

Sabine LEITNER BSc

Untersuchung verschiedener Features zur Kartierung von Degradation in Kongo

MASTERARBEIT

zur Erlangung des akademischen Grades
Master of Science (MSc)



Technische Universität Graz

Betreuer:

Univ.-Prof. Dr.rer.nat. Mathias Schardt
Institut für Fernerkundung und Photogrammetrie

Graz, August 2012

Beschluss der Curricula-Kommission für Bachelor-, Master- und Diplomstudien vom 10.11.2008
Genehmigung des Senates am 1.12.2008

EIDESSTATTLICHE ERKLÄRUNG

Ich erkläre an Eides statt, dass ich die vorliegende Arbeit selbstständig verfasst, andere als die angegebenen Quellen/Hilfsmittel nicht benutzt, und die den benutzten Quellen wörtlich und inhaltlich entnommene Stellen als solche kenntlich gemacht habe.

Graz, am

.....

(Unterschrift)

STATUTORY DECLARATION

I declare that I have authored this thesis independently, that I have not used other than the declared sources / resources, and that I have explicitly marked all material which has been quoted either literally or by content from the used sources.

.....

Date

.....

(signature)

Zusammenfassung

Im Rahmen der REDD Initiative zur Reduktion von Emissionen aus der Abholzung und Zerstörung von tropischen Wäldern werden in dieser Masterarbeit unterschiedliche Features zur Degradationskartierung von Wäldern in der Republik Kongo untersucht. Als Features sind in diesem Zusammenhang aus den Spektralbändern abgeleitete künstliche Kanäle zu verstehen. Einleitend wird die REDD Initiative vorgestellt sowie der Begriff der Degradation und deren Charakteristika erläutert. Anschließend werden die Methoden zur Degradationskartierung (Kartierung von Lücken und Beschirmung), von der Feldarbeit, über die visuelle Interpretation bis hin zur automatischen Bildverarbeitung von Satellitenbilddaten aus der Literatur vorgestellt. Aus diesen sowie aus der Analyse des zur Verfügung stehenden Datenmaterials werden für ein Testgebiet im Norden der Republik Kongo Features auf Basis von Landsatdaten berechnet. Die Ergebnisse daraus werden mit Referenzdaten aus der visuellen Interpretation einer Ikonosszene korreliert und analysiert. Als bestes Feature zur Kartierung von Degradation stellt sich dabei die spektrale Entmischungsanalyse (SMA) der Landsatbänder 3 (rot) und 4 (nahes Infrarot) heraus. Die Klassifizierung und Verifizierung dieser Daten zeigt jedoch, dass die Kartierung von kleinen Lücken eine Herausforderung darstellt. Des Weiteren wird anhand von Landsatdaten unter Verwendung der SMA eine multitemporale Analyse von Lücken und Wiederbewuchsflächen durchgeführt. Dabei zeigt sich, dass Lücken innerhalb von 3,5 Jahren nach der Holzentnahme am besten durch die Bodenfraktion resultierend aus der SMA beschrieben werden, während in den darauffolgenden Jahren der Wiederbewuchs auf diesen Flächen für ein Monitoring verwendet werden kann. Wiederbewuchs ist dabei am besten in der grünen Vegetationsfraktion zu beobachten.

Abstract

Within the initiative *Reducing Emissions from Deforestation and Degradation* (REDD) this master thesis investigates different features for degradation mapping of forests in the Republic of Congo. In this context features are defined as artificial bands extracted from spectral bands. After a short introduction of the REDD Initiative and the definition of degradation and their characteristics, the state of the art chapter gives an overview of the different methods for degradation mapping (mapping of gaps and canopy cover) from fieldwork to visual interpretation up to automatic approaches. According to the literature review and the existing data a stack of features is generated for a test site in the north of the Republic of Congo. These features are correlated to the ground-truth resulting from visual interpretation of an Ikonos Scene. The results are analyzed due to their potential for degradation mapping. The spectral unmixing of Landsat bands 3 (red) and 4 (near infrared) serves as best feature for degradation mapping. However, classification and verification of this feature showed that mapping of small gaps is challenging. Furthermore multi temporal analyses assess the time span for which degradation and re-vegetation is detectable. The latter is important as re-vegetation signals persist for a longer time period. The results showed that logging gaps can be detected within 3.5 years after the logging event in the soil fraction of SMA. In the following years re-vegetation can be well detected in the green vegetation fraction.

Danksagung

Hiermit möchte ich mich bei den Menschen bedanken, die mich während meiner Studienzeit und insbesondere während meiner Masterarbeit begleitet und unterstützt haben. Allen voran bei meiner Mutter, die mir mein Studium ermöglicht hat, mich in meinen Entscheidungen nie beeinflusst, jedoch immer unterstützt hat.

Weiters möchte ich mich bei meinen Studienkolleginnen und Freundinnen, Monika, Bettina und Claudia für die vielen schönen gemeinsam verbrachten Stunden und so manch wertvolle Tipps und Ratschläge bedanken. Darüber hinaus möchte ich mich bei meinem Freund Harald für die Unterstützung und Motivation während der Abfassung dieser Arbeit bedanken.

Weiterer Dank gebührt natürlich Herrn Prof. Dr. Mathias Schardt für die Ermöglichung und Betreuung dieser Masterarbeit sowie auch Dr. Manuela Hirschmugl, die mich in vielen Fragen der Masterarbeit betreut und unterstützt hat.

Inhaltsverzeichnis

1.	Einleitung.....	1
1.1.	REDD als Hintergrund der Arbeit	1
1.2.	Definition und Charakteristika von Degradation	2
1.3.	Ziele dieser Arbeit	5
2.	Methoden zur Degradationskartierung - State of the Art	6
2.1.	Überblick über verwendete Daten und Methoden	6
2.2.	Felderhebung	12
2.3.	Verwendung optischer Fernerkundungsdaten	13
2.3.1.	Visuelle Interpretation	14
2.3.2.	Automatische Verfahren.....	16
2.3.2.1.	Reflexion	16
2.3.2.2.	Indizes	17
2.3.2.3.	Tasseled Cap.....	20
2.3.2.4.	Spectral Mixture Analysis.....	21
2.3.2.5.	Klassifikationsmethoden.....	26
2.3.2.6.	Kontextanalyse.....	29
2.3.2.7.	Carnegie Landsat Analysis System (CLAS)	30
2.3.3.	Hot-Spot Mapping.....	32
2.4.	Verwendung von SAR-Daten.....	32
2.5.	Alternative Fernerkundungsdaten - LiDAR	34
3.	Testgebiet und verwendete Satellitenbilddaten.....	36
3.1.	Testgebiet	36
3.2.	Verwendete Satellitenbilddaten	39
4.	Methoden und Arbeitsschritte.....	42
4.1.	Generierung von Referenzdaten.....	42
4.1.1.	Datenvorverarbeitung.....	43
4.1.2.	Digitalisierung	43
4.1.3.	Festlegung der Analyseeinheit.....	46
4.1.4.	Erweiterung der Referenz um intakte Waldbereiche	46
4.1.5.	Visuelle Interpretation weiterer Parameter mittels Beispielschlüssel	47
4.2.	Generierung von Features	51
4.2.1.	Reflexion	51
4.2.2.	Indizes	52
4.2.3.	SMA Features	53
4.2.3.1.	<i>Spectral Unmixing</i> mit manueller <i>Endmember</i> Selektion	53
4.2.3.2.	REDD <i>Spectral Mixture Analysis Workflow</i> mit automatischer <i>Endmember</i> Selektion	55
4.2.3.3.	mNDFI (modified Normalized Difference Fraction Index)	56

4.3.	Korrelation von Referenzdaten und Features.....	56
4.4.	Klassifikation zur monotemporalen Degradationskartierung.....	57
4.5.	Übertragung von <i>Endmember</i>	59
4.6.	Multitemporale Betrachtung der Degradationsgebiete	60
5.	Ergebnisse	64
5.1.	Visuelle Betrachtung der spektralen Bänder	64
5.2.	Ergebnisse aus der Korrelation von Referenzdaten und Features	66
5.2.1.	Reflexion	68
5.2.2.	Indizes	70
5.2.3.	SMA Features	75
5.2.4.	Fazit	81
5.3.	Ergebnisse der monotemporalen Degradationskartierung	81
5.3.1.	Signaturanalyse	82
5.3.2.	Klassifikationsergebnisse	84
5.4.	Ergebnisse aus der Übertragung von <i>Endmember</i>	87
5.4.1.	Räumliche Übertragung	87
5.4.2.	Zeitliche Übertragung	90
5.5.	Ergebnisse der multitemporalen Betrachtung der Degradationsgebiete	92
5.5.1.	Multitemporale Entwicklung von vegetationslosen Lücken	92
5.5.2.	Multitemporale Entwicklung von Wiederbewuchs	100
6.	Zusammenfassung und Ausblick	103
	Quellenverzeichnis.....	106

Abbildungsverzeichnis

Abb. 1: Reflexionseigenschaften des roten und des nahen Infrarotkanales	18
Abb. 2: Schematische Repräsentation eines Mischungsmodells.....	22
Abb. 3: Lage des Testgebietes.....	38
Abb. 4: Ikonosszene, aufgenommen am 27.6.2002 (RGB 432)	43
Abb. 5: Charakteristische Zusammensetzung selektiver Abholzungsgebiete	44
Abb. 6: Beispiele aus der Digitalisierung der Ikonosszene zur Referenz und Validierung.....	45
Abb. 7: Beispiele für intakte Waldbereiche (90m Einheiten)	46
Abb. 8: Vorliegende Referenzzellen.....	47
Abb. 9: Beispielschlüssel zur Interpretation der Entwicklungsstufe von Degradation/Wiederbewuchs.....	48
Abb. 10: Beispielschlüssel zur Interpretation des häufigsten Kronendurchmessers.....	49
Abb. 11: Beispielschlüssel zur Interpretation des dominierenden Erscheinungsbildes der Bäume.....	50
Abb. 12: Spektraler Merkmalsraum von Band 3 und 4 der Landsatsszene vom 13.12.2002..	54
Abb. 13: Räumliche Verteilung der Verifizierungszellen	58
Abb. 14: Schematische Visualisierung des erwarteten spektralen Verhaltens von Boden und Wiederbewuchs über die Zeit	61
Abb. 15: Grauwertbilder der Landsatbänder für einen Ausschnitt mit selektiver Abholung	64
Abb. 16: Spektraler Merkmalsraum von Band 3 und 4.....	65
Abb. 17: Korrelationsergebnisse (Überblick)	66
Abb. 18: Korrelationen von Band 3 und Band 4	68
Abb. 19: Korrelationen von Band 5 und Band 7	69
Abb. 20: Korrelationen der Ratio-Indizes Band 4/Band 3, Band 5/Band 4 und Band 7/Band 4	71
Abb. 21: Korrelationen der Vegetationsindizes NDVI, SAVI und GEMI.....	72
Abb. 22: Korrelationen der Infrarotindizes.....	73
Abb. 23: Korrelationen der Tasseled Cap Bänder <i>greenness</i> und <i>wetness</i>	74
Abb. 24: Fraktionsbilder der SMA Band 3,4 mit manueller <i>Endmember</i> Selektion.....	75
Abb. 25: Korrelationen der SMA Fraktionsbilder aus Band 3 und 4	76
Abb. 26: Lage von Dunst und Wolken im spektralen Merkmalsraum von Band 3 und 4	76
Abb. 27: Korrelationen der SMA Fraktionsbilder aus Band 4 und 5	77
Abb. 28: Gegenüberstellung der Korrelationen der SMA Fraktionsbilder aus B234 und B3457	78
Abb. 29: Korrelationen des mNDFI aus Band 34 bzw. Band 234	80
Abb. 30: Verteilung von intaktem Wald, Wiederbewuchs und degradiertem Wald in den <i>Endmemberfraktionen</i> der SMA B34.....	83
Abb. 31: Klassifikationsergebnis (VHR Ausschnitt)	84

