



Universität Augsburg
Fakultät für Angewandte Informatik
Institut für Geographie

Landbedeckungs- / Landnutzungsklassifizierung von Deutschland auf der Grundlage von Daten des Sensors MERIS

Diplomarbeit im Fach Geographie

vorgelegt von Ursula Geßner

Augsburg im Januar 2005

Gutachter:
Prof. Dr. Arne Friedmann
PD Dr. Karl-Friedrich Wetzel

angefertigt am Deutschen Zentrum für Luft- und Raumfahrt (DLR)



Selbständigkeitserklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit selbständig und nur unter Verwendung der angegebenen Literatur und Hilfsmittel angefertigt habe.

Augsburg im Januar 2005

(Ursula Geßner)

Danksagung

Herrn Prof. Dr. Arne Friedmann und Herrn PD Dr. Karl-Friedrich Wetzel danke ich dafür, dass sie mir diese Diplomarbeit durch ihre Betreuung und ihr Interesse ermöglicht haben.

Weiterhin danke ich Herrn PD Dr. Michael Bittner, durch dessen Unterstützung und Förderung diese Arbeit in der Abteilung Klima- und Atmosphärenprodukte des DFD entstehen konnte.

Mein ganz besonderer Dank gilt Herrn Dr. Kurt Günther, der mir stets motivierend zur Seite stand und durch seine intensive fachliche Betreuung zum Gelingen dieser Arbeit beitrug.

Darüber hinaus möchte ich mich bei allen hier nicht namentlich genannten Personen bedanken, die mir beim Zustandekommen dieser Diplomarbeit geholfen haben.

Abstract

Within the MERIS Applications and Regional Products Project (MAPP), an operational algorithm was developed for calculating a map of land cover / land use of Germany, based on MERIS full resolution data. This algorithm is composed of a multispectral maximum-likelihood-classification and a multitemporal analysis. By building a multispectral database and multitemporal reference vectors, the classification can be updated automatically every year.

Within the scope of this thesis, an appropriate classification system (GLC 2000) and an applicable reference data set for validation (CORINE 2000) are proposed. Furthermore, the spectral signatures of the eight considered land cover / land use classes are analysed. In this context, the occurrence of BRDF-effects in MERIS data is studied. Additional investigations concentrate on how the phenology of all considered classes is expressed in MERIS data and how this information should be taken into account in the multitemporal analysis. On that basis, recommendations for minimising the computing time by channel reduction and for improving cloud identification are made. The results of the preparation of the MAPP classification are verified by means of a monotemporal classification with the image analysis software ENVI 4.0. The resulting land cover / land use map for the beginning of August shows good agreement with the reference data set, concerning both coarse and detailed structures. The overall accuracy of the monotemporal classification result is 57.3 %.

Kurzfassung

Im Rahmen des MERIS Applications and Regional Products Project (MAPP) steht ein Prozessor zur Verfügung, der die Erstellung einer jährlich aktualisierbaren Landbedeckungs- / Landnutzungskarte von Deutschland auf Grundlage von Daten des Sensors MERIS ermöglicht. Der Klassifizierungsalgorithmus setzt sich aus einer multispektralen Maximum-Likelihood-Klassifizierung und einem anschließenden multitemporalen Rechenschritt zusammen. Nach einer einmaligen Vorbereitungsphase, die den Aufbau einer multispektralen Datenbank und die Definition von multitemporalen Referenzvektoren umfasst, kann die MAPP-Klassifizierung jedes Jahr automatisch durchgeführt werden.

Im Rahmen dieser Arbeit werden ein geeignetes Klassifikationssystem (GLC 2000) sowie ein Referenzdatensatz (CORINE 2000) zur Validierung der Ergebnisse ausgewählt. Anhand von Trainingsgebieten findet eine Analyse der spektralen Signaturen von acht in Betracht gezogenen Landbedeckungs- / Landnutzungsklassen statt. Hierbei werden die in MERIS-Daten auftretenden BRDF-Effekte untersucht. Zudem wird analysiert, wie die Phänologie aller berücksichtigten Klassen in den spektralen Signaturen der MERIS-Daten zum Ausdruck kommt und auf welche Weise diese im multispektralen Klassifizierungsschritt berücksichtigt werden muss. Es folgen Vorschläge zur Verkürzung der Rechenzeit mittels Kanalreduktion und zur Verbesserung der Wolkenerkennung. Die Resultate der Klassifizierungsvorbereitungen werden anhand einer monotemporalen Klassifizierung mit Hilfe des Bildverarbeitungssystems ENVI 4.0 überprüft. Das Ergebnis der Datenauswertung für das erste Augustdrittel zeigt gute Übereinstimmung mit der Referenz, sowohl für großräumige als auch für detaillierte Strukturen. Die Gesamtgenauigkeit des monotemporalen Klassifizierungsergebnisses beträgt 57,3 %.

Inhaltsverzeichnis

Abbildungsverzeichnis.....	4
Tabellenverzeichnis	6
Abkürzungsverzeichnis.....	7
1 Einführung	8
2 Grundlagen.....	11
2.1 Landbedeckung und Landnutzung.....	11
2.1.1 Begriffsklärung	11
2.1.2 Bedeutung von Landbedeckungs- und Landnutzungsinformationen	12
2.2 Die Informationsquellen Satellitenbild und thematische Karte im Vergleich	13
2.3 Optische, multispektrale Fernerkundungsdaten	14
2.3.1 Radiometrische Eigenschaften	15
2.3.2 Einflussfaktoren auf radiometrische Eigenschaften	15
2.3.2.1 Spektrale Zusammensetzung der Reflexion von Objekten der Landoberfläche	15
2.3.2.2 Bidirektionale Reflexionsverteilung von Objekten der Landoberfläche	17
2.3.2.3 Atmosphärische Einflüsse.....	18
2.3.3 Geometrische Eigenschaften	20
2.4 Landbedeckungs- /Landnutzungsklassifizierungen.....	22
2.4.1 Klassifikationssysteme.....	22
2.4.2 Erhebung von Landbedeckungsdaten im Feld und mit Methoden der Fernerkundung.....	28
2.4.3 Methoden zur Klassifizierung multispektraler Fernerkundungsdaten	28
2.4.3.1 Visuelle Interpretationen.....	29
2.4.3.2 Digitale, multispektrale Klassifizierungsverfahren	29
2.4.3.3 Multitemporale Analyse	31
2.4.4 Verifizierungsmethoden	31
2.5 Forschungsstand	33
2.5.1 Globale und europäische Landbedeckungs- und Landnutzungskarten aus Fernerkundungsdaten	33
2.5.2 Landbedeckungsklassifizierungen mit MERIS-Daten.....	36

3	Die MAPP-Landbedeckungs- / Landnutzungs-klassifizierung	37
3.1	Das Projekt MAPP	37
3.2	Arbeitsgrundlagen	38
3.2.1	Der europäische Umweltsatellit ENVISAT	38
3.2.2	Das Medium Resolution Imaging Spectrometer MERIS	39
3.2.3	Datengrundlage	41
3.3	Der MERIS-VA-LCC-Prozessor	43
3.3.1	Der multispektrale Klassifizierungsschritt	44
3.3.2	Der multitemporale Klassifizierungsschritt	45
4	Klassifizierungsvorbereitung für den MAPP-VA-LCC-Prozessor	48
4.1	Auswahl eines Klassifikationsschlüssels	48
4.2	Erstellen der Legende	49
4.3	Referenzdaten	50
4.3.1	Auswahl eines Referenzdatensatzes	50
4.3.2	Anpassung der Referenz an die MAPP-LCC	53
4.4	Auswahl von Trainingsgebieten	53
4.5	Analyse der spektralen Signaturen der Trainingsgebiete	55
4.5.1	Untersuchung der BRDF-Effekte	55
4.5.2	Definition der zu berücksichtigenden Farbklassen	63
4.5.3	Definition von Referenzvektoren	66
4.5.4	Kanalauswahl	67
4.6	Alternative Möglichkeiten der Wolkenerkennung	68
4.7	Untersuchung der Georeferenzierung	70
5	Multispektrale Testklassifizierung mit ENVI	72
5.1	Auswahl des Klassifikationszeitraumes	72
5.2	Auswahl der zu berücksichtigenden Klassen	72
5.3	Vorbereitung der MERIS-Daten	74
5.3.1	Umwandlung in ein geeignetes Datenformat	74
5.3.2	Wolken- und Wassermaskierung	74
5.4	Maximum-Likelihood-Klassifizierung	75

5.5	Fertigstellung der Karte und Validierung	77
5.6	Ergebnisse der Klassifizierung mit ENVI.....	78
5.6.1	Ergebniskarte	78
5.6.2	Validierungsergebnisse	82
5.6.2.1	Gesamtvergleich.....	82
5.6.2.2	Detailvergleich	85
5.6.3	Klassifizierungsergebnisse mit Kanalreduktion.....	88
5.6.4	Diskussion der Klassifizierungsergebnisse	90
6	Zusammenfassung und Ausblick.....	92
	Literaturverzeichnis	96
	Internetquellen.....	100
	Sonstige Quellen.....	101
	Anhang A Spektrale Signaturen.....	102
	Anhang B Korrelationsmatrizen.....	111

Abbildungsverzeichnis

Abbildung 2.1:	Geometrischer Zusammenhang zwischen der Einfallrichtung der Sonnenstrahlung und der Beobachtungsrichtung.....	14
Abbildung 2.2:	Reflexionsspektren unterschiedlicher Landbedeckungsarten.....	16
Abbildung 2.3:	Spezifischer Absorptionskoeffizient von Chlorophyll a und b	17
Abbildung 2.4:	Reflexion an unterschiedlichen Oberflächen.....	17
Abbildung 2.5:	Bidirektionale Reflexionsverteilung eines immergrünen Nadelwaldes.....	18
Abbildung 2.6:	Transmission der Atmosphäre.....	19
Abbildung 2.7:	Strahlungsverhältnisse bei Aufnahme.....	19
Abbildung 2.8:	Auswirkungen von Fehlern in Plattformposition und -lage.....	21
Abbildung 3.1:	Typische Lage der MERIS-Pässe über Europa.....	38
Abbildung 3.2:	Der europäische Umweltsatellit ENVISAT mit seinen Instrumenten.....	39
Abbildung 3.3:	Aufbau des Sensors MERIS aus 5 Kameras	40
Abbildung 3.4:	Aufbau eines MERIS-Detektors	41
Abbildung 3.5:	Klassifizierungsablauf der MAPP-LCC.....	43
Abbildung 3.6:	Vergleich von Pixel- und Referenzvektoren.....	47
Abbildung 4.1:	Veränderung der Reflexionsgrade einer Graslandfläche bei $\varphi_{rel} \approx 54^\circ$	56
Abbildung 4.2:	Veränderung der Reflexionsgrade einer Graslandfläche bei $\varphi_{rel} \approx 120^\circ$	56
Abbildung 4.3:	Typische Lage von vier MERIS-Szenen.....	57
Abbildung 4.4:	Spektrale Signaturen von Nadelwaldflächen.....	58
Abbildung 4.5:	Spektrale Signaturen von Grasflächen.....	60

Abbildung 4.6:	Reflexionsgrade eines Nadelwaldes von POLDER und DISMA.....	61
Abbildung 4.7:	Spektrale Signaturen einer vegetationslosen Tagebaufläche bei variierendem Sonnenstand	62
Abbildung 4.8:	Wolkenidentifizierung mit Hilfe einer Maximum-Likelihood- Klassifizierung	69
Abbildung 4.9:	Der Tharandter Wald bei Dresden in drei MERIS-L 2-FR-Szenen mit unterschiedlicher Georeferenzierungsqualität	70
Abbildung 5.1:	Bei der Klassifizierung vorgegebene Mustersignaturen.....	75
Abbildung 5.2:	Bei der Klassifizierung vorgegebene Mustersignaturen mit Standardabweichungen.....	77
Abbildung 5.3:	Ergebnis der monotemporalen Landbedeckungs- / Landnutzungsklassifizierung in ENVI	79
Abbildung 5.4:	Referenzdatensatz CORINE Land Cover 2000	80
Abbildung 5.5:	Differenzbild des Vergleiches zwischen dem Klassifizierungsergebnis und dem CORINE-Referenzdatensatz.....	81
Abbildung 5.6:	Detailvergleich von Klassifizierungsergebnis und Referenzdatensatz.	86
Abbildung 5.7:	Klassifizierungsergebnisse bei Berücksichtigung unterschiedlicher Kanäle.....	89

Tabellenverzeichnis

Tabelle 2.1:	Die oberste Hierarchiestufe des USGS-Klassifikationssystems.....	23
Tabelle 2.2:	Das IGBP-Landbedeckungs-Klassifikationssystem.....	23
Tabelle 2.3:	Das Klassifikationssystem der CORINE Land Cover.....	24
Tabelle 2.4:	Auswahl wichtiger Classifier des LCCS	26
Tabelle 2.5:	Klassifikationsschlüssel der GLC 2000 mit LCCS-Formeln	27
Tabelle 2.6:	Beispiel einer Konfusionsmatrix für drei Klassen.....	32
Tabelle 3.1:	Die derzeit festgelegten Spektralkanäle des Sensors MERIS	40
Tabelle 4.1:	Die für die MAPP-LCC in Betracht gezogenen Klassen der GLC 2000	51
Tabelle 4.2:	Übersetzung der CORINE Land Cover-Klassen in die GLC 2000	52
Tabelle 4.4:	Vorschlag zur Untergliederung der spektralen Datenbank der MAPP-LCC	63
Tabelle 4.5:	Farbklassen für den multispektralen Klassifizierungsschritt	66
Tabelle 4.6:	Referenzvektoren für die multitemporale Analyse.....	67
Tabelle 5.1:	Die in der Testklassifizierung berücksichtigten Farbklassen.....	73
Tabelle 5.2:	Konfusionsmatrix des Gesamtvergleiches.....	82
Tabelle 5.3:	Hersteller- und Benutzergenauigkeiten sowie Gesamtgenauigkeit und Kappa-Koeffizient des Gesamtvergleiches	82
Tabelle 5.4 :	In Folge der Testklassifizierung abgeänderte Referenzvektoren	84
Tabelle 5.5:	Konfusionsmatrix des Detailvergleiches	87
Tabelle 5.6:	Hersteller- und Benutzergenauigkeiten sowie Gesamtgenauigkeit und Kappa-Koeffizient des Detailvergleiches.....	87

Abkürzungsverzeichnis

AVHRR	Advanced Very High Resolution Radiometer
BRDF	Bidirectional Reflectance Distribution Function
CCD	Charge-Coupled Device
CORINE	Coordination of Information on the Environment
DFD	Deutsches Fernerkundungsdatenzentrum
DLR	Deutsches Zentrum für Luft- und Raumfahrt e. V.
ECMWF	European Centre for Medium-Range Weather Forecasts
ESA	European Space Agency
ESOC	European Space Operations Centre
FAO	Food and Agriculture Organization of the United Nations
FR	Full Resolution
GLC 2000	Global Land Cover 2000
GOFC-GOLD	Global Observation of Forest and Land Cover Dynamics
GTOS	Global Terrestrial Observing System
IGBP	International Geosphere Biosphere Programme
JRC	Joint Research Centre
JRC – IES	Joint Research Centre – Institute for Environment and Sustainability
L 1b	Level 1b
L 2	Level 2
LCCS	Land Cover Classification System
MAPP	MERIS Applications and Regional Products Project
MAPP-LCC	MAPP-Land Cover Classification
MERIS	Medium Resolution Imaging Spectrometer
MLCCA	MODIS Land Cover Classification Algorithm
NDVI	Normalised Difference Vegetation Index
NOAA	National Oceanic and Atmospheric Administration
PELCOM	Pan-European Land Cover Monitoring
RGB	Rot-Grün-Blau
ROI	Region Of Interest
TOA	Top Of the Atmosphere
UNEP	United Nations Environment Programme
USGS	United States Geological Survey
VA	Value-Added
WDC-RSAT	World Data Center for Remote Sensing of the Atmosphere
WGS 84	World Geodetic System 1984

1 Einführung

Das Wissen um die Beschaffenheit und die Veränderungen der Landbedeckung ist für viele umweltwissenschaftliche Fragestellungen von entscheidender Bedeutung. Aktuelle Landbedeckungskarten stellen eine wichtige Datengrundlage, beispielsweise für Klimaforschung, Kohlenstoffbilanzierung, Meteorologie und Hydrologie dar (KYUNG-SOO et al. 2004, S. 52). Besonders in dicht besiedelten Räumen wie Europa steht die Landbedeckung zudem in engem Zusammenhang mit der Landnutzung und bestimmt somit die Bedeutung der Landoberfläche für den Menschen (CHILAR 2000, S. 1093). Trotz des hohen Bedarfs an zuverlässigen, aktuellen Informationen zur Landbedeckung, existiert jedoch bisher kein Landbedeckungsdatensatz von Europa, der jährlich mit geringem Arbeitsaufwand aktualisiert werden kann.

Die Kartierung von Landbedeckung und Landnutzung wird heute häufig mit Hilfe von satellitengestützten, optischen Fernerkundungssensoren durchgeführt. Diese Sensoren liefern in regelmäßigen Zeitabständen Informationen über spektrale Eigenschaften der Erdoberfläche, die mittels entsprechender Fachkenntnisse in Informationen zur Landbedeckung beziehungsweise Landnutzung übersetzt werden können. Die Interpretation der Fernerkundungsdaten erfolgt traditionell durch visuelle Bildinterpretation. Seit den siebziger Jahren wurden jedoch zahlreiche rechnergestützte Verfahren entwickelt, mit deren Hilfe Landnutzungsinformationen aus digitalen Fernerkundungsdaten weitaus effizienter abgeleitet werden können.

Gerade für die Erfassung größerer Gebiete bleibt die Interpretation von Fernerkundungsdaten jedoch auch mit rechnergestützten Methoden zeit- und kostenintensiv. Aus diesem Grund wird häufig nicht der gesamte Informationsgehalt von Fernerkundungsdaten in die Untersuchungen einbezogen. So werden teilweise lediglich Aufnahmen eines kurzen Zeitraumes ausgewertet, wobei der phänologische Informationsgehalt der Satellitendaten weitgehend unberücksichtigt bleibt (z.B. KEUCHEL et al. 2003). Andere Klassifizierungsvorhaben basieren zwar auf Daten mehrerer, über das Jahr verteilter Aufnahmezeitpunkte, der genutzte spektrale Informationsgehalt ist hierbei jedoch meist auf einige wenige Spektralkanäle beschränkt (z.B. LOVELAND et al. 2000). Erst seit einigen Jahren werden Versuche unternommen, für großflächige Landbedeckungsklassifizierungen sowohl den multitemporalen als auch den multispektralen Informationsgehalt optischer Fernerkundungssensoren gleichzeitig zu nutzen. Derartige Verfahren werden beispielsweise von SKINNER & LUCKMAN (2003) oder von MÜCHER et al. (2000) beschrieben und führen größtenteils zu guten Erfolgen.

Durch den Einsatz automatisch aktualisierbarer Verfahren können, gerade bei der Erfassung zeitlicher Veränderungen der Landbedeckung, sowohl Kosten- als auch Zeitaufwand deutlich reduziert werden. Aus diesem Grund werden von einigen Seiten Versuche unternommen, Landbedeckungsklassifizierungen zu automatisieren (z.B. MÜCHER et al. 2000 & KEUCHEL et al. 2003). Ein Verfahren der großräumigen Landbedeckungsklassifizierung, in dem der multispektrale Informationsgehalt von

Satellitendaten eines kompletten Jahres automatisiert ausgewertet werden kann, ist bisher jedoch nicht bekannt.

Im Rahmen des Projektes MAPP wurde am Deutschen Fernerkundungsdatenzentrum (DFD) des Deutschen Zentrums für Luft- und Raumfahrt (DLR) der so genannte MAPP-VA-LCC-Prozessor entwickelt. Dieser Prozessor wird, auf der Grundlage von Daten des Sensors MERIS, die Erstellung jährlich aktueller Landbedeckungskarten von Deutschland mit einer räumlichen Auflösung von 300 m ermöglichen. Nach einer erfolgreichen Anwendung des Klassifizierungsverfahrens für Deutschland, ist eine Ausweitung der Methodik auf die Fläche Europas vorgesehen. Die MAPP-Klassifizierung umfasst sowohl einen multispektralen als auch einen multitemporalen Klassifizierungsschritt, in dem alle verfügbaren Aufnahmen eines Jahres analysiert werden. Nach einer einmaligen Vorbereitung des Klassifizierungsverfahrens, wird es möglich sein, den Landbedeckungsdatensatz jedes Jahr automatisch zu erstellen.

Als der Prozessor im Jahr 2001 entwickelt wurde, standen noch keine Daten des Sensors MERIS zu Verfügung. Aus diesem Grund konnte die Vorbereitung des Klassifizierungsverfahrens bisher noch nicht anhand von MERIS-Daten durchgeführt werden. ARNDT (2001) stellte das Klassifizierungsverfahren des MAPP-VA-LCC-Prozessors auf der Basis von Daten des Sensors MOS nach, einem Sensor, der ähnliche spektrale Eigenschaften wie MERIS besitzt.

Seit Mai 2003 stehen dem Deutschen Fernerkundungsdatenzentrum auswertbare MERIS-Daten zur Verfügung. Ziel der vorliegenden Arbeit ist es, auf Basis dieser Daten, vorbereitende Schritte und Untersuchungen für das MAPP-Klassifizierungsverfahren durchzuführen. Hierbei handelt es sich um:

- die Auswahl eines geeigneten Klassifikationsschlüssels und die Erstellung einer Legende
- die Auswahl und Vorbereitung eines Referenzdatensatzes für die Validierung der Klassifizierungsergebnisse
- die Definition geeigneter Trainingsgebiete zur Bestimmung typischer spektraler Signaturen aller Landbedeckungsklassen
- die Untersuchung dieser spektralen Signaturen in Bezug auf BRDF-Effekte
- die Abschätzung von Art und Anzahl der Klassen, die im multispektralen Klassifizierungsschritt unterschieden werden können
- die Untersuchung der typischen Veränderungen von spektralen Signaturen aller berücksichtigten Landbedeckungsklassen im Jahresverlauf
- die Abschätzung einer möglichen Kanalreduktion
- Vorschläge zur Verbesserung von Wolkenerkennung und Georeferenzierung

Zunächst war vorgesehen, die Ergebnisse der oben angeführten Klassifizierungsvorbereitungen in Testläufen des MAPP-VA-LCC-Prozessors zu überprüfen. Da der Prozessor jedoch während der Durchführung der vorliegenden Arbeit keine auswertbaren Klassifizierungsergebnisse liefern konnte, wurde der monotemporale,

multispektrale Klassifizierungsschritt mit Hilfe des Bildverarbeitungssystems ENVI 4.0 nachgestellt und die Untersuchungsergebnisse hierbei überprüft.

Das zweite Kapitel der vorliegenden Arbeit behandelt wichtige Grundlagen der satellitengestützten Landbedeckungs- und Landnutzungskartierung. Zunächst werden die Begriffe Landbedeckung und Landnutzung geklärt, und die Bedeutung der Landbedeckung als Gegenstand wissenschaftlicher Fragestellungen herausgestellt. Anschließend findet ein Vergleich der Informationsquellen Satellitenbild und thematischen Karte statt, gefolgt von der Darstellung grundlegender Eigenschaften optischer, multispektraler Fernerkundungsdaten. Die wichtigsten Methoden der Landbedeckungs- und Landnutzungsklassifizierung sowie deren Vor- und Nachteile werden im folgenden Abschnitt erläutert, und schließlich der aktuelle Forschungsstand zusammengefasst.

Kapitel 3 befasst sich mit der MAPP-Landbedeckungs- / Landnutzungsklassifizierung. Nach einer Beschreibung des Projektes MAPP werden die Arbeitsgrundlagen der Klassifizierung, der Satellit ENVISAT, der Sensor MERIS und die für die Klassifizierung genutzten Daten vorgestellt. Anschließend wird das Klassifizierungsverfahren des MAPP-VA-LCC-Prozessors erläutert.

Das vierte Kapitel befasst sich mit den Vorbereitungen für den MAPP-VA-LCC-Prozessor. Hier wird die Durchführung der oben angeführten, vorbereitenden Untersuchungen beschrieben, und die entsprechenden Ergebnisse dargestellt.

Kapitel 5 erläutert die Vorgehensweise bei der multispektralen Testklassifizierung mit ENVI 4.0. Schließlich werden die Klassifizierungsergebnisse vorgestellt und diskutiert, sowie deren Bedeutung für den MAPP-VA-LCC-Prozessor abgeschätzt.

Im letzten Kapitel werden die Untersuchungsergebnisse der vorliegenden Arbeit zusammenfassend dargestellt und Schlussfolgerungen für zukünftige Arbeiten mit dem MAPP-VA-LCC-Prozessor gezogen.

2 Grundlagen

2.1 Landbedeckung und Landnutzung

2.1.1 Begriffsklärung

Die Begriffe Landnutzung und Landbedeckung werden im Bereich der Klassifizierung von Fernerkundungsdaten oft nicht klar unterschieden oder sogar synonym gebraucht (AVERY & BERLIN 1992, S. 206). Daher sollen zunächst die Inhalte dieser beiden Begriffe geklärt und voneinander abgegrenzt werden.

Seit Beginn der sechziger Jahre wird in der englischsprachigen Literatur der Ausdruck *land cover* gebraucht, der üblicherweise mit dem deutschen Begriff Landbedeckung übersetzt wird. Die Landbedeckung umfasst nach BURLEY (1961, S. 18) die Bedeckung der Landoberfläche sowohl durch Vegetation als auch durch anthropogene Bebauung. In diesem Zusammenhang wird nicht berücksichtigt, welche Bedeutung die Fläche für den Menschen besitzt.

Der Begriff Landnutzung (engl. *land use*) war schon vor dem Ausdruck Landbedeckung in der Wissenschaftssprache gebräuchlich. Er beschreibt die Nutzung der Landoberfläche durch, und deren Bedeutung für den Menschen und geht somit über die rein physische Gestalt der Bedeckung der Landoberfläche hinaus.

Nach LO (1986, S. 227) kann die Landbedeckung normalerweise direkt in Fernerkundungsdaten erkannt werden, wohingegen die Landnutzung nicht direkt aus diesen ablesbar ist. Dies trifft vor allem für die Interpretation von Fernerkundungsdaten mit Hilfe digitaler Klassifizierungsverfahren zu. So ist mit digitalen Verfahren beispielsweise die Zuweisung einer mit Gras bestandenen Fläche zur Landbedeckungsklasse Grasland möglich. Ihre Nutzung, beispielsweise als Weide oder städtische Erholungsfläche, kann dagegen nicht aus ihren spektralen Eigenschaften abgelesen werden. Auch bei der Klassifizierung von Flächen, die fast vollständig durch menschliche Nutzung geprägt sind, können demnach mit digitalen Klassifizierungsverfahren keine direkten Aussagen über die Landnutzung getroffen werden.

Bei der Kartierung von Klassen wie ‚landwirtschaftliche Flächen‘ oder ‚städtische Flächen‘ können dennoch indirekt Landnutzungsaspekte berücksichtigt werden, da bei der Datenauswertung das Wissen des Bearbeiters um die Art der Landnutzung im Untersuchungsgebiet einfließt. Im Folgenden wird daher für die in der vorliegenden Arbeit durchgeführte Klassifizierung der kombinierte Begriff Landbedeckungs- / Landnutzungsklassifizierung verwendet.

2.1.2 Bedeutung von Landbedeckungs- und Landnutzungsinformationen

Das Wissen um die räumliche Verteilung, Zusammensetzung und Dynamik der Landbedeckung und Landnutzung ist für Umweltwissenschaften, Ressourcenmanagement und Politik von grundlegender Bedeutung. Zahlreiche politische Entscheidungen benötigen eine fundierte Kenntnis des Zustandes und der Veränderungen der Landbedeckungssituation. Beispielhaft hierfür sind Entscheidungen im Zusammenhang mit dem Kyoto-Protokoll, da im Rahmen dieses Abkommens Veränderungen der Größe von nationalen Waldflächen auf den genehmigten Umfang des Kohlendioxidausstoßes eines Staates angerechnet werden (UNFCCC 1997, Artikel 3, Absatz 3).

Für den Bereich des Ressourcenmanagements besitzen Landbedeckungs- und Landnutzungsdaten vor allem aufgrund ihres Informationsgehaltes bezüglich der Verfügbarkeit der Ressourcen Holz und Wasser eine entscheidende Rolle.

Für die Umweltwissenschaften ist vor allem der Einfluss der Landbedeckung auf das Klimasystem der Erde von Interesse. Die Landbedeckung ist für den Zustand und die Veränderungen des Klimas von Bedeutung, da sie in entscheidender Weise den Austausch von Energie, Wasser und Gasen zwischen Landoberfläche und Atmosphäre beeinflusst. Sie kann sowohl als Quelle als auch als Senke im Kohlenstoffkreislauf fungieren. In diesem Zusammenhang spielt häufig auch der Landnutzungsaspekt eine entscheidende Rolle. Für die Funktion einer Graslandfläche im Kohlenstoffkreislauf ist es beispielsweise von großer Bedeutung, ob es sich um eine regelmäßig gemähte Wiese beziehungsweise um eine Weide oder aber um eine Fläche handelt, der keine Biomasse durch menschlichen Eingriff entzogen wird. Aus Landbedeckungsdatensätzen können unter anderem Informationen zum Anteil immergrüner und sommergrüner Vegetationsbestände, zur oberirdischen Biomasse und zur Blattmorphologie (Nadel-, Laub- oder Grasvegetation) abgeleitet werden. Diese Informationen werden als Eingangsdaten für Kohlenstoffkreislaufmodelle benötigt und sowohl zur Abschätzung der Oberflächenalbedo mit ihren räumlichen und zeitlichen Veränderungen als auch zur Berechnung der Feuchtigkeitsverfügbarkeit an der Landoberfläche herangezogen. Ebenso können anhand dieser Informationen, und zwar besonders durch die Kenntnis der Blattmorphologie, Rückschlüsse auf Gasaustauschvorgänge zwischen Vegetation und Atmosphäre gezogen werden. (vgl. GEIDER et al. 2001)

Landbedeckungsinformationen sind neben der Klimaforschung auch für die Beantwortung anderer umweltwissenschaftlicher Fragestellungen, beispielsweise aus den Bereichen Hydrologie, Meteorologie und Ökologie relevant. Generell liefern Landbedeckungsdatensätze elementare Informationen zur wissenschaftlichen Beurteilung der Interaktionen zwischen Mensch und Umwelt. (KYUNG-SOO et al. 2004, S. 52)

Weltweit ist für die vergangenen Dekaden sowohl bezüglich Landbedeckung als auch Landnutzung ein deutlicher Wandel zu verzeichnen. Nach Statistiken der FAO ging beispielsweise die landwirtschaftlich genutzte Fläche in der Europäischen Union¹ von 1970 bis 2002 um 11,24 %, permanentes Weideland um 13,48 % zurück (FAO 2004).

¹ Gemeint sind die 15 Mitgliedstaaten der EU vor 2004

Die regelmäßige, möglichst flächendeckende Erfassung von Daten zur Landnutzung und Landbedeckung besitzt folglich für wissenschaftliche, politische und gesellschaftliche Interessen eine besondere Bedeutung.

2.2 Die Informationsquellen Satellitenbild und thematische Karte im Vergleich

Die vorliegende Arbeit befasst sich mit der Erstellung einer thematischen Karte aus optischen, multispektralen Satellitenbildern und somit mit der Übersetzung einer bestimmten Informationsquelle in eine andere Art von Informationsquelle. Im Folgenden soll daher der Informationsgehalt von Karten einerseits und Satellitendaten andererseits betrachtet werden.

Satellitenaufnahmen bilden ebenso wie Karten einen Teil der Land- oder Meeresoberfläche ab und geben dabei Informationen über diese Ausschnitte wieder. Grundsätzlich können Karten und Satellitenbilder sowohl qualitativ als auch quantitativ analysiert werden. Vergleicht man die Entstehung von Satellitendaten und Karten und die Art und Weise, wie aus ihnen Informationen gewonnen werden können, so werden jedoch grundlegende Unterschiede deutlich.

Für die Erstellung von Karten sind die Entscheidungen des Kartographen bezüglich Objektauswahl und -gestaltung von grundlegender Bedeutung. Karte und Gelände stehen so in einem konventionellen Zusammenhang, der durch Vereinbarungen definiert ist (ALBERTZ 2001, S. 92). Karten sind immer auf die vereinfachte Darstellung der für den jeweiligen Fall als wesentlich erachteten Informationen reduziert. Die Informationsdarstellung erfolgt in der Karte mit Hilfe von graphischen Zeichen und Signaturen, deren Bedeutung in einer Kartenlegende festgehalten ist. Der Anwender muss also die Bedeutung der in einer Karte sichtbaren Flächen und Formen nicht von Grund auf selbst interpretieren. Elemente ohne festgelegte Bedeutung treten in Karten grundsätzlich nicht auf.

Bei der Entstehung von Satellitenaufnahmen empfängt der Sensor Informationen über die reale Welt mittels elektromagnetischer Strahlung, die in elektrische Signale gewandelt, und durch die Grauwert- oder Farbverteilungen des Bildes dargestellt wird. Daher bestehen zwischen der wiedergegebenen Erdoberfläche und dem Satellitenbild kausale Zusammenhänge (ALBERTZ 2001, S. 90). Die Identifizierung von Formen und Flächen als Abbild bestimmter Objekte kann bei Satellitenbildern nur durch die Fähigkeit zur visuellen oder digitalen Bildinterpretation des Bearbeiters erfolgen. Hierbei können, vom Interpretieren abhängig, unterschiedliche Ergebnisse entstehen. Satellitenaufnahmen enthalten stets Einzelheiten, die nur mit Hilfe zusätzlicher Informationen, zum Beispiel durch Geländebegehungen, interpretiert werden können. Die Informationsdichte von Satellitendaten ist hoch, allerdings liefern die Daten auch immer für die jeweilige Anwendung unwichtige oder unerwünschte Informationen, wie etwa Wolkeninformationen für den Fall von Untersuchungen der Landoberfläche. (ALBERTZ 2001, S 90ff.)

Üblicherweise kann die breite Masse der Nutzer die in Satellitenbildern enthaltenen Informationen nicht ohne weiteres selbst interpretieren. Es ist daher notwendig, dass Fachleute aus Satellitenbildinformationen thematische Karten ableiten. Diese Karten sind mit Hilfe der in der Kartenlegende kodierten Zeichen für alle Anwender leicht interpretier- und nutzbar.

2.3 Optische, multispektrale Fernerkundungsdaten

Die in der vorliegenden Arbeit durchgeführte Landbedeckungs- / Landnutzungsklassifizierung basiert auf Daten des Sensors MERIS. Hierbei handelt es sich um optische, multispektrale Daten mit charakteristischen radiometrischen und geometrischen Eigenschaften, die in den folgenden Abschnitten näher erläutert werden.




Abbildung 2.1: Geometrischer Zusammenhang zwischen der Einfallsrichtung der Sonnenstrahlung und der Beobachtungsrichtung

ϑ_r : Beobachtungszenitwinkel des Sensors

ϑ_i : Sonnenzenitwinkel

φ_r : Azimutwinkel des Sensors

φ_i : Azimutwinkel der Sonne

φ_{rel} : Relativer Azimutwinkel zwischen Sensor und Sonne

(verändert nach ALBERTZ 2001, S. 23)

2.3.1 Radiometrische Eigenschaften

Multispektrale Fernerkundungsdaten enthalten Informationen über die vom Sensor empfangene Strahlung in mehreren Wellenlängenbereichen. Die aufgezeichneten Spektralbereiche werden als Kanäle oder Bänder bezeichnet. Jeder Kanal kann als ein Bildlayer dargestellt werden, wobei jedem Pixel dieses Layers ein Strahldichte- oder Reflexionswert für den jeweiligen Wellenlängenbereich zugeordnet ist.

Dieser Wert entsteht im Fall der optischen Fernerkundung der Landoberfläche durch die zum Sensor hin gerichtete Reflexion im sichtbaren und nahinfraroten Spektralbereich. Der Fernerkundungssensor erfasst immer einen von der Objektfläche ausgehenden Strahlenkegel mit dem Öffnungswinkel Ω (s. Abbildung 2.1). Somit wird die Strahldichte L eines in Richtung ϑ_r φ_r orientierten Strahlenkegels in $W / m^2 \cdot sr^{-1}$ gemessen.

Aus der vom Sensor gemessenen Strahldichte wird der Reflexionsgrad R abgeleitet. Dieser stellt das Verhältnis zwischen der in eine bestimmte Richtung reflektierten, gemessenen Strahldichte und der in dieselbe Richtung reflektierten Strahldichte eines weißen Lambert-Reflektors² bei gleicher Beleuchtung dar. Der spektrale Reflexionsgrad $R(\lambda)$ ist, parallel dazu, der auf eine bestimmte Wellenlänge λ , beziehungsweise im vorliegenden Fall, der auf die jeweiligen Wellenlängenbereiche des Fernerkundungssensors bezogene Reflexionsgrad. (vgl. z.B. HILDEBRANDT 1996, S. 21-23)

2.3.2 Einflussfaktoren auf radiometrische Eigenschaften

Der radiometrische Informationsgehalt von optischen Fernerkundungsdaten wird durch zahlreiche Einflussfaktoren bestimmt. Neben Sensoreigenschaften wie spektraler und räumlicher Auflösung spielen das Reflexionsverhalten des erfassten Objektes, die Beobachtungs- und Beleuchtungsgeometrie sowie der Strahlungstransport durch die zwischen Objekt und Sensor liegende Atmosphäre eine entscheidende Rolle.

2.3.2.1 Spektrale Zusammensetzung der Reflexion von Objekten der Landoberfläche

Abbildung 2.2 zeigt beispielhaft Reflexionsspektren unterschiedlicher Oberflächentypen für den Wellenlängenbereich von 410 nm bis 910 nm.

Die für Vegetation typischen qualitativen Reflexionscharakteristika lassen sich anhand der dargestellten spektralen Signaturen nachvollziehen. Im sichtbaren Bereich von etwa 400 nm bis 700 nm sind die Reflexionsgrade aufgrund der Absorptionseigenschaft von Blattpigmenten wie Chlorophyll a beziehungsweise b und Carotin verhältnismäßig klein. Das relative Maximum um 550 nm wird durch die geringere Absorption grüner Wellenlängen durch Chlorophyll bestimmt (s. Abbildung 2.3). Im Bereich des Nahinfrarots zwischen etwa 700 nm und 1300 nm ist das Reflexionsvermögen von Pflanzen dagegen

² Körper, der die auftreffende Strahlung vollständig und in alle Richtungen gleichmäßig reflektiert

deutlich größer. In diesem Wellenlängenbereich hängt die reflektierte Strahlung entscheidend von der Zellstruktur der Pflanzen und deren Ausrichtung im Verhältnis zur Einstrahlungsrichtung ab (REINARTZ 1998, S. 29f.).

Für vegetationslose Böden ist ein relativ kontinuierlicher Anstieg der Reflexionskurven vom sichtbaren bis zum nahinfraroten Spektralbereich charakteristisch (s. Abbildung 2.2). Die Reflexionsgrade aller betrachteten Wellenlängen nehmen mit steigendem Humusanteil und steigendem Eisenoxidgehalt des Oberbodens ab. Schnee und Wolken reflektieren sichtbare und nahinfrarote Wellenlängen stark und sind bei alleiniger Betrachtung dieses Spektralbereiches nicht voneinander trennbar (KAPPAS 1994, S. 64ff.).




Abbildung 2.2: Typische Reflexionsspektren unterschiedlicher Landbedeckungsarten (Datenquelle: LIANG 2004, CD-ROM)

Die Reflexionscharakteristika von Objekten der Landoberfläche sind also vor allem von deren Material, physikalischem Zustand und Oberflächenbeschaffenheit beeinflusst. Um verschiedene Arten von Landbedeckungen mit Hilfe von Satellitenaufnahmen unterscheiden zu können, müssen messbare Abweichungen der Reflexionsspektren der einzelnen Geländeobjekte vorhanden sein. In Abbildung 2.2 sind beispielsweise die spektralen Signaturen von blankem Boden und Gras leicht voneinander zu unterscheiden, wohingegen sich diejenigen von Reis und Soja stark ähneln. Bei multispektralen Klassifizierungsverfahren treten in solchen Fällen daher häufig Schwierigkeiten bei der Trennbarkeit bestimmter Klassen auf. Diese Schwierigkeiten können unter anderem verringert werden, indem man die phänologischen Veränderungen der Vegetation im Jahresverlauf berücksichtigt.




Abbildung 2.3: Spezifischer Absorptionskoeffizient von Chlorophyll a und b
(Quelle: LIANG 2004, S. 96)

2.3.2.2 Bidirektionale Reflexionsverteilung von Objekten der Landoberfläche

Die Reflexion an den meist rauen Oberflächen von Geländeobjekten erfolgt anisotrop. Die auftreffende Strahlung wird also meist nicht in alle Raumwinkel gleichmäßig stark zurückgeworfen. Die Richtungsverteilung der reflektierten Strahlung wird, neben der Oberflächenrauigkeit und Struktur der reflektierenden Objekte, vom Sonnenzenitwinkel ϑ_i beeinflusst. Die objektspezifische Reflexion in Abhängigkeit von Beleuchtungs- und Beobachtungswinkel kann durch eine Funktion, die so genannte BRDF (*bidirectional reflectance distribution function*) beschrieben werden.

Nur bei Objekten mit relativ glatter, horizontal liegender Oberfläche wird der Großteil der auftreffenden Strahlung von der Strahlungsquelle weg, also vorwärts gerichtet reflektiert. Für Vegetationsbestände und Böden ist jedoch eine deutlich ausgeprägte rückwärts gerichtete Reflexionscharakteristik typisch (s. Abbildung 2.4).




Abbildung 2.4: Schematische Darstellung der Reflexion an unterschiedlichen Oberflächen
Links: An einer relativ glatten, horizontal ausgerichteten Oberfläche
Rechts: An einer stark strukturierten Oberfläche, typisch für Vegetationsbestände und Böden
(eigener Entwurf)

Bei den meisten Objekten der Erdoberfläche überwiegt also die Reflexion zurück in Richtung der Sonne. Besonders deutlich ausgeprägt ist diese Rückwärtscharakteristik bei spitzkronigen Bäumen wie Fichten und bei rauen Ackerböden (REINARTZ 1989, S. 27f.). Abbildung 2.5 zeigt die für Objekte der Landoberfläche typische Richtungsverteilung der Reflexion am Beispiel einer immergrünen Nadelwaldfläche. Die Stärke der BRDF-Effekte hängt gerade bei Vegetationsoberflächen von der Wellenlänge der reflektierten Strahlung ab. Diese Effekte sind in sichtbaren Wellenlängenbereichen verhältnismäßig schwach ausgeprägt, für die Reflexion der nahinfraroten Strahlung, die zu einem großen Anteil von der Zellausrichtung der Pflanzen geprägt wird, treten dagegen deutlichere BRDF-Einflüsse auf (s. Abbildung 2.5).

Fernerkundungssensoren messen lediglich den in ihre Richtung reflektierten Strahlungsanteil der Geländeoberfläche. Bei Aufnahmesystemen mit einem weiten Gesichtsfeld treten deutlich unterschiedliche Beobachtungszenitwinkel (θ_r) auf. Gerade bei solchen Sensoren können BRDF-Effekte dazu führen, dass für gleiche Objekte in unterschiedlichen Aufnahmen unterschiedliche Reflexionsgrade gemessen werden.




Abbildung 2.5: Die bidirektionale Reflexionsverteilung eines immergrünen Nadelwaldes aus POLDER-Messungen für $\lambda = 670 \text{ nm}$ (links) und $\lambda = 865 \text{ nm}$ (rechts). Der Stern kennzeichnet den Sonnenstand, die Kreuze (links) die Beobachtungsgeometrie der Messungen. Die drei konzentrischen Kreise stehen von innen nach außen für Beobachtungszenitwinkel von 15° , 30° und 45° . (Quelle: CAMACHO DE COCA 2003, S. 13)

2.3.2.3 Atmosphärische Einflüsse

Bevor die von der Erdoberfläche reflektierte Strahlung den Fernerkundungssensor erreicht, legt sie einen zweifachen Weg durch die Atmosphäre zurück, zunächst von der Sonne zur Erdoberfläche und schließlich von dort in Richtung Sensor. Auf diesem Weg wird die Strahlung durch Absorption und Streuung an Atmosphärenpartikeln verändert.

Bei der Absorption von Strahlung an Molekülen der Atmosphäre wird Strahlungsenergie in andere Energieformen, beispielsweise in Wärmeenergie umgewandelt. Hierbei spielen vor

allem Kohlendioxid-, Wasser-, Sauerstoff-, und Ozonmoleküle eine entscheidende Rolle, wobei jedes Molekül in bestimmten Wellenlängenbereichen besonders stark absorbiert (s. Abbildung 2.6).

Durch Streuung an Atmosphärenpartikeln entsteht die so genannte diffuse Himmelsstrahlung. Hierbei lassen sich, abhängig von der Partikelgröße, zwei Streuungsarten unterscheiden. Die Streuung an Teilchen, die deutlich kleiner als die Wellenlänge des Lichtes sind, also beispielsweise an Luftmolekülen, wird Rayleigh-Streuung genannt. Sie ist proportional zu λ^{-4} . Wird Licht an größeren Partikeln wie etwa Aerosolen gestreut, so spricht man von Mie-Streuung. Diese Streuung ist proportional zu λ^α , mit $-1,5 < \alpha < -1$, und somit weniger stark von der Wellenlänge abhängig. Sind die atmosphärischen Partikel im Vergleich zur Wellenlänge sehr groß, so ist die Streuung praktisch wellenlängenunabhängig. Dieser Fall ist typischerweise bei der Streuung sichtbarer und nahinfraroter Wellenlängen durch Wolken oder Nebel gegeben. (ROEDEL 1992, S. 22-27)




Abbildung 2.6: Transmission der Atmosphäre für die Mittelbreiten, berechnet mit dem Modell MODTRAN.
(Quelle: SCHOWENGERDT 1997, S. 40)

Auf dem Weg von der Erdoberfläche zum Sensor wird die von einem bestimmten Ausschnitt der Erdoberfläche reflektierte Strahlung durch die Reflexion benachbarter Bereiche und durch Luftlicht überlagert. Unter Luftlicht (s. Abbildung 2.7) versteht man hierbei die Strahlung, die von Atmosphärenpartikeln direkt in Richtung Sensor gestreut wird und somit keine Informationen über die Erdoberfläche enthält. (RICHARDS & JIA 1999, S. 39-43)

In Abbildung 2.7 sind die Einflüsse der Atmosphäre auf die Geländebeleuchtung und auf die den Sensor erreichende Strahlung zusammenfassend dargestellt.

