gründen für diese Arbeit nicht eingesetzt werden.

- I) Wie ein Vergleich zwischen pixelbasierten und objektbasierten Verfahren bei KOCH *et al.* (2003) zeigt, gehen durch die Segmentierung (Generalisierung und Homogenisierung) des Bildes viele Informationen verloren. Die Studie empfiehlt die Kombination der Methoden aus pixel- und objektbasierter Klassifikation. Für viele heterogen aufgebaute CORINE Klassen (z. B. Hafenanlagen, Parkflächen und Landwirtschaftsflächen mit komplexer Parzellenstruktur) sind Informationen auf Sub-Segment-Ebene wichtig.
- II) Der zweite Grund liegt in der Repräsentation des Expertenwissens. Trotz unscharfer Angaben der Merkmale über *fuzzy-sets* sind die gewählten Parameter bildabhängig, d.h. sie können nur durch Adaption an neue Szenen wiederverwendet werden. In einer Szene produziert das Regelwerk verschiedene Ergebnisse für zufällig ausgewählte Ausschnitte (ESCH, 2003). Die generierten Bildobjekte oder Bildsegmente unterscheiden sich ebenfalls von Ausschnitt zu Ausschnitt. Durch die fehlende Übertragbarkeit des Regelwerks unter der Bildobjekte können umfangreichere Datenmengen nicht automatisiert klassifiziert werden. Zudem läuft das Programm

durch das verwendete komplexe Datenmodell bei größeren Datenmengen nicht mehr stabil genug.

- III) Die Einbindung der Funktionalität von *eCognition* in eine operationelle Prozesskette ist durch das gekapselte Programmkonzept ebenfalls nicht gegeben. Es können keine Funktionen über eine Schnittstelle von externen Programmen genutzt werden. Komplexere Ablaufschritte sind seit kurzem nur in der Entwicklerversion von *eCognition* möglich.

Aus diesen Gründen wurde ein Konzept basierend auf der objektorientierten Klassifikation aufgebaut und eine eigene Software entwickelt, um die Grundfunktionalität zur Klassifikation bereitzustellen. Diese Software wird an dem CORINE LC Regelwerk angepasst und anschließend validiert. Das entwickelte Konzept erweitert damit die Funktionalität von *eCognition* um folgende Aspekte:

- Durch die pixelweise Auswertung der Segmente gehen für spektrale Auswertungen keine Informationen verloren.
- Der Aufbau eines eigenen Datenmodells ermöglicht die Erweiterbarkeit von weiteren Merkmalen. Besonders bildinvariante Merkmale erlauben deshalb die Übertragbarkeit des Regelwerkes auf weitere Datensätze.
- Modularisierung und Parallelisierung der Software gestatten die Prozessierung von umfangreichen Datensätzen in mehreren Instanzen.

2.4 Grundlage der objektorientierten Klassifikation

Unter dem Begriff der objektorientierten Klassifikation von Satellitendaten versteht man die hierarchische Auswertung auf Basis von Segmenten (oder Bildobjekten) als einfachste Bildprimitive (BENZ *et al.*, 2003). Sie baut auf den informationstechnischen Grundlagen der objektorientierten Modellierung auf und beinhaltet folgende Säulen: *Abstraktion*, *Einkapselung*, *Vererbung* und *Vielgestaltigkeit*. Unter der *Abstraktion* versteht man die Repräsentation von komplexen Datentypen durch Klassen und Objekten. Computer können in erster Linie nur mit numerischen Datentypen umgehen. Die Abstraktion bietet den Vorteil, Datentypen aus der menschlichen Repräsentation zu implementieren. Dadurch können zum Beispiel komplexere Landbedeckungsklassen aus einer Kombination von bestimmten Merkmalen abgeleitet werden. Unter der *Einkapselung* versteht man die technische Eigenschaft der kombinierten Haltung von Daten und Methoden (Funktionen) für die jeweiligen Objekte. Durch *Vererbung* können Eigenschaften (Daten und Methoden) von Elternklassen an ihre Kinderklassen weitergegeben und verändert werden. Die *Vielgestaltigkeit*, auch Polymorphismus genannt, ermöglicht das unterschiedliche Verhalten von Klassen in veränderten Situationen. Das Objekt *See* der Klasse *Landbedeckung* kann andere Parameter zurückliefern als das Objekt *Fluss*.

Die Verwendung von *bedeutungsvollen* Bildobjekten als unterste Bildprimitive basiert aus den Erkenntnissen der menschlichen

Wahrnehmungsleistung (BENZ *et al.*, 2003; SCHIEWE, 2003). Nach dem Postulat von MARR (1982) muss die menschliche Objektwahrnehmung als „*vielschichtiger und komplexer informationsverarbeitender (kognitiver) Prozess*“ verstanden werden, um ihn technisch umsetzen zu können. Dieser Prozess besteht aus der

- I) *Extraktion von Informationen* aus dem Gesehenen
- II) *und der Repräsentation dieser Informationen* im Gehirn.

Dabei herrschen zwei Verfahren vor: **Identifikation** und **Kategorisierung**. Um nun einen informationsverarbeitenden Prozess von einer Maschine ausführen zu lassen, müssen drei verschiedene Ebenen betrachtet werden: die *informatische Theorie, Repräsentation und Algorithmen* sowie die *Implementierung*.

Informatische Theorie

Diese oberste Ebene liefert den abstrakten theoretischen Hintergrund. Sie bestimmt, auf welche Weise Informationen umgewandelt werden können, um für den Auswertungsprozess nutzbar zu sein. Dazu muss das Problem verstanden und soweit abstrahiert sein, dass geeignete Algorithmen auf dieser Basis ausgewählt oder entwickelt werden können. Sie ist die wichtigste Ebene für den informationsverarbeitenden Prozess, da das Problem in seiner Ganzheit verstanden und gelöst werden muss. MARR (1982) gibt dazu ein anschauliches Beispiel zur Problematik des Vogelflugs. Die Analyse einer Feder (Aufbau, unterschiedliche Erscheinungen) löst nicht das Problem, da auch andere Bereiche (Aerodynamik, Ana-

tomie, Effizienz usw.) miteinbezogen werden müssen. Der Abschnitt 2.4.2 über die Objekterkennung verweist daher auf die Erkenntnisse der computerbasierten Bildauswertung und der wissensbasierten Repräsentation von Objekten. Im weiteren liefert Abschnitt 3.1 die theoretische Basis für den Rahmen der automatisierten Klassifikation von Fernerkundungsdaten.

Repräsentation und Algorithmen

Diese Ebene definiert die benötigten Eingabe- und Ausgabedaten und beschreibt die verwendeten Algorithmen, um diese Daten zu transformieren. Dazu zählen hauptsächlich Algorithmen zur Extraktion von Merkmalen aus den Daten und deren Bewertung. Im Gegensatz zur obersten Ebene gibt es schon eine Reihe von etablierten Algorithmen und Mechanismen (z. B. Klassifikationsverfahren und Kantenerkennung), die dazu genutzt werden können. Das Kapitel 3.1 geht darauf näher ein.

Hardware und Softwareimplementierung

Die unterste Ebene berücksichtigt sowohl die Hardware, als auch die Software, die eingesetzt werden soll, um die Algorithmen letztendlich zu implementieren. Dazu zählen auch die technischen Anforderungen an die Algorithmen und das Datenmanagement. Diese Punkte werden im Kapitel 3.5 über die technischen Aspekte der Software behandelt.

Tabelle 2.5: Physikalische Annahmen in der Bildwahrnehmung nach MARR

Annahme 1 (Existenz von Oberflächen) *Die sichtbare Welt kann als Zusammenstellung von verschiedenen Oberflächen, die bestimmte Reflektanzfunktion mit räumlichen Mustern besitzen, aufgefasst werden.*

Annahme 2 (Hierarchische Anordnung) *Die räumliche Verteilung dieser Reflektanzfunktionen wird durch eine Anzahl von verschiedenen Prozessen bestimmt, die auf unterschiedlichen Maßstabsebenen agieren.*

Annahme 3 (Ähnlichkeit) *Objekte vom gleichen Typ auf einer Oberfläche besitzen in Abhängigkeit des Maßstabs ähnliche Prozesse für die Reflektanzfunktion, und damit eine ähnliche Erscheinung in Größe, lokalem Kontrast, Farbe und räumlicher Verteilung, als Objekte von unterschiedlichem Typ.*

Annahme 4 (Räumliche Stetigkeit) *Einfache Objekte auf einer Oberfläche sind oft räumlich besonders verteilt, d.h. bilden Kurven oder Linien und erstellen oft noch komplexere Muster.*

Annahme 5 (Weiterführung der Diskontinuität) *Diskontinuierliche Ortskurven (Loci) auf einer Oberfläche verlaufen nahtlos weiter.*

Annahme 6 (Kontinuität der Bewegung) *Wenn die Richtung einer Bewegung an mehr als einen Punkt – z. B. an einer Linie – unterbrochen ist, handelt es sich um eine Objektgrenze.*

2.4.1 Bildwahrnehmung und Fernerkundung

Für viele Bereiche der *Künstlichen Intelligenz* existieren keine vollständigen informatischen Grundlagen, d.h. eindeutige Theorien, die informatisch umgesetzt werden können. Dazu zählt auch die Bildwahrnehmung. In den Neurowissenschaften gibt es ebenfalls keine einheitliche Theorie der Wahrnehmung. Dennoch erklären die existierenden Theorien und Modelle bestimmte Teile der Wahrnehmung und helfen damit, den Gesamtkomplex besser verstehen zu lernen. Diese Ansätze können in Form von Theorien und Algorithmen für die Auswertung von Fernerkundungsdaten angewendet werden, wenn es darum geht, komplexere Zusammenhänge aus Rasterbildern zu extrahieren.

Das menschliche Sehvermögen kann, auch im Kontext der Satellitenbildauswertung,

als Prozess verstanden werden, der Bilder aus der externen Welt nutzt und in eine, für Menschen nutzbare Beschreibung umwandelt und dabei irrelevante, störende Informationen ausblendet (nach MARR (1982)). Das Ziel eines Bildverständnissystems ist deshalb die **Objektidentifikation** und die **Ermittlung seiner Bedeutung**. Diese Transformation von der einen Repräsentation (beispielsweise physikalische Signale) in die andere Repräsentation (Symbole) innerhalb der Bild-Domäne ist eine der wichtigsten und schwierigsten Aufgaben in dem Bereich der *Künstlichen Intelligenz*. Die biologischen Aufnahme- und Verarbeitungssysteme unterscheiden sich signifikant von denen elektronischer Systemen. Deshalb kann der Prozess trotz Analogien (CCD-Array – Retina, Computer – Gehirn) nicht direkt, geschweige denn vollständig umgesetzt werden. Trotzdem kann die Prozesskette an sich adaptiert und angewendet werden. Für die aufgenommenen Intensitäten spielen vier Faktoren eine

Rolle: Geometrie, Reflektion des Objektes, Beleuchtung und Blickpunkt. Bei der Auswertung von Satellitenbildern erleichtern die bekannte Geometrie, der Blickpunkt und die eingeschränkte Thematik die Analyse. Diese Vereinfachung ermöglicht erst die automatisierte Auswertung von Fernerkundungsdaten.

Verständnis von Bildwahrnehmung

In der Arbeit von MARR (1982) werden eine Reihe von physikalischen Annahmen (Tabelle 2.5) aufgestellt, wie Bilder repräsentiert werden können. Auf diesen Thesen aufbauend, stellt er seine Theorie auf. Als Basiselement dienen dazu Intensitätsänderungen in der Bilddomäne. Durch diese Änderungen ergeben sich unterschiedliche Oberflächen, basierend auf Muster und Texturen auf verschiedenen Maßstabsebenen (extrahiert durch unterschiedliche Hoch- und Tiefpassfilter). Diese Muster werden durch Platzhalter (*place tokens*) ersetzt, um die gewonnenen Informationen (Richtung, Texturdichte, etc.) zu erhalten. Zu den Platzhaltern zählen Ecken / Grenzen, Balken und Anhäufungen. Das Bild wird dadurch in ein einfacheres Schema (*primal sketch*) transformiert. Der Hauptvorteil bei diesem Bearbeitungsschritt liegt in der weiteren Betrachtung des vereinfachten Schemata an Stelle des realen Objektes. Damit wird die Komplexität der realen Objekte und ihrer Konfigurationen in einem hohen Maße simplifiziert. Aus den Intensitätsänderungen durch die Beleuchtung werden räumliche Informationen gewonnen. Aus deren Kombination mit dem vereinfachten Schemata entsteht ein $2\frac{1}{2}$ -D Schema, das mit gelernten 3-D Modellrepräsentationen verglichen werden kann.

Anstatt einer 3-D Repräsentation von Objekten wird für eine CORINE LC Klassifikation die flächenhafte Repräsentation von bestimmten Klassen der Landbedeckung resp. Landnutzung benötigt. Dabei können Objektbestandteile (beispielsweise Flächen mit *einfachen* Landbedeckungsklassen, wie Wasser, offener Boden, Vegetation etc.) in einem hierarchischen Klassifikationsprozess als Platzhalter dienen. Diese Platzhalter fließen in der weiteren Prozessierung als bildunabhängige Merkmale in die Klassifikation mit ein und sind damit die Grundlage für ein bildunabhängiges Regelwerk (Klassenrepräsentation).

Wiedererkennung durch die Komponenten

Auf dem Modell von MARR (1982) aufbauend, entwickelte BIEDERMAN (1987) die Idee der Objekterkennung durch Zerlegung der Objekte weiter. Dabei definierte er analog zu MARR drei Basiseigenschaften (siehe Tabelle 2.6), die ein Bildverständnissystem erfüllen sollte. Sein ROC-Modell (*Recognition-by-Components*) basiert auf der Annahme, dass beliebige Objekte durch eine kleine Untermenge von Bildprimitiven repräsentiert werden können. Diese kleinsten Informationseinheiten, **geons** (*geometrical ions*) genannt, können nach Skalierung und Transformation zu beliebig komplexen Objekten kombiniert werden. Die Objektkennung liegt damit in der Erkennung dieser Komponenten. BIEDERMAN identifizierte 36 verschiedene *geons*. Dabei dienen geometrische Körper, wie Kegel, Zylinder, Quader usw. als Grundform. Durch Kombination von nur zwei *geons* können über 74.000 Objekte generiert werden. Analog zur menschlichen Sprache genügen nach




Abbildung 2.5: Angenommene Prozessierungsschritte im ROC-Modell zur Objekterkennung (verändert nach Biederman (1987))

MARSLÉN-WILSON UND TYLER (1980) 44 Phoneme, um den kompletten englischen Wortschatz wiedergeben zu können, beziehungsweise 55 Phoneme für alle Sprachen weltweit. Durch Kombination und Abänderung (Aussprache und Betonung) dieser Basiseinheiten entsteht ein großes Potential an Möglichkeiten, um komplexere Informationen zu repräsentieren. Dieses Potential kann auch für die Repräsentation der CORINE LC Klassen genutzt werden, da alle Klassen durch eine Kombination von wenigen Basiseinheiten zusammengesetzt werden können. Dabei gelten die Eigenschaften aus Tabelle 2.6 auch für eine CLC Klassifikation, um eine automatische Prozessierung zu ermöglichen. Komplexe Regelwerke sind in den seltensten Fällen übertragbar, da die getroffenen Regeln ei-

ne regionale Klasse gut beschreiben können, aber nicht für größere Datensätze verwendet werden können aufgrund der fehlenden Generalisierung. Zur Identifikation der CLC Klassen werden keine Merkmale benötigt, die invariant zur Lage oder Orientierung sind (ROC-Modell versucht, das räumliche Bildverständnis zu erklären). Analog benötigt die Klassifikation von CORINE LC sensorunabhängige und zeitlich invariante Merkmale. Darunter fallen alle semantischen Merkmale, wie Basislandbedeckung, Bedeckungsgrade, zeitliche Charakteristiken und Formmerkmale. Einfach strukturierte Regelwerke und invariante, stabile Merkmale ermöglichen die Identifikation von Objekten, auch wenn nicht alle Merkmale zur Verfügung stehen.

Tabelle 2.6: Basisphänomene der Objekterkennung nach BIEDERMAN

Phänomen 1 (Einfachheit) *Der Objektrepräsentation sollte so einfach, wie möglich umgesetzt sein, damit die Entscheidungsprozess nicht langsam und fehleranfällig ist..*

Phänomen 2 (Merkmale) *Der Entscheidungsprozess basiert auf Informationen, die relativ invariant zur Lage, Orientierung und (leichten) Veränderungen sein sollten..*

Phänomen 3 (Unvollständigkeit) *Das Prinzip der Objekterkennung sollte unabhängig von der Vollständigkeit des abgebildeten Objektes sein..*

BIEDERMAN (1987) unterteilt den Prozess der Objekterkennung in mehrere, kaskadenhafte Subprozesse auf (siehe Abbildung 2.5). Die Segmentbildung geschieht durch Kantenextraktion, um invariant gegen Beleuchtungs-, Textur- und Farbeffekte der Objektoberfläche zu sein. Im anschließenden Schritt werden essentielle Eigenschaften der Segmente, wie z.B. Kolinearität, Kurvenverhalten und Symmetrie untereinander extrahiert. Diese Eigenschaften beeinflussen die Kantenextraktion rückwirkend (*top-down* Prozessierung). Damit basiert die Segmentierung auf den Eigenschaften des Objektes und nicht auf gelernen Objekten. Die Merkmale werden auf Segmentebene und für daraus entstehende homogene Bereiche (konkave Einheiten) generiert. Jede segmentierte Region wird einem *geon* annäherungsweise durch Eigenschaften der Kanten, wie Kurvenverhalten, Kolinearität, Parallelismus, Symmetrie und Koterminierung zugeordnet. Diese Komponenten sind einfache, 3-dimensionale, meist symmetrische Körper (Kegel, Zylinder, Quader und Hyperellipsen), die rotiert, transformiert und skaliert werden können. Sie bestimmen die einzelnen Bestandteile des Objektes. Die gefundenen Komponenten können strukturell beschrieben werden — *geon structural description* (GSD). Diese Beschreibung beinhaltet Informationen über die einzelnen *geons*, deren Eigenschaften und ihren Relationen untereinander. Über einen Vergleich mit der Wissensbasis durch ein adaptiertes künstliches neuronales Netzwerk können ähnliche Repräsentationen gefunden werden, dem das Objekt zugeordnet werden kann. Bei dem Ansatz wird theoretisch angenommen, dass der Vergleich parallel und mit unbegrenzter Kapazität stattfinden kann. Dadurch kön-

nen auch unvollständig wahrgenommene Objekte erkannt und einer Gruppe zugeordnet werden.

Wenn das Objekt mit den notwendigen Informationen aus dem Bild extrahiert ist, erfolgt der zweite Schritt der Objektwahrnehmung: die **Identifikation** bzw. die **Kategorisierung** auf Basis einer vorhandenen Wissensbasis. Diese *a-priori* Wissensbasis legt fest, welche Gruppen und Klassen erkannt werden können. Ohne diese Repräsentation können Objekte nur durch ihre Eigenschaften beschrieben werden. Die Abstraktion vom Objekt zu einer Objektgruppe (Klasse) wird durch die folgenden Theorien von SELFRIDGE und EDELMAN näher beschrieben. Der erste Ansatz benutzt ein hierarchisches Netzwerk zur Speicherung von Informationen. Das weiterentwickelte Modell von EDELMAN verwendet die Ähnlichkeit innerhalb einer Klasse zur Zuweisung eines Objektes. In dieser Arbeit wurden beide Ansätze berücksichtigt.

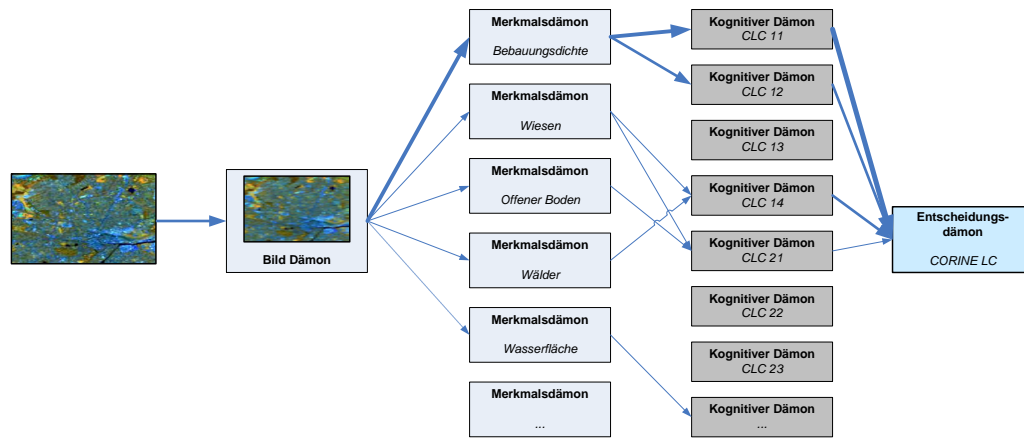
SELFRIDGE (1959) stellt ein einfaches Modell vor, dass Merkmalsgenerierung und Objektrepräsentation in einer netzwerkartigen Struktur zusammenfasst. In Anlehnung an das Werk *Paradise lost* von JOHN MILTON symbolisieren Dämonen als gekapselte Funktionen (Merkmalsextraktion, Klassifikation) in einer strengen Hierarchie die einzelnen Komponenten. Jede Domäne (Bild, Merkmale, Klassifikation und Entscheidung) ist hierarchisch hintereinander geschaltet. Die Verarbeitung innerhalb einer Domäne erfolgt unabhängig von anderen Prozessen. Die Information mit den stärksten „Reiz“ führt zu der Entscheidung (Klassifikation), welche Klasse dem Objekt zugewiesen wird. Das *Pandemonium-*

Modell zeichnet sich durch parallele Verarbeitung, Konnektivität und adaptiertem Lernverhalten aus. Es besteht aus vier getrennten Ebenen mit jeweils unterschiedlichen Funktionen: Bildbeschreibung, Merkmalsgenerierung, kognitiver Selektion und Identifikation. Die Verbindungen zwischen den Schichten sind gewichtet und statisch. Beim Lernprozess werden die Gewichtungen in Abhängigkeit des Klassifikationsergebnisses iterativ durch viele Beispiele optimiert. Ein genetischer Algorithmus kann selten benutzte Funktionen durch neu mutierte bzw. zusammengesetzte ersetzen. In Abbildung 2.6(a) wird der Klassifikationsverlauf für die CLC Klasse 11x: *Siedlungen* dargestellt. Die Bildanalyse zerlegt das Bild in zahlreiche Merkmale und gibt diese Information an die nächste Schicht weiter. In Abhängigkeit zum Eingangsreiz beeinflusst die Merkmalschicht die anschließende Filterung der Signale. Die Signalstärke entscheidet letztendlich über die Identifikation. Der Vorteil des *Pandemonium*-Modelles liegt in der Einfachheit seiner Struktur. Der statische Aufbau limitiert das Modell jedoch in seinem Abstraktionsverhalten. Prinzipiell erhöhen die verwendeten Merkmale die Komplexität des Modells. Dies führt zu Verlusten in der Abstraktionsfähigkeit und kann die Stabilität der Klassifikation verringern. Verbesserungen des Modells wurden von JACKSON (1987) durchgeführt, der die statischen Hierarchien durch dynamische Gruppen ersetzte.

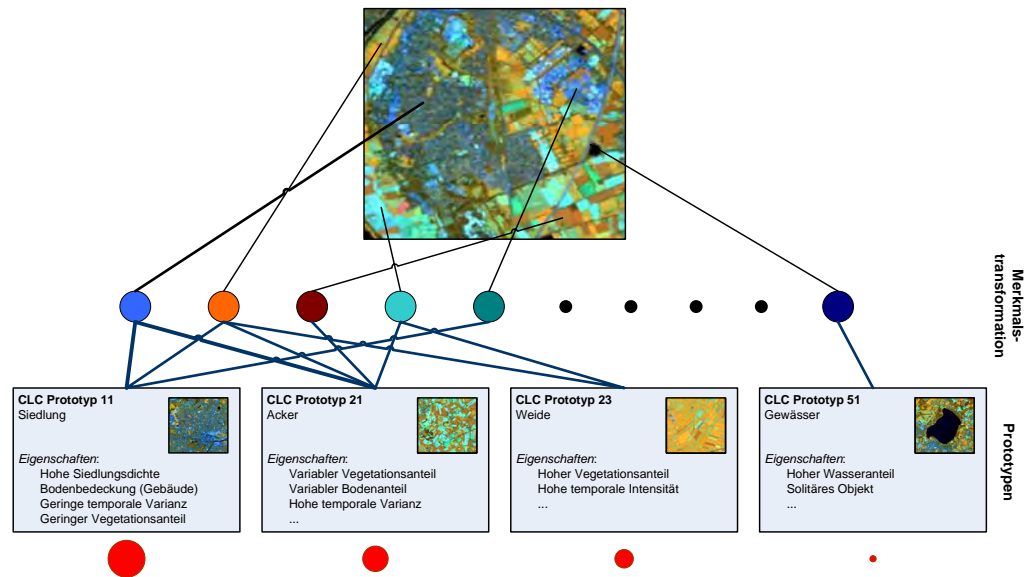
Der entscheidende Punkt bei der Objekterkennung liegt in der Repräsentation der Objekte (EDELMAN, 1995, p.45). EDELMAN stellt in seiner Arbeit einen rechenbasierten Ansatz vor, der auf der Verwendung von Ähnlichkeiten der Objekte in

Form von **Prototypen** basiert. Gleichartige Objekte werden durch eine kleine diverse Menge von Prototypen repräsentiert. Der Begriff des Prototypen wird in diesem Zusammenhang als *abstrakte Gruppe von Objekten mit gleichen Merkmalen* definiert. Der Stimulus wird durch Merkmalstransformation in einen hochdimensionalen Bewertungsraum projiziert. Anschließend wird er, je nach Ähnlichkeit, einen oder mehreren Prototypen zugewiesen. Dies führt zu einer Reduktion des Merkmalsraums für die Zuweisung, da der Repräsentationsraum oder Merkmalsraum nicht mehr durch die einzelnen Objekteigenschaften im Bewertungsraum, sondern durch die Prototypen im Merkmalsgruppen aufgespannt wird.

Dreidimensionale Objekte werden im Repräsentationsraum ihrer Form nach abgelegt. Ähnlichkeiten werden über bestimmte Metriken, wie Distanzmaße, errechnet. Die Ähnlichkeiten unterteilen sich in drei Ebenen: Basis-, untergeordnete und übergeordnete Ebene. Dadurch können Relationen zwischen Objektklassen abgebildet werden. Informatisch gesehen können Merkmalsgruppen selbst als einzelne Klassifikatoren angesehen werden. Eine neue Kategorie kann durch Referenzobjekte erlernt werden. Dabei wird ein neuronales Netzwerk für jeden Blickpunkt trainiert. Die Kategorisierung findet durch das Aktivitätsmuster des Netzwerkes und dem daraus resultierendem Prototypen statt. Als Beispiel für diesen Sachverhalt dient die Identifikation einer Siedlungsfläche in Abbildung 2.6(b). Der maximale Ausgangsreiz wird nach der Merkmalstransformation der CLC Klasse 11: *Städtisch geprägte Flächen* zugewiesen.



(a) Pandemonium-Modell von SELFRIDGE



(b) COP-Modell von EDELMAN

Abbildung 2.6: SELFRIDGE stellte sich vor, dass die Objektidentifikation durch mehrere Gruppen von funktionalen Komponenten (Dämonen) gelöst werden könnte. Jede Gruppe ist hochspezialisiert und mit bestimmten Dämonen aus anderen Gruppen verbunden. Die eigentliche Klassifikation wird durch den Entscheidungsdämon getroffen basierend auf der höchsten Signalstärke. Das *Chorus of Prototypes*-Modell hingegen nutzt die Ähnlichkeit von Objektgruppen aus, um neue Objekte einer Kategorie zuzuordnen. Die einzelnen Objektgruppen werden durch Prototypen realisiert, um den Repräsentationsraum (Merkmalsraum) zu minimieren. Im Gegensatz zum Pandemonium-Modell bestimmt nicht der stärkste Reiz die Klassifikation (Entscheidung), sondern alle Reize (rote Kreise).

Im Gegensatz zum chaotischen Pandemonium-Modell werden die Merkmalsgruppen (Chor der Prototypen) gleichberechtigt verwendet. Die Verringerung des Repräsentationsraums führt zu einer effektiveren und schnelleren Verarbeitung der Reize. Objekte werden jedoch nicht nur durch visuelle Reize (Form, Farbe oder Komposition) repräsentiert, sondern viele weitere gelernte Eigenschaften und Empfindungen werden mit diesen Objekten assoziiert, wie RIESENHUBER UND POGGIO (2000) dies richtig erwähnen.

Welchen Nutzen kann die Fernerkundung aus der menschlichen Bildwahrnehmung ziehen ?

Die Bildwahrnehmung ist ein komplexer Prozess, der bis jetzt durch kein einzelnes Modell erklärt werden kann. Die Modelle helfen jedoch zu verstehen, wie Bildwahrnehmung funktionieren kann. Alle genannten Theorien versuchen immer die umfassende, hauptsächlich dreidimensionale Objekterkennung des Menschen zu erklären. Für die Klassifikation von Bildern werden die komplexen Formanalysen jedoch nicht benötigt, da keine dreidimensionalen Körper rekonstruiert werden müssen. Vielmehr beschreibt die spektrale Reflexionscharakteristik und eine Vielzahl von weiteren Merkmalen die Landoberfläche exakter, da durch die Mischpixelproblematik die unterschiedlichen diskreten Landschaftselemente in eine kontinuierliche multispektrale Rastermatrix abgebildet werden. Im folgendem Abschnitt werden die einzelnen Theorien auf die Problemstellung abgebildet, um CORINE LC Objekte aus Fernerkundungsdaten ableiten zu können.

Fernerkundungsdaten sind das Ergebnis einer zweidimensional projizierten Digitalisierung der Erdoberfläche. Sie bilden Oberflächenobjekte spektral und geometrisch in Abhängigkeit des verwendeten Sensors ab. Deshalb werden Objekte in den seltensten Fällen unverändert übernommen, sondern bilden neue, übergeordnetere Oberflächenstrukturen. Diese zweidimensionalen Oberflächentypen repräsentieren auf der untersten Maßstabsebene die verschiedenen Landbedeckungs- und Landnutzungsklassen. Das Klassifikationssystem wird demnach an diesen zweidimensionalen Oberflächentypen trainiert. Durch Veränderung des Betrachtungsmaßstabes können Objekte neue Strukturen bilden, die wiederum für eine Identifikation verwendet werden können.

Die Aspekte aus Tabelle 2.7 erweitern die physikalischen Annahmen von MARR (1982) und dienen als Grundlage für das entwickelte Konzept. Die genannten **Vereinfachungen** und **erweiterten Annahmen** ermöglichen die automatisierte Klassifikation von CORINE Land Cover. Sie bilden damit die Grundlage für den Klassifikationsrahmen der Software. Die Klassifikation von CORINE Objekten basiert auf der spektral eindeutigen Abgrenzbarkeit von anderen Objekten. Die Objekte auf der Oberfläche werden je nach Auflösung des Sensors und des verwendeten Maßstabs zu neuen Objekten aggregiert (Häuser und Straßen zu Wohngebieten). Diese Objektprimitiven bilden die unterste Stufe für die Klassifikation und Identifikation. Die Klassifikation dieser Primitiven durch eine Wissensbasis baut auf dem Ähnlichkeitsprinzip (Annahme 3 von MARR (1982)) auf. Es wird davon ausgegangen, dass bei den ein-

Tabelle 2.7: Eigene Erweiterungen der physikalischen Annahmen zur Klassifikation von CORINE Land Cover

Annahme 1 (Landbedeckung) Die Erdoberfläche wird von unterschiedlichen Klassen der Landbedeckung abgedeckt. Dabei bilden Flächen mit homogenen Eigenschaften sogenannte **Landbedeckungsobjekte**.

Annahme 2 (Landnutzung) Je nach anthropogener Funktion kommt zur Landbedeckung die Landnutzung als unabhängige Dimension hinzu. Diese Funktion kann durch unterschiedliche Intensität der anthropogenen Nutzung Einfluss auf die Charakteristik der Landbedeckung haben.

Annahme 3 (Bildprimitiven) In Anlehnung an die geometrischen Bildprimitiven von BIEDERMAN besteht das Bild aus homogenen Flächen mit der gleichen Landbedeckung. Diese Primitiven werden *visions (visible ions)* genannt.

Annahme 4 (CLC Methodologie) Die CORINE Land Cover Klassen werden durch verschiedene Gruppen von Landbedeckung und -nutzung aufgebaut und werden durch **CLC Objekte** abgebildet.

Annahme 5 (Generalisierung) Durch die CLC Interpretationsvorschrift werden Objekte kleiner 25 ha durch die flächenhaft dominante Klasse (Majorität) oder bestimmte Sammelklassen (Heterogene Landwirtschaftliche Flächen) berücksichtigt.

Annahme 6 (Veränderungen) Veränderungen im Datensatz zwischen 1990 und 2000 entstehen durch Veränderungen der Oberfläche bzw. der anthropogenen Funktion einer Oberflächenstruktur. Die Mindestgröße für CLC Veränderungsobjekte beträgt 5 ha.

zelenen Oberflächentypen ähnliche Prozesse auftreten.

2.4.2 Objekterkennung

We look at the world under various grain sizes and abstract from it only those things that serve our present interests.

HOBBS (1985, S. 542)

Eine der grundlegenden Eigenschaften der menschlichen Objekterkennung ist die Anpassung des Auswertungsmaßstabes an die jeweilige Fragestellung. HOBBS (1985)

führte dazu in seiner Arbeit zur Wissensrepräsentation den Begriff der *Granularität* ein. Der Begriff beschreibt das Konzept zur Beschreibung der strukturellen Komplexität der Welt. Anstatt einer globalen Theorie können viele lokale Theorien das Gesamtphänomen eindeutiger beschreiben. Diese Einzeltheorien ermöglichen einen *Granularitätsebenenwechsel*, d.h. eine Vereinfachung und Reduktion der Information zur effektiveren Planung und Repräsentation des Wissens. Dieses Konzept kann um die folgenden Aspekte Dimensionalität, Granularitätsgröße und Granularitätsebenen erweitert werden (HOBBS, 1985).

- a) *Dimensionalität:* Vegetation kann unter anderem durch den NDVI (eine Dimension) repräsentiert werden. Um ver-

schiedene Vegetationstypen weiter differenzieren zu können, werden spektrale Informationen für eine Klassifikation genutzt. Die Trennung von anthropogen extensiv und intensiv genutzten Vegetationsflächen benötigt Aussagen über den zeitlichen Verlauf des Eingriffs als weitere Dimensionsebene. Der benötigte Grad der Dimensionalität wird somit durch die Aufgabenstellung vorgegeben.

- b) *Granulatsgröße*: In der Fernerkundung können unterschiedliche Oberflächentypen von Objekten abgeleitet werden. Diese Oberflächen können je nach Eigenschaft *granularitätsabhängig* sein. Offener Boden besitzt bei allen Aufnahmemaststäben (30 cm bis 500 m und darüber) der FE Systeme die gleichen Materialeigenschaften und ist damit unabhängig zur Granularität. Heterogen aufgebaute Oberflächen, wie Waldflächen und Siedlungen besitzen, je nach Maßstab einen unterschiedlichen Detailgrad. Je nach Granularitätsebene können Häuser, Stadtteile und Siedlungsgebiete unterschieden werden.
- c) *Ununterscheidbarkeit und Granularitätsebenen*: Auf einer spektral oder geometrisch höher aufgelösten Granularitätsebene können ähnliche Objekte zu einem Objekt zusammengefasst werden, ohne einen Verlust der Information zu riskieren.

Zusammenfassend erlaubt die Theorie der Granularität nach HOBBS (1985) *eine Reduktion der Komplexität und die Anpassung der Repräsentation von Objekten an eine bestimmte Aufgabenstellung*. Diese Fähigkeit zur Abstraktion wird für den Prozess der Objekterkennung mit seinen Unteraufgaben

Identifikation und **Kategorisierung** benötigt (PALMERI UND GAUTHIER, 2004; RIESENHUBER UND POGGIO, 2000). Unter der **Identifikation** versteht man die eindeutige Zuordnung eines Objektes zu einer Klasse. Sie benötigt dafür Merkmale zur Unterscheidung und die Eigenschaft der Generalisierung (Veränderung der Form durch Translation, Rotation und Skalierung). Das Objekt *Frankfurter Flughafen* kann zum Beispiel durch seine Lage in Relation zur Stadt Frankfurt oder seinem Aufbau (Konfiguration der Landebahnen und Terminals) eindeutig identifiziert werden. Die **Kategorisierung** hingegen trifft eine Entscheidung über die Klassenzugehörigkeit eines Objektes. Eine weitreichendere Generalisierung und stabile Merkmale sind dafür erforderlich. Die Klasse *Flughäfen* besitzt im Vergleich zu anderen Klassen beispielsweise mindestens eine Landebahn. Beide Aufgaben sind Teile der Generalisierung auf verschiedenen Ebenen.

Um Objekte zu erkennen, werden sie identifiziert oder kategorisiert. Dazu muss die visuelle Repräsentation mit gespeichertem Wissen verglichen werden. Es existieren verschiedene Modelle, um zu erklären, auf welche Weise das Hintergrundwissen im Gehirn abgelegt ist. Grundsätzlich wird unterschieden, ob die Informationen prototypenhaft (*structural description models*) oder bildbasiert (*image based models*) abgelegt sind (PALMERI UND GAUTHIER, 2004). Weiterentwickelte Modelle verwenden beide Techniken, um die Blickpunkt-spezifischen (durch Bildvergleich) und Bildpunkt-invarianten (Verwendung von Prototypen) Eigenschaften zu nutzen, um Objekte zu repräsentieren. Dazu werden die Objekte in einem multidimensionalen

Merkmalsraum abgelegt und mit neuen Objekten verglichen. Die Ähnlichkeit errechnet sich aus dem Abstand im Merkmalsraum zwischen den einzelnen Objekten. Die zweite Herangehensweise ist das Speichern von Prototypen, die einzelnen Objektgruppen entsprechen. Neue Objekte werden mit den gespeicherten Prototypen verglichen und kategorisiert. Der Vorteil der Strukturbeschreibungsmodelle liegt in der einfacheren Repräsentation von umfangreichen Objektgruppen. Einzelne CLC-Klassen brauchen nur einmal als Prototyp abgelegt werden. Das auf Beispielen basierende Modell benötigt dagegen viele unterschiedliche Objekte, um ausreichend kategorisieren zu können.

Informationsebenen in Bildern

Die Tabelle 2.8 zeigt, dass die pixelbasierte Bildauswertung nur die unterste Informationsebene (**Pixel-Ebene**) berücksichtigt. Damit können schon viele Landbedeckungsklassen mit herkömmlichen Verfahren für den einzelnen Pixel bestimmt werden. Parameter über Textur und Pixelverteilungen können nur aus statischen Bereichen mit fester Fenstergröße (*Kernel*) abgeleitet werden. Die abgeleiteten Ergebnisse sind deshalb stark skalenabhängig. Die **Segmentebene** ermöglicht die Klassifikation auf Basis von flächenbezogenen Pixelverteilungen (gewonnen aus dem Segment) und ist damit abhängig von der radiometrischen und geometrischen Auflösung des verwendeten Sensors. Bei einer Klassifikation werden Pixelausreißer eliminiert und die Fehlklassifikation durch die Mischpixelproblematik vermindert. Zusätzlich stehen weitere Parameter, wie Textur, Größe, Ausrichtung im Raum und Form zur Verfügung.

Die aus dem Segment gewonnenen Texturparameter repräsentieren im Gegensatz zu festen Kernelgrößen das korrekte flächenhafte Bodenbedeckungsobjekt. Die inhaltliche Zuweisung der Klassen erfolgt am Ende der Klassifikation. Dadurch unterscheiden sich Segment-Ebene und **Objektebene** voneinander. Diese Geoobjekte besitzen immer eine Semantik, die durch ein oder mehrere Attribute (Merkmale oder Variablen) vertreten werden (DE LANGE, 2002, S.163). Bevor Objekte klassifiziert werden können, müssen sie zuvor beschrieben bzw. definiert werden (Aufbau des *a-priori* Wissens). Ein See ist zum Beispiel für den Klassifikator ein flächenhaftes Segment, das hauptsächlich vom Oberflächentyp *Wasser* bedeckt wird. Ein CLC Objekt kann dabei ein einzelnes homogenes Landbedeckungsobjekt darstellen (Abb. 2.7(a)) oder durch Subobjekte (beispielsweise Landebahnen, Terminalkomplexe, Grasflächen) heterogen aufgebaut sein. Diese bilden zusammen das Superobjekt — in diesem Falle das CORINE Objekt 124: *Flughafen* (Abb. 2.7(b)).