Abb. 32: Klassifikationsergebnis (Detailausschnitt)	85
Abb. 33: Spektraler Merkmalsraum Band 3 und 4 bzw. Band 4 und 5 der Landsatzenne vom 18.01.2011 in Kamerun	87
Abb. 34: SMA Ergebnisse mit räumlich übertragenen <i>Endmember</i>	89
Abb. 35: Spektraler Merkmalsraum Band 3 und 4 bzw. Band 4 und 5 der Landsatzenne vom 18.02.2010 im Testgebiet der Republik Kongo	90
Abb. 36: SMA Ergebnisse mit zeitlich übertragenen <i>Endmember</i>	91
Abb. 37: Entwicklung des spektralen Signals von Lücken in der Bodenfraktion	93
Abb. 38: Differenz von Lücken und intaktem Wald in der Bodenfraktion.....	94
Abb. 39: Entwicklung des spektralen Signals von Lücken in der Bodenfraktion unter Berücksichtigung der Phänologie	95
Abb. 40: Differenz von Lücken und intaktem Wald in der Bodenfraktion unter Berücksichtigung der Phänologie	96
Abb. 41: Entwicklung des spektralen Signals von Lücken in der GV-Fraktion	97
Abb. 42: Differenz von Lücken und intaktem Wald in der GV-Fraktion	98
Abb. 43: Entwicklung des spektralen Signals von Lücken in der GV-Fraktion unter Berücksichtigung der Phänologie	99
Abb. 44: Differenz von Lücken und intaktem Wald in der GV-Fraktion unter Berücksichtigung der Phänologie	99
Abb. 45: Entwicklung des spektralen Signals von Wiederbewuchs in der GV-Fraktion	100
Abb. 46: Differenz von Wiederbewuchs und intaktem Wald in der GV-Fraktion.....	101
Abb. 47: Entwicklung des spektralen Signals von Wiederbewuchs in der GV-Fraktion unter Berücksichtigung der Phänologie	102
Abb. 48: Differenz von Wiederbewuchs und intaktem Wald in der GV-Fraktion unter Berücksichtigung der Phänologie	102

Tabellenverzeichnis

Tab. 1: Verfügbare Sensoren für das Degradationsmonitoring	7
Tab. 2: Untersuchte Studien zur Degradationskartierung in tropischen Wäldern 1998-2003	9
Tab. 3: Untersuchte Studien zur Degradationskartierung in tropischen Wäldern 2004-2006	10
Tab. 4: Untersuchte Studien zur Degradationskartierung in tropischen Wäldern 2007-2011	11
Tab. 5: Ikonos Sensorcharakteristika	39
Tab. 6: Aufnahmezeitpunkte der Landsatdaten	40
Tab. 7: Landsat Sensorcharakteristika	41
Tab. 8: Bestimmtheitsmaß der Korrelationen von den Features mit den Referenzdaten	67
Tab. 9: Konfusionsmatrix der monotemporalen Degradationsklassifizierung	86

Abkürzungsverzeichnis

ALI	Earth Observing-1 Advanced Land Imager
ALOS	Advanced Land Observing Satellite
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer
AVHRR	Advanced Very High Resolution Radiometer
AVNIR	Advanced Visible and Near Infrared Radiometer
BHD	Brusthöhdurchmesser
CBERS	China-Brazil Earth Resources Satellite
CLAS	Carnegie Landsat Analysis System
COP	Conference of the Parties
DEM	Digital Elevation Model
DMC	Disaster Monitoring Constellation (Verbund von Erdbeobachtungssatelliten)
EM	Endmember
Envisat	Environmental Satellite
ERS	European Remote Sensing Satellite
ETM+	Enhanced Thematic Mapper Plus
FAO	Food and Agriculture Organization
FID	Feature Identifikation
GEMI	Global Environment Monitoring Index
GLAS	Geoscience Laser Altimeter System
GMES	Global Monitoring for Environment and Security
GOFC-GOLD	Global Observation of Forest and Land Cover Dynamics
GSE	GMES Service Element
GV	grüne Vegetation
HH	horizontal-horizontal Polarisation
HV	horizontal-vertikal Polarisation
ICESat	Ice, Cloud and land Elevation Satellite
IMPACT	Image Processing and Classification Toolkit, Softwarebibliothek von Joanneum Research
IPCC	Intergovernmental Panel on Climate Change
IRS	Indian Remote Sensing Satellite
JERS	Japanese Earth Resources Satellite
JR	Joanneum Research
LiDAR	Light Detection and Ranging
MERIS	Medium Resolution Imaging Spectrometer
mGEMI	Modified Global Environment Monitoring Index
MIR	mittleres Infrarot
mNDFI	Modified Normalized Difference Fraction Index
MNF	Minimum Noise Fraction

MODIS	Moderate Resolution Imaging Spectroradiometer
MOI	Material of Interest
mSAVI	Modified Soil-Adjusted Vegetation Index
NASA	National Aeronautics and Space Administration (USA)
NDFI	Normalized Difference Fraction Index
NDII	Normalized Difference Infrared Index
NDVI	Normalized Difference Vegetation Index
NIR	Nahes Infrarot
NPV	nicht photosynthetische Vegetation
PALSAR	Phased Array L-band Synthetic Aperture Radar
PCA	Principal Component Analysis
PIF	pseudo-invariantes Feature
Pol-InSAR	Polarimetric SAR Interferometry
PPI	Pixel Purity Index
PV	photosynthetische Vegetation
REDD	Reducing Emissions from Deforestation and Degradation
REDDAF	Reducing Emissions from Deforestation and Degradation in Africa
RGB	Rot Grün Blau (Farbgebung)
RSG	Remote Sensing Software Graz, Software von Joanneum Research
RVI	Ratio-Vegetationsindex
SAR	Synthetic Aperture Radar
SAVI	Soil-Adjusted Vegetation Index
SLC	Scan Line Corrector
SMA	Spectral Mixture Analysis
SPOT	Satellite pour l'Observation de la Terre
SPOT HRV	Satellite pour l'Observation de la Terre High Resolution Visible
TM	Thematic Mapper
UNFCCC	United Nations Framework Convention on Climate Change
UN-REDD	United Nations Collaborative Programme on Reducing Emissions from Deforestation and Forest Degradation in Developing Countries
VHR	Very High Resolution
VV	vertikal-vertikal Polarisation

1. Einleitung

1.1. REDD als Hintergrund der Arbeit

Reducing Emissions from Deforestation and forest Degradation (REDD) ist eine Initiative der *United Nations Framework Convention on Climate Change* (UNFCCC) mit dem Ziel Emissionen aus der Abholzung und Zerstörung von Wäldern, vor allem tropischer Wälder, zu reduzieren und somit einen wertvollen Beitrag zum Klimaschutz zu leisten (UN-REDD 2011). Nach Parker et al. (2009) speichern tropische Wälder rund ein Viertel des Kohlenstoffes der terrestrischen Biosphäre. Durch die Zerstörung dieser Wälder werden große Mengen an Kohlenstoffdioxid in die Atmosphäre freigesetzt, wodurch der Klimawandel weiter begünstigt wird. In vielen tropischen Ländern verursachen Abholzung, Waldbrände sowie Brandrodung einen Großteil der Kohlenstoffdioxidemissionen. Laut UN-REDD (2008) wurden zwischen 1990 und 2005 jährlich rund 13 Millionen Hektar Wald, größtenteils in den Tropen, abgeholzt und in andere Landnutzungen, meist Landwirtschaft, umgewandelt. Durch die Entwaldung wird etwa ein Fünftel der weltweiten Kohlenstoffemissionen freigesetzt, womit diese als zweitgrößter Verursacher für die globale Erwärmung anzusehen ist (Parker et al. 2009).

Aus diesem Grund wurde 2005 im Rahmen der *Conference of the Parties* (COP) 11 in Montreal die REDD Initiative gegründet. Bei diesem Gipfel sprachen sich Papua Neuguinea und Costa Rica, unterstützt von anderen lateinamerikanischen und afrikanischen Ländern, für ein Instrument zur Reduzierung von Treibhausgasen aus der Abholzung von Wäldern in Entwicklungsländern aus. Nach einem zweijährigen Prozess wurden im Zuge der Klimakonferenz in Bali 2007 (COP 13) die Rahmenbedingungen von REDD im Bali-Aktionsplan verankert. Das Grundprinzip ist ein finanzieller Ausgleich für jene Länder, welche bereit sind, die Emissionen aus der Zerstörung ihrer Wälder zu reduzieren und die nachhaltige Nutzung ihrer Waldressourcen forcieren (Parker et al. 2009, UNFCCC 2011, UN-REDD 2008). Für die Einhaltung der Vereinbarungen unter REDD ist ein dementsprechendes Monitoring notwendig, für welches die Fernerkundung einen sehr wichtigen Beitrag leistet. Für ein Waldmonitoring auf nationaler Ebene stellen nach De Fries et al. (2006) die Interpretation von Fernerkundungsdaten in Verbindung mit Erhebungen vor Ort den einzigen praktikablen Zugang dar.

Joanneum Research führte im Rahmen der europäischen Initiative *Global Monitoring for Environment and Security* (GMES) bereits REDD Pilotprojekte in Bolivien und Kamerun durch. In weiterer Folge wurde das *GSE REDD Extension* Projekt initiiert, welches operationelle Waldanwendungen für die Nutzergemeinschaft in der Republik Kongo und in der Republik Gabun bereitstellt. Die diesbezüglichen Services inkludieren die Kartierung von flächenhaften Abholzungen und Degradationserscheinungen sowie den

Aufbau und die Stärkung von Kapazitäten in den Partnerländern. Um in Zusammenhang mit diesem Projekt eine optimale Kartierung von Degradation zu erreichen, werden im Zuge dieser Masterarbeit verschiedenste Features zur (halb-) automatischen Erkennung von Degradation anhand von Landsatdaten in einem Testgebiet im Norden der Republik Kongo untersucht. Als Features sind in diesem Zusammenhang aus den Spektralbändern abgeleitete künstliche Kanäle von mittel auflösenden Landsatdaten zu verstehen, anhand deren Degradationserscheinungen als auch die Regeneration der Vegetation leichter detektiert werden können. Darüber hinaus wird versucht, mittels Zeitreihenanalyse eine temporale Spektralkurve über das spektrale Verhalten von Degradations- und Wiederbewuchsflächen abzuleiten.

1.2. Definition und Charakteristika von Degradation

Für den Begriff Degradation gibt es zahlreiche, zum Teil unterschiedliche Definitionen. Generell wird Degradation als eine negative Veränderung des Waldes im Sinne einer geringeren Produktivität, einer Veränderung der Artenzusammensetzung oder der Artenvielfalt verstanden. In Bezug auf den Klimawandel und somit auch in Bezug auf die REDD Initiative bezeichnet diese Veränderung den Verlust des Kohlenstoffspeichers der Wälder (Penman et al. [Hrsg.] 2003, Skutsch und Trines 2008). Nach einer Empfehlung des zwischenstaatlichen Gremiums für Klimaveränderung (IPCC) definiert sich Degradation als *ein direkter vom Menschen verursachter langfristiger Verlust (andauernd für X Jahre oder mehr) von mindestens Y% des Kohlenstoffspeichers der Wälder seit Zeitpunkt T, wobei dieser Verlust nicht als Entwaldung oder als ausgewählte Aktivität unter Artikel 3.4 des Kyoto-Protokolls deklariert ist.* Um die Definition zu operationalisieren, müssen noch die Werte für die Variablen X, Y und T spezifiziert werden (Penman et al [Hrsg.] 2003). Durch die natürliche Regeneration des Waldes kann der Verlust des Kohlenstoffspeichers von temporärer Dauer sein. Wird weiterhin Druck auf den Wald ausgeübt, kann das Ökosystem dermaßen degradiert werden, dass eine Regeneration nicht mehr möglich ist bzw. der Wald durch weitere Abholzung komplett verschwindet, wodurch der gesamte lebende Kohlenstoffspeicher verloren geht (Skutsch und Trines 2008).