Da die Partikelzusammensetzung der Atmosphäre räumlich und zeitlich schwankt, können die atmosphärischen Einflüsse auf Fernerkundungsmessungen stark variieren. Bei Aufnahmesystemen mit weitem Gesichtsfeld und bei der Untersuchung von Gelände mit hoher Reliefenergie kann zudem die Weglänge der Strahlung durch die Atmosphäre

beachtlich schwanken. Aufgrund ihrer Wellenlängenabhängigkeit sind Atmosphäreinflüsse zudem in jedem Spektralkanal unterschiedlich ausgeprägt.

Es existieren verschiedene Atmosphärenkorrekturmodelle, mit denen vom Sensor gemessene Strahldichten in Reflexionswerte der Erdoberfläche zurückgerechnet werden können, wie beispielsweise das Modell SMAC nach RAHMAN & DEDIEU (1994) oder das Modell ATCOR nach RICHTER & SCHLÄPFER (2003). Die Atmosphärenkorrektur von MERIS-Daten der Landoberfläche wird nach SANTER et al. (2000) vorgenommen.

Bei bewölkten oder dunstigen Verhältnissen ist der Einfluss der Atmosphäre auf Messungen im sichtbaren und nahinfraroten Spektralbereich besonders gravierend, da Wolken und Dunst die Strahlung dieser Wellenlängen stark streuen und reflektieren. Von Wolken oder Dunst beeinflusste optische Fernerkundungsdaten sind daher für die Untersuchung der Landoberfläche nicht oder nur sehr eingeschränkt nutzbar.




Abbildung 2.7: Schematische Darstellung der Strahlungsverhältnisse bei Aufnahme (verändert nach ALBERTZ 2001, S. 15)

2.3.3 Geometrische Eigenschaften

Digitale Fernerkundungsdaten sind üblicherweise geokodiert beziehungsweise georeferenziert. Dies bedeutet, dass jedem Pixel Längen- und Breitenkoordinaten zugeordnet sind. Die Geokodierung ist für die Dateninterpretation in vielen Fällen von großer Bedeutung. Die Resultate der Auswertung von Fernerkundungsdaten sollen üblicherweise geometrisch korrekt in Karten dargestellt werden. Bei einigen Verfahren, so zum Beispiel bei multitemporalen Analysen oder bei der Bearbeitung von Daten mehrerer Sensoren, ist zudem eine präzise Übertragung der genutzten Datensätze in ein gemeinsames Koordinatensystem unbedingt erforderlich.

Die Geokodierung von digitalen Fernerkundungsdaten erfolgt auf der Basis von Informationen zur Lagebeziehung zwischen Sensor und Objekt und zum Aufnahmeverfahren. Fehler in der Georeferenzierung können nach RICHARDS und JIA (1999, S. 39ff.) zahlreiche Ursachen haben, die im Wesentlichen auf folgende Faktoren zurückzuführen sind:

- Erddrehung während der Bildaufnahme
- begrenzte Scanrate einiger Sensoren
- weites Gesichtsfeld des Sensors
- Erdkrümmung
- Schwankungen in Höhe, Geschwindigkeit und Lage der Sensorplattform (s. Abbildung 2.8)
- Panoramaeffekte im Zusammenhang mit der Aufnahmegeometrie
- Geländehöhe

Die Informationen zu Höhe, Geschwindigkeit und Lage der Sensorplattform werden in Form von so genannten Orbitvektoren festgehalten. Werden zur Bestimmung der Orbitvektoren vorhersagende Berechnungen angestellt, so spricht man von so genannten *orbit state* Vektoren, beruhen die Angaben dagegen auf präzisen Vermessungen der Sensorplattform zum Aufnahmezeitpunkt, so handelt es sich um konsolidierte Orbitvektoren.

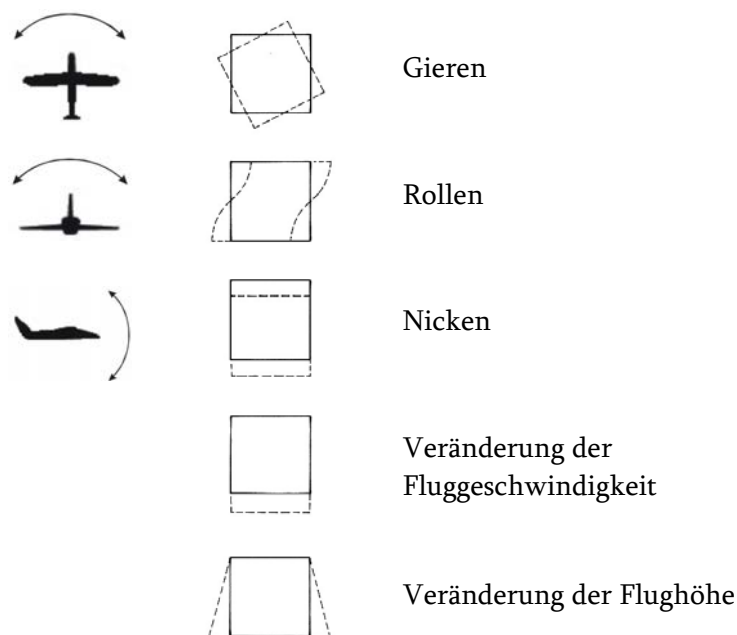


Abbildung 2.8: Auswirkungen von Fehlern in Plattformposition und -lage auf den vom Sensor aufgenommenen Ausschnitt der Erdoberfläche (verändert nach RICHARDS & JIA 1999, S. 55)

2.4 Landbedeckungs- /Landnutzungsklassifizierungen

2.4.1 Klassifikationssysteme

Jeder Landbedeckungs- oder Landnutzungsklassifizierung liegt ein bestimmter Klassifikationsschlüssel zugrunde, der auch als Klassifikationssystem bezeichnet werden kann. Ein solcher Klassifikationsschlüssel regelt die Unterteilung des Themenkomplexes Landbedeckung beziehungsweise Landnutzung in Klassen. Häufig sind Klassifikationssysteme hierarchisch gegliedert, so dass Klassen höherer Hierarchiestufen mehrere Klassen einer niedrigeren Stufe beinhalten. Der Klassifikationsschlüssel darf nicht mit der Kartenlegende gleichgesetzt werden. Während ein Klassifikationssystem lediglich potentiell unterscheidbare Klassen vorgibt, entsteht die Legende erst bei der Anwendung eines Klassifikationssystems auf ein spezielles Gebiet unter Verwendung eines festgelegten Kartenmaßstabs und eines bestimmten Datensatzes (DI GREGORIO & JANSEN 2000).

Ein Klassifikationssystem sollte unterschiedliche Anforderungen erfüllen. Hierbei wird vor allem auf eine eindeutige Terminologie, auf die Orientierung an den Bedürfnissen der Nutzer und auf die lückenlose Beschreibung des Untersuchungsgebietes Wert gelegt (HEYMANN 1994, S. 25). Zudem ist eine möglichst hohe Flexibilität bei der Beschreibung der einzelnen Klassen nötig (DI GREGORIO & JANSEN 2000).

Derzeit wird eine große Anzahl unterschiedlicher regionaler und globaler Klassifikationssysteme für Landnutzung und Landbedeckung verwendet. Einige dieser Systeme sind auf die Auswertung von Daten eines bestimmten Typs oder einer festgelegten räumlichen Auflösung zugeschnitten. Andere Klassifikationssysteme legen besonders auf die Beschreibung eines speziellen Teilbereichs der Landoberfläche Wert, so dass beispielsweise landwirtschaftliche Flächen oder räumlich begrenzte Gebiete besonders detailliert, andere Bereiche dagegen nur grob beschrieben werden. (DI GREGORIO & JANSEN 2000)

Im Folgenden sollen die Klassifikationssysteme wichtiger großflächiger Landbedeckungs- und Landnutzungskartierungen vorgestellt werden.

Im Jahr 1971 begann die vom US Geological Survey (USGS) koordinierte Entwicklung des **USGS-Klassifikationssystems** (ANDERSON et al. 1976). Das USGS-System wurde sowohl für die Nutzung konventioneller Datenquellen als auch für die Verwendung von Luftbildern und LANDSAT-Daten konzipiert. Durch die Einteilung der Klassen in bis zu vier hierarchische Stufen kann das System allerdings auch an die Auflösung anderer Sensoren ebenso wie an die Bedürfnisse verschiedener Nutzergruppen angepasst werden. Die Klassen der ersten Hierarchiestufe des USGS-Klassifikationssystems sind in Tabelle 2.1 zusammengestellt.

Tabelle 2.1: Die oberste Hierarchiestufe des USGS-Landbedeckungsklassifikationssystems (Quelle: ANDERSON et al. 1976, S. 14f.)

1	Städtische oder bebaute Flächen
2	Landwirtschaftliche Flächen
3	Grasland
4	Waldflächen
5	Wasserflächen
6	Feuchtgebiete
7	Vegetationslose Flächen
8	Tundra
9	Schnee und Eis

Mitte der neunziger Jahre wurde das **IGBP-Klassifikationssystem** als Grundlage für den globalen Landbedeckungsdatensatz DISCover des International Geosphere Biosphere Programme (IGBP) entwickelt (BELWARD 1996). Das System unterscheidet 17 Landbedeckungsklassen (s. Tabelle 2.2), die eine weltweit vollständige und eindeutige Gliederung der Landoberfläche ermöglichen. Das Klassifizierungsschema wurde auf die Nutzung von NOAA-AVHRR-Daten mit einer räumlichen Auflösung von 1 km abgestimmt. Die Klasseneinteilung orientiert sich an den drei *canopy components* nach RUNNING et al. (1994) Biomasse, Lebensdauer der Blätter und Blatttyp. Somit können die IGBP-Klassen besonders gut in biogeochemischen Modellrechnungen der neunziger Jahre genutzt werden (LOVELAND et al. 2000 & BELWARD et al. 1999).

Tabelle 2.2: Das IGBP-Landbedeckungs-Klassifikationssystem (Quelle: BELWARD 1996)

Gruppe	Klasse
Natürliche Vegetation	1 Immergrüner Nadelwald
	2 Immergrüner Laubwald
	3 Sommergrüner Nadelwald
	4 Sommergrüner Laubwald
	5 Mischwald
	6 Geschlossenes Strauchland
	7 Offenes Strauchland
	8 Waldsteppe , -savanne
	9 Steppe, Savanne
	10 Grasland
	11 Feuchtgebiete
Entwickelte und gemischte Flächen	12 Ackerland
	13 Städtische und bebaute Flächen
	14 Mosaik aus Ackerland und anderer, natürlicher Vegetation
Vegetationslose Flächen	15 Schnee und Eis
	16 Vegetationslose oder -arme Flächen
	17 Wasserflächen

Tabelle 2.3: Das Klassifikationssystem der CORINE Land Cover
(Quelle: HEYMANN 1994, S. 27)

Ebene 1		Ebene 2		Ebene 3	
1	Bebaute Flächen	1.1	Städtisch geprägte Flächen	1.1.1	Durchgängig städtische Prägung
				1.1.2	Nicht durchgängig städtische Prägung
		1.2	Industrie-, Gewerbe- und Verkehrsflächen	1.2.1	Industrie- und Gewerbeflächen
				1.2.2	Straßen-, Eisenbahnnetze und funktionell zugeordnete Flächen
				1.2.3	Hafengebiete
				1.2.4	Flughäfen
		1.3	Abbauflächen, Deponien, Baustellen	1.3.1	Abbauflächen
				1.3.2	Deponien und Abraumhalden
				1.3.3	Baustellen
		1.4	Künstlich angelegte, nicht landwirtschaftl. genutzte Grünflächen	1.4.1	Städtische Grünflächen
1.4.2	Sport- und Freizeitanlagen				
2	Landwirtschaftliche Flächen	2.1	Ackerflächen	2.1.1	Nicht bewässertes Ackerland
				2.1.2	Regelmäßig bewässertes Ackerland
				2.1.3	Reisfelder
		2.2	Dauerkulturen	2.2.1	Weinbauflächen
				2.2.2	Obst- und Beerenobstbestände
				2.2.3	Olivenhaine
		2.3	Grünland	2.3.1	Wiesen und Weiden
		2.4	Landwirtschaftliche Flächen heterogener Struktur	2.4.1	Einjährige Kulturen in Verbindung mit Dauerkulturen
				2.4.2	Komplexe Parzellenstrukturen
				2.4.3	Landwirtschaftlich genutztes Land mit Flächen natürliche Vegetation von signifikanter Größe
				2.4.4	Land- und Forstwirtschaftliche Flächen
		3	Wälder und naturnahe Flächen	3.1	Wälder
3.1.2	Nadelwälder				
3.1.3	Mischwälder				
3.2	Strauch- und Krautvegetation			3.2.1	Natürliches Grünland
				3.2.2	Heiden und Moorheiden
				3.2.3	Hartlaubbewuchs
				3.2.4	Wald-Strauch-Übergangsstadien
3.3	Offene Flächen ohne oder mit geringer Vegetation			3.3.1	Strände, Dünen und Sandflächen
				3.3.2	Felsflächen ohne Vegetation
				3.3.3	Flächen mit spärlicher Vegetation
		3.3.4	Brandflächen		
		3.3.5	Gletscher und Dauerschneegebiete		
4	Feuchtflächen	4.1	Feuchtflächen im Landesinnern	4.1.1	Sümpfe
				4.1.2	Torfmoor
		4.2	Feuchtflächen an der Küste	4.2.1	Salzwiesen
				4.2.2	Salinen
				4.2.3	In der Gezeitenzone liegende Flächen
5	Wasserflächen	5.1	Wasserflächen im Landesinnern	5.1.1	Gewässerläufe
				5.1.2	Wasserflächen
		5.2	Meeresgewässer	5.2.1	Lagunen
				5.2.2	Mündungsgebiete
				5.2.3	Meere und Ozeane

Das 1994 von HEYMANN vorgestellte **Klassifikationssystem des CORINE Land Cover Projektes** der Europäischen Kommission ist speziell auf europäische Landbedeckungs- und Landnutzungsverhältnisse abgestimmt. Das hierarchische System ist in drei Ebenen gegliedert, wobei die dritte Ebene in 44 Klassen unterteilt ist (s. Tabelle 2.3). Bei Bedarf kann die Nomenklatur um eine vierte Ebene erweitert werden. Eine ausführlichere Formulierung der Klassendefinitionen erschien im Rahmen der Aktualisierung des CORINE-Datensatzes bei BOSSARD et al. (2000, S. 22ff).

Das Klassifikationssystem wurde für die visuelle Interpretation von LANDSAT- und SPOT-Daten mit einer Auflösung von 20 m bis 30 m entwickelt. Vor allem in der dritten Ebene des Klassifikationssystems sind einige Klassen nicht ausschließlich nach Landbedeckungs- sondern auch nach Landnutzungskriterien definiert (PERDIGAO & ANNONI 1997, S. 3f.). Beispiele hierfür sind die Klassen 1.2.3 ‚Hafengebiete‘, 1.4.1 ‚Städtische Grünflächen‘ und 1.4.2 ‚Sport- und Freizeitanlagen‘. Weiterhin entsprechen einige Klassen nicht einer homogenen Landbedeckung, so beispielsweise die Klasse 2.4.2 ‚Komplexe Parzellenstrukturen‘. Aus diesem Grund sind einige CORINE-Klassen nicht ausschließlich durch eine einheitliche spektrale Signatur definiert. Es ist daher nicht möglich, alle Klassen des CORINE-Systems mit rein digitalen Klassifizierungsverfahren zu erfassen.

Das von FAO und UNEP entwickelte **Land Cover Classification System (LCCS)** entstand als Antwort auf Forderungen nach einer weltweiten Harmonisierung von Landbedeckungsdatensätzen. Mit Hilfe eines international akzeptierten, standardisierten Klassifikationssystems soll die Validierung und die Vergleichbarkeit dieser Datensätze verbessert werden.

In DI GREGORIO & JANSEN (2000) wird dieses Klassifikationssystem ausführlich vorgestellt. Das Konzept des LCCS gibt keine festgelegten Klassen vor, unter denen der Anwender auswählen kann. Vielmehr kann jeder Nutzer anhand bestimmter Klassifikationskriterien, wie beispielsweise Bedeckungsgrad oder Vegetationshöhe, individuelle Klassen festlegen. In diesem Zusammenhang sind jedoch gewisse Merkmale bereits vorgegeben, zwischen denen der Anwender wählen kann. Dies ist beispielsweise die Vegetationshöhe von 0,03-3 m für krautartige Vegetation, 0,3-5 m für Sträucher und 3-30 m für Bäume. Weist eine Landbedeckungsklasse bestimmte dieser vordefinierten diagnostischen Merkmale auf, so wird ihr für jedes Merkmal eine entsprechende Buchstaben- und Ziffernkombination, ein so genannter Classifier zugewiesen. Eine Auswahl dieser Classifier ist in Tabelle 2.4 aufgelistet. Die spezifischen Landbedeckungseigenschaften einer Klasse können durch Aneinanderreihung mehrerer Classifier in Form einer so genannten LCCS-Formel eindeutig ausgedrückt und identifiziert werden. Je nach Detaillierungsgrad eines Landbedeckungsprodukts werden mehr oder weniger Classifier zur Definition einer Klasse verwendet.

Das LCCS wird von GOFC-GOLD und GTOS als Standard für zukünftige Landbedeckungsklassifizierungen empfohlen. In Projekten wie AFRICOVER (s. FAO 2003) und GLC 2000 wurde dieses System bereits zur Landbedeckungsklassifizierung verwendet. Im Zuge internationaler Harmonisierungsbemühungen werden derzeit viele aktuelle Landbedeckungsdatensätze in das LCCS übertragen, darunter beispielsweise auch die CORINE Land Cover. (GOFC-GOLD 2004 a)

Der auf dem LCCS basierende GLC 2000-Klassifikationsschlüssel ist in Tabelle 2.5 dargestellt. Er beinhaltet 22 Klassen, die teilweise in weitere Unterklassen gegliedert werden können. Die einzelnen Klassen sind beispielsweise bezüglich Bedeckungsgrad und Vegetationshöhe genau definiert und den Normen des LCCS angepasst.

Tabelle 2.4: Auswahl wichtiger Classifier des LCCS
(Quelle: JRC-IES 2004 a)

Classifier	Bedeutung
Kombinierbare Classifier:	
A2	Krautartige Vegetation
A3	Bäume
A4	Sträucher
A10	Geschlossen (Bedeckungsgrad >(70-60) %)
A11	Offen (70-60)-(20-10) %
A12	Geschlossen (>70-60) % (nur aquatische / überflutete Flächen)
A13	Sehr offen 40-(10-20) %
A14	Spärlich (20-10)-1%
A20	Geschlossen bis offen 100-15 %
A21	Geschlossen bis offen (100-40) % (am Ende)
B2	Höhe Bäume >30-3 m
B3	Höhe Sträucher 5-0,3 m
B4	Höhe krautartige Vegetation 3-0,03 m
D1	Laubvegetation
D2	Nadelvegetation
E1	Immergrün
E2	Sommergrün
C1	Ständig überflutetes Land
C2	Zeitweise überflutetes Land
C3	Tägliche Veränderung der Überflutung
Alleine stehende Classifier:	
A11	Landwirtschaftliche, terrestrische Flächen
A23	Landwirtschaftliche, aquatische oder regelmäßig überflutete Flächen
B16	Vegetationslose Flächen
A1	Bebaute Flächen
A1	Binnengewässer
A2	Schnee
A3	Eis

Tabelle 2.5: Klassifikationsschlüssel der GLC 2000 mit LCCS-Formeln

(zusammengestellt aus: JRC-IES 2004 b & JRC-IES 2004 c)

Klasse	LCCS-Formel	Beschreibung	Unterklassen
1 Immergrüner Laubbaumbestand	A3A20B2XXD1E1	Hauptvegetationsschicht besteht aus immergrünen Laubbäumen mit einem Kronenschluss von 15-100%	Kronenschluss: 40-100%
2 Sommergrüner, geschlossener Laubbaumbestand	A3A20B2XXD1E2-A21	Hauptvegetationsschicht besteht aus sommergrünen Laubbäumen mit einem Kronenschluss von 40-100	
3 Sommergrüner, offener Laubbaumbestand	A3A11B2XXD1E2-A13	Hauptvegetationsschicht besteht aus sommergrünen Laubbäumen mit einem Kronenschluss von (10-20)-(60-70)%	
4 Immergrüner Nadelbaumbestand	A3A20B2XXD2E1	Hauptvegetationsschicht besteht aus immergrünen Nadelbäumen mit einem Kronenschluss von 15-100%	Kronenschluss: 40-100%
5 Sommergrüner Nadelbaumbestand	A3A20B2XXD2E2	Hauptvegetationsschicht besteht aus sommergrünen Nadelbäumen mit einem Kronenschluss von 15-100%	Kronenschluss: 40-100%
6 Gemischter Baumbestand	A3A20B2XXD1 // A3A20B2XXD2	Hauptvegetationsschicht besteht aus Nadel- und Laubbäumen mit einem Kronenschluss von 15-100%	Kronenschluss: 40-100%
7 Regelmäßig überfluteter Baumbestand, immergrün, Süß- und Brackwasser	A3A20B2C1D1E1-R1 // A3A20B2C1D1E1-R2 // A3A20B2C2D1E1-R1 // A3A20B2C2D1E1-R2	Hauptvegetationsschicht besteht aus immergrünen Laubbäumen auf ständig von Süß- oder Brackwasser überfluteten Flächen mit einem Kronenschluss von 15-100%	Kronenschluss: 40-100%
8 Regelmäßig überfluteter Baumbestand, immergrün, Salzwasser	A3A12B2C1D1E1-C5-R3	Hauptvegetationsschicht besteht aus immergrünen Laubbäumen auf ständig von Salzwasser überfluteten Flächen mit einem Kronenschluss von über 60-70%	
9 Mosaik aus Baumbestand und anderer natürlicher Vegetation oder landwirtschaftlichen Flächen	A3A10B2 / A12 / A11	Mosaik aus: <ul style="list-style-type: none"> - Baumbeständen mit einem Kronenschluss von über 60-70% - (Halb)natürlicher Vegetation mit einem Bedeckungsgrad von über 4% während mindestens 2 Monaten - Landwirtschaftlichen Flächen 	
10 Verbrannter Baumbestand	A3A20Z99	Hauptvegetationsschicht besteht aus verbrannten Bäumen mit einem Kronenschluss von 15-100%	Kronenschluss: 40-100%
11 Geschlossener bis offener, immergrüner Strauchbestand	A4A20B3XXD1E1 // A4A20B3XXD2E1	Hauptvegetationsschicht besteht aus immergrünen Sträuchern mit einem Bedeckungsgrad von 15-100%	Bedeckungsgrad: 40-100%
12 Geschlossener bis offener, sommergrüner Strauchbestand	A4A20B3XXD1E2	Hauptvegetationsschicht besteht aus sommergrünen Sträuchern mit einem Bedeckungsgrad von 15-100%	Bedeckungsgrad: 40-100%
13 Geschlossener bis offener, krautartiger Bestand	A2A20B4	Hauptvegetationsschicht besteht aus krautartiger Vegetation mit einem Bedeckungsgrad 15-100%	Bedeckungsgrad: 40-100%
14 Offener krautartiger oder strauchartiger Bestand	A2A14 // A4A14	Hauptvegetationsschicht besteht aus Sträuchern und krautartiger Vegetation mit einem Bedeckungsgrad von 1 % - (10-20) %	
15 Strauchartiger und/oder krautartiger Bestand, regelmäßig überfluteter oder wassergesättigter Boden	A4A20B3C1-R1 // A4A20B3C1-R2 // A4A20B3C2-R1 // A4A20B3C2-R2 // A2A20B4C1-R1 // A2A20B4C1-R2 // A2A20B4C2-R1 // A2A20B4C2-R2	Hauptvegetationsschicht besteht aus Sträuchern und/oder krautartiger Vegetation auf ständig oder saisonal von Süß- oder Brackwasser überfluteten Flächen oder wassergesättigtem Boden mit einem Bedeckungsgrad von 15-100%	Bedeckungsgrad: 40-100%
16 Landwirtschaftliche Flächen	A11 // A23	(Halb)natürliche Vegetation wurde vom Menschen entfernt und durch Vegetation ersetzt, die am Ende der Wachstumsperiode (teilweise) geerntet wird. Nach der Ernte ist eine Periode ohne Vegetationsbedeckung möglich. Die Fläche weist mindestens 2 Monate lang einen Bedeckungsgrad von über 4% auf. Flächen können überflutet sein.	
17 Mosaik aus landwirtschaftlichen Flächen, Baumbestand und anderer natürlicher Vegetation	A11 / A3A20B2 / A12	Mosaik aus: <ul style="list-style-type: none"> - Landwirtschaftlichen Flächen - Bäumen mit einem Kronenschluss von 15-100% - (Halb)natürlicher Vegetation mit einem Bedeckungsgrad von über 4% mindestens während 2 Monaten 	Kronenschluss: 40-100%
18 Mosaik aus landwirtschaftlichen Flächen und strauchartiger oder krautartiger Vegetation	A11 / A4A20B3 / A2A20B4	Mosaik aus: <ul style="list-style-type: none"> - Landwirtschaftlichen Flächen - Sträuchern mit einem Bedeckungsgrad von 15-100% - Krautartiger Vegetation mit einem Bedeckungsgrad von 15-100% 	Bedeckungsgrad: 40-100%
19 Vegetationslose und -arme Flächen	B16	Weniger als 4% Vegetationsbedeckung während mehr als 10 Monaten. Die Bedeckung ist natürlich.	
20 Wasserflächen	A1	künstliche oder natürliche Wasserflächen	
21 Schnee und Eis	A2 // A3	Künstliche oder natürliche Schnee- und Eisflächen	
22 Künstliche Oberflächen und zugeordnete Flächen	A1	Bebaute Flächen	

2.4.2 Erhebung von Landbedeckungsdaten im Feld und mit Methoden der Fernerkundung

Bis in die 1930er Jahre stellten Kartierungen im Gelände die einzig übliche Methode zur Erhebung von Landbedeckungs- beziehungsweise Landnutzungsdaten dar. Auch heute noch besitzt die Geländekartierung für zahlreiche Anwendungen entscheidende Vorteile. Gerade für kleinräumige Untersuchungen, die eine äußerst präzise Erfassung von detailliert gegliederten Klassen erfordern, sind Datenerhebungen im Feld besonders geeignet. Schwierigkeiten treten jedoch vor allem dann auf, wenn Landbedeckungs- oder Landnutzungskartierungen für große Gebiete durchgeführt werden sollen. In solchen Fällen sind Geländekartierungen meist deutlich zu personal- und kostenaufwendig. Zusätzliche Probleme ergeben sich hier bei der Kartierung von schwer zugänglichem oder weitläufigem Gelände.

Aufgrund der Schwächen geländebasierter Methoden, gerade im Zusammenhang mit großräumigen Datenerhebungen, werden Landbedeckungs- und Landnutzungskartierungen heute meist auf der Basis von Fernerkundungsdaten durchgeführt. Unabhängig von der Zugänglichkeit des Geländes kann auf diese Weise eine flächendeckende Datengrundlage für das Klassifizierungsverfahren geschaffen werden. Im Falle von Satellitenbildern ist eine Datenerhebung auch für mehrere Zeitpunkte problemlos möglich. So können multitemporale Analysen - zur Beurteilung dynamischer Effekte oder zur Verbesserung der Klassifizierungsergebnisse durch die Berücksichtigung der Phänologie - ohne großen Mehraufwand durchgeführt werden. Weiterhin vorteilhaft ist, dass Fernerkundungsdaten archivierbar sind, und somit der Zustand des Geländes zum Bezugszeitraum dauerhaft nachvollziehbar bleibt. Korrekturen und Veränderungen der Kartierung sind folglich auch im Nachhinein noch möglich.

Die Kartierung von Landbedeckung und Landnutzung auf der Basis von Fernerkundungsdaten besitzt also, besonders für großräumige Untersuchungen, zahlreiche Vorteile. Trotzdem ist die Nutzung von Daten aus Geländeerhebungen vor allem für die Validierung der Klassifizierungsprodukte oftmals von großer Bedeutung. Dennoch wird aus Kosten- und Zeitgründen häufig auf Geländebegehungen zur Verifizierung von Klassifikationen verzichtet.

2.4.3 Methoden zur Klassifizierung multispektraler Fernerkundungsdaten

Wie in Abschnitt 2.2 erläutert wurde, ist die in multispektralen Fernerkundungsdaten enthaltene Information für viele Anwender nicht oder nur eingeschränkt verständlich und nutzbar. Daher wurden unterschiedliche Verfahren entwickelt, auf deren Grundlage Fernerkundungsdaten von Fachleuten klassifiziert werden können, um diese Daten schließlich für eine größere Nutzergruppe anwendbar zu machen.

2.4.3.1 Visuelle Interpretationen

Bei der visuellen Klassifizierung von Fernerkundungsdaten identifiziert der Auswerter durch Betrachtung des Bildes die Klassenzugehörigkeit der einzelnen Bildelemente. Hierbei können Vorkenntnisse und Assoziationsfähigkeit des Interpreten genutzt werden und zu Ergebnissen führen, die mit Hilfe rein rechnerischer Verfahren nicht erreichbar sind. So kann der Bildinterpret beispielsweise durch Kontextwissen nicht nur die Landbedeckung einer bestimmten Fläche erkennen, sondern auch auf deren Nutzung schließen. Die Subjektivität und die hohe Irrtumswahrscheinlichkeit menschlicher Entscheidungen kann sich jedoch negativ auf visuelle Interpretationsergebnisse auswirken (HILDEBRANDT 1996). Nachteilig ist zudem, dass visuelle Bildinterpretationen kosten- und zeitaufwendig sind und nicht in automatisierten Klassifikationsverfahren angewendet werden können.

2.4.3.2 Digitale, multispektrale Klassifizierungsverfahren

Digitale oder numerische Klassifizierungsverfahren gruppieren Bildelemente nach ihren spektralen Eigenschaften, und weisen die so entstandenen Pixelgruppen thematischen Klassen zu. Diese Verfahren werden heute häufig eingesetzt, um aus digitalen Fernerkundungsdaten thematische Karten zu erzeugen. Es gibt unterschiedliche mathematische und methodische Ansätze numerischer Klassifizierungen, von denen im Folgenden die wichtigsten erläutert werden sollen.

Unüberwachte Klassifizierungen sind rein auf statistischen Ansätzen beruhende Verfahren. Hierbei werden die Bildpunkte Spektralklassen zugewiesen, ohne dass diese Klassen zuvor vom Bearbeiter definiert wurden. Der Auswerter kann lediglich die Anzahl der zu ermittelnden Klassen bestimmen. Erst im Nachhinein wird die thematische Bedeutung der Pixelgruppen, die in der unüberwachten Klassifizierung gebildet wurden, festgelegt.

Der Rechenaufwand für unüberwachte Klassifizierungsverfahren ist verhältnismäßig hoch. Üblicherweise werden unüberwachte Methoden lediglich mit kleinen Bildausschnitten als vorbereitender Schritt für überwachte Klassifizierungen durchgeführt, um potentielle homogene Trainingsgebiete leichter identifizieren zu können. (RICHARDS & JIA 1999, S. 262-264)

Bei **überwachten Klassifizierungsverfahren** definiert der Auswerter zunächst auf der Basis eines Klassifikationsschlüssels die gewünschten thematischen Objektklassen und wählt für jede vorhergesehene Klasse mehrere repräsentative Trainingsgebiete aus. In einer Analyse der spektralen Eigenschaften der Trainingsgebiete werden wichtige statistische Parameter wie Mittelvektoren, Standardabweichungen und Kovarianzmatrizen berechnet und miteinander verglichen. Auf der Grundlage dieser Vergleiche definiert der Auswerter für jede zu unterscheidende Klasse typische spektrale Signaturen, die so genannten Musterklassen. (RICHARDS & JIA 1999, S. 181f.)

Erst jetzt folgt die Klassifizierung der multispektralen Daten. Mit Hilfe bestimmter Algorithmen, so genannter Klassifikatoren, wird jedes Bildelement auf die Ähnlichkeit seiner Werte in allen betrachteten Spektralkanälen mit den Werten der zuvor definierten

Musterklassen überprüft. Ein Pixel wird schließlich der Klasse zugewiesen, zu der die größte spektrale Ähnlichkeit besteht. Liegt die Ähnlichkeit eines Bildpunktes für alle Objektklassen unter einem gewissen Schwellenwert, so ist dieses Pixel nicht klassifizierbar. Die bekanntesten Klassifikatoren für überwachte Verfahren sind der Minimum-Distance-Klassifikator und der Maximum-Likelihood-Klassifikator.

(RICHARDS & JIA 1999)

Beim Minimum-Distance-Verfahren wird die euklidische Distanz als Maß für die Ähnlichkeit eines Pixels zur Musterklasse herangezogen. Dieser Klassifikator kommt demnach mit einfach durchführbaren Berechnungen aus. Für überwachte Klassifizierungsverfahren wird jedoch meist, wie auch in der vorliegenden Arbeit, die Maximum-Likelihood-Entscheidungsregel angewendet. Bei diesem Verfahren werden für jedes Pixel die Mahalanobis-Distanzen zu allen Klassen berechnet. Diese Distanzen drücken die Zugehörigkeitswahrscheinlichkeit des Pixels zur jeweiligen Klasse aus, wobei die der Klasse zugrunde liegende statistische Verteilung berücksichtigt wird. Ein Pixel wird schließlich derjenigen Klasse zugewiesen, zu der es die kleinste Mahalanobis-Distanz aufweist. Dieses Verfahren geht von der Annahme aus, dass jeder Klasse eine Normalverteilung zugrunde liegt, was für die meisten Anwendungsfälle der Fernerkundung gerechtfertigt ist (REINARTZ 1998, S. 39). Bei der Anwendung des Maximum-Likelihood-Klassifikators wird die statistische Verteilung der Musterklasse berücksichtigt. Der Rechenaufwand ist somit zwar größer als beim Minimum-Distance-Klassifikator, es sind jedoch gleichzeitig wesentlich bessere Klassifizierungsergebnisse zu erwarten (RICHARDS & JIA 1999, S. 190).

Die Qualität überwachter Klassifizierungsergebnisse hängt in erster Linie von den vorbereitenden Arbeitsschritten, wie Trainingsgebiet- und Klassenwahl ab. Der Arbeitsaufwand für die Vorbereitung überwachter Klassifizierungen liegt deutlich über dem Nachbereitungsaufwand bei unüberwachten Verfahren. Das in überwachte Klassifizierungen einfließende Wissen des Auswerter führt jedoch meist zu besseren und zielgerichteten Ergebnissen. (RICHARDS & JIA 1999, S. 259-264)

Bei **hierarchischen** oder **baumförmigen Klassifizierungsverfahren** erfolgt die Klassenzuweisung der Bildpunkte schrittweise durch mehrere aufeinander folgende Einzelentscheidungen. In jedem Entscheidungsschritt kann zwischen nur wenigen Klassen gewählt werden. Im folgenden Schritt wird die ausgewählte Klasse in weitere Unterklassen gegliedert.

Vorteilhaft an hierarchischen Klassifizierungsmethoden ist, dass für jede Einzelentscheidung die jeweils aussagekräftigsten Teilaspekte der Datengrundlage herangezogen werden können. Zudem kann jeder Entscheidungsschritt mit Hilfe eines individuellen, für den jeweiligen Fall optimalen Algorithmus durchgeführt werden.

Der Arbeitsaufwand hierarchischer Klassifizierungen ist aufgrund der Vielzahl an Arbeitsschritten jedoch sehr hoch. Ein zusätzlicher Nachteil liegt in der möglichen Fehlerakkumulation im Laufe der Entscheidungsschritte, so dass die Fehlerwahrscheinlichkeit für die Einzelentscheidungen äußerst gering gehalten werden muss. Durch Fehlerakkumulation beträgt beispielsweise für fünf aufeinander folgende

Entscheidungen mit einer jeweiligen Fehlerwahrscheinlichkeit von 10 % der Gesamtfehler 59 %.

(RICHARDS & JIA 1999, S. 283ff.)

2.4.3.3 Multitemporale Analyse

Die im vorangegangenen Kapitel erläuterten, multispektralen Klassifizierungsverfahren können durch zahlreiche Ansätze weiterentwickelt werden (vgl. z.B. REINARTZ 1989 & GANGKOFNER 1996). Besonders deutliche Verbesserungen lassen sich hierbei durch die Auswertung mehrerer Datensätze unterschiedlicher Aufnahmezeitpunkte erreichen.

Landbedeckungsklassen, die durch Vegetation charakterisiert sind, zeigen typische phänologische Veränderungen im Jahresverlauf. Das Ergebnis einer monotemporalen Multispektralklassifizierung kann sich allerdings nur auf die Ausprägung der betrachteten Klassen für einen einzigen Zeitpunkt beziehen. Die spektralen Eigenschaften der phänologischen Phasen einiger Landbedeckungsklassen lassen sich jedoch zu bestimmten Zeitpunkten nur schwer voneinander trennen, wohingegen sie zu anderen Zeitpunkten deutlich voneinander abgrenzbar sind. So unterscheiden sich beispielsweise sommergrüne Laubwälder im Winter nur geringfügig von landwirtschaftlichen Flächen. Mischwälder lassen sich zu diesem Zeitpunkt jedoch spektral unterscheiden. Im Hochsommer dagegen weisen landwirtschaftliche Flächen größere spektrale Unterschiede zu Laubwäldern auf, Mischwälder vergleichsweise geringere. In solchen Fällen können multispektrale, monotemporale Klassifizierungsansätze durch den Vergleich von Klassifizierungsergebnissen mehrerer Zeitpunkte beachtlich verbessert werden. (vgl. z.B. HILDEBRANDT 1996, S. 552f. & GANGKOFNER 1996, S. 98f.)

2.4.4 Verifizierungsmethoden

Die Nutzbarkeit von Daten, die durch Auswertung von Satellitenbildern gewonnen werden, hängt stark von einer aussagekräftigen Validierung ab. Ein wichtiger Bestandteil jedes Klassifizierungsvorhabens ist daher, die Zuverlässigkeit der Ergebniskarte mit Hilfe geeigneter Verifizierungsmethoden zu überprüfen. Diese Qualitätsbeurteilung gewann zu Beginn der achtziger Jahre mit dem verstärkten Aufkommen digitaler Klassifizierungsverfahren zunehmend an Bedeutung. (CONGALTON 1991, S. 35)

Die Verifizierung von Klassifikationsergebnissen erfolgt üblicherweise durch den Vergleich des Kartenproduktes mit Referenzdaten, die unabhängig von der zu prüfenden Klassifizierung erhoben wurden. Dieser Validierungsansatz geht von der Annahme aus, dass die genutzten Referenzdaten die Realität korrekt abbilden. Die Referenzinformation muss hierbei mindestens in der gleichen räumlichen und thematischen Auflösung wie die zu validierende Klassifizierung vorliegen und von hoher Genauigkeit sein. Die Referenzdaten können beispielsweise auf Geländebegehungen, präzisen Geländekenntnissen oder hoch aufgelösten Satelliten- und Luftbildern beruhen. In der wissenschaftlichen Praxis werden häufig qualitativ hochwertige thematische Karten mit vergleichbaren Legendeneinheiten als Referenz herangezogen (z.B. CLEVERS et al. 2003 &

KYUNG-SOO et al. 2004). Hierbei müssen Metadaten der Referenzkarte, wie Klassifizierungsmethode, Datengrundlage, Bezugszeitraum und Genauigkeit bekannt sein. Für den Fall, dass Referenzdaten nicht flächendeckend vorhanden sind, wird die Validierung eines Klassifizierungsergebnisses an Stichproben durchgeführt. Durch eine bewusst durchdachte Stichprobenwahl können hierbei Aussagen über die Kartenqualität für bestimmte regionale oder thematische Teilaspekte des bearbeiteten Gebietes getroffen werden.

Die Standardmethode zur anschaulichen Überprüfung der Qualität eines Klassifikationsergebnisses ist die Konfusionsmatrix (CONGALTON 1991, S. 36). Hierbei werden das Klassifizierungsergebnis und der Referenzdatensatz einander in Form einer quadratischen Matrix gegenübergestellt (s. Tabelle 2.6). Die Matrixzeilen entsprechen den Klassen des Klassifizierungsergebnisses, die Spalten denen der Referenz. Die einzelnen Elemente der Matrix beinhalten die Anzahl der Pixel, die im Klassifizierungsergebnis der Klasse der jeweiligen Zeile und gleichzeitig in der Referenz der Klasse der jeweiligen Spalte zugeordnet sind. Die Hauptdiagonale der Matrix enthält folglich für jede Klasse die Anzahl der korrekt klassifizierten Pixel.

Tabelle 2.6: Beispiel einer Konfusionsmatrix für drei Klassen
(eigener Entwurf)

		Referenz			Total
		Laubwald	Nadelwald	Grasland	
Klassifizierung	Laubwald	30	7	15	52
	Nadelwald	5	42	6	53
	Grasland	15	3	23	41
	Total	50	52	44	146

Zusätzlich zur anschaulichen Darstellungsform der Konfusionsmatrix sollte eine Validierung der Klassifikationsergebnisse mit Hilfe aussagekräftiger, statistischer Indizes erfolgen. Als Standardmaßzahlen kommen hierfür nach CONGALTON (1991, S. 36) vor allem die im Folgenden beschriebenen Genauigkeitsindizes in Frage.

Die Gesamtgenauigkeit berechnet sich aus dem Anteil der korrekt klassifizierten Pixel an der gesamten Pixelzahl. Sie lässt sich anhand einer Konfusionsmatrix berechnen, indem man die Summe der Elemente der Matrixdiagonale durch die Gesamtpixelzahl dividiert. In der Beispielmatrix in Tabelle 2.6 beträgt die Gesamtgenauigkeit 65,1%.

Die Benutzergenauigkeit drückt aus, welcher Prozentanteil einer Klasse des Kartenproduktes korrekt klassifiziert ist. Im Beispiel der Tabelle 2.6 weist die Klasse Grasland eine Benutzergenauigkeit von $23 \div 41 = 56,1\%$ auf. Es gehören also 43,9% der in der Karte als Grasland bezeichneten Fläche in Wirklichkeit einer anderen Klasse an. Diese Fehlzugeordnung wird als Einschlussfehler bezeichnet.

Die Herstellergenauigkeit beziffert den Prozentsatz, zu dem die Bildpunkte einer Klasse des Referenzdatensatzes im Kartenergebnis richtig erkannt wurden. In Tabelle 2.6 ist die Herstellergenauigkeit für Grasland demzufolge $23 \div 44 = 52,3\%$. In diesem Fall wurden

47,7% der gemäß der Referenz mit Gras bewachsenen Flächen nicht der Klasse Grasland zugeordnet. Diesen nicht erfassten Flächenanteil nennt man Unterlassungsfehler.

Eine weiterer Index zur Validierung eines aus Fernerkundungsdaten abgeleiteten Kartenprodukts ist der Kappa-Koeffizient oder die Khat-Genauigkeit (\hat{K}). Dieser Koeffizient vergleicht die tatsächlich mit der Referenz übereinstimmenden Stichprobeneinheiten mit den Stichprobeneinheiten, die im Falle einer zufälligen Verteilung übereinstimmen würden. Er berücksichtigt also, inwieweit die Übereinstimmung zwischen Klassifizierungsergebnis und Referenz zufällig ist (GANGKOFNER 1996, S. 44f.). Nach CONGALTON (1991, S. 40) wird die Khat-Statistik auf Basis der Konfusionsmatrix nach Gleichung 2.1 berechnet.

$$\hat{K} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \quad , \quad (\text{Gl. 2.1})$$

wobei	r :	Anzahl der Matrixspalten
	x_{ii} :	Anzahl der Beobachtungen im Matrixelement (i;i)
	x_{i+} :	Summe der Zeile i
	x_{+i} :	Summe der Spalte i
	N :	Anzahl aller Beobachtungen der Matrix

Für das Beispiel in Tabelle 2.6 beträgt der Kappa-Koeffizient \hat{K} 0,474, das Klassifizierungsergebnis stimmt also um 47,4% besser mit der Referenz überein, als dies bei einer rein zufälligen Verteilung zu erwarten wäre. Der Kappa-Koeffizient ist eine aussagekräftige Maßzahl für die Qualität eines Klassifizierungsverfahrens. Für den Kartennutzer selbst ist er jedoch weniger interessant, da es aus Anwenderperspektive nicht entscheidend ist, zu welchem Anteil die Richtigkeit einer Karte auf dem Zufall beruht (GANGKOFNER 1996, S. 45f.).

2.5 Forschungsstand

2.5.1 Globale und europäische Landbedeckungs- und Landnutzungskarten aus Fernerkundungsdaten

Die Landbedeckungsklassifizierung ist eine der frühesten Anwendungen der Fernerkundung. Erste großflächige, auf Fernerkundungsdaten basierende Landbedeckungskartierungen wurden jedoch erst vor etwa zehn Jahren durchgeführt. Diese neuartigen Klassifizierungsversuche gründeten sich sowohl auf die gestiegenen

Anforderungen an umweltwissenschaftlich relevante Informationen als auch auf technische Weiterentwicklungen in der Fernerkundung. (CHILAR 2000)

Seitdem entstanden auf der Basis von Fernerkundungsdaten mehrere globale beziehungsweise europäische Landbedeckungsdatensätze, von denen die wichtigsten im Folgenden dargestellt werden.

Die Anfang der neunziger Jahre existierenden globalen Landbedeckungsdaten entsprachen nicht den Bedürfnissen vieler Kernprojekte des IGBP. Daher erarbeiteten Wissenschaftler des USGS und des JRC im Rahmen der **IGBP-DISCover** Initiative einen an die Fragestellungen der Umweltwissenschaften angepassten globalen Landbedeckungsdatensatz.

Zur Erstellung dieses Datensatzes wurde, zunächst für jeden Kontinent einzeln, eine unüberwachte Klassifizierung von Monatskompositen des AVHRR-NDVI für den Zeitraum April 1992 bis März 1993 durchgeführt. Die resultierenden Cluster repräsentieren vorläufige Grünheitsklassen. Diese Grünheitsklassen wurden in einem anschließenden Verfahren von mindestens drei Experten auf der Basis von zusätzlichen Hilfsdaten in 961 so genannte saisonale Landbedeckungsregionen gegliedert. Da diese kontinentspezifischen saisonalen Landbedeckungsregionen nicht standardisiert sind, wurden sie in einem weiteren Schritt in die 94 Klassen der Olson-Legende (OLSON 1994) übertragen. Auf Grundlage dieser 94 Klassen konnte die IGBP-DISCover schließlich in unterschiedliche gröbere Klassifikationsschlüssel übersetzt werden, so zum Beispiel in das Klassifikationssystem des USGS oder in die 17 Klassen der IGBP-Legende (s. Tabelle 2.2). (LOVELAND et al. 2000)

Die Validierung der IGBP-DISCover durch SCEPAN (1999) mit Hilfe von LANDSAT-TM- und SPOT-Daten ergab eine Gesamtgenauigkeit von 66,9%.