Die nächste semantische Ebene (**Klassen-Ebene**) fasst ähnliche Objekte (*Großer Müggelsee, Wannsee, Tegernsee, Bodensee, usw.*) zu Klassen zusammen; in diesem Fall zu der Klasse *Deutsche Seen*. Dadurch lassen sich Nachbarschaftsbeziehungen, räumliche Verteilungen und Muster zur Identifikation von größeren Räumen nutzen. Seen besitzen oft einen Zu- bzw. Abfluss. Flughäfen liegen in unmittelbarer Nähe zu größeren Siedlungen, etc. Die **Landchaftsebene** als höchste Abstraktionsform wird durch eine bestimmte Objektkomposition definiert. Sie kann jedoch nur in Ausnahmefällen, wie bei der Höhenzonierung,

Tabelle 2.8: Die Tabelle nennt die verschiedenen Informationsebenen in einem Bild. Je höher der Informationsgehalt ist, desto komplexer ist der Informationstyp und dessen Auswertung für eine Klassifikation.

	Ebene	gewonnen aus	Informationstyp
Bild-Ebene	Pixel Ebene	Spektrale Pixeldaten	Farbwert Helligkeit, Sättigung Textur (Kernelgröße)
	Segment-Ebene	Spektrale Pixeldaten Form	Textur (adaptiert) Größe (absolute) Kompaktheit
Semantische Ebene	Objekt-Ebene	Form Segmente	Größe (relative) Kompaktheit Segmentmuster
	Klassen-Ebene	Objekte	Muster der Objekte Räumliche Verteilung Nachbarschaft Konnektivität
	Landschafts-Ebene	Klassen, Objekte	Räumliche Verteilung Diversität



(a)



(b)

Abbildung 2.7: CORINE Objekte können in Bildobjekte oder Bildsegmente zerlegt werden. Abb. 2.7(a) zeigt den *Großen Müggelsee* südöstlich von Berlin, der durch ein einzelnes Bildobjekt repräsentiert werden kann. Der Flughafen *Tegel* (Abb. 2.7(b)) hingegen beinhaltet die einzelnen Bildobjekte: Startbahnen, Flughafengebäude und die umliegenden Grünflächen (rot hervorgehobene Fläche). Die Ausschnitte stammen aus dem **Image 2000** Datensatz.

scharf von anderen Einheiten abgegrenzt werden.

Unterschiedliche Repräsentation von Objekten

Objekte haben ein unterschiedliches Erscheinungsbild, das je nach Aufgabenstellung, Betrachtungsweise und Hintergrundwissen des Interpreten ausgewertet werden kann. Diese hochdynamische Charakteristik von Objekten verdeutlicht Abb. 2.8. Ein Teil des Terminalkomplexes aus Abb. 2.8(a) mit der Hintergrundsilhouette von Frankfurt kann durch *a-priori* Wissen mit dem Frankfurter Flughafen verknüpft werden. Abbildung 2.8(b) ist ein Ausschnitt aus einer multispektralen Landsat ETM+ Szene (Kanalkombination NIR-SWIR1-R für die Grundfarben Rot, Grün und Blau). Das Bild wurde räumlich um den Faktor 0.1 auf 250 m Pixelgröße aggregiert. Nach einer Interpretation des Objektes als Klasse *Flughafen* durch einen menschlichen Interpreten kann der vorherigen Ausschnitt durch die CORINE Klasse 124: *Flughafen* repräsentiert werden (Abb. 2.8(c)). Die letzte Abbildung stellt das Logo des Flughafenbetreibers dar, das mit dem nötigen Hintergrundwissen ebenfalls dem Frankfurter Flughafen zugeordnet werden kann.


Diese hohe Variabilität der Darstellungsformen von einem Objekt wird in Fernerkundungsdaten nicht erreicht. Die Sensoreigenschaften (spektrale, radiometrische, temporale und geometrische Auflösung bei FE-Sensoren) geben den Rahmen vor, wie Objekte in einem Bild identifizierbar sind. Das heißt, dass die Objekte einzeln aufgelöst oder diskret von umliegenden Objekten

trennbar sein müssen. Im Idealfall sind dabei noch Objektbestandteile oder Unterobjekte erkennbar (ATKINSON UND CURRAN, 1995). Für die genannten Sensoreigenschaften gilt das **WKS-Sampling-Theorem** nach WHITTAKER, KOTELNIKOW und SHANNON, auch **Nyquist-Shannon Abtasttheorem** genannt, aus dem Jahr 1948. Dieses Theorem besagt, dass ein Signal mit der Maximalfrequenz f_{max} mindestens mit einer Frequenz von $2f_{max}$ abgetastet werden muß, um das Ausgangssignal ohne Informationsverlust rekonstruieren zu können. Die daraus folgende *Nyquist-Frequenz* lautet $1/2f_{abtast}$. Das Abtasttheorem gilt analog auch für andere Signale (z.B. Pixel in Bildern). Die gerechnete geometrische Auflösung der Image2000 Daten (25 m für multispektrale Kanäle, 12.5 m für den panchromatischen Kanal) ermöglicht die Extraktion von Objekten mit der Größe von 50 m. Die theoretische Mindest-Objektgröße beträgt dabei ca. 0.6 ha, um reine Spektren für die Klassifikation zu bekommen (siehe Abbildung 2.4 zur Mischpixelproblematik). Neben der Lage der Objekte im Pixel beeinflusst das Sensorelement selbst über die Punktverbreitungsfunktion (PSF oder *point spread function*) das Signal im Pixel, da die Abtastung der Oberfläche ungefähr einer zweidimensionalen Gauss-Kurve entspricht.


Neben der entsprechenden Wiedergabe durch den Sensor müssen Objektklassen eindeutig beschrieben werden können. Dies erfordert eine Analyse der CLC Klassen in Abhängigkeit der zur Verfügung stehenden Daten, der daraus abgeleiteten Eigenschaften (Merkmale) und den Aufbau eines Beschreibungskataloges (*a-priori* Wissensbasis). Diese Wissensbasis beinhal-



(a)



(b)



(c)



(d)

Abbildung 2.8: Das gleiche Objekt kann, je nach Betrachtungsweise und Hintergrundwissen, unterschiedlich dargestellt und repräsentiert sein (Granularitätsebenen des Frankfurter Flughafens). Optische Aufnahmesysteme ermöglichen die Abbildungen 2.8(a) und 2.8(b). CORINE Objekte (Abb. 2.8(c)) entstehen nach einer Interpretation von Fernerkundungsdaten. Das Betreiberlogo (Abb. 2.8(d)) stellt die abstrakteste Form des Objektes dar. Die Abbildungen 2.8(a) und 2.8(d) unterliegen dem Copyright der Fraport AG.

tet nicht nur Informationen und Regeln über die Objekte und Klassen, sondern auch eine Ontologie bzw. Struktur über diese Regeln. Sie kann mit diesen strukturieren Regeln Schlüsse ziehen (inferieren) und damit die Wissensbasis auf ihre Logik hin überprüfen oder neues Wissen ableiten (HAARSLEV *et al.*, 2003).

Einsatz von Hintergrundwissen für die Klassifikation

Sowohl die Struktur der Wissensbasis, als auch die Wissensbasis selbst basieren auf *a-priori* Wissen oder Hintergrundwissen zu einer bestimmten Thematik. Dieses Wissen kann sich nach nach BALTSAVIAS (2003) auf die Zielobjekte und den Kontext der Szene, die Eingangsdaten für die Objektextraktion, die angewandten Prozessierungsmethoden und die Kontrollmechanismen beziehen.

Objektwissen kann spektrale, geometrische, topologische und attributive Informationen beinhalten. Das Wissen über die Eingangsdaten inklusive Metadaten dient zur Ableitung von weiteren Informationen (z.B. Extraktion der Vegetation aus normierten Bandverhältnissen und Ableitung von Schattenparametern aus den Zeit- und Winkeldaten sowie dem Zustand der Vegetation in Abhängigkeit des Aufnahmezeitpunktes). Metadaten können auch Auskunft über die Qualität des Klassifikationsproduktes geben, darunter die Lagegenauigkeit und der atmosphärische Einflüsse im Bild. Das Wissen über die verwendeten Methoden zur Prozessierung basiert auf vorherigen Ergebnisse und theoretischen Überlegungen. Der Einsatz der

Verfahren richtet sich nach der Leistung der jeweiligen Methode, den Eigenschaften der verwendeten Datensätze und der Qualität der gewünschten Ergebnisse. Die Repräsentation des Wissens kann durch informativische Aspekte (z.B. Sprache), Modellierungsaspekte, logische Strukturierung und architektonische Darstellung sowie durch Datenhaltung und Datenmanagement geschehen. Dabei spielt die Repräsentation der Unsicherheit des Wissens eine Schlüsselrolle, um generelle Aussagen ableiten zu können (Abstraktion). Eine wissensbasierte Anwendung zur „intelligenten“ Bildsuche *Image Data Mining* auf Basis von hierarchischen Bayes'schen Netzen wird in den Arbeiten von DATCU UND SEIDEL (2005); DATCU *et al.* (1998) vorgestellt.

Bei der Nutzung von *a-priori* Wissen treten eine Reihe von Problemen auf. Trotz der Entwicklung von unscharfen Grenzen durch ZADEH (1965) werden Entscheidungen durch Computer „hart“ und strikt getroffen. Menschliche Entscheidungsprozesse sind darüber hinaus nicht linear, d.h. einzelne Komponenten können die Entscheidung radikal ändern trotz geringer Wichtigkeit im Gesamtzusammenhang. Das grundsätzliche Problem liegt jedoch in der mangelnden Fertigkeit der Computer, aus vorherigen Prozessen zu lernen. Relevantes Wissen muss also manuell vor der Prozessierung abstrahiert und implementiert werden. Ein Ausweg bieten insbesondere objektorientierte Verfahren an (CHAN, 1996; PIPER, 1998). Probleme können kohärent in Teilprobleme zerlegt werden, die dadurch einfacher lösbar sind. Die Abstraktion durch Klassenhierarchien ermöglicht die Prozessierung von unterschiedlichen Datensätzen (multisensorische Ana-

lysen), da die verwendeten Eigenschaften möglichst sensorunabhängig ein Objekt beschreiben. Dabei sollte die Wissensrepräsentation und das Datenmanagement auf objektorientierten Verfahren basieren, um große Teile der Klassenstruktur und Logik im System direkt abbilden zu können.

Über die Ontologie der Klassifikation von Fernerkundungsdaten

Die *Ontologie* ist eine Teildisziplin der Philosophie (speziell die Metaphysik von ARISTOTELES), die sich mit dem Seienden und der Existenz von Entitäten befasst (JOHANSSON, 1989; SIMONS, 1987). Im Gegensatz zur Epistemologie (*Erkenntnistheorie*) basiert sie nicht auf Möglichkeiten und Grenzen der menschlicher Wahrnehmung und Erkenntnis, sondern auf deren Existenz in der Realität. „*Ontologie erklärt die Beschaffenheit der Welt; Epistemologie erklärt die Beschaffenheit unserer Erfahrung von dieser Welt*“ (VON FOERSTER, 1985). Die Ontologie versucht in einer bestimmten Domäne ihre Bestandteile und dessen Beziehungen untereinander und zu Bestandteilen in anderen Domänen systematisch zu beschreiben und zu ordnen (klassifizieren). Damit schafft sie einen Rahmen für interdisziplinäre Verbindungen zwischen den verschiedenen Wissenschaftsdomänen. Zusammenhänge aus der realen Welt können somit exakter abgebildet oder erklärt und als Information wiedergegeben werden. Die Verwendung von Ontologien unterstützt die Informationserfassung, Informationsverwaltung und das Auffinden von Informationen. Aus diesem Grund wurden für die verschiedenen Domänen (Kategorien), wie zum Beispiel Orte, Landschafts-

formen, Geographie (FONSECA UND EGENHOFER, 1999; FONSECA *et al.*, 2003; TOMAI UND KAVOURAS, 2004), Medizin, Jura und Ökonomie (FONSECA *et al.*, 2002; FRANK, 1997; SMITH UND CASATI, 1994; SMITH UND MARK, 2003), Konzepte entwickelt, die auf einer Ontologie aufbauen. Die Informatik greift ebenfalls auf die Theorie der Ontologie zurück, um Informationen und Zusammenhänge abzubilden (Wissensmanagement, Datenbanken, objektorientierte Programmierung / Modellierung oder Künstliche Intelligenz). Sie ist damit nach GRUBER (1993B) *die Spezifikation von einer Konzeptionierung*. Ein bekanntes Beispiel sind die Ontologien der *Food and Agriculture Organization* (FAO). Diese werden über einen Konzeptserver (FAO, 2006) zur Verfügung gestellt und ermöglichen den Aufbau von redundanzfreien Informationssystemen durch eine standardisierte Terminologie bzw. Vokabular für verschiedene Wissensbereiche in vielen wichtigen Sprachen.

Die Ontologie beschreibt die Konzepte eines Systems in einer bestimmten Anwendungsdomäne. Für diese Arbeit ist die Anwendungsdomäne die Klassifikation von CORINE LC Klassen auf Basis von Fernerkundungsdaten. Diese Anwendungsdomäne kann als Untergruppe der Bilddomäne aufgefasst werden. PEUQUET (1984) sagt über die Dichotomie der Wahrnehmung von Bildern aus, dass räumliche Informationen in Bildern sowohl über kontinuierliche räumliche Variationen (*Feldmodell*) der Pixelintensität, als auch über diskrete Objekte (*Objektmodell*) durch *a-priori* Wissen repräsentiert und damit identifiziert werden können. Ein Beispiel für das Feldmodell ist die Extraktion von topographischen In-

formationen aus Fernerkundungsdaten auf Basis der Geländebeleuchtung bzw. Schattenwurf. Über die räumliche Lage können beide Informationsebenen miteinander kombiniert werden.

Die Objekte bzw. ihre Grenzen (Geometrien) können bei der Erstellung in zwei Gruppen unterteilt werden: *fiat Objekte* (lat. „es werde“) und *bona fide Objekte* (lat. „in gutem Glauben“). Die Objekte der ersten Gruppe zeichnen sich durch ihre rein theoretische Natur aus. Die Objekte grenzen sich durch definierte Eigenschaften „willkürlich“ voneinander ab. Beispiele dafür sind administrative Grenzen und geographische Bezeichnungen, wie das deutsche Staatsgebiet, die Nordsee, das Himalayagebirge und die Sahara. Die zweite Gruppe beinhaltet *real* existierende Objekte mit physikalisch vorgegebenen Abgrenzungen. Hierunter fallen Objekte, wie einzelne Gebäude und Ackerflächen. Für beide Gruppen gelten eine Reihe von Abhängigkeiten und Bedingungen (SMITH UND VARZI, 2000): *Bona fide* Objekte können mittels Fernerkundungsdaten durch ihre physikalischen Eigenschaften, wie das Reflexionsverhalten erkannt werden. Eine Gruppierung der Objekte führt zu einer Klassifikation der Landbedeckung. Die *fiat Objekte* benötigen für die Identifikation neben *a-priori* Wissen zusätzliche Eigenschaften und **eine vorgegebene Geometrie**, um sie erkennen und untereinander abgrenzen zu können. Viele Klassen von CORINE LC gehören durch ihre funktionale Komponente oder durch ihren heterogenen Aufbau in die erste Kategorie. Aus diesem Grund reicht die einfache Beschreibung der Landschaft durch (bio-)physikalische Parameter nicht aus, um diese Klassen hinreichend zu iden-

tifizieren. Die existierende **CLC 1990** Kartierung stellt die Basisgeometrie zur Verfügung, um die Objekte untereinander abgrenzen zu können. Der tatsächliche Verlauf der Grenze kann anschließend durch die spektralen Daten abgeleitet werden.

MONTELLO (2001) definieren durch Fernerkundung gewonnene Bilder *als Instrumente zur Abbildung von landschaftlicher Dynamik* im ontologischen Sinne. Diese Dynamik wird von diversen geographischen Prozessen auf unterschiedlichen zeitlichen und räumlichen Maßstabsebenen verursacht. Sie prägen das physikalische Bild der Landschaft. Es wird ein theoretischer Rahmen definiert, der eine Reihe von Komponenten und Klassen beschreibt, um die unterschiedlichen Bestandteile der Ontologie zu charakterisieren. Dazu zählen

- das Bild,
- Bildsequenzen,
- geometrische Strukturen,
- Bildverarbeitungsfunktionen,
- Bildklassifikationsfunktionen,
- Landschaftsobjekte,
- Ähnlichkeitsmaße,
- die räumliche Konfiguration,
- strukturelle Abgleichung,
- funktionale Abgleichung und
- raum- zeitliche Muster.

Diese Komponenten beschreiben den Datensatz, die durchgeführten Analyseschritte und den extrahierten Inhalt auf eine konzeptionelle Weise. Das System wurde für die Ontologie dieser Arbeit übernommen und an die Problemstellung angepasst. Darauf basierend können folgende Fragen für den Aufbau einer Ontologie gestellt werden:

- Wie sind CORINE Klassen aufgebaut?
- Welche Verarbeitungsschritte sind nötig, um CLC Klassen zu bestimmen?
- Welche Klassen können spektral, temporal, über die Form etc. klassifiziert werden?
- Welche Merkmale aus dem Bild können darüber hinaus abgeleitet werden?

Konzepte bzw. *Klassen*, *Beziehungen*, *Instanzen* und *Axiome* sind essentielle Bestandteile einer formalen Sprache einer jeden Ontologie (GRUBER, 1993A; TOMAI UND KAVOURAS, 2004; USCHOLD UND GRUNINGER, 1996) und sind damit vor ihrem Aufbau zu definieren. Die Einteilung von ähnlichen Objekten in **Klassen** ist eine Abstraktion oder Generalisierung, um Datenstrukturen innerhalb einer Domäne zu vereinfachen. Alle Mitglieder einer Klassen besitzen damit die gleichen Attribute und Funktionen. Durch eine *ist ein/-e*-Beziehung können mehrere Unterklassen zusammen eine Superklasse bilden.

Es gibt nach USCHOLD UND GRUNINGER (1996) mehrere Möglichkeiten, um eine Klassenhierarchie aufzubauen. Wenn eine fertige Hierarchie, wie im Falle von CORINE Land Cover existiert, kann eine **top-down** Entwicklung erfolgen. Die Superklasse *CORINE Land Cover Classes* besteht aus den Klassen der CLC Stufe I (*Siedlungen, Landwirtschaft, Wälder und naturnahe Flächen, Feuchtflächen und Wasserflächen*). Diese setzen sich ihrerseits aus den Klassen der CLC Stufe II und III zusammen. Die verwendeten Klassifikationsmerkmale wurden nach dem **bottom-up** Verfahren erstellt, da nicht alle verwendeten Klassen am Anfang bestimmt und implementiert wurden. Ein Beispiel für diese Vorge-

weise sind die Klassen *Keine Vegetation*, *Mischvegetation* und *Reine Vegetation* aus der Merkmalshierarchie. Sie bilden zusammen die Superklasse *Vegetation*. Diese Klasse beschreibt den Vegetationsanteil im Pixel unter Verwendung eines Vegetationsindex (Beispiel für ein unscharfes Bildmerkmal) und gehört ihrerseits der Superklasse *Spektrale Merkmale* an.

Die **Beziehungen** beschreiben die Interaktionen zwischen Klassen untereinander und den Eigenschaften von Klassen. Sie lassen sich in Taxonomien und assoziative Beziehungen typisieren (WINSTON *et al.*, 1987). Die *is-a* Beziehung baut die Taxonomie auf, d.h. die CLC Klassen 511: *Flüsse* und 512: *Seen* sind *Inlandwasserkörper* (CLC 51x). Assoziative Beziehungen verknüpfen unterschiedliche Konzepte mit einer Eigenschaft. Die CLC Klasse 5xx: *Wasserkörper* hat die Beziehung *hasLCType* zu der Landbedeckungsklasse *Wasser*, d.h. Wasserkörper müssen als Landbedeckungsklasse *Wasser* klassifiziert worden sein.

Instanzen sind einzelne Objekte, die zu Klassen in Abhängigkeit ihrer Eigenschaften gruppiert werden. Die Instanz *Frankfurter Flughafen* gehört zur Klasse CLC 124: *Flughäfen*. Die Ontologie besitzt keine Instanzen, weil sie nur zu einer Konzeptionierung der Domäne dient und nicht zur Beschreibung oder Klassifikation von Instanzen verwendet wird. Erst die Kombination der Ontologie mit assoziierten Instanzen (auch *Wissensbasis* genannt) übernimmt diese Aufgabe.

Das **Axiom** ist eine grundlegende und eindeutige Aussage, die in einer bestimmten Domäne Gültigkeit besitzt. Axiome wer-

den verwendet, um Klassen oder Instanzen durch ihre Beziehungen genauer zu beschreiben. Die CLC Klasse 111 hat zum Beispiel das Axiom *Versiegelungsgrad größer 0,75*. Damit unterscheiden sich die CLC Klassen 111 und 112 durch ihren unterschiedlichen Versiegelungsgrad voneinander.

Validierung des Konzeptes

Für die Erstellung, Visualisierung und Validierung der Ontologie und der Wissensbasis wurde das Programmpaket *Protege* von NOY UND MCGUINNESS (2001) verwendet. Es erlaubt eine einfache Modellierung von Wissensstrukturen und Ontologien. In Verbindung mit der Inferenzmaschine *Racer* von HAARSLEV *et al.* (2003) kann der Aufbau nach inkonsistenten Strukturen untersucht werden. Besonders komplexe Strukturen müssen automatisiert validiert werden, um mehrdeutige Bedingungen zu eliminieren. Zusätzlich kann die Inferenzmaschine die Wissensbasis interpretieren, d.h. auf den Regeln basierend unbekannte Elemente klassifizieren.

Anwendung von Theorien der menschlichen Bildwahrnehmung in der Fernerkundung

In diesem Kapitel wurde der Unterschied zwischen der Landbedeckung und der Landnutzung beschrieben und die Schwierigkeit aufgezeigt, anthropogene Nutzung aus Fernerkundungsdaten zu extrahieren. Die Zusammensetzung des Klassenschlüs-

sels, die umfangreiche Dokumentation und die regelmäßige Aktualisierungsrate des Projektes weisen dem CORINE Land Cover System in Vergleich zu anderen LC Nomenklaturen für diese Arbeit eine hohe Relevanz zu. Existierende Ansätze zur Klassifikation von Fernerkundungsdaten erlauben zur Zeit nicht die automatisierte Verarbeitung von großflächigen und komplexen Datensätzen. Darüber hinaus gibt es keine automatisierte Methodik, um die Landnutzungsklassen der CORINE LC Nomenklatur zu identifizieren. Aus diesem Grund wird ein neues Paradigma, die objektorientierte Klassifikation, angewendet und mit Theorien aus dem Bereich der Wahrnehmungspsychologie kombiniert. Dazu zählen allgemeine Verfahrensweisen von MARR (1982) und BIEDERMAN (1987), um den Prozess der Bildwahrnehmung verstehen zu können und mögliche Prozessierungsschritte zu definieren. Dabei spielen die Unterprozesse *Bildsegmentierung*, *Merkmalsgenerierung* und *der Vergleich des Objektes mit einer gelernten Wissensbasis* eine herausragende Rolle. Die Theorie zur *Wiedererkennung durch Komponenten* beschreibt die Möglichkeit, komplexe Strukturen, wie beispielsweise flächenhafte CLC Objekte durch bestimmte Detailinformationen zu bestimmen. Zu diesen Informationen zählen alle bildinvarianten Merkmale, wie die Landbedeckung, die Objektform, die Nutzungsintensität, usw. Je nach Aufbau und Beschreibung der CLC Klasse verknüpft der resultierende Prototyp die benötigten Merkmale miteinander und ermöglicht damit einen Vergleich zwischen den im Datensatz vorkommenden Objekten und den Referenzklassen aus der CLC Dokumentation. Die *Definition von Prototypen* fordert auf der einen Seite stabile Merkmale, garan-

tiert auf der anderen Seite damit eine Übertragbarkeit des Regelwerks auf eine große Fläche. Im nächsten Kapitel wird auf diesen Theorien und Verfahren aufgebaut und ein Konzept vorgestellt, das in der Softwareumgebung gnosis umgesetzt wurde.

3

Entwickelte Methodik

DIE Automatisierung von thematisch umfangreichen und großflächigen Klassifikationen erfordert einen Paradigmenwechsel in der computerbasierten Auswertung (MADHOK UND LANDGREBE, 2002). Der in dieser Arbeit entwickelte Ansatz bildet die Grundlage für die Entwicklung der Rahmensoftware gnosis. Diese Software nutzt die Eigenschaften der objektorientierten Klassifikation und dient zur Erstellung des CORINE Land Cover Datensatzes. gnosis bedeutet auf griechisch *Erkenntnis, Wissen* und lehnt sich an die mittelalterliche Vorstellung an, die besagt, dass Macht über Mensch und Natur nur über ihren *wahren* Namen (Identität) erlangt werden kann. Dieser *wahre* Name ist die einzigartige Eigenschaft zur Beschreibung eines Individuums bzw. Sache. Übertragen auf das Klassifikationsproblem entscheidet die Kenntnis der genauen – einzigartigen – Eigenschaften und die Beschreibung einer Klasse über den Erfolg, sie aus den Daten extrahieren zu können.

Die Methodologie von CORINE Land Cover basiert auf der Kategorisierung von

Oberflächenobjekten durch prototypenhafte Klassenbeschreibungen. Das erfordert stabile Merkmale für die Generalisierung statt umfangreiche Informationen über Einzelobjekte, die für eine Objektidentifikation notwendig wären. Der detaillierte Klassenkatalog ermöglicht darüber hinaus die Anwendung von überwachten Lernverfahren und die Nutzung von *a-priori* Wissen. Ohne diese grundlegenden Informationen über die Szene müssten unüberwachte Lernverfahren mit statistischen Modellen angewendet werden (EDELMAN UND INTRATOR, 2004). Es folgt eine **Zusammenstellung der adaptierten Merkmale** aus den genannten Theorien der Bildwahrnehmung. Diese Annahmen bilden zusammen die Grundlage für die entwickelte Methodik in diesem Kapitel.

Bildwahrnehmung als rechenbasierter Prozess: MARR (1982) zeigte, dass Bildwahrnehmung als ein rechenbasierter Prozess angesehen werden kann. Seine physikalischen Annahmen aus Tabelle 2.5 bilden dabei die Grundlage für eine Übertragbarkeit der Klassifikation (besonders der Existenz von Oberflächen (Annahme 1), die hierarchische Anordnung von Gruppen oder Klassen (Annahme 2) und die Ähnlichkeit von Objekten mit gleichen Eigenschaften (Annahme 3)).

Repräsentation der Objekte durch Flächen: Die Repräsentation der Objekte durch Pixel führt bei der Prozessierung von flächenhaften Strukturen, wie CLC Objekte, zu einem Informationsverlust bei der Auswertung. Aus diesem Grund müssen Objekte auf Basis ihrer Oberfläche extrahiert

und identifiziert werden (objektorientierter Klassifikationsansatz).

Prozesskette: Der Objektidentifikationsprozess kann in mehrere Subprozesse untergliedert werden. Dazu zählen nach BIEDERMAN (1987) (1) die **Bildsegmentierung**, (2) die **Merkmalsgenerierung** (3) und der **Vergleich** mit gelernten Objektgruppen.

Segmentierung: Die Bildsegmentierung bildet die Grundlage für die Objektidentifikation. Dabei spielen Objektformen die Hauptrolle in der menschlichen Wahrnehmung. Aus diesem Grund werden Verfahren, die auf Kantenextraktion basieren, bevorzugt. Für die Auswertung von Daten aus der Fernerkundung können prinzipiell alle Methoden verwendet werden. Durch die geometrische Degradierung von hochaufgelösten Sensoren (bis 5 m geometrische Auflösung) erzielen regionenbasierte Verfahren jedoch bessere Ergebnisse (ZHANG, 1996).

Merkmalstransformation: In keinem genannten Modell erfolgt die Repräsentation der Objekte durch die spektralen Intensitätsvariationen ihrer Oberflächen. Sie bilden die Grundlage für die Segmentierung und die Extraktion von zusätzlichen Merkmalen, wie Farbe, Form, Lichtverhältnissen, usw. Die geometrischen Eigenschaften der Daten (Generalisierung und Abstraktion auf dem Erfassungsmaßstab 1:100.000) und die CORINE Land Cover Thematik verhindern die Verwendung der Objektform. Deshalb stammen die Basisinforma-

tionen der Objekte hauptsächlich aus den spektralen Informationen.

Zerlegung in die enthaltenen Komponenten: Nach der Theorie von BIEDERMAN (1987) können Objekte durch ihre Merkmale identifiziert werden. In dem ersten Abstraktionsschritt werden komplexe Objekte in einfachere Primitiven (Cluster) zerlegt. Die Topologie und *a-priori* Wissen über gelernte Objektklassen werden genutzt, um Objekte durch ihre Eigenschaften bestimmten Gruppen zuzuordnen. Fast alle CORINE Land Cover Klassen sind aufgrund der geometrischen und thematischen Generalisierung durch aggregierte Landbedeckungs- und Landnutzungstypen aufgebaut. Nach der Zerlegung eines CORINE Land Cover Objektes in seine thematischen Bestandteile kann dieser Cluster aus Landbedeckungs- und Landnutzungsobjekten durch *a-priori* Wissen wieder einer CLC Klasse zugewiesen werden.

Multiskalige Auswertung: Objekte können abhängig von den gefundenen Komponenten auf verschiedenen Maßstabsebenen untersucht werden und damit zu unterschiedlichen Ergebnissen führen. Dieses Maßstabsproblem wird bei der Kategorisierung von CORINE Land Cover Klassen umgangen, indem alle CLC Objekte in ihre kleinsten Bestandteile zerlegt und nach ihren Eigenschaften wieder zusammgebaut werden.

Repräsentation durch Prototypen: Die Objektidentifikation bzw. Kategorisierung baut auf erlerntem Wissen auf, da essen-

tielle Informationen über die Komposition der Gruppen benötigt werden. Die CORINE Land Cover Methodologie definiert die einzelnen Klassen und gibt Vorschriften für die Kategorisierung. Dieser Klassenkatalog kann als Sammlung von prototypenhaften Klassen gesehen werden. Er kann als Grundlage für ein Regelwerk dienen, um Objekte einer CLC Klasse zuzuweisen.

Kategorisierung und Validation: Unter der Annahme, dass alle CORINE Land Cover Klassen der Wissensbasis eindeutig repräsentiert sind, können die CLC-Objekte einer Gruppe zugewiesen werden, die vollständig durch ihre Merkmale beschrieben werden. Fehlen Eigenschaften für die Objektbeschreibung, werden Annahmen für mehrere CLC Klassen getroffen. Im speziellen Fall können bestehende Objekte durch ihre Bestandteile rekonstruiert und damit validiert werden.

Auf dieser theoretischen Basis wird die Software *gnosis* entwickelt und vorgestellt, die den objektorientierten Klassifikationsprozess und das konzipierte Datenmodell informationstechnisch abbildet. Dieser Prozess umfasst die Schritte **Objekterstellung** (durch Bildsegmentierung und Merkmalsgenerierung) und **Klassenbestimmung** (CORINE Land Cover Klassenkatalog) durch Identifikation und Validation. Die Zuordnung der Objekte zu den jeweiligen CLC Klassen erfordert die Generierung von unabhängigen Merkmalen. In dieser Arbeit werden Merkmale zur Bestimmung der Landbedeckung, Phänologie, Objektform, bestimmte Farbeigenschaften, der Versiegelungsgrad und

der Einbeziehung des Kontextes entwickelt. Diese Merkmale dienen als Grundlage der Beschreibung von CLC Klassen im **CLC Klassenkatalog**, was einem Regelwerk entsprechen würde. Das vorliegende Kapitel schließt mit den technischen Aspekten der Softwareimplementierung ab und beschreibt den Systemaufbau und das generelle Datenkonzept.

3.1 Der Klassifikationsrahmen

Die entwickelte Rahmensoftware *gnosis* stellt verschiedene Komponenten, darunter Softwaremodule, Merkmale und den CLC Regelkatalog zur Verfügung, um automatisiert CORINE Land Cover Daten durch ein objektorientiertes Klassifikationsverfahren zu erzeugen. Die **Identifikation** der CLC Landbedeckungsklassen basiert auf der Zerlegung der CORINE LC Objekte in einzelne Bestandteile der Landbedeckung und deren Aggregation. Dazu werden Bildobjekte oder Bildsegmente aus den optischen Daten durch Bildsegmentierung extrahiert. Diese Bildobjekte bilden die Basisgeometrie für die weiteren Analysen. Alle generierten Merkmale, darunter die Landbedeckung, die *a-priori* Klassifikation (**CLC 1990**), der phänologische Gang der Vegetation, usw. werden diesen Objekten vererbt. Aus diesem Grund muss der optische FE-Datensatz den thematischen und geometrischen Spezifikationen von CORINE Land Cover entsprechen (Maßstab 1:100 000). Die Abbildung 3.1 stellt diesen Ablauf mit den verschiedenen Informationsebenen graphisch dar.




Abbildung 3.1: Die Identifizierung der CLC Objekte (A und B) erfolgt durch die Transformation der bildvarianten Rastermerkmale (z.B. NDVI) in bildinvariante Klassifikationsmerkmale (Landbedeckung, Versiegelung, Nachbarschaft usw.). Die Bildsegmente dienen als Container für diese Merkmale. Der Klassenkatalog beschreibt die einzelnen CLC Klassen mit Hilfe dieser Merkmale. Die Objektzuweisung erfolgt über die Ähnlichkeit der Objekte mit den jeweiligen Klassenprototypen.

Die verschiedenen Informationsebenen sollen eine detaillierte Charakterisierung des Bildobjektes ermöglichen. In der Folge erlaubt diese Charakterisierung eine direkte Identifikation der CLC Klasse. Neben Landbedeckungsklassen, wie *Siedlungen* und *Wälder* können darüber hinaus auch Landnutzungsklassen identifiziert werden, wenn

- a) die anthropogene Nutzung Einfluss auf die spektrale Charakteristik des Objektes hat (z.B. bei CLC 124: *Flughäfen*),
- b) bestimmte Nachbarschaften die Nutzung erklären (CLC 123: *Hafenanlagen*) oder
- c) Zusatzmerkmale die Identifizierung ermöglichen (Trennung von CLC 211: *Nicht bewässertes Ackerland* und CLC 231: *Weideland* durch temporale Informationen).

Durch die komplexe Zusammensetzung des CORINE Schlüssels und der einzelnen Klassendefinitionen können nicht alle Klassen direkt identifiziert werden. Die CORINE LC Nomenklatur beinhaltet Klassen der Landbedeckung und Landnutzung. Bei der Generierung von CORINE Objekten wird eine thematische und geometrische Generalisierung angewendet, d.h. Objekte kleiner 25 ha werden mit umliegenden Objekten verschmolzen. Hierbei kann eine **Validation** der Objekte durch ihre Klassenbeschreibung basierend auf ihren Merkmalen erfolgen. Dazu werden die CORINE Land Cover Klassen je nach interner Struktur bzw. Diversität der Landbedeckung in zwei Gruppen (Beispiel in Abbildung 3.1) unterteilt:

→ CLC Klassen mit dominierender homogener Landbedeckung

→ CLC Klassen mit semantisch heterogener Landbedeckung


CLC Gruppen mit einfacher Zusammensetzung

Diese Gruppe beinhaltet alle Landbedeckungsklassen von CORINE LC. Darunter fallen Siedlungsgebiete (CLC 11x), Wälder (CLC 31x), bestimmte landwirtschaftliche Flächen (Sonderkulturen, CLC 22x) und Wasserflächen (CLC 5xx). Diese Klassen zeichnen sich durch einen homogenen Aufbau von dominanten Landbedeckungsklassen aus (abgesehen von aggregierten Objekten kleiner 25 ha bzw. 5 ha bei Veränderungsflächen durch geometrische Generalisierung).

CLC Gruppen mit komplexer Zusammensetzung

Alle in dieser Gruppe enthaltenen Klassen zeichnen sich durch einen thematisch komplexen Aufbau und durch unterschiedliche Landbedeckungsklassen aus. Diese Struktur wird bedingt durch die verschiedenen Landnutzungen und die Generalisierungsvorschriften von CORINE LC. Zu dieser Gruppe gehören die „Sammelklassen“ (CLC 24x: *Heterogene Landwirtschaftliche Flächen*), die landwirtschaftlichen Klassen 211 und 231 und bestimmte Feuchtgebiete, darunter CLC 411.

CORINE Objekte aus der ersten Gruppe können aus Bildobjekten oder Bildsegmenten zusammengesetzt werden, d.h. ein CORINE Objekt kann durch die Summe seiner (Sub-) Bildobjekte repräsentiert werden. Eine verfügbare *a-priori* Klassifikation ist nicht notwendig, verbessert aber das Klas-



(a) CLC 312: Nadelwaldgebiete im Taunus



(b) CLC 124: Frankfurter Flughafen

Abbildung 3.2: Beide Abbildungen sind Bildkomposite aus synthetischen und spektralen Merkmalen (abgeleitete Landbedeckung und Pan Kanal von Landsat ETM+). Bei der CORINE Landcover Klasse 312: *Nadelwald* (Abb. 3.2(a)) beschreibt die Landbedeckung eindeutig den Charakter der Klasse. Kleinere Flächen, bestehend aus Laubwald, Grünflächen und Siedlungen fallen durch die Generalisierung nicht ins Gewicht. Das CLC-Objekt kann durch die enthaltenen Nadelwaldflächen annähernd rekonstruiert werden (**Objektidentifikation**). Der Flughafen (3.2(b)) hingegen wird durch eine Vielzahl von Landbedeckungen (Asphalt, offener Boden, Grünland, Gebäude) in unterschiedlichen Anteilen definiert. Eine Abgrenzung zu Nachbarobjekten ist rein spektral nicht möglich. Deshalb kann das *a-priori* klassifizierte Flughafen-Objekt nur validiert werden, indem die enthaltenen Bildobjekte auf Konsistenz zum CLC Klassenkatalog überprüft werden (**Objektvalidation**).

sifikationsergebnis. Bei der Objektvalidati-
on muss eine umfangreiche Klassifikation
als Grundlage zur Verfügung stehen. Ein
Sonderfall stellt die CORINE LC Klasse
211: *Nicht bewässertes Ackerland* dar. Durch
temporale Informationen (Vergleich der in-
traannuellen und interannuellen Phänolo-
gie) kann diese Gruppe von anderen Klas-
sen, wie CLC 231 und CLC 32x getrennt
und somit identifiziert werden. Die Zuwei-
sung der jeweiligen CORINE Klasse erfolgt
durch ein spezielles Regelwerk. Die kon-
zeptionellen Unterschiede zwischen Identi-
fikation und Validierung werden im nächs-
ten Abschnitt genauer erläutert.

Für den folgenden Sachverhalt ist es
notwendig, eine Nomenklatur einzufüh-
ren. Der Fernerkundungsdatensatz D
kann in spektral homogene Bildobjekte
resp. Bildsegmente seg_1 bis seg_n einge-
teilt werden. Diese Bildobjekte repräsen-
tieren die CORINE LandCover Objekte
 clc_1 bis clc_m . Die CORINE Landcover Me-
thodologie gruppiert diese Objekte the-
matisch in 44 Klassen $CLC_x \mid x =$
 $\{111, 112, 121, \dots, 522, 523\}$. Zur Ableitung
dieser CORINE Klassen sind eine Reihe
von Merkmalen notwendig: f_1 bis f_o . Diese
können (1) aus dem Datensatz selbst be-
rechnet werden bzw. (2) aus einem ande-
ren Datensatz abgeleitet werden. Für die
zudem eindeutige Zuweisung von CLC_x

Tabelle 3.1: Grundannahmen der Objektrepräsentation

Grundannahme 1 (Semantische Repräsentation) Eine CORINE LC Klasse CLC_x wird durch die Merkmale f_1 bis f_o eindeutig definiert. Das bedeutet, dass die CORINE LC Klasse $CLC_x = f_1 \cap f_2 \cap \dots \cap f_o$. Eindeutigkeit bedeutet in diesem Fall $CLC_x \not\subseteq CLC_y$.

Grundannahme 2 (Geometrische Repräsentation) Ein CORINE Objekt clc wird durch die Bildobjekte seg_1 bis seg_n repräsentiert. Im Idealfall gilt damit $seg \in clc$ und $clc = seg_1 \cup seg_2 \cup \dots \cup seg_n$. Dieser Fall trifft für den Großteil der CORINE Objekte nicht zu, da es zu Abweichungen zwischen der Segmentgeometrie und der CLC Objektgeometrie kommt. Diese werden durch thematische bzw. geometrische Generalisierungsschritte oder Digitalisierungsfehler verursacht. Deshalb gilt für den Normalfall $seg \cap clc$ und $clc = (seg_1 \cap clc) \cup (seg_2 \cap clc) \cup \dots \cup (seg_n \cap clc)$. Daraus resultiert der erklärende Anteil $\sum \frac{1}{n} (A_{seg} \cap A_{clc}) / A_{seg}$. Der erklärende Anteil beschreibt, wie gut ein CLC Objekt geometrisch durch seine Bildsegmente repräsentiert wird.

ist es wichtig, dass diese Merkmale voneinander unabhängig sind. Das Rahmenwerk gründet auf den beiden Grundannahmen in Tabelle 3.1.