Die Degradation von Wäldern zählt weltweit zu den größten Verursachern von Treibhausgasen. So entfallen etwa ein Viertel der Emissionen aus der Landnutzung in Brasilien auf die Degradation im Amazonasgebiet. In Zentralafrika ist Degradation zur Hälfte für die Entwaldung verantwortlich, industrielle Abholzung gilt in diesem Gebiet als intensivste Form der Landnutzung. Für 30 Prozent der Waldfläche (600.000 km²) wurden Konzessionen für die Abholzung vergeben, lediglich 12 Prozent des Waldes stehen unter Schutz (Laporte et al. 2007). Ohne eine Einbeziehung von Degradation in die REDD Initiative würde nicht nur deren Anteil der Emissionen aus der Zerstörung der Wälder unberücksichtigt bleiben, sondern auch eine Verschiebung der Emissionsbilanz ermöglicht werden. Die Länder könnten anstelle von großflächigen Rodungen zur Degradation ihrer Wälder übergehen, um somit keinen Verlust an Waldflächen

aufzuweisen und dadurch ihre Emissionen zu verschieben anstatt sie zu reduzieren (Skutsch und Trines 2008). Nach einer Definition der FAO muss Wald einen Beschirmungsgrad von mindestens 10 Prozent, eine Höhe von 5 Metern und eine Fläche von mindestens 0,5 Hektar aufweisen sowie vorrangig als Wald genutzt werden, um als solcher ausgewiesen zu werden. Im Hinblick auf das Kyoto Protokoll werden im Übereinkommen von Marrakesch folgende Mindestanforderungen für Wälder vorgegeben:

- minimale Waldfläche 0,05 bis 1 Hektar
- Potential einer Minimalhöhe im Reifealter in situ von 2 bis 5 Meter
- Überschirmungsgrad (oder gleichwertiger Bestockungsgrad) von 10-30 Prozent

Unter Berücksichtigung des vorgegebenen Rahmenbereiches kann jedes Land Wald innerhalb seiner nationalen Grenzen selbst definieren. Dies ermöglicht es Ländern Wälder mit dichtem Beschirmungsgrad bis zum Erreichen des minimalen Beschirmungsgrades zu degradieren, ohne dabei einen Verlust an Waldfläche aufzuweisen. Erst wenn eine Änderung der Nutzung und somit keine Chance auf Regeneration besteht, wird das Gebiet als Nicht-Wald klassifiziert (GOFC-Gold 2011).

Degradation in tropischen Wäldern kann aus verschiedenen Aktivitäten, nämlich aus selektiver Abholzung, Waldbränden sowie durch Aktivitäten der lokalen Bevölkerung, hervorgehen. Die Auswirkungen der unterschiedlichen Arten von Degradation auf das Ökosystem Wald sind dabei unterschiedlich. Für ein Monitoring von Degradation ist daher das Wissen über die verschiedenen Degradationspraktiken, deren Gründe und Einflüsse auf den Kohlenstoffbestandteil unabdingbar. Nicht alle Aktivitäten können bzw. müssen mit Methoden der Fernerkundung überwacht werden (GOFC-Gold 2011).

- **Selektive Abholzung (legal oder illegal):**

Bei der selektiven Abholzung werden einige Bäume pro Hektar aus dem Wald heraus gefällt, während der restliche Bestand bestehen bleibt. Durch diese Art der Abholzung entstehen jedoch große Schäden an verbleibenden Bäumen, in der Unterholzvegetation sowie an den Böden. Diese wirken sich negativ auf den Kohlenstoffspeicher des Waldes, hydrologische Prozesse, Erosionen sowie auf die Tier- und Pflanzenwelt aus (Asner et al. 2005a). Selektive Abholzung wird vor allem in tropischen Ländern praktiziert, um so wertvolle Bäume für den Export zu gewinnen. Dies erfordert eine gewisse Organisation sowie eine dementsprechende Infrastruktur an Straßen und Holzlagerplätzen. Wälder, in denen selektive Abholzung betrieben wird, bilden ein Mosaik bestehend aus:

- Bereichen mit intaktem Wald, welche nicht von Abholzungsaktivitäten betroffen sind. Diese sind meist aufgrund von Sumpfgebieten, Flüssen oder aufgrund der Topographie schwer zugänglich oder haben nur einen geringen Bestand an kommerziell nutzbaren Hölzern.
- Gerodeten Flächen für Holzlagerplätze und Straßen für den Holztransport.
- Wälder mit zerstörten Baumkronen durch das Fällen von Bäumen und deren Entnahme (Matricardi et al. 2001, Souza et al.2005a).

Durch den raschen Wiederbewuchs von Vegetation sind die Erscheinungen von selektiver Abholzung in Satellitenbildern nur innerhalb eines begrenzten Zeitraumes erkennbar. Doch auch wenn die Lücken in der Beschirmung nach einigen Jahren geschlossen sind, dauert es Jahrzehnte und länger, bis der ursprüngliche Zustand des Waldes und dessen Biomassevolumen wiederhergestellt ist (Souza et al. 2009).

- **Degradation durch großflächige Waldbrände**

Durch Waldbrände wird nicht nur der Kohlenstoffspeicher der Wälder dezimiert, sondern zusätzlich Kohlenstoffdioxid sowie weitere Treibhausgase durch die brennende Biomasse freigesetzt (Haas 2009, S. 7). Die Intensität der Degradation durch Waldbrände ist von der Schwere und dem Ausmaß des Feuers abhängig. Waldbrände werden in tropischen Regenwäldern nahezu ausschließlich von den Menschen verursacht, da Blitzeinschläge gewöhnlich mit heftigen Regenfällen verbunden sind (GOFC-Gold 2011). Ein intakter tropischer Regenwald ist nahezu feuerresistent, da das dichte Kronendach den Boden vor dem Austrocknen schützt und dieser dadurch seinen hohen Feuchtigkeitsgehalt beibehalten kann. Durch die Zerstörung des Waldes, vor allem durch selektive Abholzung und die dadurch entstehenden Lücken im Kronendach, trocknet die am Boden liegende Biomasse aus und die Anfälligkeit des Waldes für Brände wird erhöht (Stone und Lefebvre 1998). So stellten Stone und Lefebvre (1998) fest, dass die meisten Waldbrände in tropischen Wäldern in Gebieten mit vorangegangener selektiver Abholzung stattfanden. Vom Feuer verschonte Flächen wiesen keine Zeichen von Abholzungsaktivitäten auf. Das Feuer brannte entlang den Grenzen zu intaktem Wald, infiltrierte an den Rändern, konnte jedoch nicht übergreifen. Während die degradierten Flächen verbrannten, wurden die intakten Waldflächen nur leicht beschädigt.

- **Aktivitäten der lokalen Bevölkerung**

Die Aktivitäten der lokalen Bevölkerung beziehen sich meist auf das Sammeln von Brennholz und anderen Waldprodukten, der Produktion von Holzkohle, der Beweidung und dem Wanderfeldbau. Die dadurch entstehende Degradation ist meist kleinräumig und hängt mit dem Bevölkerungsdruck zusammen, welcher eine Übernutzung der Wälder in siedlungsnahen Bereichen zur Folge hat. Trotz der kleinräumigen Nutzung geht der Regenerationsprozess sehr langsam vonstatten und wird durch Beweidung zum Teil gänzlich verhindert. Solange diese Art von Degradation keine größere Veränderung in den Kronen hervorruft, ist diese in Satellitenbildern nicht erkennbar (GOFC-Gold 2011).

1.3. Ziele dieser Arbeit

Das Ziel dieser Arbeit ist es, im Rahmen des REDD Extension Projektes verschiedene *Features* zur Degradationskartierung in einem Testgebiet im Norden der Republik Kongo zu untersuchen. Als *Features* sind in diesem Zusammenhang, wie bereits erwähnt, aus den Spektralbändern abgeleitete künstliche Kanäle von Landsatdaten zu verstehen, welche die Kartierung von Degradation als auch der Regeneration der Vegetation erleichtern sollen. Obwohl es schon zahlreiche Studien zur Degradationskartierung in tropischen Wäldern gibt, so wurden diese nahezu ausschließlich im Amazonasgebiet durchgeführt. Eine erfolgreiche Übertragung der Methoden auf das Kongobecken ist fraglich, da im Amazonasgebiet andere Abholzungspraktiken als im Kongobecken angewandt werden. Daher ist es notwendig, die verschiedenen *Features* zur Degradationskartierung in der Republik Kongo erneut zu testen.

In einem ersten Schritt wird eine Literaturrecherche hinsichtlich der verschiedensten Methoden zur Degradationskartierung und den Erkenntnissen aus den Studien durchgeführt. Im praktischen Teil der Arbeit werden die aus der Literatur sowie aus der Untersuchung der zur Verfügung stehenden Daten hervorgehenden Erfolg versprechenden *Features* aus den Landsatdaten extrahiert. Das Testgebiet, für welches die *Features* berechnet werden, befindet sich im Norden der Republik Kongo. Diese *Features* werden anschließend mit Referenzdaten, resultierend aus einer visuellen Interpretation von Ikonosdaten, korreliert. Dabei soll herausgefunden werden, welche *Features* am besten für die Detektion von „frischer“ Degradation in Form von vegetationslosem Boden geeignet sind und welche *Features* die Regeneration von Vegetation am besten beschreiben. Anhand des geeignetsten *Features* wird eine Klassifizierung des Untersuchungsgebietes im Sinne einer Degradationskartierung durchgeführt. In einem weiteren Schritt werden die Degradations- und Wiederbewuchsflächen in multitemporaler Hinsicht betrachtet. Dabei soll geklärt werden, wie lange eine Störung mittels der zur Verfügung stehenden Landsatdaten erkennbar ist und wie sich das Signal über die Zeit verhält.

2. Methoden zur Degradationskartierung - State of the Art

In den vergangenen Jahrzehnten ist dem Verstehen und der Überwachung von Degradationsprozessen in tropischen Wäldern eine immer größere Bedeutung zugekommen. Die räumliche Ausdehnung von selektiver Abholzung und Waldbränden wurde bis in die 1990er Jahre nicht in Studien zur Abholzung der tropischen Wälder miteinbezogen, wodurch das gesamte Ausmaß der anthropogenen Einflüsse auf diese Wälder nicht bekannt war (Nepstad et al. 1999). Aus diesem Grund wurden in der Fernerkundung verschiedenste Methoden zur Degradationskartierung, von der visuellen Interpretation bis hin zu automatischen Bildverarbeitungsalgorithmen, entwickelt. Die folgenden Kapitel geben einen Überblick über die verwendeten Daten und Methoden zur Degradationskartierung und zeigen den derzeitigen Stand der Technik in diesem Bereich auf.