Das Projekt **CORINE Land Cover** der europäischen Umweltagentur befasst sich mit der Ermittlung von Bodenbedeckungsdaten Europas. Eine Aktualisierung der Landbedeckungsklassifizierung, die teilweise auch Landnutzungsaspekte berücksichtigt, wird im Abstand von etwa zehn Jahren durchgeführt.

Im Rahmen des CORINE Land Cover Projektes werden in nationalen Teilprojekten auf der Grundlage eines harmonisierten Klassifikationsschlüssels (s. Tabelle 2.3) und einer einheitlichen Erfassungsmethode Daten des Satelliten LANDSAT und SPOT ausgewertet. Als zusätzliche Informationsquelle werden unter anderem topographische Karten und Luftbilder herangezogen. Die Bildinterpretation erfolgt visuell bei einer unteren Erfassungsuntergrenze von 25 ha für flächenhafte Objekte. (HEYMANN 1994)

In den Jahren 1986 bis 1995 wurde in einer Ersterfassung zum Bezugsjahr 1990 die Bodenbedeckung für alle EU-Mitgliedsstaaten kartiert. Derzeit werden im Rahmen der CORINE 2000 die Bodenbedeckung für das Bezugsjahr 2000 sowie die Veränderungen gegenüber dem Jahr 1990 ermittelt. Die Koordination und das Management des deutschen Teilprojektes der CORINE 2000 finden seit Mai 2001 im Auftrag des Umweltbundesamtes am Deutschen Fernerkundungsdatenzentrum des DLR statt. (KIEFL et al. 2003)

Zu Beginn des Jahres 2005 wird der komplette aktualisierte CORINE Land Cover 2000 Datensatz für Deutschland verfügbar sein.

Das **Projekt Pan-European Land Cover Monitoring (PELCOM)** wurde in den Jahren 1996 bis 1999 durchgeführt. Im Rahmen dieses Projektes entstand eine aus NOAA-AVHRR abgeleitete Datenbank der Landbedeckung Europas. Hierzu wurden multitemporale AVHRR-NDVI Daten mit einer Auflösung von 1 km ausgewertet. Die Klassifizierung von Wald erfolgte aus multispektralen AVHRR-Szenen mit Hilfe einer Schwellenwertbildung in Kanal 1. Städtische Gebiete, Binnengewässer und später auch Feuchtgebiete wurden mit Hilfe von externen Zusatzdaten des CORINE-Datensatzes und des Digital Chart of the World (DCW) abgeleitet. Insgesamt ist die PELCOM-Datenbank in 16 Landbedeckungsklassen gegliedert. Die Validierung des Datensatzes mit LANDSAT-TM-Daten ergab eine mittlere Gesamtgenauigkeit von 69,2 %.

Eine zu Projektbeginn beabsichtigte Automatisierung der Methode konnte unter anderem nicht erreicht werden, da einige Klassifizierungsschritte keine zufrieden stellenden Ergebnisse lieferten und durch visuelle Interpretationen ergänzt werden mussten. (MÜCHER et al. 2000)

Die Universität Boston entwickelte den **MODIS Land Cover Classification Algorithm (MLCCA)** zur Erstellung globaler Landbedeckungsdatensätze auf Grundlage des Sensors MODIS (FRIEDL et al. 2002). Der hierarchische Klassifizierungsansatz berücksichtigt sowohl sieben Kanäle als auch den MODIS Vegetationsindex EVI. Der Algorithmus greift hierbei auf eine Datenbank zu, die spektrale Informationen weltweit verteilter Trainingsgebiete enthält. In einem multitemporalen Ansatz werden 16-Tages-Komposite für das gesamte Jahr ausgewertet. Die Aktualisierung des Landbedeckungsdatensatzes mit einer räumlichen Auflösung von 1 km soll in jährlichen Abständen stattfinden. Ein erstes Klassifizierungsergebnis, das auf den 17 Klassen des IGBP-Klassifikationssystems beruht, wurde aus Daten des Zeitraumes Juli bis Dezember 2000 erstellt. Die Genauigkeit des Datensatzes hängt stark von der genutzten spektralen Datenbank ab. Aus diesem Grund zielen Verbesserungsansätze großteils auf eine Erweiterung und Optimierung dieser Datenbank ab.

Unter der Leitung des Joint Research Centre (JRC) der Europäischen Kommission arbeiteten rund 30 Forschungsgruppen an dem Projekt **Global Land Cover 2000 (GLC 2000)**. Im Rahmen dieses Programms wurden Daten des Sensors VEGETATION mit einer räumlichen Auflösung von 1 km aus dem Zeitraum November bis Dezember 2000 ausgewertet. Teilweise wurden zusätzlich die Sensoren ATSR, JERS, ERS und DMSP herangezogen, um etwa Regionen mit dauerhafter Wolkenbedeckung oder städtische Gebiete besser kartieren zu können. Die Klassifizierungsmethodik konnte von den beteiligten Forschungsgruppen frei gewählt werden.

Die GLC 2000 basiert auf dem LCCS von FAO und UNEP (s. Tabelle 2.5). Die Datenbank enthält zum einen 19 regionale Landbedeckungskarten mit detaillierten, für das jeweilige Gebiet relevanten Legendeneinheiten, darunter auch eine europäische Teilkarte. Zudem wurde ein globaler Landbedeckungsdatensatz erstellt, der alle regionalen Landbedeckungsklassen in konsistenter Weise miteinander kombiniert. Dies ist aufgrund der flexiblen Struktur des LCCS möglich. (FRITZ et al. 2003)

Die letzten Dokumentationen zur Validierung der GLC 2000-Datenbank sind derzeit in Bearbeitung und bisher noch nicht verfügbar (GOFC-GOLD 2004 b).

Die Erstellung der angeführten globalen beziehungsweise europäischen Landbedeckungsdatensätze kommt nicht ohne externe Zusatzdaten oder visuelle Bildinterpretation aus. Eine automatisierte Aktualisierung ist daher in keinem der angeführten Fälle möglich. Bis auf die CORINE Land Cover besitzen zudem alle dargestellten Landbedeckungskarten eine relativ grobe räumliche Auflösung von 1 km.

2.5.2 Landbedeckungsklassifizierungen mit MERIS-Daten

Derzeit werden von unterschiedlichen Seiten Versuche unternommen, die Daten des ursprünglich für Ozeananwendungen konzipierten Sensors MERIS zur Klassifizierung von Landbedeckung und -nutzung heranzuziehen. Klassifizierungen, die über einen nationalen Rahmen hinausgehen, wurden mit MERIS-Daten bisher jedoch noch nicht durchgeführt. Ebenso wenig zielen die bisherigen Klassifizierungsansätze mit MERIS-Daten auf eine automatisierte Aktualisierung der Resultate ab.

CLEVERS et. al. (2003) werteten Level 1b-Daten der Niederlande von fünf über das Jahr verteilten Zeitpunkten aus. In monotemporalen Klassifizierungen mit Hilfe des Minimum-Distance-Verfahrens konnten sie sechs Landbedeckungsklassen unterscheiden. Die besten Ergebnisse konnten bisher, mit einer Gesamtgenauigkeit von 51,4 % bei der Klassifizierung einer Juniszene erreicht werden. Die häufigsten Verwechslungen traten hier zwischen den Klassen Grasland und landwirtschaftliche Flächen auf.

SEILER und CSAPLOVICS (2003) untersuchten die Vegetationsdynamik des Niger Deltas anhand von fünf MERIS-Level 1b-Szenen in voller räumlicher Auflösung, die im Zeitraum August 2002 bis Juni 2003 aufgenommen wurden. Es wurden sowohl überwachte Klassifizierungen als auch Analysen des NDVI vorgenommen. In Ergänzung zu den oben genannten MERIS-Daten nutzten SEILER und CSAPLOVICS externe Zusatzdaten. Die in den Untersuchungen erzielte Genauigkeit hängt stark von der Anzahl und Art dieser Zusatzinformationen ab. Probleme entstanden während des Klassifizierungsverfahrens vor allem aufgrund von Ungenauigkeiten der Georeferenzierung der genutzten MERIS-Daten.

Im Rahmen des Projektes SIBERIA II der EU wurde an der University of Wales Swansea der Versuch unternommen, Informationen zur Landbedeckung Sibiriens aus MERIS-Daten abzuleiten (SKINNER & LUCKMAN 2003). Hierfür wurden monotemporale, hierarchische Klassifizierungen mehrerer Bezugszeitpunkte durchgeführt. Jedes Pixel wurde derjenigen Landbedeckungsklasse zugewiesen, die es in allen monotemporalen Einzelergebnissen am häufigsten aufwies. SKINNER und LUCKMAN führten für das gleiche Testgebiet ebenso Klassifizierungen auf der Basis von MODIS-Daten durch. Im Vergleich zu diesen Analysen erreichte die Auswertung von MERIS-Daten keine Verbesserung der Genauigkeit.

3 Die MAPP-Landbedeckungs- / Landnutzungs-klassifizierung

Die vorliegende Arbeit entstand im Rahmen des MERIS Application and Regional Products Project (MAPP). Am Deutschen Zentrum für Luft- und Raumfahrt (DLR) wird derzeit in diesem Projekt an einer automatisierten Landbedeckungs- / Landnutzungsklassifizierung auf Grundlage von Daten des Sensors MERIS gearbeitet. In den folgenden Abschnitten werden sowohl das MAPP-Projekt als auch die Arbeitsgrundlagen und der Ablauf des MAPP-Klassifizierungsverfahrens dargestellt.

3.1 Das Projekt MAPP

Das Projekt MAPP wurde im Jahr 1997 in Zusammenarbeit des GKSS-Forschungszentrums Geesthacht, des Instituts für Weltraumwissenschaften der FU Berlin, der Softwarefirma SCICON und des Deutschen Zentrums für Luft- und Raumfahrt gegründet. Das vom Deutschen Bundesministerium für Bildung und Forschung geförderte Projekt ist in GÜNTHER et al. (2002) und in SCHULZ (1998) detailliert beschrieben.

Im Rahmen des MAPP-Projektes werden aus ESA-Standardprodukten des Sensors MERIS so genannte VA-Produkte für regionale Anwendungen erzeugt. Diese Produkte sollen, besser als dies bei den reinen Strahldichte- oder Reflexionswerten der Standardprodukte der Fall ist, MERIS-Daten für breite Anwendergruppen nutzbar und verständlich machen. Alle MAPP-Produkte können von Öffentlichkeit und Wissenschaft für nicht-kommerzielle Anwendungen kostenlos genutzt werden und ermöglichen es somit, umweltbezogene Planung und Organisation auf zuverlässige Grundlagen zu stellen.

MAPP stellt regionale Datenprodukte bereit, die anwendungsorientierte Informationen zu Meer, Binnengewässern, Atmosphäre und Landoberfläche liefern. Die beiden wichtigsten Zielsetzungen für den Bereich Landoberfläche sind hierbei die Ableitung eines AVHRR-kompatiblen NDVI und eine jährlich aktualisierbare, automatische Landbedeckungs-/ Landnutzungsklassifizierung von Deutschland beziehungsweise von Europa, die so genannte MAPP-LCC. Alle Produkte des Projekts können am Deutschen Fernerkundungsdatenzentrum des DLR in Neustrelitz mit Hilfe des MERIS-VA-Prozessors erzeugt werden.

Im Rahmen des Projektes MAPP empfängt die DLR-Bodenstation in Neustrelitz mit Genehmigung von ESA MERIS-Daten, die mit Hilfe des ESA-Standardprozessors zu Level 1b- und Level 2-Produkten in voller Auflösung prozessiert werden. Die Empfangsstation in Neustrelitz erhält am Tag Daten von durchschnittlich zwei bis drei Pässen über Europa (s. Abbildung 3.1). Aus den empfangenen Daten wurden im Zeitraum Juli 2003 bis August 2004 knapp 800 Level 2-Szenen mit einer Auflösung von 265 m x 292 m im Nadir prozessiert, die Teile von Deutschland abbilden. Diese Szenen

wurden recht unregelmäßig empfangen. Für einige Monate sind daher Daten für fast jeden zweiten Tag verfügbar, in anderen Zeiträumen bestehen jedoch - häufig durch Wolkenbedeckung verstärkt - größere Datenlücken von bis zu zwei Wochen.

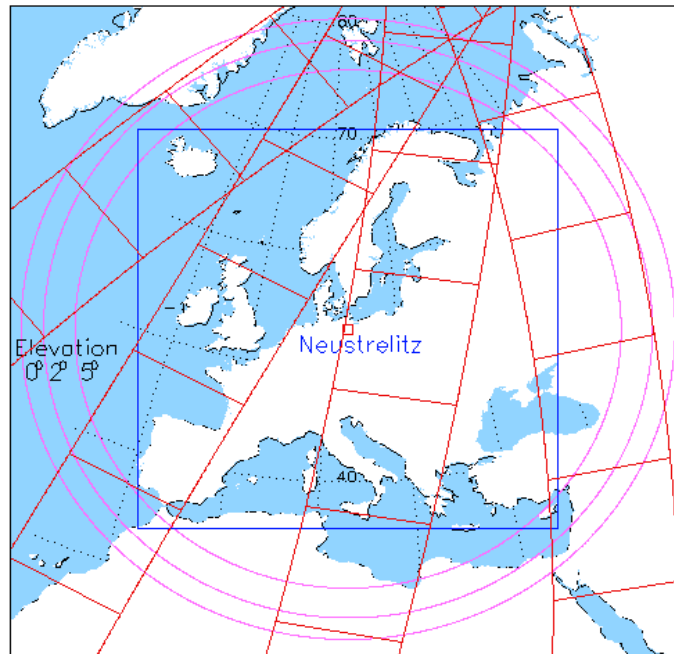


Abbildung 3.1: Typische Lage der MERIS-Pässe über Europa, die in Neustrelitz empfangen werden können.
(Quelle: WDC-RSAT, 19.11.2004)

3.2 Arbeitsgrundlagen

Die Daten des Sensors MERIS sind Grundlagen der Landbedeckungs- / Landnutzungsklassifizierung im Rahmen des Projektes MAPP. In den folgenden Abschnitten werden zum besseren Verständnis dieser Daten zunächst die Sensorplattform ENVISAT sowie der Sensor MERIS und schließlich die für die Klassifizierung genutzten MERIS-Daten beschrieben.

3.2.1 Der europäische Umweltsatellit ENVISAT

Im März 2002 startete die Europäische Raumfahrtbehörde ESA den Umweltsatelliten ENVISAT. Der sonnensynchrone Satellit umkreist die Erde in einer Höhe von 799,8 km mit einer Inklination von 98,55° und einer Wiederholungsfrequenz von 35 Tagen.

Die ENVISAT-Mission hat die Erforschung von Zustand und Veränderung der Umwelt zum Ziel und steht somit in der Tradition der europäischen ERS-Satelliten. Die Themenbereiche globale Erwärmung, Klimaänderung, Ozonabbau und Monitoring von Ozeanen und Eis stehen hierbei im Vordergrund. ENVISAT ist mit zehn Instrumenten zur

Beobachtung von Ozeanen, Landoberfläche, Eis und Atmosphäre ausgestattet. (s. Abbildung 3.2)

Diese Instrumente dienen der Radarfernerkundung (ASAR), der optischen Fernerkundung von Ozean und Land (MERIS, AATSR), der Beobachtung der Atmosphäre (GOMOS, SCIAMACHY, MIPAS) sowie der Höhenmessung (RA-2, MWR, LRR, DORIS). Mit Hilfe dieser Instrumente sind sowohl globale Messungen als auch regional begrenzte, präzise Untersuchungen der Erdoberfläche und der Atmosphäre möglich.

(ESA a, 03.06.2004)




Abbildung 3.2: Der europäische Umweltsatellit ENVISAT mit seinen Instrumenten
(Quelle: ESA & Astrium GmbH 2002, S. 8)

3.2.2 Das Medium Resolution Imaging Spectrometer MERIS

Das Medium Resolution Imaging Spectrometer MERIS ist eines der zehn Instrumente des europäischen Umweltsatelliten ENVISAT. MERIS wurde ursprünglich für die Messung von Ozeanfarben konzipiert, im Laufe seiner Entwicklung wurde er jedoch zusätzlich an die Beobachtung von Landoberflächen- und Atmosphäreigenschaften angepasst.

MERIS kann die von der Erde reflektierte solare Strahlung in 15 Kanälen vom sichtbaren bis zum nahinfraroten Wellenlängenbereich von 390 bis 1040 nm messen. Die Breite und Position der Spektralkanäle können geändert werden, selbst wenn sich der Sensor bereits im Weltraum befindet. Die derzeit im Hinblick auf die wichtigsten Zielsetzungen der Mission festgelegten MERIS-Kanäle und ihre möglichen Anwendungsbereiche sind in Tabelle 3.1 dargestellt.

Tabelle 3.1: Die derzeit festgelegten Spektralkanäle des Sensors MERIS
(Quelle: ESA b, 15.11.2004)

Band Nr.	Bandzentrum [nm]	Bandweite [nm]	Mögliche Anwendungsbereiche	Anmerkung
1	412,5	10	Gelbstoff	
2	442,5	10	Absorptionsmaximum Chlorophyll	
3	490	10	Chlorophyll und andere Pigmente	
4	510	10	Schwebfracht, Rotalgen	
5	560	10	Absorptionsminimum Chlorophyll	
6	620	10	Schwebfracht	
7	665	10	Absorption Chlorophyll & Referenz Fluoreszenz	
8	681,25	7,5	Fluoreszenzpeak Chlorophyll	
9	705	10	Referenz Fluoreszenz, Atmosphärenkorrektur	
10	753,75	7,5	Vegetation, Wolken	
11	760	2,5	Sauerstoffabsorption	nicht Level 2
12	775	15	Atmosphärenkorrektur	
13	865	20	Vegetation, Referenz Wasserdampf	
14	890	10	Atmosphärenkorrektur	
15	900	10	Wasserdampf, Land	nicht Level 2

MERIS gehört zur Gruppe der optoelektronischen Sensoren. Anders als bei optomechanischen Sensoren, bei denen mit Hilfe eines beweglichen Spiegels die Bildpunkte einer Bildzeile nacheinander abgetastet werden, werden hier alle Pixel einer Bildzeile gleichzeitig aufgenommen. MERIS besitzt ein für ein optoelektronisches System außergewöhnlich weites Gesichtsfeld von $68,5^\circ$ und kann so pro Überflug einen 1150 km breiten Streifen der Erdoberfläche abtasten. Dies ist möglich, da das Gesichtsfeld von fünf identischen Kameras mit einem Blickwinkel von je 14° aufgebaut wird, die senkrecht zur Bewegungsrichtung des Satelliten angeordnet sind (s. Abbildung 3.3).




Abbildung 3.3: Aufbau des Sensors MERIS aus 5 Kameras
(verändert nach: ESA b, 15.11.2004)

Jede der fünf Kameras besitzt als Detektor ein Feld von in Zeilen und Spalten angeordneten, lichtempfindlichen Halbleitersensoren, ein so genanntes CCD-Array (s. Abbildung 3.4). Durch die CCD-Elemente kann das auf den Detektor treffende Licht in ein analoges elektrisches Signal gewandelt werden. Das CCD-Feld nimmt eine komplette Bildzeile nach der anderen auf. Das am Sensor ankommende Licht trifft zunächst auf ein Reflexionsgitter (s. Abbildung 3.3). Hier wird es, abhängig von seiner Wellenlänge, unterschiedlich stark in Zeilenrichtung (y) gebeugt und erreicht so das CCD-Feld. Auf jede Zeile des CCD-Feldes trifft der Strahlungsanteil eines bestimmten, genau 1,25 nm breiten Wellenlängenbereiches. Jede Spalte des CCD-Arrays bildet dabei einen etwa 260 m breiten Abschnitt der Erdoberfläche ab. Durch ein CCD-Array wird also gleichzeitig in Zeilenrichtung (x) die räumliche, in Spaltenrichtung (y) dagegen die spektrale Information einer Bildzeile abgebildet.

MERIS nimmt kontinuierlich bei Sonnenzenitwinkeln von weniger als 80° Daten mit einer reduzierten räumlichen Auflösung von 1040 x 1160 m im Nadir für alle Orbits auf. Bei Bedarf werden von ESA zudem für regionale Anwendungen Daten in voller Auflösung von 265 m x 292 m im Nadir angeboten.

(ESA 2002)




Abbildung 3.4: Schematische Darstellung des Aufbaus eines MERIS-Detektors (CCD-Array) (verändert nach: ESA b, 15.11.2004)

3.2.3 Datengrundlage

Von der Europäischen Weltraumbehörde ESA werden standardmäßig verschiedene Arten von MERIS-Daten prozessiert und angeboten. Aufbau, Inhalt und Qualität dieser Daten sind im MERIS Produkt-Handbuch (ESA 2002) detailliert beschrieben. Hier sollen die wichtigsten Informationen zusammengefasst werden.

ESA liefert zum einen MERIS-Daten mit unterschiedlicher räumlicher Auflösung von entweder 265 m x 292 m (*full resolution* – FR) oder 1040 m x 1160 m (*reduced resolution*) im Nadir. Weiterhin bestehen Unterschiede zwischen den angebotenen Datenprodukten bezüglich der Qualität der genutzten externen Zusatzinformationen. Einerseits werden kurz nach Empfang Aufnahmen in *near-real-time* angeboten, die mit Hilfe

vorausberechneter externer Zusatzdaten erstellt wurden. Konsolidierte Daten, deren externe Zusatzinformationen auf präzisen Messungen beruhen, sollen etwa drei Wochen nach Datenaufnahme verfügbar sein. MERIS-Daten werden schließlich in vier unterschiedlichen Qualitätsstufen, den so genannten Produkt-Levels angeboten.

- Level 0-Produkte basieren auf kaum veränderten Rohdaten.
- Level 1b-Produkte sind radiometrisch kalibrierte und georeferenzierte MERIS-Daten. Sie beinhalten nicht atmosphärenkorrigierte *top-of-the-atmosphere* (TOA) Strahldichtewerte in $W / m^2 \cdot sr^{-1} \cdot nm^{-1}$ für die 15 in Tabelle 3.1 aufgelisteten Wellenlängenbereiche.
- Die so genannten Browse-Produkte sind RGB-Bilder aus TOA Strahldichten mit einer Auflösung von 4800 m.
- Level 2-Daten enthalten sowohl Reflexionsgrade für 13 atmosphärisch korrigierte Kanäle (s. Tabelle 3.1) als auch georeferenzierte geophysikalische Parameter.

Die Datengrundlage für die MAPP-Landbedeckungsklassifizierung sind *near-real-time* Level 2-Daten in voller räumlicher Auflösung von 265 m x 292 m im Nadir. Die Szenen der Level 2-FR-Daten sind 575 km x 575 km große Ausschnitte eines MERIS-Passes, die einen Speicherplatz von rund 178 MB benötigen.

Für jedes Pixel werden neben Angaben zur Geolokation sowohl Reflexionsgrade in 13 spektralen Kanälen (s. Tabelle 3.1) als auch unterschiedliche geophysikalische Produkte, wie etwa Algen- oder Vegetationsindizes geliefert. Bei der Berechnung der Reflexionsgrade werden Atmosphäreneinflüsse in Form von Ozon- und Wasserdampfabsorption sowie Rayleigh-Streuung berücksichtigt. Der Einfluss von Aerosolen dagegen wird für Landpixel nicht korrigiert (SANTER et al. 2000).

MERIS-L2-FR-Daten enthalten in einem Gitter von so genannten *tie points* mit einer Maschenweite von 36 Pixeln folgende Zusatzinformationen:

Meteorologische Daten des ECMWF:

- Mittlerer Luftdruck auf Meereshöhe
- Windgeschwindigkeit
- Relative Luftfeuchte
- Gesamtozonsäule

Geographische und geometrische Informationen basierend auf dem WGS 84:

- Geographische Länge und Breite
- Höhe über NN
- Meerestiefe
- Sonnenzenitwinkel
- Sonnenazimutwinkel
- Beobachtungszenitwinkel
- Beobachtungsazimutwinkel

Bei den für die MAPP-LCC verwendeten *near-real-time*-Produkten beruhen die oben angeführten Zusatzdaten auf meteorologischen Prognosen beziehungsweise auf vorausberechneten Orbitdaten des Satelliten.

MERIS-Level 2-FR-Daten verfügen zudem über 29 Flags. Dies bedeutet, dass für jedes Pixel Informationen zu 29 Eigenschaften abfragbar sind. Besitzt ein Pixel für ein bestimmtes Flag den Wert ‚true‘, so trifft die Eigenschaft auf das Pixel zu, ist dagegen der Wert ‚false‘ gesetzt, besitzt das Pixel die betrachtete Eigenschaft nicht. Flags kennzeichnen beispielsweise, ob ein Pixel Wasser, Wolke oder Land abbildet, und ob die Werte eines Pixels ungültig sind.

Die Europäische Weltraumbehörde gibt für die Reflexionsgrade von MERIS-Level 2-Daten über Land einen mittleren Fehler von weniger als 5 % (ESA 2002) und für die Geolokation einen mittleren Fehler von weniger als 2000 m (ESA 2000, S. 213) an.

3.3 Der MERIS-VA-LCC-Prozessor

Diejenige Komponente des MERIS-VA-Prozessors, die für die Durchführung der MAPP-Landbedeckungs- / Landnutzungs-klassifizierung verantwortlich ist, wird als MERIS-VA-LCC-Prozessor bezeichnet. Dieser Prozessor wurde 2001 am DLR konzipiert. Zu diesem Zeitpunkt war ENVISAT noch nicht gestartet, so dass folglich noch keine MERIS-Daten zum Test des Verfahrens zur Verfügung standen.

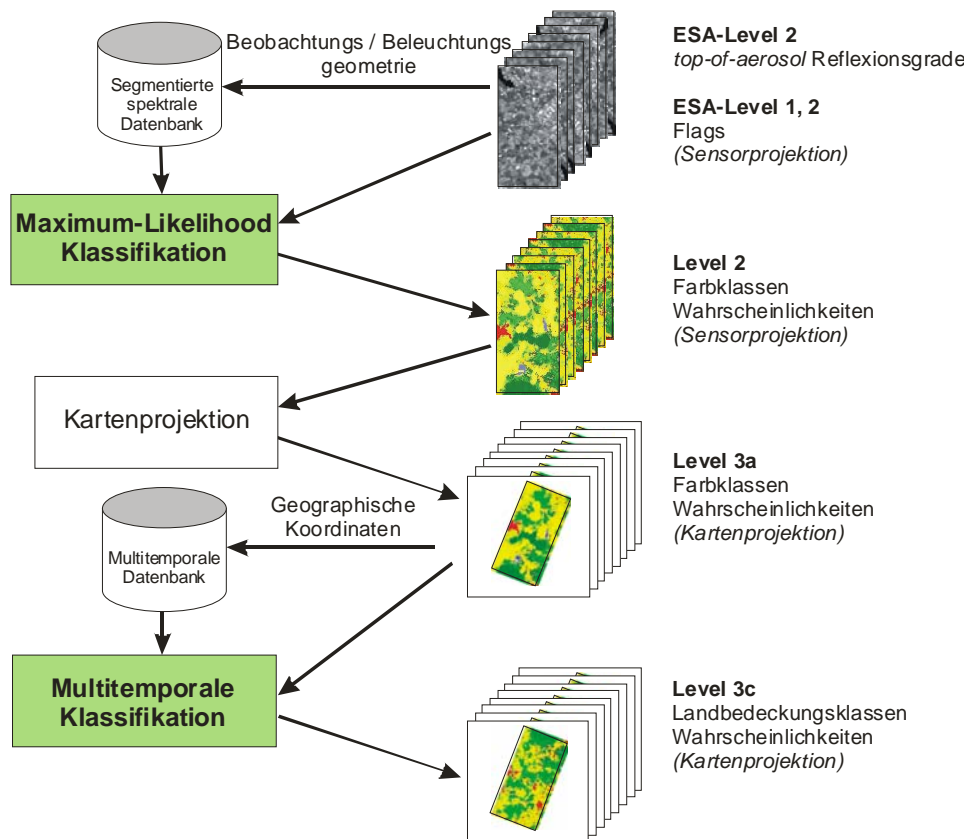


Abbildung 3.5: Schematische Darstellung des Klassifizierungsablaufs der MAPP-LCC (leicht verändert nach GEßNER et al. 2004)

In einem automatisierten Klassifizierungsablauf soll mit Hilfe des MERIS-VA-LCC-Prozessors jährlich eine aktuelle Landbedeckungskarte für Deutschland berechnet werden. Sobald das automatische Klassifizierungsverfahren für Deutschland erfolgreich ablaufen wird, kann eine Erweiterung der Methodik auf die Fläche von ganz Europa stattfinden. Der Klassifizierungsprozess der MAPP-LCC ist in zwei Hauptschritte, eine multispektrale Maximum-Likelihood-Klassifizierung und eine multitemporale Analyse gegliedert (s. Abbildung 3.5).

3.3.1 Der multispektrale Klassifizierungsschritt

Zunächst wird jede einzelne MERIS-Level 2-Szene eines Jahres in einem überwachten Maximum-Likelihood-Verfahren multispektral klassifiziert. Wolken- und Wasserpixel sowie Bildpunkte von geringer Qualität werden mit Hilfe der Level 2-Flags ‚*cloud*‘ und ‚*water*‘ sowie der aus Level 1b-Daten stammenden Flags ‚*invalid*‘ und ‚*suspect*‘ von der Klassifizierung ausgeschlossen.

Die statistischen Parameter der Musterklassen, die für das überwachte Klassifizierungsverfahren nötig sind, werden im MAPP-VA-LCC-Prozessor aus einer spektralen Datenbank abgefragt. Diese Datenbank muss einmalig vor dem Start des MERIS-VA-LCC-Prozessors erstellt werden, und kann für alle jährlichen, automatischen Aktualisierungen der Landbedeckungskarte wieder verwendet werden. Um den in MERIS-Daten auftretenden BRDF-Effekten im multispektralen Klassifizierungsverfahren Rechnung zu tragen, ist die spektrale Datenbank in mehrere Segmente unterteilt. Jedes Segment enthält diejenigen spektralen Informationen der Musterklassen, die für die Aufnahme bei einer bestimmten Kombination aus Beobachtungs- und Beleuchtungswinkelsegmenten typisch sind. Hierbei werden der relative Azimutwinkel φ_{rel} sowie der Sonnenzenitwinkel ϑ_i und der Blickzenitwinkel ϑ_r berücksichtigt (s. Abbildung 2.1). Bei der Zuweisung eines Pixels zu einer Klasse wird lediglich das eine Datenbanksegment abgefragt, das der Winkelkombination des betrachteten Pixels entspricht.

Der multispektrale Verfahrensschritt liefert für jede Szene zwei monotemporale Klassifizierungsergebnisse. Das erste Ergebnis gibt für jedes Pixel die Klasse an, der es mit der höchsten Wahrscheinlichkeit zugeordnet werden kann (Klasse I), das zweite Ergebnis dementsprechend die Klasse mit der zweithöchsten Wahrscheinlichkeit (Klasse II). Für jedes Pixel wird zudem der *separability factor* sf nach Gleichung 3.1 berechnet.

$$sf = \frac{d(x, I)}{d(x, II)}, \quad (\text{Gl. 3.1})$$

wobei	sf:	<i>separability factor</i>
	d(x,I):	Mahalanobis-Distanz zwischen Pixel und Klasse I
	d(x,II):	Mahalanobis-Distanz zwischen Pixel und Klasse II

Geht sf gegen 0, so ist die Zugehörigkeit des Pixels zur Klasse I eindeutig, ist der Wert jedoch nahe 1, so kann nicht klar entschieden werden, ob das Pixel Klasse I oder Klasse II angehört.

Ein variabler Zurückweisungsschwellwert, der so genannte Sigma-Faktor ermöglicht, dass Pixel, die keiner Musterklasse mit einer ausreichend hohen Wahrscheinlichkeit angehören, unklassifiziert bleiben. Für den Sigma-Faktor kann nur ein einziger Wert vorgegeben werden, unterschiedliche Zurückweisungsschwellen für jede Klasse sind also nicht möglich.

Eine Besonderheit der MAPP-Landbedeckungsklassifizierung ist, dass die im multispektralen Schritt unterschiedenen Klassen keine Landbedeckungsklassen, sondern so genannte Farbklassen sind. Diese Farbklassen spiegeln die phänologische Phase der Landbedeckungsklassen für den betrachteten Zeitpunkt wider. Der Betrachtung von Farbklassen liegt die Tatsache zugrunde, dass sich einige Landbedeckungsklassen während bestimmter Zeiträume im Jahr spektral stark ähneln. Diese in einer monotemporalen Betrachtung kaum trennbaren Landbedeckungsklassen werden im ersten Klassifizierungsschritt der MAPP-LCC zu bestimmten Zeitpunkten der gleichen Farbkasse zugeordnet.

3.3.2 Der multitemporale Klassifizierungsschritt

Im zweiten Hauptschritt der MAPP-Klassifizierung werden die monotemporalen Farbklassenergebnisse multitemporal analysiert. Grundlage dieser Auswertung sind die für jede Landbedeckungsklasse charakteristischen Abfolgen von spektralen Farbklassen im Jahresverlauf, die so genannten Referenzvektoren. Im Vorfeld der eigentlichen Klassifizierungsberechnungen muss für jede Landbedeckungsklasse mindestens ein Referenzvektor definiert werden. Bei deutlichen regionalen Unterschieden in der Phänologie bestimmter Klassen sind mehrere Referenzvektoren nötig. Dies wäre beispielsweise bei einem verzögerten Ergrünen von Laubbäumen in Mittelgebirgsregionen der Fall. Gleiches gilt, falls für eine Landbedeckungsklasse alternative Phänologien auftreten können, die nicht direkt von ihrer geographischen Lage abhängen. Ein Beispiel hierfür ist die Phänologie landwirtschaftlicher Flächen, die durch unterschiedliche Bestellungs- und Erntezeitpunkte verschieden ausfallen kann.

Vor der eigentlichen multitemporalen Analyse werden die in Sensorprojektion vorliegenden, monotemporalen Klassifizierungsergebnisse in eine einheitliche Kartenprojektion gebracht (s. Abbildung 3.5). Basierend auf den geographischen Lageinformationen ist so für jedes Pixel die Ermittlung der äquivalenten Bildpunkte in allen anderen monotemporalen Farbklassenkarten möglich. Anschließend wird für jeden Bildpunkt ein Pixelvektor erstellt. Hierzu werden die dem Pixel in jedem einzelnen monotemporalen Klassifikationsergebnis zugewiesenen Farbklassen I und II in ihrer zeitlichen Abfolge dargestellt.

Für jeden Bildpunkt werden anschließend die einzelnen Elemente des Pixelvektors mit den Elementen der Referenzvektoren aller Landbedeckungsklassen verglichen (s. Abbildung 3.6). Für den Fall, dass Klasse I eines Elementes des Pixelvektors mit der

Klasse des entsprechenden Elementes eines Referenzvektors übereinstimmt, ist die Verlässlichkeit V , mit der die betrachteten Elemente übereinstimmen folgendermaßen definiert:

$$V_{cll}(sf) = 1 - 0,5 \cdot sf \quad . \quad (\text{Gl. 3.2})$$

Stimmt dagegen die Klasse II eines Elementes des Pixelvektors mit der Referenz überein, so gilt:

$$V_{cIII}(sf) = 1 - V_{cll}(sf) = 0,5 \cdot sf \quad . \quad (\text{Gl. 3.3})$$

Ist keine Übereinstimmung zwischen den Elementen des Pixel- und des Referenzvektors vorhanden, so gilt: $V = 0$. Das betrachtete Pixel wird schließlich der Landbedeckungsklasse zugewiesen, für deren Referenzvektor die mittlere Verlässlichkeit

$$\bar{V} = \frac{\sum_{i=1}^n V_i}{n} \quad , \quad (\text{G. 3.4})$$

wobei n: Anzahl der Elemente des Referenzvektors
 Vi: Verlässlichkeit der Übereinstimmung für Element i,

maximal ist. Erst in diesem multitemporalen Klassifizierungsschritt werden die Bildpunkte also den eigentlichen Landbedeckungs- beziehungsweise Landnutzungsklassen zugeordnet.

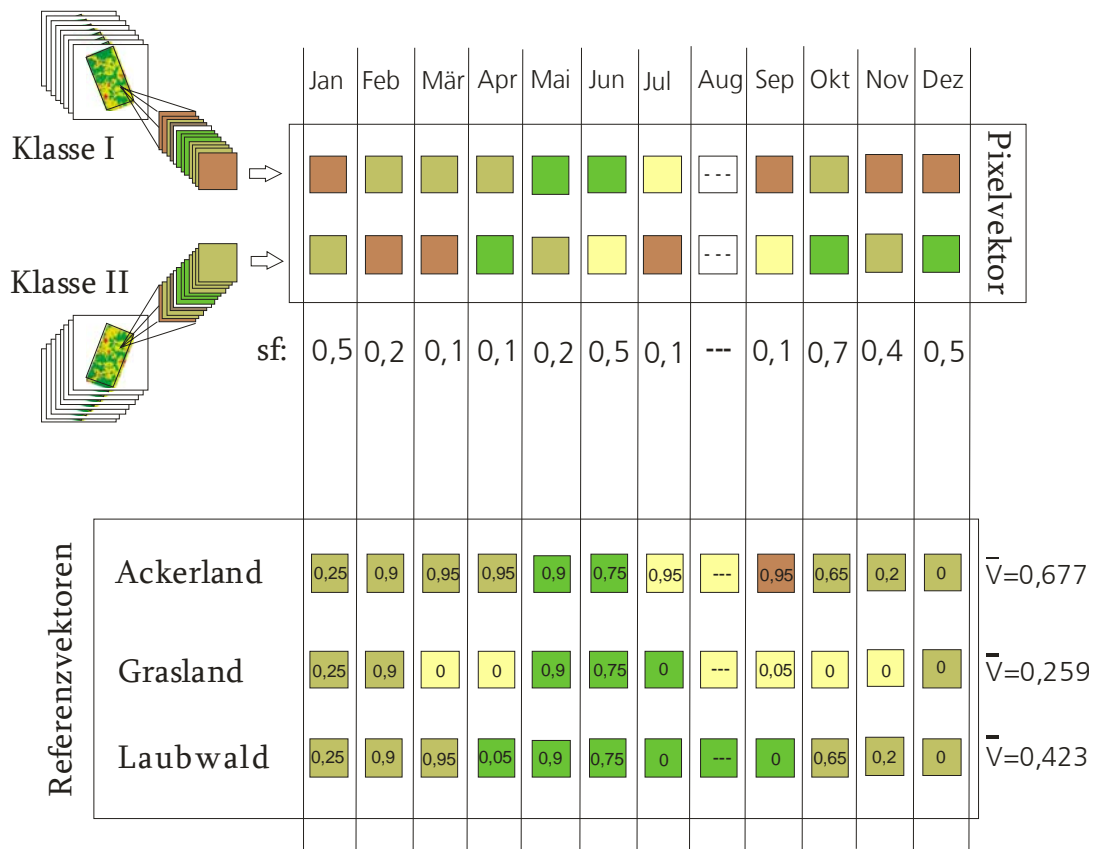


Abbildung 3.6: Vergleich von Pixel- und Referenzvektoren im multitemporalen Klassifizierungsschritt.
 Im Beispiel wird ein Pixelvektor mit drei Referenzvektoren verglichen.
 In den Elementen der Referenzvektoren ist die jeweilige Verlässlichkeit V der Übereinstimmung eingetragen. Der Pixelvektor wird im gegebenen Beispiel der Klasse ‚Ackerland‘ zugewiesen, da er mit dieser Klasse die größte mittlere Verlässlichkeit \bar{V} aufweist.
 (verändert nach GEßNER et al. 2004)

4 Klassifizierungsvorbereitung für den MAPP-VA-LCC-Prozessor

Die Vorbereitung des automatisierten Klassifizierungsverfahrens des MERIS-VA-LCC-Prozessors umfasst mehrere wichtige Punkte. Es handelt sich hierbei zunächst um die Auswahl eines Klassifikationssystems und um die Festlegung und Vorbereitung eines Referenzdatensatzes zur Validierung der Klassifizierungsergebnisse. Für den multispektralen Klassifizierungsschritt ist der Aufbau einer spektralen Datenbank mit Festlegung von Größe und Lage der Winkelsegmente, sowie der Bestimmung von Art und Anzahl der zu berücksichtigenden Farbklassen nötig. Zur Vorbereitung des multitemporalen Klassifizierungsschrittes muss die typische Phänologie aller Landbedeckungs- beziehungsweise Landnutzungsklassen in Form von Referenzvektoren festgehalten werden. Des Weiteren ist es sinnvoll, die Möglichkeit einer Datenreduktion durch das Weglassen von Spektralkanälen zu überprüfen, und mögliche Verbesserungen von Wolkenerkennung und Geolokation der MERIS-Daten aufzuzeigen.

Da der MERIS-VA-LCC-Prozessor bisher noch keinen optimalen Klassifizierungsablauf gewährleistet, können die Ergebnisse dieser vorbereitenden Schritte nicht in Testläufen des Prozessors überprüft werden. Der Schwerpunkt der in diesem Kapitel dargestellten Untersuchungen liegt folglich auf theoretischen Überlegungen.

4.1 Auswahl eines Klassifikationsschlüssels

Zunächst soll ein geeignetes Klassifikationssystem als Ausgangsbasis für die Legende der MAPP-LCC bestimmt werden. ARNDT (2001) schlug im Rahmen seiner Vorbereitungsarbeiten für die MAPP-LCC in diesem Zusammenhang das IGBP-System vor. Seine Entscheidung gründete vor allem auf zwei wesentlichen Vorteilen. So handelt es sich bei dem vorgeschlagenen System um ein fast reines Landbedeckungsklassifikationssystem, das sich folglich auf automatisierte, rechnergestützte Verfahren anwenden lässt. Zudem ist der IGBP-Klassifikationsschlüssel weit verbreitet (z.B. LOVELAND et al. 2000 oder FRIEDL et al. 2002), und ermöglicht somit eine Vergleichbarkeit mit zahlreichen anderen Landbedeckungsdatensätzen.

Einen auf dem Land Cover Classification System LCCS basierenden Klassifikationsschlüssel zog ARNDT bei seiner Wahl nicht in Erwägung. Zum Zeitpunkt seiner Arbeiten wurde das LCCS gerade erst aufgebaut, so dass entsprechende Klassifikationsschlüssel noch nicht weit verbreitet waren. Heute sollte das von FAO und UNEP entwickelte System bei der Wahl eines Klassifikationsschlüssels jedoch unbedingt in Betracht gezogen werden (GOFC-GOLD 2004 a).

Der wohl bekannteste, auf dem LCCS basierende Klassifikationsschlüssel entstand im Rahmen der GLC 2000 (s. Tabelle 2.5). Dieser Klassifikationsschlüssel setzt sich, ebenso wie der IGBP-Schlüssel, fast ausschließlich aus reinen Landbedeckungsklassen zusammen.

Aufgrund der, verglichen mit dem IGBP-Schlüssel, deutlich höheren Flexibilität in der Klassengestaltung ist eine verbesserte Anpassung sowohl an digitale, automatisierte Verfahren als auch an die spezielle räumliche und spektrale Auflösung des genutzten Sensors möglich. Die präzise definierten Klassen der GLC 2000 können bei Bedarf durch leichte Veränderung der Classifier abgewandelt werden, wobei die Klassengrenzen trotzdem nachvollziehbar bleiben. Klassifikationsschlüssel, die auf dem LCCS basieren können zudem recht problemlos miteinander verglichen werden. Die Nutzung des GLC 2000-Schlüssels ermöglicht somit einen Schritt in Richtung einer weltweiten Standardisierung und Harmonisierung von Landbedeckungsdatensätzen.

Wegen der genannten Vorteile, wird der Klassifikationsschlüssel der GLC 2000 dem bisher vorgesehenen IGBP-Schlüssel vorgezogen und als Ausgangsbasis für die Legende der MAPP-LCC vorgeschlagen.

4.2 Erstellen der Legende

Eine Legende entsteht erst durch die Anwendung eines Klassifikationssystems auf ein spezielles Gebiet unter Verwendung eines festgelegten Kartenmaßstabes und eines bestimmten Datensatzes (DI GREGORIO & JANSEN 2000). Bei der Erstellung einer Legende fallen also diejenigen Klassen des Klassifikationsschlüssels weg, die in dem betrachteten Untersuchungsgebiet nicht existieren. Ausgehend vom Klassifikationsschlüssel der GLC 2000 (s. Tabelle 2.5) sind dies für Deutschland die Klassen:

- 1 Immergrüner Laubbaumbestand
- 7 Regelmäßig überfluteter Baumbestand, immergrün, Süß- und Brackwasser
- 8 Regelmäßig überfluteter Baumbestand, immergrün, Salzwasser
- 11 Geschlossener bis offener, immergrüner Strauchbestand
- 14 Offener krautartiger oder strauchartiger Bestand

Weiterhin können all diejenigen Klassen nicht berücksichtigt werden, die aufgrund ihrer geringen räumlichen Ausdehnung im Untersuchungsgebiet mit Daten einer Auflösung von knapp 300 m nicht erfassbar sind. Für Deutschland handelt es sich hierbei um die Klassen:

- 3 Sommergrüner, offener Laubbaumbestand
- 5 Sommergrüner Nadelbaumbestand
- 10 Verbrannter Baumbestand
- 12 Geschlossener bis offener, sommergrüner Strauchbestand

Einige Klassen können zudem aufgrund ihrer mosaikartigen Struktur mit Daten einer räumlichen Auflösung von fast 300 m nicht erkannt werden. Diese setzen sich zu etwa gleichen Anteilen aus zwei bis drei Landbedeckungsklassen zusammen, deren Reflexionseigenschaften sich voneinander grundsätzlich unterscheiden. Die Flächen folgender Klassen werden daher vom Sensor als kaum differenzierbare spektrale

Mischsignaturen aufgezeichnet, und können folglich in der Legende der MAPP-LCC nicht berücksichtigt werden:

- 9 Mosaik aus Baumbestand und anderer natürlicher Vegetation oder landwirtschaftlichen Flächen
- 17 Mosaik aus landwirtschaftlichen Flächen, Baumbestand und anderer natürlicher Vegetation
- 18 Mosaik aus landwirtschaftlichen Flächen und strauchartiger oder krautartiger Vegetation

Die GLC 2000-Klasse 21 ‚Schnee und Eis‘ kann in der MAPP-LCC nicht erfasst werden, da diese Landbedeckung in dem von MERIS abgedeckten Wellenlängenbereich von 412,5 nm bis 900 nm nicht von Bewölkung unterschieden werden kann (KAPPAS 1994, S. 67f.). Schnee- und Eispixel werden folglich im Zuge der Datenvorbereitung als Wolkenpixel erkannt und von der Klassifizierung ausgeschlossen.