Semantische Repräsentation der CLC Objekte

Die Implementierung der Grundannahme zur semantischen Repräsentation basiert auf der Klassenbeschreibung durch Prototypen (analog zum *chorus of prototypes* von EDELMAN (1995)). Dabei werden Merkmale aus einem Merkmalskatalog entnommen, um CORINE LC Klassen eindeutig zu beschreiben. Für die Differenzierung der Klassen werden Regeln basierend auf dem Merkmalskatalog entworfen und in einem Regelkatalog (CLC Klassenkatalog) abgelegt. Die verwendeten Merkmale werden im Kapitel 3.3 näher beschrieben. Eine genaue Beschreibung der einzelnen CORINE LC Klassen wird in Kapitel 3.4 gegeben.

Die Zuweisung der CORINE LC Klasse erfolgt durch ein spezielles **Gewichtungssystem** durch den Wichtungsvektor G . Für jedes Objekt (clc oder seg) ist

$G = \{111, 112, \dots, 522, 523\}$. Dieses Abtraktionssystem ermöglicht die unscharfe Zuweisung von Informationen für komplexe Objektstrukturen und die Abbildung von Klassenbeziehungen (gewonnen aus der Ontologie) durch das Regelwerk.

Dabei werden die Zwischenergebnisse der einzelnen Gewichtungen und Regeln pro Objekt in einem Vektor G gespeichert. Die Summe der Gewichtungen definiert das Superobjekt. Aus dem Verhältnis der Gewichtungen können Aussagen über die Komposition und Verteilung der Klassen im Superobjekt abgeleitet werden. Neben der dominierenden, flächenbezogen am häufigsten auftretenden Klasse bestimmt auch die Häufigkeitsverteilung der kleineren Klassen und das Verhältnis zwischen diesen Klassen die endgültige CLC Klasse. Je größer das Verhältnis zwischen der dominierenden Klasse zu den restlichen Klassen ist, desto eindeutiger repräsentiert diese Klasse das Gesamtobjekt. Die Repräsentation der Klassen in einem Vektorraum ermöglicht neben der Beibehaltung aller Informationen über ein Superobjekt die Kodierung von Zusammenhängen zwischen den Klassen. Beispielsweise können sich




Abbildung 3.3: Die Zusammensetzung des Überobjektes in Abb. 3.3(a) zeigt die dominierende Klasse A und ermöglicht dadurch eine eindeutige Zuordnung der CLC Klasse. Eine mehrdeutige Zuordnung (Abb. 3.3(b)) kann in bestimmten Fällen für die Zuweisung der CLC Klasse ohne manuelle Hilfe nicht verwendet werden.

bestimmte Vegetationsklassen untereinander verstärken oder andere Klassen abschwächen. Laub-, Misch- und Nadelwälder gehören zur Kategorie Wald. Wenn ein Superobjekt durch Laubwald dominiert wird, kann durch die Gruppenzugehörigkeit (Wald) auch die beiden anderen Waldklassen und die Wald-Übergangsklasse verstärkt werden. Auf der anderen Seite können Merkmale CLC Klassen auch dämpfen. Ein niedriges phänologisches Verhalten der Vegetation kann für ein Superobjekt alle CLC Klassen mit Vegetationsanteil abschwächen. Die Kombination aus Verstärkung und Abschwächung ermöglicht die dynamische Verknüpfung von verschiedenen Datenebenen wie beispielsweise die *a-priori* Klassifikation **CLC 1990**, die aktuelle Landbedeckung **Image 2000** und die zeitliche Charakteristik der Vegetation zwischen 2000–2005. Diese Tatsache erlaubt die Bestimmung von CLC Klassen, die nicht eindeutig durch bestimmte Merkmale beschrieben werden können.

Das genannte Prinzip stammt aus der Biomechanik (*Populationsvektor*) und wird beispielsweise in der Informatik für Fragestellungen in den Bereichen Robotik und Mustererkennung angewendet (GEORGOPOULUS *et al.*, 1989). Der Populationsvektor ist als Summenvektor der einzelnen CLC-Klassenvektoren definiert und indiziert die gewichteten Summen einer Klassengruppe (z.B. Wald).

Die Abbildungen 3.3(a) und 3.3(b) veranschaulichen symbolhaft das Prinzip dieser Repräsentation. Alle Unterobjekte sind kleiner als 5 ha und sind damit Bestandteile oder Unterobjekte des Superobjektes. In Abb. 3.3(a) kann die dominante Klasse A das Superobjekt durch das Flächenverhältnis zu den anderen Klassen eindeutig beschreiben, d.h. die Fläche von A ist größer als die Flächen der anderen Klassen zusammen. Das Größenverhältnis A zum nächst kleineren Objekt B liegt unter einem bestimmten Schwellwert. Dennoch fließen alle Informationen der Unterobjekte in die endgültige Bestimmung mit ein. Sammel-

klassen, wie die CLC Klasse 242: *Komplexe Parzellenstruktur* mit 75 % landwirtschaftlich genutzten Flächen können durch das Verhältnis zwischen der dominanten Klasse A und den restlichen Klassen bestimmt werden.

Das Verhältnis zwischen den Klassen A und B verhindert in Abb. 3.3(b) die eindeutige Zuordnung des Superobjektes. Eine CLC Klasse kann dennoch zugewiesen werden, wenn durch die Verknüpfung der Merkmale eine CLC Klasse verstärkt wird. Ein Beispiel dafür sind die landwirtschaftlichen Klassen CLC 211 und CLC 231. Die CLC Klasse 231: *Weideland* verstärkt die Klasse 211, da viele kleinflächigen (kleiner 5 ha bzw. kleiner 25 ha) Weideflächen zu den landwirtschaftlichen Klassen aggregiert werden.

In ungünstigen Fällen können Verstärkungen oder Abschwächungen zu widersprüchlichen Aussagen führen. In diesem Fall kann das Objekt einer falschen CLC Klasse zugewiesen werden und zu einer Fehlklassifikation führen. Die verwendeten und implementierten Gewichtungen befinden sich in der Tabelle C.2 (Anhang). Die Gewichtungen wurden empirisch aus den Daten ermittelt.

Geometrische Repräsentation der CLC Objekte


Der Grundgedanke zur geometrischen Repräsentation wurde durch das verwendete Datenmodell von gnosis umgesetzt. Die verschiedenen Informationsebenen werden durch die technischen Klassen RasterObject, ImageObject, LCObject,

CorineObject und CLCObject dargestellt.

Das UML-Diagramm (Unified Modelling Language – eine Beschreibungssprache für IT Abstraktionen) aus Abbildung 3.4 stellt die wichtigsten Attribute und Methoden für die implementierten Klassen zusammen, um eine Klasse in eine informationstechnisch höherwertige Klasse zu überführen (**Bottom-Up Ansatz**). Dieser Ansatz wird für die **Neuklassifikation** von CORINE LC angewendet. Die Objekte aus der Klasse ImageObject entstehen durch eine Bildsegmentierung aus der Klasse RasterObject, also dem Bilddatensatz. Nach einer per-pixel Klassifikation der Landbedeckung können bestimmte Merkmale für die Objekte der Klasse LCObject in Abhängigkeit von ihrer Landbedeckungsklasse berechnet werden. Diese Merkmale werden vom Klassenkatalog verwendet, um das Objekt zu gewichten. Je nach Gewichtung und Gewichtungsfunktion kann eine CORINE LC Klasse ermittelt und dem Objekt der Klasse CorineObject zugewiesen werden. Objekte aus dieser Klasse können wiederum mit ähnlichen Nachbarobjekten aggregiert werden. Grundeigenschaften werden durch die Klassenhierarchie hinweg an die höheren Klassen weitergegeben oder vererbt. Objekte der Klasse CLCObject entsprechen den existierenden **CLC 1990** bzw. **CLC 2000** Objekten. Diese können durch ihre Bestandteile validiert werden.

Der **Top-Down Ansatz** hingegen versucht, eine Hypothese (z.B. „Gehört das Objekt *x* noch zur CORINE LC Klasse CLC 124: *Flughafen*?“) zu bestätigen oder zu verwerfen. Dieses Verfahren wird für eine **Verän-**

Abbildung 3.4: Darstellung des Datenmodells in gnosis in Anlehnung an die verschiedenen Informationsebenen in Bildern



derungskartierung verwendet. Dazu wird das Objekt clc_x segmentiert und in seine Bestandteile seg_1 bis seg_n aus der Klasse ImageObject zerlegt. Diese werden wieder in Objekte der Klasse LCObject umgewandelt und stehen der Analyse zur Verfügung. Der Regelkatalog definiert für die komplexen Klassen, welche Bestandteile vorkommen dürfen. Wenn zusätzliche Bestandteile gefunden werden, kann eine Veränderung stattgefunden haben. Beide Ansätze werden im nächsten Kapitel näher vorgestellt.

3.2 Der Aufbau des Klassifikationsprozesses

Der Klassifikationsprozess beschreibt den Vorgang der CLC Prozessierung und kann vereinfacht in vier Unterprozesse aufgeteilt werden:

- 1) **Datenvorverarbeitung**
- 2) **Objekterstellung**
- 3) **Objektidentifikation**
- 4) **Validierung.**

Eine Beschreibung der technischen Aspekte der Implementierung des Klassifikationsprozesses erfolgt im Abschnitt 3.5. Es folgt eine Übersicht (Tabelle 3.2) der ein-

zelnen Verarbeitungsschritte (Unterpunkte), die in gnosis durchgeführt und implementiert wurden. Fehlende Verarbeitungsschritte sind *kursiv* dargestellt.

Tabelle 3.2: Implementierte Verarbeitungsschritte in gnosis; nicht implementierte Schritte sind *kursiv* geschrieben

1. **Datenvorverarbeitung**
 - a) *Atmosphärenkorrektur / Normalisierung*
 - b) Datenimport
2. **Objekterstellung**
 - a) *Segmentierung*
 - b) Aufbau des Objektmodells
3. **Objektidentifikation**
 - a) *Neuklassifikation*
 - i. Klassifikation / Zuordnung der Komponenten
 - ii. Aggregation der Komponenten zu CLC Objekten
 - iii. Identifikation der CLC Objekte
 - b) *Veränderungskartierung*
 - i. Zerlegung des Objektes in seine Komponenten
 - ii. Klassifikation / Zuordnung der Komponenten
 - iii. *Validierung der Komponenten in Abhängigkeit des CLC Objektes*
4. **Objektvalidierung**

- a) Automatische Validierung via CLC2000 Datensatz
- b) *Manuelle Validierung via Interpretationen*

Datenvorverarbeitung

Die Klassifikation von CORINE Land Cover benötigt eine Reihe von Datensätzen aus den Bereichen Fernerkundung, Topographie und GIS. Die detaillierte Aufschlüsselung der verwendeten Daten und deren Vorprozessierung erfolgt in Abschnitt 3.5.2. Eine Atmosphärenkorrektur wurde mit den **Image 2000** Daten nicht durchgeführt, da einige Kanäle, wie der Kanal 3 und 4, zur Verbesserung der manuellen Interpretation verändert wurden. Um eine Verarbeitung mit gnosis zu ermöglichen, muss ein Projektgebiet definiert werden, d.h. die Daten werden für die Software an denselben Ausschnitt angepasst und benötigen die gleiche Projektion und Auflösung. Diese Vorverarbeitungsschritte wurden mit der Software ENVI durchgeführt. Die Rahmensoftware ist in der Lage, die gängigen Datenformate zu lesen und in eine relationale Datenbank zu importieren. Diese Datenbank stellt die Daten über das Netzwerk den einzelnen Prozessen zur Verfügung.

Objekterstellung

Als Basis für die objektorientierte Klassifikation dienen Bildsegmente oder Bildobjekte. Diese Bildobjekte wurden in einem weiteren Verarbeitungsschritt mit dem Programm eCognition 3 von der Firma *Definiens* generiert und in gnosis importiert. Dieses Verfahren basiert auf der Multi-

resolution Segmentierung (BENZ *et al.*, 2003) und kann in die Gruppe der *region-growing*-Algorithmen eingeordnet werden. Für die Segmentierung selbst müssen in eCognition drei Parameter definiert werden: Maßstab, Farb- und Formeinfluss (Segment= $f(\text{image}, \text{scale}, \text{color}, \text{shape})$). Die Rahmenbedingungen setzen jedoch voraus, dass jedes CLC Objekt durch mindestens ein Bildobjekt repräsentiert wird. Aus diesem Grund müssen die drei Parameter zur Zeit manuell an diese Bedingung angepasst werden. Es ist darüber hinaus möglich, die Geometrie der **CLC 1990** Klassifikation in den Segmentierungsprozess mit einfließen zu lassen.

Durch räumliche und semantische Verknüpfung der einzelnen Datensätze mit den Bildobjekten entsteht das **Objektmodell**. Es verknüpft die verschiedenen Informationsebenen miteinander und ermöglicht konsistente Analysen der einzelnen Objekte. Die erste Differenzierung der Objekte erfolgt dann durch eine überwachte Klassifikation der Landbedeckung. Um mit einer möglichst geringen Anzahl von Trainingsgebieten über eine heterogene Datenbasis akzeptable Ergebnisse zu erzielen, benötigt das Klassifikationsverfahren ein hohes Maß an Generalisierbarkeit. Aus diesem Grund wurde ein empirisches Verfahren zur strukturellen Risikominimierung gewählt, das mit hoch variablen Trainingspektren gute Ergebnisse produziert, ohne vorher durch umfangreiche Verfahren trainiert werden zu müssen (FOODY UND MATHUR, 2004B).

Der Informationsgehalt der Bildobjekte steigt daraufhin iterativ mit der Anzahl der berechneten Merkmale. An der

höchsten Stelle stehen Objekte der Klasse `CorineObject`. Diese verbinden die Informationen der Bildobjekte und Landbedeckungsobjekte mit den CLC Daten.

Objektidentifikation

CORINE Land Cover Objekte können je nach Gruppenzugehörigkeit in *gnosis* entweder **identifiziert**, **validiert** oder **nicht prozessiert** werden.

Eine detailliertere Aufschlüsselung (*Klassenkatalog*) der CLC Klassen, der benötigten Merkmale für die Verarbeitung und die Gruppenzugehörigkeit ist in Tabelle 3.11 auf Seite 91 zusammengefasst.

In den folgenden NASSI-SHNEIDERMAN Struktogrammen werden die implementierten Algorithmen zur Identifikation durch den *bottom-up* Ansatz (Abb. 3.5(b)) und Validation durch den *top-down* Ansatz (Abb. ??) der Objekte als Pseudocode vorgestellt.

Das Struktogramm zeigt den schematischen Aufbau einer Programmstruktur in Form einer graphischen, zweidimensionalen Darstellung. In den beiden Struktogrammen werden die Algorithmen gegenüber gestellt. Der *Bottom-up* Ansatz wandelt BILDobjekte in CORINEobjekt um und erstellt durch Aggregation mit ähnlichen Nachbarobjekten entsprechende CLC Objekte. Veränderungen erkennt er durch einen Vergleich mit den **CLC 1990** Objekten. Dieser Ansatz benötigt keine *a-priori* Klassifikation und kann daher auch unbekannte Objekte einer Klasse zuweisen. Dieser Vorgang wird Identifizierung genannt. Der *Top-down* Ansatz hingegen kann vor-

her klassifizierte Objekte validieren, d.h. deren Existenz bestätigen oder negieren. Der *a-priori* Datensatz wird jedoch für eine weitere Differenzierung (Bildung der Schnittmenge zwischen den BILDobjekten und dem CORINEobjekt) der Objekte benötigt, weil die verwendeten Merkmale diese Differenzierung nicht unterstützen.

Validierung des Ergebnisses

Das Ergebnis der Identifikation resp. Validierung wird mit dem **CLC 2000** Datensatz verglichen. Die Qualität der Prozessierung kann durch die Wahrheitsmatrix und weitere statistische Maße (Korrelation, COHENS Kappa-Koeffizient und Gesamtgenauigkeit) ermittelt werden. Durch iterative Veränderungen der Eingangsparameter (z.B. Segmentgröße, Wahl der Trainingsgebiete und Einfluss der Gewichtungen) kann darüber hinaus der Identifikations- und Validationsprozess automatisiert werden. Dabei wird der **CLC 2000** Datensatz als Referenz verwendet.

3.3 Entwickelte Merkmale zur Identifikation von CLC Klassen

In dieser Arbeit wurden eine Reihe von Merkmalen entwickelt, auf denen die Klassifikation von CORINE Land Cover basiert. Die Merkmale dienen zur Differenzierung der verschiedenen CORINE LC Klassen. In einem iterativen Prozess werden diese Merkmale für jedes Objekt berechnet und in der Projektdatenbank abgelegt. Der Gewichtungsprozess führt die gewon-

3.3 Entwickelte Merkmale zur Identifikation von CLC Klassen

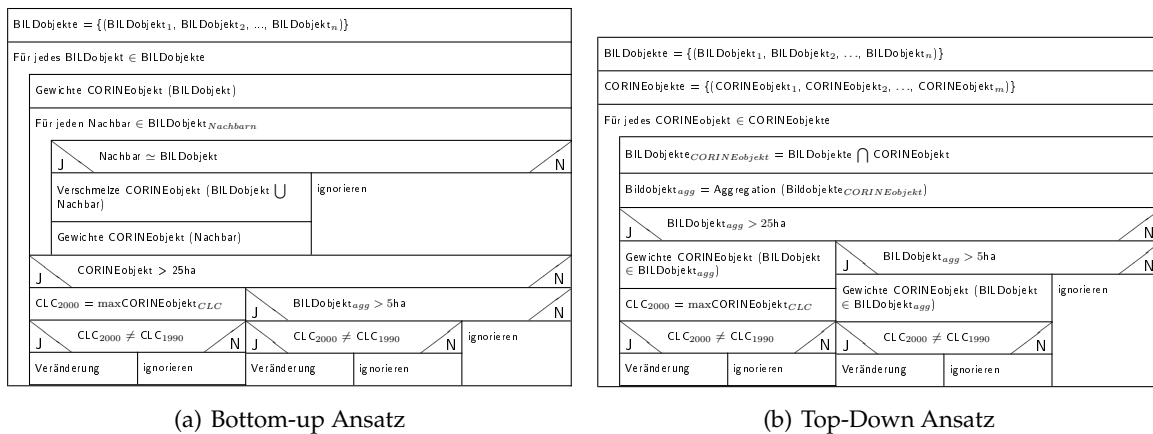


Abbildung 3.5: In den beiden Struktogrammen werden die Algorithmen gegenüber gestellt. Der Bottom-Up Ansatz benötigt keine *a-priori* Klassifikation und kann damit unbekannte Objekte einer Klasse zuweisen (identifizieren). Der Top-Down Ansatz hingegen kann klassifizierte Objekte validieren, d.h. deren Existenz bestätigen oder negieren.

nenen Informationen zusammen und extrahiert die CORINE LC Klasse.

Folgende Merkmale werden erstellt:

- Landbedeckung
- Phänologie
- Form
- Kontext
- Farbmerkmale
- Versiegelungsgrad

Die Landbedeckung ist die Basis für die CORINE LC Klassifikation und beeinflusst die Generierung der weiteren Merkmale. Erst auf Basis dieser Information bekommen die weiteren Merkmale eine semantische Bedeutung. Der phänologische Verlauf beschreibt nur den Vegetationsanteil im Objekt. Analog dazu muss der Versiegelungsgrad für bebauten Flächen angewendet werden. Die Phänologie ist ein zeitliches Merkmal zur Ableitung von intra- und interannuellen Veränderungen der Vegetation. Abweichungen vom natürlichen

Verlauf der Vegetation korrelieren mit der anthropogenen Nutzung. Form und Kontext werden durch die Geometrie und Topologie der Segmentierung bestimmt. Farbmerkmale dienen als Beispiel für die Parametrisierung von unscharfen Informationen. Implementiert wurden Zugehörigkeitsfunktionen (*fuzzy sets*) für die Bereiche Wasser, Vegetation und Boden. Der Versiegelungsgrad gibt einen weiteren kontinuierlichen Wert zwischen 0.0 und 1.0 an, der den versiegelten Anteil von Gebäuden und Straßen in einem Pixel entspricht.

3.3.1 Diskrete spektrale Merkmale

Analog zu der Arbeit von FULLER *et al.* (1994) können viele CORINE LC Klassen aus abgeleiteten Informationen der Landbedeckung aggregiert werden. Dazu wurde ein Verfahren zur überwachten Klassifikation gewählt, dass auf Trainingsgebieten aufbaut. Überwachte Klassifikationsverfah-

ren haben den Vorteil, dass die extrahierten Klassen durch die vordefinierten Trainingsgebiete eine Semantik besitzen. Bei der Implementierung von gnosis konnte die Anzahl von 22 Landbedeckungsklassen (FULLER *et al.*, 1994) auf zehn Basisklassen reduziert werden, da zusätzliche Merkmale gefunden wurden, um den Großteil der CORINE LC Klassen zu kodieren. Die Reduktion der Klassen hatte darüber hinaus den Vorteil, die per-Pixel Klassifikation automatisch durchführen zu können. Die Ergebnisse sind stabiler, da die Trennbarkeit der spektrale Klassen erhöht wurde. Die extrahierten Klassen sind

- I) Wasser,
- II) Laubwald,
- III) Nadelwald,
- IV) strukturierte Siedlung ,
- V) Siedlung mit hoher Intensität,
- VI) offener Boden (2 Klassen)
- VII) und dichte niedrige Vegetation (3 Klassen).

Heterogene Klassen (z.B. IV und VII) können je nach Komplexität der Landschaft weiter unterteilt werden. Eine zweifache Hierarchie wird von gnosis unterstützt, d.h. Wälder können nach einer ersten Klassifikation in Laub- und Nadelwaldklassen weiter unterteilt werden. In der ersten Iteration werden die Wurzelklassen oder Klassen erster Ordnung prozessiert. Ein Beispiel für die Ansteuerung des SVM-Klassifikators befindet sich im Anhang (Tab. B.1). Mit Hilfe dieser Steuerungsdatei wurden die Projekte in dieser Arbeit prozessiert.

Verwendete Trainingsdaten für die überwachte Klassifikation

Die Trainingsdaten (Abb. 3.6) wurden aus den **Image 2000** Datensatz unter Zuhilfenahme der **CLC 2000** Klassifikation und topographischen Karten generiert und in einer Datenbank abgelegt (Tabelle R0Imeta und R0Idata). Eine detaillierte Zusammensetzung der verwendeten Trainingsgebiete befindet sich im Anhang (Tabelle C.1). Insgesamt stehen dem Verfahren ca. 3 000 Trainingsgebiete mit 388 766 Trainingspektren für die Klassifikation der einzelnen CLC Klassen zur Verfügung. Die Trainingsgebiete beschreiben die spektrale Charakteristik für eine Reihe von Basislandbedeckungsklassen auf Grundlage der genannten Steuerungsdatei im Anhang (Beispiel für die Kodierung der Landbedeckungsklasse *Wasser* \mapsto CLC 511, CLC 512 und CLC 523). Einige CLC Klassen werden jedoch rein funktional definiert. Diese Klassen wurden für die spektrale Klassifikation nicht berücksichtigt, da die Trainingsdatenbank nur spektrale Landbedeckungsklassen beschreiben kann. Dazu zählen folgende Klassen: CLC 122: *Straßen, Eisenbahn*, CLC 123: *Hafengebiete*, CLC 124: *Flughäfen*, CLC 132: *Deponien und Abraumhalden*, CLC 133: *Baustellen* und CLC 142: *Sport- und Freizeitanlagen*. Die Klasse CLC 211: *Nicht bewässertes Ackerland* wurde weiter aufgeteilt in CLC 2111 (mit Vegetationsbestand) und CLC 2112 (vegetationslos), um die unterschiedlichen phänologischen Stadien der Feldfrüchte in der Datenbank zu berücksichtigen. Die CLC Klassen 24x: *Heterogene landwirtschaftliche Flächen* werden durch vegetationsbedeckte, spektral homogene Trainingsgebiete wiedergegeben. Die anderen Bestandteile dieser Klasse werden durch



Abbildung 3.6: Im Rahmen dieser Arbeit wurden Trainingsgebiete für die CLC Klassen aus 12 Landsat ETM+ Szenen generiert, um die spektrale und temporale Variabilität der Klassen für den Stützvektorklassifikator zu beschreiben.

die CLC Klassen 112, 211 und 231 repräsentiert.

Der **Image 2000** Datensatz ist aus ETM+-Szenen von unterschiedlichen Aufnahmezeitpunkten zwischen 1999 und 2001 zusammengesetzt. Dies wirkt sich auf die Variabilität in den Spektren der einzelnen Klassen aus und wird verursacht durch den veränderten Sonnenstand, durch unterschiedliche phänologische Stadien der Vegetation und der spektralen Heterogenität der Landbedeckungsklassen für eine großräumige. Um diese Diversität beim Training des Klassifikators zu berücksichtigen, mussten Trainingsgebiete aus verschiedenen Szenen gesammelt werden. Zum Training des Klassifikators wurden dazu n Spektren für jede CLC Klasse zufällig aus der deutschlandweiten Trainingsdatenbank gewählt (Tabelle 3.3).

Tabelle 3.3: Zeitlicher Aufbau der Trainingsdatenbank

Path	Row	Aufnahmedatum	Anzahl der Spektren
192	24	24.9.2000	29 036
193	23	14.8.2000	37 892
193	24	13.9.1999	29 613
193	26	13.9.1999	29 056
193	27	13.9.1999	33 724
194	25	18.6.2000	34 662
194	26	18.6.2000	23 797
195	23	9.6.2000	49 695
195	24	9.6.2000	20 464
196	22	15.5.2000	44 714
196	25	5.7.2001	23 360
197	23	26.8.2000	32 754

Eine Beschreibung der Steuerdatei für das Klassifikationsverfahren wird in Kapitel 3.5 gegeben. Durch die Kodierung auf Basis von CORINE LC Klassen können

im Rahmen der Aufgabenstellung beliebige spektrale Klassen definiert werden, die semantisch einen Landbedeckungstyp beschreiben. Die Tabelle C.4 (Anhang) zeigt als Beispiel die Transformation durch Klassifikation der spektralen Daten in die zehn Landbedeckungsklassen: Wasser, Siedlung (dichte Bebauung, lockere Bebauung), Laubwald, niedrige Vegetation (darunter verschiedene Sonderkulturen und Vegetationsstadien), offener Boden (hellerer und dunklerer Boden) und Nadelwald. Dabei werden die bundesweiten Trainingsdaten – gewonnen aus CORINE LC – auf diese Landbedeckungsklassen durch ihre spektralen Eigenschaften abgebildet. Nicht miteinbezogene Testdaten aus der Datenbank werden mit dem trainierten Klassifikator prozessiert, um die Genauigkeit in Form einer Wahrheitsmatrix (*confusion matrix*) zu ermitteln.

Aus der Tabelle C.4 (Anhang) kann abgelesen werden, wie gut der Klassifikator die verschiedenen trainierten Klassen identifizieren kann, welche Klassen spektral ähnlich zueinander sind und welche Klassen eine gute spektrale Trennbarkeit für den SVM Klassifikator besitzen. Je ähnlicher die Klassen sind (z. B. bei den Vegetationsklassen), desto größer ist der resultierende Klassifikationsfehler. Dieser Fehler kann minimiert werden durch

- I) eine Reduzierung der Klassen (Aggregation der Problemklassen) in einem hierarchischen System,
- II) die Erhöhung der Separabilität durch Berücksichtigung von weiteren Merkmalen (z. B. zusätzliche spektrale Kanäle)

Tabelle 3.4: Wahrheitsmatrix (*Confusion matrix*) nach Kreuzvalidation (10-fach gefaltet) für die verwendete Steuerdatei

CLC	11x	12x	13x	21x	22x	23x	24x	31x	32x	33x	41x	42x	5xx	Σ	%
11x	734	76	37	4	1	0	21	6	34	8	29	0	2	952	77,1
12x	71	401	19	0	0	29	30	11	5	1	4	0	0	571	70,23
13x	8	3	784	36	14	0	4	0	40	0	6	0	73	968	80,99
21x	10	0	48	667	6	1	6	25	54	0	47	33	89	986	67,65
22x	25	0	3	39	827	75	0	0	46	15	79	1	0	1110	74,5
23x	0	0	0	26	3	1892	0	0	0	0	23	0	0	1944	97,33
24x	3	16	13	0	0	0	430	0	5	5	10	0	0	482	89,21
31x	89	2	0	85	0	1	3	376	49	4	149	22	130	910	41,32
32x	52	2	37	16	39	0	6	2	564	43	109	0	43	913	61,77
33x	0	0	0	1	68	0	0	1	163	401	152	16	23	825	48,61
41x	1	0	0	1	42	0	0	10	27	21	176	22	15	315	55,87
42x	5	0	1	34	0	1	0	69	1	1	185	1367	30	1694	80,7
5xx	2	0	58	91	0	1	0	0	12	1	31	39	1095	1330	82,33
Σ	1000	500	1000	1000	1000	2000	500	500	1000	500	1000	1500	1500		
%	73,4	80,2	78,4	66,7	82,7	94,6	86	75,2	56,4	80,2	17,6	91,13	73		

III) optimierte Selektion — zeitlich und räumlich betrachtet — der vorgegebenen Trainingsgebiete.

Die Tabelle 3.4 vergleicht die spektralen Ähnlichkeiten untereinander zwischen den einzelnen CORINE LC Klassen auf der zweiten Hierarchiestufe auf Basis der Trainingsdaten ($n = 5000$). Dazu wurde eine Kreuzvalidation der Trainingsdaten durchgeführt. Mit Hilfe der Steuerdatei können die einzelnen CORINE LC Klassen direkt als Wurzelklassen abgebildet werden. Bei der Kreuzvalidation wird die gesamte Trainingsmenge in zehn Untermengen ($k = 10$) geteilt. Jede Untermenge wird in einen Test- und einen Trainingsdatensatz ($k - 1$) untergliedert, die anschließend getrennt prozessiert werden. Die Tabelle zeigt den durchschnittlichen Klassifikationsfehler der einzelnen Klassen für k Durchläufe. Der mittlere Fehler für alle Klassen beträgt 73 %.

Dabei zeigt sich, dass bis auf die CLC Klasse 41x: *Feuchtgebiete im Inland* alle weiteren Klassen eine mittlere Klassifikationsgenauigkeit von ca. 70 % besitzen. Dennoch können nicht alle Klassen aus der zweiten CLC Hierarchie als Basisklassen für die Landbedeckung genutzt werden, da die Trainingsgebiete nicht die Gesamtheit aller Variationen abbilden. Für die Erstellung der Trainingsdatenbank wurden homogene Flächen im Sinne der Landbedeckung ausgewählt. Aus diesem Grund wird die CLC Klasse 24x: *Heterogene landwirtschaftliche Flächen* überproportional gut klassifiziert, da keine Siedlungs-, Wald- und Wasseranteile in der Trainingsdatenbank vorliegen. Viele Klassen können durch die Aggregation bzw. Generalisierung der CLC Objekte, der Mischpixelproblematik und der spektralen Auflösung von Landsat ETM+ mit sieben Bändern für den Klassifikator nicht eindeutig definiert werden. Aufgrund des Klassifikationsergebnisses könnte das Merkmal Landbedeckung für groß-

flächige Prozessierungen nicht mehr als stabiles Merkmal eingesetzt werden. Durch die Erhöhung der geometrischen und spektralen Auflösung könnte die Anzahl der Basisklassen erhöht werden. Aus diesem Grund können CLC Objekte nicht durch die spektrale Charakteristik der zweiten und der dritten Hierarchiestufe klassifiziert werden, sondern müssen durch reduzierte Basislandbedeckungsklassen beschrieben werden. In dieser Arbeit wurde die Anzahl der Landbedeckungsklassen deshalb auf zehn Klassen reduziert.

Das Klassifikationsergebnis kann als Analyseverfahren verwendet werden, um die CORINE LC Klassen auf ihre spektrale Komposition hin zu überprüfen, wenn die Klassifikationseigenschaften (Genauigkeit, Separabilität) der Klassen bekannt sind. Auf Grundlage dieser Analysen können Basisklassen der Landbedeckung determiniert werden, die für eine erste Einteilung der Bildobjekte dienen (Basislandnutzungsklassen).

Die Trainingsdaten für die Prozessierung in gnosis dieser Basislandnutzungsklassen sind in zwei Hierarchiestufen (Wurzelklassen und erweiterte Klassen) unterteilt. Dabei wurde die Wurzelklasse $\mapsto \{0, 1, 2, 3, 4, 5\}$ wie folgt zusammengesetzt: 0: Wasser, 1: Siedlungen, 2: Laubwald, 3: übrige Vegetation, 4: Boden, 5: Nadelwald. Die erste Ebene $1 \mapsto \{11, 12, 13\}$ und $3 \mapsto \{31, 32\}$ sammelt die Klassen 11: lockere Siedlungen, 12: dichte Siedlungen, 13: Industriegebiete, 31: Dichte Vegetation und 32: Mischvegetation. Die gemittelte Gesamtgenauigkeit (*overall accuracy*) der Klassifikation für diese Basisklassen beträgt 85 % auf der Wurzelebene.

In Tabelle 3.5 wurden 1 500 zufällig gewählte Punkte für alle enthaltenen CLC Klassen aus dem Testdatensatz Rhein-Main Gebiet gewählt und klassifiziert. Im Gegensatz zur Klassifikation der Trainingsgebiete (Tabelle C.4) zeigt das Ergebnis den heterogenen Aufbau der CLC Objekte und die Variabilität der Spektren. Aus der resultierenden Klassifikationsgenauigkeit können folgende Fragen gestellt werden:

1. Wie gut können welche CLC Klassen spektral klassifiziert werden?
2. Wie sind die CORINE LC Klassen intern strukturiert?

Der erste Punkt ist durch die Wahrheitsmatrix der Trainingsgebiete mit den CLC Klassen (Tabelle C.4 im Anhang) bekannt. Damit beschreibt die folgende Tabelle 3.5 die Zusammensetzung der Landbedeckung der einzelnen CORINE LC Klassen. Eine CLC Klasse mit geringem Klassifikationsfehler kann demnach direkt spektral klassifiziert werden. Zu diesen Klassen gehören die dicht bebauten Siedlungen und Laubwälder. Hohe Fehler müssen durch weitere Merkmale oder Eigenschaften kompensiert werden. Interessant ist dabei, dass die CLC Klasse 512: *Wasserflächen* mit einer Genauigkeit von 67 % klassifiziert wurden. Die Trainingsspektren wurden jedoch mit einer Genauigkeit von über 99 % identifiziert. Dieser relativ hohe Fehler bei der Klassifikation von Wasser aus CORINE Objekten basiert auf der Generalisierung von CORINE LC. Um die 25 ha Mindestgröße zu erreichen, wurden bei der Interpretation von Wasserflächen auch Uferbereiche der CLC Klasse 512 hinzugefügt, die von der Landbedeckung gesehen zu einer „Fehlklassifikation“ führen. Viele Ve-

getationsklassen aus CLC sind der Basis-klasse 3 zugeordnet worden. Eine weitere Differenzierung kann durch die eingeschränkte multispektrale Information und der hohen Variabilität der Szenenaufnahmen durch dieses Merkmal nicht erfolgen.

Dieser interne Aufbau bestimmt die Zugehörigkeit der einzelnen CLC Klassen im Klassenkatalog in die Gruppen mit einfacher und komplexer Zusammensetzung (Tab. 3.10). Dabei können thematisch einfach zusammengesetzte Klassen in ihrer spektralen Charakteristik komplex aufgebaut sein (z.B. Ackerland mit allen Zustandsformen und Bedeckungsgraden von Vegetation). Zugleich zeigt die Tabelle auch die Problematik der Generalisierung von CORINE LC. Spektral einfach definierte Klassen, wie z.B. Wasserflächen können einen komplexen Aufbau besitzen, der durch die CORINE Interpretationsmethodik definiert wird. Diese Zusammenlegung von heterogenen Bestandteilen kann zu einer Verschlechterung der Identifikation von einzelnen CORINE Objekte führen.

Tabelle 3.5: CLC Klassenanalyse durch SVM Klassifikation im Testgebiet *Rhein-Main Gebiet*

CLC	0	1	2	3	4	5
111	0,01	0,96	0,00	0,01	0,00	0,01
112	0,00	0,65	0,05	0,21	0,06	0,03
131	0,17	0,24	0,07	0,17	0,28	0,08
⋮						

CLC	0	1	2	3	4	5
141	0,00	0,18	0,29	0,40	0,03	0,10
211	0,00	0,06	0,03	0,46	0,44	0,01
221	0,00	0,03	0,05	0,86	0,05	0,01
222	0,00	0,04	0,23	0,64	0,07	0,02
231	0,00	0,03	0,21	0,70	0,05	0,01
242	0,00	0,06	0,16	0,63	0,13	0,02
243	0,01	0,04	0,41	0,42	0,05	0,08
311	0,00	0,00	0,92	0,02	0,00	0,05
312	0,00	0,00	0,45	0,02	0,00	0,53
313	0,00	0,01	0,76	0,03	0,00	0,20
321	0,00	0,02	0,19	0,70	0,06	0,02
322	0,00	0,05	0,41	0,39	0,05	0,10
324	0,00	0,01	0,70	0,15	0,02	0,12
333	0,00	0,03	0,13	0,68	0,15	0,01
411	0,05	0,02	0,22	0,64	0,03	0,05
412	0,00	0,01	0,79	0,18	0,00	0,02
511	0,69	0,07	0,02	0,03	0,01	0,18
512	0,67	0,09	0,03	0,04	0,06	0,11

Die Klassifikation der Landbedeckung unterteilt die Landoberfläche spektral in diskrete Klassen. Dabei geht ein Teil der Informationen (Zustand der Vegetation, Bedeckungsgrad usw.) verloren und stehen dem CLC Klassifikationsprozess nicht mehr zur Verfügung. Aus diesem Grund werden auf diesen Landbedeckungsklassen basierend weitere Merkmale aus den Daten generiert.

3.3.2 Kontinuierliche spektrale Merkmale

Unschärfe Merkmale können genutzt werden, um kontinuierliche Parameter im Klassifikationsprozess abzubilden. Die Verwendung der *Fuzzy-Logik* ermöglicht die direkte Umwandlung von menschlichen Wissen in ein mathematisches Modell. Basierend auf den Arbeiten von ZADEH (1965) besteht ein *Fuzzy Regel System* aus

I) Fuzzifizierung

- II) Fuzzy-Inferenz
- III) Defuzzifizierung

Dabei wird der Grad der Unschärfe im Gegensatz zur Wahrscheinlichkeitstheorie durch eine Zugehörigkeitsfunktion beschrieben.

I) Fuzzifizierung der Eingangsgrößen

Durch eine Menge A von Zugehörigkeitsfunktionen wird eine unscharfe Menge (engl. *fuzzy set*) definiert, die eine Eingangsgröße oder *Linguistische Variable* über den Zugehörigkeitsgrad unscharf kodiert. Beispiele für Zugehörigkeitsfunktionen sind Dreiecks-, Trapez- und die Sigmafunktion. Einzelwerte können durch sogenannte Singeltone repräsentiert werden. Als Eingangsgrößen dienen die spektralen Bänder des **Image 2000** Datensatzes.

II) Fuzzy-Inferenz und Regelkomposition

Die verschiedenen Eingangsgrößen können in einem Inferenzmodell logisch miteinander verknüpft werden. Folgende Operationen können nach ZADEH (1965) auf die Mengen angewendet werden: Komplement $\neg A$, Durchschnitt (Konjunktion) $A \cup B$ und Vereinigung (Disjunktion) $A \cap B$. Es gibt mehrere Inferenzmodelle, von denen dabei die MAXMIN-Inferenz und die MAXPROD-Inferenz die wichtigsten Ansätze sind. Für gnosis wurde das erste Verfahren verwendet. Dabei bestimmt das Minimum der verschiedenen Zugehörigkeitsgrade in der Regelkonklusion das Ergebnis der Ausgangsgröße. Das Ergebnis dabei ist wieder eine Fuzzy Menge.

III) Defuzzifizierung der Ausgangsgrößen

Diese *Fuzzy Menge* der Ausgangsgröße muss auf einen exakten Wert ($x \in \mathbb{R}$) reduziert werden. Dabei gibt es wieder verschiedene Ansätze (z. B. *Maximum-Methode* oder *Centre of Gravity Methode*) zur Konstruktion. Das erste Verfahren verwendet dabei den Punkt der maximalen Zugehörigkeit. Das letzte Verfahren beschreibt die Größe durch den Schwerpunkt der Fläche unter der Zugehörigkeitsfunktion. Die implementierten Merkmale nutzen die *Maximum-Methode*.

Für die entwickelte Software gnosis wurden beispielhaft vier unscharfe Merkmale entwickelt und verwendet.