2.1. Überblick über verwendete Daten und Methoden

Seit den 1990er Jahren wurden verschiedenste Studien zur Detektion von Degradation, vorwiegend im Amazonasgebiet, durchgeführt. Kartiert wurden die Degradationserscheinungen von selektiver Abholzung und von Waldbränden, welche die dominantesten Formen von Degradation darstellen (GOF-C-Gold 2011). Neben der Felderhebung (Gerwing 2002) werden hierbei vor allem Methoden der Fernerkundung eingesetzt. Diese reichen von der visuellen Interpretation (Stone und Lefebvre 1998, Nepstad et al. 1999) über die Analyse der Reflexionswerte einzelner Bildkanäle (Asner et al. 2002), Indizes (Asner et al. 2003, Souza et al. 2005b) bis hin zu hoch entwickelten Bildverarbeitungsalgorithmen auf Basis der spektralen Entmischungsanalyse (Asner et al. 2005a). Für ein Monitoring in Bezug auf REDD sind die verwendeten Methoden und Daten stark voneinander abhängig. So wird die Verwendbarkeit der einzelnen Methoden von der räumlichen und zeitlichen Abdeckung der Daten als auch von deren Kosten begrenzt. Dies wird anhand folgender Tabelle verdeutlicht, welche einen Überblick über die unterschiedlichen Fernerkundungsdatenoptionen, deren Vorteile, Einschränkungen und Kosten gibt.

Tab. 1: Verfügbare Sensoren für das Degradationsmonitoring

Sensor	Auflösung	Beispiele für Sensoren	Kosten	Verwendbarkeit und Vorteile	Einschränkungen
Optische Sensoren	grob (250-1000m)	SPOT-Vegetation Terra-MODIS Envisat-MERIS	Gering oder kostenlos	<ul style="list-style-type: none"> Monitoring von größeren Entwaldungsflächen Lokalisierung von „Hotspots“ zur weiteren Analyse mit Daten mittlerer Auflösung, schnelle Bewertung und tägliche Abdeckung vermindert Probleme in Bezug auf die Wolkenbedeckung und jahreszeitliche Veränderungen der Wälder 	<ul style="list-style-type: none"> Ungeeignet zur Erkennung von Degradation und kleinräumigen Rodungen
	mittel (10-60m)	Landsat TM/ ETM+, ASTER, IRS AWiFs/ LISS III CBERS HRCCD DMC SPOT HRV	Landsat & CBERS kostenlos, andere: <\$0,001/km ² für historische Daten, \$0,02/km ² - \$0.5/km ² für aktuelle Daten	<ul style="list-style-type: none"> Primäre Sensoren zur Kartierung von Entwaldung Berechnung von Flächenänderungen 	<ul style="list-style-type: none"> Nur bedingt geeignet für wolkenreiche Regionen
	fein (<5 m)	IKONOS QuickBird Luftbilder	Hoch bis sehr hoch \$2 -30 /km ²	<ul style="list-style-type: none"> Validierung von Ergebnissen aus niedrigeren Auflösungen Training von Algorithmen 	<ul style="list-style-type: none"> Nationale Abdeckung nicht verfügbar aufwendig zu verarbeiten
SAR	hoch (~30m)	ERS, JERS Radarsat, ALOS PALSAR	Hoch bis kostenlos	<ul style="list-style-type: none"> Durchdringung von Wolken Ergänzung anderer Daten Volle Abdeckung verfügbar 	<ul style="list-style-type: none"> Verwendung benötigt Fachwissen Informationstiefe Beschränkte Anwendbarkeit in Gebieten mit größeren Reliefunterschieden
LiDAR	3D	GLAS LiDAR, Flugzeuggetragene Sensoren	Hoch	<ul style="list-style-type: none"> großes Potential für Biomassebewertung und Detektion von Veränderungen 	<ul style="list-style-type: none"> flugzeuggetragene Systeme zu kostenintensiv für ein operationelles Monitoring

Quelle: GOFC-Gold 2011, Wertz-Kanounnikoff 2008

Für das Monitoring von Degradation werden meist optische Fernerkundungsdaten mittlerer Auflösung verwendet. Aus diesem Grund wurden auch verschiedene Methoden zur Degradationskartierung in Bezug auf mittel auflösende Daten entwickelt und optimiert (GOFC-Gold 2011). Die bevorzugte Verwendung von optischen Fernerkundungsdaten mittlerer Auflösung, allen voran Landsatdaten, zeigt sich auch in der Zusammenfassung der untersuchten Studien (siehe Tab. 2, Tab. 3 und Tab. 4). Der räumliche Schwerpunkt dieser Studien liegt dabei im Amazonasgebiet Brasiliens (20 von 25 Studien), die Tropenwaldgebiete Afrikas oder Südostasiens werden kaum behandelt. Des Weiteren beziehen sich die Studien zumeist auf lokale Testgebiete, wodurch sich die Frage nach der Übertragbarkeit der verwendeten Methoden auf andere Ökosysteme stellt. Eine Ausnahme stellt das Carnegie Landsat Analysis System dar, auf Basis dessen Kartierungen für weitläufige Gebiete im Amazonasgebiet Brasiliens und Perus durchgeführt wurden. Die vereinfachte Version CLASlite wurde auch außerhalb des südamerikanischen Raumes erfolgreich angewandt (Asner et al. 2009). Untersucht werden vor allem die Degradationserscheinungen von selektiver Abholzung, einige wenige Studien beziehen sich auf Waldbrände, während Methoden zur Erkennung von Degradation aus Aktivitäten der lokalen Bevölkerungen in der Literatur nicht gefunden wurden. Die bevorzugte Methode zur Detektion von Degradation ist die *Spectral Mixture Analysis (SMA)* basierend auf Landsatdaten. Darauf aufbauend verbessern Kontextanalysen die Unterscheidung von natürlichen und anthropogenen Waldschäden. Eingeschränkt wird die Kartierung von Degradation durch die rasche Veränderung der Degradationssignaturen innerhalb von 2 Jahren, bedingt durch die Regeneration der Vegetation. Um eine Fehlklassifizierung von älteren degradierten Waldgebieten zu intaktem Wald zu vermeiden, ist daher ein jährliches Monitoring notwendig (GOFC-Gold 2011).

Im Rahmen dieser Masterarbeit werden Landsatdaten, welche über eine mittlere Auflösung von 30m verfügen, herangezogen, um anhand dieser Daten verschiedenste Features zur Degradationskartierung in Kongo zu testen. Daher werden im *State of the Art* Kapitel tabellarisch Methoden auf Basis von mittel auflösenden Daten stärker behandelt als alternative Datenoptionen wie Synthetic Aperture Radar (SAR) oder Light Detection and Ranging (LiDAR) Daten.

Tab. 2: Untersuchte Studien zur Degradationskartierung in tropischen Wäldern 1998-2003

Jahr	Autoren	Räumliche Ausdehnung	Methoden	kartierte Degradationsart	Sensor	Erkenntnisse
1998	Cochrane und Souza	lokal Pará, Brasilien	SMA (EM Boden, NPV, GV, Schatten) zur Unterscheidung von nicht-verbranntem, kürzlich verbranntem und seit längerer Zeit verbranntem Wald	Waldbrände	Landsat TM	Beste Trennbarkeit von nicht-verbranntem, kürzlich verbranntem und seit längerer Zeit verbranntem Wald in der NPV Fraktion, 2 Jahresintervall ist ausreichend für eine Detektion von verbrannten Waldflächen
1998	Stone und Lefebvre	lokal, Paragominas, Pará, Brasilien	Visuelle Interpretation von Zeitreihen, unüberwachte und überwachte Klassifizierung, Texturanalyse B4, NDVI	Selective Abholzung	Landsat TM	Selective Abholzung binnen 3 Jahren nach dem Abholzungseignis nicht mehr erkennbar, unüberwachte und überwachte Klassifikation, Texturanalyse von Band 4 und NDVI nicht zur Unterscheidung von degradiertem zu intaktem Wald geeignet
1999	Nepstad et al.	ausgewählte Regionen im brasilianischen Amazonasgebiet	Visuelle Interpretation, Interviews mit Landbesitzern	Selective Abholzung, Waldbrände	Landsat TM	Landbesitzer unterschätzen die Fläche der Zerstörung, nur 10% der verbliebenen Waldfläche ist intakt
2000	Souza und Barreto	lokal, Paragominas, Pará, Brasilien	Feldarbeit, SMA (PPI, EM Boden, Schatten, GV), Boden-Fraktion zur Detektion von Holzlagerplätzen, Kontextanalyse (Puffer um Holzlagerplätze)	Selective Abholzung	Landsat TM	Holzentnahme in einem Radius von 162m von den Holzplätzen (bezogen auf Landsat 180m), zeitlicher Abstand für multitemporale Analysen maximal 2 Jahre
2001	Matricardi et al.	brasilianisches Amazonasgebiet	Visuelle Interpretation, Texturanalyse, 180m Holzentnahme-Radius um Holzlagerplätze	Selective Abholzung	Landsat TM	Visuelle Interpretation erfolgreicher als automatische Detektion mittels Texturalgorithmen
2002	Asner et al.	lokal Pará, Brasilien	Feldarbeit, Reflexion einzelner Bänder, Texturanalyse	Selective Abholzung	Landsat ETM+	Lücken durch gefällte Bäume, Rückgassen und Straßen sind bis zu 0,5 Jahre nach dem Abholzungseignis erkennbar, Holzplätze bis zu 1,5 Jahre danach. Degradation ab einem Kronenschluss >50% nicht mehr erkennbar.
2002	Pierce et al.	Mato Grosso, Brasilien	CBERS Band 3 zur Detektion von bloßem Boden	Selective Abholzung	CBERS 1	Texturanalyse ungeeignet zur Degradationskartierung Detektion von selektiver Abholzung anhand von CBERS Daten möglich
2002	Qi et al.	lokal, Mato Grosso, Brasilien	SMA (EM Boden, GV), MSAVI zur Berechnung der anteilmäßigen Überschirmung	Selective Abholzung	Landsat ETM+	GV Bedeckungsanteil eignet sich gut für die Abschätzung von Degradation und Regeneration
2003	Monteiro et al.	lokal, Mato Grosso, Brasilien	SMA (nach Souza und Barreto 2000), Kontextanalyse (Holzentnahmepuffer um Holzplätze)	Selective Abholzung	Landsat TM, ETM+	Bodenanteilsbilder sind geeignet um Abholzung in Übergangswäldern zu detektieren, Holzentnahmeradius ist in Übergangswäldern größer (350m) als in Terra Firme Wäldern (180m)
2003	Souza et al.	lokal, Paragominas, Pará, Brasilien	SMA (PPI, EM Boden, NPV, GV, Schatten), Decision Tree Classifier, Waldklassen: intakt, abgeholzt, degradiert, regenerierend	Selective Abholzung, Waldbrände	SPOT4	NPV Endmember am bedeutendsten, Degradation anhand des Bodenanteils 2 Jahre erkennbar, in NPV Anteil teilweise länger

Tab. 3: Untersuchte Studien zur Degradationskartierung in tropischen Wäldern 2004-2006