Nadel- und Mischwälder treten in Deutschland typischerweise mit einem Kronenschluss von über 40 % auf. Aus diesem Grund werden anstatt der Hauptklassen 4 ‚Immergrüner Nadelbaumbestand‘ und 6 ‚Gemischter Baumbestand‘ die dazugehörigen Unterklassen mit einem Kronenschluss von 40 % bis 100 % gewählt.

Bei der GLC-Klasse ‚landwirtschaftliche Flächen‘ wird der Classifier A23, der für regelmäßig überflutete landwirtschaftliche Flächen steht, weggelassen, da derartige Flächen in Deutschland nicht existieren.

Für die MAPP Landbedeckungs- / Landnutzungskarte von Deutschland werden folglich die in Tabelle 4.1 aufgelisteten Legendeneinheiten berücksichtigt.

4.3 Referenzdaten

4.3.1 Auswahl eines Referenzdatensatzes

Die Nutzung eines bereits vorhandenen, möglichst flächendeckenden Datensatzes als Referenz besitzt deutliche Vorteile gegenüber der Nutzung von Daten aus kleinräumigen Geländeerhebungen. Sind nämlich Referenzdaten für große Teile des Untersuchungsgebietes vorhanden, so können mit Hilfe von Genauigkeitsindizes besonders repräsentative Aussagen für das gesamte Klassifizierungsergebnis getroffen werden. Ein wesentlicher Vorteil bereits existierender Datensätze ist zudem, dass keine zusätzliche, zeit- und kostenaufwendige Datenerhebung im Gelände vorgenommen werden muss.

Relativ aktuelle, flächendeckende Informationen zur Landbedeckung Deutschlands liefert das IGBP-DIS, die PELCOM, die MLCCA-Klassifikation und die Global Land Cover 2000. Die CORINE Land Cover 2000 lag im Oktober 2004 für etwa vier Fünftel der Fläche Deutschlands vor. Aus diesen Datensätzen soll ein Referenzdatensatz für die Validierung der MAPP-LCC, gemäß der in Abschnitt 2.4.4 angeführten Anforderungen, ausgewählt werden.

Bezüglich der räumlichen Auflösung eignet sich von den genannten Datensätzen ausschließlich die CORINE Land Cover, mit einer Erfassungsuntergrenze von 25 ha, als Referenz für die MAPP-Klassifizierung. Alle anderen Datensätze besitzen eine geringere Auflösung als das zu überprüfende Klassifizierungsergebnis. Der CORINE Landbedeckungsdatensatz ist in 44 thematisch stark detaillierte Klassen gegliedert, wobei zu jeder Klasse genaue Definitionen vorliegen (BOSSARD et al. 2000). Es ist also möglich, die CORINE Nomenklatur in die Legende der GLC 2000 zu übersetzen. Des Weiteren ist die CORINE 2000 als Referenzdatensatz geeignet, da sie unabhängig von den zu validierenden Daten der MAPP-LCC entstand, und mit dem Bezugsjahr 2000 derzeit neben der GLC 2000 den aktuellsten Landbedeckungsdatensatz Deutschlands darstellt. Die CORINE 2000 besitzt zudem, aufgrund des ihr zu Grunde liegenden präzisen Klassifizierungsverfahrens, eine als Referenz ausreichend hohe Zuverlässigkeit. Die CORINE Land Cover 2000 erfüllt demnach alle an einen Referenzdatensatz gestellten Anforderungen. Besonders aufgrund ihrer hohen räumlichen Auflösung besitzt sie deutliche Vorteile gegenüber den übrigen in Frage kommenden Karten, und wird deshalb, obwohl sie während der durchgeführten Untersuchungen noch nicht flächendeckend für Deutschland vorliegt, als Referenzdatensatz für die Validierung der MAPP-LCC ausgewählt.

Tabelle 4.1: Auflistung der für die MAPP-LCC in Betracht gezogenen, teilweise leicht veränderten Klassen der GLC 2000 mit den auf die Klassifizierungsvoraussetzungen angepassten LCCS-Formeln und der Kurzbezeichnungen, die im weiteren Verlauf der Arbeit für diese Klassen verwendet werden.
(zusammengestellt aus: JRC-IES 2004 b & JRC-IES 2004 c)

GLC-Klasse	LCCS-Formel	Kurzbezeichnung
2 Sommergrüner, geschlossener Laubbaumbestand	A3A20B2XXD1E2-A21	Sommergrüner Laubwald
4 Immergrüner Nadelbaumbestand, Kronenschluss: 40-100 %	A3A20B2XXD2E1-A21	Immergrüner Nadelwald
6 Gemischter Baumbestand, Kronenschluss: 40-100 %	A3A20B2XXD1-A21// A3A20B2XXD2-A21	Mischwald
13 Geschlossener bis offener krautartiger Bestand	A2A20B4	Grasland
15 Strauchartiger und/oder krautartiger Bestand, regelmäßig überfluteter oder wassergesättigter Boden	A4A20B3C1-R1// A4A20B3C1-R2// A4A20B3C2-R1// A4A20B3C2-R2// A2A20B4C1-R1// A2A20B4C1-R2// A2A20B4C2-R1// A2A20B4C2-R2	Feuchtgebiete
16 Landwirtschaftliche Flächen	A11	Landwirtschaftliche Flächen
19 Vegetationslose und -arme Flächen	B16	Vegetationslose und -arme Flächen
20 Wasserflächen	A1	Wasserflächen
22 Künstliche Oberflächen und zugehörige Flächen	A1	Städtische und bebaute Flächen

Tabelle 4.2: Übersetzung der CORINE Land Cover-Klassen der Ebene 3 in die Klassen der GLC 2000
(eigener Entwurf)

CORINE Ebene 3		GLC 2000	
1.1.1	Durchgängig städtische Prägung	22	Künstliche Oberflächen und zugehörige Flächen
1.1.2	Nicht durchgängig städtische Prägung	22	Künstliche Oberflächen und zugehörige Flächen
1.2.1	Industrie- und Gewerbeflächen	22	Künstliche Oberflächen und zugehörige Flächen
1.2.2	Straßen-, Eisenbahnnetze und funktionell zugeordnete Flächen	22	Künstliche Oberflächen und zugehörige Flächen
1.2.3	Hafengebiete	22	Künstliche Oberflächen und zugehörige Flächen
1.2.4	Flughäfen	22	Künstliche Oberflächen und zugehörige Flächen
1.3.1	Abbauflächen	19	Vegetationslose und -arme Flächen
1.3.2	Deponien und Abraumhalden	22	Künstliche Oberflächen und zugehörige Flächen
1.3.3	Baustellen	22	Künstliche Oberflächen und zugehörige Flächen
1.4.1	Städtische Grünflächen		Übersetzung nicht möglich
1.4.2	Sport- und Freizeitanlagen		Übersetzung nicht möglich
2.1.1	Nicht bewässertes Ackerland	16	Landwirtschaftliche Flächen
2.1.2	Regelmäßig bewässertes Ackerland	16	Landwirtschaftliche Flächen
2.1.3	Reisfelder	16	Landwirtschaftliche Flächen
2.2.1	Weinbauflächen	16	Landwirtschaftliche Flächen
2.2.2	Obst- und Beerenobstbestände	16	Landwirtschaftliche Flächen
2.2.3	Olivenhaine	16	Landwirtschaftliche Flächen
2.3.1	Wiesen und Weiden	13	Geschlossener bis offener krautartiger Bestand
2.4.1	Einjährige Kulturen in Verbindung mit Dauerkulturen	16	Landwirtschaftliche Flächen
2.4.2	Komplexe Parzellenstrukturen	16	Landwirtschaftliche Flächen
2.4.3	Landwirtschaftl. genutztes Land m. Flächen natürlicher Veg. von signifikanter Größe	17	Mosaik aus landwirtschaftlichen Flächen, Baumbestand und anderer natürlicher Vegetation
2.4.4	Land- und forstwirtschaftliche Flächen	9	Mosaik aus Baumbestand und anderer natürlicher Vegetation oder landwirtschaftlichen Flächen
3.1.1	Laubwälder	2	Sommergrüner geschlossener Laubbestand
3.1.2	Nadelwälder	4	Immergrüner Nadelbaumbestand (Kronenschluss: 40-100%)
3.1.3	Mischwälder	6	Gemischter Baumbestand (Kronenschluss: 40-100%)
3.2.1	Natürliches Grünland	13	Geschlossener bis offener krautartiger Bestand
3.2.2	Heiden und Moorheiden	9	Mosaik aus Baumbestand und anderer natürlicher Vegetation oder landwirtschaftlichen Flächen
3.2.3	Hartlaubbewuchs	11	Geschlossener bis offener, immergrüner Strauchbestand
3.2.4	Wald-Strauch-Übergangsstadien	9	Mosaik aus Baumbestand und anderer natürlicher Vegetation oder landwirtschaftlichen Flächen
3.3.1	Strände, Dünen und Sandflächen	19	Vegetationslose und -arme Flächen
3.3.2	Felsflächen ohne Vegetation	19	Vegetationslose und -arme Flächen
3.3.3	Flächen mit spärlicher Vegetation	19	Vegetationslose und -arme Flächen
3.3.4	Brandflächen		Übersetzung nicht möglich
3.3.5	Gletscher und Dauerschneegebiete	21	Schnee und Eis
4.1.1	Sümpfe	15	Strauchartiger und/oder krautartiger Bestand, regelmäßig überfluteter oder wassergesättigter Boden
4.1.2	Torfmoor	15	Strauchartiger und/oder krautartiger Bestand, regelmäßig überfluteter oder wassergesättigter Boden
4.2.1	Salzwiesen	15	Regelmäßig überfluteter strauchartiger und/oder krautartiger Bestand
4.2.2	Salinen	22	Künstliche Oberflächen und zugeordnete Flächen
4.2.3	In der Gezeitenzone liegende Flächen	20	Wasserflächen
5.1.1	Gewässerläufe	20	Wasserflächen
5.1.2	Wasserflächen	20	Wasserflächen
5.2.1	Lagunen	20	Wasserflächen
5.2.2	Mündungsgebiete	20	Wasserflächen
5.2.3	Meere und Ozeane	20	Wasserflächen

4.3.2 Anpassung der Referenz an die MAPP-LCC

Der Landbedeckungsdatensatz CORINE 2000 beruht auf dem in Abschnitt 2.4.1 vorgestellten CORINE-Klassifikationssystem, die MAPP-LCC dagegen auf dem Klassifikationsschlüssel der GLC 2000 (s. Tabelle 2.5). Um einen Vergleich zwischen CORINE 2000 und MAPP-LCC zu ermöglichen, müssen folglich die Legendeneinheiten der beiden Karten aneinander angeglichen werden. Zu diesem Zweck wird eine Übersetzungstabelle (Tabelle 4.2) entwickelt, mit deren Hilfe jede Legendeneinheit der CORINE Land Cover einer Klasse der GLC 2000 zugeordnet werden kann. Im Hinblick auf eine spätere Erweiterung der MAPP-LCC auf die Fläche Europas wird das gesamte CORINE-Klassifikationssystem übertragen, also auch diejenigen Klassen, die in Deutschland nicht vorkommen. Klassen, die keine eindeutigen Rückschlüsse auf die Landbedeckung zulassen, können hier jedoch nicht übersetzt werden. Dies betrifft die CORINE-Legendeneinheiten ‚städtische Grünflächen‘ und ‚Sport- und Freizeitanlagen‘, deren Landbedeckung von Fall zu Fall völlig unterschiedlich ausgeprägt sein kann.

Der aktualisierte CORINE-Datensatz für das Bezugsjahr 2000 war im Oktober 2004 bereits für vier Fünftel der Fläche Deutschlands fertig gestellt. Die eigentlich als Vektordaten konzipierte Karte liegt am DFD auch als Rasterdatensatz mit einer Pixelgröße von 300 m x 300 m vor (UMWELTBUNDESAMT 10/2004). Dieser Datensatz wird gemäß dem in Tabelle 4.2 dargestellten Schema in die Klassen der GLC 2000 übersetzt. Da in ENVI keine Funktion zur Verfügung steht, mit deren Hilfe dieser Arbeitsschritt vorgenommen werden kann, wird der CORINE 2000-Rasterdatensatz in der Programmiersprache IDL auf die Klassen der Global Land Cover 2000 aggregiert und zur weiteren Verarbeitung wieder in ENVI eingelesen.

4.4 Auswahl von Trainingsgebieten

Für den überwachten, multispektralen Klassifizierungsschritt der MAPP-LCC müssen dem Prozessor spektrale Mustersignaturen aller Klassen in Form einer Datenbank zur Verfügung gestellt werden.

Um typische spektrale Signaturen der vorgesehenen Landbedeckungsklassen definieren zu können, werden zunächst für jede Klasse mehrere Flächen als Trainingsgebiete ausgewählt. Hierfür eignen sich vor allem National- beziehungsweise Naturparks und andere Flächen, für die besonders detaillierte Informationen zu Vegetationszusammensetzung, Bedeckungsgrad, Bestandesalter etc. vorliegen. Bei der Wahl der Trainingsgebiete werden bestimmte Kriterien beachtet. Einerseits sollten die Flächen repräsentativ für die jeweilige Landbedeckungsklasse sein und die Variabilität der Ausprägung einer Klasse berücksichtigen. Es werden also beispielsweise für sommergrünen Laubwald Bestände unterschiedlichen Alters und unterschiedlicher Artenzusammensetzung betrachtet. Ein weiteres Kriterium für die Wahl eines Trainingsgebietes ist dessen Homogenität. Um typische spektrale Mustersignaturen zu erhalten, muss das Gebiet flächendeckend von

einer einzigen Klasse eingenommen werden. Kreuzende Verkehrswege, Gewässer oder andere Unregelmäßigkeiten werden daher aus Trainingsgebieten ausgeschlossen. Aus demselben Grund wird darauf geachtet, die Randbereiche von Landbedeckungsklassen nicht als Trainingsgebiete heranzuziehen.

Die als Trainingsgebiete gewählten Flächen werden in allen zur Verfügung stehenden MERIS-Szenen des Zeitraumes Juli 2003 bis August 2004 unter Zuhilfenahme von topographischen Karten, Luftbildern und der CORINE Land Cover identifiziert. Mit Hilfe des Softwarepaketes BEAM werden diese Gebiete als *regions of interest* (ROI) digitalisiert. Aufgrund von Ungenauigkeiten in der Georeferenzierung der bearbeiteten MERIS-Daten (s. Abschnitt 4.7) können die ROI jedoch nicht anhand geographischer Koordinaten definiert und von Szene zu Szene übertragen werden. Vielmehr müssen die Trainingsflächen in jeder Szene erneut visuell identifiziert und per Hand digitalisiert werden. Aus den Daten eines Zeitraumes von mehr als einem Jahr können so für jedes Trainingsgebiet spektrale Informationen extrahiert werden, die unterschiedlichsten Sensorblickwinkeln und Beleuchtungsverhältnissen entsprechen. Ebenso ist es möglich, die Phänologie der Trainingsgebiete für den Zeitraum eines ganzen Jahres zu erfassen.

Obwohl im multispektralen Schritt der MAPP-LCC vorerst Farbklassen unterschieden werden, orientiert sich die Trainingsgebietauswahl an Landbedeckungsklassen. Für die Definition von Trainingsgebieten für bestimmte Farbklassen hätte bereits bekannt sein müssen, welche Farbkategorie eine Landbedeckungskategorie zu einem bestimmten Zeitpunkt im Jahr besitzt. Eine solche Zuordnung ist jedoch erst nach der spektralen Analyse aller Landbedeckungsklassen möglich.

Bei der Wahl der Trainingsgebiete werden alle Landbedeckungsklassen der in Abschnitt 4.2 erarbeiteten Legende berücksichtigt (s. Tabelle 4.1). Ausgenommen ist hierbei lediglich die Klasse ‚Wasserflächen‘, da diese im MAPP-LCC-Prozessor mit Hilfe des Level 2-Wasserflags identifiziert wird, und folglich im Maximum-Likelihood-Verfahren nicht berücksichtigt werden muss.

Für die Klasse ‚landwirtschaftliche Flächen‘ werden Trainingsgebiete gewählt, die sich über mehrere unterschiedlich bewirtschaftete Felder ausdehnen. Auf diese Weise können Mustersignaturen von Mischpixeln erstellt werden, die durch die Reflexionseigenschaften mehrerer Feldfrüchte geprägt sind. Diese Mustersignaturen sind somit repräsentativ für viele landwirtschaftliche Gebiete Deutschlands, die aufgrund ihrer kleinflächigen Anbaustrukturen in Satellitenaufnahmen einer Auflösung von etwa 300 m als Mischpixel dargestellt werden. Die Trainingsgebiete der Klasse ‚landwirtschaftliche Flächen‘ sind folglich nicht, wie oben gefordert, homogen aufgebaut. Da die so gewonnenen Mustersignaturen die typischen spektralen Eigenschaften der genannten Klasse abbilden, verspricht diese Vorgehensweise jedoch, zu guten Ergebnissen zu führen.

In einigen Teilen Deutschlands sind überdurchschnittlich große, einheitlich bestellte landwirtschaftliche Flächen vorhanden. Dies trifft vor allem für Betriebe zu, denen Flächen ehemaliger landwirtschaftlicher Produktionsgenossenschaften angehören, und die dadurch bedingt noch heute besonders großflächige Anbaustrukturen aufweisen. Bei einheitlich bewirtschafteten Schlägen von oftmals deutlich mehr als 100 ha liegen auch in

Daten mit einer räumlichen Auflösung von knapp 300 m Bildpunkte vor, die für die spektralen Eigenschaften einer einzigen Feldfrucht repräsentativ sind. Mit Hilfe von Anbaudaten der DFD-Forschungsfläche Demmin in Mecklenburg-Vorpommern werden daher Versuche unternommen, homogene Trainingsgebiete für unterschiedliche Feldfrüchte zu definieren. Aufgrund der schwankenden Qualität der Georeferenzierung der genutzten MERIS-Daten (s. Abschnitt 4.7) können die Vektordaten der Anbauflächen jedoch nicht ausreichend genau mit den Satellitendaten in Beziehung gesetzt werden. Auch durch visuelle Interpretation ist es nur für wenige Monate möglich, Pixel einheitlicher Feldfrüchte mit zufrieden stellender Sicherheit zu identifizieren. Aus diesem Grund können keine Trainingsgebiete für einzelne Anbaufrüchte definiert werden. In Folge einer erhofften Verbesserung der Georeferenzierung von MERIS-Daten könnte dies jedoch in Zukunft möglich sein.

4.5 Analyse der spektralen Signaturen der Trainingsgebiete

4.5.1 Untersuchung der BRDF-Effekte

Um eine optimale Segmentierung der spektralen Datenbank des MAPP-VA-LCC-Prozessors abschätzen zu können, werden die Art und das Ausmaß der bidirektionalen Reflexionsverteilung auf die spektralen Signaturen der Trainingsgebiete untersucht. Dies geschieht durch den Vergleich von Aufnahmesituationen mit unterschiedlichen, für Mitteleuropa typischen Sonnenzenitwinkeln ϑ_i , Beobachtungszenitwinkeln ϑ_r und relativen Azimutwinkeln zwischen Sensor und Sonne φ_{rel} . Diese Winkel schwanken in MERIS-Aufnahmen von Deutschland typischerweise zwischen den in Tabelle 4.3 angeführten Werten.

Tabelle 4.3: In MERIS-Szenen von Deutschland typischerweise auftretende Schwankungsbereiche von ϑ_i , ϑ_r und φ_{rel} .

Sonnenzenitwinkel ϑ_i :	29° - 81°
Beobachtungszenitwinkel ϑ_r :	0° - 39°
Relativer Azimutwinkel φ_{rel} :	33° - 60° und 120° - 147°

In einem ersten Schritt wird untersucht, wie sich die spektralen Signaturen einzelner Trainingsflächen in unterschiedlichen MERIS-Szenen in Abhängigkeit vom Zenitwinkel des Sensors verändern. Hierfür werden Daten herangezogen, in denen bestimmte Trainingsgebiete bei vergleichbaren Sonnenzenit- und relativen Azimutwinkeln aufgenommen wurden, der Beobachtungszenitwinkel jedoch unterschiedliche Werte annimmt.

Die Abbildungen 4.1 und 4.2 zeigen ein typisches Ergebnis dieser Untersuchungen für ein Trainingsgebiet der Landbedeckungsklasse ‚Grasland‘. Die Diagramme stellen die in Kanal 8 (681,25 nm) und in Kanal 13 (865 nm) gemessenen Reflexionsgrade in Abhängigkeit vom Beobachtungszenitwinkel ϑ_r dar. Kanal 8 steht hierbei stellvertretend

für den sichtbaren, Kanal 13 für den nahinfraroten Wellenlängenbereich. Abbildung 4.1 zeigt Werte für kleine φ_{rel} um 54° , Abbildung 4.2 dagegen die Verhältnisse bei großen relativen Azimutwinkeln von etwa 120° . Für die Werte bei $681,25 \text{ nm}$ ist in beiden Fällen eine Abhängigkeit der Reflexionsgrade vom Blickzenitwinkel kaum erkennbar. Die Reflexionsgrade bei 865 nm steigen jedoch mit dem Sensorblickwinkel ϑ_r an, im Falle der rückwärts gerichteten Reflexionssituation etwas deutlicher als im Falle der vorwärts gerichteten.




Abbildung 4.1: Veränderung der Reflexionsgrade einer Graslandfläche bei $\lambda = 681,25 \text{ nm}$ und $\lambda = 865 \text{ nm}$ in Abhängigkeit vom Beobachtungszenitwinkel. Der Sonnenzenitwinkel liegt zwischen 60° und 70° , der relative Azimutwinkel bei etwa 54° (eigener Entwurf)




Abbildung 4.2: Veränderung der Reflexionsgrade einer Graslandfläche bei $\lambda = 681,25 \text{ nm}$ und $\lambda = 865 \text{ nm}$ in Abhängigkeit vom Beobachtungszenitwinkel. Der Sonnenzenitwinkel liegt zwischen 60° und 70° , der relative Azimutwinkel bei etwa 120° (eigener Entwurf)

Die hier beobachteten Tendenzen entsprechen qualitativ den erwarteten BRDF-Effekten (s. Abschnitt 2.3.2.2). Quantitative Aussagen zum Anstieg des Reflexionsgrades von der Nadirblickrichtung bis zum Szenenrand können jedoch nicht getroffen werden, da dieser Anstieg selbst bei Trainingsgebieten, die derselben Landbedeckungsklasse zugerechnet werden, sehr unterschiedlich stark ausfällt. Für mehrere Trainingsflächen kann sogar überhaupt keine eindeutige Abhängigkeit der Reflexionswerte von ϑ_i festgestellt werden. Schwierigkeiten der beschriebenen Vorgehensweise liegen vor allem darin, dass für einzelne Trainingsgebiete nur wenige Aufnahmen vorliegen, bei denen sowohl Sonnenstand als auch relativer Azimutwinkel konstante Werte aufweisen, während lediglich der Beobachtungszenitwinkel variiert. In vielen Fällen ist daher kaum feststellbar, inwieweit eine Veränderung der Reflexionsgrade auf leichte Variationen der eigentlich als konstant angenommenen Winkel φ_{rel} und ϑ_i zurückzuführen ist, oder ob ein beobachteter Effekt tatsächlich auf dem Einfluss des Blickzenitwinkels beruht.

Die oben dargestellten Schwierigkeiten treten nicht auf, wenn man die spektralen Signaturen mehrerer Flächen gleicher Landbedeckung vergleicht, die während eines einzelnen ENVISAT-Passes über das Untersuchungsgebiet aufgezeichnet wurden. In den Daten eines solchen Überfluges schwankt der Sonnenstand ϑ_i um weniger als 10° . Alle Bildpunkte nordwestlich der Nadirlinie des Sensors werden bei weitgehend unveränderten relativen Azimutwinkeln φ_{rel1} aufgenommen, ebenso wie alle Pixel südöstlich dieser Linie in etwa die gleichen relativen Azimutwinkel φ_{rel2} aufweisen (s. Abbildung 4.3). Hierbei gilt: $\varphi_{rel2} = 180^\circ - \varphi_{rel1}$. Relativer Azimutwinkel und Sonnenzenitwinkel sind also innerhalb der nordwestlichen und innerhalb der südöstlichen Hälfte eines Passes über Mitteleuropa weitgehend konstant, es treten lediglich unterschiedliche Beobachtungszenitwinkel ϑ_i auf.



Abbildung 4.3: Typische Lage von vier MERIS-Szenen eines ENVISAT-Passes über Deutschland. (eigener Entwurf)

Im Folgenden werden die beobachteten BRDF-Effekte anhand der spektralen Signaturen von Nadelwald- und Graslandflächen erläutert. Diese beiden Landbedeckungsklassen repräsentieren, mit dem stark gegliederten Kronendach der Nadelwälder und der vergleichsweise fein strukturierten Oberfläche von Grasland, zwei sehr ungleiche Arten der Bestandesstruktur, an denen sich BRDF-Effekte unterschiedlich auswirken können. Die Abbildungen 4.4 a) bis c) zeigen Reflexionsspektren von 25 Nadelwaldgebieten, die während eines ENVISAT-Passes am 26. September 2003 aufgenommen wurden. Der Sonnenzenitwinkel schwankt in diesen Aufnahmen zwischen 51° und 57° . In Abbildung 4.4 a) sind spektrale Signaturen dargestellt, bei deren Aufnahme der Beobachtungszenitwinkel weniger als 5° betrug. Abbildung 4.4 b) zeigt Reflexionsspektren für relative Azimutwinkel um 125° und Beobachtungszenitwinkel über 30° . In Abbildung 4.4 c) sind schließlich diejenigen spektralen Signaturen zu sehen, die bei relativen Azimutwinkeln von etwa 55° und bei Beobachtungszenitwinkeln zwischen 15° und 30° aufgenommen wurden.




Abbildung 4.4: Spektrale Signaturen von Nadelwaldflächen aus Daten eines MERIS-Passes vom 26.09.2003

- a) Für Beobachtungszenitwinkel $< 5^\circ$
- b) Für Beobachtungszenitwinkel $> 30^\circ$, relativer Azimutwinkel = 125°
- c) Für Beobachtungszenitwinkel 15° – 30° , relativer Azimutwinkel = 55°
- d) Mittlere Signaturen der Pixel aus a) in rot, b) in blau und c) in grün (eigener Entwurf)

Bei jeweils fast völlig identischer Beobachtungs- und Beleuchtungsgeometrie zeigen die Reflexionsspektren der einzelnen Nadelwaldflächen beachtliche Variationen. Die Reflexionsgrade der nahinfraroten Wellenlängen weisen in Abbildung 4.4 a) und b) Schwankungen von bis zu 0,07 auf, in Abbildung 4.4 c) fallen die Unterschiede mit 0,025 jedoch deutlich geringer aus. Die beobachteten Variationen lassen sich vermutlich auf die mehr oder weniger stark ausgeprägten Unterschiede der Nadelwaldflächen bezüglich ihres Laubvegetationsanteils, Bestandesalters, Bedeckungsgrades etc. zurückführen. Die spektralen Signaturen aus Abbildung 4.4 a) und b) schwanken in etwa zwischen den gleichen Extremwerten, die Reflexionsspektren in Abbildung 4.4 c) liegen dagegen insgesamt höher. Abbildung 4.4 d) stellt die mittleren Signaturen für alle drei betrachteten Winkelverhältnisse dar. Hier zeigt sich, dass die mittlere spektrale Signatur aller betrachteten Nadelwaldpixel mit Beobachtungszenitwinkeln kleiner 5° (rot) lediglich 0,025 unter derjenigen für Beobachtungszenitwinkel über 30° und relative Azimutwinkel um 125° (blau) liegt. Die mittlere Reflexionskurve für Beobachtungszenitwinkel zwischen 15° und 30° und relative Azimutwinkel um 55° (grün) liegt dagegen mit 0,05 deutlicher über derjenigen für $\vartheta_r < 5^\circ$.

Ein ähnliches Bild zeigt sich bei der Betrachtung der spektralen Eigenschaften von Grasflächen (Abbildungen 4.5 a) bis d)). Auffällig ist zunächst, dass die Reflexionsgrade der einzelnen Graslandgebiete untereinander weniger stark variieren, als dies für Nadelwälder festgestellt wurde. Die mittleren Reflexionsgrade der bei $\vartheta_r > 30^\circ$ und $\varphi_{\text{rel}} = 125^\circ$ betrachteten Flächen (blau) liegen mit weniger als 0,01 noch geringfügiger unter den bei $\vartheta_r < 5^\circ$ aufgezeichneten, mittleren Werten (rot), als dies bei Nadelwald der Fall ist. Die Mittelvektoren für Beobachtungszenitwinkel zwischen 15° und 30° und relative Azimutwinkel von etwa 55° (grün) weisen dagegen mit 0,03, ähnlich wie bei Nadelwald, etwas stärkere Unterschiede zur Nadirblickrichtung auf.

Für Grasland und Nadelwald können also in MERIS-Daten bei Aufnahmesituationen mit einem relativen Azimutwinkel von 125° keine durch den Beobachtungszenitwinkel hervorgerufenen Veränderungen der Reflexionsgrade von deutlich mehr als 0,025 festgestellt werden. Dieses Ergebnis kann als repräsentativ für die Verhältnisse in Aufnahmesituationen mit großen relativen Azimutwinkeln zwischen 120° und 147° (s. Tabelle 4.3) angesehen werden. Bedenkt man die Schwankungen der Werte für unterschiedlich zusammengesetzte Nadelwälder von bis zu 0,07 und die von ESA angegebenen mittleren Fehler der Reflexionsgrade von 5 %, so wird deutlich, dass der hier beobachtete Einfluss von ϑ_r auf die spektralen Signaturen dagegen vernachlässigbar gering ausfällt. Die dargestellten Beispiele für relative Azimutwinkel von etwa 55° stehen stellvertretend für Aufnahmesituationen mit φ_{rel} zwischen 33° und 60° . Hier fallen die Einflüsse des Beobachtungszenitwinkels auf die spektralen Signaturen mit bis zu 0,05, vor allem für Nadelwälder, stärker als bei vorwärts gerichteten Reflexionsbedingungen aus. Im nahinfraroten Wellenlängenbereich wirken sich die beobachteten BRDF-Effekte deutlicher als in den sichtbaren Kanäle aus, der Einfluss der Beobachtungs- und Beleuchtungsgeometrie auf die Reflexionsgrade in MERIS-Daten weist also eine gewisse Wellenlängenabhängigkeit auf.




Abbildung 4.5: Spektrale Signaturen von Grasflächen aus einer MERIS-Aufnahme vom 26.09.2003

- a) Beobachtungszenitwinkel $< 5^\circ$
- b) Beobachtungszenitwinkel $> 30^\circ$, relativer Azimutwinkel = 125°
- c) Beobachtungszenitwinkel $15-30^\circ$, relativer Azimutwinkel = 55°
- d) Mittlere Signaturen der Pixel aus a) in rot, b) in blau und c) in grün
(eigener Entwurf)

Vergleicht man die hier beobachteten BRDF-Effekte mit den Ergebnissen anderer Untersuchungen zur bidirektionalen Reflexionsverteilung, so zeigen sich gute qualitative Übereinstimmungen. Abbildung 4.6 stellt Reflexionsgrade eines Nadelwaldes in Abhängigkeit des Beobachtungszenitwinkels dar, die von CAMACHO DE COCA (2003) aus Messungen des Sensors POLDER und aus Modellrechnungen des Modells DISMA zusammengestellt wurden. Die hier angeführten Werte sind für einen Sonnenzenitwinkel von 40° gültig, und beziehen sich auf die Reflexionsverhältnisse in der Hauptebene der Reflexion ($\varphi_{\text{rel}1} = 0^\circ$; $\varphi_{\text{rel}2} = 180^\circ$). Es sind hier also stärkere BRDF-Effekte als im oben dargestellten Beispiel der MERIS-Daten, mit relativen Azimutwinkeln von 125° beziehungsweise 55° , zu erwarten.

Die Abbildung zeigt für die vorwärts gerichtete Reflexionssituation ($\varphi_{\text{rel}} = 180^\circ$) sowohl für sichtbare als auch für nahinfrarote Wellenlängen nur eine geringe Abhängigkeit vom Beobachtungszenitwinkel. Stehen Sonne und Sensor in der gleichen Himmelsrichtung, ist also $\varphi_{\text{rel}} = 0^\circ$, so ist die Abhängigkeit vom Beobachtungszenitwinkel deutlicher ausgeprägt. Die von POLDER aufgezeichneten Reflexionsgrade bei 864 nm und die entsprechenden

modellierten Werte verändern sich im dargestellten Beispiel zwischen $\vartheta_r=0^\circ$ und $\vartheta_r=25^\circ$, ebenso wie dies in MERIS-Daten festgestellt werden konnte, um etwa 0,05.




Abbildung 4.6: Reflexionsgrade eines Nadelwaldes für $\lambda = 864$ nm (orange), $\lambda = 670$ nm (rot) und $\lambda = 550$ nm (schwarz) in Abhängigkeit vom Beobachtungszenitwinkel. Der Stern zeigt den Sonnenstand.

Durchgezogene Linien: Messwerte von POLDER

Rauten: Modellrechnungen mit DISMA

(Quelle: CAMACHO DE COCA 2003, S. 33)

Die bisherigen Betrachtungen beziehen sich auf die durch von relativem Azimutwinkel und Beobachtungszenitwinkel abhängigen BRDF-Effekte. Die Auswirkungen des Sonnenzenitwinkels sind schwieriger zu beurteilen, da in Aufnahmen des sonnensynchronen Sensors MERIS deutlich unterschiedliche Sonnenstände nur zu unterschiedlichen Jahreszeiten auftreten. In diesem Zusammenhang muss daher darauf geachtet werden, die Einflüsse des Sonnenzenitwinkels und die Einflüsse der zu einer bestimmten Jahreszeit auftretenden phänologischen Phase der betrachteten Vegetationsbedeckung nicht miteinander zu verwechseln. Die Reflexionsgrade der nahinfraroten Kanäle für Grasland sind beispielsweise für den Monat März grundsätzlich niedriger als für den Monat Mai. Es ist in diesem Fall nicht eindeutig nachvollziehbar, inwieweit der beobachtete Reflexionsanstieg durch den Sonnenzenitwinkel hervorgerufen wird und inwieweit er auf einer phänologischen Veränderung der Grasvegetation beruht. Aus diesem Grund kann die Abhängigkeit der Reflexionsgrade vom Sonnenzenitwinkel lediglich an solchen Trainingsgebieten untersucht werden, deren Spektren nur geringe Schwankungen im Jahreslauf aufweisen. Dies sind insbesondere Flächen, die nicht durch Vegetation geprägt sind. Abbildung 4.7 zeigt das Beispiel einer vegetationslosen Tagebaufläche mit einer relativ rauen Oberflächenstruktur. Die Reflexionsgrade sinken mit steigendem Sonnenazimutwinkel über alle Kanäle hinweg annähernd parallel ab. Die für $\vartheta_i = 75,55^\circ$ besonders niedrig ausfallenden Reflexionsgrade lassen sich durch einen besonders hohen Anteil an Schattenflächen bei der speziellen Kombination aus gegebener Oberflächenrauigkeit und Sonnenzenitwinkel erklären.




Abbildung 4.7: Spektrale Signaturen einer vegetationslosen Tagebaufläche bei variierendem Sonnenstand ϑ_i ($34,57^\circ$ / $45,13^\circ$ / $52,41^\circ$ / $75,55^\circ$).
Der Beobachtungszenitwinkel ist in allen Fällen größer 29° , der relative Azimutwinkel liegt zwischen 35° und 57° .
(eigener Entwurf)

Für vegetationslose Flächen kann also ein Einfluss des Sonnenstandes auf die von MERIS gemessenen Reflexionsgrade festgestellt werden. Alle übrigen, in Betracht gezogenen Landbedeckungs- beziehungsweise Landnutzungsklassen sind durch Vegetation geprägt. In solchen Fällen ist es nicht möglich, Einflüsse des Sonnenzenitwinkels von denen der phänologischen Phasen der Pflanzen klar zu trennen. In Folge dessen ist für die Erstellung von Mustersignaturen eine direkte Berücksichtigung des Sonnenzenitwinkels nicht möglich.

Die Untersuchungen zur Auswirkung des Beobachtungszenitwinkels ϑ_r , des relativen Azimutwinkels φ_{rel} und des Sonnenzenitwinkels auf MERIS-Daten erbringen folgende wichtige Ergebnisse, die bei Segmentierung der spektralen Datenbank der MAPP-LCC berücksichtigt werden müssen.

Für Bildpunkte mit großen relativen Azimutwinkeln von 120° bis 147° (vorwärts gerichtete Reflexionsbedingungen) können nur sehr schwache, von ϑ_r abhängige BRDF-Effekte festgestellt werden. Es ist zu erwarten, dass diese Effekte in vielen Fällen durch die innerhalb einer Klasse auftretenden Variationen, durch nicht korrigierte atmosphärische Einflüsse oder durch sonstige radiometrische Ungenauigkeiten der MERIS-Daten überprägt werden.

Die bei kleinen relativen Azimutwinkeln zwischen 33° und 60° (rückwärts gerichtete Reflexionsbedingungen) auftretenden Reflexionsgrade sind dagegen deutlicher vom Beobachtungszenitwinkel abhängig. Die Stärke dieser Abhängigkeit schwankt von Klasse zu Klasse.

Der Einfluss des Sonnenstandes auf MERIS-Daten ist zwar nachweisbar vorhanden, aber äußerst schwierig vom Einfluss der Phänologie trennbar. Häufig wird es daher sinnvoller

sein, eine zusätzliche Farbklassse für eine bestimmte Periode im Jahresverlauf einzuführen, als eine bestehende Klasse in Bezug auf den Sonnenzenitwinkel weiter zu untergliedern. Aufgrund des beschriebenen Einflusses von Beobachtungs- und Beleuchtungsgeometrie auf MERIS-Daten wird vorgeschlagen, die spektrale Datenbank der MAPP-LCC in die in Tabelle 4.4 dargestellten Segmente zu untergliedern. Segment I, II und III kann hierbei mit denselben spektralen Mustersignaturen gefüllt werden.

Tabelle 4.4: Vorschlag zur Untergliederung der spektralen Datenbank der MAPP-LCC (eigener Entwurf)

Segment I	Segment II	Segment III	Segment IV	Segment V
$120^\circ < \varphi_{\text{rel}} < 147^\circ$ und $5^\circ < \vartheta_r \leq 39^\circ$	$120^\circ < \varphi_{\text{rel}} < 147^\circ$ und $\vartheta_r \leq 5^\circ$	$33^\circ < \varphi_{\text{rel}} < 60^\circ$ und $\vartheta_r \leq 5^\circ$	$33^\circ < \varphi_{\text{rel}} < 60^\circ$ und $5^\circ < \vartheta_r \leq 25^\circ$	$33^\circ < \varphi_{\text{rel}} < 60^\circ$ und $20^\circ < \vartheta_r \leq 39^\circ$

4.5.2 Definition der zu berücksichtigenden Farbklassen

Zur Untersuchung der Reflexionseigenschaften der in Betracht gezogenen Landbedeckungs- / Landnutzungsklassen, werden die spektralen Signaturen aller Trainingsgebiete graphisch dargestellt, chronologisch sortiert und miteinander verglichen. Anhang A zeigt für jede Landbedeckungs- / Landnutzungsklasse typische Reflexionskurven im Jahresverlauf. Bei den dargestellten spektralen Signaturen werden nicht spezielle Beobachtungs- und Beleuchtungsverhältnisse berücksichtigt, die Werte sind ein bis drei Trainingsgebieten mit jeweils unterschiedlichen Winkelverhältnissen entnommen. Durch den Vergleich der Reflexionskurven aller Trainingsgebiete kann festgestellt werden, zu welchen Zeitpunkten sich die betrachteten Klassen spektral ähneln, und wann die Spektren einzelner Klassen voneinander eindeutig unterscheidbar sind. Mit Hilfe dieser Feststellungen kann abgeschätzt werden, welche Farbklassen im monotemporalen Klassifizierungsschritt zu berücksichtigen sind.

Die Landbedeckungsklasse ‚vegetationslose und –arme Flächen‘ ist gekennzeichnet durch einen kontinuierlichen Anstieg der Reflexionsgrade über das gesamte betrachtete Spektrum hinweg. Diese Landbedeckungsklasse tritt in helleren und dunkleren Varianten auf (s. Anhang A.1 & A.2). Der Grund für die mehr oder weniger starken Reflexionseigenschaften dieser Flächen, sind vor allem deren unterschiedlicher Gehalt an humosem Material und deren mineralische Zusammensetzung einschließlich Art und Menge der vorhandenen Eisenoxide sowie deren Wassergehalt. Die betrachtete Landbedeckungsklasse weist wegen des fehlenden Vegetationseinflusses keine phänologischen Veränderungen im Jahresverlauf auf und muss daher mit Hilfe von nur einer Farbklassse pro Helligkeitsvariante berücksichtigt werden. Eine Einteilung in mindestens zwei Farbklassen ‚hellbraun‘ und ‚dunkelbraun‘ wird als sinnvoll erachtet.

Die Landbedeckungsklasse ‚immergrüner Nadelwald‘ zeigt von September bis April gleich bleibende Reflexionseigenschaften (s. Anhang A.3). Diese sind durch sehr niedrig liegende

Reflexionsgrade in den Kanälen 1 bis 8 gekennzeichnet. Selbst bei 550 nm bis 570 nm (Kanal 5), dem Spektralbereich mit den niedrigsten spezifischen Absorptionskoeffizienten von Chlorophyll a und b (s. Abbildung 2.3), übersteigen die Reflexionsgrade kaum 5 %. Zum Nahinfrarot hin steigen die Reflexionsgrade auf etwa 15 % bis 18 % in Kanal 14 an. Diese spektrale Signatur wird im Folgenden die Farbklasse ‚dunkelgrün‘ repräsentieren. Für die Monate Mai bis August steigen die Reflexionsgrade um 560 nm leicht über 5 %, in den nahinfraroten Kanälen 10, 12, 13 und 14 auf Werte zwischen 20 % und 25 %. Diese Reflexionskurven werden der Farbklasse ‚mittelgrün‘ zugeordnet.

Die spektralen Signaturen der Landbedeckungsklasse ‚sommergrüner Laubwald‘ unterliegen deutlichen Veränderungen im Jahresverlauf (s. Anhang A.4). Von November bis Anfang April zeigt sich ein recht einheitliches Bild mit großer Ähnlichkeit zur Farbklasse ‚dunkelbraun‘. Der einzige Unterschied besteht hier in etwas niedrigeren Reflexionsgraden in Kanal 7 und 8, die auf einen sehr geringen Anteil an chlorophyllhaltiger Vegetation hinweist. Ob diese spektrale Signatur im Klassifizierungsverfahren des MAPP-VA-LCC-Prozessors von der Farbklasse ‚dunkelbraun‘ trennbar ist, kann allerdings erst durch Testläufe des Prozessors sicher geklärt werden. Die Farbklasse eines Laubwaldes von November bis Anfang April soll hier zunächst ‚dunkelbraun mit wenig grün‘ genannt werden. Ab etwa Mitte April wird das Ergrünen der Laubbäume und des Unterwuchses, das bis September anhält, sichtbar. Dies äußert sich in einem Anstieg der Reflexionsgrade um 560 nm auf 5 % bis 8 % und noch deutlicher durch das Ansteigen der Werte in den Kanälen 10, 12, 13 und 14. In Kanal 14 erreichen die Reflexionsgrade hier Werte zwischen 30 % und gut 40 %. Diese spektrale Signatur wird der Farbklasse ‚grün‘ zugeordnet. Die Reflexionskurven der Monate April und Oktober bilden einen fließenden Übergang zwischen den Farbklassen ‚grün‘ und ‚dunkelbraun mit grün‘.

Auch die Klasse ‚Mischwald‘ weist deutliche Schwankungen im Jahresverlauf auf (s. Anhang A.5). Von November bis Anfang April besitzt diese Landbedeckungsklasse die spektralen Eigenschaften der Farbklasse ‚dunkelgrün‘. Diese Tatsache lässt sich durch die starke Prägung der Reflexionskurven durch Nadelbäume im Winterhalbjahr erklären. Mit dem ab Ende April sichtbaren Ergrünen der Laubbäume kann die Klasse ‚Mischwald‘ bis Anfang September entweder der Farbklasse ‚grün‘ oder der Farbklasse ‚mittelgrün‘ zugeordnet werden. Die Farbklasse hängt hier vom Laub- beziehungsweise Nadelbaumanteil des betrachteten Bestandes ab. Von Mitte September bis in den Oktober sind gemischte Baumbestände der Farbklasse ‚mittelgrün‘ zuzuordnen.

Die Landbedeckungsklasse ‚Grasland‘ besitzt das gesamte Jahr über recht konstante spektrale Eigenschaften mit Reflexionsgraden bei 560 nm von 7 % bis gut 10 % und sehr hohen Reflexionswerten in den nahinfraroten Wellenlängenbereichen (s. Anhang A.6). Für die Monate Oktober bis März besitzt Grasland die spektralen Eigenschaften der Farbklasse ‚grün‘. Für die Monate April bis September liegen die Reflexionsgrade in den nahinfraroten Kanälen höher als in den Wintermonaten. In Kanal 14 sind Reflexionsgrade von etwa 37 % bis etwas über 40 % zu verzeichnen. Grasland wird daher für April bis September der Farbklasse ‚hellgrün‘ zugeordnet.