- a. Wasserzugehörigkeit
- b. Vegetationzugehörigkeit
- c. Bodenfarbe
- d. Versiegelungsgrad

Für die ersten drei Merkmale wurde eine unscharfe Menge mit drei Zugehörigkeitsfunktionen gewählt (keine Ausprägung, mittlere Ausprägung, starke Ausprägung des jeweiligen Merkmals). Die Defuzzifizierung erfolgt durch die *Maximum-Methode*, d.h. die höchste Zugehörigkeit wird zurückgegeben. Die Stützpunkte für die verschiedenen Zugehörigkeitsfunktionen wurden aus den verwendeten Testszenen ermittelt. Damit stehen neben der Landbedeckungsklasse auch drei kontinuierliche Werte über die Ausprägung (Wasser, Vegetation und Boden) zur Verfügung. Abb. 3.7 zeigt eine Zusammenstellung der maximalen Ausprägung (R: Boden, G: Vegetation und B: Wasser). Dunkle Bereiche im Bild wurden keinem Merkmal zugeordnet. Die-




Abbildung 3.7: Beispiel für die Anwendung der unscharfen Merkmale *Bodenzugehörigkeit*, *Vegetationszugehörigkeit* und *Wasserzugehörigkeit* (RGB) für den Raum Frankfurt; durch die Merkmale nicht beschriebene Flächen sind schwarz dargestellt.

se Flächen werden jedoch über den Parameter Versiegelungsgrad abgedeckt. Dieser Parameter wurde durch das Verfahren der Stützvektorregression aus den multispektralen Daten abgeleitet.

a. Wasserzugehörigkeit

Die Ausgangsgröße Wasserzugehörigkeit wird pro Pixel indirekt über die dunkelsten Spektren im Bild gerechnet. Dabei wird ausgenutzt, dass der zurück reflektierte Anteil der Strahlung ρ zum Sensor im nahen und mittleren Infrarot (Wellenlängen in nm angegeben) sehr gering ist.

$$f_{Wasser} = \frac{\rho_{830} + \rho_{1650} + \rho_{2210}}{\max \rho_{830} + \max \rho_{1650} + \max \rho_{2210}}$$

Das Ergebnis wird normiert, indem die Summe durch die maximalen Werte der Szene geteilt wird. Die nächste Grafik zeigt die verwendete Fuzzy Menge. Dabei kodieren drei Zugehörigkeitsfunktionen (Abb. 3.8) die Merkmale Reines Wasser, Wasser/Land und Land die Eingangsgröße f_{Wasser} . Die Zugehörigkeitsfunktionen ermöglichen die Charakterisierung der drei Merkmale auch für nicht angepasste Szenen, da die Funktion f_{Wasser} mit relativen Werten arbeitet. Eine Atmosphärenkorrektur würde die Ergebnisse aber zusätzlich stabilisieren.

Neben Wasseroberflächen gibt es auch andere Landbedeckungsklassen, die eine spektrale Ähnlichkeit im Bereich des nahen und mittleren Infrarotbereichs (800 nm bis 2500 nm) aufweisen. Dazu zählt hauptsächlich die Klasse Nadelwald. Durch eine Berücksichtigung einer Vorklassifikation oder eines Vegetationsindizes kann dieses Problem behoben werden. Die Kombination von verschiedenen Merkmalen ermöglicht die eigentliche Differenzierung der Bildobjekte. Das Merkmal Wasserzugehörigkeit wird verwendet, um den Wasseranteil in Objekten pro Pixel mit den Merkmalen reines Wasser, Mischwasser, kein Wasser zu berücksichtigen. Nach der Zuordnung des Objektes zu einer Landbedeckungsklasse stehen einzelne Pixelinformationen für den Klassifikationsprozess direkt nicht mehr zur Verfügung. Dieses Merkmal stellt Hafenanlagen mit kleineren Hafenbecken oder Parkanlagen können dadurch identifiziert werden, wenn die Information der Landbedeckung nicht ausreicht.

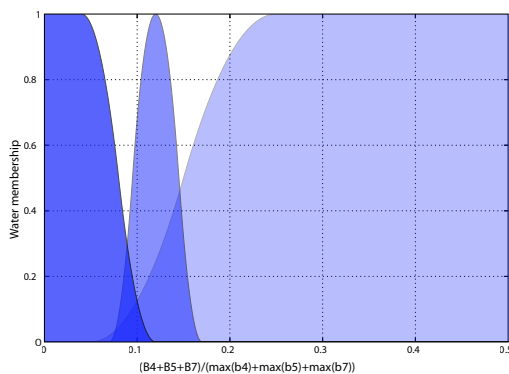


Abbildung 3.8: Fuzzy-Inferenzfunktion zur Bestimmung des Wasseranteils im Pixel

b. Vegetationzugehörigkeit

Die Vegetationszugehörigkeit als Ausgangsgröße wird aus dem NDVI (*Normalised Difference Vegetation Index*), einem Vegetationsindex (LILLESAND UND KIEFER, 2000) berechnet. Dieser Index basiert auf der Reflexionscharakteristik der Zellwand und der Absorption durch Chlorophyll in Pflanzen. Er beschreibt damit Dichte und Vitalität der Vegetationsdecke. Der NDVI wird wie folgt definiert (Angaben in nm):

$$f_{NDVI} = \frac{\rho_{830} - \rho_{660}}{\rho_{830} + \rho_{660}}$$

Der Parameter wird in gnosis verwendet, um Vegetationsklassen im CLC Klassenkatalog weiter differenzieren zu können. Die Basisklassen der Landbedeckung erlauben nur eine diskrete Einteilung der Vegetation. Für Übergangsklassen, wie beispielsweise CLC 324, ist neben der Landbedeckungsklasse auch der Bedeckungsgrad oder der Zustand der Vegetation für die eindeutige Zuweisung nötig.

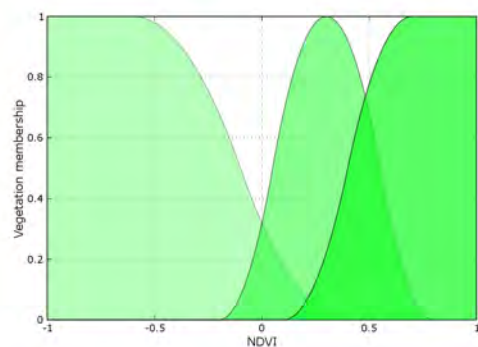


Abbildung 3.9: Fuzzy-Inferenzfunktion zur Bestimmung des Vegetationsanteils im Pixel

Die notwendige Inferenzfunktion (Abb. 3.9) bereitet die Merkmale dichte Vegetation, Mischvegetation und keine Vegetation für die Klassifikation auf.

c. Bodenfarbe

Neben dem Verhältnis von Bandkombinationen kann auch die Charakteristik einer Farbkombination benutzt werden, um Eigenschaften zu beschreiben. Farbe kann unterschiedlich repräsentiert sein (MATTIKALLI, 1997). Eine weitverbreitete Methode dabei ist die HSV-Farbtransformation (*Hue Saturation Value*). Das Farbmerkmal wird dabei durch den Parameter Farbwert (*hue* beschrieben. Der Farbwert und die Sättigung des Echtfarbenkomposits dienen dabei als Eingangsvariablen für das Merkmal Bodenfarbe. In Abbildung 3.10 ist der Parameter der Sättigung konstant.

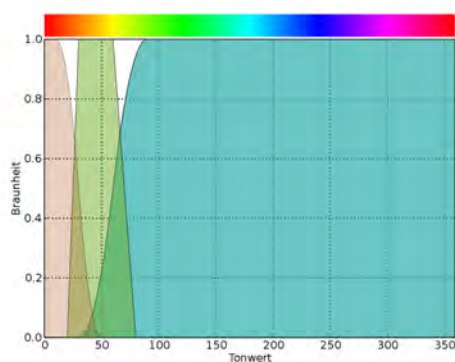


Abbildung 3.10: Fuzzy-Inferenzfunktion zur Bestimmung des Wasseranteils im Pixel

Farbliche Unterschiede zwischen bestimmten Bodentypen und offener Siedlung ermöglichen dem Merkmal die Trennung dieser Landbedeckungsklassen und erhöhen

dadurch die Klassifikationsgenauigkeit dieser Landbedeckungsklassen.

d. Versiegelungsgrad

Der Versiegelungsgrad ist der prozentuale Anteil von durchlässiger (Vegetation und offener Boden) und undurchlässiger (bebaute Flächen) Bodenfläche zu einer Bezugsfläche. Diese Bezugsfläche ist in dieser Arbeit das Pixel. Er dient als wichtiges Merkmal zur Trennung von dicht bebauten (CLC 111) und locker bebauten Siedlungen (CLC 112) bei der automatisierten Klassifikation des gnosis Klassifikationsschemas. Der Parameter kann indirekt durch verschiedene Verfahren aus den Fernerkundungsdaten abgeleitet werden. Beispiele dafür sind das lineare spektrale Entmischungmodell von LU UND WENG (2006) und die Korrelation mit dem NDVI durch DE KOK R. (2005); ESCH (2003).

In dieser Arbeit wurde eine weitere Technik entwickelt, das Merkmal Versiegelungsgrad aus Fernerkundungsdaten abzuleiten. Um die nicht-lineare Dynamik des Parameters abbilden und den Einfluss des offenen Bodens besser berücksichtigen zu können, wurde der Ansatz von ESCH (2003) erweitert. Dabei wurde die lineare Funktion der NDVI-Regression durch eine multiple, nicht-lineare Regressionsfunktion ersetzt. Als Modell wurde dabei die Stützvektor Regression (SVR) verwendet (Details zu der Funktionsweise und der Anwendung von SVR in SMO-LA UND SCHÖLKOPF (2004)). Dabei wird die Response-Variable Versiegelungsgrad durch die Prediktor-Variablen, in diesem Fall die ETM+ Kanäle, bestimmt. Das Mo-

dell wird durch eine Reihe von Stützvektoren trainiert. Die Angaben über den tatsächlich versiegelten Anteil pro Pixel werden aus geometrisch höher aufgelöste Daten, wie beispielsweise Ikonos oder Quickbird Daten, errechnet.

Der tatsächliche Grad der Versiegelung wird aus einer pangeschärften Ikonos-Szene (Abb. 3.11(a)) für den Raum Frankfurt vom 24.6.2003 berechnet. Dazu wird die höher aufgelöste Szene (1 m) nach Wasser, Boden, Vegetation und versiegelten Flächen, wie Straßen und Häuser klassifiziert (Abb. fig:mini:ikonos-sealed). Es wurde ein einfacher Klassifikationsansatz mit empirisch ermittelten Schwellenwerten auf Basis des Vegetationsindex gewählt (NDVI < 0.15 \mapsto Siedlung/Strasse; NDVI > 0.15 und NDVI < 0.3 \mapsto Boden; NDVI > 0.3 \mapsto Vegetation). Der Versiegelungsgrad pro Landsat Pixel (25 m geometrische Auflösung) errechnet sich aus dem Verhältnis der Häufigkeiten der unversiegelten zu den versiegelten Ikonos Pixeln (1 m geometrische Auflösung). Das Ergebnis (Abb. 3.11(c)) ist ein kontinuierlicher 25 m Datensatz der Flächenversiegelung zwischen 0 und 1. Die Trainingsmenge oder die Eingangsvektoren der Regression beinhaltet alle sieben ETM+ Kanäle plus Pan-Kanal, der auf 25 m heruntergerechnet wurde. Der TIR-Kanal (thermales Infrarot) wurde ebenfalls auf 25 m heruntergerechnet. Die Gesamtmenge der Trainingsvektoren wurde von ca. 79 000 Eingangsvektoren auf 30 260 unter der Bedingung von NDVI kleiner 0,1 reduziert, um nur vegetationsfreie Pixel für das Modell zu berücksichtigen.

Dieser Datensatz wird für das Modell aufbereitet (konvertiert und skaliert). Als

Modell wurden Teile der *Support Vector Machines* genutzt, die neben der binären Klassifikation auch multivariate Regressionen durchführen können. Als freie SVM-Bibliothek wurde `libsvm2` von CITET-CHANG2001 verwendet.





Abbildung 3.12: Das Subtraktionsbild zwischen dem modellierten und tatsächlich ermittelten Versiegelungsgrad zeigt die Fehler des Verfahrens auf. Die Darstellung wurde zur besseren Interpretation invertiert. Dunkle Bereiche weisen eine höhere Abweichung auf.

Der *RMSE* (mittlere quadratische Abweichung) des Modells belief sich auf 0,06 mit einem Korrelationskoeffizienten von 0,61. Durch die Modellierung verschob sich der Wertebereich von $[0 \dots 1]$ nach $[0.11 \dots 1.19]$. Der Wertebereich wurde durch eine *MinMax* Skalierung an den Bereich $[0.0 \dots 1.0]$ korrigiert.


Die Abbildung 3.12 zeigt die Unterschiede zwischen den modellierten (Abb. 3.11(d)) und den tatsächlichen Werten




(a)



(b)



(c)



(d)

Abbildung 3.11: Durch eine überwachte Klassifikation wurde aus der IKONOS Szene (3.11(a)) die versiegelten Flächen (Siedlungs- und Verkehrsflächen) extrahiert (3.11(b)). Anschließend wurde der Versiegelungsanteil für einen 25 m Pixel berechnet (3.11(c)). Abb. 3.11(d) ist das Ergebnis einer Regression aus dem ETM+ Daten und dem trainierten SVR-Modell.

(Abb. 3.11(b)) in Form eines Differenzbildes. Eine hohe Abweichung wird in dunklen Tönen dargestellt. Der größte Fehler trat an den Objekträndern auf, da die geometrisch höher aufgelösten Ikonos Daten trotz Skalierung und Aggregation auf 25 m einen größeren Detailgrad aufwiesen. Weitere Fehler treten in offenen Ackerflächen durch die hohe spektrale Ähnlichkeit und durch flächenhafte Veränderungen (Wohngebiet im Süden) zwischen den beiden Datensätzen (Landsat: 2000 und Ikonos: 2005) auf.

3.3.3 Formmerkmale

Aus der durch Segmentierung generierten Geometrie können Formparameter abgeleitet werden, die eine weitere unabhängige Informationsebene für die Klassifikation darstellen, um eine Klasse zu beschreiben. Beispiele für einfache Merkmale sind Fläche, Umfang, Kompaktheit und fraktale Dimension. Aufwendigere Verfahren verwenden z. B. die Skelettierung der Polygone, um die Hauptausrichtungen oder die Komplexität des Objektes zu bestimmen. Für die Software gnosys wurde ein weiteres Merkmal entworfen, um regelmäßige Objekte zu identifizieren. Die Regelmäßigkeit ist hierbei das Vorhandensein von bestimmten Winkeln an den Objektgrenzen. Anthropogen geprägte Flächen zeichnen sich durch regelmäßige Formen bzw. Winkel in den Geometrien aus, wie zum Beispiel lineare Grenzabschnitte oder bestimmte Winkel basierend auf den Parzel-

lengrenzen und den Wegenetzen. Diese Eigenschaft kann genutzt werden, um anthropogen genutzte Objekte zu identifizieren.




Abbildung 3.13: Beispielhafte Extraktion der Objektwinkelliste durch die Schritte (a) Positionsliste, (b) Objektkanten und (c) Objektwinkel.

Detektion der Grenzen

Für die programminterne Verarbeitung der Objekte existiert eine zweidimensionale Rastermatrix der einzelnen Pixelpositionen $P = \{1, 2, 3, \dots, 23\}$. Diese wird verwendet, um die Objektgrenzen zu extrahieren. Ein Verfolgungsalgorithmus ermittelt die Randpixel des Objektes im Uhrzeigersinn und legt diese in eine Randliste R ab. In dem Beispiel aus Abb. 3.13 ist $R = \{1, 2, 3, 4, 8, \dots, 13, 9, 5, 1\}$.

Erstellung der Winkelliste

Aus der Randliste R kann eine pixelbasierte vorläufige Winkelliste $W_p = \{90^\circ, 90^\circ, 90^\circ, 180^\circ, 135^\circ, \dots, 90^\circ\}$ erstellt werden. Diese Liste wird zu der absoluten Winkelliste W_a generalisiert, indem durch eine Kostenfunktion $f(\varphi, L)$ ermittelt wird, welche Punkte für die Randwinkel berücksichtigt werden. Die Liste besteht aus den Winkel φ und der jeweiligen Abschnittslänge L .

Der Winkel φ wird wie folgt ermittelt: für die zwei Punkte $\frac{x_1}{y_1}$ und $\frac{x_2}{y_2}$ berechnet man $x = x_2 - x_1$ und $y = y_2 - y_1$. Dabei müssen die zwei folgenden Fallunterscheidungen betrachtet werden.

$$\varphi = \begin{cases} \frac{\pi}{2} - 2 * \arctan \frac{x}{\sqrt{x^2+y^2+y}} & , y \geq 0 \\ \frac{3\pi}{2} + 2 * \arctan \frac{x}{\sqrt{x^2+y^2-y}} & , y < 0 \end{cases}$$

Der Bogenmaß-Winkel wird zur besseren Lesbarkeit durch $\varphi = \frac{\varphi * 180}{\pi}$ transformiert. Der euklidischen Abstand L zwischen den Punkten $\frac{x_1}{y_1}$ und $\frac{x_2}{y_2}$ wird bestimmt durch

$$L = \sqrt{(|x_1 - x_2|)^2 + (|y_1 - y_2|)^2}$$

Die Kostenfunktion (Abb. 3.14) garantiert, dass der relative Startwinkel in jeder Richtung aus den nächsten Punkt suchen kann. Je größer der Abstand L dabei wird, desto kleiner wird dabei der Suchwinkel φ .




Abbildung 3.14: Schematische Darstellung der Kostenfunktion für die Ermittlung des generalisierten Winkels

Für das Beispiel aus Abb. 3.13 ist die ermittelte absolute Winkelliste $Wa = \{90^\circ : 75m, 150^\circ : 65m, 220^\circ : 90m, 270^\circ : 50m, 0^\circ : 125m\}$ bei einer gegebenen Pixelgröße von 25 m.

Auswertung der Winkelliste

Die erzeugte Winkelliste kann absolut und relativ betrachtet werden. Die absoluten Winkel aus Wa geben die Hauptrichtung des Objektes an. Dazu kann die Häufigkeitsverteilung der Winkel und deren Längen genutzt werden. In dem gezeigten Beispiel dominiert kein einzelner Winkel.

Darüber hinaus kann die Winkelliste relativiert werden, d.h. es wird eine neue Liste mit Winkeldifferenzen erstellt. Dabei gilt $Wr_i = 180^\circ - (Wa_i - Wa_{i-1})$ für $i = 1, 3, \dots, n$ und $Wa_0 = Wa_n$. Die Liste Wr für das obengenannte Beispiel ist $\{130^\circ, 110^\circ, 130^\circ, 90^\circ, 90^\circ\}$.

Diese Liste der Winkeldifferenzen gibt die objektinterne Winkelzusammensetzung wieder. Damit können unabhängig zur Ausrichtung des Objektes die internen Winkel extrahiert und analysiert werden. Die Winkelangaben können die Winkeltypen typisiert werden in:

- Vollwinkel: 360°
- überstumpfer Winkel: $> 180^\circ \wedge < 360^\circ$
- gestreckter Winkel: 180°
- stumpfer Winkel: $> 90^\circ \wedge < 180^\circ$
- rechter Winkel: 90°
- spitzer Winkel: $< 90^\circ$

Das Merkmal kann verwendet werden, um regelmäßige Objekte, darunter landwirtschaftlich genutzte Flächen und Waldpar-

zellen zusätzlich zur Landbedeckung zu beschreiben.




Abbildung 3.15: Beispiel für den regelmäßigen Formenschatz der Bildsegmente in landwirtschaftlich genutzten Flächen

Die Auswertung der Geometrie (Abb. 3.15) ist abhängig von der Erstellung der Bildsegmente. Im Programm eCognition wird die Segmentierung durch die drei Parameter *Scale*, *Shape* und *Compactness* gesteuert. Der *scale*-Parameter ist ein abstrakter Wert, der die maximal zulässige Heterogenität für die Verschmelzung von zwei Flächen beschreibt. Er steht damit indirekt in Beziehung zur durchschnittlichen Objektgröße, da eine größere Heterogenität auch größere Flächen bedingt. Der *shape*-Parameter steuert den Einfluss der Eingangsbänder und der darin enthaltenen Pixelverteilung durch das Verhältnis $1 = color + shape$. Je größer der *shape*-Parameter gewählt wird, desto unabhängiger werden die Segmente von den Eingangsdaten gebildet. Dann beschreibt das Verhältnis $shape = smoothness + compactness$ die endgültige Ausprägung der Segmente.

Mehrere Arbeiten, darunter LEUKERT (2002) haben gezeigt, dass eine Anpassung dieser Parameter in Abhängigkeit zum verwendeten Sensors und der zu extrahierenden Objektarten erfolgen muss. Die Testszenen in dieser Arbeit wurden mit den Parametern ($scale=[20, 40, 60]$, $shape=0.2$ und $compactness=0.6$) segmentiert.

3.3.4 Merkmale durch räumlichen Kontexteinbezug

Neben der Betrachtung der Geometrie kann auch die Topologie genutzt werden, um hilfreiche Merkmale zur Klassifikation abzuleiten. Unter der Topologie werden nach BARTELME (2005) die nicht-metrischen Eigenschaften des Raums zusammengefasst. Darunter fallen solche Eigenschaften, die bei umkehrbar eindeutigen und stetigen Abbildungen oder Transformationen invariant bleiben, wie beispielsweise die gegenseitige Lage und Anordnung der geometrischen Gebilde.

Ein wichtiges Element dabei ist die Nachbarschaftsbeziehung zu anderen Objekten (BAR, 2004). Diese Nachbarschaftsstruktur kann einfach oder erweitert berücksichtigt werden. Einfach berücksichtigt bedeutet in diesem Zusammenhang, dass nur die jeweiligen Nachbarobjekte eines Zentralobjektes berücksichtigt werden.

Bei der erweiterten Nachbarschaft hingegen vergrößert sich die Struktur, indem ein Nachbarschaftskomplex betrachtet wird. Der Nachbarschaftskomplex ist eine dynamische Struktur, die eine funktionale Einheit im räumlichen oder thematischen Sinne beschreiben kann. Dabei kön-

nen die Parameter Komposition und Konfiguration zur Klassifikation des Raums oder zur Identifikation von Substrukturen genutzt werden.

Die Nachbarschaft eines beliebigen Objektes, z.B. der Bildsegmente seg_i oder CLC Objekte clc_i , wird in einer Adjazenzliste abgelegt. Der Begriff Adjazenz stammt aus der Graphentheorie und bezeichnet die Berührung von gleichen Strukturen. Sie beschreibt damit die Beziehung zwischen gleichartigen Elementen in einem Graph. Die Nachbarschaft kann somit in einem zusammenhängenden Graphen dargestellt werden. Für die Verarbeitung von Graphen gibt es eine Reihe von Verfahren aus der Informatik, wie beispielsweise Datenrepräsentation, Struktursuche und Generalisierung (DISTEL, 1990).




Abbildung 3.16: Nachbarschaften und ihre Repräsentation durch Graphen

Einfache Nachbarschaftsbeziehungen

Die Nachbarschaften werden über den Vektor N beschrieben und in einer relationalen Datenbank über eine 1:n Beziehung gespeichert. Das Objekt seg_i hat dann die Nachbarn seg_a, seg_b, \dots . Dann ist der Nachbarvektor von diesem Objekt $N_i =$

$\{seg_a, seg_b, \dots\}$. Da die Nachbarschaft von beiden Objekten ausgeht, ist der Graph ungerichtet (Abb. 3.16 und 3.17). Die Beziehungen „ist Nachbar von“ und „hat Nachbar“ werden in der Ontologie berücksichtigt, spielen aber bei der Klassifikation keine Rolle.

Tabelle 3.6: CLC Klassen, die durch Nachbarschaften definiert werden

CLC Klasse	Nachbar zu CLC ...
CLC 123	51x, 52x
CLC 141	112
CLC 331	zwischen 51x und 52x oder 41x / 423
CLC 412	324
CLC 423	zwischen 51x und 52x
CLC 521	331 oder 523

Tabelle 3.6 zeigt alle CORINE LC Klassen auf, die neben der Landbedeckung durch ihre Nachbarschaft definiert werden. Neben der direkten Ableitung der CLC Klasse kann die Nachbarschaft als Wichtungsfaktor genutzt werden, um die Landbedeckungsklassifikation der Bildsegmente zu optimieren.

Die Nachbarschaft allein reicht nicht aus, um CLC Klassen korrekt zuzuweisen. Nicht jedes Industriegebiet an einem Fluss oder dem Meer ist auch automatisch eine Hafenanlage. Das dafür benötigte Merkmal wäre die Information über das Vorhandensein von Hafenbecken.

Erweiterte Nachbarschaftsbeziehungen

Die erweiterte Nachbarschaft fügt in einem rekursiven Prozess die umliegenden Objekte mit ihren Nachbarn in die Struktur des Nachbarschaftskomplexes. Dabei kann die-

se räumlich, wie zum Beispiel beim Voralpenland oder thematisch, ein beliebiges Stadtgebiet, begrenzt werden. Im Rahmen einer Diplomarbeit wurde eine Methode entwickelt (SCHORCHT, 2006), um Subgraphen im Gesamtgraph fehlertolerant wiederzufinden. Dieses Verfahren kann adaptiert werden, um komplexe Strukturen für die Klassifikation zu parametrisieren.

Abb. 3.17 verdeutlicht den Aufbau einer Nachbarschaftsstruktur. Dabei können kleinere, homogene Strukturen (grau hinterlegte Objekte) weiter zusammengefasst werden. Der Parameter Komposition gibt die Verteilung der einzelnen Objekte aufgrund der Landbedeckung an. Die Konfiguration hingegen verwendet keine Einzelobjekte, sondern Tuplets und Triplets, um die Verteilung von Substrukturen, wie die Muster aus dicht und locker bebauten Flächen zu berücksichtigen.

Tabelle 3.7: CLC Klassen, die durch ihre Struktur definiert sind

CLC Klasse	Zusammengesetzt aus CLC
CLC 242	112, 211, 231, 31x
CLC 243	(21x, 22x, 231) > 75% oder 3xx > 75%

In der CORINE LC Methodologie gibt es nur zwei Klassen in der Gruppe CLC 24x: *Heterogene landwirtschaftliche Flächen*) mit einer komplexen semantischen Zusammensetzung. Diese fallen in den landwirtschaftlichen Bereich und decken eine Fläche von ca. 8% des Staatsgebietes ab (siehe Tabelle C.3).

Die alpine Vegetationsfolge der CLC Klassen 321 (*Natürliches Grünland*), 322 (*Heiden und Moorheiden*), 324 (*Wald-Strauch-Übergangsstadien*) und 312 (*Nadelwald*) auf-

grund der Höhenzonierung kann ebenfalls als Nachbarschaftsstruktur aufgefasst werden und ermöglicht neben der Höheninformation die Klassifikation der Objekte.

In der Arbeit von SCHORCHT (2006) konnte gezeigt werden, dass die Identifikation von räumlichen Strukturen durch ihre Nachbarschaften möglich ist. Dabei konnten diese Substrukturen in vielen Fällen sogar ohne semantische Informationen gefunden werden.

3.3.5 Zeitliche Merkmale

Zeitliche Merkmale ermöglichen die Berücksichtigung von temporalen Veränderungen eines Objektes in die Klassifikation. Dies ermöglicht die Identifikation von bestimmten Klassen der Landnutzung (siehe Tabelle 3.8) identifiziert werden. Die zeitliche Komponente kann in Fernerkundungsdaten durch zwei Verfahrensweisen abgedeckt werden:

- I) Erkennung der Veränderungen in mindestens zwei zeitlich unterschiedlichen Aufnahmen (*Change detection*)
- II) und Verarbeitung von kontinuierlichen Daten, der Zeitreihen-Analyse.

Für die automatisierte Auswertung der Daten ist die Analyse von Zeitreihen zu bevorzugen, da ohne *a-priori* Wissen der einzelnen Datenaufnahmen und der stattfindenden Prozesse gearbeitet werden kann. Der Verlust der Vegetationsdecke kann durch viele Veränderungsprozesse (systembedingt, natürliche oder anthropogene Veränderungen) verursacht werden. Systematische Veränderungen können durch Me-




Abbildung 3.17: Ausschnitt einer komplexen Nachbarschaftsbeziehung zwischen mehreren CLC Objekten (rot: Siedlung, blau: Wasserkörper, grün: Wälder, Ockertöne: landwirtschaftliche Flächen). Diese Strukturen können durch einen zusammenhängenden Graphen beschrieben werden und stehen nach einer Parametrisierung für eine Klassifikation zur Verfügung.

thoden der Datenvorverarbeitung (Szenen-anpassung, Atmosphärenkorrektur, Ausmaskierung von „Datenausreißern“) minimiert werden. Natürliche Veränderungen, wie Phänologie und Sukzession, können durch inter-annuelle Analysen extrahiert werden, da diese Änderungen sich langsam in bestimmten Zyklen (periodische Veränderungen) vollziehen. Anthropogene Eingriffe hingegen verändern die Landoberfläche zeitlich gesehen schnell und aperiodisch; diese Änderungen können intra-annuell detektiert werden. Ausnahmen davon sind Katastrophenereignisse, wie z. B. Wind- und Feuerschäden, die ebenfalls zeitlich schnelle Ereignisse darstellen, die nicht unbedingt anthropogen induziert sind. Kontinuierliche Daten erlauben die Betrachtung des Kontextes einer Veränderung und wurden in dieser Arbeit angewendet. Zeitreihenanalysen von optischen Fernerkundungsdaten wurden beispielsweise zur Klassifikation von Ernte- phänologien (SAKAMOTO *et al.*, 2005) und Vegetationsveränderungen ZHANG *et al.*

(2003) verwendet. Neben optischen Daten können auch multitemporale SAR-Daten als Grundlage zur Klassifikation von Landbedeckung als Grundlage dienen (KUROSU *et al.*, 2001).




Abbildung 3.18: Der intra- und interannuelle Vergleich der Phänologie ermöglicht die Trennung zwischen Ackerland (hellgrün) und Grünland (dunkelgrün).

Die Abbildung 3.18 zeigt den durchschnittlichen phänologischen Vegetationsverlauf der CLC Klassen 211: Nicht bewässertes

Ackerland und CLC 231: Weideland zwischen Januar 2001 und Dezember 2004. Die Phänologie wurde aus dem zeitlichen Verlauf des Vegetationsindizes EVI, dem *Enhanced Vegetation Index*, aus MODIS-Daten ermittelt. Eine Beschreibung der Vorverarbeitung von MODIS-Daten erfolgt im Abschnitt über die technischen Aspekte der Implementierung im Abschnitt 3.5.2. Die dunkelgrüne Kurve ist die gemittelte Phänologie für ein CLC Objekt der Klasse Weideland (CLC 231). Trotz der jahreszeitlichen Schwankungen ist die Vegetationsschicht in der Vegetationsperiode sehr dicht und vital (während der vegetationsaktiven Phase zwischen 0,5 und 0,75). Im Unterschied zum gemittelten Verlauf der Klasse Ackerland (CLC 211) gibt es keinen Abbruch der Vegetationstätigkeit durch eine Ernte im Sommer. Die starken Schwankungen der Daten spiegeln den systematischen Fehler verursacht durch die Atmosphäre, Aufnahmewinkel und Schneebedeckung im Winter wider.

Der Verlauf zeigt eindeutig die anthropogen bedingten Unterschiede zwischen den CLC Klassen 211 und 231. Ohne diese zeitliche Zusatzinformation können diese CLC Klassen nicht eindeutig getrennt werden. Die Abbildung 3.18 zeigt zusätzlich die Schwierigkeit, diese Informationsebene zu parametrisieren. Die Auswertung von absoluten Werten führt durch die zuvor erwähnten Störungen zu instabilen Ergebnissen. Univariate statistische Parameter können weiterhin keine Aussagen über den kontinuierlichen Verlauf der Phänologie geben. Aus diesem Grund wurde die Fourier-Transformation, ein Verfahren aus der Signalverarbeitung gewählt, das die Informa-

tion auf der Basis von periodischen Schwingungen auswertet.

Die **Fourier-Transformation** gehört zu den Integralfunktionen, wie z.B. die Laplace-Transformation, die eine gegebene Funktion $f(t)$ einer anderen Funktion $(Tf(t))$ zuweist. Sie wandelt eine von der Zeit t abhängige Funktion in den *reziproken* Frequenzraum um und bildet sie durch eine Reihe von Basisfunktionen ab. Die stetige Zeitfunktion $f(t)$ kann in eine Fourierreihe transformiert werden, wenn die Funktion absolut integrierbar ist, d.h. in $L^1(R)$ liegt. Die Definitionsmenge von f ist ein diskretes, endliches und periodisches Intervall. Das aus der Fourier-Transformation (genauer diskrete Fourier-Transformation) abgeleitete Frequenzspektrum ist wiederum diskret und endlich.




Abbildung 3.19: Die verschiedenen Schwingungen der Fourierreihe besitzen bei gleicher Phase unterschiedliche Amplituden

FOURIER postulierte, dass sich eine diskrete kontinuierliche Funktion $f(t)$ aus periodischen, harmonischen Schwingungen (Sinus- oder Kosinusfunktionen mit verschiedenen Phasen und Amplituden) zu-

sammensetzt (Abb. 3.19). Durch trigonometrische Summierung kann diese periodische Funktion durch die Fourier-Reihe approximiert werden. Die Koeffizienten von $\cos(nx)$ und $\sin(nx)$ in einer diskreten Fourierreihe, die einer stetigen Funktion $f(t)$ zugeordnet sind, werden **Fourierkoeffizienten** genannt.

Dazu gilt für die Berechnung für die reelle Fourierreihe im Periodenbereich zwischen 0 und T und der Grundfrequenz $\omega = 2 * \pi / T$ in der allgemeinen Form:

$$f(t) = \frac{1}{2}a_0 + \sum_{n=1}^{\infty} (a_n \cos(\omega n t) + b_n \sin(\omega n t))$$

$$a_n = \frac{1}{T} \int_0^T f(t) \cos(\omega n x) dt$$

$$b_n = \frac{1}{T} \int_0^T f(t) \sin(\omega n x) dt$$

Die Darstellung der Koeffizienten kann in einer komplexen und reellen Form erfolgen. Für die Parametrisierung der zeitlichen Charakteristik wurden die reellen Koeffizienten der Sinus- und Kosinusfunktion verwendet. In dieser Arbeit wurden die reellen Koeffizienten für die Sinus- und Kosinusschwingungen verwendet, um die Parametrisierung zu vereinfachen und die Datenhaltung nicht um komplexe Zahlen erweitern zu müssen.




Abbildung 3.20: Der phänologischen Jahresgang von Ackerflächen im Verlauf von vier Jahren und die harmonischen Komponenten

Die Rekonstruktion der phänologischen Kurve kann durch ihre harmonischen Schwingungen erfolgen (Abb. 3.20). Die obere Abbildung zeigt die Originalwerte des EVI für die CLC Klasse 211 in dem Zeitfenster zwischen 2001 und 2004. Die Daten basieren auf dem 16-tägigen temporalen Komposit des MODIS-Produkts MOD13 – *Vegetation Index* (insgesamt 92 Zeitschnitte für vier Jahre). Diese Zeitreihe kann als Funktion in ihre harmonischen Schwingungen zerlegt werden (untere Abbildung). Die Farbe der Schwingung zeigt den Grad der harmonischen Schwingung an (von hellgrau $n = 0$ oder Mittelwert der Schwingung nach dunkelgrau $n = 46$). Die Zerlegung des Signals in die einzelnen harmonischen Schwingungen kann als *Glättungsfilter* durch Rekonstruktion oder Aufmodulierung der ersten Schwingungen verwendet werden. Zusätzlich stellen die einzel-

nen Koeffizienten eine weitere unabhängige zusätzliche Informationsebene dar.

Die Koeffizienten beeinflussen die Amplitudenstärke der jeweiligen harmonischen Schwingung und werden durch den phänologischen Verlauf der Bodenbedeckung beeinflusst. Weiterhin bestimmt die Anzahl der Schwingungen und die Komplexität des Signals sowohl die einzelnen harmonischen Schwingungen, als auch die Koeffizienten. Aus diesem Grund wurden nachfolgende Analysen nur mit Jahresverläufen durchgeführt. Der Einfluss der Koeffizienten aus der Fourierreihe kann für die verschiedenen CLC Klassen genutzt werden, um Vegetationsklassen weiter differenzieren zu können (Abb. 3.21). Als Ba-

sis für die folgenden CLC Klassenanalysen dienen MODIS-Daten für Deutschland (Vegetationsindex EVI mit 250m Auflösung von 2001 bis 2005) und der CLC 2000 Datensatz. Die Phänologie wurde jahresweise berechnet (23 Datensätze). Zur Ableitung der Vegetationsdichte auf der X-Achse wurde der Mittelwert des zweiten Kosinus-Koeffizienten für die jeweilige CLC Klasse ausgerechnet. Vegetationslose Klassen haben dadurch negative Werte. Die CLC Klasse 231: *Weideland* weist den – zeitlich gesehen – höchsten Vegetationsindex auf. Die Standardabweichung des dritten Sinus-Koeffizienten (auf der Y-Achse) beschreibt die Schwankung der Phänologie über den Jahresverlauf. *Meeresgewässer* (CLC 523) und dicht bebaute Flächen (CLC

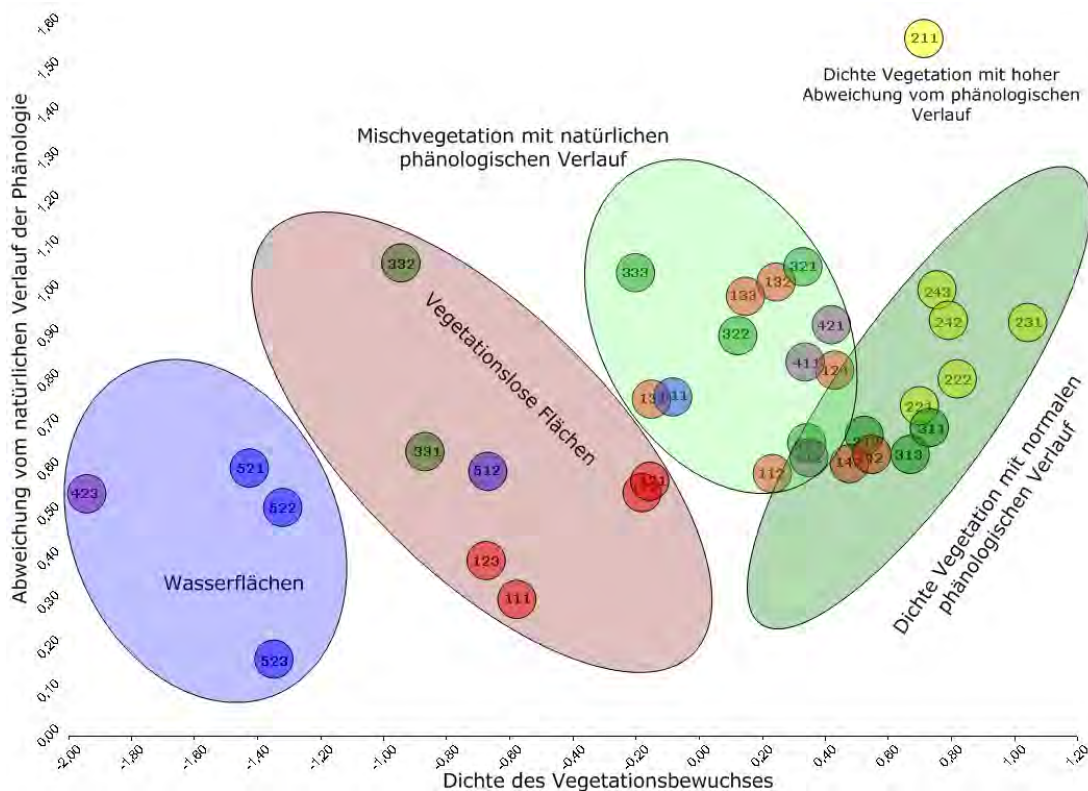


Abbildung 3.21: Differenzierung der CLC Klassen durch temporale Merkmale

111 und CLC 123) besitzen die geringsten Schwankungen in der Phänologie. Die größten Schwankungen treten in den landwirtschaftlichen Klassen (CLC 211) auf. Heterogene Klassen (CLC 242 und CLC 243) heben sich durch ihren Aufbau statistisch nicht von natürlicher Vegetation (CLC 321 und CLC 333) ab.

Für die Software *gnosis* wurden aus diesen Koeffizienten der Fourierreihe zwei Parameter für die CLC Klassifikation empirisch ermittelt: die temporale Variabilität der Phänologie durch die dritte Sinusschwingung und die temporale Intensität der Phänologie durch die zweite Kosinusschwingung. Die **temporale Variabilität** wird in dieser Arbeit als Abweichung der Phänologie vom natürlichen jahreszeitlichen Verlauf definiert. Das Merkmal **temporale Intensität** hingegen beschreibt den Zustand bzw. Dichte der Vegetation über das Jahr gesehen. Durch die Kombination dieser Parameter mit der Landbedeckungsklassifikation kann in dieser Arbeit gezeigt werden, dass landwirtschaftlich genutzte Flächen identifiziert und weiter aufgeschlüsselt werden können.

Durch die Verwendung des Vegetationsindex *Enhanced Vegetation Index* (EVI) zum Aufbau der Zeitreihe können nur phänologische Eigenschaften abgeleitet werden. Die genannten temporalen Merkmale nutzen das charakteristische Verhalten der Vegetation im Jahresverlauf aus, um bestimmte anthropogene Funktionen der Nutzung genauer bestimmen zu können. Um weitere Landnutzungen (Tabelle 3.8) aus den Daten extrahieren zu können, müssen ergänzende Daten aus der Fernerkundung in die Analysen einfließen. Zeitliche Informatio-

nen über die Oberflächenreflexionen, beispielsweise dem MODIS Produkt MOD09, können dabei helfen, Abbauflächen und Baustellen zu detektieren.