Jahr	Autoren	Räumliche Ausdehnung	Methoden	kartierte Degradationsart	Sensor	Erkenntnisse
2004	Asner et al.	lokal, Paragominas Pará, Brasilien	Felderhebung, SMA (Monte Carlo Unmixing, EM Boden, NPV, GV)	Selektive Abholzung	Landsat ETM+	SMA detektiert selektive Abholzung bis zu 3,5 Jahre nach dem Einschlag, etwa 50% der Kronenöffnung schließt sich innerhalb eines Jahres
2004	De Wasseige und Defourny	lokal, Zentral-afrikanische Republik	Visuelle Interpretation, Umrechnung der Daten auf 120m Auflösung	Selektive Abholzung	SPOT XS, Landsat TM	5 Jahre nach dem Abholzungsereignis sind noch mehr als 50% der Holzwege sichtbar, bei einer Auflösung von 120m sind es nur mehr 34 %
2004	Hussin und Atmopawiro	lokal, East Kalimantan, Indonesien	Felderhebung von gefällten Einzelbäumen, Maximum Likelihood Klassifikation, IMAGINE Subpixel-Klassifikator	Selektive Abholzung	Landsat ETM+	Subpixel-Klassifikator liefert bessere Ergebnisse als die Maximum-Likelihood Klassifikation
2005	Asner et al.	brasilianisches Amazonasgebiet	Carnegie Landsat Analysis System (CLAS) basierend auf SMA (Monte Carlo Unmixing, EM PV, NPV, Boden) und Mustererkennungsalgorithmen	Selektive Abholzung	Landsat ETM+	Schnelle, automatische Methode, liefert präzise und genaue Ergebnisse, Anwendung auf große Gebiete möglich (getestet für das gesamte brasilianische Amazonasgebiet)
2005	Matricardi et al.	lokal, Sinop, Mato Grosso, Brasilien	Felderhebung, visuelle Interpretation für ground-truth, Texturanalyse Landsatbänder 3,4,5, Holzentnahmepuffer um Holzlagerplätze	Selektive Abholzung	Landsat TM, ETM+, Ikonos	Texturanalyse von B5 liefert gute Ergebnisse zur Erkennung von Holzlagerplätzen, Holzentnahme in einem Radius von 180m um Holzlagerplätze, Erkennbarkeit von Holzlagerplätzen in Ikonos Daten 1-2 Jahre
2005a	Souza et al.	lokal, Sinop, Mato Grosso, Brasilien	SMA (PPI, EM Boden, NPV, GV, Schatten), NDFI, Contextual Classification Algorithm (CCA), Klassen: intakter Wald, nicht-mechanisierte Abholzung, gemanagte Abholzung, konventionelle Abholzung, abgeholzt und verbrannt	Selektive Abholzung, Waldbrände	Landsat TM, ETM+	Boden-, NPV- und GV- Anteile empfindlich für Walddegradation, NDFI ermöglicht bessere Detektion von Schäden in der Überschrumpfung als die individuellen Fraktionen, CCA funktioniert lokal, nicht für gesamtes Amazonasgebiet (Anpassung der Schwellwerte an die jeweiligen Ökosysteme notwendig)
2005b	Souza et al.	lokal, Sinop, Cláudia, Mato Grosso, Brasilien	Felderhebung, Reflexion, Indizes (NDVI, SAVI, NDI15, NDI17), SMA (PPI, EM Boden, NPV, GV, Schatten), Klassen: intakter Wald, nicht-mechanisierte Abholzung, gemanagte Abholzung, konventionelle Abholzung, abgeholzt und verbrannt	Selektive Abholzung, Waldbrände	Landsat TM, ETM+	Fraktionsbilder aus SMA sensibler für Veränderungen in Übergangswäldern als Indizes und Reflexionswerte, Veränderungen in GV-Fraktion nicht länger als 1 Jahr erkennbar, in NPV Fraktion bis zu 2 Jahre, 2-3 Jahre nach dem Abholzungsereignis ist ein signifikantes Regenerationsignal in den Reflexionswerten und den Fraktionsbildern zu beobachten.
2005	Souza und Roberts	lokal, Paragominas, Pará, Brasilien	Visuelle Interpretation von selektiven Abholzungserscheinungen	Selektive Abholzung, Waldbrände	Landsat TM, SPOT4, Ikonos	2 Jahre nach dem Einschlag keine klare Erkennung von Holzlagerplätzen, Waldbrände können anhand von Ikonoszenen bis zu 4 Jahre danach identifiziert werden
2006	Brandão und Souza	lokal, Pará, Brasilien	Visuelle Interpretation von offiziellen und inoffiziellen Straßen	Selektive Abholzung	Landsat TM, ETM+	Schutzgebiete verlangsamen den Straßenbau und somit die selektive Abholzung, halten ihn aber nicht auf

Tab. 4: Untersuchte Studien zur Degradationskartierung in tropischen Wäldern 2007-2011

Jahr	Autoren	Räumliche Ausdehnung	Methoden	kartierte Degradationsart	Sensor	Erkenntnisse
2007	Oliveira et al.	Peruanisches Amazonasgebiet	Optimierter CLAS Algorithmus	Selektive Abholzung	Landsat TM, ETM+	CLAS liefert auch im peruanischen Amazonasgebiet, das durch kleinräumigere Degradation gekennzeichnet ist, genaue und präzise Ergebnisse
2009	Asner et al.	Brasilianisches und peruanisches Amazonasgebiet	CLASlite (Monte Carlo Unmixing, EM PV, NPV, Boden, Mustererkennungsalgorithmen)	Selektive Abholzung, Waldbrände	Landsat ETM+	Rasche, vollautomatische Kartierung von Waldbedeckung, Degradation und Entwaldung für Nicht-Experten
2009	Haas	Kamerun	Felderhebung, Reflexion einzelner Bänder, Indizes (NDVI, SAVI, NDI15, NDI17), SMA, mNDFI	Selektive Abholzung	Landsat TM, ETM+, ASTER, AVNIR-2	mNDFI bestes Feature für Degradation unabhängig vom verwendeten Sensor, Regeneration wird am besten durch das NIR Band und GV Fraktion beschrieben, Regeneration zeigt eine höhere Trennbarkeit und zeitliche Persistenz im Vergleich zu Degradation, Holzplätze mit Bodenanteilsbild detektierbar
2009	Souza et al.	ausgewählte Regionen im brasilianischen Amazonasgebiet	Felderhebung, SMA (PPI, EM Boden, NPV, GV, Schatten), NDFI	Selektive Abholzung, Waldbrände	Landsat TM, ETM+, SPOT 4	NDFI sinkt mit der Degradationsintensität, negative lineare Beziehung zwischen NDFI und oberirdischer lebender Biomasse, d.h. höhere NDFI Werte für intakten Wald, und geringe für die meist degradierte Klasse, diese starke Beziehung verschwindet 1 Jahr nach dem Abholzungsereignis.
2010	Matricardi et al.	lokal, Sinop, Mato Grosso, Brasilien	Felderhebung, Vegetationsindizes, SMA (PPI, EM Boden, NPV, GV, Schatten)	Selektive Abholzung, Waldbrände	Landsat TM, ETM+	mSAVI liefert beste Ergebnisse bei schlechten atmosphärischen Bedingungen
2011	Negrón-Juarez et al.	lokal, Manaus, Amazonas, Brasilien	Felderhebung, Kartierung von Lücken durch gefällte Bäume mittels SMA (PPI, EM GV, NPV, Schatten)	Selektive Abholzung	Landsat TM	NPV-Anteilsbild zur Kartierung von Lücken aufgrund gefällter Bäume, mittels Landsatdaten sind Lücken in der Größenordnung von 100m ² detektierbar

2.2. Felderhebung

Felderhebungen stellen in der Fernerkundung oft eine Basis zur Gewinnung von Bodenverifikationsdaten, so genannten ground-truth Daten dar, um mit diesen Klassifikatoren besser trainieren zu können oder Ergebnisse zu verifizieren. Sie können jedoch auch als eigenständige Erhebung gesehen werden. In Zusammenhang mit diesem Kapitel wird die Felderhebung zur Gewinnung von Referenzdaten für satellitenbasierte Verfahren zur Degradationskartierung betrachtet. So führten beispielsweise Stone und Lefebvre (1998), Asner et al. (2002) sowie Souza et al. (2005b) Felderhebungen zur Verifikation ihrer Ergebnisse durch. Durch die enormen Kosten und den Zeitaufwand von Felderhebungen können diese nur begrenzt durchgeführt werden (Souza und Roberts, 2005).

Asner et al. (2002) kombinierten eine intensive Felderhebung mit einer Untersuchung der Eignung von Reflexion einzelner Landsat ETM+ Bänder (vgl. Kapitel 2.3.2.2.1) und Texturanalysen für die Erkennung von selektiver Abholzung in der Region Paragominas, im östlichen brasilianischen Amazonasgebiet. Die Feldstudie umfasste Messungen bezüglich des zerstörten Bodens und des Anteils an Lücken im Kronendach in einer Zeitreihe von 0,5 bis 3,5 Jahren nach dem Abholzungsereignis. Untersucht wurden zwei konventionell abgeholzte Gebiete mit hohen Kollateralschäden, zwei ressourcenschonend abgeholzte Gebiete mit geringen Kollateralschäden sowie ein intakter Waldblock ohne jeglichen Einfluss von selektiver Abholzung. Die Areale wurden jeweils vor und nach der Holzentnahme untersucht. Innerhalb der Areale wurden die Anzahl der gefälltten Bäume, das herausgezogene Holzvolumen aus dem Wald aufgezeichnet sowie Straßen, Holzlagerplätze und Rutschlängen von Bäumen und Baumstandorte gemessen. Des Weiteren wurde die Zerstörung der Überschildung durch Bestimmung des Kronenlückenanteils erhoben. Dies erfolgte anhand von Analysegeräten, welche den Anteil der Hemisphäre über dem Instrument mit freier Sicht zum Himmel bestimmen. Messungen wurden für Straßen, Holzplätze, Holzwege, umgestürzte Bäume sowie intakten Wald durchgeführt und basieren auf zufälliger Auswahl. Durch Extrapolation der Messungen wird der gesamte Lückenanteil für jedes Segment berechnet. Asner et al. (2002) zeigten dabei auf, dass die Methoden der selektiven Abholzung (konventionell oder ressourcenschonend) direkten Einfluss auf den Zerstörungsgrad der Überschildung und die Regenerationsraten haben. Generell erfolgt ein rascherer Wiederbewuchs in jenen Gebieten, in welchen auf eine ressourcenschonende Abholzung Wert gelegt wurde. Holzplätze für die Lagerung von Baumstämmen rufen unmittelbar nach deren Rodung die größten Lücken hervor, machen insgesamt jedoch nur 1-2 Prozent der gesamten Holzeinschlagsfläche aus. Ein erheblicher Rückgang des Lückenanteils konnte binnen 1,5 Jahren nach der Stilllegung festgestellt werden. Asner et al. (2004) dehnten die Studie auf zwei weitere Blöcke aus und fanden dabei heraus, dass Straßen in selektiv abgeholzten Gebieten 2,5 Jahre nach den Eingriffen stets hohe Lückenanteile aufwiesen. Rutschungsflächen weisen die stärkste Bodenzerstörung auf, regenerieren sich jedoch in einem Jahr um mehr als 70 Prozent des Lückenanteils. Areale von umgestürzten Bäumen haben den geringsten Lückenanteil, sind jedoch räumlich stark ausgedehnt. Darüber hinaus variiert der

Lückenanteil umgefallener Bäume, wodurch eine Detektion der Kronenzerstörung erschwert wird.

Um die Komplexität und die Folgen von Degradation besser erkennen zu können, führte Gerwing (2002) Feldinventuren in 14 unterschiedlich stark degradierten Waldbeständen in der Region Paragominas, Brasilien durch. Ziel der Studie war es, die Struktur des Waldes sowie die Zusammensetzung unter Beständen, welche unterschiedlichen Intensitäten von selektiver Abholzung und Waldbränden ausgesetzt waren, zu vergleichen. In 10x500m Arealen wurden in jedem Bestand Stichproben von lebenden und toten stehenden Bäumen sowie Lianen mit einem Brusthöhendurchmesser (BHD) von >10cm genommen und deren Art bestimmt. Kleine Bäume mit einer Höhe von mehr als zwei Metern und einem BHD von <10cm sowie alle Kletterlianen wurden in Subarealen zu je 100m² betrachtet. In jedem dieser Subareale wurde das Verhältnis des Waldbodens, bedeckt durch intakte Waldvegetation, gestörten Boden, Totholz und verbrannter Vegetation, bestimmt. Die Messung des Überschirmungsgrades erfolgte mit Hilfe von sphärischen Densiometern. Anhand von Regressionsgleichungen wurde aus den BHD Daten die oberirdische Biomasse für jedes Areal bestimmt. Die Studie liefert somit genaue Informationen über die Einflüsse verschiedener Degradationsarten und -intensitäten auf das gesamte Ökosystem, sowie die damit verbundenen Veränderungen im Kohlenstoffbestand. Souza et al. (2005b) bestätigten den Erfolg dieser Felderhebungsmethode und führten Feldinventuren zur Charakterisierung von degradierten Waldbereichen in Übergangswäldern in Mato Grosso, Brasilien, nach dem Protokoll von Gerwing (2002) durch.