Die Klasse ‚städtische und bebaute Flächen‘ weist für Oktober bis März über den gesamten Spektralbereich von MERIS hinweg fast konstante Reflexionsgrade auf, die von Kanal 1 bis Kanal 14 um nur knapp 5 % ansteigen (s. Anhang A.7). Diese Reflexionskurven unterscheiden sich von der Farbklasse ‚dunkelbraun‘ lediglich durch geringfügig niedrigere Werte in den Kanälen 13 und 14. Aufgrund dieser nur sehr leichten Unterschiede können sie ebenfalls der Farbklasse ‚dunkelbraun‘ zugeordnet werden. Von April bis September treten in den spektralen Signaturen Vegetationseinflüsse hervor, der Anteil der vegetationslosen, bebauten Flächen bleibt jedoch weiterhin erkennbar. Das durch Chlorophyll hervorgerufene relative Maximum bei 560 nm sowie das relative Minimum bei 681,25 nm werden hier durch die Reflexionswerte der vegetationslosen Flächen überprägt, die typischerweise über das gesamte Spektrum hinweg konstant ansteigen. Die Farbklasse, der städtische und bebaute Gebiete von April bis September angehören, wird als ‚braun mit wenig grün‘ bezeichnet.

Gerade im Frühjahr, Herbst und Winter werden die spektralen Signaturen der Landbedeckungsklasse ‚Feuchtgebiete‘ durch das Reflexionsverhalten von Boden mit einem typischerweise hohem Humusgehalt geprägt (s. Anhang A.8). Gleichzeitig zeigen sich in Kanal 8, im Wellenlängenbereich starker Chlorophyllabsorption, leichte Vegetationseinflüsse. Von Ende September bis Anfang Mai wird die Klasse ‚Feuchtgebiete‘ daher der Farbklasse ‚dunkelbraun mit wenig grün‘ zugeordnet. Von Ende Mai bis September sind Feuchtgebiete deutlicher durch Vegetation geprägt und besitzen spektrale Signaturen, die der Farbklasse ‚mittelgrün‘ zuzuordnen sind.

Die Klasse ‚landwirtschaftliche Flächen‘ kann, je nach angebauter Feldfrucht und nach Bewirtschaftungsmethode, sehr unterschiedliche Jahresgänge der spektralen Signaturen aufweisen. An dieser Stelle wird beispielhaft ein Trainingsgebiet im Dungau beschrieben, dessen Reflexionseigenschaften durch Mischpixel gekennzeichnet sind, und somit für viele landwirtschaftliche Gebiete Deutschlands als repräsentativ angesehen werden können (s. Anhang A.9). Die Mischpixel sind hauptsächlich durch die Reflexionseigenschaften von Wintergetreide, Hackfrüchten und Raps gekennzeichnet. Die spektralen Signaturen des Zeitraums November bis Anfang März können der Farbklasse ‚braun mit wenig grün‘ zugerechnet werden. Sie sind geprägt durch die spektralen Eigenschaften von Boden mit einem geringen Vegetationsanteil. Von März bis Juni nimmt das Bodensignal durch den zunehmenden Bedeckungsgrad der Feldfrüchte immer mehr ab, was sich in einem Absinken der Reflexionsgrade in Kanal 7 und 8, und einem gleichzeitigen Anstieg der Reflexionen im nahinfraroten Wellenlängenbereich und bei 560 nm äußert. Von Ende März bis Mai entsprechen daher die spektralen Signaturen der Farbklasse ‚braun mit grün‘. Auch im September und Anfang Oktober, wenn die Ernte schon teilweise vonstatten gegangen ist, weisen landwirtschaftliche Flächen diese Farbklasse auf. Von Juni bis Mitte Juli, bei einem hohen Bedeckungsgrad durch Hackfrüchte, Raps und Getreide, verschwinden die Bodencharakteristika in den Reflexionskurven völlig. Je nach Anteil der beteiligten Feldfrüchte treten zu dieser Zeit die Farbklassen ‚grün‘ oder ‚hellgrün‘ auf. Die spektralen Signaturen für Ende Juli und Anfang August zeichnen sich durch das Nebeneinander von reifem Getreide, bereits geernteten, vegetationslosen Feldern und den

grünen Blättern der Hackfrüchte aus. Sowohl die grüne Vegetation als auch das chlorophyllarme, reife Getreide tragen zu hohen Reflexionsgraden bis zu über 40 % im nahinfraroten Wellenlängenbereich bei. Die grünen Pflanzenbestände sorgen für eine schwächere Absorption bei 560 nm, wobei jedoch das Absorptionsmaximum von Chlorophyll bei 681,25 nm durch das Bodensignal der abgeernteten Felder überprägt wird. Die beschriebene Farbklasse wird als ‚grün mit gelb und braun‘ bezeichnet. Einzelne Pixel, die fast ausschließlich abgeerntete Felder abbilden, weisen spektrale Signaturen auf, die der Farbklasse ‚hellbraun‘ sehr ähnlich sind. Sie unterscheiden sich lediglich durch einen etwas deutlicheren Reflexionsanstieg in den von 681,25 nm bis 753,75 nm und werden im Folgenden der Farbklasse ‚hellbraun mit wenig grün‘ zugeordnet.

Grundsätzlich ist zu berücksichtigen, dass alle beschriebenen Farbklassen in den Wintermonaten auch in einer von Schnee beeinflussten Variante auftreten können. Die durch Schneebedeckung geprägten spektralen Signaturen zeichnen sich durch insgesamt höher liegende Reflexionsgrade aus, was besonders in den Kanälen 1 bis 4 zum Tragen kommt. Beispiele hierfür sind in Anhang A, Abbildung A.1 (Dezember), Abbildung A.2 (Dezember), Abbildung A.5 (Januar) und Abbildung A.7 (Januar) zu sehen.

In Tabelle 4.5 sind die Farbklassen zusammengefasst, die für den multispektralen Klassifizierungsschritt im MAPP-VA-LCC-Prozessor vorgeschlagen werden.

Tabelle 4.5: Für den multispektralen Klassifizierungsschritt vorgeschlagene Farbklassen (eigener Entwurf)

hellbraun
dunkelbraun
dunkelgrün
mittelgrün
dunkelbraun mit wenig grün
grün
braun mit wenig grün
hellgrün
braun mit grün
grün mit gelb und braun
hellbraun mit wenig grün

4.5.3 Definition von Referenzvektoren

Aus den Überlegungen des vorangegangenen Kapitels kann für jede in Betracht gezogene Landbedeckungs-/ Landnutzungsklasse mindestens eine typische zeitliche Abfolge von Farbklassen im Jahresverlauf festgelegt werden. Diese typischen Farbklassenabfolgen, die so genannten Referenzvektoren, sind für die Durchführung des multitemporalen Klassifizierungsschrittes im MAPP-LCC-Prozessor nötig.

In Tabelle 4.6 sind Referenzvektoren in monatlichen Zeitschritten für jede Landbedeckungs-/ Landnutzungsklasse aufgelistet. Teilweise können in einem Monat,

alternativ oder aufeinander folgend, mehrere Farbklassen auftreten. In solchen Fällen sind alle Möglichkeiten durch Schrägstriche getrennt angeführt.

Voraussetzung für die Nutzbarkeit der dargestellten Referenzvektoren ist, dass im monotemporalen Klassifizierungsschritt des MAPP-VA-LCC-Prozessors alle hier berücksichtigten Farbklassen voneinander trennbar sind. Dies konnte jedoch bisher nicht überprüft werden, da der Prozessor bis zum Abschluss der vorliegenden Untersuchungen noch keine auswertbaren Klassifizierungsergebnisse lieferte. Aus diesem Grund ist es bisher nicht sinnvoll, die Referenzvektoren in kleinere Zeitschritte zu untergliedern. Viele phänologische Veränderungen, wie beispielsweise die Blattentfaltung von Laubbäumen oder die Ernte von landwirtschaftlich genutzten Flächen, führen jedoch innerhalb einer Zeitspanne von deutlich weniger als einem Monat zu beachtlichen Veränderungen der spektralen Eigenschaften bestimmter Klassen. Daher erscheint es sinnvoll, die Referenzvektoren, nach erfolgten Testklassifizierungen mit dem MAPP-VA-LCC-Prozessor, in Zeitschritte von etwa zehn Tagen zu untergliedern.

Tabelle 4.6: Referenzvektoren für die multitemporale Analyse im MAPP-VA-LCC-Prozessor. Die angegebenen Zahlen stehen für folgende Farbklassen: (eigener Entwurf)

1: hellbraun	7: braun mit wenig grün
2: dunkelbraun	8: hellgrün
3: dunkelgrün	9: braun mit grün
4: mittelgrün	10: grün mit gelb und braun
5: dunkelbraun mit wenig grün	11: hellbraun mit wenig grün
6: grün	

Klasse	J	F	M	A	M	J	J	A	S	O	N	D
Immergrüner Nadelwald	3	3	3	3	3/4	3/4	4/3	4/3	3	3	3	3
Sommergrüner Laubwald	5/2	5/2	5/2	5/6	6	6	6	6	6	6/5	5/2	5/2
Mischwald	3	3	3	3/4/6	4/6	4/6	4/6	4/6	4/6	4/3	3	3
Grasland	6	6	6	8	8	8	8	8	8	6	6	6
Feuchtgebiete	5	5	5	5	5/4	4	4	4	4/5	5	5	5
Landwirtschaftliche Flächen	7	7	7/9	9	9	6/8	6/8/10	10/11	9	9/7	7	7
Städtische & bebaute Flächen	2	2	2	2/7	7	7	7	7	7	2	2	2
Vegetationslose & -arme Flächen I	1	1	1	1	1	1	1	1	1	1	1	1
Vegetationslose & -arme Flächen II	2	2	2	2	2	2	2	2	2	2	2	2

4.5.4 Kanalauswahl

Die Anzahl der in einer multispektralen Klassifizierung berücksichtigten Spektralkanäle hat großen Einfluss auf die zu bearbeitende Datenmenge und somit auf den Rechenzeitbedarf. Es ist daher sinnvoll, lediglich eine Auswahl der verfügbaren Kanäle in die Berechnungen einzubeziehen.

Um allerdings die Qualität der Klassifizierung nicht zu vermindern, dürfen nur diejenigen Spektralkanäle unberücksichtigt bleiben, die kaum oder gar nicht zur Klassentrennbarkeit

beitragen. Dies sind zum einen diejenigen Spektralkanäle, die mit mindestens einem anderen Kanal in den spektralen Signaturen aller betrachteten Klassen stark korrelieren. Um die Korrelationen zwischen den MERIS-Kanälen zu untersuchen, werden für neun Trainingsgebiete unterschiedlicher Landbedeckung Korrelationsmatrizen erstellt (s. Anhang B). Bei der Analyse dieser Matrizen wird deutlich, dass zwischen benachbarten Kanälen in fast allen Fällen starke Abhängigkeiten bestehen. Eine Ausnahme stellt hier lediglich Kanal 9 dar, der besonders bei Klassen mit Vegetationseinfluss verhältnismäßig geringe Korrelationen, auch zu benachbarten Kanälen aufweist. Besonders starke Korrelationen bestehen vor allem zwischen Kanal 7 und 8, zwischen Kanal 10 und 12 sowie zwischen Kanal 13 und 14. Hier liegen die Korrelationskoeffizienten für alle betrachteten Klassen bei mindestens 0,985.

Spektralkanäle, deren Informationsgehalt in bedeutendem Umfang von anderen Faktoren als den Reflexionseigenschaften der zu unterscheidenden Klassen bestimmt wird, tragen ebenfalls kaum zur Klassentrennbarkeit bei. Die Berücksichtigung solcher Kanäle kann das Klassifizierungsergebnis sogar verschlechtern. Bei MERIS-Daten der Landoberfläche spielt in diesem Zusammenhang vor allem der nicht korrigierte Aerosoleinfluss eine Rolle. Da die durch Aerosole hervorgerufene Mie-Streuung im mittleren Regelfall proportional zu λ^α , mit $-1,5 < \alpha < -1$ ist (ROEDEL 1992, S. 26), sind besonders die Kanäle mit kleinen Wellenlängen durch Streuungseffekte der Aerosole geprägt. Der Aerosoleinfluss wirkt sich daher besonders in den Kanälen 1 bis 3 aus, und überprägt hier teilweise deutlich die von der Landoberfläche reflektierte Strahlung.

Für den multispektralen Klassifizierungsschritt der MAPP-LCC wird aus den oben genannten Gründen die Berücksichtigung der MERIS-Kanäle 4, 5, 6, 8, 9, 10 und 13 vorgeschlagen. Die Bänder 1, 2, 3, 7, 12 und 14 können bei der Klassifizierung der Landbedeckung beziehungsweise Landnutzung Deutschlands vermutlich ohne erkennbare Verschlechterung der Klassentrennbarkeit vernachlässigt werden. Diese Annahmen sollten jedoch im Rahmen weiterer Untersuchungen mittels Testklassifizierungen überprüft werden.

4.6 Alternative Möglichkeiten der Wolkenerkennung

Im MAPP-VA-LCC-Prozessor ist bisher vorgesehen, bewölkte Pixel mit Hilfe des Wolkenflags der MERIS-Level 2-Daten von der Klassifizierung auszuschließen. Ein Pixel ist in Level 2-Daten jedoch nur dann mit einem Wolkenflag markiert, wenn für diesen Bildpunkt so genannte Wolkenprodukte (z.B. die optischen Dicken der Wolken oder die Wolkenalbedo) vorhanden sind. Im Laufe der Untersuchungen stellte sich heraus, dass dieses Flag nur Bereiche mit sehr dichten Wolken markiert. Dünnere Wolken und dunstige Bereiche, die Klassifizierungsergebnisse deutlich verschlechtern, sind dagegen nicht als Wolke gekennzeichnet. Aus diesem Grund wird nach alternativen Möglichkeiten zur Erkennung bewölkter und dunstiger Pixel gesucht.

In einem ersten Versuch werden die Wolkenpixel mit Hilfe einer überwachten Maximum-Likelihood-Klassifizierung identifiziert. In mehreren Testklassifizierungen stellt sich

heraus, dass die beste Wolkenerkennung auf Grundlage von nur vier Klassen, nämlich ‚Land und Wasser, wolkenlos‘, ‚Wasser, leicht bewölkt‘, ‚Land, leicht bewölkt‘ und ‚dichte Bewölkung‘ zu erzielen ist. Abbildung 4.8 zeigt ein gutes Ergebnis dieser Wolkenerkennung am Beispiel einer MERIS-Szene vom 21. April 2004. Schwierigkeiten ergeben sich bei dieser Methode durch die, je nach bearbeiteter Szene, stark schwankende Qualität der Ergebnisse.




Abbildung 4.8: Wolkenidentifizierung mit Hilfe einer Maximum-Likelihood-Klassifizierung.
 Links: MERIS-L 2-FR-Szene vom 21.04.2004
 Rechts: Ergebnis der Wolkenidentifizierung für diese Szene. Dichte Bewölkung ist in gelb eingefärbt, leicht bewölktes Land in hellblau und leicht bewölktetes Wasser in dunkelblau.
 (eigener Entwurf)

In einem zweiten Versuch der Wolkenerkennung wird eine einfache Schwellwertbildung in Kanal 1 bei 412,5 nm vorgenommen. In diesem Wellenlängenbereich weisen alle Land- und Wasseroberflächen sehr niedrige Reflexionsgrade auf, Wolken und Dunst dagegen etwas höhere. Es zeigt sich, dass Pixel, deren Reflexionsgrad in MERIS-Level 2-Szenen bei 421,5 nm über 10 % liegt, meist dunstig oder bewölkt sind. Lediglich schnee- und eisbedeckte Gebiete und sehr helle, vegetationslose Flächen liegen in Kanal 1 ebenfalls über diesem Schwellenwert. Da Schnee und Eis in der MAPP-LCC ohnehin nicht berücksichtigt werden können (s. Kapitel 4.2) und sehr helle, vegetationslose Flächen in Deutschland nur kleinräumig existieren (z.B. Sandstrände der Nordseeküste), kann ein Reflexionsgrad von 10 % als Schwellenwert für die Wolkenerkennung in Kanal 1 herangezogen werden. Die untersuchte Methode maskiert tendenziell eher wolkenfreie

Pixel aus, als dass sie leicht bewölkte Pixel zur Klassifizierung zulässt. Diese Tendenz kann als positiv bewertet werden, da auch nur leicht bewölkte Pixel das Klassifizierungsergebnis deutlich verschlechtern können. Zudem sind bei einer zukünftigen Auswertung von MERIS-Daten eines ganzen Jahres ausreichend große Datenmengen vorhanden, um auf einige fälschlicherweise ausmaskierte Pixel verzichten zu können.

Eine weitere Verbesserungsmöglichkeit der Wolkenerkennung im MAPP-VA-LCC-Prozessor ist die Maskierung der Wolken durch das Flag ‚bright‘ der MERIS-Level 1b-Daten. Dieses Flag markiert zwar nicht alle schwach bewölkten Pixel, allerdings doch deutlich mehr als das bisher genutzte Wolkenflag der Level 2-Daten. Durch die Nutzung des Flags ‚bright‘ könnte also eine leicht umsetzbare Verbesserung der Wolkenmaskierung im MAPP-VA-LCC-Prozessor erzielt werden.

4.7 Untersuchung der Georeferenzierung

Präzise georeferenzierte Daten sind für die multitemporale Analyse im MAPP-Prozessor unbedingt erforderlich. Eine korrekte Geolokation ist besonders von Bedeutung, wenn die Datenanalyse, wie bei der MAPP-LCC, automatisiert ablaufen soll, da in diesem Fall keine Korrektur durch *ground control points* vorgenommen werden kann. Schon eine Abweichung von ein bis zwei Pixeln kann zu deutlichen Verschlechterungen des multitemporalen Analyseergebnisses führen. Nach Angaben der MERIS Scientific Advisory Group wird für Landanwendungen mit MERIS eine Genauigkeit der Geolokation von 600 m als vertretbar angesehen (ESA 1995, S. 24). Der mittlere Fehler von MERIS-Daten in voller Auflösung beträgt nach Angaben der ESA weniger als 2000 m (ESA 2000, S. 213).




Abbildung 4.9: Der Tharandter Wald bei Dresden in drei MERIS-L 2-FR-Szenen mit unterschiedlicher Georeferenzierungsqualität. In den drei Abbildungen markieren die roten Flächen die nach geographischen Koordinaten korrekte Position der im Satellitenbild dunkel erscheinenden Nadelwaldfläche.

Links: Korrekte Georeferenzierung

Mitte: Abweichung um etwa 7 Pixel

Rechts: Abweichung um 30 Pixel

(eigener Entwurf)

Während der Arbeiten an der MAPP-LCC wurde festgestellt, dass die meisten MERIS-Level 2-Szenen des Zeitraumes Juli 2003 bis August 2004 Georeferenzierungsfehler von ein bis drei Pixeln aufweisen. Bei einigen wenigen Szenen fallen jedoch deutlich größere

Abweichungen in der Geolokation auf. In knapp zehn Szenen wurden Verschiebungen von fünf bis sieben Pixeln gefunden, für eine Oktoberszene des Jahres 2003 weisen die geographischen Koordinaten sogar eine Verschiebung von über 30 Pixeln auf (s. Abbildung 4.9). Auffällig häufig traten diese besonders schwerwiegenden Ungenauigkeiten bis in den Dezember 2003 auf.

Zur Erklärung der Ungenauigkeiten in der Georeferenzierung wurden zunächst unterschiedliche Ursachen in Erwägung gezogen. Diese stützten sich auf Fehler bei der Berücksichtigung der Geländehöhe, auf Verzerrungen bei der Anpassung des Satellitenbildes an tatsächliche Küstenlinien und auf Ungenauigkeiten der genutzten *orbit state* Vektoren.

Auf dem ENVISAT Symposium im September 2004 wurde bekannt, dass seit dem Start von ENVISAT auch andere Nutzergruppen über Georeferenzierungsfehler in Daten des Satelliten berichteten. DUESMANN et al. (2004) stellen dar, dass die Ursache dieser Fehler in zweimal täglich auftretenden Nickbewegungen (s. Abbildung 2.8) von ENVISAT zu finden sei. Das ESOC entwickelte eine verbesserte Version des Algorithmus zur Berechnung der Orbitparameter, die seit Mitte Dezember 2003 bei der Prozessierung aller ENVISAT-Daten operationell genutzt wird. Datenanalysen des ersten Quartals des Jahres 2004 belegen eine deutliche Verminderung der Ungenauigkeiten durch plötzliche Nickbewegungen des Satelliten. (DUESMANN et al. 2004)

Es bleibt also zu hoffen, dass, aufgrund des verbesserten Algorithmus zur Berechnung der Orbitvektoren, extreme Geolokationsfehler in Zukunft nicht mehr auftreten werden.

Momentan werden zudem alle archivierten MERIS-Daten mit Hilfe einer verbesserten Version des ESA-Standardprozessors erneut prozessiert, so dass auch die Geolokation bereits vorhandener MERIS-Level 2-Daten eventuell korrigiert werden kann.

5 Multispektrale Testklassifizierung mit ENVI

Die Ergebnisse des vorangegangenen Kapitels sollten ursprünglich in Testläufen des MERIS-VA-LCC-Prozessors überprüft werden. Der Prozessor liefert jedoch bisher aus noch ungeklärten Gründen keine auswertbaren Klassifizierungsergebnisse. Aus diesem Grund wurde nach einer Alternativlösung gesucht, mit deren Hilfe die durchgeführten Klassifizierungsvorbereitungen zumindest teilweise nachvollzogen werden können. Die Wahl fiel hierbei auf das Bildverarbeitungssystem ENVI 4.0, mit dem multispektrale Klassifizierungen von Fernerkundungsdaten durchgeführt, und die daraus resultierenden Ergebnisse validiert werden können. Die im MERIS-VA-LCC-Prozessor automatisch ablaufenden Arbeitsschritte müssen bei der Testklassifizierung in ENVI einzeln nachgeahmt werden, so dass im Rahmen dieser Arbeit lediglich der monotemporale Klassifizierungsschritt beispielhaft vollzogen werden kann.

5.1 Auswahl des Klassifikationszeitraumes

Die multispektrale Testklassifizierung mit ENVI soll auf der Grundlage von MERIS-Daten durchgeführt werden, die in einem Zeitraum von etwa zehn Tagen aufgenommen wurden. Ein Zeitintervall von zehn Tagen ist sinnvoll, da die Phänologie, und somit die Reflexionseigenschaften der Landbedeckung, innerhalb dieses Zeitraumes keine starken Veränderungen aufweisen. Im MAPP-Prozessor werden bei der Definition von Referenzvektoren voraussichtlich ebenfalls Zeitschritte von zehn Tagen berücksichtigt, so dass die Ergebnisse der hier durchgeführten Testklassifizierung mit dem Klassifizierungsverfahren des MAPP-VA-LCC-Prozessors vergleichbar sind.

Für die Auswahl eines geeigneten Klassifizierungszeitraumes sind vor allem die Phänologie der betrachteten Klassen und die Verfügbarkeit von MERIS-Daten von entscheidender Bedeutung. Von Mai bis August lassen sich die betrachteten Landbedeckungsklassen aufgrund ihrer Phänologie am besten unterscheiden (s. Tabelle 4.6). Da die Bewölkung in den vorhandenen MERIS-Daten während der ersten Augushälfte am geringsten ausgeprägt war, wird die Periode vom 2. August bis zum 13. August für die Testklassifizierungen ausgewählt. Für diesen Zeitraum liegen sieben MERIS-Level 2-Szenen vor, die eine nahezu vollständige Abdeckung Deutschlands gewährleisten.

5.2 Auswahl der zu berücksichtigenden Klassen

Im multispektralen Klassifizierungsschritt des MAPP-VA-LCC-Prozessors werden keine Landbedeckungsklassen sondern Farbklassen unterschieden. Bei der Testklassifizierung in ENVI soll diese Vorgehensweise ebenfalls berücksichtigt werden.

Wie aus den Referenzvektoren in Tabelle 4.6 ersichtlich wird, sind für den gewählten Bezugszeitraum vermutlich nicht alle Landbedeckungsklassen, die in der MAPP-LCC unterschieden werden, eindeutig voneinander trennbar. Die spektralen Signaturen der Klassen ‚Feuchtgebiete‘ und ‚immergrüner Nadelwald‘ sind Anfang August sehr ähnlich. Die Klasse ‚Mischwald‘ kann in diesem Zeitraum sowohl derselben Farbkategorie wie ‚sommergrüner Laubwald‘ als auch derselben Farbkategorie wie ‚immergrüner Nadelwald‘ beziehungsweise ‚Feuchtgebiete‘ angehören.

Die Klasse ‚landwirtschaftliche Flächen‘ tritt Anfang August in Form von zwei unterschiedlichen Farbkategorien auf. Hierbei handelt es sich zum einen um die Farbkategorie ‚grün mit gelb und braun‘, die für Mischpixel in kleinflächig strukturierten landwirtschaftlichen Gebieten typisch ist. Zum anderen gehören diejenigen Pixel, die fast ausschließlich abgeerntete Felder abbilden, der Farbkategorie ‚hellbraun mit wenig grün‘ an. Pixel der Farbkategorie ‚hellbraun‘ werden durch die Wolkenmaskierung von der Klassifizierung ausgeschlossen (s. Abschnitt 5.3.2). Für die Klasse ‚vegetationslose und vegetationsarme Flächen‘ wird daher lediglich die Farbkategorie ‚braun‘ als Mustersignatur genutzt.

Für den Testlauf des multispektralen Klassifizierungsschrittes wird zunächst – trotz der angestellten Vorüberlegungen – für jede der zu unterscheidenden Landbedeckungs-/ Landnutzungsklassen eine individuelle Mustersignatur vorgegeben, für landwirtschaftliche Flächen die zwei möglichen Signaturen (s. Tabelle 5.1). Anhand dieser Vorgehensweise kann überprüft werden, ob Farbkategorien, deren Reflexionskurven bei der visuellen Interpretation sehr ähnlich erschienen, nicht doch mit Hilfe des Maximum-Likelihood-Verfahrens unterschieden werden können. Falls also die Klassen ‚immergrüner Nadelwald‘ und ‚Feuchtgebiete‘ beziehungsweise ‚Mischwald‘ und ‚sommergrüner Laubwald‘ oder ‚immergrüner Nadelwald‘ im Klassifizierungsergebnis ausgesprochen gut getrennt werden, so können für diese Landbedeckungsklassen während des betrachteten Zeitraumes auch zukünftig individuelle Farbkategorien definiert werden. Sollten die genannten Klassen jedoch auffallend häufig miteinander verwechselt werden, so ist für den betrachteten Zeitpunkt die beabsichtigte Zusammenfassung zu einer einzigen Farbkategorie gerechtfertigt.

Tabelle 5.1: Die in der Testklassifizierung berücksichtigten Farbkategorien mit den entsprechenden Landbedeckungsklassen für Anfang August (eigener Entwurf)

Farbkategorie	Entsprechende Landbedeckungskategorie für Anfang August
mittelgrün, Nadelwald	Immergrüner Nadelwald
grün, Mischwald	Mischwald
grün, Laubwald	Sommergrüner Laubwald
hellgrün	Grasland
grün mit gelb und braun	Landwirtschaftliche Flächen
hellbraun mit wenig grün	Landwirtschaftliche Flächen
dunkelbraun	Vegetationslose und –arme Flächen
braun mit wenig grün	Städtische und bebaute Flächen
mittelgrün, Feuchtgebiete	Feuchtgebiete

5.3 Vorbereitung der MERIS-Daten

Für den MAPP-VA-LCC-Prozessor ist keine Datenvorbereitung nötig. Sowohl die Atmosphärenkorrektur als auch die Georeferenzierung der MERIS-Level 2-Daten werden als ausreichend gut erachtet und unverändert vom ESA-Prozessor übernommen. Die Wasser- und Wolkenmaskierung wird automatisch mit Hilfe der in den Level 2-Daten vorhandenen Wasser- und Wolkenflags durchgeführt.

Um das geplante Klassifizierungsverfahren mit Hilfe von ENVI testen zu können, müssen für die genutzten MERIS-Szenen dennoch vorbereitende Schritte bezüglich Datenformat sowie Wolken- und Wassermaskierung durchgeführt werden. Die für die Testklassifizierung gewählten Szenen weisen einen Geolokationsfehler von ein bis drei Pixeln auf. Es wird allerdings keine Verbesserung der Georeferenzierung durchgeführt, da dies auch im automatisierten Verfahren der MAPP-LCC nicht möglich ist.

5.3.1 Umwandlung in ein geeignetes Datenformat

Die Bildverarbeitungssoftware ENVI 4.0 verfügt über eine Funktion zum Öffnen von MERIS-Daten, die allerdings kein optimales Einlesen gewährleistet. Entscheidende Probleme sind hierbei vor allem, dass die Daten spiegelverkehrt und getrennt von den geographischen Koordinaten gelesen werden. Zudem werden die Reflexionsgrade in 16-bit-Werten ohne Berücksichtigung von Offset und Skalierungsfaktor dargestellt.

Um diese Probleme zu umgehen, werden die ausgewählten MERIS-Daten zunächst mit Hilfe der MERIS-Toolbox BEAM 3.0 geöffnet. Von hier können sie in dem von SPOT-Image entwickelten Datenformat DIMAP exportiert werden. Eine MERIS-Level 2-Szene im DIMAP-Format setzt sich aus einer in XML geschriebenen Headerdatei und aus insgesamt 31 ENVI-kompatiblen, georeferenzierten Bilddateien für jeden Spektralkanal und für alle geophysikalischen Parameter zusammen. Zu jeder dieser Bilddateien ist nochmals eine eigene Headerdatei vorhanden. Für die sieben ausgewählten Szenen werden die Bilddateien der 13 Spektralkanäle zunächst einzeln in ENVI eingelesen und anschließend zu einem Bilddatensatz mit 13 Layern zusammengeführt. In dieser Form können die MERIS-Daten in allen weiteren Arbeitsschritten genutzt werden.

5.3.2 Wolken- und Wassermaskierung

Im MAPP-VA-LCC-Prozessor werden Wolken- und Wasserpixel von der Klassifizierung ausgeschlossen. Hierfür nutzt der Prozessor die Wolken- und Wasserflags der Level 2-Daten.

Bei der Testklassifizierung wird für jede Szene auf Grundlage der Wasserflags eine Wassermaske in ENVI gebildet. Da die Wolkenflags der MERIS-Daten bewölkte Pixel nicht ausreichend markieren, wird für die Wolkenmaskierung die in Abschnitt 4.6

beschriebene Methode der Schwellwertbildung in Kanal 1 herangezogen. Mit Hilfe von ENVI wird folglich für jede Szene eine Wolkenmaske gebildet, die all diejenigen Pixel von der weiteren Klassifizierung ausschließt, die bei 412,5 nm Reflexionsgrade von über 10 % aufweisen. Diese Methode ist leicht anzuwenden und führt gleichzeitig zu guten Ergebnissen. Lediglich einige leicht dunstige Bereiche im Westen der Bundesländer Niedersachsen, Nordrhein-Westfalen und Rheinland-Pfalz sowie im Saarland können nicht vollständig ausmaskiert werden.

In einem abschließenden Schritt wird für jede Szene die Wolkenmaske mit der entsprechenden Wassermaske verschnitten, so dass die Klassifizierung unter Anwendung einer einzigen Maske - sowohl für Wolken als auch Wasser - durchgeführt werden kann.

5.4 Maximum-Likelihood-Klassifizierung

Zur Durchführung der multispektralen Klassifizierung in ENVI wird die Maximum-Likelihood-Methode gewählt, die auch im monotemporalen Klassifizierungsschritt des MAPP-VA-LCC-Prozessors genutzt wird.

Die für das überwachte Verfahren nötigen Mustersignaturen werden aus Trainingsgebieten der sieben ausgewählten Szenen entnommen. Hierbei werden für jede Klasse Pixel mehrerer Trainingsgebiete zusammengefasst, um die Mustersignaturen auf die Grundlage einer ausreichenden Anzahl von Trainingspixeln zu stellen. Nach SWAIN und DAVIS (1978) sollte die Anzahl der Trainingspixel bei n Kanälen mindestens $10 \cdot n$ betragen. Dieser Empfehlungswert kann bei der Testklassifizierung für alle Klassen, bis auf die Klasse ‚dunkelbraun‘ (43 Trainingspixel) eingehalten werden.




Abbildung 5.1: Bei der Klassifizierung vorgegebene Mustersignaturen, die aus Trainingsgebieten mit $\varphi_{\text{rel}} \approx 43^\circ$ und $5^\circ < \vartheta_r < 25^\circ$ abgeleitet wurden.
(eigener Entwurf)

Bei einer Klassifizierung in ENVI ist es nicht wie im MAPP-VA-LCC-Prozessor möglich, für jede Klasse, je nach Beleuchtungs- und Beobachtungsgeometrie, unterschiedliche Mustersignaturen vorzugeben. Daher wird auf eine Mosaikbildung vor der Klassifizierung

verzichtet, und jede der ausgewählten Szenen zunächst einzeln, mit speziell ausgewählten Mustersignaturen, klassifiziert. Innerhalb einer Szene schwanken sowohl Sonnenstand als auch relativer Azimutwinkel nur unwesentlich. In den ausgewählten Szenen liegt der Sonnenzenitwinkel zwischen 35° und 45° , der relative Azimutwinkel schwankt geringfügig, entweder um $39^\circ \pm 5^\circ$ oder um $141^\circ \pm 5^\circ$. Bei der Klassifizierung einer einzelnen Szene sind also lediglich diejenigen BRDF-Effekte zu berücksichtigen, die durch den Beobachtungszenitwinkel ϑ_r hervorgerufen werden.

Wie in Abschnitt 4.5.1 festgestellt wurde, hat ϑ_r jedoch in Aufnahmesituationen mit großen relativen Azimutwinkeln nur einen äußerst geringen Einfluss auf die Reflexionsgrade der MERIS-Daten. Für Szenen mit φ_{rel} größer 120° muss daher nur eine Mustersignatur für jede Klasse vorgegeben werden. Durch diese Vorgehensweise können, über die gesamte Fläche aller Szenen hinweg, gleichmäßig gute Klassifizierungsergebnisse erzielt werden.

Für Daten, die bei relativen Azimutwinkeln von weniger als 60° aufgenommen wurden, spielt der Beobachtungszenitwinkel jedoch eine größere Rolle (s. Abbildung 4.4 & 4.5). Für solche Szenen werden daher gleichzeitig mehrere Mustersignaturen für jede Klasse vorgegeben. Hierbei werden Trainingsgebiete aus Aufnahmesituationen mit einerseits $25^\circ < \vartheta_r < 39^\circ$ und andererseits $5^\circ < \vartheta_r < 25^\circ$ berücksichtigt. Die Klassifizierungsergebnisse zeigen, dass die Pixel der Klassen ‚immergrüner Nadelwald‘, ‚Feuchtgebiete‘ und ‚städtische und bebaute Flächen‘ tatsächlich überwiegend denjenigen Farbklassen zugewiesen werden, die ihrer Beobachtungs- und Beleuchtungsgeometrie entsprechen. Für alle anderen Klassen kann diese Tendenz nur andeutungsweise erkannt werden. Abbildung 5.1 zeigt beispielhaft die vorgegebenen Mustersignaturen für $\varphi_{rel} \approx 43^\circ$ und $5^\circ < \vartheta_r < 25^\circ$, in Abbildung 5.2 sind dieselben Signaturen einzeln mit den entsprechenden Standardabweichungen dargestellt.

Bei der Klassifizierung wurden bisher alle Pixel eines Satellitenbildes ausnahmslos einer der vorgegebenen Klassen zugeordnet. Man muss jedoch davon ausgehen, dass die Ausgangsdaten auch Bildpunkte enthalten, die in Wirklichkeit keiner der vorgegebenen Klassen angehören. Für alle Klassifizierungsergebnisse werden daher Zurückweisungsschwellwerte derart festgelegt, dass ein Bildpunkt nicht klassifiziert wird, wenn die Zugehörigkeitswahrscheinlichkeit dieses Pixels zu allen vorgegebenen Klassen unter 10 % liegt. Durch eine gesonderte Erhöhung der Schwellwerte für die Klasse ‚braun mit wenig grün‘ auf 45 % und für die Klasse ‚grün mit gelb und braun‘ auf 20 %, können die Klassifizierungsergebnisse weiter verbessert werden.

Um die Auswirkungen der Kanalreduktion zu überprüfen, wird anschließend eine Szene mehrfach unter Berücksichtigung unterschiedlicher Spektralkanäle klassifiziert. Zunächst wird ein möglichst optimales Klassifizierungsergebnis mit den Kanälen 4 bis 14 angestrebt. Mit dieser Kanalkombination wird der Informationsgehalt der MERIS-Daten für Landanwendungen voll ausgeschöpft. Die Kanäle 1 bis 4 werden hierbei nicht berücksichtigt, da sie stark durch Atmosphäreneinflüsse geprägt sind und das Klassifizierungsergebnis folglich verschlechtern können (s. Abschnitt 4.5.4). Anschließend wird die Szene mit den gleichen Mustersignaturvorgaben nochmals klassifiziert, wobei diesmal lediglich die in Kapitel 4.5.4 vorgeschlagenen Kanäle 4, 5, 6, 8, 9, 10 und 13

berücksichtigt werden. Die Ergebnisse der Testklassifizierungen werden in Abschnitt 5.6 vorgestellt.

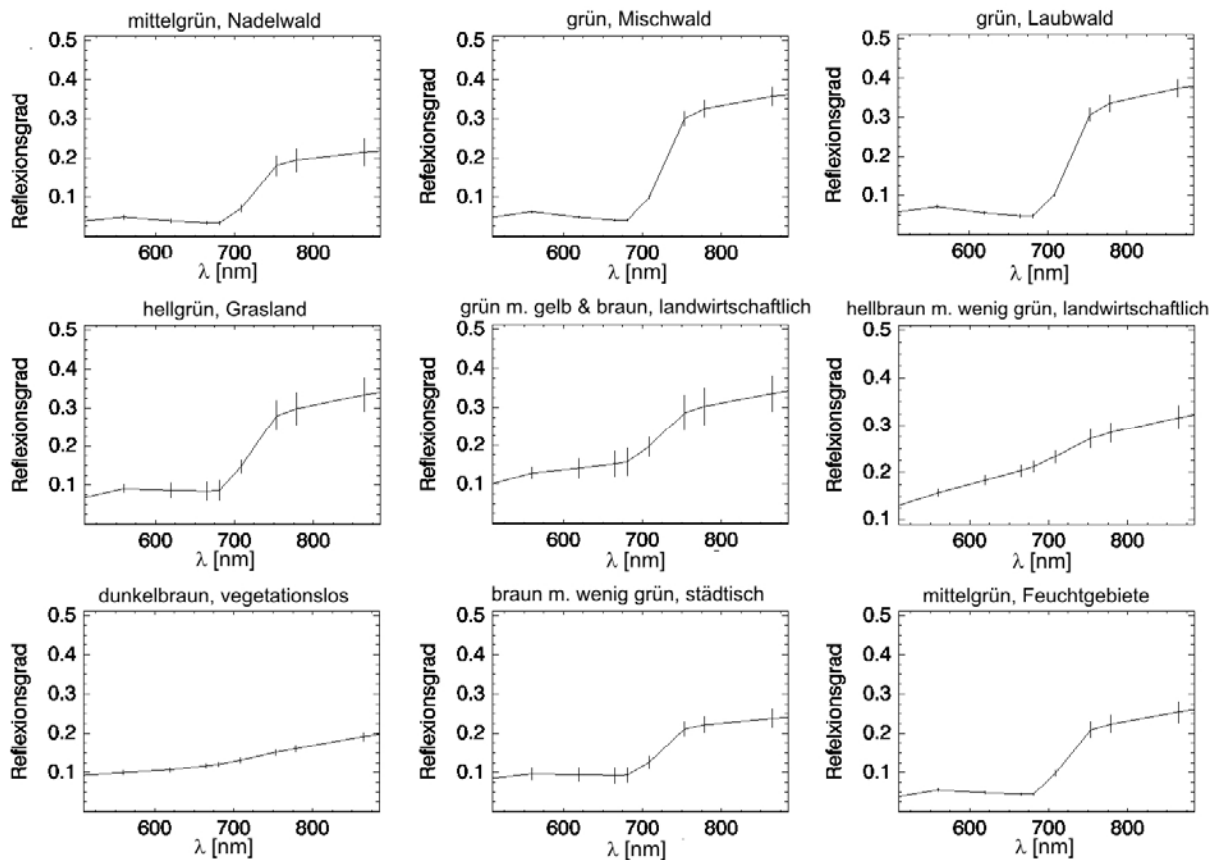


Abbildung 5.2: Bei der Klassifizierung vorgegebene Mustersignaturen, die aus Trainingsgebieten mit $\varphi_{\text{rel}} \approx 43^\circ$ und $5^\circ < \theta_r < 25^\circ$ abgeleitet wurden einschließlich der dazugehörigen Standardabweichungen.
(eigener Entwurf)

5.5 Fertigstellung der Karte und Validierung

In einem anschließenden Arbeitsschritt werden die Klassifikationsergebnisse aller sieben bearbeiteten Szenen mit Hilfe von ENVI zu einem Mosaik zusammengefasst. Im Zuge der Mosaikbildung werden alle Pixel auf eine einheitliche Größe von 300 m x 300 m gebracht, wie dies auch für den MAPP-VA-LCC-Prozessor vorgesehen ist. Im Anschluss an die Mosaikbildung wird das Klassifizierungsergebnis, ebenfalls in ENVI, von der bisherigen Sensorprojektion in die transversale Merkator-Projektion umprojiziert, in der auch der CORINE-Referenzdatensatz vorliegt.

Zur Bewertung der Qualität des Klassifizierungsergebnisses wird die Ergebniskarte mit der CORINE Land Cover 2000 verglichen. Hierfür wird jede Farbklasse des Klassifizierungsergebnisses der ihr entsprechenden Landbedeckungs- beziehungsweise

Landnutzungsklasse zugeordnet (s. Tabelle 5.1). Mit Hilfe von ENVI 4.0 werden Konfusionsmatrizen erstellt und die Gesamtgenauigkeiten, die Benutzer- und Herstellergenauigkeiten sowie der Kappa-Koeffizient berechnet.

Zunächst wird eine nahezu flächendeckende Validierung des Untersuchungsgebietes durchgeführt. Hierfür können die im Oktober 2004 zur Verfügung stehenden vier Fünftel des Referenzdatensatzes CORINE 2000 (UMWELTBUNDESAMT 10/2004) mit dem Klassifizierungsergebnis verglichen werden. Für den südlichen Teil Bayerns und Baden-Württembergs kann die Klassifizierungsqualität jedoch nicht quantitativ bewertet werden.

Um Einzelheiten des Klassifizierungsergebnisses besser beurteilen zu können, wird zusätzlich ein Detailvergleich für einen Kartenausschnitt im Bereich des Harzes durchgeführt.

5.6 Ergebnisse der Klassifizierung mit ENVI

5.6.1 Ergebniskarte

Abbildung 5.3 zeigt das Ergebnis der monotemporalen Testklassifizierung in ENVI für den Zeitraum vom 2. bis zum 13. August. Zum Vergleich ist die auf neun Klassen aggregierte CORINE Land Cover 2000 mit einer räumlichen Auflösung von 300 m in Abbildung 5.4 gegenübergestellt. In Abbildung 5.5 sind die Übereinstimmungen zwischen der Ergebniskarte und dem zur Validierung genutzten Teil der CORINE 2000 als schwarze, Fehlklassifizierungen dagegen als weiße Flächen dargestellt.

Beim visuellen Vergleich der beiden Karten zeigen sich über die gesamte Fläche Deutschlands hinweg sehr gute Übereinstimmungen in großräumigen Strukturen wie Großstädten, ausgedehnten landwirtschaftlich genutzten Flächen und Waldgebieten. Ebenso sind detailliertere Landbedeckungsstrukturen beinahe im gesamten Kartiergebiet deutlich zu erkennen. An dieser Stelle soll nur beispielhaft auf eindeutig erkennbare Details, wie den Hamburger Stadtpark, die Kleinstadt Clausthal-Zellerfeld im Harz (s. auch Abbildung 5.6 a)) und die Nadelwaldstrukturen südlich von München verwiesen werden.

Die Karte besitzt für ein 12-Tages-Komposit insgesamt eine gute Abdeckung. Vor allem im nordwestlichen Untersuchungsgebiet treten allerdings größere unklassifizierte Bereiche auf, die in erster Linie auf Datenlücken aufgrund von Bewölkung zurückgeführt werden können. Andere, deutlich kleiner ausfallende Lücken der Ergebniskarte weisen auf Bildpunkte hin, deren spektrale Ähnlichkeit zu allen Mustersignaturen unter einem Schwellenwert von 10 % liegt. Solche Flächen sind vor allem im Zentrum der Städte München, Berlin und Nürnberg und entlang von Flüssen erkennbar.

An zwei Stellen weist das Klassifizierungsergebnis scharfe linienhafte Brüche auf. Eine dieser Strukturen im südlichen Thüringen und Sachsen beruht auf der Vorgabe unterschiedlicher Mustersignaturen gemäß Beleuchtungs- und Beobachtungsgeometrie. Die zweite Struktur, die in etwa nord-südlicher Richtung durch Ostfriesland verläuft, beruht auf einem Kalibrierungsfehler einer der fünf MERIS-Kameras.