Tabelle 3.8: CLC Klassen mit temporalen Eigenschaften

CLC Klasse	Veränderung
131: Abbauflächen	kontinuierliche Veränderung der Bodenbedeckung
133: Baustellen	kurzfristige Veränderung der Bodenbedeckung
211: Ackerland	mehrwähriges Muster von Brache und intensiver Nutzung
231: Weideland	ganzjährig hohe Vegetationswerte (intensive Nutzung) mit geringer Dynamik

Temporale Variabilität

Mit Hilfe des dritten Sinuskoeffizienten können phänologische Schwankungen im Jahresverlauf beschrieben werden. Dadurch können natürliche Vegetationsbedeckungen von anthropogen genutzten Flächen unterschieden werden. Eine Verschneidung des Merkmals mit der CLC Klasse 211: *Nicht bewässertes Ackerland* hat gezeigt, dass 94 % aller Pixel dieser Klasse zugewiesen wurden (Nutzergenauigkeit). Allerdings werden nur 36 % aller landwirtschaftlichen Pixel aus dem CLC 2000 Datensatz bei einer Generalisierung auf 200 m geometrische Pixelgröße gefunden (Erstellergenauigkeit). Für die Klassifikation wurde angenommen, dass Oberflächen mit einer hohen Varianz der intraannuellen Phänologie (Standardabweichung von größer eins) der landwirtschaftlich genutzten CLC Klasse 211 entspricht.

Um verschiedene Jahre vergleichen zu können, wurden die Jahresdatensätze angepasst (Normierung erfolgt durch die *z-Standardisierung* $f(x_i) = (x_i - \mu_i)/\sigma_i$) für das Jahr i . Die Parameter für diese Normierung können aus Tabelle 3.9 entnommen werden. Für den interannuellen Vergleich zwischen 2001 und 2005 wurde $\sigma > 5$ für die Klassifikation des Ackerlandes angenommen. Das bedeutet, dass der Wert pro Pixel größer einer Standardabweichung pro Jahr liegen muss, um als Ackerland klassifiziert zu werden.



Abbildung 3.22: Die gelben Flächen haben durchschnittliche Werte von größer einer Standardabweichung σ und repräsentieren damit eine intensive agrarische Nutzung. Dunkle Flächen hingegen haben einen Wertebereich kleiner σ .

Viele kleinen Parzellen mit Flächen unter 20 ha können durch die geometrische Auflösung des MODIS Sensors nur ungenau wiedergegeben werden. Zusätzlich können heterogene Strukturen, wie unterschiedliche Landbedeckungstypen das Vegetationssignal vermischen. Im extremen Fall können sich komplexe Parzellenstrukturen im Subpixelbereich gegeneinander aufheben. In Abbildung 3.22 wurden die Koeffizienten für die Jahre 2001 bis 2005 deutschlandweit summiert und farblich kodiert wiedergegeben. Dabei bestimmt das Vielfache der Standardabweichung die Helligkeit. Die flächenhaften, landwirtschaftlich dominierten Regionen der Bundesrepublik Deutschland gehen aus dieser Abbildung klar deutlich hervor.

Die Abbildung 3.23 zeigt einen Detailausschnitt des CLC 2000 Datensatzes von der Region Magdeburg. Die dunkelbraune Rasterung in den landwirtschaftlichen Flächen (beigefarben, siehe CLC Legende A.3) wurde aus dem Parameter der temporalen Variabilität des MODIS-Datensatzes für die Jahre 2001 bis 2005 abgeleitet. Dabei entsprechen Werte mit $\sigma > 5$ der CLC Klasse 211. Durch die unterschiedlichen Maßstabsebenen der verwendeten Datensätze (CLC 1:100 000 und MODIS 1:1.000 000) werden kleinere landwirtschaftliche Bereiche und Mischflächen mit anderen CLC Klassen nicht berücksichtigt. Dennoch erlaubt der Parameter die Trennung zwischen CLC

211: *Nicht bewässertes Ackerland* (gelb) und CLC 231: *Weideland* (hellgrün) bzw. die restlichen CLC Klassen für großflächige homogene Flächen.




Abbildung 3.23: Beispiel für die Ableitung von Ackerflächen durch den Parameter *temporale Variabilität* in der Region Magdeburg

Temporale Intensität

Neben der Abweichung von dem natürlichen phänologischen Verlauf der Vegetation spielt die Vegetationsdichte und der Vegetationszustand eine große Rolle bei der temporalen Klassifikation. Dieser Parameter wird durch den Vegetationsindex direkt beschrieben. Um Ausreißer der Daten bei der Parametrisierung zu minimieren, wurde anstatt des Mittelwertes oder Medians der zweite Kosinuskoeffizient der Fourierreihe verwendet. Dieses Merkmal repräsentiert die Gesamtamplitude der Phänologie für ein Jahr.




Abbildung 3.24: Beispiel für eine Klassifikation der Vegetation auf Basis der temporalen Intensität

Die Validierung des Merkmals mit dem CLC 2000 Datensatz hat für das Staatsgebiet ergeben, dass 47 % aller Pixel mit $x > 5\sigma$ korrekt der CLC Klasse 231: *Weideland* zugewiesen wurden (Nutzergenauigkeit). Bei der Aggregation der CLC Klassen 231, 242 und 243 erhöht sich die Klassifikationsgenauigkeit auf 58 %. Durch die Generalisierungsvorschriften von CORINE werden flächenhaft nicht dominante Flächen kleiner 25 ha der umgebenden, dominierenden Klasse zugewiesen. Aus diesem Grund wurden deutschlandweit 24 % der Klasse CLC 211: *Nicht bewässertes Ackerland* durch das temporale Merkmal als Weideland identifiziert. Eine visuelle Kontrolle ergab, dass in vielen Fällen Weideland kleiner 25 ha der CLC Klasse 211 zugewiesen wurde. Von der CLC Klasse 231 wurden

55 % der Gesamtfläche aus dem CLC 2000 Datensatz richtig klassifiziert (Erstellergenauigkeit).

Die Abbildung 3.24 zeigt die Einteilung in Gebiete mit fehlender und geringer Vegetationsintensität (rote und schwarze Farbe), normaler Vegetationsintensität (grau) und überdurchschnittlicher Vegetationsintensität (hellgrün) auf. Die Weidelandflächen in Norddeutschland (Geest) und im Voralpenland können eindeutig identifiziert werden.




Abbildung 3.25: Detailausschnitt für die CLC Klasse 231 zwischen Augsburg und München

Der Ausschnitt in Abbildung 3.25 stellt in den olivgrünen Flächen die klassifizierte Weideflächen für die Region westlich von München dar. Nicht klassifizierte Flächen sind hellgrün wiedergegeben (z.B. Teile der Leechauen). Das Merkmal *temporale Intensität* ist in der Lage, kleine Strukturen, wie Grünflächen in den Auenbereichen der Flüsse korrekt zu identifizieren. Der Übergang zwischen den Weideflächen im Süden

und dem Ackerland und Waldgebieten im Norden wird richtig wiedergegeben.

Tabelle 3.9: Verwendeter Mittelwert und Standardabweichung der *z-Standardisierung* für die temporalen Merkmale zwischen 2001 und 2005

Jahr	Variabilität		Intensität	
	μ	σ	μ	σ
2001	0.003	0.052	0.496	0.393
2002	0.015	0.052	0.486	0.385
2003	0.005	0.034	0.439	0.349
2004	0.006	0.049	0.477	0.378
2005	0.006	0.044	0.473	0.376

Die Tabelle 3.9 führt die verwendeten Parameter für die Normierung der Jahresdatensätze auf. Interessant ist dabei, dass bei den Parametern der Jahrhundertssummer 2003 sich durch niedrigere Werte bemerkbar macht. Sowohl der Mittelwert der temporalen Intensität, als auch die Standardabweichung der temporalen Variabilität unterscheiden sich von den anderen Jahren. Die extreme Trockenheit in der Hauptvegetationsphase bedingt eine geringere Vegetationsaktivität und damit eine geringere Schwankung über das Jahr gesehen.

Die Eigenschaft der temporalen Intensität kann durch die kontinuierliche Charakterisierung der Vegetation folgende Klassen beschreiben:

- *Keine Intensität:* Vegetationslose Klassen, wie Wasser- und Siedlungsflächen
- *Niedrige Intensität:* Nadelwald, spärlich bewachsene Flächen
- *Mittlere Intensität:* Laubwälder, landwirtschaftliche Flächen
- *Hohe Intensität:* hauptsächlich Weideland

Die entwickelten Merkmale aus den Bereichen Landbedeckung, der phänologische Charakteristik, Form, Nachbarschaft und die unscharfen Merkmale dienen als Grundlage für die Beschreibung der einzelnen CLC Klassen. Die Beschreibung bzw. Modellierung der Klassen erfolgt über der Prototypenbildung im nächsten Abschnitt

3.4 Klassenmodellierung

Die Identifikation und Validation der CLC Objekte benötigt eine prototypenhafte Beschreibung der einzelnen CLC Klassen und werden in dem **Klassenkatalog** gesammelt. Dazu werden eindeutige Merkmale verwendet, um die CLC Klassen zu modellieren und untereinander abzugrenzen. Die Entwicklung und Implementierung der Klassenbeschreibungen und der benötigten Merkmale richtet sich in dieser Arbeit nach dem flächenhaften Vorkommen der einzelnen CLC Klassen. Die fünfzehn häufigsten CLC Klassen mit dem Anteil an der Gesamtfläche finden sich in Tabelle 3.10. Zusätzlich sind die Klassen in thematisch einfache und thematisch komplexe Klassen unterteilt. Die thematische Zusammenstellung (Komposition) entscheidet über die Einteilung der CLC Klasse (siehe Abschnitt 3.1) in diese beiden Gruppen. Diese fünfzehn Klassen bilden den Schwerpunkt dieser Arbeit und wurden in der Rahmensoftware gnosis beispielhaft umgesetzt. Die Anforderung an die entwickelten Merkmale wurden durch diese Klassen vorgegeben.

Tabelle 3.10: Gruppierung der fünfzehn flächenhaft dominanten CORINE LC Klassen nach einfacher und komplexer Zusammensetzung

1. **Thematisch einfache Klassen**
 - 38%** CLC 211: *Nicht bewässertes Ackerland*
 - 16%** CLC 312: *Nadelwälder*
 - 13%** CLC 231: *Wiesen und Weiden*
 - 7%** CLC 311: *Laubwälder*
 - 6%** CLC 112: *Nicht durchgängig städtische Prägung*
 - 1%** CLC 512: *Wasserflächen*
 - <1%** CLC 121: *Industrie- und Gewerbeflächen*
 - <1%** CLC 321: *Natürliches Grünland*
 - <1%** CLC 221: *Weinbauflächen*
 - <1%** CLC 222: *Obst- oder Beerenobstbestände*
2. **Thematisch komplexe Klassen**
 - 7%** CLC 313: *Mischwälder*
 - 6%** CLC 242: *Komplexe Parzellenstrukturen*
 - 2%** CLC 243: *Landwirtschaftlich genutztes Land mit Flächen natürlicher Vegetation von signifikanter Größe*
 - <1%** CLC 324: *Wald/Strauch Übergangsstadien*

Der folgende Klassenkatalog beschreibt alle CLC Klassen, die in Deutschland vorkommen. Dabei wurde versucht, weitgehend die Klassendefinition der EEA (PERDIGAO UND ANNONI, 1997) zu verwenden. Dabei wurde versucht, allgemeine Regeln aufzustellen, die für alle Objekte der jeweiligen Klasse zutreffen. Ausnahmen und Einschränkungen wurden vermieden, um das Regelwerk für die automatisierte Pro-

zessierung einfach und konsistent zu halten.

3.4.1 Klassenkatalog für CLC 1xx – Bebaute Flächen

Städtisch geprägte Flächen sind hauptsächlich vom Landbedeckungstyp *Siedlung*. Die Differenzierung zwischen CLC 111: *durchgängig städtischer Prägung* und CLC 112: *nicht durchgängig städtische Prägung* erfolgt über den Versiegelungsgrad des Objektes. Ein Versiegelungsgrad von größer 80 % und die Lage in einem größeren Verdichtungsraum definiert dabei die Klasse CLC 111.

CLC 121: *Industrie- und Gewerbeflächen* können spektral nur von städtisch geprägten Flächen (CLC 11x) unterschieden werden, wenn die Bebauungsstruktur, wie große Hallenanlagen und versiegelte Freiflächen, die Intensität der reflektierten Strahlung erhöht. Objekte vom Typ CLC 121 befinden sich oft am Rand von Siedlungsflächen (CLC 11x). Funktionale Flächen, wie administrative Gebäudekomplexe, können auf Basis von Fernerkundungsdaten nicht der Klasse 121 zugeordnet werden. Daher werden zusätzliche Informationen, wie das *Amtliche Topographische Kartographische Informationssystem* (ATKIS) benötigt, um diese Lücke umfassend zu füllen. CLC 122: *Verkehrsflächen* können spektral nur unzureichend identifiziert und validiert werden, da die geometrische Auflösung des **Image 2000** Datensatzes trotz Mindestobjektbreite von 100 m nicht genügt, um Signale ohne Mischpixelanteil für die Klassifikation zu erhalten. Aus diesem Grund können Formmerkmale (Linearität) nur bedingt genutzt

werden, da Verkehrsflächen unzureichend von der Umgebung extrahiert werden können. Zusätzliche Informationen, wie Strassenkataster können dabei den Klassifikationsprozess unterstützen. CLC 123: *Hafenanlagen* werden als Industriegebiete am Rand von Wasserkörpern angesprochen, besonders wenn das Objekt ein Hafenbecken enthält. CLC 124: *Flughäfen* können nur validiert werden, wenn sich Bestandteile (versiegelte Flächen, Grün- und Freiflächen) grundlegend geändert haben. Eine höhere geometrische Auflösung kann die Extraktion von Bestandteilen oder Unterobjekten des Flughafens, wie Landebahnen (lineare, in sich geschlossene und versiegelte Objekte) ermöglichen. In diesem Fall kann der Flughafen durch diese Unterobjekte sogar identifiziert werden.

CLC 131: *Abbauflächen* können durch ihre Oberflächencharakteristik nur validiert werden, da eine Abgrenzung zu anderen vegetationslosen Klassentypen (CLC 13x, 211 und 333) aufgrund der fehlenden funktionalen Komponente nicht flächendeckend möglich ist. Großflächige Abbaugelände kommen in Deutschland jedoch nur vereinzelt in bestimmten Bundesländern vor. Neu erschlossene Gebiete beschränken sich auf diese Regionen. CLC 132: *Deponien und Abraumhalden* und CLC 133: *Baustellen* können aufgrund ihrer spektralen heterogenen Eigenschaften (Deponien) und ihrer zeitlichen hohen Dynamik (Baustellen) weder identifiziert, noch validiert werden.

Nachbarschaftsbeziehungen können zur Identifikation von CLC 141: *Städtische Grünflächen* genutzt werden, da diese Flächen von Siedlungsobjekten ganz oder teilweise umschlossen sein müssen. CLC 142:

Sport- und Freizeitanlagen hingegen können aufgrund ihrer vielfältigen anthropogenen Nutzung, der damit verbundenen komplexen Struktur und Lage nicht identifiziert oder validiert werden.

3.4.2 Klassenkatalog für CLC 2xx – Landwirtschaftliche Flächen

Die CORINE LC Klasse 211: *Nicht bewässertes Ackerland* stellt aufgrund ihres Flächenanteils die wichtigste Klasse in der CORINE Klassenhierarchie dar. In der Interpretationsanleitung von BOSSARD *et al.* (2000, S. 48) wird ein Entscheidungsschema definiert, wie die CORINE LC Klassen 211, 22x, 231 und 32x zu unterscheiden sind. Dabei bestimmt der Grad der anthropogenen Nutzungsintensität die jeweilige CLC Klasse (Abb. 3.26). Diese Eigenschaft kann aus Fernerkundungsdaten indirekt durch hochaufgelöste temporale Datensätze abgeleitet werden (siehe 3.3.5).




Abbildung 3.26: Einfluss der anthropogenen Nutzung führt zur Änderung der Landnutzung

Als Basis für die Identifikation werden intra- und interannuelle phänologische Änderungen der Objekte genutzt. Eine extensive oder intensive landwirtschaftliche Nutzung verursacht entweder eine geringe

oder hohe Abweichung vom natürlichen phänologischen Jahresverlauf der Vegetation. Neben diesen temporalen Informationen kann auch die Landbedeckung und die Objektform in die Identifikation miteinbezogen werden. Um bestimmte, spektral ähnliche Bodentypen von Siedlungsobjekten trennen zu können, müssen weitere Merkmale verwendet werden, darunter Objektform und Textur. Die vorgegebene Parzellenstruktur der landwirtschaftlichen Flächen und die spektrale Homogenität kann genutzt werden, um Ackerflächen von unregelmäßigen und spektral stark heterogenen Siedlungsobjekten abzugrenzen. CLC 221: *Weinbauflächen* und CLC 222: *Obst-/ Beerenobstbestände* können multispektral aus den **Image 2000** Daten nicht eindeutig von anderen Vegetationstypen unterschieden werden. Die besonderen Bedürfnisse der Weinstöcke, wie beispielsweise die Sonneneinstrahlung oder bestimmte Bodentypen beschränken den Weinanbau auf bestimmte Anbaugebiete in Deutschland. Durch die intensive Pflege ergeben sich bei beiden Klassen durch das Versorgungswegenetz bestimmte Texturen, die mit geometrisch höheraufgelösten Fernerkundungsdaten extrahiert werden können (TRIAS-SANZ, 2005). Bei der Klasse CLC 231: *Wiesen und Weiden* ist die temporale Charakteristik hingegen essentiell (Abb. 3.27). Im Gegensatz zum Ackerland bleibt die Vegetationsdecke bis auf Mahdereignisse das Jahr über weitgehend geschlossen. Die Vegetationsentwicklung ist deshalb gleichmäßiger als bei Ackerflächen. Die Mahd als anthropogener Einfluss verändert den Zustand der Vegetation, d.h. es kommt zu einem detektierbaren Einbruch des Vegetationssignals zu bestimmten Zeiten im Jahr. Diese Eigenschaft er-




Abbildung 3.27: Die Abbildungen zeigen den phänologischen Verlauf von zwei CORINE LC Klassen für das Jahr 2003. Die ersten und letzten beiden Monate wurden nicht berücksichtigt, da für diese Monate keine reinen Vegetationssignale aufgrund von Wolkenkontaminationen zur Verfügung standen. Details zu der Generierung der Diagramme werden in Abschnitt 3.3.5 gegeben.

möglichst eine Trennung zu CLC 321: *natürlichen Grünland*.

Die CORINE LC Klassen der Gruppe 24x *Landwirtschaftliche Flächen mit heterogener Struktur* sind Sammelklassen für landwirtschaftlich dominierte Flächen und durch die CORINE Klassifikationsvorschrift und der damit verbundenen Flächenaggregation und -generalisierung verursacht. Neben rein landwirtschaftlich genutzten Flächen (Acker- und Weideland) können beliebige andere CLC Klassen mit einer Fläche unter 25 ha vorkommen, wenn der Landwirtschaftsanteil dominiert (größer 75%). Sie gehören deshalb zu der Gruppe der semantisch komplexen Klassen. Die Klasse CLC 242: *Komplexe Parzellenstruktur* kann validiert werden, indem die Unterobjekte auf ihre Größe von kleiner 25 ha hin kontrolliert werden. Objekte mit Flächen größer fünf ha und einer nicht agrarischen Nutzung weisen auf eine mögliche Änderungsfläche hin. Eine Differenzierung zur CORINE LC Klasse *Landwirtschaft und natürliche Bodenbedeckung* (CLC 243) ist schwierig, da die anthropogene Nutzung und ihre Funktion aus den Da-

ten nicht direkt abgeleitet werden kann. Die kontinuierliche funktionale Intensität erschwert die Trennung von anthropogen unbeeinflussten Bestandteilen, wie natürliches Grünland und anthropogen genutzten Flächen, wie beispielsweise Weideland. Eine Verringerung der Objektmindestgröße von 25 auf fünf Hektar würden diese Klassen und die damit verbundene Problematik jedoch lösen können.

3.4.3 Klassenkatalog für CLC 3xx – Wälder und naturnahe Flächen

Die CORINE Nomenklatur definiert einen Wald durch die Fläche des geschlossenen Kronendaches von mindestens 30% der Objektfläche. Die Klassen CLC 311: *Laubwälder* und CLC 312: *Nadelwälder* sind spektral gut identifizierbar. Sie zeichnen sich durch einen Anteil von mehr als 75% Laubwald- oder Nadelwaldanteil aus. CLC 313: *Mischwälder* gehören in die komplexe Kategoriegruppe (Tabelle 3.10), da die Verteilung der Waldtypen auf Objekt-, Pixel-

oder Subpixelebene einen Mischwald definieren können. Die spektrale Auflösung von multispektralen Sensoren, wie Landsat ETM+, SPOT XS und IRS LISS-3 erschwert die Differenzierung von Mischwäldern auf der Pixel- und Subpixelebene durch spektrale Klassifikations- oder Entmischungsverfahren. Eine höhere geometrische Auflösung, wie z.B. von IKONOS-Daten, verschiebt diese Problematik in den Sub-Hektarbereich und würde damit die Identifikation von Mischwäldern in Hinblick auf CLC ermöglichen. Zur weiteren Unterscheidung können Winter- oder Frühjahrsszenen verwendet werden, um kleinere Nadelwaldbestände vom umgebenden Laubwald zu trennen. Die Klasse CLC 321: *natürliches Grünland* kann nicht direkt identifiziert oder validiert werden, da die Intensität der Landnutzung nicht detektiert werden kann. Die verwendeten spektralen und temporalen Merkmale sind nicht sensitiv genug, um diese Klasse mit einer geforderten Genauigkeit von größer 85 % vom Weideland differenzieren zu können.

CLC 322: *Heiden und Moorheiden* können ebenfalls durch ihren heterogenen Aufbau und ihr komplexes Erscheinungsbild weder identifiziert, noch validiert werden. Moore werden hauptsächlich durch ihre Bodeneigenschaften definiert. Fernerkundungsdaten liefern jedoch Informationen über die Bedeckung der Oberfläche. Bei Bewuchs können deshalb Informationen über die Vegetation abgeleitet werden. Heideflächen besitzen keinen einheitlichen Charakter. Sie können als Sukzessionsflächen zum Beispiel auf Truppenübungsplätzen und in der Höhenzonierung der Vegetation in den Alpen vorkommen. CLC 324 *Wald-, Strauch- Übergangsstadien* bilden eine Über-

gangsklasse zwischen CORINE LC 31x und den umliegenden Vegetationsklassen. In der CLC Nomenklatur wird sie als vorübergehende Änderungsklasse angesehen, um beispielsweise Sturmwurfflächen zu kennzeichnen. Die Klasse CLC 331: *Strände, Dünen und Sandflächen* kommt nur in Verbindung mit Feucht- und Wasserflächen (CLC 4xx und CLC 5xx) vor und ist vegetationsfrei. Durch die Eigenschaften Landbedeckung und Nachbarschaft kann diese Klasse validiert werden. Die Klassen CLC 332: *Felsflächen ohne Vegetation* und CLC 333: *Flächen mit spärlicher Vegetation* hingegen können durch die spektrale Ähnlichkeit nicht eindeutig von anthropogenen Klassen getrennt werden. Indizien können Höheninformationen und die Nähe zu Objekten der CLC Klassen 1xx und 2xx liefern. CLC 334: *Brandflächen* können durch zeitlich kontinuierliche Informationen der Landoberfläche gewonnen werden, beispielsweise durch das MODIS Feuerprodukt. Die Lage der Feuer dient dann als Grundlage für die nachfolgende spektrale Analyse der verbrannten Fläche. Durch eine Kombination aus einer zeitlichen Beobachtung und von Höheninformationen kann die Klasse CLC 335: *Gletscher und Dauerschneegebiete* identifiziert werden. In Deutschland kommt diese Klasse jedoch nur am Zugspitzmassiv vor.

3.4.4 Klassenkatalog für CLC 4xx – Feuchtflächen

Feuchtflächen (CLC 4xx) können im allgemeinen monotemporal nicht eindeutig identifiziert oder validiert werden, da das Hauptmerkmal, die regelmäßige Überflutung durch Hochwasser oder Gezeiten, der

Klasse nur über eine konstante zeitlich hochaufgelöste Beobachtung des Objektes abgeleitet werden kann. CLC 411: *Sümpfe* können durch ihre komplexe Oberflächencharakter von anderen Vegetationsklassen nicht weiter differenziert werden. Bodenkarten können als weitere Information verwendet werden, um diese CLC Klasse validieren zu können. Durch eine geringe phänologische Aktivität, gemessen durch das Merkmal temporale Intensität und der Einbeziehung der Nachbarschaftsverhältnisse zur CLC Klasse 324 können Objekte der Klasse CLC 412: *Torfmoore* validiert werden. Die CLC Nomenklatur beschreibt das Vorkommen und eine klare Abfolge von CLC Klassen für die Klasse 412.

Feuchtplächen an der Küste (CLC 42x) unterliegen den Einfluss der Gezeiten. CLC 421: *Salzwiesen* und CLC 423: *in der Gezeitenzone liegende Flächen* können durch zeitlich höchstauflöste Daten identifiziert werden. Spektral unterscheiden sich Salzwiesen vom umgebenden Grünland und können damit klassifiziert werden. Durch Nachbarschaftsbeziehungen zu Objekten der Klasse 52x kann die Klasse CLC 423 validiert werden.

3.4.5 Klassenkatalog für CLC 5xx – Wasserflächen

Wasserflächen (CLC 5xx) können durch ihre spektrale Charakteristik gut identifiziert werden. Die Differenzierung innerhalb der Gruppe erfolgt über Formparameter der Objekte (bei den Wasserflächen im Landesinneren (CLC 51x)) und ihre Lage im Kontext (Meeresgewässern (CLC 52x)). CLC 511: *Gewässerläufe* sind lineare Objekte mit

einer Mindestbreite von 100 m. Die Objektbreite kann durch eine inverse Pufferung des Objektes an verschiedenen Stellen kontrolliert werden. CLC 512: *Wasserflächen* unterscheiden sich von Gewässerläufen durch ihren flächenhaften Charakter, beispielsweise über den Rundheitsindex $\frac{4\pi A}{p^2}$ nach SELKIRK.

Meeresgewässer können größtenteils aus der CLC 1990 Klassifikation übernommen werden. Abgrenzungen zu Inlandgewässern finden über den Salzgehalt statt, der nicht direkt aus Fernerkundungsdatensätzen abgeleitet werden kann. Eine vordefinierte Küstenlinie und Nachbarschaften können als Indiz genutzt werden, um diese Klassen zu identifizieren. CLC 521: *Lagunen* befinden sich nur in den Flachwasserzonen der Ostsee. Die Klasse CLC 522: *Mündungsgebiete* von Flüssen können durch die Nachbarschaft von Flüssen und dem offenen Meer identifiziert werden. Aufgrund der subjektiven Grenzziehung dieser Klassen ist eine automatische Extraktion dieser Klassen jedoch nicht möglich.

3.4.6 Zusammenfassung

Der Klassenkatalog beschreibt die einzelnen CLC Klassen und gibt die benötigten Merkmale zur Identifikation oder Validation an. Auf dieser Grundlage kann ein *Regelwerk* aufgebaut werden, dass diese *a-priori* Beschreibungen informationstechnisch umsetzt. Die Tabelle 3.11 gibt einen Überblick, welche Merkmale für die einzelnen CLC Klassen für die Prozessierung benötigt werden. Das Vorkommen der Klassen wird flächenhaft betrachtet. Die Merkmale sind in den Kategorien **Identifikation** und **Valida-**

tion geordnet. Der Status gibt an, ob eine Klasse identifiziert (**I**), validiert (**V**) oder nicht verarbeitet (–) werden kann. Das Vorkommen gibt den Rank der CLC Klasse im Flächenvergleich an. Die Bedeutungen der Abkürzungen für die in der Tabelle verwendeten Merkmale sind:

fuzzy: unscharfes Merkmal (Farbmerkmal oder Versiegelungsgrad)

Kontext: Nachbarschaftsbeziehungen

Komposition: Zusammensetzung des Oberobjektes

Zusatz: Zusätzliche Merkmale, wie beispielsweise Boden-, oder Biotoypkarten

LC: Merkmal der Landbedeckung

temp: zeitliches Merkmal (entweder temporale Variabilität oder Intensität)

Dieser Klassenkatalog ist damit die Grundlage für das Gewichtungssystem (Tabelle C.2) für gnosis.

Tabelle 3.11: Klassenkatalog für CORINE LC Klassen

CORINE Hierarchie			Vorkommen	Identifikation					Validation				Status	CLC3
CLC1	CLC2	CLC3		LC	temp	fuzzy	Kontext	Zusatz	LC	temp	Komposition	Kontext		
1xx	11x	111	27	✓		✓							I	111
		112	6	✓		✓							I	112
	12x	121	10	✓		✓	(✓)						I	121
		122	31										–	122
		123	33				✓						V	123
		124	24								✓		V	124
	13x	131	17								✓		V	131
		132	30										–	132
		133	34										–	133
	14x	141	25	✓			✓						I	141
		142	18										–	142
2xx	21x	211	1		✓								I	211
	22x	221	14						✓				V	221
		222	15						✓	✓			V	222
	23x													

Weiterführung auf der nächsten Seite...

3 Entwickelte Methodik

CORINE Hierarchie				Identifikation					Validation				Status	CLC3
CLC1	CLC2	CLC3	Vorkommen	LC	temp	fuzzy	Kontext	Zusatz	LC	temp	Komposition	Kontext		
	24x	231	3	✓	✓								I	231
		242	7						✓		✓		V	242
		243	8										-	243
3xx	31x	311	4	✓									I	311
		312	2	✓									I	312
		313	5	✓				✓					I	313
	32x	321	13					✓	✓				V	321
		322	21										-	322
		324	21								✓	✓	V	324
	33x	331	32						✓			✓	V	331
		332	28										-	332
		333	22						✓		✓		V	333
		335	35	✓	✓								I	335
4xx	41x	411	23										-	411
		412	19						✓	✓			V	412
	42x	421	29						✓				V	421
		423	11									✓	-	423
5xx	51x	511	20	✓									I	511
		512	9	✓									I	512
	52x	521	16						✓	✓			V	521
		522	26	✓			✓						I	522
		523	-	✓			✓						I	523

3.5 Technische Aspekte der Implementierung

Im Rahmen dieser Arbeit wurde eine Software entwickelt und implementiert, um die benötigte Funktionalität zu testen und die Ergebnisse validieren zu können. Das Softwarepaket *gnosis* ist in der Interpretersprache *Python* umgesetzt worden und steht eine Durchführung der Klassifikation von Corine Land Cover als Prototyp zur Verfügung. *Python* zählt zu den objektorientierten Programmiersprachen, unterstützt die schnelle Anwendungsentwicklung (*Rapid Application Development*) und zeichnet sich durch einen strukturierten und gut lesbaren Quellcode aus. Die Programmiersprache wurde von GUIDO VAN ROSSUM am *Centrum voor Wiskunde en Informatica* (CWI) in Amsterdam entwickelt und wird aufgrund ihrer Einfachheit, den kurzen Entwicklungszeiten und den umfangreichen Zusatzbibliotheken in vielen Bereichen der Informationstechnologie (Web-Technologie, Client-Server Dienste, XML-Datenverarbeitung) eingesetzt (VAN ROSSUM, 1995). In dieser Arbeit wird ein kurzer Überblick über die Implementierung des Programmpaketes und der Datenhaltung gegeben. Eine detailliertere Beschreibung der Software liegt dem Programmpaket als technische Dokumentation bei.

3.5.1 Systemaufbau und Umsetzung

Das Programmpaket besteht aus mehreren modularen Komponenten. Dazu zählen Datenimport und -export, der SVM Klassifikator, die Merkmalsgenerierung für

die Sensoren Landsat ETM+ und MODIS, das abstrahierte Datenmodell und das Gewichtungssystem. Der modulare Aufbau ermöglicht eine flexible Erweiterung der Software in Hinblick auf neue Merkmale und Klassifikationsverfahren. Um die Prozessierung von größeren Datenmengen und eine parallele Verarbeitung der einzelnen Klassifikationsschritte zu ermöglichen, wurde statt einer dateibasierten Datenhaltung ein relationales Datenbankmodell eingesetzt. Damit wurde der Datenzugriff der einzelnen Module über das Netzwerk ermöglicht. Weiterhin kann die effiziente Haltung der Daten (Speicherung, Indizierung, Filterung und Verknüpfung) von dem Datenbanksystem übernommen werden. Die Verknüpfung der verschiedenen Datensätze erfolgt über relationale Beziehungen (Pixelbeziehungen von 1:1 bei gleicher geometrischer Auflösung und 1:n bei größerer geometrischer Auflösung) untereinander und kann mit einfachen SQL-Anweisungen (*Structured Query Language*) standardisiert abgefragt werden.

Die einzelnen Klassifikationsschritte (Segmentierung, Merkmalsgenerierung und Objektgewichtung) spiegeln sich in den folgenden Modulen wider:

- `accuracy`: Erstellung der Fehlermatrix
- `classification`: Pixel- und objektbasierte SVM Klassifikation
- `db_management`: Import / Export der Datenbank
- `fuzzy_features`: objektbasierte Prozessierung der Farbmerkmale
- `processes`: Verwaltung der Prozesse für parallele Verarbeitung
- `validation`: Validierung der Ergebnisse mit CLC 2000 Daten

→ `weights`: Anwendung des Regelwerkes (Gewichtungssystem)

Diese Klassen basieren auf den Modulen `ooC` (object-oriented Classification), `features` (verwendete Merkmale) und `utils` (Hilfsfunktionen). Es folgt eine Liste der implementierten Untermodule.

- `ooC.model`: abstrahiertes Datenmodell (Raster, Bildsegmente, Landbedeckungsobjekte, Corineobjekte, Gewichtungssystem)
- `ooC.classifier`: SVM Klassifikator (Aufbau und Optimierung des Modells / Training und Klassifikation der Objekte)
- `features.glco`: Texturmerkmale der Co-Occurrence Matrix nach HARALICK
- `features.landsat`: Farbmerkmale (Vegetation, Wasser und Bodenfarbe) für Landsat ETM+
- `features.modis`: Verarbeitung der MODIS-Daten und zeitliche Merkmale
- `utils.mysql`: Datenbankbindung zu MySQL (relationales Datenbanksystem)
- `utils.graphics`: Import / Export der Rasterdaten
- `utils.xmlconfig`: Konfiguration von `gnosis`
- `utils.xmlcatalogue`: Zusammenstellung der Trainingsgebiete für die überwachte Klassifikation

Implementierung

Bei der Umsetzung des Programmes wurde darauf geachtet, dass der hierarchische Klassenaufbau (Abstraktion) in den verschiedenen Informationsebenen (Bildobjek-

te, Landbedeckungsobjekte, CORINE Objekte) unabhängig bzw. gekapselt abgebildet wird und die einzelnen Klassifikationsschritte (Segmentierung, Merkmalsgenerierung, Objektgewichtung) parallel nebeneinander arbeiten können. Der Klassifikationsprozess ist damit direkt mit dem implementierten Datenmodell gekoppelt (siehe UML Diagramm in Abb. 3.4).

Diese Bedingungen spiegeln sich im Hauptmodul (`ooC.model`) von `gnosis` wider. Die Abbildung 3.28 zeigt das UML-Diagramm (*Unified Modelling Language* – eine standardisierte Sprache zur Modellierung von Software und betrieblichen Anwendungssystemen) dieses Moduls und den enthaltenen Klassen inklusive der Vererbungsstruktur.

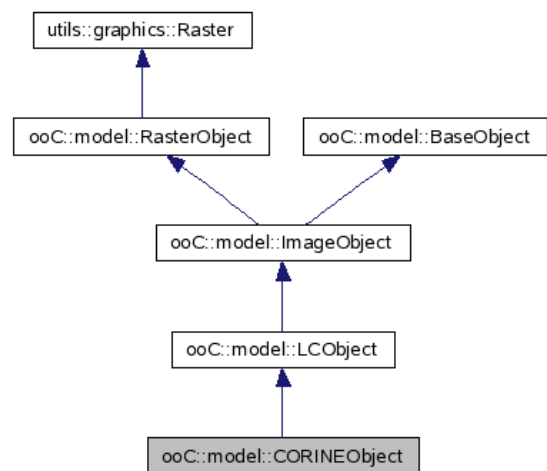


Abbildung 3.28: Klassenhierarchie (Vererbung) der Klasse `CORINEObject` aus dem Modul `ooC.model`

Der technische Ablauf umfasst die folgenden Punkte:

- Vorbereitung

- Definition der Landbedeckungsklassen für die Vorklassifikation
- Projekterstellung
- Datenaufbereitung
 - Bildsegmentierung
 - Ausschnittsbildung mit evtl. Umprojektion
 - Temporale Merkmalsgenerierung aus MODIS-Daten
 - Datenimport
- objektweise Prozessierung
 - Klassifikation und Zuweisung der Landbedeckung
 - Aufbau der Nachbarschaftsbeziehungen
 - weitere Generierung von Merkmalen
 - Objekttaggregation
 - Gewichtung des CLC Objektes durch enthaltene LC Objekte in Abhängigkeit der Objektgröße
- Validierung der CLC Objekte durch CLC2000 Datensatz
- Bestimmung der Gesamtgenauigkeit

Die Prozessierung in gnosis erfolgt projektweise, d.h. alle Daten decken einen festen geographischen Ausschnitt in der gleichen Projektion ab. Nach der Datenaufbereitung und dem Datenbankimport werden durch eine Segmentierung (bisher mit dem kommerziellen Softwarepaket eCognition durchgeführt) Landbedeckungsobjekte erstellt. Durch die Segmentierung wandelt sich die Klasse *RasterObject* zum *ImageObject*. Durch diese Umwandlung bekommt diese Klasse eine Reihe von neuen Methoden, darunter

- `get_neighbours()`
- `get_size()`
- `get_spectra()`

- `get_centerxy()`
- `get_occurrencematrix()`

Mit Hilfe der Klasse *Myclassifier* und der Methode `estimate_fuzzylandcover()` kann jedes Objekt der Klasse *ImageObject* pixelweise überwacht klassifiziert werden. Dazu wird ein SVM Modell trainiert, das auf vorher definierten und zusammengestellten Trainingsklassen basiert. Nach der Zuweisung der Landbedeckungsklassen stehen Objekte der Klasse *LCObject* mit weiteren Methoden (`get_temporal_intensity()`, `merge_neighbours()`, `get_dem_slope()`, etc.) zur Verfügung. Um CORINE Objekte zu identifizieren bzw. validieren, wird die Klasse *CORINEObject* verwendet. Das Gewichtungssystem wird mit den Methoden (`weighten_classification()`, `weighten_clc90`, etc.) angewendet. Dabei läuft die Datenhaltung im Hintergrund über ein beliebiges Datenbanksystem. Die Software gnosis fungiert dabei als Zwischenanwendung (*middleware*) zwischen Datenbanksystem und Klassifikationssystem. Jedes geometrische Objekt kann durch diese Abstraktion als separates Objekt mit den jeweiligen Methoden (Eigenschaften und GIS-Funktionen) konsistent im Programm verwendet werden. Durch diese objektweise Datenhaltung können beliebig große Datensätze prozessiert werden, da einem Modul nur Daten zur Verfügung gestellt werden, die für die jeweilige Verarbeitung benötigt werden. Die Identifikation der einzelnen Objekte erfolgt über eine global gültige Objekt-ID der Vektordatensätze und garantiert somit den synchronisierten Abgleich zwischen Geometrie- und Attributdaten im externen GI-System.

3.5.2 Datenkonzept

Der Einsatz von Datenbanksystemen ermöglicht eine schnelle, effektive und übertragbare Datenspeicherung, die zusätzlich eine erweiterte Funktionalität, wie hybride Datenhaltung von Raster- und Vektordaten, Objektinformationen über Geometrie, Topologie und Attribute, Veränderungskontrolle mit Protokollierungsfunktion und Datenzugriff über Netzwerk liefert. Das verwendete Datenbanksystem spielt dabei nur eine untergeordnete Rolle, da nur die Basisfunktionalität ohne räumliche Datenstrukturen verwendet wird. Für diese Arbeit wurde die freie Datenbank MySQL 5.0 von der Firma MySQL AB (2005) aus Schweden verwendet.

Die Projektgrößen (Image2000-Berlin: 9.6GB , Image2000-FFM: 3.1GB und Image2000-OL: 850MB) der Testgebiete unterscheiden sich von der dateibasierten Datenhaltung um mehr als das Dreifache, da die Datenbank zusätzliche Indizes pro Tabelle verwalten muss. Die vorher genannten Eigenschaften der Datenbank rechtfertigen jedoch diesen erhöhten Speicherbedarf im Datenbanksystem. Die Indizes werden benötigt, um intertabulare Abfragen zu ermöglichen. Die Abbildung 3.29 zeigt die Abhängigkeit der Tabellen untereinander mit Datensätzen von gleicher und unterschiedlicher geometrischer Auflösung. Durch diese Art der Verwaltung können verschiedene Datentypen über den Raumbezug miteinander verknüpft werden. Damit besitzt das Datenhaltungssystem eine hohe Erweiterbarkeit für weitere Sensoren und Datenquellen. Die Tabelle `Data_spectral` und `Data_CLC` besitzen die gleiche Auflösung

und stehen damit in einer 1:1 Relation. Die Tabelle `Data_temporal` hingegen wird aus MODIS-Daten mit 250 m Auflösung abgeleitet. Die Daten wurden auf eine Auflösung von 100 m (*Cubic convolution resampling*) heruntergerechnet. Ein temporaler Datenpunkt wird deshalb von 16 spektralen Datenpunkten abgedeckt (1:n Relation).