2.3. Verwendung optischer Fernerkundungsdaten

Wie bereits in Kapitel 2.1 angesprochen, werden in Bezug auf das Degradationsmonitoring vor allem optische Fernerkundungsdaten **mittlerer Auflösung** verwendet, wodurch eine Vielzahl der Methoden zur Degradationskartierung auf mittel auflösende Daten abgestimmt sind (siehe Kapitel 2.1, Tab. 2, Tab. 3 und Tab. 4). Nach Olander et al. (2008) stellt die Analyse von jährlichen Zeitreihen von mittel auflösenden Landsatdaten im Rahmen von REDD den idealen Zugang zur Kartierung von Degradation sowie zur Beobachtung von Veränderungen dar. Mittel auflösende Daten wie Landsat verfügen jedoch über eine zu geringe temporale Auflösung um eine ausreichende jährliche Abdeckung mit wolkenfreien Bildern sicher zu stellen. Auch leichte Wolkenbedeckung oder Dunst über tropischen Wäldern kann ein Problem darstellen, da dies in einer Klassifikation oft mit degradierten Waldbereichen verwechselt wird.

Grob auflösende Daten (250m - 1km) verfügen zwar über eine hohe temporale Auflösung, wodurch es einfacher ist, an wolkenfreie optische Daten zu gelangen und Zeitreihen durchzuführen, haben durch ihre geringe räumliche Auflösung jedoch den Nachteil, einen Großteil der Degradation, welche meist kleinräumig ist, nicht unterscheiden zu können. Die Rolle von grob auflösenden optischen Daten wie MODIS

oder SPOT Vegetation liegt daher in der Lokalisierung von so genannten *Hot-Spots* für eine weitere Analyse mit Daten mittlerer Auflösung (siehe Kapitel 0) (Olander et al. 2008, GOFC-Gold 2011).

Fein auflösende Daten, so genannte VHR Daten, mit einer Auflösung von unter 5m werden meist dazu verwendet, um Ergebnisse zu verifizieren und Algorithmen für die Analyse mittel auflösender Daten zu trainieren. Für ein Monitoring größerer Gebiete sind die Datenkosten zu hoch als auch die Verfügbarkeit von Daten zu gering. Ein zusätzliches Problem stellt die häufige Wolkenbedeckung dar (GOFC-Gold 2011). Zudem fanden Souza und Roberts (2005) heraus, dass die Verwendung von hochauflösenden Daten wie Ikonos die Zeitspanne, in der Degradationserscheinungen erkennbar sind, nicht verlängert (siehe Kapitel 2.3.1).

2.3.1. Visuelle Interpretation

Die visuelle Interpretation von optischen VHR-Daten stellt eine Alternative zur Felderhebung dar, um an Bodenverifikationsdaten (*ground-truth*) zu gelangen, so wie es auch in dieser Arbeit der Fall ist. Der Vorteil liegt dabei in dem geringeren Zeit- und Kostenaufwand im Vergleich zu terrestrischen Erhebungen (Souza und Roberts 2005). Darüber hinaus wird die visuelle Interpretation auch zur direkten Kartierung von Degradation herangezogen. In diesem Zusammenhang liegt der Vorteil der visuellen Interpretation in der Unabhängigkeit von hoch entwickelten Bildverarbeitungstechniken. Als Nachteile sind der hohe Zeitaufwand gegenüber automatischen Verfahren sowie die Beeinflussung der Ergebnisse seitens des Interpreters zu nennen (Matricardi et al. 2001, GOFC-Gold 2011).

Visuelle Interpretation von VHR Daten für Referenz und Validierung

Matricardi et al. (2005) führten im Rahmen ihrer Studie eine visuelle Interpretation einer hochauflösenden Ikonoszene zur Generierung von Bodenverifikationsdaten durch, um auf Basis dieser die Genauigkeit der semiautomatischen Analyse von Landsatdaten zu überprüfen. Zur besseren visuellen Interpretierbarkeit der Ikonosdaten wurde ein *Pansharpening* durchgeführt, wodurch multispektrale Informationen in einer räumlichen Auflösung von 1m verfügbar sind. Die Interpretation selbst wurde in der Bandkomposition RGB 3/2/4 in voller Auflösung durchgeführt. Darüber hinaus wurde eine Feldstudie zur Verbesserung der visuellen Interpretation herangezogen.

Visuelle Interpretation zur Kartierung von Degradation

Stone und Lefebvre (1998) führten eine visuelle Interpretation von Landsat TM Daten im brasilianischen Amazonasregenwald durch, um die Lage und das Ausmaß der Degradation, hervorgerufen durch selektive Abholzung, zu kartieren. Die betroffenen

Flächen wurden dabei als Polygone digitalisiert. Stone und Lefebvre (1998) fanden heraus, dass die sichtbaren Hinweise für selektive Abholzung in Landsatdaten drei Jahre nach dem Abholzungsereignis nicht mehr erkennbar sind. Des Weiteren empfehlen Stone und Lefebvre die Verwendung von hochauflösenden Daten zur visuellen Interpretation, da in Landsatdaten aufgrund deren mittlerer Auflösung von 30m kleine Lücken nicht erkennbar sind. Eine automatische Klassifizierung wurde von Stone und Lefebvre (1998) aufgrund der Mischung aus intaktem Wald, abgestorbenen Bäumen, Lücken aufgrund gefällter Bäume, Straßen und Holzlagerplätzen, welche selektive Abholzungsflächen charakterisiert, angezweifelt. Auch Matricardi et al. (2001) wählten eine visuelle Interpretation zur Kartierung von selektiv abgeholzten Wäldern im brasilianischen Amazonasgebiet. Die Digitalisierung erfolgte auf Basis von Landsatdaten in der Bandkomposition von RGB 5,3,2 mit einem variierenden Digitalisierungsmaßstab von 1:30.000 bis 1:100.000. Die Abholzungsflächen wurden in zwei Klassen eingeteilt: in deutliche Abholzung (Straßen, Holzlagerplätze und deutlich zerstörte Kronen) und subtile Abholzung (abgeholzte Gebiete mit sichtbar zerstörten Kronen, verschwindenden Holzlagerplätzen oder keinen Holzlagerplätzen).

De Wasseige und Defourny (2004) kartierten sichtbare Holzwege auf Basis von Landsatzenen in der Zentralafrikanischen Republik. Trotz der schnellen Regeneration des Waldes war fünf Jahre nach der letzten Holzentnahme noch mehr als die Hälfte des Wegenetzes sichtbar, in einem auf 120m resampelten Bild waren es lediglich 34 Prozent.

Brandão und Souza (2006) verwendeten ebenfalls Landsatdaten um offizielle als auch inoffizielle Straßen im zentralen Westen des Bundesstaates Pará, Brasilien, zu identifizieren, zu kartieren sowie hinsichtlich deren Länge und Wachstumsraten zu quantifizieren. Dabei gehen sie von einem engen Zusammenhang zwischen Straßennetzwerken und Aktivitäten selektiver Abholzung aus. Die visuelle Interpretation wurde im Maßstab 1:50.000 durchgeführt. Zur Verbesserung des Kontrastes und der Kontextinformation wurde die Bandkombination 5,4,3 (entsprechend für RGB) gewählt. Basierend auf spektralen und räumlichen Besonderheiten wurden folgende drei Arten von Straßen unterschieden und digitalisiert: sichtbare Straßen (erkennbar anhand durchgehender linearer Features), fragmentierte Straßen (unterbrochene lineare Features, angerissen um die sichtbaren Straßenabschnitte zu verbinden) sowie teilweise sichtbare Straßen (erkennbar anhand ihres Kontextes und deren räumlicher Anordnung, z.B. angrenzend an selektiv abgeholzte Bereiche, zerstörte Kronendächer). In Bezug auf den Zeitaufwand einer manuellen Digitalisierung (2,29h bei 100 Personen) hielten Brandão und Souza (2006) eine flächendeckende Kartierung des gesamten Straßennetzwerkes im brasilianischen Amazonasgebiet für machbar.

Souza und Roberts (2005) untersuchten die Eignung von hochauflösenden Ikonosdaten zur Kartierung von selektiver Abholzung in den Terra Firme Wäldern der Region Paragominas (Pará, Brasilien). Durch eine Fusionierung (*pansharpening*) der multispektralen Kanäle mit dem panchromatischen Kanal beträgt die räumliche Auflösung der Daten 1m. Visuell konnten alle Erscheinungen von selektiver Abholzung (Straßen, Holzplätze, Rückegassen, Lücken in der Beschirmung, Wiederbewuchs) als

auch verbrannte Flächen identifiziert werden. Das Bild zeigte dabei eine Synergie zwischen selektiver Abholzung und Waldbränden. In der Studie wurde geprüft, ob Abholzungserscheinungen, welche anhand von Landsat und Spot Daten in den Jahren 1984 bis 1999 kartiert wurden, in der Ikonoszene aus dem Jahr 2000 unterschieden werden können. Dabei zeigte sich, dass durch den raschen Vegetationswiederbewuchs und dem Kronenschluss eine Identifizierung von stillgelegten Holzplätzen im Ikonosbild nur innerhalb von zwei Jahren möglich ist. Dies entspricht der zeitlichen Begrenzung von mittel auflösenden Daten, welche von zahlreichen Studien angegeben wird (Stone und Lefebvre 1998, Asner et al. 2002, Souza und Barreto 2000, Souza et al. 2003). Alte verbrannte Wälder können im Ikonosbild bis zu vier Jahre nach dem Brand kartiert werden. Generell verlängert die Verwendung von hochauflösenden Daten jedoch nicht die Zeitspanne, in welcher Degradationserscheinungen erkennbar sind. Auch Matricardi et al. (2005) geben in ihrer Studie eine Erkennbarkeit von selektiven Abholzungserscheinungen in Ikonosdaten von ein bis zwei Jahren an.

2.3.2. Automatische Verfahren

Um die Nachteile der visuellen Interpretation (hoher Zeitaufwand, Beeinflussung der Ergebnisse seitens des Interpreters) auszugleichen, wurden verschiedenste Verfahren zur (halb-)automatischen Extraktion von Degradation aus optischen Fernerkundungsdaten entwickelt. Diese umfassen die Analyse der Reflexionswerte einzelner Bänder, die Berechnung von Indizes, spektrale Entmischung, statistische Klassifikationen sowie Kontextanalysen. Darüber hinaus entwickelten Asner et al. (2005c) einen automatischer Verarbeitungsprozess, welcher sich aus einer Kombination von spektraler Entmischung und Kontextanalyse zusammensetzt (siehe Kapitel 2.3.2.7).