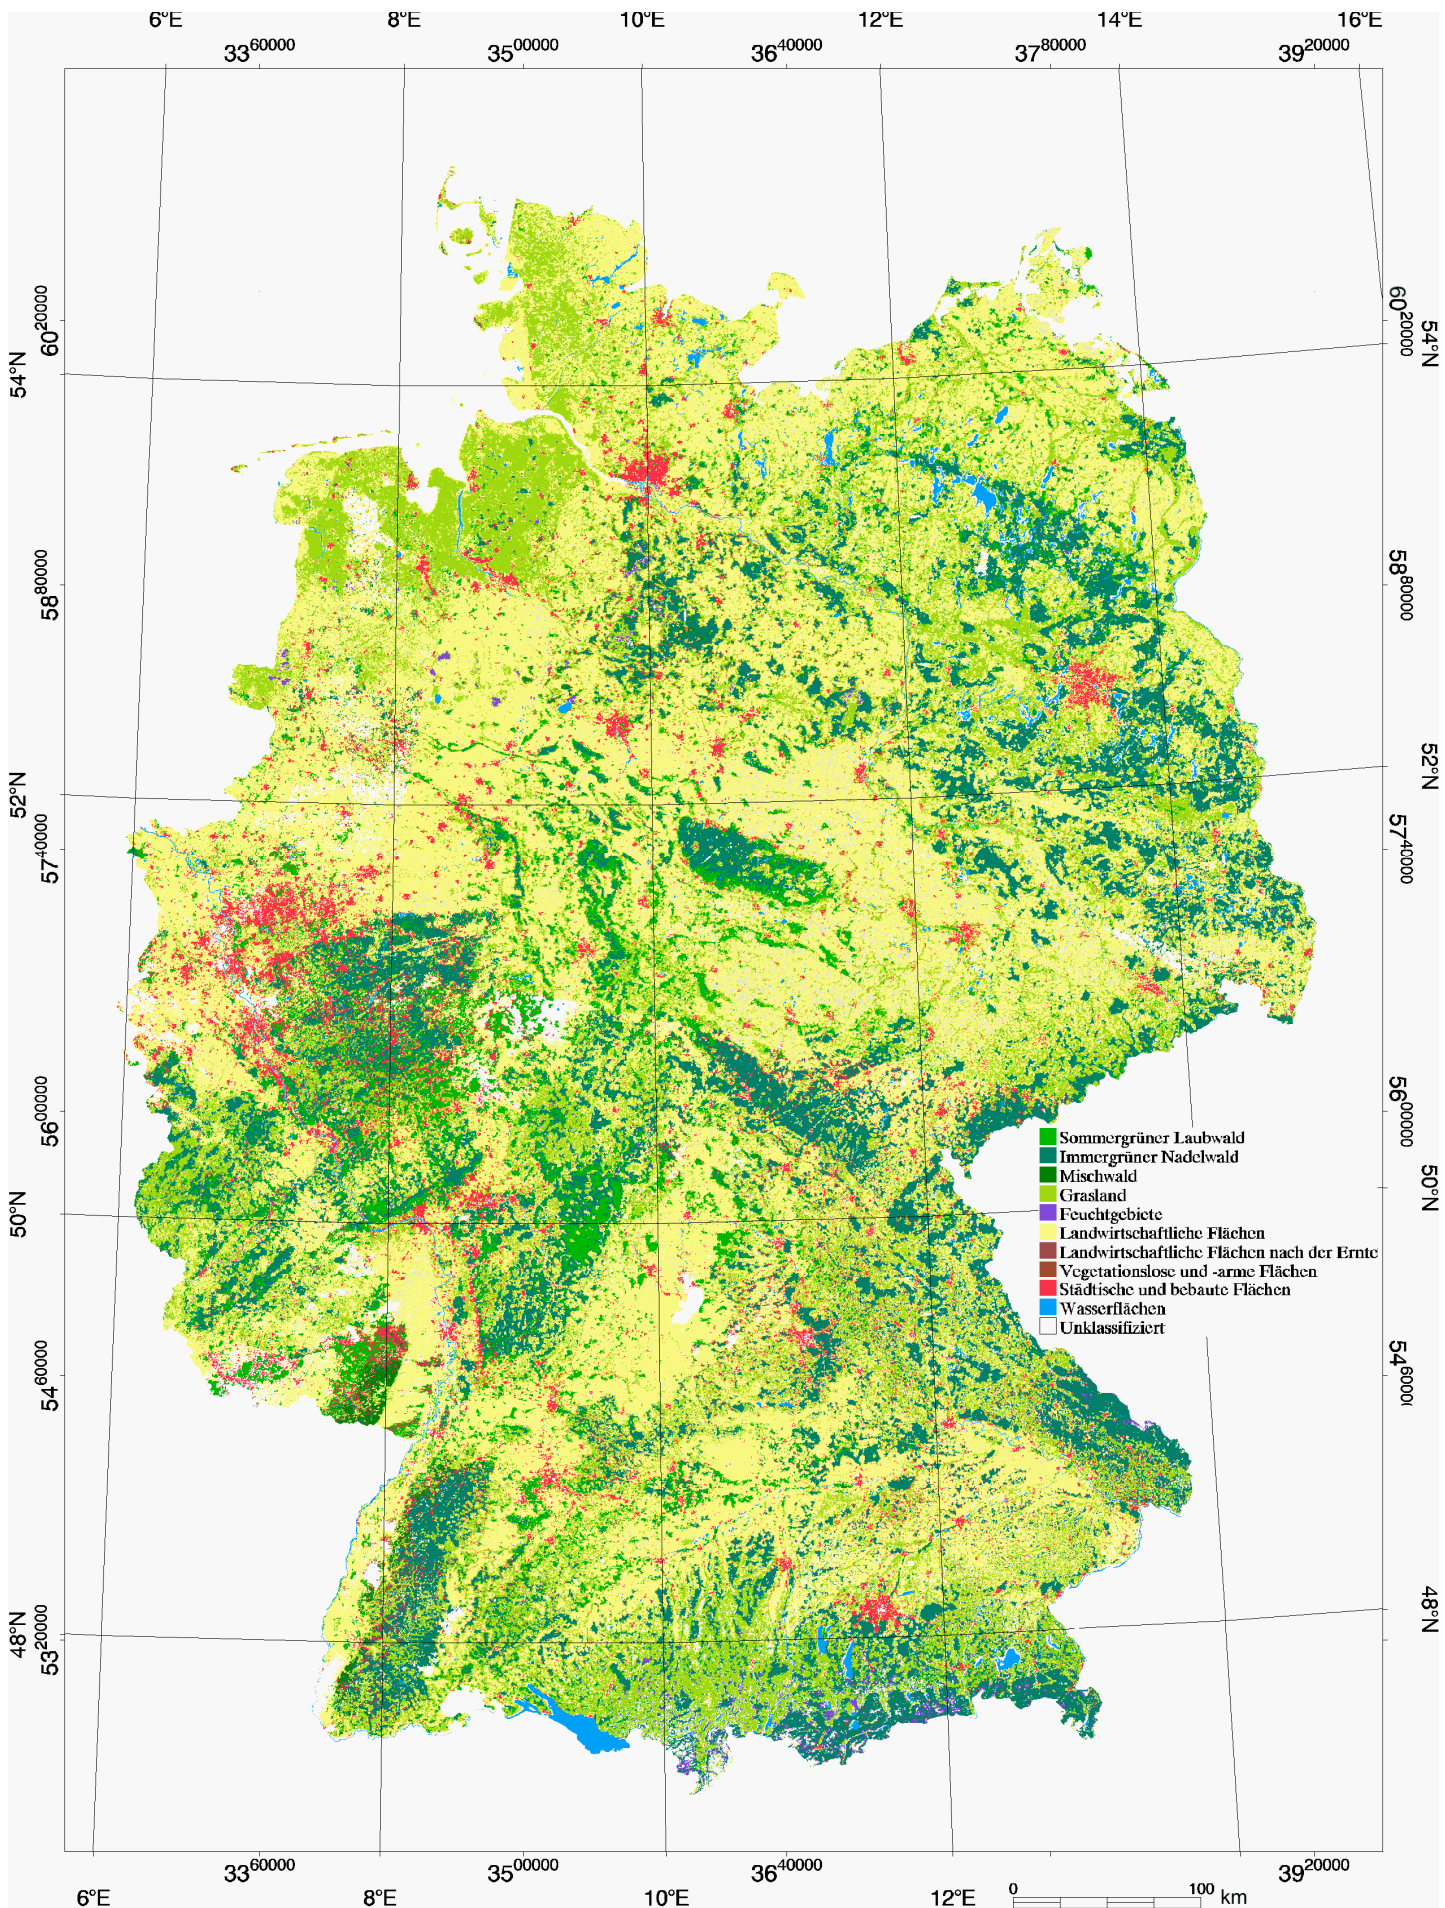


Abbildung 5.3: Ergebnis der monotemporalen Landbedeckungs- / Landnutzungsklassifizierung in ENVI 4.0, auf Basis von MERIS-L 2-FR-Daten des 2. bis 13. August. Zur Orientierung ist zusätzlich die Klasse 5.1 'Wasserflächen im Landesinneren' der CORINE 2000 dargestellt. (eigener Entwurf)

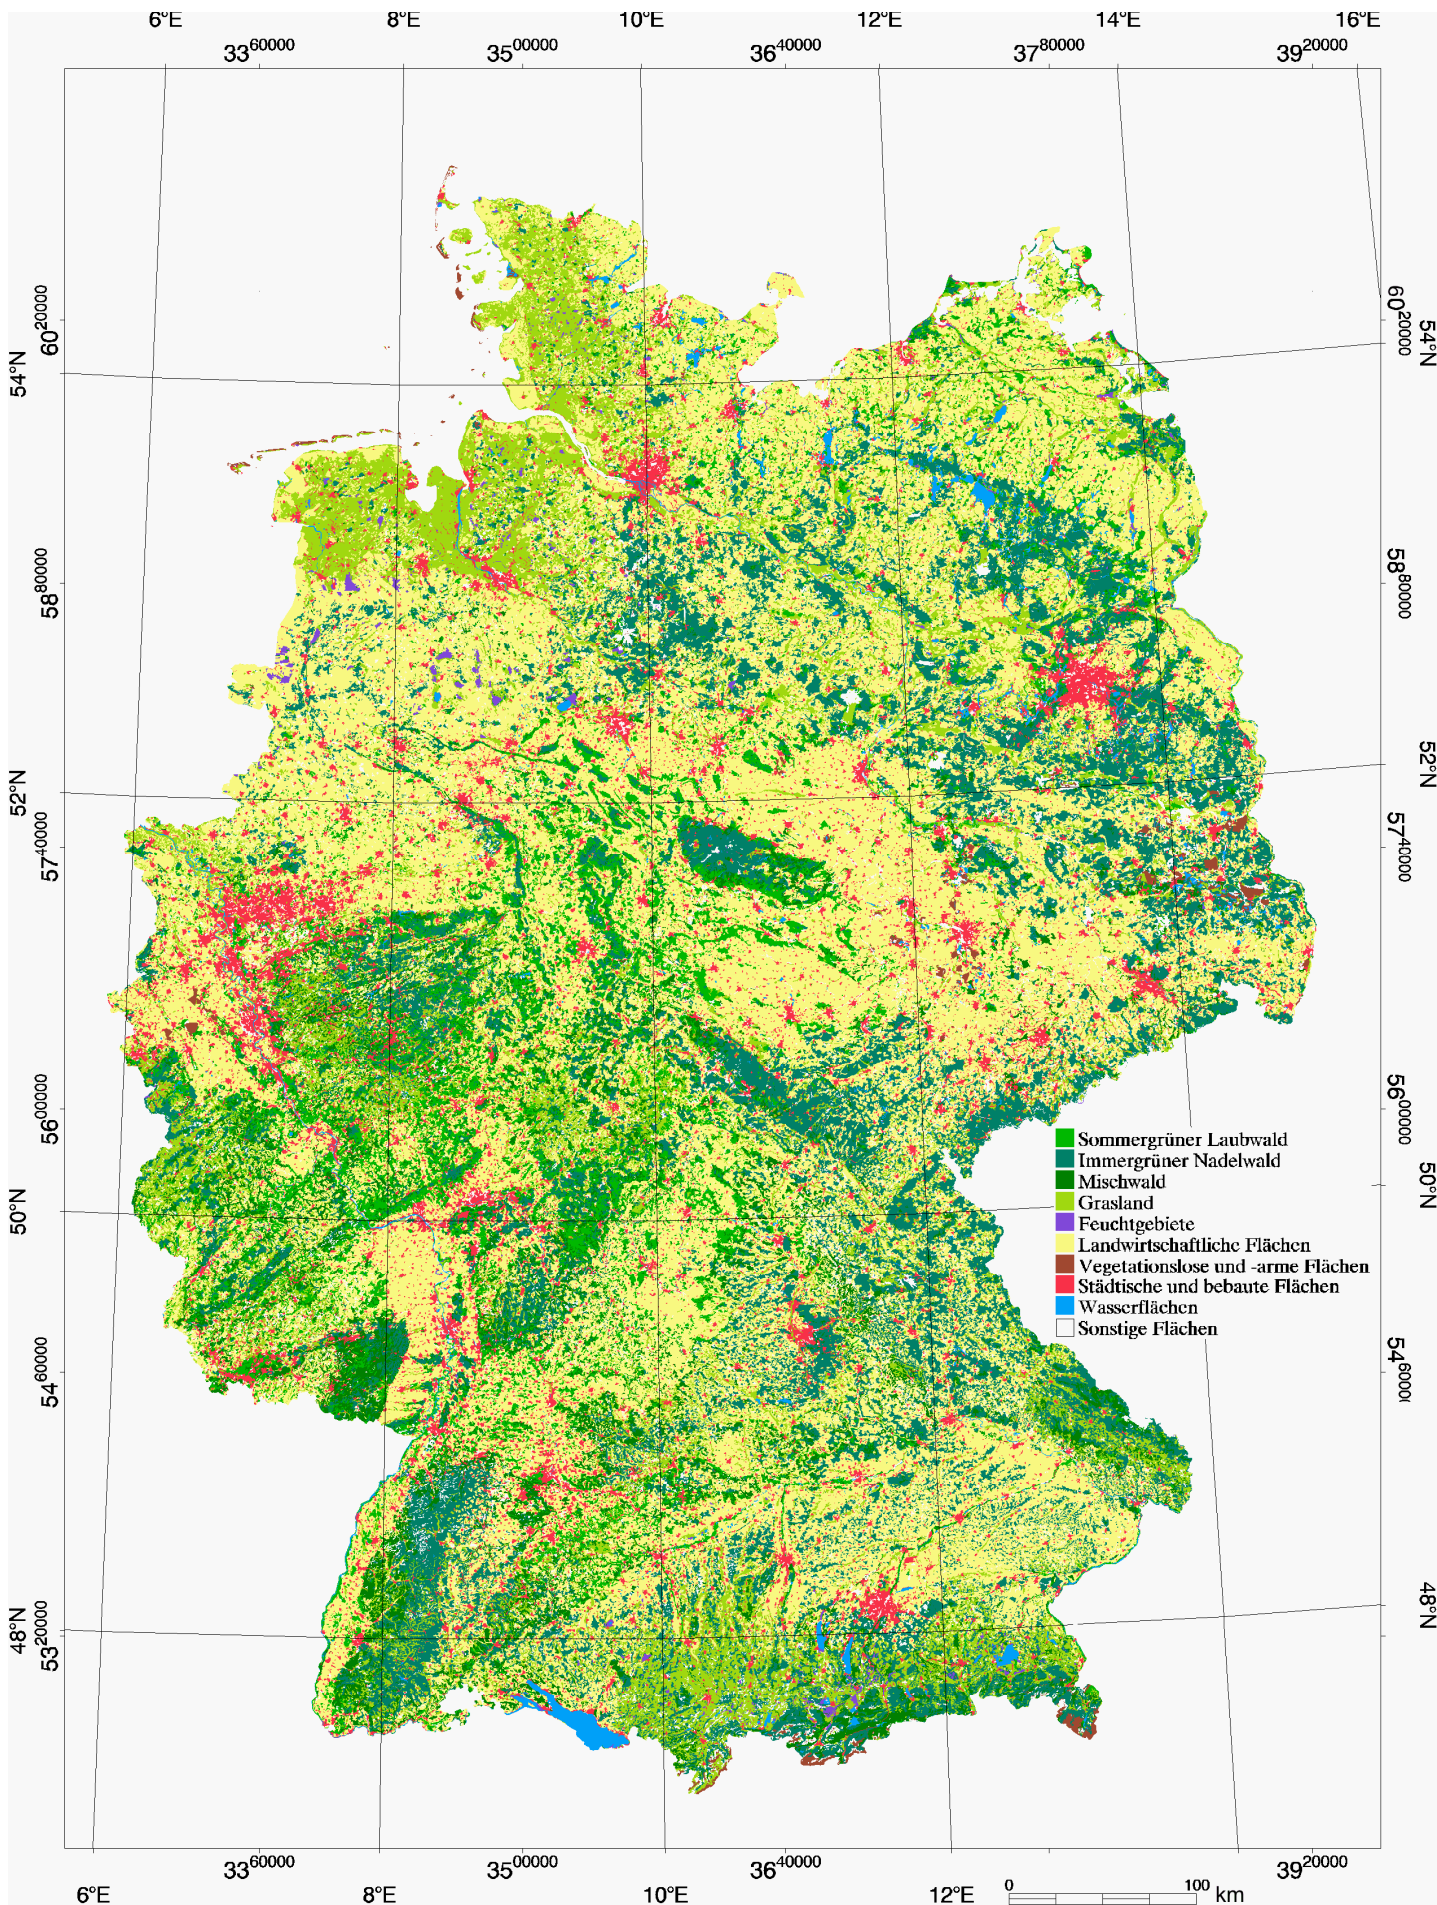


Abbildung 5.4: Referenzdatensatz CORINE Land Cover 2000, aggregiert auf die Klassen der Karte in Abbildung 5.3 (eigener Entwurf, Datengrundlage: UMWELTBUNDESAMT 11/2004)




Abbildung 5.5: Differenzbild des Vergleiches zwischen dem Klassifizierungsergebnis aus Abbildung 5.3 und dem CORINE-Referenzdatensatz (eigener Entwurf)

5.6.2 Validierungsergebnisse

5.6.2.1 Gesamtvergleich

Der Vergleich des Klassifizierungsergebnisses mit dem Referenzdatensatz CORINE 2000 ergibt eine Gesamtgenauigkeit von 57,3 %, der Kappa-Koeffizient liegt bei 0,368. Die Konfusionsmatrix des Gesamtvergleichs von Klassifizierungsergebnis und Referenzdatensatz ist in Tabelle 5.2 dargestellt, Benutzer- und Herstellergenauigkeiten der einzelnen Klassen befinden sich in Tabelle 5.3.

Tabelle 5.2: Konfusionsmatrix des Gesamtvergleiches der Klassifizierung in ENVI mit der CORINE 2000 für etwa vier Fünftel der Fläche Deutschlands. (eigener Entwurf)

		Referenz							Total
		LWI	SB	NW	GL	FG	VL	MW	
Klassifizierung	LWI	1124723	112257	103200	166902	5397	9066	54910	1648442
	SB	30535	76123	18712	10490	147	598	8514	150730
	NW	40507	6681	261264	20630	510	738	60313	435113
	GL	256025	31582	48390	178583	4143	1816	22022	572128
	FG	290	55	392	454	1373	49	82	2859
	VL	4	0	5	4	0	63	0	76
	MW	1190	222	3853	1053	33	10	3892	12068
	LAU	26776	4430	31757	12386	696	185	38377	197537
Total		1480050	231350	467573	390502	12299	12525	188110	3018953

Tabelle 5.3: Hersteller- und Benutzergenauigkeiten sowie Gesamtgenauigkeit und Kappa-Koeffizient des Gesamtvergleiches (eigener Entwurf)

Klasse		Herstellergenauigkeit [%]	Benutzergenauigkeit [%]
LWI	Landwirtschaftliche Flächen	75,99	68,23
SB	Städtische und bebaute Flächen	32,9	50,5
NW	Immergrüner Nadelwald	55,88	60,05
GL	Grasland	45,73	31,21
FG	Feuchtgebiete	11,16	48,02
VL	Vegetationslose und -arme Flächen	0,5	82,89
MW	Mischwald	2,07	32,25
LAU	Sommergrüner Laubwald	35,06	41,98
Gesamtgenauigkeit:		57,3 %	
Kappa-Koeffizient:		0,368	

Die Klasse ‚landwirtschaftliche Flächen‘, die etwa die Hälfte des validierten Untersuchungsgebietes ausmacht, weist die höchsten Klassifizierungsgenauigkeiten auf. 75,99 % der tatsächlich landwirtschaftlich genutzten Flächen werden richtig erkannt. Die Farbklasse ‚grün mit gelb und braun‘ gibt somit die spektralen Eigenschaften

landwirtschaftlich genutzter Flächen gut wieder. Bis auf Nadelwald werden alle anderen Klassen zu einem verhältnismäßig großen Anteil fälschlicherweise der Gruppe der landwirtschaftlichen Flächen zugeordnet. Diese Tatsache beruht vermutlich auf der großen Streuung der Mustersignatur ‚grün mit gelb und braun‘, auf die das angewandte Maximum-Likelihood-Verfahren empfindlich reagiert. Die hohen Standardabweichungen zwischen 0,013 in Kanal 4 bis 0,048 in Kanal 12 (s. Abbildung 5.2) kommen zustande, weil die Mustersignatur aus Pixeln mit sehr unterschiedlichen spektralen Eigenschaften gebildet wurde.

Die Landbedeckungsklasse ‚Grasland‘ wird durch die Farbklasse ‚hellgrün‘ zufrieden stellend repräsentiert. Gebiete, die in der Referenz als Grasflächen bezeichnet sind, werden jedoch zu einem recht hohen Anteil als landwirtschaftliche Flächen erkannt, was, wie bereits erwähnt durch die große Schwankungsbreite der Farbklasse ‚grün mit gelb und braun‘ erklärt werden kann. Ähnlich wie bei der Mustersignatur ‚grün mit gelb und braun‘ liegen die Standardabweichungen der Farbklasse ‚hellgrün‘ mit bis zu 0,043 vergleichsweise hoch (s. Abbildung 5.2). Folglich werden Pixel, die tatsächlich einer anderen Klasse angehören, häufig der Farbklasse ‚hellgrün‘ zugeordnet. Dies ist jedoch seltener der Fall, als dies für die Mustersignatur ‚grün mit gelb und braun‘ festgestellt werden kann (s. Tabelle 5.2).

Nadelwaldflächen werden mit einer Herstellergenauigkeit von 55,8 % und einer Benutzergenauigkeit von 60,05 % verhältnismäßig gut erkannt. Verwechslungen treten hier lediglich mit Mischwald auf.

Die Mischwaldgebiete der Referenz sind nur zu 2,07 % korrekt klassifiziert. Etwa 30 % der Mischwaldfläche werden – wegen der hohen Varianzen der Farbklasse ‚grün mit gelb und braun‘ – als landwirtschaftliche Gebiete erkannt. Rund 30 % der tatsächlichen Mischwaldfläche sind fälschlicherweise Nadelwäldern und rund 20 % Laubwäldern zugeordnet. Diese fehlerhafte Klassifizierung von etwa 50 % der Mischwaldpixel der Referenz zu Gunsten von Laub- und Nadelwald bestätigen die Abschätzung aus Abschnitt 4.4.3, nach der Mischwälder im Sommer entweder der Farbklasse ‚grün‘ oder der Farbklasse ‚mittelgrün‘ angehören können. Höhere Genauigkeitsindizes für die Landbedeckungsklasse ‚Mischwald‘ sind demzufolge erst nach einer multispektralen Analyse erreichbar.

41,98 % der im Klassifizierungsergebnis als Laubwald gekennzeichneten Flächen stimmen mit der Referenz überein. Die in der CORINE 2000 als Laubwald klassifizierten Flächen werden zu gut 30 % als landwirtschaftliche Flächen und zu knapp 19 % als Nadelwälder erkannt.

Die Klasse der Feuchtgebiete weist eine Benutzergenauigkeit von 48,02 % auf. Beinahe die Hälfte der im Klassifizierungsergebnis als Feuchtgebiete dargestellten Fläche ist also korrekt erkannt. Viel schlechter erscheint dagegen die Herstellergenauigkeit von 11,16 %. Etwas über drei Viertel der tatsächlichen Feuchtgebietsflächen sind entweder als landwirtschaftlich genutzte Gebiete oder als Grasland klassifiziert. Bei den fälschlicherweise als Grasland erkannten Flächen handelt es sich, gemäß CORINE 2000, größtenteils um Salzwiesen im Bereich der Nordseeküste, deren spektrale Signatur der Farbklasse ‚hellgrün‘ sehr ähnlich sind. Auf die Herstellergenauigkeit wirkt sich zudem besonders negativ aus, dass die im westlichen Niedersachsen zahlreich auftretenden

Feuchtgebiete schlecht erkannt werden. Die Ursache für diese Fehlklassifizierungen sind leicht dunstige Bereiche der Datengrundlage, die im äußersten nordwestlichen Teil Deutschlands nicht vollständig ausmaskiert werden konnten. Anders als bei der Definition der Referenzvektoren (Tabelle 4.6) abgeschätzt wurde, treten keine nennenswerten Verwechslungen von Feuchtgebieten und Nadelwald auf. Folglich ist es für Anfang August sinnvoll, unterschiedliche Farbklassen für Nadelwald und Feuchtgebiete vorzugeben. In Folge der Testklassifizierungsergebnisse muss also der Referenzvektor für Feuchtgebiete abgeändert werden. Der korrigierte Referenzvektor ist in Tabelle 5.4 als ‚Feuchtgebiete I‘ dargestellt. Ein alternativer Referenzvektor, hier als ‚Feuchtgebiete II‘ bezeichnet, kann gegebenenfalls für Flächen eingeführt werden, deren spektrale Eigenschaften denen von Salzwiesen entsprechen.

Tabelle 5.4 : In Folge der Testklassifizierung abgeänderte Referenzvektoren für die Landbedeckungsklasse ‚Feuchtgebiete‘ (eigener Entwurf)

	<div style="border: 1px solid black; padding: 5px; margin: 5px auto; width: fit-content;"> 4: mittelgrün 5: dunkelbraun mit wenig grün 8: hellgrün 11: mittelgrün, Feuchtgebiete </div>											
	J	F	M	A	M	J	J	A	S	O	N	D
Feuchtgebiete I	5	5	5	5	5/11	11	11	11	11/5	5	5	5
Feuchtgebiete II	4	4	4	4	4/8	8	8	8	8/4	4	4	4

Deutliche Klassifizierungsschwierigkeiten treten bei der Landbedeckungsklasse ‚vegetationslose und -arme Flächen‘ auf. Hier werden lediglich 76 der 12525 Pixel der Referenz richtig klassifiziert. Von den 76 als ‚vegetationslose und -arme Flächen‘ erkannten Pixeln stimmen jedoch 63 Pixel, also 82,89 %, mit dem Referenzdatensatz überein. Diese extremen Unterschiede zwischen Hersteller- und Benutzergenauigkeit entstehen durch die geringen Standardabweichungen (0,005 bis 0,011) der Mustersignatur ‚dunkelbraun‘, die lediglich auf 43 Trainingspixeln basiert. Ein Pixel darf daher nur minimale Abweichungen von dem vorgegebenen Mittelvektor der Mustersignatur aufweisen, um im Maximum-Likelihood-Verfahren der Klasse ‚dunkelbraun‘ zugewiesen zu werden. Die als ‚dunkelbraun‘ klassifizierten Pixel gehören also mit hoher Sicherheit auch in Wirklichkeit dieser Klasse an. Da jedoch die spektrale Signatur der Landbedeckungsklasse ‚vegetationslose und -arme Flächen‘, je nach Oberflächenmaterial, recht unterschiedlich ausfallen kann (s. Abschnitt 2.3.2.1), werden zahlreiche Bildpunkte, die vegetationslose Flächen abbilden, nicht der Klasse ‚braun‘ zugewiesen. Um in diesem Fall höhere Klassifizierungsgenauigkeiten zu erzielen, ist es also notwendig, mehrere alternative Farbklassen für vegetationslose Flächen zu definieren, beziehungsweise die Varianzen der entsprechenden Mustersignaturen zu erhöhen.

Bei der Auswertung des Klassifizierungsergebnisses bestätigt sich also die Annahme der Vorüberlegungen, dass die Klasse ‚Mischwald‘ während des betrachteten Zeitraums nicht eindeutig von Laubwald und Nadelwald trennbar ist. Alle anderen Landbedeckungs-

beziehungsweise Landnutzungsklassen sind jedoch Anfang August durch Farbklassen unterscheidbar (vgl. Tabelle 4.6 & Tabelle 5.4).

Daher kann die in Tabelle 5.2 dargestellte Konfusionsmatrix um die Klasse ‚Mischwald‘ reduziert werden. Diejenigen Pixel, die gemäß der Referenz Mischwald darstellen, im Klassifizierungsergebnis jedoch als Nadelwald gekennzeichnet sind, werden als korrekt klassifiziert bewertet. Ebenso wird mit Pixeln verfahren, die im Referenzdatensatz Mischwaldvegetation aufweisen, in der Ergebniskarte jedoch als Laubwald erkannt werden. Nach dieser Reduzierung der Konfusionsmatrix auf sieben Klassen ergibt sich eine Verbesserung der Gesamtgenauigkeit auf 60,41 %.

5.6.2.2 Detailvergleich

Die Stärken und Schwächen des Klassifizierungsergebnisses sollen im Folgenden anhand eines Detailausschnittes der Ergebniskarte näher betrachtet werden. Dieser Ausschnitt mit dem dazugehörigen Teilbereich des Referenzdatensatzes und des Differenzbildes sind in den Abbildungen 5.6 a) bis c) dargestellt. Die Konfusionsmatrix sowie die entsprechenden Genauigkeitsindizes des Beispielausschnittes sind in den Tabellen 5.5 & 5.6 zu finden.

Im Zentrum des gewählten Kartenausschnitts liegt der Harz, umgeben von den landwirtschaftlichen Flächen der Magdeburger Börde im Norden und des Thüringer Beckens im Süden. Das westliche Drittel des betrachteten Ausschnittes stellt ein vergleichsweise kleinflächig strukturiertes Gebiet mit Laubwäldern, Nadelwäldern und landwirtschaftlichen Flächen dar. Im gesamten Detailausschnitt sind zahlreiche, teilweise kleinflächige Siedlungen von der Größe weniger Pixel vorhanden.

Das Differenzbild zeigt für das gewählte Detailbeispiel sowohl Bereiche sehr guter Übereinstimmung (schwarz erscheinende Flächen) als auch Bereiche mit größeren Ungenauigkeiten (hell erscheinende Flächen). Im gesamten Klassifizierungsergebnis, selbst in den Bereichen geringer Übereinstimmung (weiße Flächen des Differenzbildes), sind alle wesentlichen Landbedeckungsstrukturen der Referenz erkennbar. Teilweise zeichnen sich im Differenzbild weiße Linien schlechter Übereinstimmung am Rand dieser Strukturen ab. Diese Zuweisungsfehler können zum einen auf die Fehlklassifizierung von Mischpixeln an Landbedeckungsgrenzen zurückgeführt werden. Andererseits werden sie teilweise auch durch Ungenauigkeiten in der Georeferenzierung des Klassifizierungsergebnisses hervorgerufen.

Form und Lage der Waldflächen der Referenzkarte sind für den gesamten betrachteten Ausschnitt auch im Klassifizierungsergebnis klar zu erkennen. Häufig sind jedoch Verwechslungen der Waldklassen untereinander, vor allem zwischen Laub- und Mischwald, zu verzeichnen. Im kleinflächig strukturierten Südwesten des gezeigten Detailausschnitts sind Wald- und Ackerflächen zudem besonders häufig als Grasland klassifiziert. Die Ursache dieser Fehlklassifizierungen scheinen hier ebenfalls Mischpixel der MERIS-Daten und die hohen Standardabweichungen der Farbklasse ‚hellgrün‘ zu sein.

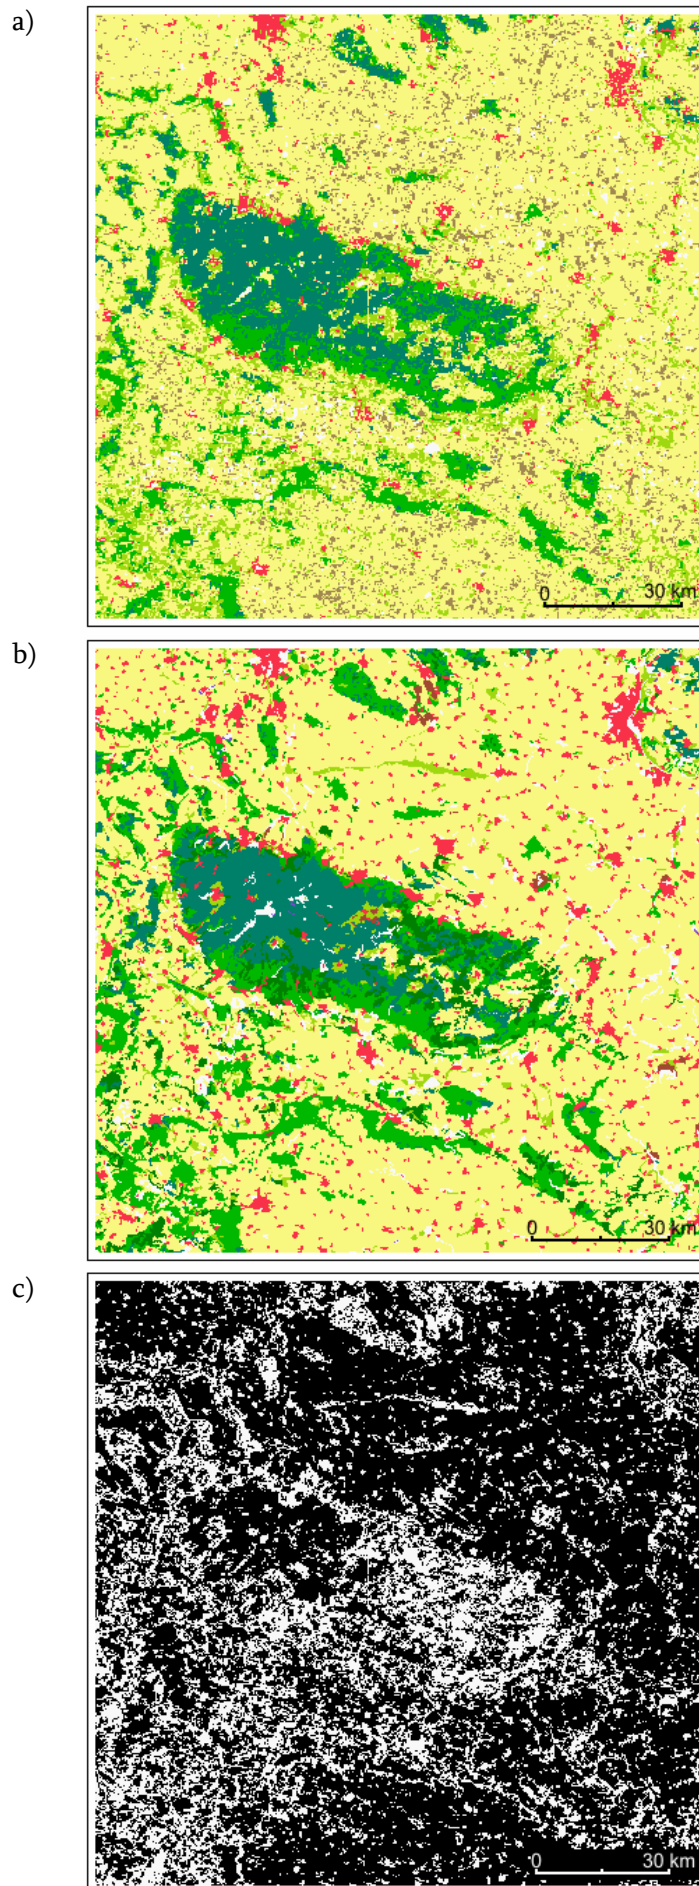


Abbildung 5.6:

Detailvergleich von Klassifizierungsergebnis und Referenzdatensatz.

Der Ausschnitt zeigt den Harz im Zentrum, umgeben von den landwirtschaftlichen Flächen der Magdeburger Börde im Norden und des Thüringer Beckens im Süden.

a) Ergebnis der Testklassifizierung

b) CORINE Land Cover 2000

c) Differenzbild

Die Farbgebung entspricht Abb. 5.3. (a), Abb. 5.4 (b) bzw. Abb. 5.5 (c).

(eigener Entwurf; Datengrundlage b): UMWELTBUNDESAMT 10/2004)

Viele der im Bildausschnitt vorhandenen, extrem kleinflächigen Siedlungen können mit dem räumlichen Auflösungsvermögen des Sensors MERIS nicht erkannt werden. Sie werden meist fälschlicherweise der Klasse ‚landwirtschaftliche Flächen‘ zugewiesen. Hieraus ergibt sich die, im Vergleich zum Gesamtergebnis, relativ niedrige Herstellergenauigkeit der Klasse ‚städtische und bebaute Flächen‘ für den betrachteten Detailausschnitt.

Tabelle 5.5: Konfusionsmatrix des Detailvergleiches für das in Abbildung 5.6 dargestellte Gebiet mit der CORINE 2000. (eigener Entwurf)

		Referenz								Total
		LWI	SB	NW	GL	FG	VL	MW	LAU	
Klassifizierung	LWI	102145	7664	1494	2994	18	494	1792	6881	123482
	SB	1028	2818	122	139	1	30	97	0	4444
	NW	594	189	9220	267	12	33	2001	2861	15177
	GL	10284	1504	753	1438	18	120	1129	3693	18939
	FG	0	0	1	3	0	0	0	0	4
	VL	0	0	0	0	0	1	0	0	1
	MW	8	8	19	2	0	0	16	26	79
	LAU	1570	169	1959	266	2	17	2759	9786	16528
Total		115629	12352	13568	5109	51	695	7794	23456	178654

Tabelle 5.6: Hersteller- und Benutzergenauigkeiten sowie Gesamtgenauigkeit und Kappa-Koeffizient des Detailvergleiches. (eigener Entwurf)

Klasse		Herstellergenauigkeit [%]	Benutzergenauigkeit [%]
LWI	Landwirtschaftliche Flächen	88,34	82,72
SB	Städtische und bebaute Flächen	22,81	63,41
NW	Immergrüner Nadelwald	67,95	60,75
GL	Grasland	28,15	7,59
FG	Feuchtgebiete	0	0
VL	Vegetationslose und -arme Flächen	0,14	100
MW	Mischwald	0,21	20,25
LAU	Sommergrüner Laubwald	41,72	59,21
Gesamtgenauigkeit:		70,21 %	
Kappa-Koeffizient:		0,437	

Wie bereits beim Gesamtvergleich des vorangegangenen Abschnitts ersichtlich wurde, sind auch im gezeigten Detailausschnitt die höchsten Übereinstimmungen mit der Referenz für die Klassen ‚landwirtschaftliche Flächen‘ und ‚immergrüner Nadelwald‘ zu verzeichnen. Deutlich zu erkennen ist im dargestellten Beispiel die Untergliederung der landwirtschaftlichen Flächen in die Farbklassen ‚grün mit gelb und braun‘ (Legendeneinheit ‚landwirtschaftliche Flächen‘) und ‚hellbraun mit wenig grün‘ (Legendeneinheit ‚landwirtschaftliche Flächen nach der Ernte‘). Während des Bezugszeitraumes Anfang August waren Wintergetreidearten wie Winterweizen, -roggen und -gerste bereits geerntet (DWD 2004). Die Farbkategorie ‚hellbraun mit wenig grün‘ steht

also im Klassifizierungsergebnis für die bereits abgeernteten Flächen dieser Getreidesorten. Die als ‚grün mit gelb und braun‘ klassifizierten Bereiche stellen noch nicht geerntete Felder oder Mischungen aus geernteten und noch mit Vegetation bestandenen Flächen dar. Es zeigt sich also, dass Anfang August in MERIS-Daten Pixel, die fast ausschließlich Wintergetreidearten abbilden, von sonstigen landwirtschaftlichen Flächen mit Hilfe des genutzten Verfahrens unterschieden werden können.

Der gewählte Detailausschnitt weist mit einer Gesamtgenauigkeit von 70,2 % ein etwas besseres Klassifizierungsergebnis als der Gesamtvergleich auf. Reduziert man die Konfusionsmatrix des Beispielausschnittes (Tabelle 5.5), wie beim Gesamtvergleich beschrieben wurde, um die Klasse ‚Mischwald‘, so verbessert sich diese Gesamtgenauigkeit weiter auf 72,9 %.

5.6.3 Klassifizierungsergebnisse mit Kanalreduktion

In Abbildung 5.7 sind Ausschnitte aus Klassifizierungsergebnissen dargestellt, die unter Berücksichtigung unterschiedlicher Spektralkanäle erzielt werden. Abbildung 5.7 a) zeigt das Ergebnis unter Vorgabe der zehn Kanäle und der Zurückweisungsschwellenwerte, wie sie bei der Erstellung der monotemporalen Ergebniskarte (Abbildung 5.3) verwendet wurden (‚braun mit wenig grün‘: 45 %; ‚grün mit gelb und braun‘: 20 %; alle übrigen Klassen: 10 %). Für das in Abbildung 5.7 b) dargestellte Klassifizierungsergebnis werden bei gleichen Zurückweisungsschwellen lediglich sieben Kanäle, nämlich Kanal 4, 5, 6, 8, 9, 10 und 13 berücksichtigt. Das Klassifizierungsergebnis ist durch die Reduktion um drei Spektralkanäle deutlich verschlechtert. Im gesamten Klassifizierungsergebnis wird kein einziges Pixel den Farbklassen ‚grün mit gelb und braun‘ (Legendeneinheit ‚landwirtschaftliche Flächen‘) und ‚braun mit wenig grün‘ (Legendeneinheit ‚städtische und bebaute Flächen‘) zugewiesen. Diejenigen Pixel, die in der Klassifizierung mit zehn Kanälen diesen beiden Farbklassen zugeordnet sind, bleiben nach der Kanalreduktion unklassifiziert. Auch die übrigen Farbklassen werden hier seltener erkannt. Daher wird die Zurückweisungsschwelle für die Farbklasse ‚grün mit gelb und braun‘ auf 15 % gesenkt, für die Farbklasse ‚braun mit wenig grün‘ auf 30 % und für alle übrigen Farbklassen auf 5 %. Das entsprechende Ergebnis ist in Abbildung 5.7 c) dargestellt. Beim Vergleich mit Abbildung 5.7 a) zeigt sich, dass das Klassifizierungsergebnis mit sieben Kanälen nun nur noch geringfügig schlechter ausfällt, als das Ergebnis mit zehn Kanälen. Der Anteil an unklassifizierten Pixeln liegt in Abbildung 5.7 c) etwas höher. Zudem werden landwirtschaftliche Flächen insgesamt häufiger fälschlicherweise als Graslandflächen erkannt.

Die vorgeschlagene Reduzierung der zu berücksichtigenden Spektralkanäle auf Band 4, 5, 6, 8, 9, 10 und 13 ist nach den Ergebnissen in ENVI mit geringen Qualitätseinbußen möglich. Die genauen Auswirkungen einer Kanalreduktion auf die Klassifizierungsergebnisse im MAPP-VA-LCC-Prozessor müssen am Prozessor selbst geprüft werden. Erst dann können die Vorteile durch Rechenzeitverkürzung bei der Verarbeitung von MERIS-Daten eines ganzen Jahres gegen die Nachteile, die durch den Qualitätsverlust im Zuge einer Kanalreduktion entstehen, abgewogen werden.

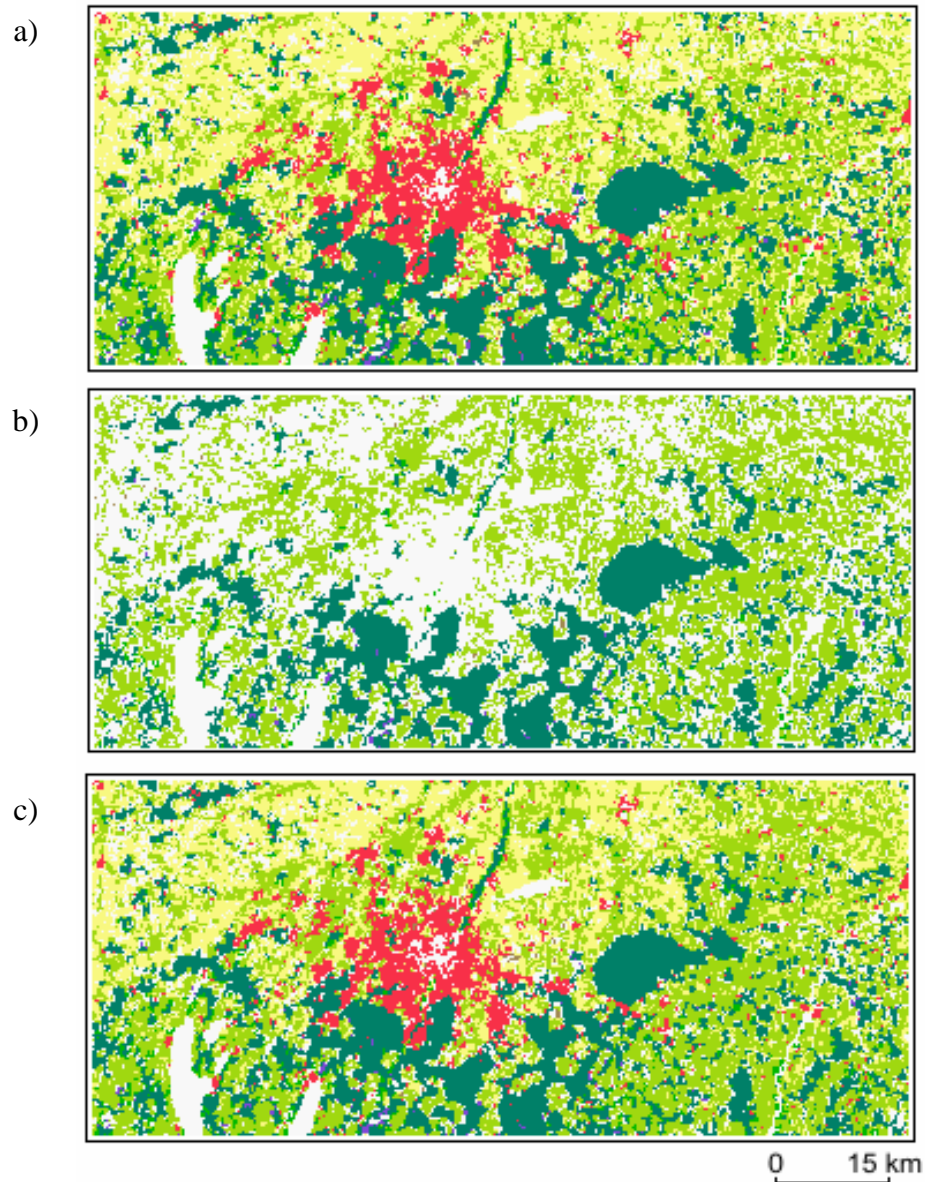


Abbildung 5.7: Klassifizierungsergebnisse bei Berücksichtigung unterschiedlicher MERIS-L 2-FR-Kanäle. Der Detailausschnitt zeigt München und Umgebung.

- a) Berücksichtigung der zehn Kanäle 4, 5, 6, 7, 8, 9, 10, 12, 13 und 14
- b) Berücksichtigung der sieben Kanäle 4, 5, 6, 8, 9, 10 und 13 mit unveränderten Zurückweisungsschwellen
- c) Berücksichtigung der sieben Kanäle 4, 5, 6, 8, 9, 10 und 13 mit gesenkten Zurückweisungsschwellen

Die Farbgebung entspricht der Abbildung 5.3.
(eigener Entwurf)

5.6.4 Diskussion der Klassifizierungsergebnisse

Obwohl die zur Klassifizierung herangezogenen MERIS-Daten eine verhältnismäßig gute Georeferenzierungsqualität aufweisen, sind zwischen Referenz und Ergebniskarte immer noch Abweichungen von ein bis drei Pixeln feststellbar. Daher ist davon auszugehen, dass der Vergleich zwischen Referenzdatensatz und Klassifizierungsergebnis besonders an den Klassengrenzen keine korrekten Ergebnisse liefern kann. Aufgrund dieser Tatsache liegen die tatsächlichen Gesamtgenauigkeiten sowie die klassenspezifischen Benutzer- und Herstellergenauigkeiten vermutlich höher als die oben angegebenen Werte.