Abbildung 3.29: Beispiel für die relationale Repräsentation der Daten im Projekt

Das Datenkonzept unterscheidet zwischen den Projektdatensätzen (`Image2000-*`) und globalen Daten (`gnosis`, `gnosisNET`). Zu den global verfügbaren Daten gehören Metadaten (Projektion, Erstellungszeit und Bearbeiter), Prozessierungsprotokoll, Geometriedaten für Webapplikationen, Trainingsdaten für den Klassifikator und Prozesslisten für die parallele Verarbeitung.

Log: Jede Funktion in `gnosis` kann mitprotokolliert werden. Ergebnisse und Probleme können damit im Nachhinein analysiert werden.

Metadata: Informationen über die gespeicherten Rasterdaten, wie Sensorspezifikationen, Projektion etc. werden benötigt, um Einstellungen für die Klassifikation anzupassen und prozessierte Datensätze aus der Datenbank exportieren zu können.

ROImeta: Die semantischen Informationen der abgespeicherten Trainingsgebiete werden für die überwachte Klassifikation benötigt. Dabei können Trainingsgebiete von verschiedenen Szenen und Sensoren verwendet werden.

ROIdata: Die spektralen Daten der Trainingsgebiete stehen in Relation mit den semantischen Informationen. Damit können gezielt Trainingsdaten für den Klassifikator zur Verfügung gestellt werden.

Grid Die Tabelle dient als Sammelcontainer für die verteilte Prozessierung. Parallel ablaufende Rechenprozesse holen sich Aufgaben aus diesem Container ab und prozessieren diese lokal. Die Ergebnisse werden in die betreffende Projektdatenbank zurückgeschrieben.

In den einzelnen Projektdatenbanken (Image2000-*) werden die gerasterten Datensätze gespeichert und den Prozessen zur Verfügung gestellt. Die Objektinformationen befinden sich ebenfalls in dieser Datenbank.

Data_clc: Die existierende Klassifikation von 1990 wird für die Identifikation bzw. Validierung der einzelnen Objekte verwendet. Die Abschätzung der Genauigkeit des Klassifikationsprozesses erfolgt durch den vorhandenen CORINE LC 2000 Datensatz.

Data_georef: Die Georeferenzierung der einzelnen Pixel wird benötigt, um unterschiedliche Projekte miteinander in Beziehung setzen zu können. Randprobleme können damit genauer untersucht werden.

Data_segment Der Kern des Objektmodells besteht aus den Bildobjekten/-Segmenten. Das Ergebnis der Segmentierung aus eCognition wird als Rasterdatei in diese Tabelle importiert.

Data_spectral: Die spektralen Daten für die Bildobjekte werden aus dem Image2000 Datensatz importiert. Diese Daten werden für die Klassifikation der Landbedeckung und der unscharfen Bildmerkmale verwendet.

Data_temporal: Die Informationen über den phänologischen Verlauf der Objekte werden aus dem Vegetationsprodukt (MYDQ13) des MODIS-Sensors generiert. Die Parameter (temporale Intensität und temporale Variabilität) können für die Jahre 2001 bis 2004 aus dieser Tabelle gelesen werden.

Data_topography: Topographische Informationen werden aus einem digitalen Höhenmodell (DHM) abgeleitet. Die Parameter aus der Tabelle sind: absolute Höhe über Normalnull, Hangneigung und Hangseite.

Obj_clc: Für jedes Objekt wird eine Gewichtung in Abhängigkeit der Merkmale vorgenommen. Das Ergebnis der Gewichtung führt zu der für das Objekt geltenden CLC Klasse.

Obj_img_metadata: Bildobjektbezogene Informationen (Größe, Umfang, Lage, Landbedeckungsklasse, Superobjekt, etc.) liegen in dieser Tabelle vor

Obj_img_topology: Um die räumliche Analyse mit Nachbarschaftsbeziehungen zu erweitern, wird eine Nachbarschaftsliste pro Bildobjekte erzeugt und gespeichert.

hash_*: Temporäre Indizes

Um einfach und effizient den Katalog für die Landbedeckungsklassen definieren und verändern zu können, befinden sich die Trainingspektren der CLC Klassen für die überwachte Klassifikationsmethode ebenfalls in der global abrufbaren Datenbank. Die Tabelle R0Imeta (*region of interest*) stellt die Metadaten (CLC Klasse, geographische Lage, Ursprungsszene, Größe, etc.) der Trainingsgebiete zur Verfügung. In der Tabelle R0Idata befinden sich die exportierten Spektren aus dem **Image 2000** Datensatz und können über einen Index den Metadaten zugewiesen werden. Durch diese Verknüpfung kann eine umfangreiche Menge an Trainingspektren nach CLC Klasse (mit verschiedenen Hierarchiestufen) und Aufnahmezeitpunkt (Szene) gefiltert und dem Klassifikator zur Verfügung gestellt werden.

Die Kontrolle des Klassifikators erfolgt über eine spezielle Steuerdatei im XML-Format (*eXtensible Markup Language*). Ein Beispiel für eine Steuerdatei ist im Anhang zu finden (Abschnitt B.1). Diese Steuerdatei definiert aus den vorhandenen CORINE LC Klassen hierarchisch neue Landbedeckungsklassen. Damit ist es möglich, den Klassifikator in Abhängigkeit der Szene und der vorhandenen Klassen (über den **CLC 1990** Datensatz) „semi“-automatisch anzupassen.

Listing 3.1: Beispiel einer Definition der LC Klasse *Wasser*

```
<LC_CLASS INHERITED="-1">
  <CLASSNAME>
    0
  </CLASSNAME>
  <DESCRIPTION>
    Waterbodies
  </DESCRIPTION>
  <ORIGIN>
    random
```

```
</ORIGIN>
<CLC_CLASS Type="CLC1" Quantum="500">
  5
</CLC_CLASS>
<OPTIMIZE>
  no
</OPTIMIZE>
</LC_CLASS>
```

Das Listing 3.1 beschreibt die Landbedeckungsklasse *Wasser* (0), indem 500 zufällig gewählte Trainingspektren aus der Datenbank R0Idata vom CORINE LC Typ 5xx (erste Hierarchie) zum Trainieren des Klassifikators verwendet werden. Das Schlüsselwort **INHERITED** dient zum Aufbau einer Hierarchie und gibt an, auf welche andere Klasse sich diese (Sub)-Klasse bezieht. In diesem Fall ist dies eine Wurzelklasse (-1).

Fernerkundungsdaten

Für das Rahmenprogramm *gnosis* wurden neben CORINE Land Cover nur Datensätze aus der Fernerkundung verwendet, die für die Bundesrepublik Deutschland und Europa zur Verfügung stehen. Damit ist gewährleistet, dass die Methodik auf das gesamte CLC Projektgebiet erweitert werden kann. Als Basisdatensatz wurde der *Image2000* Datensatz vom JRC verwendet. Zur Validierung der entwickelten Methodik sind drei Testgebiete ausgewählt worden:

- I) Großraum Berlin (5700 x 5700 Pixel 71 km x 71 km mit 15 m geometrische Auflösung),
- II) Raum Frankfurt (5000 x 3000 Pixel oder 125 km x 75 km)

III) und Raum Oldenburg (1500 x 2500 Pixel oder 37 km x 62 km)

Für die Klassifikation der CORINE LC Klassen fand die CORINE LC Kartierung von 1990 Verwendung. Die Evaluierung der Ergebnisse wurde mit dem CLC 2000 Datensatz durchgeführt. Alle verwendeten Vektordaten wurden vor der Importierung in ArcGIS auf 25 m Auflösung gerastert. Das verwendete digitale Geländemodell (gewonnen aus ERS-Tandem Daten) lag in der geometrischen Auflösung von 25 m vor. Für die Generierung der Bildobjekte wurden aus eCognition Raster- und Vektordaten exportiert und in die Tabellen `Data_segment` und `Obj_img_metadata` importiert.

Die phänologischen Informationen wurden aus dem MODIS-Produkt MYD13 (Vegetationsprodukt von der AQUA Plattform bzw. EOS PM-1) abgeleitet. Der MODIS Sensor (*Moderate Resolution Imaging Spectroradiometer*) ist ein Hauptinstrument der beiden Plattformen Terra und Aqua. Die erste Plattform (Terra) wurde 1999 in den Orbit gebracht. Das zweite Instrument liefert seit 2002 Daten über die Erdoberfläche. Der große Aufnahmewinkel (*swath*) von ca. 2300 km erlaubt eine globale Abdeckung in 1 bis 2 Tagen bei einer durchschnittlichen Repetitionsrate von 16 Tagen. Das Instrument nimmt die Erdoberfläche in 36 verschiedenen spektralen Bändern (von 0.4μ bis 14.4μ) mit unterschiedlichen geometrischen Auflösungen (250m, 500m und 1km) auf. Die prozessierten Land-Produkte stehen in einer zeitlichen Auflösung von 1 Tag (MOD09: *surface reflectances*) bis 365 Tage (MOD12: *land cover dynamics*) zur Verfü-

gung. Das Vegetationsprodukt umfasst die beiden Indizes NDVI und EVI.

Der EVI (*Enhanced Vegetation Index*) unterscheidet sich vom NDVI durch die Einbeziehung des Blaukanals zur Korrektur von atmosphärischen Störungen und einer Bodenkorrektur. Der Vegetationsindex ist wie folgt definiert:

$$EVI = G * \frac{\rho_{859} - \rho_{645}}{\rho_{859} + C_1 * \rho_{645} - C_2 * \rho_{469} + L} \quad (3.1)$$

Die verwendeten Variablen stehen für die Koeffizienten $C_1 = 6$ und $C_2 = 7.5$ und dienen zur Atmosphärenkorrektur (Rayleigh Streuung und Absorption durch atmosphärisches Ozon) der Bänder Rot und Blau. Zusätzlich fließt eine Verstärkung $G = 2.5$ und der Korrekturfaktor $L = 1$ für den Untergrund mit ein.

Eine detaillierte Beschreibung zur Bestimmung der Parameter temporale Intensität und temporale Variabilität kann dem Kapitel 3.3.5 entnommen werden. Die Vorverarbeitung der MODIS-Daten umfasste die Schritte: Datenkonvertierung, Extraktion des EVI, Generierung des Datenstapels und eine Umprojektion nach UTM bzw. Gauss-Krüger. Das MODIS Datenprodukt MYD13 (Kachel h18v03 und h18v04) wurde für die Jahre 2001 bis 2004 vom *Land Processes Distributed Active Archive Center* (LPDAAC) in Sioux Falls heruntergeladen. In einer ersten Verarbeitung ist der Vegetationsindex *EVI* aus den HDF Dateien (*Hierarchical Data Format*) extrahiert worden. Aus dem 16-Tage Produkt wurde ein zeitlicher Datenstapel von 23 Zeitebenen generiert. Die einzelnen Kacheln liegen in einer MODIS-spezifischen Projektion (sinusoidale Projektion) vor und wurden für die einzelnen Untersuchungs-

gebiete umprojiziert. Anschließend erfolgte für die einzelnen Untersuchungsräume der Datenimport in die Datenbank (Tabelle `data_temporal`).

Abhängigkeiten von gnosis

Alle benötigten externen Zusatzbibliotheken stehen zur Nutzung frei zur Verfügung. Darunter befinden sich die Datenbankanbindung zum MySQL Server, die Geodaten-Bibliothek *Geospatial Data Abstraction Library* (GDAL) (WARMERDAM, 2004), der SVM-Klassifikator *PyML* von BEN-HUR UND NOBLE (2005), das *support vector* Regressionsmodul *libsvm* von CHANG UND LIN (2001) und viele weitere Bibliotheken.

4

Ergebnisse und Diskussion

IN diesem Kapitel werden die Ergebnisse aus verschiedenen Testläufen mit dem Rahmenwerk gnosis vorgestellt und die einzelnen Einflussfaktoren auf die Klassifikation diskutiert. Für die Prozessierung wurden folgende CLC Klassen im Regelwerk implementiert:

- CLC 111: *Durchgängig städtische Prägung*
- CLC 112: *Nicht durchgängig städtische Prägung*
- CLC 121: *Industrie- und Gewerbegebiete*
- CLC 131: *Abbauflächen*
- CLC 211: *Nicht bewässertes Ackerland*
- CLC 231: *Wiesen und Weiden*
- CLC 311: *Laubwälder*
- CLC 312: *Nadelwälder*
- CLC 321: *Natürliches Grünland*
- CLC 313: *Mischwälder*
- CLC 511: *Gewässerläufe*
- CLC 512: *Wasserflächen*

Durch die Parallelisierung der einzelnen Module konnte die Prozessierungszeit von mehreren Tagen pro Projekt auf einen Tag reduziert werden. Darüber hinaus wurden rechenintensive Merkmale (Textur-

und Formparameter, direkte und indirekte Nachbarschaftsbeziehungen) nicht in die Testläufe miteinbezogen. Bei der Gewichtung wurden folgende Merkmale berücksichtigt:

1. Existierende Klassifikation (CLC1990)
2. Temporale Variabilität / Intensität
3. Fuzzy-Merkmale (Wasser / Vegetation)
4. Landbedeckungsklassifikation

Das genaue Regelwerk mit den Gewichtungsfaktoren befindet sich in Tabelle C.2 im Anhang.

4.1 Validierung

Durch die getroffenen Grundannahmen der Methodik auf Seite 53 muss ein Objekt sowohl geometrisch, als auch semantisch durch seine Unterobjekte repräsentiert sein. Um die Qualität der geometrischen Repräsentation messen zu können, werden die Flächenanteile der Bildsegmente, die vom Hauptobjekt (CLC Objekt) räumlich abgedeckt sind, in Verhältnis zur restlichen Fläche der Bildsegmente gesetzt. Ein Wert von eins würde dabei bedeuten, dass ein Bildobjekt (Segment) komplett im Hauptobjekt liegt und deshalb das Hauptobjekt (CLC Objekt) direkt beschreiben kann. Wenn die Bildobjekte ein CLC Objekt nur zum Teil abbilden können, verringert sich dieser Wert. Diese Objekte können dann durch die Geometrie ihrer Bestandteile nicht mehr eindeutig bestimmt werden. Um Zuweisungsfehler zu vermeiden, werden solche Objekte vom Programm nicht prozessiert, wenn die geometrische Repräsentation klei-

ner 0,5 ist. Das CLC Objekt muss mindestens die Hälfte der Bildsegmentfläche abdecken, damit das jeweilige Bildobjekt für die Bestimmung der des Gesamtobjektes verwendet werden kann.

Die Evaluierung der Ergebnisse basiert auf dem direkten Objektvergleich zwischen dem CORINE LC 2000 Datensatz und den CLC-Objekten aus der jeweiligen Projektdatenbank. Die Geometrie der CORINE Objekte von 1990 dient als Basis für die prozessierten Objekte. Durch ihre eindeutige Bezugsnummer können diese Objekte mit den Referenzobjekten (CLC 2000) direkt miteinander verglichen werden. Aufgrund der flächenhaften Eigenschaften der objektorientierten Klassifikation und der CORINE Klassenbeschreibung ist dieses Auswerteverfahren pixelbasierten, stichprobenhaften Methoden vorzuziehen. Für alle Projekte konnte eine Wahrheitsmatrix (*confusion matrix*) erstellt werden, um den Fehler der Methodik für alle Objekte messen zu können. In diesem Kapitel wurden nur die Ersteller-, bzw. die Nutzergenauigkeit von ausgewählten Klassen zusammengestellt. Aus dieser Matrix (siehe Anhang) wurde die Gesamtgenauigkeit und der Kappa Koeffizient von KOHEN abgeleitet. Im Vergleich zur Gesamtgenauigkeit beschreibt der Kappa Koeffizient den Zusammenhang zwischen zwei nominalen Merkmalen, indem er die Differenz zwischen der beobachteten Übereinstimmung mit der erwarteten Übereinstimmung misst. „*The coefficient kappa ... is the proportion of agreement after change agreement is removed from consideration*“ (Cohen, 1987).

4.2 Projektgebiete

Für die Validierung wurden drei Testgebiete ausgewählt, um die Übertragbarkeit der Methode und ihrer Bestandteile, wie Merkmale und das Regelwerk zu überprüfen. Die Auswahl der Räume richtete sich nach dem Vorkommen und der Verteilung der flächenhaft dominierenden CLC Klassen in Deutschland (Übersicht in C.3).






Abbildung 4.1: Untersuchungsgebiete für das gnosis Rahmenwerk

Die gewählten Untersuchungsgebiete (Abb. 4.1) für diese Arbeit sind:

- (a) Rhein–Main Gebiet,
- (b) Großraum Berlin und



(a) Image2000



(b) CLC2000

Abbildung 4.2: Ausschnitt des Testgebietes Rhein-Main-Gebiet

(c) Oldenburg

CLC	Gesamt	n.k.	k.	%
131	61	26	35	57,38
132	10	6	4	40
133	4	3	1	25
141	41	24	17	41,46
142	74	40	34	45,95
211	644	183	461	71,58
221	51	22	29	56,86
222	110	51	59	53,63
231	649	283	366	56,39
242	613	257	356	58,08
243	249	118	131	52,61
311	755	293	462	61,19
312	618	258	360	58,25
313	1023	539	484	47,31
321	35	13	22	62,86
322	2	2	0	0
324	87	60	27	31,03
333	3	0	3	100
411	5	1	4	80
412	1	1	0	0
511	11	2	9	81,81
512	28	5	23	82,14

a – Rhein–Main Gebiet

Das *Rhein–Main Gebiet* (Abbildung 4.2) zeichnet sich durch einen stark zersiedelten Raum (ca. 10 % der Gesamtfläche) mit hohen Anteilen landwirtschaftlich genutzter Flächen (42 % der Fläche) und Waldgebieten (39 %) aus. Der Ausschnitt stammt aus der Image2000-Szene 195/25 vom 11.9.1999, ist 125 km x 75 km gross (5000x3000 Pixel) und deckt damit eine Fläche von über 9300 qkm ab. Das Untersuchungsgebiet besteht aus 6183 CLC Objekten, die durch 11741 Bildsegmente repräsentiert werden (Ratio ca. 1 : 2).

Die folgende Tabelle 4.1 zeigt die Häufigkeit aller CLC Objekte pro Klasse und die Anzahl der vom System nicht prozessierten Objekte aufgrund ihrer mangelnden geometrischen Repräsentation. Dazu stellt die Abbildung A.2 im Anhang diese Objekte in einer Übersichtskarte dar.

Tabelle 4.1: Übersicht der vorkommenden CLC Klassen und der nicht prozessierten Objekte. Die Abkürzungen *n.k.* und *k.* stehen für *nicht klassifizierbar* bzw. *klassifizierbar*.

CLC	Gesamt	n.k.	k.	%
111	12	11	1	8,33
112	857	350	507	59,16
121	210	88	122	58,1
122	15	7	8	53,33
123	6	2	4	66,67
124	9	3	6	66,67
⋮				

Der Schwellenwert für die Prozessierung lag bei 0,5 für die geometrische Repräsentation. Das bedeutet, dass nur solche Bildobjekte für die Determinierung der CLC Klasse verwendet werden, die mindestens zur Hälfte im CLC Objekt liegen. Für die CLC Klasse 111: *Durchgängig städtische Prägung* konnten von 12 existierenden Objekten nur ein Objekt prozessiert und damit klassifiziert werden, da die unterliegenden Bildsegmente die jeweiligen CORINE Geometrien nicht hinreichend genau abdecken konnten. Der Grund für die fehlende Repräsentanz liegt beim Unterprozess *Segmentierung*. Das benötigte Merkmal *Versiegelungsgrad* wurde bei diesem Prozess nicht berücksichtigt und liegt damit der resultierenden Geometrie nicht zugrunde. Der verwendete Schwellenwert und das Ergebnis der Segmentierung verhindern damit die Prozessierung der nicht klassifizierten Objekte. Durch diese geometrische Repräsentation konnten ca. 43 % aller Objekte

aus dem Untersuchungsgebiet nicht prozessiert werden.


CLC	Ersteller	Nutzer
111	1	1
112	0,88	0,998
⋮	⋮	⋮
124	0,67	1
⋮	⋮	⋮
211	0,998	0,37
⋮	⋮	⋮
231	0,45	1
⋮	⋮	⋮
242	0,13	1
243	0,08	1
311	0,99	0,85
312	0,97	0,97
313	0,92	1
⋮	⋮	⋮
511	0,83	1

Die restlichen 57 % der Objekte werden anschließend mit einer *Gesamtgenauigkeit* von 75 % (*Kappa Koeffizient*: 0,71) der richtigen CLC Klasse zugewiesen. Die fehlklassifizierten Objekte sind in der Übersichtskarte A.1 im Anhang abgebildet. Die Tabelle 4.2 fasst die Ergebnisse der wichtigsten Klassen für das Untersuchungsgebiet zusammen. Neben der *Nutzergenauigkeit* (Anzahl der korrekt klassifizierten Referenzobjekte dividiert durch die Summe aller Objekte, die der Klasse angehören) wurde auch die *Erstellergenauigkeit* (Anzahl der korrekt klassifizierten Referenzobjekte dividiert durch die Summe aller Objekte, die der Klasse zugewiesen wurden) für die jeweiligen Klassen angegeben.

Tabelle 4.2: Klassifikationsergebnis von ausgewählten Klassen für die Rhein-Main Region; vollständige Wahrheitsmatrix in Tabelle C.6

Die Ergebnisse der Klassifikation für das *Rhein-Main Gebiet* zeigen, dass die prozessierte CLC Objekte durch die Repräsentation ihrer Unterobjekte (Bildsegmente) gut wiedergegeben werden und die Güte der Genauigkeit von der Qualität der Merkmale abhängig ist.

Für das Testgebiet Frankfurt existieren neben den Übersichtskarten aus Abbildung 4.2 exemplarisch die Karten der nicht gerechneten und falsch zugewiesenen Objekte. Wenn CLC Objekte durch ihre Unterobjekte (Bildsegmente) nur unzureichend beschrieben werden können, ignoriert der Klassifikationsprozess diese Objekte. Die umrandeten Polygone in der Karte (Abb. A.2) setzen sich hauptsächlich aus kleinflächigen Objekten zusammen (Tab. 4.1). Die verwendete Segmentierung aus *eCognition* verhindert die vollständige Repräsentation dieser Objekte. Die umrandeten Polygone aus Abbildung A.1 entsprechen den falsch klassifizierten CLC Objekten in Tabelle tab:ffm:wrong und C.6. In



(a) Image2000

(b) CLC2000

Abbildung 4.3: Ausschnitt des Testgebietes Berlin

erster Linie wurden im Regelwerk nicht berücksichtigte CLC Klassen, wie Weinbauflächen falsch klassifiziert. Eine weitere Fehlerquelle liegt in der Merkmalszuweisung bei kleinflächigen CLC Objekten, da auch Merkmale von Nachbarobjekten bestimmten CLC Objekten durch eine fehlerhafte geometrische Repräsentation zugewiesen werden kann.

b – Großraum Berlin

Der Untersuchungsraum (Abbildung 4.3) wurde ausgewählt, um die Klassifikation von Siedlungsflächen und naturnahen Flächen zu validieren. Das Gebiet ist 71 km x 71 km (5700x5700 Pixel) groß und bedeckt damit ca. 5000 qkm. Die Image2000-Szene 193/23 wurde am 14.8.2000 aufgenommen. Die CLC Klasse *Nicht bewässertes Ackerland* belegt 37 % der Flächen. Über 30 % werden von stark strukturierten Waldflächen bedeckt. Der hochkompakte Siedlungskörper von Berlin umfasst ca. 10 % des gesamten Gebietes.

Tabelle 4.3: Übersicht der vorkommenden CLC Klassen und der nicht prozessierten Objekte für den Großraum Berlin. Die Abkürzungen *n.k.* und *k.* stehen für *nicht klassifizierbar* bzw. *klassifizierbar*.

CLC	Gesamt	n.k.	k.	%
111	20	6	14	70
112	399	131	268	67,17
121	116	16	100	86,21
122	15	3	12	80
123	2	1	1	50
124	9	0	9	100
131	26	8	18	69,23
132	8	0	8	100
133	1	0	1	100
141	41	9	32	78,05
142	67	13	54	80,6
⋮				

CLC	Gesamt	n.k.	k.	%
211	273	59	214	78,39
222	7	2	5	71,43
231	252	41	211	83,73
242	10	4	6	60
243	92	8	84	91,30
311	319	74	245	76,80
312	395	134	261	66,08
313	225	82	143	63,56
321	23	4	19	82,61
322	2	0	2	100
324	19	5	14	73,68
333	3	1	2	66,67
411	27	4	23	85,19
511	2	0	2	100
512	134	17	117	87,31

Die *Gesamtgenauigkeit* für die Bestimmung der CLC Klassen (Tabelle 4.4) beträgt 69 % (*Kappa Koeffizient* 0,65). Die generell etwas schlechtere Klassifikation basiert auf der unterschiedlichen spektralen Charakteristik der Szene zu den Spektren der Trainingsgebiete aus der Trainingsdatenbank.

Das Projekt beinhaltet 2489 CLC Objekte und 13 454 Bildsegmente (Ratio ca. 1 : 5). Der Grund für diese hohe Repräsentation sind die gewählten Parameter für die Segmentierung in eCognition (niedriger *Scale*-Faktor von 20 im Vergleich zu 35 (FFM) und 40 (OL) für die anderen beiden Projekten). Ein kleiner *scale*-Faktor verringert die Größe der Bildobjekte und erhöht dadurch die Anzahl dieser Objekte im Projekt. Die Verkleinerung der Bildobjekte führt zu einer besseren geometrischen Repräsentation der CLC Objekte. Deshalb können ca. 75 % der CLC Objekte in diesem Projekt beim Klassifikationsprozess berücksichtigt werden (siehe folgende Tabelle 4.3).

Tabelle 4.4: Klassifikationsergebnis von ausgewählten Klassen für den Großraum Berlin

CLC	Ersteller	Nutzer
111	1	1
112	0,41	0,99
121	0,89	1
⋮		
CLC	Ersteller	Nutzer
211	0,95	0,36
⋮		
231	0,26	0,89
⋮		
311	0,98	0,75
312	0,94	0,8
313	0,93	0,99
321	0,47	0,6
⋮		
511	1	1
512	0,93	0,99

c – Raum Oldenburg

Der Ausschnitt *Oldenburg* (Abbildung 4.4) ist ein Teil der niedersächsischen Geestlandschaft, in der hauptsächlich die intensive landwirtschaftliche Nutzung das Landschaftsbild prägt (Klassen 211 und 231 dominieren 70 % der Fläche des Testgebietes). Dieses Untersuchungsgebiet wurde gewählt, um die Trennbarkeit zwischen den Klassen Grünland und Ackerland zu analysieren. Das Projekt hat eine Größe von ca. 37 km x 62 km (1500x2500 Pixel) und bedeckt damit die Fläche von ca. 2300 qkm.

Tabelle 4.5: Übersicht der vorkommenden CLC Klassen und der nicht prozessierten Objekte für den Raum Oldenburg. Die Abkürzungen *n.k.* und *k.* stehen für *nicht klassifizierbar* bzw. *klassifizierbar*.

CLC	Gesamt	n.k.	k.	%
111	1	1	0	0
112	208	158	50	24,038
121	32	25	7	21,88
122	2	2	0	0
123	1	1	0	0
124	2	0	2	100
131	5	2	3	60
132	2	1	1	50
141	3	2	1	33,33
142	11	8	3	27,27
211	151	85	66	43,71
231	118	68	50	42,37
242	63	23	40	63,49
243	73	49	24	32,88
311	48	27	21	43,75
312	72	28	44	61,11
313	57	29	28	49,12
321	3	2	1	33,33
322	3	0	3	100
324	3	2	1	33,333
331	2	1	1	50
333	1	0	1	100
411	5	2	3	60
412	23	12	11	47,83
421	4	0	4	100
423	3	0	3	100
511	1	0	1	100
512	17	5	12	70,59
523	1	1	0	0

In dem gewählten Ausschnitt befinden sich 915 CLC Objekte und 2572 Bildsegmente (Ratio 1:3) und stammt aus der **Image 2000** Szene 196/23 vom 15.5.2000. Durch die schlechtere Repräsentation der CLC Objekte durch die Bildsegmente werden nur ca. 50 % der CLC Objekte prozessiert (siehe Tabelle 4.5). Der *scale* Parameter für

eCognition wurde für den Untersuchungsraum Oldenburg auf 40 erhöht, da in dem Ausschnitt wenige und große CLC Objekte dominieren und getestet werden sollte, wie gut wenige Bildsegmente die vorhandenen CLC Objekte repräsentieren können. Die Gesamtgenauigkeit bzw. der Kappa-Koeffizient der Klassifikation beträgt 79 % und 0,762.

Tabelle 4.6: Klassifikationsergebnis von ausgewählten Klassen für den Raum Oldenburg

CLC	Ersteller	Nutzer
⋮		
112	0,92	1
121	0,9	0,46
⋮		
211	0,97	0,51
⋮		
231	0,78	0,93
⋮		
311	0,93	0,9
312	0,92	0,92
313	0,96	1
321	0,47	0,6
⋮		
512	0,75	1

4.3 Klassifikationsgüte

Die Tabellen 4.2, 4.4 und 4.6 stellen die Klassifikationsgenauigkeit in Form einer Wahrheitsmatrix (Konfusionsmatrix) für die drei Testgebiete dar. Folgend werden die CLC Klassen gruppenweise diskutiert.

Bebaute Flächen

Die CLC Klassen 111 bis 142 wurden für den Raum Frankfurt mit einer Erstellergenauigkeit von 0,67 zugewiesen. Gesenkt wurde dieser Wert durch fehlende Regeln für die CLC Gruppen 13x: *Abbauflächen, Deponien und Baustellen* und 14x: *Grünflächen*, die nicht im Regelwerk implementiert wurden. Die versiegelten Flächen wurden im Durchschnitt mit einer Güte von über 90 % klassifiziert. Für das Gebiet Berlin konnten alle prozessierten Objekte der Klasse 111: *Durchgängig städtische Prägung* konnten richtig zugewiesen werden. Die hohe spektrale Ähnlichkeit zwischen der CLC Klasse 112: *Nicht durchgängig städtische Prägung* und bestimmten Bodenflächen der CLC Klasse 211 *Nicht bewässertes Ackerland* bedingt die geringe Erstellergenauigkeit von 41 %. Zusätzlich erschweren Siedlungsgebiete mit hohem Grün- und Mischpixelanteil in den Vororten von Berlin die Klassifikation, da der Anteil von Vegetation und offenem Boden im Objekt mit landwirtschaftlichen Klassen vergleichbar ist. Trotz des Aufnahmezeitpunktes im Mai konnte eine hohe Klassifikationsgenauigkeit bei den *städtisch geprägten Flächen* im Gebiet Oldenburg erzielt werden. Fehlklassifikationen mit offenem Boden (Ackerland) und Vegetationsklassen traten selten auf (siehe dazu die Konfusionsmatrix für das Untersuchungsgebiet im Anhang). Die Industriegebiete wurden mit einer Nutzergenauigkeit von 46 % überschätzt. Besonders Feuchtgebiete mit einer ähnlichen spektralen Charakteristik werden dieser Klasse zugewiesen, da diese Klassen keine direkten Klassenbeschreibungen im Regelwerk besitzen.




Abbildung 4.4: Ausschnitt des Testgebietes Oldenburg

Landwirtschaftliche Flächen

Die CLC Klasse 211: *Nicht bewässertes Ackerland* identifiziert alle CLC Objekte dieser Klasse richtig, überprägt aber auch andere landwirtschaftliche Klassen, wie CLC 231, 242 und 243. Fehlende Merkmale bzw. Regeln für die CLC Klassen 242 und 243 bedingen deshalb eine unzureichende Klassifikationsgenauigkeit für diese Klassen. Die Qualität des temporalen Merkmals in Kombination mit der Landbedeckung reicht durch die unterschiedlichen geometrischen Auflösungen (25 m und 250 m) nicht aus, um zuverlässig die CLC Klasse 231: *Weideland* zu bestimmen (0,45/1 Ersteller- bzw. Nutzergenauigkeit).

Die Nutzergenauigkeit der CLC Klasse 211 liegt bei 36 %, da besonders Siedlungsgebiete als Ackerland klassifiziert wurden. Die hohe spektrale Ähnlichkeit zwischen bestimmten Boden- und Siedlungsflächen verringert ohne zusätzliche Informationen oder Merkmale die Nutzergenauigkeit. Neben der städtischen Klasse werden auch Weideflächen (CLC 231) der landwirtschaftlichen Klasse falsch zugeordnet. Die gewählten temporalen Merkmale (Intensität und Variabilität) können Objekte in der stark strukturierten und kleinräumigen Landschaft um Berlin nicht exakt beschreiben.

Wälder, naturnahe Flächen und Feuchtgebiete

Alle Waldklassen zusammengefasst werden mit einer hohen Genauigkeit von über 90 % (Ersteller) und 85 % (Nutzer) klassifiziert. Die sonstigen naturnahen Flächen und Feuchtgebiete werden unzureichend klassifiziert, da keine Regeln spezifiziert wurden, um diese Klassen zu beschreiben. Darüber hinaus fehlen Eigenschaften, um die Intensität der menschlichen Nutzung bei naturnahen Flächen zu beschreiben. Feuchtgebiete wurden in den bisherigen Prozessierungsläufen aufgrund fehlender Merkmale und Regeln nicht berücksichtigt.

Wasserflächen

Die Wasserflächen im Untersuchungsgebiet Frankfurt werden mit einer Genauigkeit von größer 90 % erkannt. Durch die spektrale Ähnlichkeit von Wasserflächen und der Klasse Nadelwald wurden zwei CLC Objekte (von insgesamt 23) der CLC Klasse 312 falsch zugewiesen. Sowohl *Gewässerläufe* (CLC 511), als auch *Wasserflächen* (CLC 512) werden in Berlin mit einer Genauigkeit von größer 93 % richtig klassifiziert. Die Gesamtgenauigkeit beträgt für die CLC Gruppe der Wasserflächen zusammen 97 %. In Oldenburg werden die Inlandgewässer mit einer hohen Genauigkeit von 75 % zugewiesen. Die Abgrenzung zwischen Flachwasserbereichen und dem offenen Meer konnte in dem monotemporalen Image2000 Datensatz durch fehlende Merkmale nicht eindeutig rekonstruiert werden.

4.4 Einflussfaktoren auf Klassifikationsgüte

Die genannten Ergebnisse aus den drei Untersuchungsgebieten spiegeln ein ungefähres Bild wieder, wie gut welche CLC Klassen bestimmt werden. Dabei wird die Qualität der Determinierung von CLC Objekten von einer Reihe von Faktoren bestimmt. Diese Einflussfaktoren können in folgenden Gruppen eingeteilt werden:

- Fehler durch falsche Repräsentation der CORINE Objekte basierend auf
 - Geometrie und
 - Thematik
- Systematische Fehler
 - Fehlerhaftes Regelwerk,
 - Falsche Gewichtungen und
 - CLC spezifische Probleme

Im Folgenden werden die genannten Punkte diskutiert und mögliche Verbesserungen vorgeschlagen.

4.4.1 Fehlerbehaftete Repräsentation

Die entwickelte Methodik basiert auf der Notwendigkeit, dass Superobjekte, in diesem Fall die CLC Objekte, durch eine Anzahl von Unterobjekten (Bildsegmente) wiedergegeben werden. Die Qualität der Bestimmung des Superobjektes wird durch die räumliche Abdeckung / geometrische Repräsentation und die Semantik / thematische Repräsentation der Unterobjekte bestimmt.

Geometrische Ungenauigkeit

Die geometrische Repräsentation der CLC Objekte wird durch den Segmentierungsprozess bestimmt. Für die Segmentierung wurde ein Verfahren verwendet, dass die Bildsegmente rein spektral aus dem Bild ableitet. In vielen Fällen können Bildsegmente dabei die CLC Objekte gut repräsentieren. Wenn jedoch weitere Merkmale (Funktion, Versiegelungsgrad oder das Verhältnis Laubwald–Nadelwald) die Geometrie bestimmen, können die CLC Objekte nicht mehr rekonstruiert werden. Durch eine Miteinbeziehung dieser Merkmale in den Segmentierungsprozess wird eine Verbesserung zur geometrischen Abbildung der CLC Objekte erzielt.


In den Ergebnissen hat sich gezeigt, dass eine hohe Abdeckung von Bildsegmenten pro CLC Objekt die Anzahl der prozessierten Objekte erhöht. Viele Bildobjekte erhöhen aber zusätzlich die Prozessierungszeit, da das entwickelte Verfahren objektbasiert arbeitet. Um den Prozessierungsaufwand gering zu halten, muß eine optimale Anzahl von Bildsegmenten pro Superobjekt gefunden werden. Die Arbeit von TUFTE (2003) konnte ein mögliches Verfahren liefern, welches eine automatische Anpassung der Segmentierungsparameter in eCognition für existierende Objekte vornehmen könnte.

Thematische Ungenauigkeit


Ein oder mehrere thematische Merkmale werden verwendet, um CLC Klassen zu beschreiben. Je eindeutiger ein Merkmal eine CLC Klasse beschreiben kann, desto höher ist die Klassifikationsgenauigkeit der

Objekte dieser Klasse. Der in dieser Arbeit erstellte Klassenkatalog (siehe Tabelle 3.11) definiert für die einzelnen CLC Klassen, welche Merkmale für die Determinierung verwendet werden. **Eindeutigkeit** bedeutet hier die Anzahl der determinierten CLC Klassen pro Merkmalskombination.

Zusätzlich zur Eindeutigkeit der verschiedenen Merkmalskombinationen beeinflusst die Qualität der Merkmale die Klassifikationsgenauigkeit. Damit addieren sich die Klassifikationsfehler der einzelnen Merkmale und beeinflussen zusammen die Gesamtgenauigkeit. Ein wichtiges Merkmal für viele CLC Klassen ist die Information über die Landbedeckung. Die Genauigkeit der Landbedeckungsklassifikation kann den beiden Tabellen 3.4 und 3.5 auf Seite 63f entnommen werden. Die Tabelle 3.5 ist dabei schwieriger zu interpretieren, da durch die Generalisierungsvorschriften von CORINE LC und dem internen Aufbau von einzelnen CLC Klassen keine einzelne Landbedeckungsklasse vorherrscht. Grundsätzlich muss ein Kompromiss zwischen der Anzahl der Klassen und der Klassifikationsgenauigkeit getroffen werden. Diese richtet sich hauptsächlich nach den jeweiligen geometrischen und radiometrischen Spezifikationen des verwendeten Sensors. Temporale Merkmale bilden eine weitere unabhängige Informationsebene zur Trennung von CLC Klassen. In Kapitel 3.3.5 wird eine Abschätzung über die Güte der Merkmale temporale Variabilität und temporale Intensität gegeben. Dabei hat sich herausgestellt, dass die verwendeten Merkmale einsetzbar sind, wenn die Objektgröße größer als 10 ha beträgt und eine Mindestbreite von 1000 m aufweist (ungefähre Größe eines MODIS-Pixels am



(a) Image2000 mit Bildsegmenten



(b) CLC2000 und zugehörige Bildsegmente

Abbildung 4.5: Beispiel für die geometrische Repräsentation der CLC Objekte durch die Bildsegmente. Die Gittermaschen haben in dem Ausschnitt von Frankfurt eine Weite von 2 km.

Rand einer nicht Nadir-Szene). Um kleinere Objekte auch in heterogenen Landschaften eindeutig identifizieren zu können, müssen die verwendeten Daten eine höhere räumliche Auflösung besitzen. Dabei kann beispielsweise auf den multispektralen *Advanced Wide Field Sensor* (AWiFS) des indischen IRS-P6 Resourcesat-1 zugegriffen werden. Dieser besitzt eine geometrische Auflösung von 60m und nimmt die Erdoberfläche in einem Repetitionszyklus von 5 Tagen auf. Das Merkmal Versiegelungsgrad kann durch unterschiedliche Methoden generiert werden (siehe Kapitel 3.3.2). In dieser Arbeit wurde ein multipler Regressionsansatz auf Basis von der Stützvektor-Regression gewählt. Die generelle Abweichung vom Kontrolldatensatz beträgt 0,06 (RMSE) bzw. 0,61 (Korrelationskoeffizient). Die CLC Klasse 111 *Durchgängig städtische Prägung* wird durch ihren Versiegelungsgrad von größer 80 % definiert. Der durchschnittliche Grad der Versiegelung für den Ausschnitt Frankfurt liegt bei dieser CLC Klasse bei ca. 60 % mit einer Standardabweichung von 0,16. Dennoch weicht die Geometrie der CLC Objekte von dieser Datengrundlage aus zwei Gründen ab:

1. der Versiegelungsgrad wird bei der Interpolation etwas unterschätzt und
2. die Abgrenzung der CLC Objekte erfolgt manuell / subjektiv bzw. basiert auf weiteren Zusatzdaten, wie Stadtplänen und topographischen Karten.