2.3.2.1. Reflexion

Eine Analyse der Reflexionswerte einzelner Bänder gilt als grundlegendster per-Pixel Ansatz. Dieser wurde von Asner et al. (2002) herangezogen, um die Sensibilität von Landsat ETM+ Bändern gegenüber selektiver Abholzung in der Region Paragominas (Pará, Brasilien) zu testen. Dabei zeigte sich, dass die Bänder 3 (rot), 5 und 7 (beide MIR) am besten für die Erkennung von nacktem Boden unmittelbar nach dem Abholzungsereignis geeignet sind. Durch die Regeneration der Vegetation geht das Signal in Band 3 zurück. Zu diesem Zeitpunkt weisen die Bänder im nahen und mittleren Infrarot den stärksten Kontrast zwischen sich regenerierenden Flächen und intaktem Wald auf. 1,5 Jahre nach der Abholzung sind Holzplätze visuell nicht mehr ersichtlich, wobei der Anteil an offenen Kronen zu diesem Zeitpunkt 42 Prozent betrug. Andere Schäden resultierend aus Degradation wie Lücken durch umgefallene Bäume, Holzwege und Straßen waren anhand den Reflexionswerten schwer zu erkennen und konnten nur in Wäldern mit intensiver selektiver Abholzung in einem Zeitraum von bis zu 0,5 Jahren nach dem Einschlag erkannt werden. Asner et al. (2002) gehen davon aus, dass eine Erkennung von Degradationserscheinungen (Holzplätze, Straßen, Rückegassen,

umgestürzte Bäume) bei einem Kronenlückenanteil von weniger als 50 Prozent nicht mehr möglich ist.

Nach De Wasseige und Defourny (2004), welche eine Studie in der Zentralafrikanischen Republik durchführten, weist das nahe Infrarot den höchsten Kontrast zwischen intaktem Wald und Bereichen selektiver Abholzung auf. Als relevanteste Bänder für die Erkennung von Abholzungswegen innerhalb des tropischen Waldes nennen sie Rot, nahes und mittleres Infrarot.

Souza et al. (2005b) untersuchten die Eignung von Reflexion einzelner Landsatbänder zur Erkennung verschiedener Degradationspraktiken im Übergangswald von Mato Grosso, Brasilien. Unterschieden wurde demzufolge nicht-mechanisierte Abholzung, gemanagte Abholzung, konventionelle Abholzung, abgeholzt und verbrannt sowie intakter Wald. Innerhalb eines Jahres nach dem Abholzungsereignis ist eine Differenzierung von gemanagter Abholzung, konventioneller Abholzung und abgeholzten sowie verbrannten Bereichen zu intaktem Wald im sichtbaren Bereich des Spektrums, folglich in Band 1 (blau), 2 (grün) und 3 (rot), möglich. Der spektrale Bereich des nahen und des mittleren Infrarots eignet sich für eine Differenzierung von intaktem Wald zu degradierten Bereichen sowie für eine Unterscheidung zwischen verschiedensten Abholzungsarten untereinander bei Verwendung von einem oder zwei Bändern. In den Bändern 3 (rot), 4 (NIR) und 5 (MIR) ließen sich gemanagte Abholzung sowie abgeholzte und verbrannte Bereiche sehr gut von intaktem Wald unterscheiden. Generell kommt es im sichtbaren Bereich des Spektrums zu einer Steigerung der durchschnittlichen Reflexion des Waldes als Folge von Degradation. Im nahen Infrarot (Band 4) ist ein Rückgang der Reflexion als Folge der Degradationsintensität zu beobachten, wohingegen im mittleren Infrarot die Reflexion ansteigt. In den folgenden ein bis vier Jahren nach dem Degradationsprozess sind in abgeholzten und verbrannten Bereichen in nahezu allen Bändern signifikante Veränderungen zu intaktem Wald zu beobachten. In Bezug auf konventionelle Abholzung zeigen sich diese Unterschiede in den folgenden zwei Jahren in den Bändern 2, 3, 5 und 7. Nach drei bis vier Jahren konnten in Band 1 und 4 dementsprechende Differenzen beobachtet werden, was auf einen Wiederbewuchs zurückzuführen sein könnte. Auch Bereiche, in denen gemanagte Abholzung betrieben wurde, zeigen sich im zweiten und dritten Jahr nach dem Einschlag Veränderungen in Band 1 und 4. Nicht-mechanisierte Abholzung zeigt zwei Jahre nach der Degradation im sichtbaren und im infraroten Bereich des Spektrums Unterschiede zu intaktem Wald.

2.3.2.2. Indizes

Indizes werden von Asner et al. (2003) als eine *dimensionslose, strahlungsbasierte Messung, berechnet aus spektralen Kombinationen von Fernerkundungsdaten* definiert. Vegetationsindizes nutzen dabei den Vorteil von starken Reflexionsunterschieden in der Vegetation zwischen dem sichtbaren roten und dem nahen Infrarotbereich des Spektrums. Während sichtbare Strahlung im rotwelligen Bereich von gesunder

Vegetation aufgrund des Chlorophylls absorbiert wird, wird diese im nahen Infrarot stark reflektiert. Die Reflexion im nahen Infrarotbereich wird durch die Strahlenbrechung der Blattzellstruktur verursacht (Abb. 1).




Abb. 1: Reflexionseigenschaften des roten und des nahen Infrarotkanales

Quelle: Schardt, 2010

Vegetationsindizes werden daher verwendet um Vegetationszustände oder Vegetationsdichten besser unterscheiden zu können und spielen aus diesem Grund auch eine wichtige Rolle in der Fernerkundung von Wäldern (Asner et al. 2003). Der *Ratio-Vegetationsindex* (RVI) liefert vor allem in Bezug auf dichte grüne Vegetation gute Ergebnisse (Jackson und Huete 1991) und berechnet sich aus den Landsatbändern pb3 (rot) und pb4 (NIR). pb steht in diesem Zusammenhang für Pixel in Band.

$$RVI = \frac{\rho b4}{\rho b3}$$

Bei der Interpretation der Werte gilt: je höher der Wert des RVI umso dichter ist die grüne Vegetation. Der *Normalized Difference Vegetation Index* (NDVI) berechnet sich ebenso aus den Landsatbändern pb3 und pb4, hebt jedoch kleinere Differenzen in der Vegetationsdichte stärker hervor als der RVI.

$$NDVI = \frac{\rho b4 - \rho b3}{\rho b4 + \rho b3}$$

Die Werte des NDVI liegen zwischen -1 und 1. Hohe Werte, nahe 1, deuten auf eine hohe Dichte an grüner Vegetation hin, während niedrige Werte auf geringe bis keine Vegetation hinweisen. Der Nachteil des NDVI ist seine Sensibilität für Variationen in der Bodenhelligkeit. Eine Verdunklung des Bodens, beispielsweise durch Regen, bewirkt eine Veränderung des NDVI, welche fälschlicherweise als eine Veränderung der Vegetation

bewertet wird (Asner et al 2003). Dies führte zur Entwicklung des *Soil-Adjusted Vegetation Index* (SAVI). Dieser bodenangepasste Vegetationsindex minimiert die Bodenhelligkeitseffekte auf den Vegetationsindex und wird insbesondere für Degradationsprozesse herangezogen (Al Mohamed 2011, Asner et al 2003).

$$SAVI = 1,5 \frac{\rho b4 - \rho b3}{\rho b4 + \rho b3 + 0,5}$$

Aerosole, Dunst und verbleibende Wolken beeinflussen die Qualität von Vegetationsindizes. Aus diesem Grund wurde der *Global Environment Monitoring Index* (GEMI) geschaffen. Dieser nicht-lineare Vegetationsindex soll die Empfindlichkeit des NDVI gegenüber unerwünschten atmosphärischen Einflüssen korrigieren (Asner et al. 2003). Er berechnet sich durch:

$$GEMI = \eta (1 - 0,25\eta) - \frac{\rho b3 - 0,125}{1 - \rho b3}$$

$$\eta = \frac{2(\rho b4^2 - \rho b3^2) - 1,5 \rho b4 + 0,5 \rho b3}{\rho b4 + \rho b3 + 0,5}$$

Im Gegensatz zu den Bändern im sichtbaren Wellenlängenbereich sind nahe und mittlere Infrarotbänder unempfindlich gegenüber atmosphärischen Einflüssen und korrelieren zudem stark mit sichtbaren Bändern unter aerosolfreien atmosphärischen Bedingungen. Somit werden Infrarotindizes, wie *die Normalized Difference Infrared Indices*, als Alternative zu Vegetationsindizes herangezogen (Matricardi et al. 2010). Die *Normalized Difference Infrared Indices* (NDII5 und NDII7) werden anhand der Landsatbänder im nahen Infrarot ($\rho b4$) und im mittleren Infrarot ($\rho b5$ bzw. $\rho b7$) wie folgt berechnet:

$$NDII5 = \frac{\rho b4 - \rho b5}{\rho b4 + \rho b5}$$

$$NDII7 = \frac{\rho b4 - \rho b7}{\rho b4 + \rho b7}$$

Souza et al (2005b) untersuchten die Eignung der Indizes NDVI, SAVI, NDII5 sowie NDII7 zur Differenzierung der Abholzungsklassen nicht-mechanisierte Abholzung, gemanagte Abholzung, konventionelle Abholzung, abgeholzt und verbrannt sowie intakter Wald. Die Studie zeigte, dass innerhalb des ersten Jahres nach dem Abholzungsereignis anhand aller vier Indizes die Klassen gemanagte Abholzung, konventionelle Abholzung, abgeholzt und verbrannt von intaktem Wald unterschieden werden konnten. In Bezug auf Infrarot Indizes konnte ein Sinken des Indexwertes mit Zunahme der Degradationsintensität festgestellt werden. Nicht-mechanisierte Abholzung konnte von keinem der Indizes von intaktem Wald unterschieden werden. In multitemporaler Hinsicht zeigen sich in Bereichen mit konventioneller Abholzung signifikante zeitliche Veränderungen zu intaktem Wald bis zum dritten Jahr nach dem Holzeinschlag. Ein

signifikanter Unterschied zwischen abgeholzten und verbrannten Arealen zu intaktem Wald ist lediglich anhand des NDI15 im vierten Jahr nach dem Eingriff zu beobachten. Matricardi et al. (2010) testeten die Indizes NDVI, SAVI und GEMI zur Ableitung der Überschirmung in Mato Grosso, Brasilien. Aufgrund der starken atmosphärischen Einflüsse modifizierten sie die Indizes SAVI und GEMI indem sie anstatt des roten Bandes, das mittlere Infrarot Band zur Berechnung heranzogen. Dabei stellte sich heraus, dass der SAVI bzw. der modifizierte SAVI unter schlechteren atmosphärischen Bedingungen die besten Ergebnisse liefern.

$$mSAVI = 1,5 \frac{\rho b4 - 0,5 \rho b5}{\rho b4 + 0,5 \rho b5 + 0,5}$$

$$mGEMI = \eta (1 - 0,25\eta) - \frac{0,5 \rho b5 - 0,125}{1 - 0,5 \rho b5}$$

wobei

$$\eta = \frac{2 (\rho b4^2 - 0,5 \rho b5^2) - 1,5 \rho b4 + 0,5 (0,5 \rho b5)}{\rho b4 + 0,5 \rho b5 + 0,5}$$

2.3.2.3. Tasseled Cap

Bei Tasseled Cap handelt es sich um eine lineare Transformation der Spektralbänder in synthetische Kanäle, welche Vegetationszustände besser repräsentieren sollen. Ursprünglich wurde die Tasseled Cap Transformation für landwirtschaftliche Anwendungen konzipiert. Die erste Komponente (*brightness*) enthält Informationen zur Helligkeit, welche als Messwerte für den Boden angesehen werden können. Die zweite Komponente (*greenness*) liefert Informationen über die grüne Vegetation, während die dritte Komponente (*wetness*) die Feuchtigkeit von Boden und Vegetation repräsentiert (Al Mohamed 2011). Nach Huang et al. (2002) decken diese 3 Bänder zusammen mehr als 97 Prozent der spektralen Varianz von Landsat 7 ETM+ ab und verfügen über das Potential Waldparameter wie Arten und Struktur abzuleiten. Tasseled Cap Transformationen wurden von Healy et al (2005) in Bezug auf Waldstörungen in der gemäßigten Zone mit Landsat TM Daten getestet. Dabei wurden die drei Indizes *brightness* (Helligkeit), *greenness* (Grün) und *wetness* (Feuchtigkeit), verschiedene Kombinationen von diesen sowie ein Störungsindex verwendet. Letzterer wird aus der Kombination von *brightness*, *greenness* und *wetness* errechnet und soll die spektralen Signaturen von Nicht-Vegetation hervorheben. Sämtliche Tasseled Cap Transformationen ließen Störungen im Wald besser erkennen als die originalen Landsat TM Bänder.