In der durchgeführten monotemporalen Klassifizierung sind nicht alle Landbedeckungs- / Landnutzungsklassen voneinander trennbar. Mischwald kann zum betrachteten Zeitpunkt nicht von Laub- beziehungsweise Nadelwald unterschieden werden. In monotemporalen Klassifizierungen anderer Bezugszeiträume werden wiederum andere Landbedeckungs- / Landnutzungsklassen spektrale Signaturen aufweisen, deren Merkmalsräume sich deutlich überschneiden. Dieses Problem kann im MAPP-VA-LCC-Prozessor durch die Auswertung mehrerer Aufnahmezeitpunkte in der multitemporalen Analyse gelöst werden.

In der vorgestellten Testklassifizierung kann in MERIS-Daten von Anfang August zwischen bereits abgeernteten Feldern und sonstigen landwirtschaftlichen Flächen unterschieden werden. Es besteht demzufolge grundsätzlich die Möglichkeit, mit der angewandten Methode bestimmte Gruppen von Feldfrüchten, wie beispielsweise Wintergetreide, als eigene Klasse zu identifizieren. Durch Einbeziehung der Phänologie bestimmter Feldfrüchte in der multitemporalen Analysephase, besonders durch den prägnanten Einschnitt der Erntephase, sind diesbezüglich besonders gute Ergebnisse zu erwarten. In diesem Zusammenhang muss jedoch berücksichtigt werden, dass die Kartierung von Feldfrüchten nur für größere, einheitlich bestellte landwirtschaftliche Flächen möglich ist, die mit einer räumlichen Auflösung von 265 m x 292 m im Nadir erfasst werden können. Die landwirtschaftlichen Flächen Deutschlands sind hierfür in vielen Fällen zu kleinflächig strukturiert.

Das Klassifizierungsergebnis weist, neben Datenlücken aufgrund von Bewölkung, auch unklassifizierte Pixel auf, die keiner der vorgegebenen Klassen mit einer ausreichend hohen Wahrscheinlichkeit zugewiesen werden können. Hierin zeigt sich das grundsätzliche Problem überwachter Klassifizierungsverfahren, dass normalerweise nicht alle im Kartiergebiet vorkommenden Klassen als Mustersignaturen vorgegeben werden können. Gerade für kleinräumig und fragmentiert vorkommende Klassen ist es meist nicht möglich, Trainingsgebiete zu definieren. Zudem ist es oft äußerst schwierig und zeitaufwendig, bei der Bestimmung von Mustersignaturen tatsächlich alle möglichen spektralen Ausprägungen einer Klasse zu erfassen.

Die Benutzer- und Herstellergenauigkeiten fallen von Klasse zu Klasse sehr unterschiedlich aus. Für die Landbedeckungsklassen ‚Feuchtgebiete‘ und ‚vegetationslose und -arme Flächen‘, die mit jeweils etwa 0,4 % nur einen geringen Anteil der validierten Fläche ausmachen, können nur äußerst niedrige Genauigkeiten erzielt werden. Die im Kartiergebiet am weitesten verbreiteten Klassen, hierunter vor allem ‚landwirtschaftliche

Flächen' und 'immergrüner Nadelwald', werden dagegen mit vergleichsweise hohen Genauigkeiten erkannt. Die Gesamtgenauigkeit der Testklassifizierung von 57,3 % unter Berücksichtigung von acht, beziehungsweise 60,41 % unter Berücksichtigung von sieben Klassen, fällt etwas besser als diejenigen Ergebnisse aus, die von anderer Seite bei monotemporalen Klassifizierungen mit Hilfe optischer Sensoren vergleichbarer räumlicher Auflösung erzielt werden konnten. So erreichten beispielsweise CLEVERS et al. (2003) bei der Klassifizierung von MERIS-Daten unter Berücksichtigung von sechs Klassen eine Gesamtgenauigkeit von 51,4 %. ARNDT (2001) konnte in MOS-Daten des ersten Augustdrittels acht Klassen mit einer Gesamtgenauigkeit von knapp 52 % unterscheiden. Dennoch ist für die MAPP-LCC eine Verbesserung der Klassifizierungsqualität unbedingt wünschenswert, um zuverlässigere Eingangsdaten für umweltwissenschaftliche Modellierungen bereitstellen zu können. Diese Verbesserung kann im MAPP-VA-LCC-Prozessor durch die Auswertung der phänologischen Informationen im multitemporalen Analyseschritt erzielt werden (ARNDT 2001).

Die Ergebnisse der Testklassifizierung in ENVI können weitgehend auf den multispektralen, monotemporalen Teilschritt des MAPP-VA-LCC-Prozessors übertragen werden. Ebenso wie bei der MAPP-LCC, liegt der Testklassifizierung der Maximum-Likelihood-Klassifikator zugrunde. Die Datenvorbereitung wurde, abgesehen von der Wolkenmaskierung, gemäß dem Vorgehen im Prozessor durchgeführt. Die Abweichungen bei der Methode der Wolkenerkennung sind vertretbar, da das Verfahren der MAPP-LCC diesbezüglich ohnehin abgewandelt werden sollte (s. Abschnitt 4.6). Da für die Testklassifizierung ein Bezugszeitraum von zwölf Tagen gewählt wurde, ist das vorgestellte Ergebnis auf den monotemporalen Schritt des MAPP-VA-LCC-Prozessors, bei dem Zeitschritte von zehn Tagen berücksichtigt werden, übertragbar. Bei der Testklassifizierung in ENVI war es jedoch nicht möglich, je nach Beleuchtungs- und Beobachtungsgeometrie eines Bildpunktes unterschiedliche Mustersignaturen vorzugeben. BRDF-Effekte konnten somit nur indirekt, durch die Vorgabe mehrerer alternativer Mustersignaturen pro Klasse, berücksichtigt werden. In diesem Punkt ist die Testklassifizierung in ENVI folglich nicht ohne weiteres auf das Verfahren des MAPP-VA-LCC-Prozessors übertragbar.

6 Zusammenfassung und Ausblick

Das MAPP-Klassifizierungsverfahren ermöglicht eine automatisierte, jährlich aktualisierbare Landbedeckungs- / Landnutzungsklassifizierung auf der Grundlage von Daten des Sensors MERIS. In der vorliegenden Arbeit wurden Untersuchungen zur Vorbereitung des MAPP-VA-LCC-Prozessors durchgeführt. Die Ergebnisse dieser Untersuchungen wurden anhand von Testklassifizierungen in ENVI 4.0 überprüft.

Zunächst wurde ein geeignetes Klassifikationssystem für die MAPP-LCC ausgewählt. Die Entscheidung fiel hierbei auf den Klassifikationsschlüssel der Global Land Cover 2000 (GLC 2000), der auf dem Land Cover Classification System (LCCS) basiert. Auf der Grundlage des GLC 2000-Schlüssels wurde die Legende der MAPP-LCC erstellt. Des Weiteren wurde ein Referenzdatensatz bestimmt, der zur Validierung des MAPP-Klassifizierungsergebnisses genutzt werden kann. Am besten geeignet erscheint hierfür die CORINE Land Cover 2000. Die thematische und räumliche Auflösung dieses Datensatzes wurde an die MAPP-Landbedeckungs- / Landnutzungsklassifizierung angepasst, um den Vergleich der beiden Karten zu ermöglichen.

Zur Vorbereitung des multispektralen und des multitemporalen Klassifizierungsschrittes der MAPP-LCC wurden Trainingsgebiete für alle zu berücksichtigenden Klassen definiert und deren spektrale Signaturen untersucht.

Hierbei wurden zunächst die Einflüsse der BRDF auf MERIS-Daten ermittelt, um schließlich Vorschläge zur Segmenteinteilung der spektralen Datenbank des MAPP-VA-LCC-Prozessors geben zu können. Diese Datenbank ermöglicht einen automatisierten Ablauf des überwachten Klassifizierungsschrittes bei gleichzeitiger Berücksichtigung der in MERIS-Daten auftretenden BRDF-Effekte. Es konnte festgestellt werden, dass die durch den Beobachtungszenitwinkel θ_r hervorgerufenen Effekte in vorwärts gerichteten Reflexionssituationen, also bei großen relativen Azimutwinkeln ϕ_{rel} , geringer als die Variabilität innerhalb der Klassen und geringer als der radiometrische Fehler von MERIS-Daten ausfallen. In rückwärts gerichteten Reflexionssituationen, also bei kleinen relativen Azimutwinkeln, wirkt sich der Beobachtungszenitwinkel dagegen deutlicher auf die spektralen Signaturen der betrachteten Landbedeckungs- / Landnutzungsklassen aus. Der Einfluss des Sonnenzenitwinkels θ_i ist schwierig zu beurteilen, da dieser Winkel in MERIS-Daten nur zu unterschiedlichen Jahreszeiten deutlich unterschiedliche Werte annimmt. Daher sind die Auswirkungen des Sonnenzenitwinkels nicht eindeutig von den Einflüssen der zu einem bestimmten Zeitpunkt auftretenden phänologischen Phase der betrachteten Vegetationsbedeckung trennbar. An vegetationslosen Flächen konnten jedoch die vom Sonnenzenitwinkel abhängigen BRDF-Effekte festgestellt werden. Es erscheint grundsätzlich sinnvoller, zusätzliche Farbklassen für bestimmte Perioden im Jahresverlauf einzuführen, als eine bestehende Klasse in Bezug auf den Sonnenzenitwinkel weiter zu untergliedern. Aufgrund der Untersuchungsergebnisse wird vorgeschlagen, die spektrale Datenbank in die in Tabelle 4.4 aufgelisteten Segmente zu untergliedern.

Des Weiteren diente die Analyse der Trainingsgebiete dazu, so genannte Farbklassen zu definieren, in denen sich die Phänologie der betrachteten Landbedeckungs-/ Landnutzungsklassen widerspiegelt. Im multispektralen Schritt des MAPP-VA-LCC-Prozessors werden die Bildpunkte der MERIS-Daten eben diesen Farbklassen zugewiesen. Es wurde untersucht, wie die Phänologie der Landbedeckungs- beziehungsweise Landnutzungsklassen in den spektralen Signaturen der Trainingsgebiete zum Ausdruck kommt, und in welche Farbklassen diese Signaturen zusammengefasst werden können. Die in Tabelle 4.5 aufgelisteten Farbklassen wurden zur Berücksichtigung im multispektralen Klassifizierungsschritt vorgeschlagen.

Zur Vorbereitung des multitemporalen Klassifizierungsschrittes wurden die Veränderungen der spektralen Signaturen im Jahresverlauf analysiert. Anhang A zeigt typische Reflexionskurven für alle Landbedeckungs- / Landnutzungsklassen. Aus den zuvor definierten Farbklassen und den Veränderungen der spektralen Signaturen im Jahresverlauf konnte schließlich für jede Landbedeckungs- / Landnutzungsklasse mindestens eine typische zeitliche Abfolge von Farbklassen in monatlichen Zeitschritten festgelegt werden (s. Referenzvektoren in Tabelle 4.6). Nach einer multispektralen Testklassifizierung in ENVI wurde der Referenzvektor für die Klasse ‚Feuchtgebiete‘ gemäß Tabelle 5.4 abgeändert, die übrigen Referenzvektoren konnten für den untersuchten Zeitraum bestätigt werden.

Weitere Untersuchungen der spektralen Signaturen bezogen sich auf eine mögliche Verringerung des Rechenzeitbedarfs durch Kanalreduktion. In diesem Zusammenhang ist es sinnvoll, die Kanäle 1 bis 3 von der Klassifizierung auszuschließen, da diese stark durch die Streuung an Aerosolen beeinflusst sind. Die Kanäle 7 und 8, 10 und 12 sowie 13 und 14 weisen Korrelationskoeffizienten über 0,985 auf und enthalten somit weitgehend redundante Informationen. Bei Testklassifizierungen in ENVI konnte gezeigt werden, dass die Kanäle 7, 12 und 14 mit geringen Einbußen der Klassifizierungsqualität vom Maximum-Likelihood-Verfahren ausgeschlossen werden könnten.

Die bisherige Wolkenerkennung geschieht in der MAPP-LCC mit Hilfe des Wolkenflags der MERIS-Level 2-Daten und liefert keine zufrieden stellenden Ergebnisse. In der vorliegenden Arbeit wurden Vorschläge gebracht, die dieses Problem ansatzweise verbessern. Allerdings können auch mit Hilfe der vorgeschlagenen Verbesserungsansätze Bereiche leichter Bewölkung nicht optimal erkannt werden. Es wird dennoch empfohlen, das Flag ‚bright‘ (L 1b) anstatt des bisher genutzten Wolkenflags (L 2) für die Wolkenmaskierung einzusetzen. Diese leicht umsetzbare Veränderung des Klassifizierungsalgorithmus wird, wenn auch nicht zu einer optimalen, so doch zu einer verbesserten Wolkenerkennung führen.

In einer monotemporalen Testklassifizierung mit Hilfe der Bildverarbeitungssoftware ENVI für den Zeitraum vom 2. August bis zum 13. August wurden gute Klassifizierungsergebnisse erzielt. Sowohl großflächige als auch detailliertere Strukturen konnten im Klassifizierungsverfahren erkannt werden (s. Abbildung 5.3). Die Validierung ergab, trotz nicht vermeidbarer Geolokationsabweichungen zwischen CORINE-Referenz und Klassifizierungsergebnis, eine Gesamtgenauigkeit von 57,3 % bei der Betrachtung von

acht Landbedeckungs- / Landnutzungsklassen und eine Gesamtgenauigkeit von 60,41 % bei der Berücksichtigung von sieben Farbklassen. Die besten Klassifizierungsergebnisse wurden für Nadelwälder und landwirtschaftliche Flächen erzielt. Bei letzteren konnte zwischen noch bestellten und bereits abgeernteten Flächen unterschieden werden. Die Klassifizierungsergebnisse wurden deutlich verbessert, indem für jede berücksichtigte Klasse individuelle Zurückweisungsschwellwerte definiert wurden. Im MAPP-VA-LCC-Prozessor sind klassenspezifische Schwellwerte bisher nicht vorgesehen, ihre Einführung erscheint aufgrund der Untersuchungsergebnisse jedoch erfolgsversprechend. Schwierigkeiten traten vor allem bei den Klassen ‚Feuchtgebiete‘ und ‚vegetationslose und -arme Flächen‘ auf. Verbesserungen bei der Identifizierung vegetationsloser Flächen können durch eine Vergrößerung der Varianz der entsprechenden Musterklasse erzielt werden. Insgesamt ist damit zu rechnen, dass sich das Klassifizierungsergebnis durch den multitemporalen Klassifizierungsschritt des MAPP-VA-LCC-Prozessors deutlich verbessern lassen wird (vgl. ARNDT 2001).

Um automatisierte Klassifizierungsergebnisse des MAPP-VA-LCC-Prozessors erhalten zu können, sind noch einige wichtige Arbeitsschritte durchzuführen. Zunächst muss der monotemporale Klassifizierungsschritt für den gesamten Jahresverlauf in Testläufen des Prozessors überprüft werden. Hierbei sollten die in dieser Arbeit vorgeschlagenen Vorgaben bezüglich Datenbanksegmenten und Farbklassen angewendet und gegebenenfalls optimiert werden. Weiterhin ist zu prüfen, wie sich die vorgeschlagene Kanalreduktion in den Klassifizierungsergebnissen des Prozessors bei der Betrachtung unterschiedlicher Bezugszeiträume auswirkt. Der multitemporale Klassifizierungsschritt wurde in der vorliegenden Arbeit noch nicht in Testklassifizierungen überprüft. Dieser Analyseschritt muss folglich ebenfalls mit Hilfe des MAPP-VA-LCC-Prozessors getestet werden. Die Referenzvektoren sollten in Folge dieser multitemporalen Testklassifizierungen auf Zeitschritte von zehn Tagen angepasst werden.

Das Klassifizierungsverfahren des MAPP-VA-LCC-Prozessors kann, nach einer erfolgreichen Anwendung auf Deutschland, auf die gesamte Fläche Europas ausgeweitet werden. Hierfür ist lediglich die Definition einiger zusätzlicher Referenzvektoren und Farbklassen nötig, so dass beispielsweise auch typische nordeuropäische Landbedeckungsklassen wie etwa borealer Nadelwald klassifizierbar werden.

Bei der künftigen Klassifizierung mit Hilfe des MAPP-VA-LCC-Prozessors ist mit Schwierigkeiten besonders bezüglich Wolkenerkennung und geringen, aber doch entscheidenden Ungenauigkeiten in der Georeferenzierung zu rechnen. Klassifizierungsartefakte an Winkelsegmentgrenzen der spektralen Datenbank werden nicht völlig vermeidbar bleiben. Zudem ist absehbar, dass in einigen Fällen scharfe Brüche in den monotemporalen Klassifizierungsergebnissen auftreten werden, die auf Kalibrierungsungenauigkeiten der MERIS-Kameras zurückzuführen sind.

Insgesamt erscheint das Klassifizierungsverfahren des MAPP-VA-LCC-Prozessors jedoch äußerst erfolgsversprechend. Die Methodik berücksichtigt den multispektralen ebenso wie den multitemporalen Informationsgehalt von MERIS-Daten und ermöglicht gleichzeitig eine jährliche, automatisierte Datenaktualisierung. Mit einer räumlichen Auflösung von 300 m sind diese aktuellen Landbedeckungs- beziehungsweise Landnutzungs-

informationen besonders als Eingangsdaten für umweltwissenschaftliche Modellrechnungen interessant, für die bisher meist nur Landbedeckungsdaten mit einer Auflösung von 1 km zur Verfügung stehen.

Literaturverzeichnis

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

ANDERSON, J.R., E.E. HARDY, J.T. ROACH & R.E. WITMER (1976): A Land Use and Land Cover Classification System for Use with Remote Sensor Data. –In: U.S. Geological Survey Professional Paper 964, Washington.

ARNDT, M. (2001): Landbedeckungskartierung von Deutschland auf der Grundlage einer optischen Satellitendaten Zeitreihe: In Vorbereitung des MERIS-LCC-Prozessors. Diplomarbeit, Universität zu Köln. – [unveröff.].

AVERY, T.E. & G.L. BERLIN (1992): Fundamentals of Remote Sensing and Airphoto Interpretation. New York.

BELWARD, A.S. (1996): The IGBP-DIS Global 1 km Land Cover Data Set (DISCover): Proposal and Implementation Plans. –In: IGBP-DIS Working Paper 13, Toulouse.

BELWARD, A.S., J.E. ESTES & K.D. KLINE (1999): The IGBP-DIS Global 1-Km Land-Cover Data Set DISCover: A Projekt Overview. –In: Photogrammetric Engineering and Remote Sensing 65 (9), 1013-1020.

BOSSARD, M., J. FERANEC & J. OTAHEL (2000): CORINE Land Cover Technical Guide: Addendum 2000. EEA Technical Report 40, Kopenhagen.

BURLEY, T.M. (1961): Land Use or Land Utilization? –In: The Professional Geographer 13, 18-20.

CAMACHO DE COCA, F. (2003): Evaluation of the DISMA Prototyping Algorithm for Vegetation Parameters Retrieval on a Global Scale Using the BRDF POLDER/ADEOS Database. Visiting Scientist Report, Universität Valencia, Toulouse.

CHILAR, J. (2000): Land Cover Mapping of Large Areas from Satellites: Status and Research Priorities. –In: International Journal of Remote Sensing 21 (6/7), 1093-111.

CLEVERS, J.G.P.W., H.M. BARTHOLOMEUS, C.A. MÜCHER & A.J.W. DE WIT (2003): Use of MERIS Data for Land Cover Mapping in the Netherlands. – In: ESA (Hrsg.): Proceedings of MERIS User Workshop, 10.-13. November 2003, o. S., Noordwijk.

CONGALTON, R.G. (1991): A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. – In: Remote Sensing of Environment 37, 35-46.

DI GREGORIO, A. & L.J.M. JANSEN (2000): Land Cover Classification System (LCCS): Classification Concepts and User Manual. Rom.

DUESMANN, B., R. KOOPMAN & L. VENTIMIGLIA (submitted 2004): The Attitude of ENVISAT: The Past and Current Pointing Performance Observed by the Payload. -In: ESA (Hrsg.): Proceedings of the ENVISAT Symposium, 6.-10. September 2004, o. S., o. O..

ESA (1995): MERIS. The Medium Resolution Imaging Spectrometer. Report of the MERIS Scientific Advisory Group SP-1184, Noordwijk.

ESA (2000): ENVISAT-1 Products Specifications 11: MERIS Products Specifications. Frascati.

ESA & ASTRIUM GmbH (2002): ENVISAT: Caring for the Earth. Bristol.

FRIEDL, M. A., D. K. MCIVER, J. C. F. HODGES, X. Y. ZHANG, D. MUCHONEY, A. H. STRAHLER, C. E. WOODCOCK, S. GOPAL, A. SCHNEIDER, A. COOPER, A. BACCINI, F. GAO, C. SCHAAF (2002): Global Land Cover Mapping from MODIS: Algorithms and Early Results. –In: Remote Sensing of Environment 83, 287-302.

FRITZ, S., E. BARTHOLOME, A. BELWARD, A. HARTLEY, H.-J. STIBIG, H. EVA, P. MAYAUX, S. BARTALEV, R. LATIFOVIC, S. KOLMERT, P.S. ROY, S. AGRAWAL, W. BINGFANG, X. WENTING, M. LEDWITH, J.-F. PEKEL, C. GIRI, S. MÜCHER, E. DE BADTS, R. TATEISHI, J.-L. CHAMPEAUX & P. DEFOURNY (2003): Harmonisation, Mosaicing and Production of the Global Land Cover Database (Beta Version). EUR 20849 EN,JRC-EC, Ispra.

GANGKOFNER, U. (1996): Methodische Untersuchungen zur Vor- und Nachbereitung der Maximum Likelihood Klassifizierung optischer Fernerkundungsdaten. –In: Münchener Geographische Abhandlungen B 24, München.

GEIDER, R.J., E.H. DELUCIA, P.G. FALKOWSKI, A.C. FINZI, J.P. GRIME, J. GRACE, T.M. KANA, J. LA ROCE, S.P. LONG, B.A. OSBORNE, T. PLATT, I.C. PRENTICE, J.A. RAVEN, W.H. SCHLESINGER, V. SMETACEK, V. STUART, S. SATHYENDRANATH, R. B. THOMAS, T.C. VOGELMANN, P. WILLIAMS & F.I. WOODWARD (2001): Primary Productivity of Planet Earth: Biological Determinants and Physical Constraints in Terrestrial and Aquatic Habitats, Global Change Biology 7, 849-882.

GEßNER, U., K.P. GUENTHER & S.W. MAIER (submitted 2004): Land Cover / Land Use Map of Germany Based on MERIS Full Resolution Data. –In: ESA (Hrsg.): Proceedings of the ENVISAT Symposium, 6.-10. September 2004, o. S., o. O..

GOFC-GOLD (2004 a): Land Cover and Change: Newsletter of the GOFC-GOLD Land Cover Project Office 3, Jena.

GOFC-GOLD (2004 b): Land Cover and Change: Newsletter of the GOFC-GOLD Land Cover Project Office 4, Jena.

GÜNTHER, K.P., A. NEUMANN, P. GEGE, R. DOERFFER, J. FISCHER & C. BROCKMANN (2002): MERIS – Value Added – Products for Land-, Water- and Atmospheric Applications. – In: DECH, S. (Hrsg.): Tagungsband 19. DFD-Nutzerseminar, 15.-16. Oktober 2002, 37-51, Oberpfaffenhofen.

HEYMANN, Y. (1994): CORINE Land Cover: Technical Guide. EUR 12585 EN, EC, Luxemburg.

HILDEBRANDT, G. (1996): Fernerkundung und Luftbildmessung: für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie. Heidelberg.

KAPPAS, M. (1994): Fernerkundung nah gebracht: Leitfaden für Geowissenschaftler. Bonn.

KEUCHEL, J., S. NAUMANN, M. HEILER & A. SIEGMUND (2003): Automatic Land Cover Analysis for Tenerife by Supervised Classification Using Remotely Sensed Data. –In: Remote Sensing of Environment 86, 530-541.

KIEFL, R., M. KEIL, G. STRUNZ, H. MEHL & B. MOHAUPT-JAHR (2003): CORINE Land Cover 2000 – Stand des Teilprojektes in Deutschland.
http://caf.dlr.de/caf/anwendungen/projekte/projekte_nutzung/corine/x_images/agit2003_clc2000_Kiefl_et_al.pdf

KYUNG-SOO, H., J.-L. CHAMPEAUX & J.-L. ROUJEAN (2004): A land Cover Classification Product over France at 1 km Resolution Using SPOT/VEGETATION Data. – In: Remote Sensing of Environment 92, 52-66.

LIANG, S. (2004): Quantitative Remote Sensing of Land Surfaces. New Jersey.

LO, C.P. (1986): Applied Remote Sensing. New York.

LOVELAND, T.R., B.C. REED, J.F. BROWN, D.O. OHLEN, Z. ZHU, L. YANG & J.W. MERCHANT (2000): Development of a Global Land Cover Characteristics Database and IGBP DISCover from 1 km AVHRR Data. –In: International Journal of Remote Sensing 21 (6/7), 1303-1330.

MÜCHER, C.A., K.T. STEINNOCHER, F.P. KRESSLER & C. HEUNKS (2000): Land Cover Characterization and Change Detection for Environmental Monitoring of Pan-Europe. –In: International Journal of Remote Sensing 21 (6/7), 1159-1181.

OLSON, J.S. (1994): Global Ecosystems Framework: Definitions. Report USGS EROS Data Center, Sioux Falls.

PERDIGAO, V. & A. ANNONI (1997): Technical and Methodological Guide for Updating CORINE Land Cover Data Base. EUR 17288 EN, JRC-EC-EEA, Brüssel / Luxemburg.

RAHMAN, H. & G. DEDIEU (1994): SMAC: A Simplified Method for Atmospheric Correction of Satellite Measurements in the Solar Spectrum. –In: International Journal of Remote Sensing 15 (1), 123-143.

REINARTZ, P. (1989): Untersuchungen zur multispektralen Klassifizierung von schwer trennbaren Klassen mit Beispielen aus Waldschadensgebieten. Oberpfaffenhofen.

RICHARDS, J.A. & X. JIA (1999): Remote Sensing Digital Image Analysis: An Introduction. Berlin / Heidelberg.

RICHTER, R. & D. SCHLÄPFER (2003): Geo-Atmospheric Processing of Airborne Imaging Spectrometry Data. Part 2: Atmospheric/Topographic Correction. –In: International Journal of Remote Sensing 23 (13), 2631-2649.

ROEDEL, W. (1992): Physik unserer Umwelt: die Atmosphäre. Berlin / Heidelberg.

RUNNING, S.W., T.R. LOVELAND & L.L. PIERCE (1994): A Vegetation Classification Logic Based on Remote Sensing for Use in Global Biogeochemical Models. –In: Ambio 23, 77-81.

SANTER, R., V. CARRERE, D. DESSAILLY, P. DUBUISSON & J.-C. ROGER (2000): Algorithm Theoretical Basis Document ATBD 2.15 : Atmospheric Corrections over Land. http://envisat.esa.int/instruments/meris/pdf/atbd_2_15.pdf, 10.08.2004

SCEPAN, J. (1999): Thematic Validation of High-Resolution Global Land-Cover Data Sets. –In: Photogrammetric Engineering and Remote Sensing 65 (9), 1051-1060.

SCHOWENGERDT, R.A. (1997): Remote Sensing: Models and Methods for Image Processing. San Diego.

SEILER, R. & E. CSAPLOVICS (2003): Monitoring Land Cover Changes of the Niger Inland Delta (Mali) by Means of Envisat MERIS Data. –In: ESA (Hrsg.): Proceedings of MERIS User Workshop, 10.-13. November 2003, o. S., Noordwijk.

SKINNER, L. & A. LUCKMAN (2003): Deriving Landcover Information over Siberia Using MERIS and MODIS Data. –In: ESA (Hrsg.): Proceedings of MERIS User Workshop, 10.-13. November 2003, o. S., Noordwijk.

SWAIN, P.H. & S.M. DAVIS (1978): Remote Sensing: The Quantitative Approach. New York.

UNFCCC (1997): Kyoto Protocol to the United Nations Framework Convention on Climate Change.

http://unfccc.int/files/essential_background/kyoto_protocol/application/pdf/07a01.pdf, 23.09.2004

Internetquellen

DWD (2004): Agrowetter: Phänologische Meldestatistik.

http://www.agrowetter.de/produkte/phaeno/phaeno_GBG/index.htm, 15.11.2004

ESA (2002): MERIS Product Handbook.

<http://envisat.esa.int/dataproducts/meris/CNTR.htm>, 15.06.2004

ESA a: ENVISAT Mission and System. <http://envisat.esa.int/m-s/>, 03.06.2004

ESA b: ENVISAT Instruments: MERIS. <http://envisat.esa.int/instruments/meris/>, 15.11.2004

FAO (2003): Africover. <http://africover.org>, 18.06.2004

FAO (2004): FAOSTAT data 2004. <http://apps.fao.org>, 11.10.2004

JRC-IES (2004 a): Land Cover Classification Legend: List of Land Cover Classifiers Used.

http://www.gvm.jrc.it/glc2000/Legend/GLC2000_Lccs_110604_classifiers.pdf, 20.09.2004

JRC-IES (2004 b): Land Cover Classification – Standard Description.

http://www.gvm.jrc.it/glc2000/Legend/GLC2000_Lccs_110604.pdf, 15.09.2004

JRC-IES (2004 c): GLC 2000 Global Legend (aggregated from regional classes using LCCS).

http://www.gvm.jrc.it/glc2000/Legend/GLC2000-Global_Legend.pdf, 15.09.2004

SCHULZ, J. (1998): Projekt MERIS-Nutzung: MERIS Application and Regional Products Project – MAPP. <http://auc.dfd.dlr.de/app/MAPP/>, 03.06.2004

WDC-RSAT: Missions and Sensors. <http://wdc.dlr.de/sensors/index.html>, 19.11.2004

Sonstige Quellen

UMWELTBUNDESAMT (Hrsg., 10/2004): CORINE Land Cover 2000 von Deutschland: Vorläufige Version. Los 1-5, Rasterdatensatz, 300 m Auflösung.

UMWELTBUNDESAMT (Hrsg., 11/ 2004): CORINE Land Cover 2000 von Deutschland: Vorläufige Version. Komplette Abdeckung, Rasterdatensatz, 300 m Auflösung.

Anhang A Spektrale Signaturen

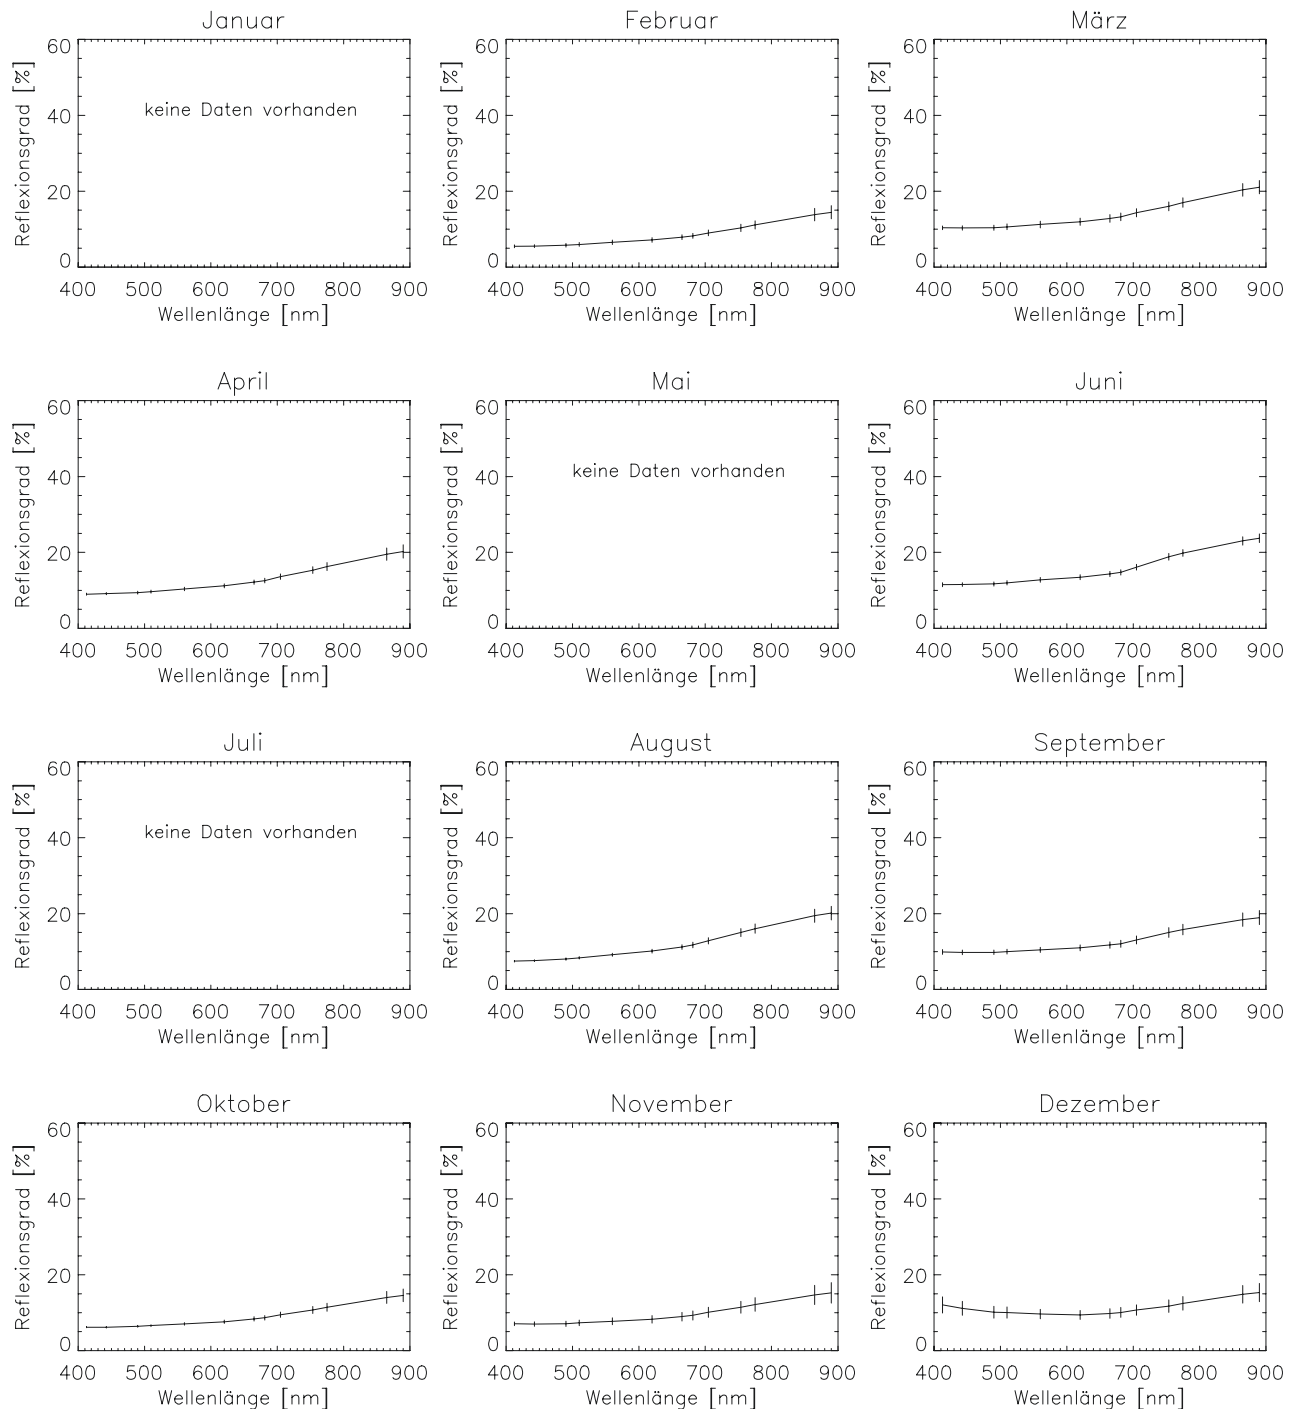


Abbildung A.1: Jahresverlauf der spektralen Signaturen der Klasse 'vegetationslose und -arme Flächen', dunkle Variante (eigener Entwurf)

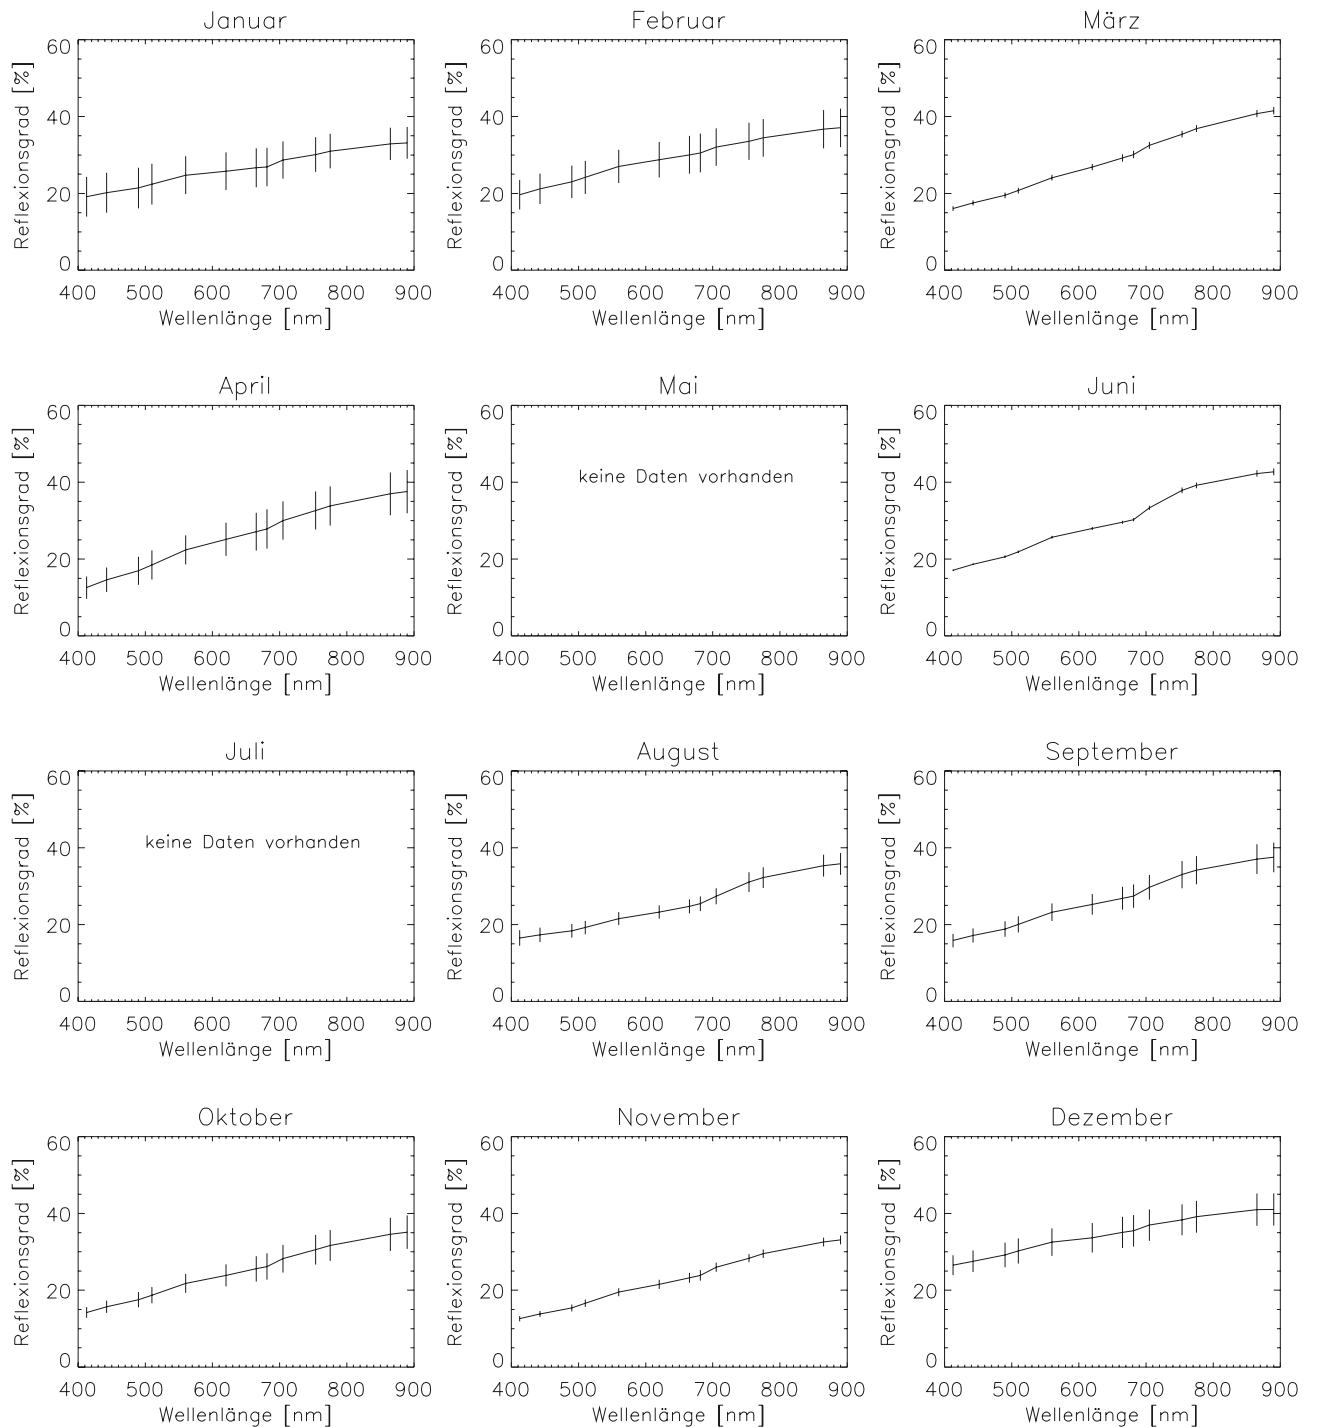


Abbildung A.2: Jahresverlauf der spektralen Signaturen der Klasse 'vegetationslose und -arme Flächen', helle Variante (eigener Entwurf)

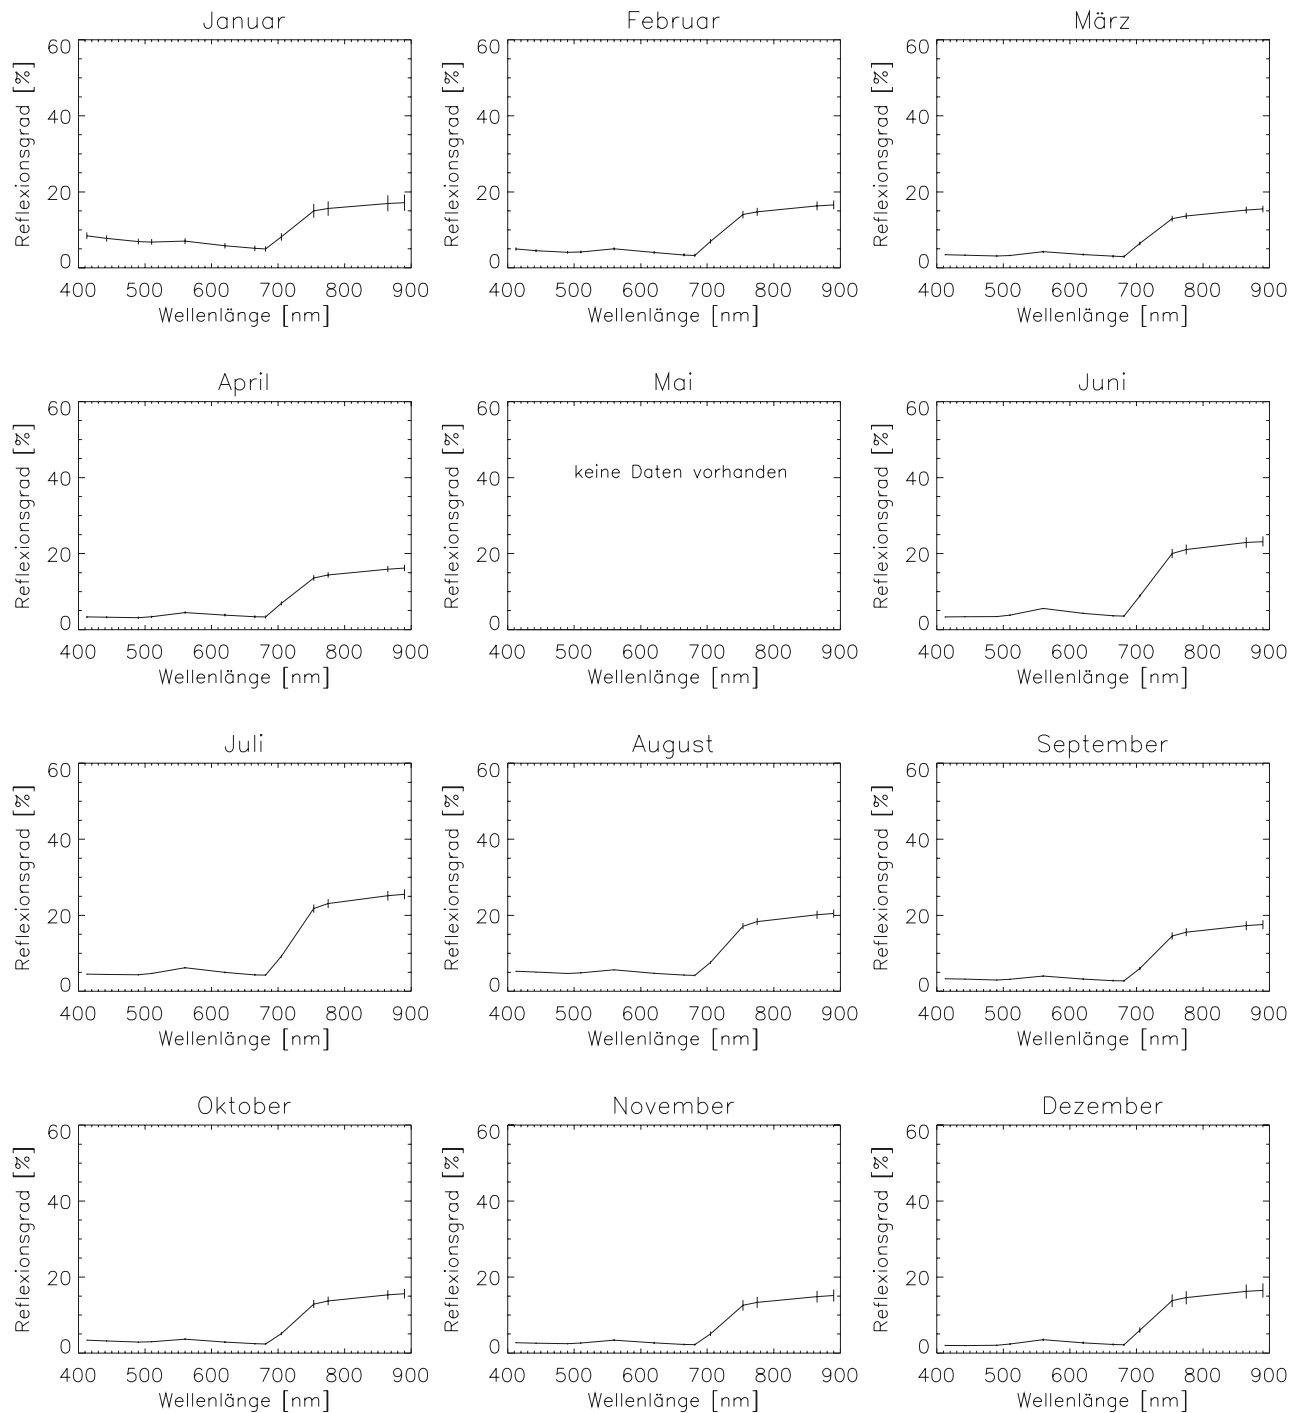


Abbildung A.3: Jahresverlauf der spektralen Signaturen der Klasse 'immergrüner Nadelwald' (eigener Entwurf)