4.4.2 Systematische Fehler

Systembedingte Fehler werden durch die Verwendung der implementierten Metho-

dik (Klassenbeschreibung durch das Regelwerk und das Gewichtungssystem) und den Spezifikationen von CORINE LC verursacht.

Regelwerk

Die Definition der CLC Klassen durch bestimmte Merkmale basiert auf der Annahme, dass der Interpret die jeweiligen Klassen eindeutig beschreiben kann. Dieses *a-priori* Wissen muss vor dem Klassifikationsprozess erarbeitet bzw. notwendige Merkmale entwickelt und implementiert werden und als *Klassenkatalog* zur Verfügung stehen. Dabei ist folgendes zu beachten:

- a) Eine falsche Klassenbeschreibung verursacht inkorrekte Zuweisungen der Klasse. Aus diesem Grund sollten sowohl die verwendeten Merkmale, als auch der Klassenkatalog global Geltung besitzen. Alternativ müssten die Merkmale bzw. die Regeln regionalisiert werden, was einen erheblichen Mehraufwand erfordert und die Objektivität der Methode mindert.
- b) Nicht konsistente Regelbeschreibungen führen zu ähnlichen Gewichtungsmustern von CLC Klassen und verhindern die eindeutige Zuordnung zu dieser Klasse. Dieses Problem basiert auf mehrfach verwendeten Merkmalen für unterschiedliche Klassen.

Gewichtungen

Das Gewichtungssystem fasst die Ergebnisse der einzelnen Merkmale pro Objekt für die einzelnen CLC Klassen zusammen. Es wird verwendet, um mehrere Merkmale unscharf miteinander zu kombinieren. Die




Abbildung 4.6: Beispiel für das Merkmal *Versiegelungsgrad* für den Raum Frankfurt. Dabei wird das Merkmal für die CLC Klassen 11x und 12x neben den nicht versiegelten CLC Objekten gezeigt.

CLC Klasse mit den meisten Treffern definiert thematisch das Objekt. Dabei können die einzelnen Merkmalsgruppen über den Gewichtungsfaktor unterschiedlichen Einfluss auf die Klassifikation ausüben. Das Setzen dieser Faktoren erfolgte für die Testläufe nach subjektiven Ermessen. Das Finden von statistisch signifikanten Gewichtungsfaktoren kann bei größeren Datensätzen bzw. mehreren Projekten automatisiert durch die Lösung eines Optimierungsproblems erfolgen. Genetische Algorithmen oder neuronale Netze können dabei als technische Verfahren eingesetzt werden.

Probleme durch CLC Spezifikationen

CLC Objekte haben eine Mindestgröße von 25 ha. Relevante Veränderungen in diesen Objekten müssen mindestens 5 ha groß sein, um erfasst zu werden. Kleinere Objekte werden aus diesem Grund mit Nachbarobjekten aggregiert und verlieren ihren thematischen Inhalt. Eine Aggregationsmatrix kann, analog zur Veränderungsmatrix in KEIL *et al.* (2005, S. 71) genutzt werden, um festzulegen, welche Kombinationen beim Aggregationsprozess möglich sind. Aus diesem Grund beeinflusst die Definition der Mindestgröße (*Generalisierungsvorschrift zur Geometrie*) sowohl Ab-

grenzung, als auch Komposition von vielen CLC Objekten.

Neben der geometrischen Aggregation gibt es mehrere heterogen aufgebaute Sammelklassen in der CLC Klassendefinition (*semantische Generalisierung*). Dazu zählen ausschließlich die CLC Klassen 24x: *Heterogene landwirtschaftliche Flächen*. Diese Klassen werden durch den Aufnahmemaßstab von 1:100 000 und der Anzahl der Gesamtobjekte (Aufwand der manuellen Interpretation) bedingt. Die aktuellen Bestrebungen im Rahmen von CLC 2006 zur Verringerung der Objektgrößen auf generell 5 ha tragen dazu bei, dass die Probleme durch geometrische und semantische Generalisierung in den Hintergrund treten werden.

Bei der Erstellung bzw. Validierung des CLC Datensatzes sind unterschiedliche Gruppen / Personen beteiligt (KEIL *et al.*, 2005). Basierend auf der CLC Klassifikationsvorschrift (EEA, 1997) wurde der CLC 2000 Datensatz mit unterschiedlichen Verfahren (von manueller Interpretation bis semi-automatischer Aggregation) erstellt. Die genannten Produktionsweisen beinhalten unterschiedliche Fehlerquellen (Genauigkeiten der Digitalisierung, Interpretation, Klassifikation und Aggregation). Die manuelle Erstellung und Interpretation der CLC Objekte durch unterschiedliche Interpreten führt zu variablen Eingabebedingungen und kann damit zu geometrischen und semantischen Fehlern im CLC Datensatz führen.

Die Abbildung 4.7 zeigt beispielhaft geometrische und semantische „Fehler“ in CLC Objekten und ihren Veränderungsflächen. Das Objekt ID 115947 ist vom Typ 121: *Industrie- und Gewerbeflächen*. Der nordöstliche Teil der Anlage ist aber dem Objekt 115847 vom Typ 211: *Nicht bewässertes Ackerland* zugeordnet. Die Thematik der Änderungsfläche 115897 wurde von 211 nach 121 verändert, obwohl der Anteil der Industriefläche weniger als 50 % dieser Fläche ausmacht. Die Generalisierungsvorschrift von CORINE LC ermöglicht diese Interpretation der landwirtschaftlichen Fläche, damit das Industriegebiet als einzelnes Objekt mit einer Größe von größer 25 ha erstellt werden kann. Die Generierung und Validierung dieser Geometrie durch automatische Verfahren ist aus diesem Grund nicht möglich.



Abbildung 4.7: Beispiel für einige Geometrie-probleme bei CLC Objekten

4.5 Zusammenfassung

Mit der entwickelten Methodik und dem Stand der Implementierung von gnosis ist

eine automatisierte Klassifikation von CORINE Land Cover automatisierbar. Die Tabelle 4.7 fasst die Ergebnisse der drei Untersuchungsgebiete zusammen und gibt den Grad der möglichen Automatisierbarkeit pro CLC Klasse an. Der Automatisierungsgrad richtet sich nach der Qualität der geometrischen und semantischen Klassenrepräsentation.

Die Symbole + (*gut*), ± (*durchschnittlich*) und – (*schlecht*) geben eine Einschätzung für die Güte der Klassenrepräsentation durch die entwickelte Methodik auf Basis der Segmentierungsergebnisse und der Qualität der verwendeten Merkmale. Die jeweiligen Graustufen geben an, ob eine CLC Klasse *voll automatisiert* (dunkelgrau), *semi-automatisiert* (hellgrau) oder *nicht automatisiert* (weiss) mit der entwickelten Software gnosis aus den Datensätzen abgeleitet werden kann.

Drei Formen zur Automatisierung der CLC Klassen können daraus abgeleitet werden:

- a) *Voll automatisierbar* bedeutet, dass die jeweiligen CLC Klassen durch die Methodik autonom zugewiesen werden. Aus dem CLC Katalog können **13 Klassen** auf diese Weise bestimmt werden. Dazu zählen die Klassen 112, 141, 211, 231, 311, 312, 313, 334, 335, 511, 512, 522 und 523.
- b) Die *semi-automatisierte* Prozessierung kann den Interpreten durch Vorschläge unterstützen. Die endgültige räumliche bzw. inhaltliche Abgrenzung erfolgt jedoch interaktiv. Zu den semi-automatisierten Klassen gehören 111, 121, 123, 124, 131, 221, 242, 321, 324, 331, 333, 412, 421 und 521. Ohne manuelle

Unterstützung können diese **14 Klassen** mit einem höheren Klassifikationsfehler identifiziert werden.

- c) *Nicht automatisierbar* sind jene **10 Klassen**, die sowohl geometrisch, als auch semantisch durch gnosis nicht identifiziert und klassifiziert werden können. Die CLC Klassen 122, 132, 133, 142, 222, 243, 322, 332, 411 und 423 müssen weiterhin manuell interpretiert werden.

Für die Anwendbarkeit der Methodik und der Implementierung durch gnosis ergeben sich folgende Szenarien:

- 1) *Anwendung zur Erstellung des CLC Produktes* – Aus dem CORINE Klassenkatalog können 13 Klassen vollautomatisch bzw. 14 Klassen semi-automatisiert abgeleitet werden. Unter den 15 häufigsten Klassen (oder ca. 96 % aller Objekte; siehe Tabelle C.8 im Anhang) werden damit 7 Klassen ohne menschlichen Eingriff bzw. 5 mit manueller Unterstützung verarbeitet. Damit müssen nur 8,4 Prozent aller Objekte für Deutschland (oder ungefähr 15 000 Objekte) rein manuell erstellt und interpretiert werden.
- 2) *Anwendung zur Validierung von CLC Produkten* – Analog zur Klassifikation von CLC Objekten kann die Methodik verwendet werden, um bestehende CLC Datensätze zu validieren. Für die schon automatisierten Klassen kann ein optimiertes Regelwerk verwendet werden. Die semi-automatisierten Klassen können durch ein neu entworfenes Regelwerk auf ihren internen Aufbau hin untersucht und damit validiert werden. Abweichungen von Flächen, die größer 5 ha sind, können mögliche fehlende Veränderungen im CLC Datensatz sein.

Tabelle 4.7: Grad der Automatisierung von CLC Klassen

CLC Klasse	Repräsentation		Automatisierbarkeit
	geom.	sem.	
111	±	+	<i>semi</i> -automatisierbar
112	+	+	<i>voll</i> automatisierbar
121	+	±	<i>semi</i> -automatisierbar
122	–	–	<i>nicht</i> automatisierbar
123	±	+	<i>semi</i> -automatisierbar
124	–	±	<i>semi</i> -automatisierbar
131	±	+	<i>semi</i> -automatisierbar
132	±	–	<i>nicht</i> automatisierbar
133	–	–	<i>nicht</i> automatisierbar
141	+	+	<i>voll</i> automatisierbar
142	–	–	<i>nicht</i> automatisierbar
211	±	+	<i>voll</i> automatisierbar
221	±	±	<i>semi</i> automatisierbar
222	–	–	<i>nicht</i> automatisierbar
231	±	+	<i>voll</i> automatisierbar
242	–	±	<i>semi</i> -automatisierbar
243	–	–	<i>nicht</i> automatisierbar
311	+	+	<i>voll</i> automatisierbar
312	+	+	<i>voll</i> automatisierbar
313	±	+	<i>voll</i> automatisierbar
321	+	±	<i>semi</i> -automatisierbar
322	±	–	<i>nicht</i> automatisierbar
324	±	±	<i>semi</i> -automatisierbar
331	±	±	<i>semi</i> -automatisierbar
332	±	–	<i>nicht</i> automatisierbar
333	±	–	<i>semi</i> -automatisierbar
334	+	+	<i>voll</i> automatisierbar
335	+	+	<i>voll</i> automatisierbar
411	–	–	<i>nicht</i> automatisierbar
412	+	±	<i>semi</i> -automatisierbar
421	±	+	<i>semi</i> -automatisierbar
423	–	–	<i>nicht</i> automatisierbar
511	+	+	<i>voll</i> automatisierbar
512	+	+	<i>voll</i> automatisierbar
521	±	+	<i>semi</i> -automatisierbar
522	±	+	<i>voll</i> automatisierbar
523	+	+	<i>voll</i> automatisierbar

In beiden Fällen erfolgt die Optimierung der zuvor rein manuell durchgeführten CLC Interpretation. Durch Vorschläge des Systems für eine potentielle Geometrie bzw. Semantik wird die Verarbeitungszeit pro Objekt für die semi-automatisierten Klassen durch den Interpreten verringert. Der Schwerpunkt der manuellen Arbeit kann auf nicht automatisierte Klassen gelegt werden.

5

Schlussfolgerung

DIE vorliegende Arbeit befasst sich mit der Entwicklung einer Methode, um den CORINE Land Cover Datensatz automatisiert aus Fernerkundungsdaten durch objektorientierte Verfahren abzuleiten. Der CLC Datensatz fasst in seiner Interpretationsvorschrift Klassen der Landbedeckung und Landnutzung für den Arbeitsmaßstab von 1:100 000 auf europäischer Ebene zusammen.

Die entwickelte Methodik basiert auf einer Atomisierung der flächenhaften CLC Objekte durch Bildobjekte bzw. Bildsegmente (geometrische Repräsentation). Diese Unterobjekte haben durch verschiedene Merkmale einen unterschiedlichen semantischen Inhalt. Durch die interne Komposition (Zusammensetzung) und Konfiguration (Aufbau) des CLC Objektes kann die CLC Klasse durch einen Klassenkatalog (Regelwerk) rekonstruiert werden. In diesem Klassenkatalog sind beispielhaft die 15 wichtigsten CLC Klassen in Form von Prototypen implementiert. CLC Klassen können dabei in Abhängigkeit der semantischen Repräsentation und der Qualität der einfließenden Merkmale entweder identifiziert oder verifiziert werden. Die Identi-

fikation ermöglicht eine Neuklassifikation von Corine LC. Das Verfahren zur Verifikation hingegen erlaubt die Neukartierung von bestehenden Datensätzen.

Der Klassifikationsprozess kann dabei in verschiedene Aspekte untergliedert werden:

- a) Aufbereitung der Interpretationsvorschrift für den Prozessor durch Abbildung des *a-priori* Wissens in einer prozessierbaren Form,
- b) Bestimmung der Merkmale inklusive der Implementierung,
- c) Erstellung der Unterobjekte durch Bildsegmentierung,
- d) Merkmalsgenerierung für die Unterobjekte,
- e) Gewichtung der CLC Objekte durch die enthaltenen Bildobjekte und
- f) Klassenzuweisung des CLC Objektes

Autonome Prozessierung

Die Schritte a und b müssen manuell vor der Prozessierung einmalig durchgeführt werden. In Abhängigkeit von der Qualität der verwendeten Merkmale und des Klassenkataloges können die daraus gewonnenen Ergebnisse für weitere Aufgaben wiederverwendet oder auf andere Räume adaptiert werden. Die anschließende Prozessierung der Ausgangsdaten erfolgt autonom vom Benutzer.

CLC Klassenkatalog

Der Klassenkatalog kodiert die Klassenbeschreibung für die manuelle Interpretation in ein für den Computer prozessierba-

res Regelwerk. Die Verwendung einer Ontologie und Programme zu deren Erstellung und Auswertung, wie beispielsweise durch Protégé (WHITE, 2005) und Racer (HAARSLEV *et al.*, 2003) ermöglichen die Konsistenzprüfung des Regelwerk. Datenformate, wie RDF (*Resource Description Framework*) oder OWL (*Web Ontology Language*) bieten die Möglichkeit zum Austausch bzw. die Konvertierung in andere Formate und schafft damit Transparenz für den Klassifikationsprozess. Diese Transparenz ist beispielsweise wichtig für die Dokumentation der Einzelschritte und die Zertifizierung des Gesamtsystems.

Klassifikation der Landnutzung

Die optische Fernerkundung liefert spektrale Daten über die Reflexionseigenschaften von Objekten auf der Erdoberfläche. Diese Materialeigenschaften beschreiben damit die Landbedeckung. Um Aussagen über die anthropogene Nutzung oder die Intensität dieser Nutzung machen zu können, werden weitere Informationen benötigt. Einige dieser Informationen können aus zusätzlichen Merkmalen abgeleitet werden. Dazu zählen unter anderem Nachbarschaftsbeziehungen, struktureller Aufbau von Objekten und die zeitliche Dynamik der Vegetation. In dieser Arbeit wurden die benötigten Merkmale bestimmt, implementiert und in dem Klassenkatalog integriert.

Das Klassifikationsframework *gnosis* wurde dazu aufgebaut, um die entwickelte Methodik anwenden und validieren zu können. Die in Python implementierte Software erlaubt die Umsetzung und Optimierung der gefundenen Merkmale und stellt

alle benötigten Funktionen für den Klassifikationsprozess zur Verfügung. Im Gegensatz zu bestehender Software kann die Funktionalität an verschiedene Aufgabenstellungen angepasst und größere Datensätze autonom prozessiert werden.

Automatisierung des Gesamtprozesses

Das Hauptanwendungsgebiet des Softwarepaketes *gnosis* ist die automatisierte Klassifikation der Fernerkundungsdaten basierend auf *a-priori* Wissen. Folgende Module werden dafür zur Verfügung gestellt:

- a) *Datenimport*: Alle verwendeten Raster- und Vektordaten müssen in eine Projektdatenbank geladen werden und stehen damit den einzelnen Modulen zur Verfügung. Die netzwerkweite Verfügbarkeit dieser Basisdaten ist für die Skalierbarkeit des Prozessors notwendig.
- b) *Datenaufbereitung*: Aus dieser Datengrundlage werden die verschiedenen Merkmale für die Bildsegmente extrahiert. Um auch umfangreichere Projekte prozessieren zu können, werden nur die benötigten Daten für einzelne CLC Objekte aus der Datenbank geladen. Die Ergebnisse werden ebenfalls in der Projektdatenbank gespeichert.
- c) *Verarbeitung des Klassenkataloges*: Basierend auf den Merkmalen werden die einzelnen Bildsegmente den CLC Klassen zugewiesen (*bottom-up* Ansatz). Im Rahmen dieser Arbeit wurden die CLC Objekte durch ihre Komponenten bestimmt (*top-down* Ansatz), um die CLC Geometrie nicht zu verändern.
- d) *Ergebnisvalidierung*: Die Ergebnisse der CLC Prozessierung können mit dem

CLC 2000 Datensatz verglichen werden, um die Qualität der Klassifikation zu bewerten.

Der endgültige Grad der Automatisierung wird durch die verwendeten Merkmale bestimmt. CLC Klassen, die durch die Datengrundlage eindeutig identifiziert werden können, d.h. durch den *bottom-up* Ansatz bestimmt werden, können automatisiert klassifiziert werden. Durch eine manuelle Unterstützung bei anderen Klassen (siehe Tabelle 4.7) kann das Klassifikationsergebnis signifikant verbessert werden, indem das *a-priori* Wissen des Interpreten und eventuell weitere unabhängige Datenquellen die endgültige Entscheidung mitbestimmen.

Skalierbarkeit des Systems

Der Ausgangsdatsatz (**Image 2000**) für die CLC Aktualisierung besteht aus 31 Landsat ETM+ Szenen. Das entspricht einem Datenvolumen von ungefähr 26 Gigabyte. Der resultierende CLC Datensatz umfasst ca. 180 000 Objekte. Um diese Datenmengen prozessieren zu können, müssen sie effizient gehalten und den einzelnen Modulen individuell zur Verfügung gestellt werden. Diese Aufgabe übernimmt ein relationales Datenbanksystem. Die Prozessierung ist auf eine objektweise Verarbeitung konzeptioniert, d.h. es werden nur jene Daten aus der Datenbank angefordert, die für ein Objekt (CLC oder Bildobjekt) erforderlich sind. Auf dieser Basis können beliebig viele Prozessierungseinheiten an einem Projekt arbeiten.

Neben der effizienten Datenhaltung spielt die Prozessierungszeit eine wichtige Rol-

le für die Einsatzfähigkeit der Methodik. Die Prozessierung des Testgebietes Frankfurt benötigte vom Datenimport bis zur Evaluierung der Ergebnisse mehrere Tage. Gründe für den hohen Rechenaufwand waren neben den schon erwähnten Datenmengen die verwendeten Merkmale, die jeweils für die einzelnen Objekte berechnet wurden. Aus diesem Grund wurde der Klassifikationsprozess soweit modularisiert und autonom entworfen, dass mehrere Programmkomponenten parallel an einem Projekt prozessieren können, um dadurch eine Leistungssteigerung zu erzielen. Diese Prozesse können auf einer Ebene — räumlich versetzt — laufen oder iterativ geschaltet sein (Segmentierung --> Merkmalsgenerierung --> Gewichtung --> Validierung). Erst diese Parallelisierung ermöglicht den Einsatz bzw. die Validierung der entwickelten Methodik für großflächige Gebiete. Darüber hinaus können weitere, rechenintensive Merkmale, wie Texturparameter implementiert und verwendet werden.

Nutzereingriff

Das Rahmenprogramm zeichnet sich durch einen selbsttätigen Ablauf einer vorher definierten Prozesskette aus. Im Idealfall beschränkt sich der menschliche Eingriff auf den Datenimport und der Auswertung der Ergebnisse. Für gnosis müssen folgende Aufgaben manuell durchgeführt werden:

1. *Datenaufbereitung*: Die Vorbereitung der Datensätze kann mit einem beliebigen Bildverarbeitungsprogramm, wie ERDAS Imagine oder ENVI erfolgen. Zu den benötigten Funktionen

gehören unter anderem: Auswahl der verwendeten Projektion, Zusammenstellung der Rasterebenen pro Datensatz und die Anpassung der Ausschnitte und Auflösung der verschiedenen Datensätze.

2. *Aufbau des Regelwerkes / Gewichtungssysteme*: Im Rahmen dieser Arbeit wurde ein CLC Klassenkatalog erstellt, das für weitere Projekte genutzt werden kann. Dieser Katalog ist durch das Gewichtungssystem in der Software implementiert. Um Anpassungen der Regeln durchführen zu können, die durch eine räumliche oder thematische Variabilität der Klassen verursacht werden, müssen XML-Steuerdateien verändert werden. Eine iterative Optimierung dieser Steuerdateien ist in Planung.

Die Bedienung erfolgt durch eine serverseitige Webanwendung (*gnosisNET*). Die Abbildung 5.1 zeigt beispielsweise die Auswertung eines CLC Objektes, die Repräsentationsgüte durch ihre Unterobjekte und die daraus resultierende Gewichtung. Für die manuelle Kontrolle können diese Informationen und weitere Datenquellen (hier *Google Maps*) genutzt werden, um das Ergebnis zu bestätigen, oder Änderungen beziehungsweise Ergänzungen durchzuführen. Alle wichtigen Funktionen stehen dem Anwender über den Browser zur Verfügung. Neben der statistischen Auswertung der einzelnen Projekte kann das System auch für eine interaktive Kontrolle der CORINE Objekte genutzt werden. Dazu werden weitere standardisierte Internetdienste vom *Open Geospatial Consortium Inc.* (Open Geospatial Consortium, 2006) für Geodaten (WFS – *Web Feature Service* für Vektordaten,

WCS – *Web Coverage Service* für Rasterdaten und WMS – *Web Map Service* für Kartendienste) verwendet, um die benötigten Daten (zum Beispiel Image2000 Datensatz, topographische Karten, Grenzen der Naturschutzgebiete, höchst aufgelöste Fernerkundungsdaten über *Google Earth* usw.) dem Interpreten zur Verfügung zu stellen. Die Oberfläche gestattet eine manuelle Nachbearbeitung bzw. Korrektur der Ergebnisse in einer einheitlichen Umgebung.

5.1 Zukünftige Perspektiven

Diese Arbeit stellt eine Methode vor, um automatisiert und semi-automatisiert Klassen der Landbedeckung und Landnutzung aus Fernerkundungsdaten am Beispiel von *Corine Land Cover* abzuleiten. Prinzipiell kann jedes Klassifikationssystem, das Landbedeckung oder Landnutzung beschreibt und auf einer konsistenten Klassenbeschreibung aufbaut, mit dieser Methodik umgesetzt werden. Dabei müssen neue Merkmale definiert und implementiert werden, um zusätzliche Klassen zu beschreiben. Ein großes Potential liegt hierbei in der Auswertung von temporal bzw. radiometrisch hoch aufgelösten Daten für eine weitere Differenzierung der Landbedeckung und Landnutzung. Geometrisch höchst aufgelöste Datensätze eignen sich ebenfalls zur Verbesserung der Lagegenauigkeit und Abgrenzung der Objekte.

Um das bestehende System für CORINE Land Cover weiter zu optimieren, können künftig folgende Teilaspekte untersucht werden:

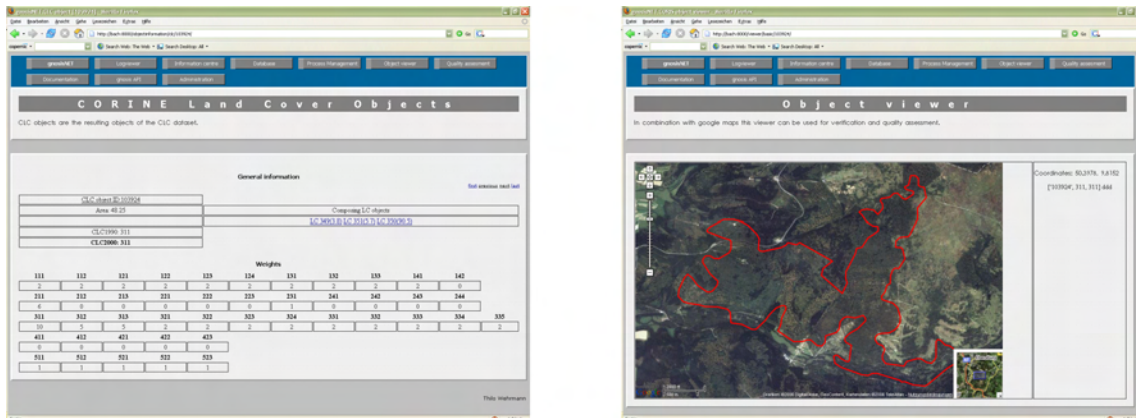


Abbildung 5.1: Ausblick für den Einsatz von gnosisNET

- *Texturbasierte Segmentierung und Klassifikation*: Die Textur spielt in der jetzigen Implementation nur eine untergeordnete Rolle. Die implementierten Texturparameter von HARALICK *et al.* (1973) wurden im Regelwerk bewußt nicht eingebunden, um die Rechenzeit nicht zusätzlich zu erhöhen. Studien von STEINNOCHER (1997) zeigen jedoch, dass die statistischen Parameter der zweiten Ordnung (Homogenität durch den *Inverse Difference Moment*, einem Parameter aus den Co-Occurrence Matrix von Haralick) eine hohe Aussagekraft bei der Extraktion von Siedlungsflächen besitzen.
 - *Landbedeckungsklassifikation*: Die Anwendung der *Support Vector Machines* zur pixelweisen Klassifikation der Landbedeckung erfolgte aufgrund ihrer hohen Generalisierungsfähigkeiten basierend auf wenigen Trainingsgebieten. Andere Klassifikationsverfahren wie beispielsweise künstliche Neuronale Netze können mit einer erweiterten Trainingsmenge, die an die einzelnen Szenen angepasst wer-
- den müssen, bessere Ergebnisse liefern (HINTON UND SALAKHUTDINOV, 2006). Dies erhöht aber unweigerlich die Bearbeitungszeit (Erstellung der Trainingsgebiete und Training des Netzwerkes).
- *Zeitliche Merkmale*: In dieser Arbeit wurden zwei Merkmale entwickelt, um kontinuierliche Zeitreihen zu parametrisieren (*temporale Intensität* und *temporale Variabilität*). Durch erweiterte Verfahren, wie beispielsweise von AURDAL *et al.* (2005) vorgestellt, können weitere Informationen aus der Phänologie gewonnen werden. Um die zeitlichen Parameter im CORINE Maßstab von 1:100 000 zur Verfügung zu stellen, reicht die geometrische Auflösung von MODIS nicht mehr aus. Eine Alternative dazu könnte eine nicht kontinuierliche Zeitreihe für die wichtigsten Zeitpunkte im Jahr aus AWIFS-Daten des indischen Satelliten IRS-P6 / Resourcesat 1 darstellen.
- Die vollständige Automatisierung setzt eine autonome Bestimmung der geeigneten

Merkmale bzw. die optimale Gewichtung für eine Klasse in Abhängigkeit von den unterschiedlichen Daten — räumlich und thematisch betrachtet — voraus. Um objektive Ergebnisse erzielen zu können, müssen Parametereinstellungen nachvollziehbar und durch eine übertragbare Methodik bestimmt werden. Hierzu können genetische Algorithmen eingesetzt werden, um die Gewichtungsverfahren iterativ an den existierenden CLC 2000 Daten für verschiedene Räume zu optimieren. Damit würde dem Gesamtsystem eine Lernkomponente hinzugefügt werden, die eine Anpassung an variable Klassen erlaubt.

Durch den Ausfall von Landsat 7 seit 2003 steht dieser Sensor für für die Akquirierung einer großflächigen und einheitlichen Datengrundlage nicht mehr zur Verfügung. Neben Landsat 5-TM (seit 1984 im Betrieb) gibt es weitere operationell laufende Plattformen mit optischen Sensoren, wie SPOT und IRS mit ähnlichen spektralen und geometrischen Charakteristiken. Unterschiedliche Sensorspezifikationen, wie geometrische, spektrale und radiometrische Auflösung erschweren jedoch die Übertragbarkeit der Software und bedürfen einer weiteren Untersuchung. Die entwickelte Methodik hingegen ist auflösungsunabhängig.

men dieser Arbeit nicht zu sprengen. Eine umfassende Beschreibung zur Implementierung und der Umsetzung der verwendeten technischen Strukturen erfolgt in einer zusätzlichen Dokumentation zu gnosis bzw. kann über die dort vorgestellte Schnittstelle zur Anwendungsprogrammierung (API) und dem Quellcode erfolgen.

5.2 Abschließende Bemerkungen

Die vorliegende Arbeit beschreibt grundlegend die entwickelte Theorie von gnosis und der verwendeten Daten bzw. Merkmale. Auf der Basis der technischen Details wurde bewusst verzichtet, um den Rah-

Literaturverzeichnis

- Anderson, J.R., E.E. Hardy, John T. Roach und Richard E. Witmer.
A Land Use And Land Cover Classification System For Use With Remote Sensor Data.
Techn. Ber, United States Department of the Interior – Geological Survey, Washington, 1976.
Geological Survey Professional Paper 964.
- Atkinson, P.M. und P.J. Curran.
Defining an optimal size of support for remote sensing investigations.
IEEE Transactions on Geoscience and Remote Sensing, 33(3):768–776, 1995.
- Aurdal, L., R.B Huseby, L. Eikvil, R. Solberg, D. Vikhamar und A.Solberg.
Classifying Multi-Temporal TM Imagery Using Markov Random Fields and Support Vector Machines.
In: King, R. L. und N. H. Younan (Herausgeber), *Proceedings of the Third International Workshop on the Analysis of Multi-temporal Remote Sensing Images.*
IEEE Publication., 2005.
- Baltsavias, E.P.
Object extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems.
ISPRS Journal of Photogrammetry & Remote Sensing, 58:129–151, 2003.
- Bar, M.
Visual objects in context.
Nature Reviews, 5:617–629, 2004.
- Bartelme, N.
Geoinformatik. Modelle, Strukturen, Funktionen.
Spektrum, 2005.
- Bartholomé, E. und A. S. Belward.
GLC2000: a new approach to global land cover mapping from Earth observation data.
Int. J. Remote Sensing, 26(9):1959–1977, 2005.
- Bastian, O. und K.-F. Schreiber.
Analyse und ökologische Bewertung der Landschaft.
Spektrum, 1999.
- Bauer, J.R., E.E. Hardy, J.T. Roach und W.E. Witmer.
Satellite inventory of Minnesota forests.
Photogrammetric Engineering and Remote Sensing, 60(3):287–298, 1994.
- Belward, A. S., J. E. Estes und K. D. Kline.
The IGBP-DIS Global 1-km Land-Cover Data Set DISCover: A Project Overview.
Photogrammetric Engineering and Remote Sensing, 65:1013–1020, 1999.

- Ben-Hur, A. und W. S. Noble.
Kernel methods for predicting protein-protein interactions.
Bioinformatics, 21 Suppl 1:1–9, 2005, ISSN 1367-4803, http://www.ncbi.nlm.nih.gov/entrez/query.fcgi?cmd=Retrieve&db=pubmed&dopt=Abstract&list_uids=15961482.
- Bennet, Kristin P. und Colin Campbell.
Support Vector Machines: Hype or Hallelujah?
Special Interest Group on Knowledge Discovery and Data Mining, 2(2):1–13, 2000.
- Benz, U.C., P. Hofmann, G. Willhauck, I. Lingenfelder und M. Heynen.
Multi-resolution, object oriented fuzzy analysis of remote sensing data for GIS-ready information.
ISPRS Journal of Photogrammetry & Remote Sensing, 58:239–258, 2003.
- Biederman, I.
Recognition-by-Components: A Theory of Human Image Understanding.
Psychological Review, 94(2):115–147, 1987.
- Blaschke, T. und J. Strobl.
What's wrong with pixels ? Some recent development interfacing remote sensing and GIS.
GIS, 6:12–17, 2001.
- Blaschke, T., S. Lang, E. Lorup, J. Strobl und P. Zeil.
Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications.
In: *Environmental information for Planning, Politics and the Public*, volume 2, S. 555–570.
Metropolis Verlag, 2000.
- Bossard, M., J. Feranec und J. Othahel.
CORINE land cover technical guide – Addendum 2000.
Techn. Ber, European Environment Agency, Copenhagen, 2000.
Technical Report 40.
- Breger, P., M. Malacarne, A. Podaire, G. Campbell, M. Doherty und S. Bruzzi.
Global Monitoring for Environment and Security (GMES): the services establishing and initial GMES capacity.
In: *31st International Symposium on Remote Sensing of Environment*, 2005.
- Bronge, L. B. und B. Näslund-Landenmark.
Wetland classification for Swedish CORINE Land Cover adopting a semi-automatic interactive approach.
Can. J. Remote Sensing, 28:139–155, 2002.
- Brown, N., F. Gerald und R. Fuller.
Mapping of Land Use Classes within the CORINE Land Cover Map of Great Britain.
Cartographic Journal, 39(1):5–14, 2002.
- Burges, C.J.C.
A Tutorial on Support Vector Machines for Pattern Recognition.

- Data Mining and Knowledge Discovery, 2:121–167, 1998.
- Camps-Valls, G., L. Gomez-Chova, J. Calpe-Maravilla, J.D. Martin-Guerrero, E. Soria-Olivias, L. Alonso-Chorda und J. Moreno.
Robust support vector method for hyperspectral data classification and knowledge discovery.
IEEE Transactions on Geoscience and Remote Sensing, 42(7):1530–1542, 2004.
- Castleman, K.R.
Digital Image Processing.
Prentice Hall Press, Upper Saddle River, NJ, USA, 1995.
- Cauwenberghs, Gert und Tomaso Poggio.
Incremental and Decremental Support Vector Machine Learning.
In: *NIPS*, S. 409–415, 2000.
- Chan, Samuel W. K.
Object-Oriented Knowledge-Based System for Image Diagnosis.
Applied Artificial Intelligence, 10(5):407–438, 1996.
- Chang, Chih-Chung und Chih-Jen Lin.
LIBSVM: a library for support vector machines, 2001.
Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- Cihlar, J.
Land cover mapping of large areas from satellites: status and research priorities.
Int. J. Remote Sensing, 21(6 & 7):1093–1114, 2000.
- Cohen, Jacob.
A Coefficient of Agreement for Nominal Scales.
Educational and Psychological Measurement., 1(20):37–46, 1987.
- Datcu, M. und K. Seidel.
Human Centered Concepts for Exploration and Understanding of Earth Observation Images.
IEEE Transaction on Geoscience and Remote Sensing, 43:601–609, 2005.
- Datcu, M., K. Seidel und M. Walessa.
Spatial Information Retrieval from Remote-Sensing Images — Part I: Information Theoretical Perspective.
IEEE Transactions on Geoscience and Remote Sensing, 36(5):1431–1445, 1998.
- Datcu, M., F. Melgani, A. Piardi und S.B. Serpico.
Multisource Data Classification With Dependence Trees.
IEEE Transactions on Geoscience and Remote Sensing, 40(3):609–617, 2002.
- Kok, R. de.
Objektorientierte Bildanalyse. Ein Lösungsansatz für den automatisierten Einsatz sehr hoch auflösender Satellitendaten für forstliche Fragestellungen.
Dissertation, Fakultät für Forstwissenschaft der Technischen Universität München, 2001.
- De Kok R., Wever T. and R. Fockelmann.

- Analysis of Urban Structures and Development applying Procedures for Automatic Mapping of Large Area Data.*
In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, volume 34, 2005.
- de Lange, N.
Geoinformatik in Theorie und Praxis.
Springer Verlag, Heidelberg, Berlin, 2002.
- de Lima, Maria Vanda Nunes.
IMAGE2000 and CLC2000 – Products and Methods.
Techn. Ber, JRC and EEA, Ispra, 2005.
- de Zeeuw, C.J. und G.W Hazeu.
Monitoring land use changes using geo-information.
Techn. Ber, Alterra, Green World Research, Wageningen, 2001.
Alterra-rapport 214.
- DeFries, R.S. und J.R.G. Townshend.
NDVI-derived land cover classification at global scales.
Int. J. Remote Sensing, 15:3567–3586, 1994.
- Desclée, B., P. Bogaert und P. Defourny.
Forest change detection by statistical object-based method.
Remote Sensing of Environment, 102:1–11, 2006.
- Gregorio, A. di und L.J.M. Jansen.
A new concept for a Land Cover Classification System. Earth observation and evolution classification.
In: *Proceedings of the seminar 13.-16 October 1997*, 1997.
Alexandria. Egypt.
- Distel, R.
Graphentheorie.
Springer Verlag, 1990.
- Duhamel, C. und C Vidal.
Objectives, tools and nomenclatures.
In: *EUROSTAT: Land Cover and Land Use information systems for European Union Policy needs.*, 1999.
- Edelman, S.
Representation, Similarity and the Chorus of Prototypes.
Minds and Machines, 5:45–68, 1995.
- Edelman, S. und N. Intrator.
Unsupervised statistical learning in vision: computational principles, biological evidence, 2004.
- EEA.
Technical and methodical guide for updating CORINE land cover data base.

- Techn. Ber, European Commission, 1997.
EUR 17288.
- EEA und ETC-TE.
CORINE Land Cover update I&CLC2000 project.
Techn. Ber, European Environment Agency, Copenhagen, 2002.
Final Version.
- Egenhofer, M. und A. Frank.
Object-oriented modelling in GIS: inheritance and propagation.
Auto-Carto, 9:588–598, 1989.
- Egenhofer, M. und A. Frank.
Object-Oriented Modelling for GIS.
Journal of the Urban and Regional Information Systems Association, 4:3–19, 1992.
- Engberg, A.
Swedish CLC2000 – Final Report.
Techn. Ber, Lantmäteriet, 2005a.
- Engberg, A.
Produktspecifikation av Svenska CORINE Marktäckedata.
Techn. Ber, Lantmäteriet, 2005b.
- Esch, T.
Eignung eines objektorientierten Klassifikationsverfahrens zur Gewinnung planungsrelevanter Informationen über urban geprägten Räumen.
Diplomarbeit, Universität Trier, 2003.
- EU.
CORINE Land Cover – Technical Guide.
Techn. Ber, EU, Brussels, 1994.
- FAO.
Agricultural Information Management Standatds Web site, 2006, <http://www.fao.org/aims/cs.htm>.
- FAO.
Overview of the Africover Initiative and of the Africover Eastern Africa Project, 2002, http://www.africover.org/download/documents/Short_Project_description_en.pdf.
- Feranec, J., G. Hazeu, S. Christensen und G. Jaffrain.
Corine land cover change detection in Europe (case studies of the Netherlands and Slovakia).
Land Use Policy, in press, 2005.
- Flach, P. A.
On the state of the art in machine learning: A personal review.
Artificial Intelligence, 131:199–222, 2001.
- Fonseca, F. und M. Egenhofer.
Ontology-Driven Geographic Information Systems.

- In: Medeiros, C. B. (Herausgeber), *ACM-GIS '99, Proceedings of the 7th International Symposium on Advances in Geographic Information Systems, November 2–6, 1999, Kansas City, USA*, ACM, 1999.
- Fonseca, F., M. Egenhofer und P. Agouris.
Using Ontologies for Integrated Geographic Information Systems.
Transaction in GIS, 6(3):231–257, 2002.
- Fonseca, F., C. Davis und G. Camara.
Bridging Ontologies and Conceptual Schemas in Geographic Information Integration.
GeoInformatica, 7(4):355–378, 2003.
- Foody, G. M. und A. Mathur.
A relative evaluation of multiclass image classification by support vector machines.
IEEE Transactions on Geoscience and Remote Sensing, 42(6):1335–1343, 2004a.
- Foody, G.M. und A. Mathur.
Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification.
Remote Sensing of Environment, 93:107–117, 2004b.
- Frank, A.
Spatial and Temporal Reasoning, S. 135–153.
Kluwer Academic Publishers, Dordrecht, The Netherlands, 1997.
- Friedl, M.A., C.E. Brodley und A. Strahler.
Maximizing land cover classification accuracies produced by decision trees at continental to global scales.
IEEE Transactions on Geoscience and Remote Sensing, 37:969–977, 1999.
- Fukuda, S. und H. Hirosawa.
Support vector machine classification of land cover: applicaiton topolarimetric SAR data.
In: *Geoscience and Remote Sensing Symposium, volume 1, IGARSS 2001*, 2001.
- Fuller, R. und N. Brown.
A CORINE map of Great Britain by automated means. Techniques for automatic generalization of the Land Cover Map of Great Britain.
Int. J. Geographical Information Systems, 10(8):937–953, 1996.
- Fuller, R., G. Groom und A. Jones.
The Land Cover Map of Great Britain: an automated classification of Landsat Thematic Mapper data.
Photogrammetric Engineering and Remote Sensing, 60:553–562, 1994.
- Fuller, R., G. Smith, J. Sanderson, R. Hill und A. Thomson.
The UK Land Cover Map 2000: construction of a parcel-based vector map from satellite images.
Cartographic Journal, 39(1):15–25, 2002.
- Georgopoulos, A.P., J.T. Lurito, M. Petrides, A.B. Schwartz und J.T. Massey.
Mental rotation of the neuronal population vector.
Nature, 243:234–236, 1989.