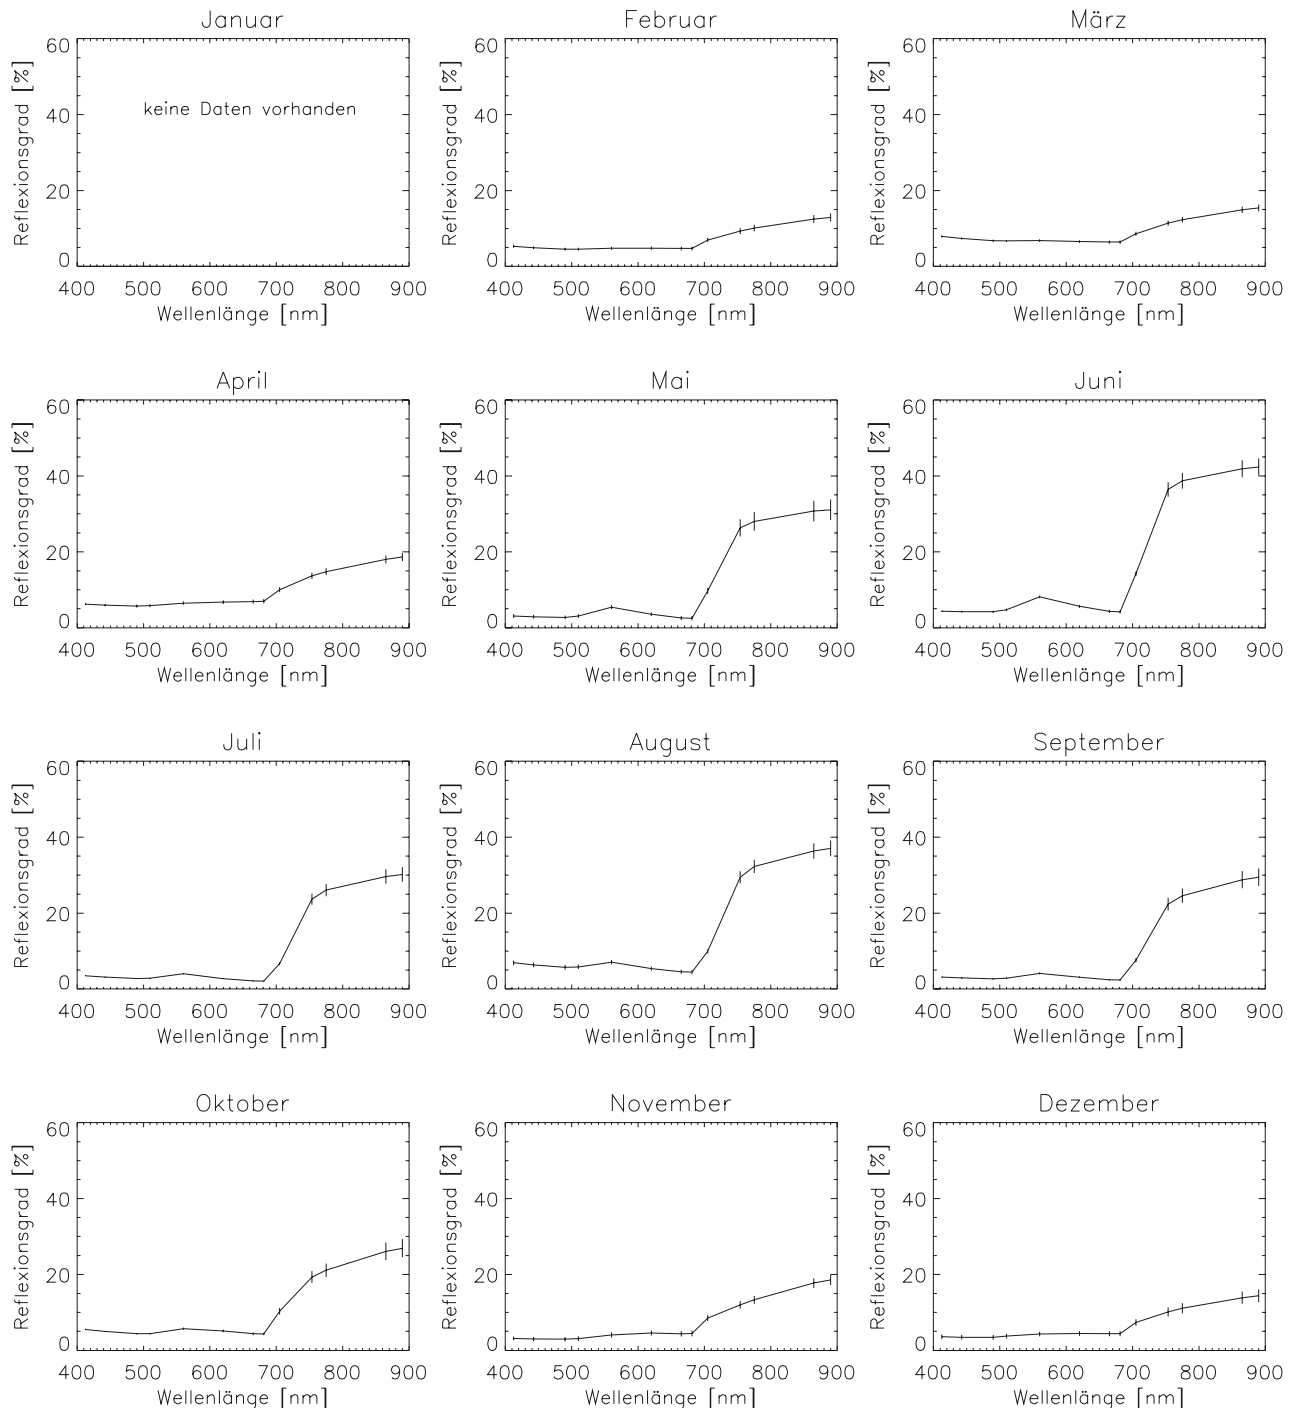


Abbildung A.4: Jahresverlauf der spektralen Signaturen der Klasse ‚sommergrüner Laubwald‘ (eigener Entwurf)

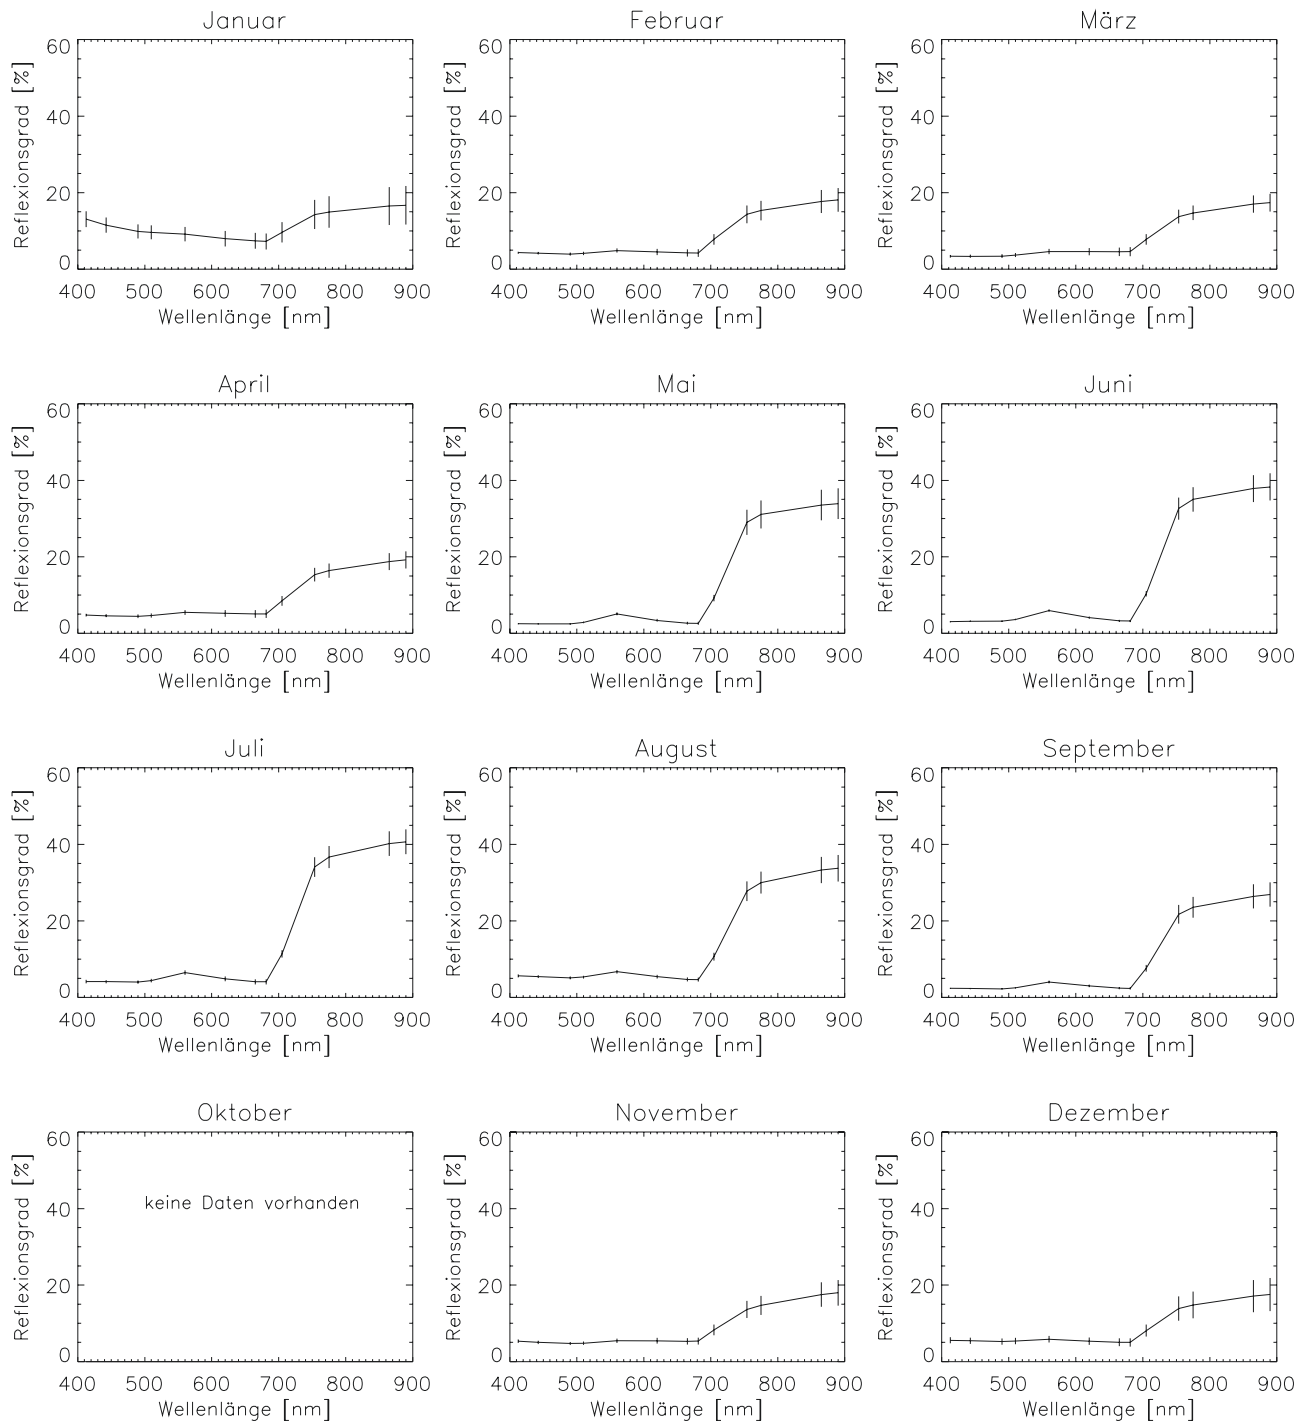


Abbildung A.5: Jahresverlauf der spektralen Signaturen der Klasse ‚Mischwald‘
(eigener Entwurf)

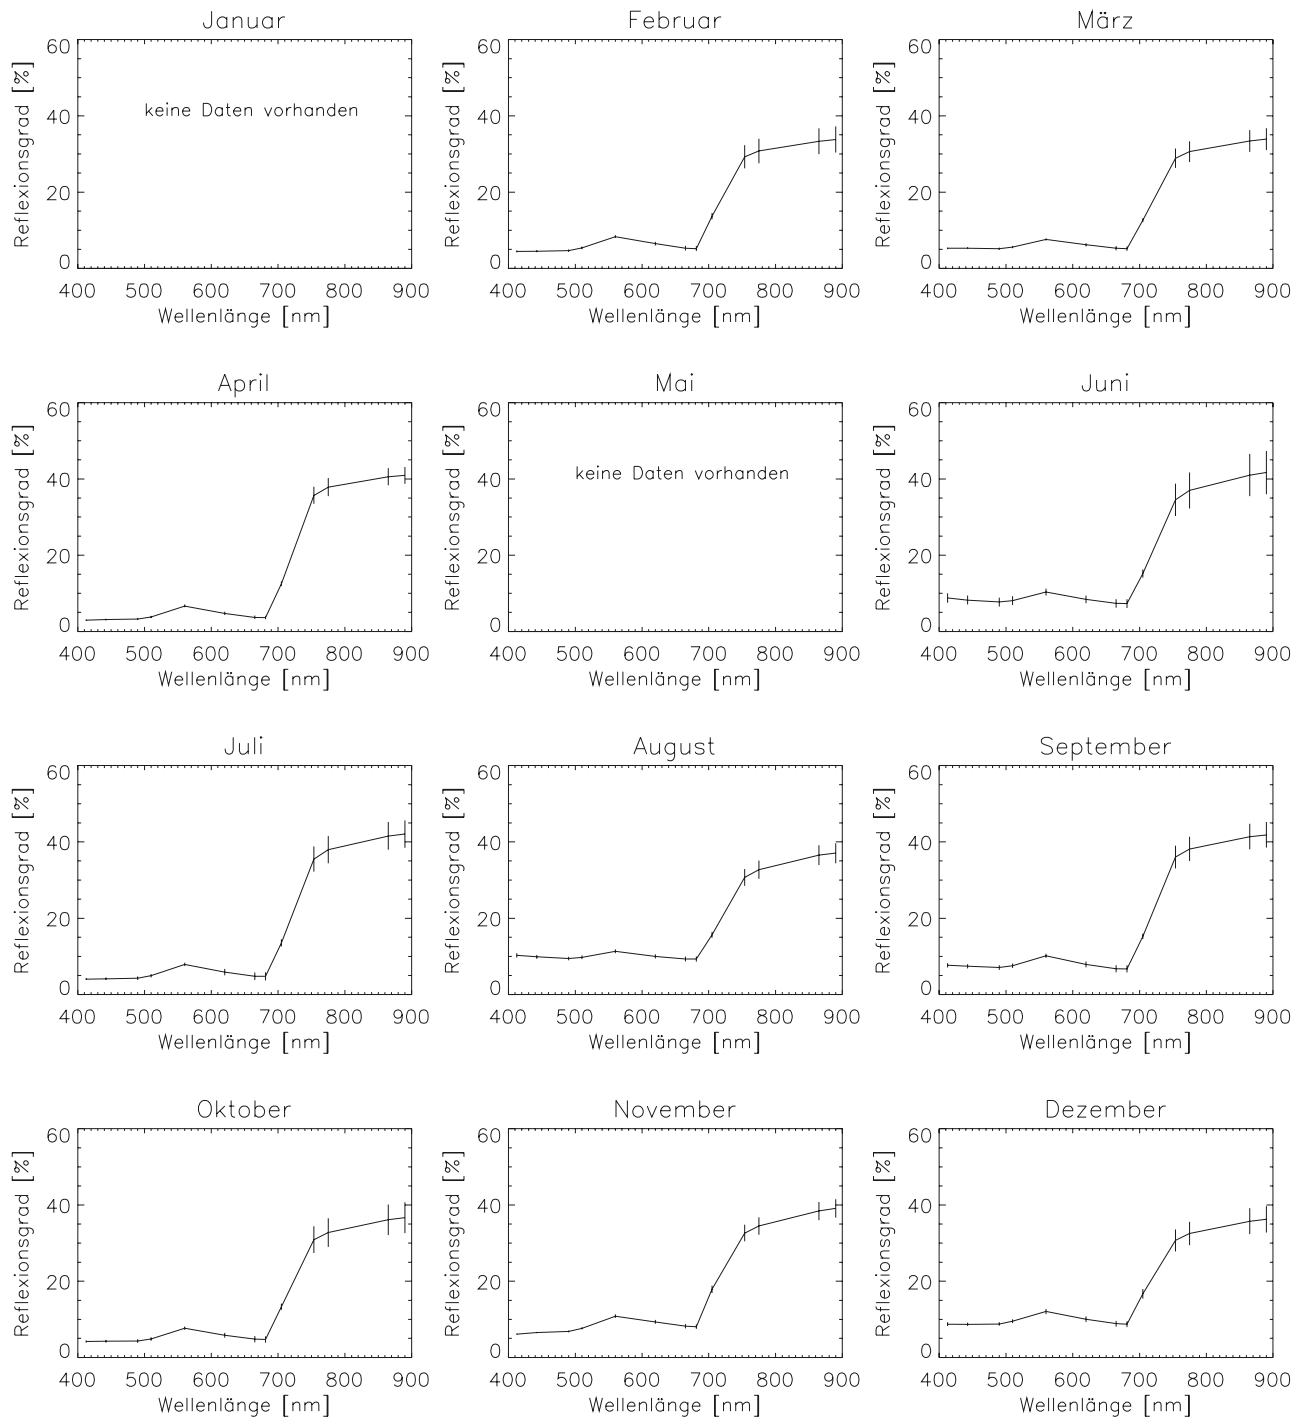


Abbildung A.6: Jahresverlauf der spektralen Signaturen der Klasse ‚Grasland‘
(eigener Entwurf)

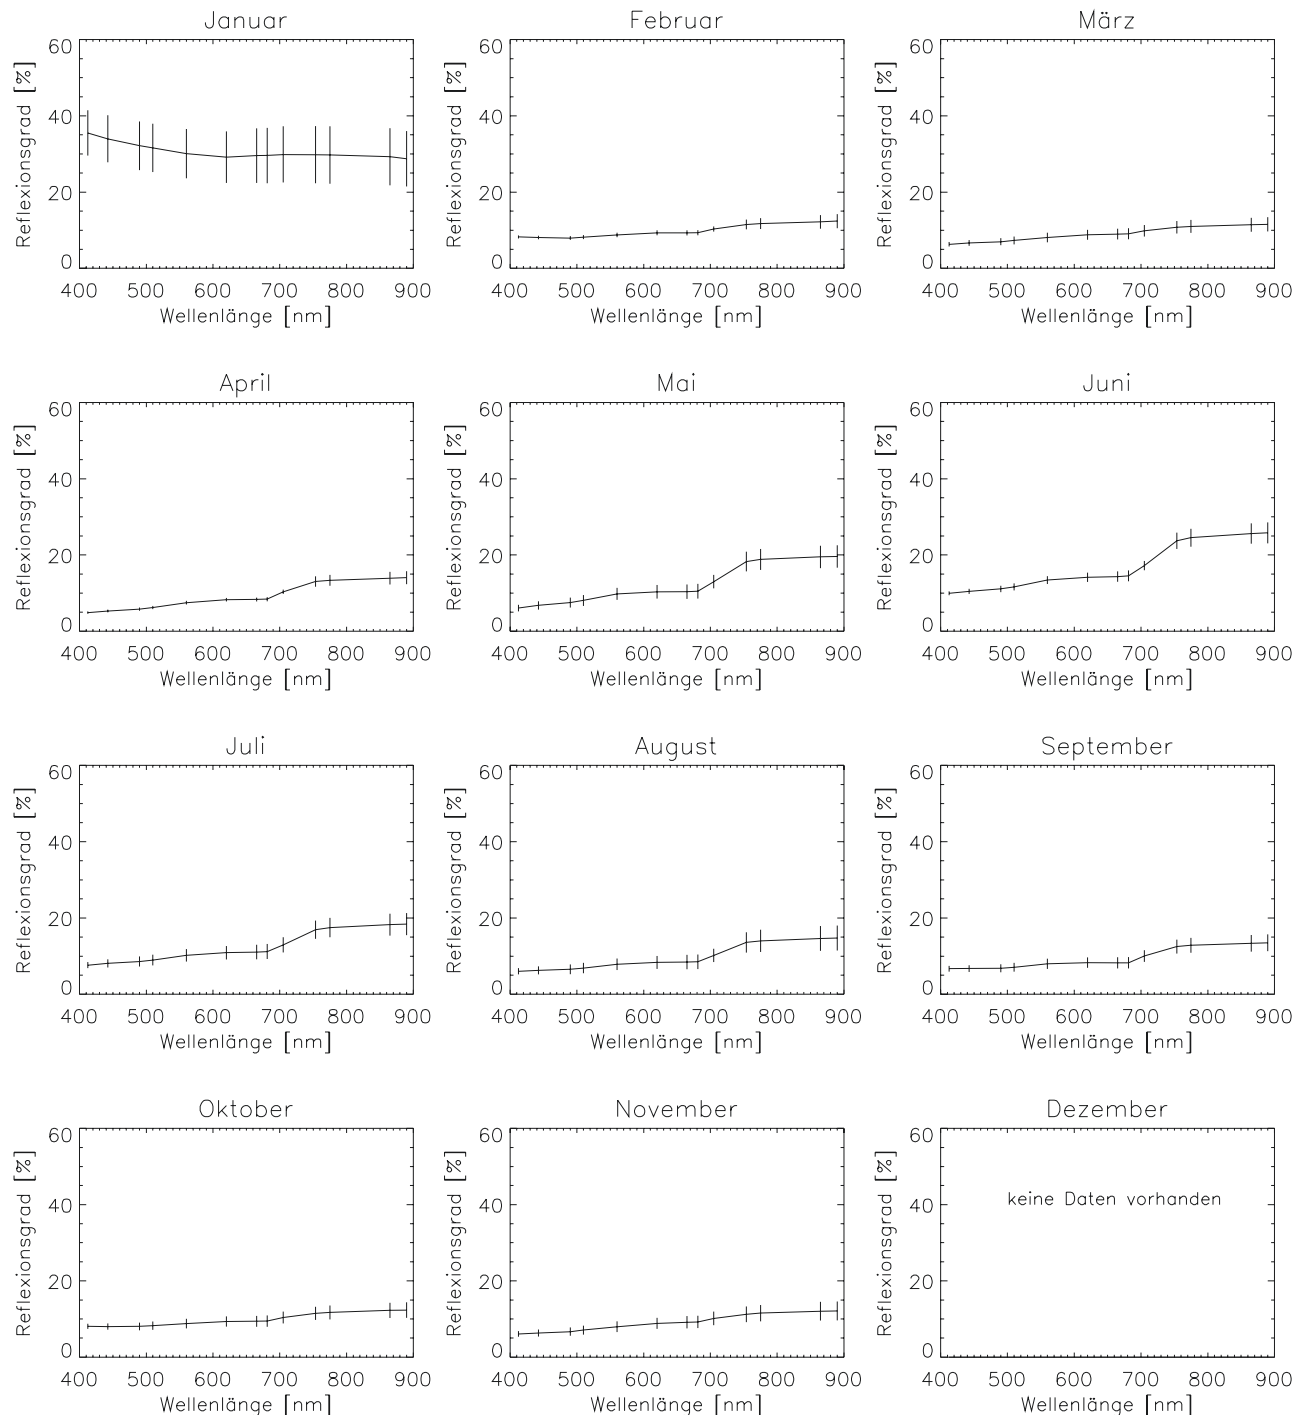


Abbildung A.7: Jahresverlauf der spektralen Signaturen der Klasse 'städtische und bebaute Flächen' (eigener Entwurf)

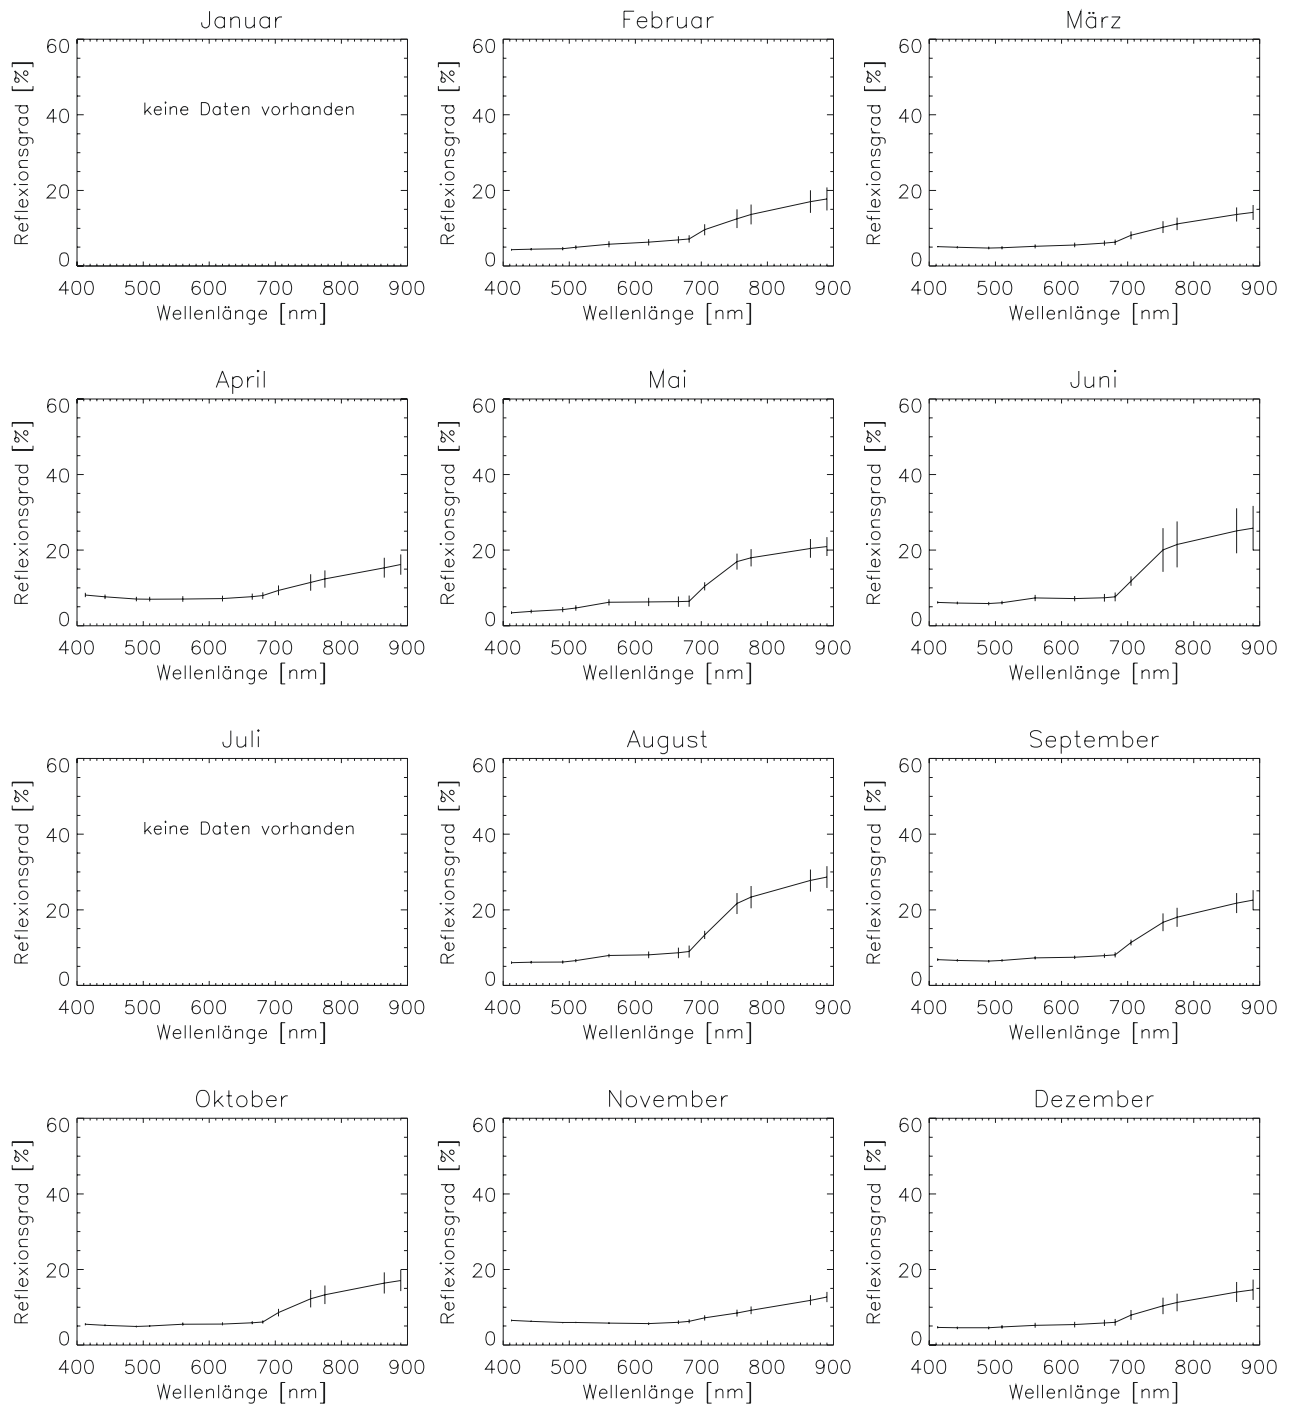


Abbildung A.8: Jahresverlauf der spektralen Signaturen der Klasse 'Feuchtgebiete' (eigener Entwurf)

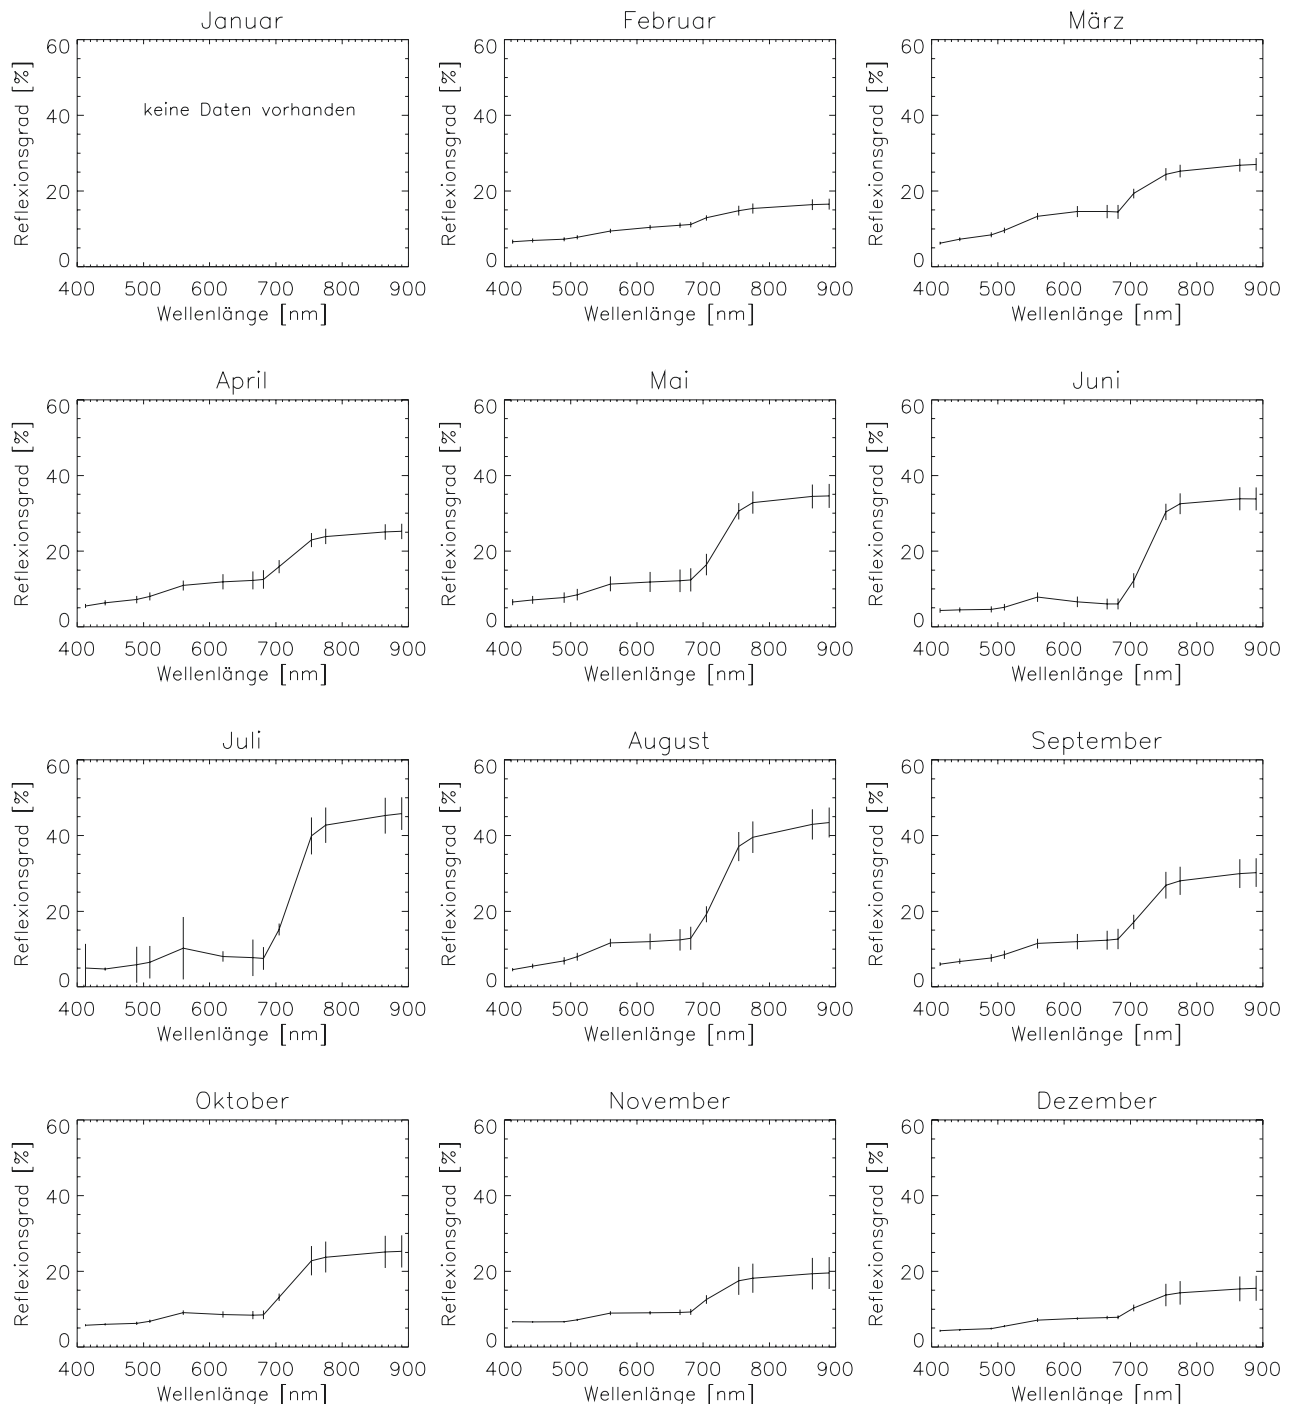


Abbildung A.9: Jahresverlauf der spektralen Signaturen der Klasse ‚landwirtschaftliche Flächen‘ (eigener Entwurf)

Anhang B Korrelationsmatrizen

Tabelle B.1: Korrelationsmatrix für die Klasse ‚vegetationslose und –arme Flächen‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.987	1											
3	0.984	0.991	1										
4	0.981	0.990	0.997	1									
5	0.969	0.979	0.991	0.993	1								
6	0.934	0.946	0.964	0.968	0.985	1							
7	0.871	0.882	0.906	0.912	0.941	0.984	1						
8	0.838	0.849	0.876	0.882	0.915	0.970	0.997	1					
9	0.772	0.784	0.814	0.821	0.861	0.934	0.982	0.992	1				
10	0.651	0.661	0.695	0.702	0.753	0.851	0.930	0.952	0.981	1			
12	0.573	0.583	0.619	0.626	0.681	0.793	0.886	0.916	0.957	0.994	1		
13	0.339	0.345	0.381	0.388	0.451	0.591	0.721	0.766	0.836	0.924	0.959	1	
14	0.297	0.302	0.337	0.345	0.408	0.551	0.686	0.734	0.809	0.904	0.943	0.998	1

Tabelle B.2: Korrelationsmatrix die Klasse ‚immergrüner Nadelwald‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.818	1											
3	0.753	0.864	1										
4	0.759	0.890	0.898	1									
5	0.577	0.691	0.786	0.851	1								
6	0.663	0.798	0.899	0.919	0.919	1							
7	0.675	0.816	0.911	0.927	0.881	0.979	1						
8	0.666	0.823	0.915	0.923	0.875	0.976	0.989	1					
9	0.457	0.566	0.644	0.733	0.944	0.816	0.773	0.766	1				
10	0.103	0.127	0.145	0.257	0.586	0.293	0.232	0.231	0.752	1			
12	0.101	0.115	0.131	0.241	0.570	0.275	0.215	0.213	0.738	0.999	1		
13	0.116	0.133	0.151	0.261	0.587	0.296	0.236	0.234	0.751	0.998	0.999	1	
14	0.117	0.128	0.149	0.259	0.585	0.295	0.236	0.233	0.749	0.998	0.998	0.999	1

Tabelle B.3: Korrelationsmatrix für die Klasse ‚sommergrüner Laubwald‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.976	1											
3	0.970	0.981	1										
4	0.958	0.974	0.987	1									
5	0.907	0.926	0.951	0.968	1								
6	0.855	0.880	0.918	0.943	0.974	1							
7	0.850	0.876	0.918	0.938	0.957	0.989	1						
8	0.841	0.868	0.910	0.931	0.950	0.986	0.994	1					
9	0.581	0.613	0.667	0.710	0.841	0.857	0.820	0.816	1				
10	0.679	0.669	0.664	0.654	0.667	0.565	0.516	0.502	0.583	1			
12	0.661	0.649	0.642	0.630	0.637	0.533	0.485	0.471	0.549	0.998	1		
13	0.597	0.583	0.578	0.569	0.590	0.491	0.440	0.425	0.550	0.987	0.992	1	
14	0.589	0.576	0.569	0.559	0.582	0.485	0.432	0.419	0.549	0.984	0.989	0.999	1

Tabelle B.4: Korrelationsmatrix für die Klasse ‚Mischwald‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.772	1											
3	0.734	0.919	1										
4	0.625	0.829	0.929	1									
5	0.455	0.680	0.836	0.897	1								
6	0.313	0.585	0.764	0.855	0.927	1							
7	0.300	0.565	0.740	0.833	0.882	0.988	1						
8	0.295	0.553	0.731	0.832	0.880	0.984	0.996	1					
9	0.232	0.473	0.644	0.728	0.915	0.911	0.871	0.868	1				
10	0.223	0.308	0.366	0.337	0.527	0.352	0.249	0.231	0.608	1			
12	0.200	0.286	0.337	0.312	0.498	0.327	0.226	0.208	0.587	0.998	1		
13	0.200	0.297	0.367	0.351	0.548	0.396	0.299	0.282	0.649	0.995	0.995	1	
14	0.199	0.308	0.380	0.367	0.564	0.414	0.317	0.300	0.663	0.993	0.993	0.999	1

Tabelle B.5: Korrelationsmatrix für die Klasse ‚Grasland‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.870	1											
3	0.661	0.918	1										
4	0.646	0.911	0.997	1									
5	0.634	0.898	0.986	0.991	1								
6	0.563	0.863	0.987	0.989	0.979	1							
7	0.513	0.831	0.977	0.979	0.966	0.997	1						
8	0.502	0.823	0.974	0.976	0.963	0.996	1.000	1					
9	0.456	0.786	0.951	0.960	0.969	0.977	0.978	0.978	1				
10	0.192	0.150	0.140	0.152	0.241	0.113	0.084	0.082	0.223	1			
12	0.144	0.117	0.126	0.139	0.228	0.104	0.078	0.077	0.223	0.997	1		
13	0.009	0.078	0.175	0.194	0.283	0.179	0.166	0.168	0.331	0.937	0.957	1	
14	-0.025	0.060	0.173	0.194	0.283	0.183	0.173	0.175	0.341	0.914	0.937	0.996	1

Tabelle B.6: Korrelationsmatrix für die Klasse ‚städtische und bebaute Flächen‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.994	1											
3	0.988	0.995	1										
4	0.984	0.993	0.999	1									
5	0.973	0.985	0.996	0.998	1								
6	0.960	0.973	0.986	0.987	0.991	1							
7	0.954	0.967	0.982	0.982	0.987	0.999	1						
8	0.953	0.966	0.981	0.981	0.986	0.999	1.000	1					
9	0.924	0.940	0.961	0.963	0.975	0.989	0.990	0.990	1				
10	0.746	0.765	0.800	0.809	0.836	0.852	0.853	0.853	0.916	1			
12	0.735	0.752	0.788	0.797	0.825	0.839	0.840	0.840	0.906	0.999	1		
13	0.738	0.756	0.790	0.801	0.828	0.838	0.838	0.838	0.904	0.994	0.997	1	
14	0.736	0.754	0.789	0.800	0.827	0.837	0.837	0.837	0.903	0.992	0.994	0.999	1

Tabelle B.7: Korrelationsmatrix für die Klasse ‚Feuchtgebiete‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.938	1											
3	0.914	0.975	1										
4	0.910	0.963	0.988	1									
5	0.613	0.661	0.684	0.747	1								
6	0.701	0.726	0.768	0.770	0.452	1							
7	0.667	0.689	0.720	0.704	0.274	0.970	1						
8	0.649	0.673	0.704	0.688	0.251	0.964	0.997	1					
9	-0.466	-0.501	-0.448	-0.421	-0.217	0.085	0.029	0.028	1				
10	-0.647	-0.664	-0.650	-0.594	0.008	-0.636	-0.751	-0.758	0.474	1			
12	-0.639	-0.655	-0.645	-0.588	0.018	-0.639	-0.753	-0.761	0.455	0.999	1		
13	-0.644	-0.657	-0.650	-0.590	0.026	-0.619	-0.734	-0.740	0.467	0.995	0.996	1	
14	-0.651	-0.662	-0.656	-0.597	0.021	-0.619	-0.733	-0.738	0.469	0.992	0.994	0.999	1

Tabelle B.8: Korrelationsmatrix die Klasse ‚landwirtschaftliche Flächen‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.948	1											
3	0.883	0.970	1										
4	0.882	0.969	0.994	1									
5	0.837	0.903	0.913	0.945	1								
6	0.782	0.908	0.969	0.971	0.905	1							
7	0.748	0.881	0.954	0.946	0.842	0.990	1						
8	0.740	0.874	0.949	0.940	0.831	0.987	0.999	1					
9	0.769	0.840	0.863	0.902	0.982	0.879	0.813	0.802	1				
10	-0.159	-0.273	-0.362	-0.295	-0.006	-0.408	-0.519	-0.535	0.054	1			
12	-0.178	-0.292	-0.383	-0.318	-0.032	-0.430	-0.540	-0.556	0.027	0.999	1		
13	-0.164	-0.279	-0.371	-0.307	-0.027	-0.423	-0.533	-0.548	0.034	0.995	0.997	1	
14	-0.156	-0.272	-0.365	-0.300	-0.023	-0.418	-0.527	-0.543	0.039	0.994	0.995	1.000	1

Tabelle B.9: Korrelationsmatrix für die Klasse ‚abgeerntete landwirtschaftliche Flächen‘
(eigener Entwurf)

Band	1	2	3	4	5	6	7	8	9	10	12	13	14
1	1												
2	0.930	1											
3	0.819	0.962	1										
4	0.777	0.939	0.995	1									
5	0.650	0.852	0.945	0.970	1								
6	0.712	0.896	0.979	0.989	0.973	1							
7	0.711	0.891	0.975	0.982	0.953	0.997	1						
8	0.706	0.886	0.972	0.979	0.950	0.996	1.000	1					
9	0.517	0.750	0.888	0.922	0.972	0.954	0.942	0.942	1				
10	-0.195	0.028	0.210	0.291	0.501	0.334	0.289	0.288	0.589	1			
12	-0.205	0.020	0.205	0.286	0.495	0.331	0.288	0.286	0.588	1.000	1		
13	-0.150	0.090	0.289	0.366	0.559	0.421	0.387	0.387	0.668	0.984	0.987	1	
14	-0.134	0.109	0.311	0.387	0.575	0.444	0.412	0.413	0.687	0.977	0.981	0.999	1