- Gopal, S., C. Woodcock und A. Strahler.
Fuzzy ARTMAP classification of global land cover from AVHRR data set.
In: *Proceedings of the 1996 International Geoscience and Remote Sensing Symposium*, S. 538–540, Lincoln, 1996.
- Gore, A.
The Digital Earth: Understanding our planet in the 21st Century, 1998.
Given at the California Science Center, Los Angeles, California, on January 31, 1998.
- Gregorio, Antonio Di und Louisa J.M. Jansen.
Land Cover Classification System (LCCS), 2000.
- Gruber, T. R.
Toward principles for the design of ontologies used for knowledge sharing.
In: *International Workshop on Formal Ontology*, 1993a.
- Gruber, T.R.
A translation approach to portable ontologies.
Knowledge Acquisition, 5(2):199–220, 1993b.
- Haarmann, B.
Untersuchung zur Verwendbarkeit der Software eCognition für Zwecke der CORINE Landnutzungs-Klassifikation.
Diplomarbeit, Universität Hannover – Institut für Photogrammetrie und Ingenieurvermessung, 2001.
- Haarslev, Volker, Ralf Moller und Michael Wessel.
RACER: Renamed ABox and Concept Expression Reasoner.
Verfügbar: <http://www.sts.tu-harburg.de/~r.f.moeller/racer/>, 2003.
- Haralick, R. und L. Shapiro.
Image segmentation techniques.
Computer Vision, Graphics, and Image Processing, 29:100–132, 1985.
- Haralick, R., K. Shanmugan und I. Dinstein.
Textural features for image classification.
IEEE Transactions on Systems, Man and Cybernetics, 3(1):610–621, 1973.
- Hazeu, G.W.
CLC2000 Land Cover database of the Netherlands.
Techn. Ber, Alterra, Green World Research, Wageningen, 2003.
- Hinton, G.E. und R.R. Salakhutdinov.
Reducing the Dimensionality of Data with Neural Networks.
Science, 313:504–507, 2006.
- Hobbs, J.
Granularity.
In: *Proceedings of IJCAI-85*, S. 432–435, 1985.
- Huang, C., L.S. Davis und J.R.G. Townshend.

- An assessment of support vector machines for land cover classification.*
Int. J. Remote Sensing, 23(4):725–749, 2002.
- Jackson, John V.
Idea for a Mind.
SIGGART Newsletter, 9(181):23–26, 1987.
- Jensen, J.R.
Introductory Digital Image Processing: A Remote Sensing Perspective.
Prentice Hall, 1996.
- Johansson, I.
Ontological Investigations. An Inquiry into the Categories of Nature, Man and Society.
Routledge, New York and London, 1989.
- Keil, M., R. Kiefl und G. Strunz.
CORINE Land Cover 2000 – Europaweit harmonisierte Aktualisierung der Landnutzungsdaten für Deutschland.
Techn. Ber, Umweltbundesamt (UBA), 2005.
Abschlussbericht zum F+E Vorhaben UBA FKZ 201 12 209.
- Keuchel, J., S. Naumann, M. Heiler und A. Siegmund.
Automatic land cover analysis for Tenerife by supervised classification using remotely sensed data.
Remote Sensing of Environment, 86:530–541, 2003.
- Koch, B., M. Jochum, E. Ivits und M. Dees.
Pixelbasierte Klassifikation im Vergleich und zur Ergänzung zum objektbasierten Verfahren.
Photogrammetrie · Fernerkundung · Geoinformation, 3:195–204, 2003.
- Kohonen, T.
The self-organizing map.
In: *Proceedings of the IEEE*, volume 78, S. 1464–1480, 1990.
- Kurosu, T., S. Yokoyama und M. Fujita.
Land use classification with textural analysis and the aggregation technique using multi-temporal JERS-1 L-band SAR images.
Int. J. Remote Sensing, 22(4):595–613, 2001.
- Leukert, K.
Verwendung von GIS-Daten für die Objektextraktion.
In: Blaschke, T. (Herausgeber), *Verwendung von GIS-Daten für die Objektextraktion*, S. 132–140, Heidelberg, Wichmann Verlag.
- Lillesand, T. und R. Kiefer.
Remote sensing and image interpretation.
Springer Verlag, New York, 4th Aufl., 2000.
- Loveland, T.R. und A.S. Belward.
The IGBP-DIS global 1 km land cover data set, DISCover: first results.
Int. J. Remote Sensing, 18(9):3289–3295, 1997.

- Loveland, T.R., J.W. Merchant, D.O. Ohlen und J.F. Brown.
Development of a land-cover characteristics database for the conterminous U.S.
 Photogramm. Eng. Remote Sens., 57:1453–1463, 1991.
- Lu, D. und Q. Weng.
Use of impervious surface in urban land-use classification.
 Remote Sensing of Environment, 102:146–160, 2006.
- Madhok, V. und D.A. Landgrebe.
A Process Model for Remote Sensing Data Analysis.
 IEEE Transactions on Geoscience and Remote Sensing, 40:680–686, 2002.
- Marçal, A.R.S., J.S. Borges, J.A. Gomes und J.F. Pinto da Costa.
Land cover update by supervised classification of segmented ASTER images.
 Int. J. Remote Sensing, 26(7):1347–1362, 2005.
- Marr, D.
Vision: a computational investigation into the human representation and processing of visual information.
 W.H. Freeman and Co, 1982.
- Marslen-Wilson, William D. und Lorraine K. Tyler.
The temporal structure of spoken language understanding.
 Cognition, 8:1–71, 1980.
- Mattikalli, N. M.
Soil color modeling for the visible and near-infrared bands of Landsat sensors using laboratory spectral measurements.
 Remote Sensing of Environment, 59(1):14–28, 1997.
- Meinel, G. und J. Hennersdorf.
Classification Systems of land cover and land use and their challenges for picture processing of remote sensing data – Status of international discussion and programs.
 In: *Proceedings of the 3rd International Symposium Remote sensing of urban areas*, 2002a.
- Meinel, G. und J. Hennersdorf.
Bodenbedeckung und -nutzung, Grundinformationen für die Planung – zum Stand der europäischen Nomenklaturdebatte.
 In: *Tagungsband der CORP 2002 – Geo Multimedia*, 2002b.
- Melgani, F. und L. Bruzzone.
Classification of Hyperspectral Remote Sensing Images With Support Vector Machines.
 IEEE Transaction on Geoscience and Remote Sensing, 42(8):1778–1790, 2004.
- Mitra, P.
Segmentation of multispectral remote sensing images using active support vector machines.
 Pattern Recognition Letters, 25(9):1067–1074, 2004.
- Molenaar, M. und D.E. Richardson.
Object hierarchies for linking aggregation levels in GIS.

- In: *International Archives of Photogrammetry and Remote Sensing*, volume 30, S. 610–617, Athens, 1994.
- Montello, D. (Herausgeber).
What's in an image ?, Morro Bay, COSIT, Springer Verlag.
- MySQL AB.
Reference Manual for MySQL 5.0.
Uppsala. Schweden, 2005.
- Noy, N.F. und D.L. McGuinness.
Ontology Development 101: A Guide to Creating Your First Ontology.
Techn. Ber, Stanford University, 2001.
- Open Geospatial Consortium.
Web Map Context Documents, 2006, https://portal.opengeospatial.org/files/?artifact_id=8618.
- Pal, M. und P.M. Mather.
Support vector machines for classification in remote sensing.
Int. J. Remote Sensing, 26(5):1007–1011, 2005.
- Pal, N.R. und S.K. Pal.
A review on image segmentation techniques.
Pattern Recognition, 26:1277–1294, 1993.
- Palmeri, T. und I. Gauthier.
Visual object understanding.
Nature Reviews, 5:291–303, 2004.
- Pedley, M. und P. Curran.
Per-field classification: an example using SPOT imagery.
Int. J. Remote Sensing, 12:2181–2192, 1991.
- Perdigao, V. und A. Annoni.
Technical and Methodological Guide for Updating CORINE Land Cover Data Base.
Techn. Ber, JRC and EEA, Luxembourg, 1997.
- Peuquet, D.
A Conceptual Framework and Comparison of Spatial Data Models.
Cartographica, 21:66–113, 1984.
- Piper, J. Rutovitz, D.
An investigation of object-oriented programming as the basis for an image processing and analysis system.
In: *Pattern Recognition, 1988., 9th International Conference on Pattern Recognition*, volume 2, S. 1015–1019, Rome, Italy, 1998.
- Quinlan, J.R.
C4.5: Programs for Machine Learning.
Morgan Kaufmann, 1993.

- Quinlan, J.R.
Bagging, boosting and C4.5.
In: *Proceedings of the Thirteenth National Conference on Artificial Intelligence*, S. 725–730,
Portland, 1996.
- Richards, J.A.
Remote Sensing Digital Image Analysis.
Springer Verlag, 1999.
- Riesenhuber, M. und T. Poggio.
Models of object recognition.
nature neuroscience, 3:1199–1204, 2000.
- Rinne, H.
Taschenbuch der Statistik.
Deutsch Harri GmbH, 3. Aufl., 2003.
- Sakamoto, T., M. Yokozawa, H. Toritani, M. Shibayama, N. Ishitsuka und H. Ohno.
A crop phenology detection method using time-series MODIS data.
Remote Sensing of Environment, 96:366–374, 2005.
- Scepan, J.
Thematic Validataion of High-Resolution Global Land-Cover Data Sets.
Photogram. Eng. Remote Sens, 65:1051–1060, 1999.
- Schiewe, J.
Ansätze zur Übertragung von Theorien der kognitiven Wahrnehmung auf die rechnerische Interpretation von Fernerkundungsszenen.
Photogrammetrie · Fernerkundung · Geoinformation, 3:181–194, 2003.
- Schorcht, G.
Wiedererkennen von Kartenausschnitten aufgrund von Nachbarschaftsbeziehungen von klassifizierten Fernerkundungsdaten.
Diplomarbeit, Universität Würzburg, 2006.
- Schreier, G. und S. Dech.
High resolution earth observation satellites and services in the next decade — a European perspective.
Acta Astronautica, 57:520–533, 2005.
- Selfridge, O.G.
Pandemonium: a paradigm for learning.
In: *The mechanisation of thought processes*, London, 1959.
- Simons, P.
Parts, A Study in Ontology.
Clarendon Press, Oxford, 1987.
- Smith, B. und R. Casati.
Naive Physics: An Essay in Ontology.
Philosophical Psychology, 7(2):225–244, 1994.

- Smith, B. und D. M. Mark.
Do Mountains Exist? Towards an Ontology of Landforms.
Environment and Planning B (Planning and Design), 30(3):411–427, 2003.
- Smith, B. und A. C. Varzi.
Fiat and Bona Fide Boundaries.
Philosophy and Phenomenological Research, 60(2):401–420, 2000.
- Smith, G.M. und R.M. Fuller.
An integrated approach to land cover mapping: the land cover of Jersey.
Int. J. Remote Sensing, 22:3123–3142, 2001.
- Smola, A.J. und B. Schölkopf.
A tutorial on support vector regression.
Statistical Computing, 14:199–222, 2004.
- Steenmans, C. und A. Gheorghe.
European perspective on the joint I&CLC2000 project.
Techn. Ber, European Environment Agency (EEA), 2000.
- Steinnocher, K.
Texturanalyse zur Detektion von Siedlungsgebieten in hochauflösenden panchromatischen Satellitenbilddaten.
In: *Angewandte Geographische Informationsverarbeitung.*
Selbstverlag des Institutes für Geographie der Universität Salzburg, 1997.
- T. Blaschke, C. Burnett und A. Pekkarinen.
Remote Sensing Image Analysis: Including the Spatial Domain, Kapitel Image Segmentation Methods for Object-based Analysis and Classification, S. 211–236.
Springer, 2005.
- Tomai, E. und M. Kavouras.
From „Onto-GeoNoesis “to „Onto-Genesis “: The Design of Geographic Ontologies.
GeoInformatica, 8(3):285–302, 2004.
- Townshend, J., C. Huang, S. Kalluri, R. DeFries, S. Liang und K Yank.
Beware of per-pixel characterisation of land cover.
Int. J. Remote Sensing, 21(4):839–843, 2000.
- Trias-Sanz, Roger.
A Texture Orientation Estimator for Discriminating Between Forests, Orchards, Vineyards, and Tilled Fields.
In: *Proc. of the 2005 International Geosciences And Remote Sensing Symposium (IGARSS 2005), Seoul, South Korea, 2005.*
- Tucker, C.J., J.R.G. Townshend und T.E. Goff.
African land-cover classification using satellite data.
Science, 227:369–375, 1985.
- Tufte, L.

- Automatisierte Bestimmung von Bearbeitungsskalen für die multiskalige Auswertung von hochauflösenden Fernerkundungsdaten.*
 Photogrammetrie · Fernerkundung · Geoinformation, 5:383–394, 2003.
- Uschold, M. und M. Gruninger.
Ontologies: Principles, Methods and Applications.
 The Knowledge Engineering Review, 11(2):93–136, 1996.
- Rossum, G. van.
Python Library Reference.
 CWI Report CS-R9524, Centrum voor Wiskunde en Informatica (CWI), Amsterdam, 1995.
- Vapnik, V.N.
The Nature of Statistical Learning Theory.
 Springer Verlag, 1995.
- Foerster, H. von.
KybernEthik.
 Merve Verlag, Berlin, 1985.
- Warmerdam, F.
GDAL — Geospatial Data Abstraction Library, 2004.
<http://remotesensing.org/gdal/index.html>.
- White, S.
Better computational descriptions of science.
 Scientific Computing World, 33(4), 2005.
- Willhauck, G., T. Sschneider, R. de Kok und U. Ammer.
Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos.
 In: ISPRS, volume 23, Amsterdam, 2000.
- Winston, M., R. Chaffin und D. Herrmann.
A Taxonomy of Part-Whole Relations.
 Cognitive Science, 11:417–444, 1987.
- Woodcock.
Nested-hierarchical scene models and image segmentation.
 Int. J. Remote Sensing, 13(16):3167–3187, 1992.
- Zadeh, L.
Fuzzy sets.
 Information Control, 8:338–353, 1965.
- Zhang, X., M.A. Friedl, C.B. Schaaf, A.H. Strahler, J.C.F. Hodges, F. Gao, B.C. Reed und A. Huete.
Short communication: Monitoring vegetation phenology using MODIS.
 Remote Sensing of Environment, 84:471–475, 2003.

Zhang, Y.J.

A survey on evaluation methods for image segmentation.
Pattern Recognition, 29(8):1335–1346, 1996.

Zhu, G. und D. G. Blumberg.

Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel.
Remote Sensing of Environment, 80:233–240, 2002.

Anhang



Abbildungen




Abbildung A.1: Übersicht der falsch zugewiesenen CLC Objekte durch gnotis für den Testraum Frankfurt

CORINE LC Klassen			
111	Flächen durchgängig städtischer Prägung	311	Laubwald
112	Flächen nicht-durchgängig städtischer Prägung	312	Nadelwald
121	Industrie- und Gewerbeflächen	313	Mischwald
122	Straßen und Eisenbahn	321	Natürliches Grünland
123	Hafengebiete	322	Heiden und Moorheiden
124	Flughäfen	323	Hartlaubgewächse
131	Abbauflächen	324	Wald-Strauch-Übergangsstadien
132	Deponien und Abraumhalden	331	Strände, Dünen und Sandflächen
133	Baustellen	332	Felsflächen ohne Vegetation
141	Städtische Grünflächen	333	Flächen mit spärlicher Vegetation
142	Sport und Freizeitanlagen	334	Brandflächen
211	Nicht bewässertes Ackerland	335	Gletscher und Dauerschneegebiete
212	Permanent bewässertes Ackerland	411	Sümpfe
213	Reisfelder	412	Torfmoore
221	Weinbauflächen	421	Salzwiesen
222	Obst- und Beerenobstbestände	422	Salinen
223	Olivenhaine	423	In der Gezeitenzone liegende Flächen
231	Wiesen und Weiden	511	Gewässerläufe
241	Mischung einjähriger Früchte mit Dauerkulturen	512	Wasserflächen
242	Komplexe Parzellenstrukturen	521	Lagunen
243	Landwirtschaft mit natürlicher Bodenbedeckung	522	Mündungsgebiet
244	Agroforstlich genutzte Flächen	523	Meere und Ozeane

Abbildung A.3: Die Klassennomenklatur von CORINE LC für die vorherigen CLC Karten und Abbildungen

B

Technische Strukturen

B.1 gnosis

Steuerdatei


```
<?xml version = '1.0'?>
<Training>
  <METADATA>
    <BANDS>[1, 2, 3, 4, 5, 7]</BANDS>
    <DATABASE>Image2000</DATABASE>
    <SERVER>pumpkin</SERVER>
    <DATE>23.05.2005</DATE>
    <CREATOR>Thilo Wehrmann</CREATOR>
    <DESCRIPTION>Versuch, die Grundklassen zu klassifizieren</DESCRIPTION>
  </METADATA>
  <LC_CLASS INHERITED="-1" >
    <CLASSNAME>0</CLASSNAME>
    <DESCRIPTION>Waterbodies</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC1" Quantum="500" >5</CLC_CLASS>
    <OPTIMIZE>no</OPTIMIZE>
  </LC_CLASS>
  <LC_CLASS INHERITED="-1" >
    <CLASSNAME>1</CLASSNAME>
    <DESCRIPTION>Settlement</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC3" Quantum="1500" >111</CLC_CLASS>
    <OPTIMIZE>no</OPTIMIZE>
  </LC_CLASS>
  <LC_CLASS INHERITED="-1" >
    <CLASSNAME>2</CLASSNAME>
    <DESCRIPTION>Forests</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC3" Quantum="500" >311</CLC_CLASS>
  </LC_CLASS>
</Training>
```

```

    <OPTIMIZE>no</OPTIMIZE>
    <CLC_CLASS Type="CLC3" Quantum="500" >313</CLC_CLASS>
</LC_CLASS>
<LC_CLASS INHERITED="- 1" >
    <CLASSNAME>3</CLASSNAME>
    <DESCRIPTION>Grassland</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC2" Quantum="500" >23</CLC_CLASS>
    <OPTIMIZE>no</OPTIMIZE>
    <CLC_CLASS Type="CLC4" Quantum="500" >2111</CLC_CLASS>
</LC_CLASS>
<LC_CLASS INHERITED="- 1" >
    <CLASSNAME>4</CLASSNAME>
    <DESCRIPTION>Barren</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC2" Quantum="500" >13</CLC_CLASS>
    <OPTIMIZE>no</OPTIMIZE>
    <CLC_CLASS Type="CLC4" Quantum="500" >2112</CLC_CLASS>
    <CLC_CLASS Type="CLC2" Quantum="500" >33</CLC_CLASS>
</LC_CLASS>
<LC_CLASS INHERITED="- 1" >
    <CLASSNAME>5</CLASSNAME>
    <DESCRIPTION>Needle Forests</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <OPTIMIZE>no</OPTIMIZE>
    <CLC_CLASS Type="CLC3" Quantum="500" >312</CLC_CLASS>
</LC_CLASS>
<LC_CLASS INHERITED="1" >
    <CLASSNAME>11</CLASSNAME>
    <DESCRIPTION>Settlement</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC2" Quantum="5000" >11</CLC_CLASS>
    <OPTIMIZE>no</OPTIMIZE>
</LC_CLASS>
<LC_CLASS INHERITED="1" >
    <CLASSNAME>12</CLASSNAME>
    <DESCRIPTION>Barren</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC4" Quantum="5000" >2112</CLC_CLASS>
    <OPTIMIZE>no</OPTIMIZE>
    <CLC_CLASS Type="CLC3" Quantum="600" >131</CLC_CLASS>
</LC_CLASS>
<LC_CLASS INHERITED="1" >
    <CLASSNAME>13</CLASSNAME>
    <DESCRIPTION>Industry</DESCRIPTION>
    <ORIGIN>random</ORIGIN>
    <CLC_CLASS Type="CLC3" Quantum="5000" >121</CLC_CLASS>
    <OPTIMIZE>no</OPTIMIZE>
</LC_CLASS>
<LC_CLASS INHERITED="3" >
    <CLASSNAME>31</CLASSNAME>
    <DESCRIPTION>Grassland1</DESCRIPTION>

```

```
<ORIGIN>random</ORIGIN>
<CLC_CLASS Type="CLC2" Quantum="500" >23</CLC_CLASS>
<OPTIMIZE>no</OPTIMIZE>
<CLC_CLASS Type="CLC4" Quantum="500" >2111</CLC_CLASS>
</LC_CLASS>
<LC_CLASS INHERITED="3" >
  <CLASSNAME>32</CLASSNAME>
  <DESCRIPTION>Grassland2</DESCRIPTION>
  <ORIGIN>random</ORIGIN>
  <CLC_CLASS Type="CLC2" Quantum="500" >22</CLC_CLASS>
  <OPTIMIZE>no</OPTIMIZE>
</LC_CLASS>
</Training>
```

Tabellen

C.1 Datenspezifischer Teil

Tabelle C.1: Übersicht der verwendeten Trainingsgebiete für die überwachte Klassifikation. Einige CLC Klassen wurden nur in der zweiten Hierarchiestufe berücksichtigt, da eine spektrale Trennbarkeit nicht mehr erzielt werden konnte. Die CLC Klasse 211 wurde auf Basis des Vegetationsbestandes weiter unterteilt. Die angegebene Anzahl richtet sich nach den Trainingsgebieten. Die Fläche ist in m² angegeben.

CLC1	CLC2	CLC3	CLC4	Anzahl	Fläche	Anteil	Summe	
1xx	11x	111		172	13.902.500	5,72		
		112		186	17.937.500	7,38		
	12x			180	14.497.500	5,97		
			121		15	1.460.625	0,60	
		13x			131	9.003.125	3,71	
	14x		131		15	1.254.375	0,52	
					145	10.430.000	4,29	
		141		8	328.125	0,14	28,32	
2xx	21x	211	2111	170	15.554.375	6,40		
		211	2112	173	14.489.375	5,96		
	22x	221		40	2.927.500	1,20		
		222		57	3.694.375	1,52		
	23x			151	12.183.125	5,01		
			231		30	1.667.500	0,69	
		24x	242		102	9.451.875	3,89	
		243		37	2.015.625	0,83	25,51	
3xx	31x	311		181	11.788.750	4,85		
		312		199	19.295.000	7,94		
		313		164	14.100.000	5,80		
	32x			114	8.311.250	3,42		
			321		45	3.260.625	1,34	
			322		13	1.129.375	0,46	
			324		5	315.625	0,13	
	33x			13	977.500	0,40		
			331		43	4.896.875	2,02	
			333		16	1.102.500	0,45	26,82
4xx	41x			36	2.752.500	1,13		
		411		57	3.552.500	1,46		
	42x		412		56	5.398.125	2,22	
					10	832.500	0,34	
			421		18	1.357.500	0,56	
			423		8	638.125	0,26	5,98
5xx	51x	511		120	6.088.750	2,51		
		512		163	18.036.250	7,42		
	52x	520		14	1.195.625	0,49		
		522		26	4.000.625	1,65		
		523		15	3.151.250	1,30	13,36	
Summe				2928	242.978.750			

Tabelle C.2: Das Regelwerk in gnosis beinhaltet die folgenden Regeln. Dabei fließen folgende Merkmale in den Klassifikationsprozess: *a-priori* Klassifikation (CLC90), temporale Merkmale, Reflexionscharakteristik, unscharfe Farbmerkmale (fuzzy) und die Landbedeckung (LC).

Merkm ^{al}	Bedingung	CLC	Faktor	Merkm ^{al}	Bedingung	CLC	Faktor
CLC90	*	xxx	3	temp_int	< 0,5	11x	2
temp_int	< 0,5	12x	2	temp_int	< 0,5	13x	2
temp_int	< 0,5	31x	2	temp_int	< 0,5	5xx	1
temp_int	< 0	11x	2	temp_int	< 0	12x	2
temp_int	< 0	13x	2	temp_int	< 0	5xx	1
temp_int	> 0	231	1	temp_int	> 0	3xx	2
temp_int	> 0	211	2	temp_int	> 0.9	231	4
temp_var	> 2	211	2	temp_var	> 2	1xx	-2
temp_var	> 2	231	-2	temp_var	> 2	3xx	-2
temp_var	> 2	5xx	-2	temp_var	> 1	211	4
refl	> 75	12x	4	fuzzy	Water > NoWater	5xx	2
fuzzy	dichte Veg.	31x	2	fuzzy	dichte Veg.	21x	2
fuzzy	dichte Veg.	32x	2	fuzzy	dichte Veg.	231	2
fuzzy	lose Veg.	112	2	fuzzy	lose Veg.	142	2
fuzzy	keine Veg.	111	2	fuzzy	keine Veg.	5xx	2
LC	Wasser	5xx	4	LC	Wasser	123	1
LC	Laubwald	31x	1	LC	Laubwald	311	2
LC	Laubwald	141	2	LC	Nadelwald	31x	1
LC	Nadelwald	312	4	LC	Nadelwald	313	2
LC	Boden	211	2	LC	Boden	33x	2
LC	Boden	12x	2	LC	Siedlung	11x	4
LC	Siedlung	12x	4	LC	Siedlung	13x	4
LC	Vegetation 1	211	1	LC	Vegetation 1	231	2
LC	Vegetation 2	211	1	LC	Vegetation 2	231	2

Tabelle C.3: Der Flächenanteil der CLC Klassen definiert in dieser Arbeit die Relevanz für die Erstellung und Implementierung von Merkmalen bzw. der benötigten Regeln. In der Tabelle wurden die CLC Klassen 523 (offenes Meer) und 999 (restliche Flächen) in der Statistik nicht berücksichtigt. Die Fläche ist in Quadratkilometern angegeben. Der Anteil ist zuerst einzeln, dann akkumuliert gerechnet.

Nr.	Klasse	Fläche	Anteil		Klassenbeschreibung
1.	211	137284,88	37,65	37,65	Nicht bewässertes Ackerland
2.	312	56834,68	15,59	53,24	Nadelwälder
3.	231	45720,54	12,54	65,78	Wiesen und Weiden
4.	311	24188,43	6,63	72,41	Laubwälder
5.	313	23847,26	6,54	78,95	Mischwälder
6.	112	22312,07	6,12	85,07	Nicht durchgängig städtische Prägung
7.	242	20785,91	5,70	90,77	Komplexe Parzellenstruktur
8.	243	8803,48	2,41	93,19	Landwirtschaftlich genutztes Land mit Flächen natürlicher Vegetation von signifikanter Größe
9.	512	3358,79	0,92	94,11	Wasserflächen
10.	121	3085,14	0,85	94,96	Industrie/Gewerbeflächen
11.	423	2878,24	0,79	95,75	In der Gezeitenzone liegende Flächen
12.	324	2176,53	0,60	96,34	Wald/Strauch Übergangsstadien
13.	321	1806,29	0,50	96,84	Natürliches Grünland
14.	221	1299,18	0,36	97,19	Weinbauflächen
15.	222	1232,57	0,34	97,53	Obst/Beerenobstbestände
16.	521	1128,67	0,31	97,84	Lagunen
17.	131	1058,23	0,29	98,13	Abbauflächen
18.	142	971,56	0,27	98,40	Sport/Freizeitanlagen
19.	412	898,54	0,25	98,65	Torfmoore
20.	511	832,05	0,23	98,87	Gewässerläufe
21.	322	578,84	0,16	99,03	Heiden und Moorheiden
22.	333	504,55	0,14	99,17	Flächen mit spärlicher Vegetation
23.	411	503,82	0,14	99,31	Sümpfe
24.	124	473,99	0,13	99,44	Flughäfen
25.	141	428,10	0,12	99,56	Städtische Grünflächen
26.	522	275,27	0,08	99,63	Mündungsgebiete
27.	111	232,45	0,06	99,70	Durchgängig städtische Prägung
28.	332	214,47	0,06	99,75	Felsflächen ohne Vegetation
29.	421	180,12	0,05	99,80	Salzwiesen
30.	132	178,88	0,05	99,85	Deponien, Abraumhalden
31.	122	175,66	0,05	99,90	Straßen/Eisenbahnnetze, funktionell zugeordnete Flächen
32.	331	160,76	0,04	99,95	Strände, Dünen, Sandflächen
33.	123	124,85	0,03	99,98	Hafengebiete
34.	133	75,38	0,02	99,99	Baustellen
35.	335	0,30	0,00	100,00	Gletscher/Dauerschneegebiet

Tabelle C.4: Die Klassifikation von CORINE Klassen aus der Trainingsdatenbank ergibt folgende Wahrheitsmatrix (*Confusion matrix*) für die Steuerdatei `fine_class_with_wine.xml`. Wichtige Werte zur Kodierung der CLC Klassen durch Basislandbedeckungsklassen sind **hervorgehoben**. Die Tabelle wird für die spektrale Analyse der einzelnen CLC Klassen verwendet, um spektral beschreibbare Klasse, wie z.B. die Siedlungs- und Waldklassen zu bestimmen.

CLC	Wasser	Siedlung	Laubwald	Niedrige Vegetation	offener Boden	Nadelwald	Siedlung	Boden	Industriegebiete	Vegetation I	Vegetation II
	0	1	2	3	4	5	11	12	13	31	32
111	0,00	0,97	0,00	0,01	0,02	0,00	0,87	0,01	0,09	0,00	0,01
112	0,00	0,61	0,00	0,14	0,21	0,03	0,56	0,00	0,05	0,02	0,13
121	0,00	0,69	0,00	0,00	0,30	0,00	0,10	0,00	0,59	0,00	0,00
131	0,00	0,06	0,00	0,00	0,94	0,00	0,04	0,00	0,02	0,00	0,00
211	0,00	0,07	0,00	0,03	0,89	0,00	0,03	0,03	0,01	0,02	0,01
221	0,00	0,01	0,00	0,43	0,57	0,00	0,00	0,00	0,00	0,05	0,37
231	0,00	0,01	0,00	0,95	0,05	0,00	0,00	0,00	0,00	0,80	0,15
311	0,00	0,00	0,97	0,03	0,00	0,00	0,00	0,00	0,00	0,03	0,00
312	0,00	0,00	0,05	0,00	0,00	0,95	0,00	0,00	0,00	0,00	0,00
313	0,00	0,00	0,72	0,02	0,01	0,25	0,00	0,00	0,00	0,01	0,00
321	0,00	0,04	0,06	0,45	0,44	0,01	0,04	0,00	0,00	0,27	0,18
322	0,00	0,02	0,03	0,00	0,86	0,08	0,02	0,00	0,00	0,00	0,00
511	0,99	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
512	0,99	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00
522	1,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
523	1,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Tabelle C.5: Fehlermatrize für den Untersuchungsraum *Frankfurt am Main* – nicht auftretende Kombinationen sind durch das Symbol \circ abgekürzt und stehen für die Zahl 0.

	111	112	121	122	123	124	131	132	133	141	142	211	221	222	231	242	243	311	312	313	321	324	333	411	511	512	Σ	
111	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	
112	\circ	377	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	377	
121	\circ	3	106	\circ	\circ	\circ	1	2	\circ	2	2	4	\circ	1	\circ	\circ	\circ	\circ	\circ	1	\circ	1	\circ	\circ	\circ	\circ	1	124
122	\circ	\circ	\circ	8	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	8	
123	\circ	\circ	\circ	\circ	3	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	3	
124	\circ	\circ	\circ	\circ	\circ	3	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	3	
131	\circ	\circ	1	\circ	\circ	\circ	26	\circ	\circ	3	2	\circ	1	1	\circ	2	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	37
132	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0	
133	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0	
141	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0	
142	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0	
211	\circ	118	15	\circ	\circ	3	7	2	1	7	20	457	23	53	282	316	85	38	39	135	11	13	\circ	4	\circ	\circ	1629	
221	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0	
222	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0	
231	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	1	50	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	55
242	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	8	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	8	
243	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	
311	\circ	5	\circ	\circ	\circ	\circ	\circ	\circ	\circ	3	2	\circ	\circ	2	34	17	37	423	1	2	6	8	\circ	\circ	\circ	\circ	540	
312	\circ	2	\circ	\circ	\circ	\circ	1	\circ	\circ	2	\circ	\circ	\circ	\circ	\circ	\circ	\circ	5	1	320	\circ	\circ	2	\circ	\circ	2	335	
313	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	2	\circ	4	1	\circ	9	2	\circ	\circ	343	\circ	\circ	\circ	\circ	\circ	\circ	361	
321	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	5	\circ	\circ	\circ	5		
324	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	4	\circ	\circ	5		
333	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	2	\circ	\circ	2		
411	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0	
511	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	9	9	
512	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	18	18	
Σ	1	507	122	8	3	6	35	4	1	17	31	461	29	59	366	356	130	462	360	484	22	27	3	4	9	23	3535	

Tabelle C.6: Fehlermatrize für den Untersuchungsraum *Berlin* – nicht auftretende Kombinationen sind durch das Symbol \circ abgekürzt und stehen für die Zahl 0.

	111	112	121	122	123	124	131	132	133	141	142	211	222	231	242	243	311	312	313	321	322	324	333	411	511	512	\sum
111	14	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	14
112	\circ	111	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	112
121	\circ	3	89	\circ	\circ	\circ	2	\circ	\circ	2	30	1	\circ	8	\circ	2	\circ	\circ	\circ	3	\circ	1	\circ	\circ	\circ	\circ	141
122	\circ	\circ	\circ	12	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	12
123	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
124	\circ	\circ	\circ	\circ	\circ	9	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	10
131	\circ	\circ	\circ	\circ	\circ	\circ	8	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	10
132	\circ	\circ	\circ	\circ	\circ	\circ	\circ	5	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	6
133	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
141	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	9	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	9
142	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	6	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	6
211	\circ	142	10	\circ	\circ	\circ	3	3	1	\circ	9	203	5	115	4	31	3	11	4	6	\circ	\circ	1	5	\circ	3	559
222	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0
231	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	4	\circ	55	\circ	\circ	\circ	1	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	62
242	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
243	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	22	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	22
311	\circ	2	\circ	\circ	\circ	\circ	1	\circ	\circ	2	\circ	5	\circ	29	2	21	240	1	3	\circ	\circ	1	\circ	10	\circ	1	318
312	\circ	8	\circ	\circ	\circ	\circ	4	\circ	\circ	19	9	\circ	\circ	1	\circ	8	\circ	246	1	\circ	\circ	6	\circ	4	\circ	2	308
313	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	133	\circ	\circ	\circ	\circ	\circ	\circ	1	134
321	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	1	9	\circ	3	\circ	\circ	\circ	15	
322	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	2	\circ	\circ	\circ	\circ	3	
324	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	2	
333	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	1	
411	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	2	\circ	3
511	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	2	\circ	2
512	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	109	110
\sum	14	268	100	12	1	9	18	8	1	32	54	214	5	211	6	84	245	261	143	19	2	14	2	23	2	117	1865

Tabelle C.7: Fehlermatrize für den Untersuchungsraum *Oldenburg* – nicht auftretende Kombinationen sind durch das Symbol \circ abgekürzt und stehen für die Zahl 0.

	112	121	124	131	132	141	142	211	231	242	243	311	312	313	321	322	324	331	333	411	412	421	423	511	512	\sum	
112	46	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	46
121	\circ	6	\circ	\circ	\circ	\circ	\circ	2	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	1	2	\circ	1	13	
124	\circ	\circ	2	\circ	\circ	\circ	\circ	\circ	\circ	\circ	2	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	4
131	\circ	\circ	\circ	3	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	3
132	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
141	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
142	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0
211	3	\circ	\circ	\circ	\circ	\circ	2	64	11	25	10	2	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	4	2	1	\circ	1	126
231	1	1	\circ	\circ	\circ	\circ	\circ	\circ	39	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	42
242	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	15	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	15
243	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	8	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	8
311	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	19	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	21
312	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	3	44	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	48
313	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	27	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	27
321	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
322	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	3	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	3
324	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
331	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
333	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1
411	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	3	\circ	\circ	\circ	\circ	\circ	\circ	3
412	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	5	\circ	\circ	\circ	\circ	\circ	5
421	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	\circ	\circ	\circ	1
423	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	0
511	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	1	\circ	1
512	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	\circ	9	9
\sum	50	7	2	3	1	1	3	66	50	40	24	21	44	28	1	3	1	1	1	3	11	4	3	1	12	381	

Tabelle C.8: Eine kurze Zusammenfassung der CLC Objekte aus dem CLC 2000 Datensatz für die Gesamtzahl der Objekte, der prozentuale Anteil der jeweiligen Klasse und die Anzahl der Änderungsobjekte seit 1990

CLC	Gesamt	Anteil	Änderungen	CLC	Gesamt	Anteil	Änderungen
		(%)	90→00			(%)	90→00
111	313	0.2	1	311	15577	9	404
112	28679	16	6660	312	20288	11	1255
121	5749	3	2336	313	17554	10	593
122	334	0.2	20	321	1383	0.8	153
123	141	0.08	12	322	433	0.2	8
124	302	0.2	43	324	2708	2	1413
131	1917	1	919	331	153	0.09	65
132	364	0.2	100	332	68	0.04	–
133	255	0.1	246	333	447	0.2	110
141	637	0.4	15	335	1	<0.001	–
142	1902	1	394	411	689	0.4	32
211	22537	1.3	2827	412	611	0.3	23
221	733	0.4	16	421	112	0.06	25
222	1248	0.7	81	423	469	0.3	181
231	24534	1.4	3643	511	208	0.1	19
242	15486	9	1168	512	2812	2	546
243	10686	6	138	521	36	0.02	–
				522	18	0.01	6
				523	181	0.1	99

Curriculum Vitae

Thilo Wehrmann

Persönliche Daten

Geburtstag 10. November 1974

Geburtsort Aschaffenburg

Nationalität Deutsch

Adresse Leienfelsstrasse 37
81243 München, Deutschland

email thilo.wehrmann@dlr.de, wehrmann@veyond.de

Telefon +49 89 97344197, +49 172 6711641

Ausbildung

1985-1994 Gymnasium: Franziskaner Gymnasium Kreuzburg, Groß-Krotzenburg

Abschluss: Abitur

03/95 – 08/95 Johann Wolfgang Goethe-Universität, Frankfurt

Studium der Geophysik

08/05 – 07/03 Julius-Maximilians-Universität, Würzburg

Studium der Geographie

Nebenfächer Botanik und Geologie

Titel der Diplomarbeit:

GIS-gestütztes Informationsmanagement am Beispiel eines bayerischen Landratsamtes

Abschluss: Diplom

07/03 – 12/05 Dissertation am Lehrstuhl für Fernerkundung, Geographisches Institut in Würzburg:

Automatisierte Klassifikation von Landnutzung durch Objekterkennung am Beispiel von CORINE Land Cover

Veröffentlichungen

- 2004 **Wehrmann, T. (2004)**: Development and evaluation of methods for automated landuse / land-cover classification (CORINE). In: Federal Environmental Agency (Ed.): Proceedings CORINE Land Cover 2000 Workshop, 20–21 January 2004, Berlin, Texte 04/04, ISSN 0722-186X, S. 270-274.
- Wehrmann, T., Glaser, R., Dech, S. (2004)**: An automated object-based classification approach for updating CORINE LandCover data. In: Proceedings of SPIE Remote Sensing Europe, 13-16 September, Masplomas.
- 2005 **Wehrmann, T., Colditz, R.R., Bachmann, M., Steinnocher, K. and Dech, S.W. (2005)**: Evaluation of image fusion techniques. In: Erasmí, S., Cyffka, B., Kappas, M. (Eds), Remote Sensing and GIS for Environmental Studies. Göttinger GIS and Remote Sensing Days (GGRS 2004), October 7th - 8th 2004, Göttingen, Deutschland, Göttinger Geographische Abhandlungen, 113: 296-302.
- Colditz, R.R., Wehrmann, T., Bachmann, M., Steinnocher, K., Schmidt, M., Strunz, G., Dech, S. (2005)**: Influence of Image Fusion Approaches on Classification Accuracy — A Case Study. International Journal of Remote Sensing, 27: 3311–3335
- 2006 **Colditz, R.R., Conrad, C., Wehrmann, T., Schmidt, M., Dech, S. (2006)**: Generation and assessment of MODIS time series using quality information. In: IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2006, 31. Juli – 4. August 2006, Denver, CO, 6 Seiten

Sonstiges

Sprachen:

sehr gute Kenntnisse der englischen Sprache
Grundkenntnisse der spanischen Sprache

EDV-Kenntnisse:

Bildverarbeitung: eCognition, ERDAS Imagine, Envi
GIS: ArcGIS, ArcInfo, Geomedia
Programmiersprachen: Python, IDL, Java
Administration: Windows und Linux

Hobbys: Musik, Aquarellmalerei, Bücher