2.3.2.4. Spectral Mixture Analysis

Mit dem Wissen, dass Waldökosysteme eine räumlich heterogene Zusammensetzung aus Bedeckungstypen wie Vegetation, Schatten und Boden zeigen, beinhaltet jedes Pixel eines Satellitenbildes eine Mischung aus diesen Bedeckungstypen. Der Vorteil der *Spectral Mixture Analysis* (SMA) ist, dass die Reflexion eines Pixels nicht einfach in Bezug auf dessen Eigenschaften in eine einzelne Bedeckungsklasse interpretiert wird, sondern eine Mischung aus verschiedenen Anteilen von jeder Bedeckungsklasse darstellt, die als *Endmember* bezeichnet werden. Solche *Endmember* sind nach Asner in Bezug auf das Degradationsmonitoring in tropischen Wäldern grüne Vegetation (GV), Schatten, Boden sowie nicht photosynthetische Vegetation (NPV). Ziel des Mischungsmodells ist es, die anteilmäßige Bedeckung von jeder Bedeckungsklasse innerhalb eines Pixels zu berechnen. Input für ein spektrales Mischungsmodell sind die Reflexionswerte der *Endmember* und ein Bild aus Beobachtungsvektoren (Reflexionswerte der Pixel). Output der SMA ist ein Grauwertbild pro *Endmember* und ein zusätzliches Bild, welches den Fehleranteil beinhaltet. Die Grauwerte repräsentieren dabei den Anteil des *Endmembers* im jeweiligen Pixel. Anhand der einzelnen Grauwertbilder können weitere spektrale Analysen, Modellberechnungen oder Messungen der Landbedeckung zur Bewertung von räumlichen und zeitlichen Veränderungen durchgeführt werden. Ein weiterer Vorteil der SMA ist, dass diese auf jede Kombination von Wellenlängen angewendet werden kann (Asner et al. 2003). Darüber hinaus bezeichnet GOF-C-Gold (2011) die SMA als robusteste Methode zur Detektion von Degradation in tropischen Wäldern.

Lineares Mischungsmodell

Die Annahme eines linearen Mischungsmodellansatzes ist, dass die Reflexion eines Pixels die Summe der Reflexion aller Bedeckungstypen (*Endmember*) darstellt, gewichtet durch deren anteilmäßige Präsenz innerhalb eines jeden Pixels. In Abb. 2 wird dies für einen einfachen Fall mit zwei Dimensionen dargestellt. Jeder Punkt in der Abbildung repräsentiert die Position eines Pixels im Raum, welcher durch die zwei Reflexionsbänder x und y definiert wird. Die dadurch entstehende Punktwolke stellt im optimalen Fall die geometrische Form eines Dreiecks dar. Die Eckpunkte werden durch die *Endmember*-Vektoren (EM 1, EM 2 und EM 3) gebildet. Jeder Punkt innerhalb des Dreiecks kann als eine lineare Kombination von *Endmember*-Vektoren ausgedrückt werden. Die Gewichtung eines jeden *Endmember*-Vektors stellt seinen mengenmäßigen Anteil an einer Bedeckung innerhalb eines Pixels dar. So beinhaltet Pixel A einen Anteil von je 30 Prozent an EM 1 und EM2 sowie 40 Prozent an EM 3. Die Bänder x und y könnten in diesem Beispiel als Landsatbänder 3 und 4 gedacht werden, die *Endmember* repräsentieren grüne Vegetation, Boden und Schatten (Asner et al. 2003, Haas 2009).

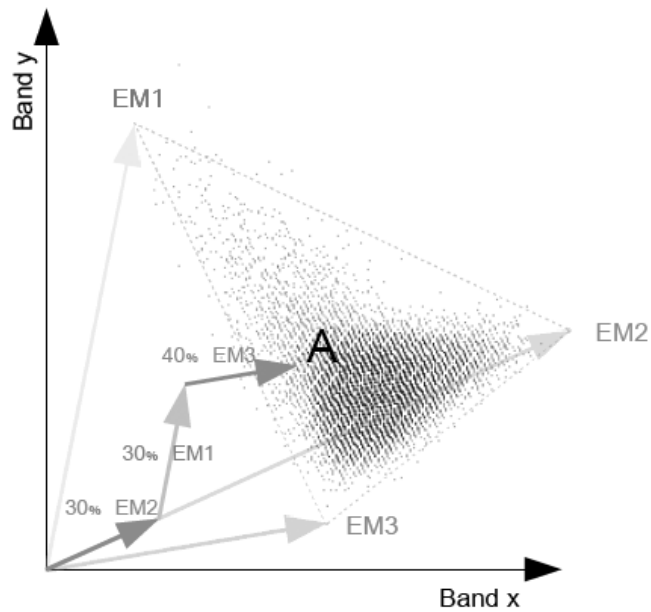


Abb. 2: Schematische Repräsentation eines Mischungsmodells

Quelle: Haas 2009 (nach Asner et al. 2003)

Mathematisch gesehen kann das Mischungsmodell nach Asner et al. (2003) folgendermaßen ausgedrückt werden:

$$\sum_{i=1}^m \rho_{i,b} C_i = \rho_b + \varepsilon_b$$

für

$$\sum_{i=1}^m C_i = 1$$

wobei sich die Summe aus m Endmembers zusammensetzt, $\rho_{i,b}$ die Reflexion des Endmembers i in Band b , C_i die räumliche Fraktion des Endmembers i innerhalb des Pixels, ρ_b die Reflexion des Pixels in Band b und ε_b den Restfehler für jedes Band b darstellt. Die zweite Gleichung beschränkt die Summe der Endmemberanteile auf 1. Wenn die Reflexion in n Wellenlängen gemessen wird, können $n+1$ mögliche Endmember Fraktionen berechnet werden. Dies ergibt sich aus den n Messungen plus die zusätzliche Gleichung zur Beschränkung der Summeneinheit. Nichtlineare Beziehungen zwischen Endmember, wie die multiple Reflexion von Photonen werden in diesem Modell vernachlässigt (Asner et al. 2003). Im Rahmen der untersuchten Studien zur Degradationskartierung basiert die spektrale Entmischungsanalyse stets auf linearen Mischungsmodellen (Cochrane und Souza 1998, Souza und Barreto 2000, Souza et al. 2003, 2005a, 2005b, Asner et al. 2004, 2005c, 2009), wodurch nicht lineare Mischungsmodelle nicht weiter behandelt werden.

Endmember Selektion

Die Auswahl von *Endmember* ist ein wichtiger Bestandteil für eine erfolgreiche Anwendung des Mischungsmodells, da diese als Input für das spektrale Mischungsmodell herangezogen werden. In Bezug auf das Degradationsmonitoring werden in der Regel die vier *Endmember*, grüne Vegetation (GV), nicht-photosynthetische Vegetation (NPV), Boden und Schatten, für die spektrale Entmischung herangezogen. *Endmember* können entweder aus Messungen von Reflexionswerten im Feld bzw. im Labor oder direkt aus den Bilddaten abgeleitet werden.

Die Ableitung von *Endmember* auf Basis von Feld- oder Labormessungen ermöglicht zwar eine bessere Kontrolle hinsichtlich der Auswahl der *Endmemberspektren*, die Messung von *Endmemberwerten* in Waldökosystemen für sämtliche Bedeckungsarten ist jedoch schwierig. Dies betrifft vor allem die Messung des *Endmembers* für intakte grüne Vegetation, da die Größe und Höhe der Baumkronen die Messung von Reflexionswerten der Baumkronen erschwert. Zusätzlich kann die Reflexion der Bedeckungsarten zeitlich variieren, wodurch beispielsweise Unterschiede in der Bodenfeuchtigkeit oder in der Phänologie zwischen dem Zeitraum der Felderhebung und dem Aufnahmedatum der Satellitenbilddaten die Interpretation der Bedeckungsarten in den Anteilbildern (*fraction images*) behindern (Asner et al. 2003). Eine genaue radiometrische Anpassung der Satellitenbilddaten ist daher unumgänglich. Asner et al. (2004, 2005b, 2009) bevorzugen dennoch in ihren Studien die Ableitung von *Endmemberspektren* aus Feldmessungen. Die Reflexionsmessungen werden mittels Spektralradiometern durchgeführt, wobei unterschiedlichste Ausprägungen eines jeden *Endmembers* erfasst werden, um diesen bestmöglich zu repräsentieren. Daraus ergibt sich eine spektrale Bibliothek von verschiedensten Signaturen für jeden *Endmember*. Die *Endmemberspektren* von photosynthetischer Vegetation (PV) werden von Asner et al. direkt aus Satellitenbilddaten abgeleitet, da die Vegetationshöhe (>20m) die Sammlung der *Endmemberspektren* im Feld unmöglich macht. Aufgrund der starken Variabilität von Schatten je nach Waldstruktur wird der Schattenanteil in den *Endmember PV* miteinbezogen (Asner et al. 2005b).

Bei der direkten Ableitung von *Endmember* aus den Bilddaten werden Reflexionswerte von relativ „reinen“ Pixeln für potentielle *Endmemberwerte* herangezogen. Diese Pixel liegen in den Extrembereichen der Punktwolke im Merkmalsraum (*Feature Space*). In Bezug auf Abb. 2 liegen diese genau an den Eckpunkten des Merkmalsraumes (Asner et al. 2003). In einem mehr als zweidimensionalen Merkmalsraum ist es schwierig, die Extreme der Punktwolke und somit die *Endmember* richtig zu erkennen. In diesem Zusammenhang ist eine Verringerung der Dimensionen durch eine *Minimum Noise Fraction* (MNF) Transformation oder eine Hauptkomponentenanalyse (*Principal Component Analysis*, kurz PCA) hilfreich. Die ersten beiden Hauptkomponenten der PCA beinhalten die Mehrheit der spektralen Varianz der Daten, wodurch lediglich ein geringer Informationsverlust durch die Verringerung der Dimensionen entsteht (Cochrane und Souza 1998, Small 2004). Eine weitere Möglichkeit zur Ableitung von

Endmemberspektren aus n-dimensionalen Merkmalsräumen ist der *Pixel Purity Index* (PPI). Anhand dieses iterativen Algorithmus werden Pixel mit hohem spektralem „Reinheitsgrad“ (*purity*) gesucht und markiert. Die reinsten Pixel an den Eckpunkten akkumulieren dabei die meisten Markierungen und korrespondieren gewöhnlich mit den *Endmember*. Im Ausgabebild wird nun die Anzahl der Markierungen für jeden Pixel und somit dessen Reinheit wiedergegeben (Boardman et al. 1995, Matricardi et al. 2010). Souza und Barreto (2000), Souza et al. (2003, 2005a, 2005b) als auch Matricardi et al. (2010) wandten den PPI zur Ableitung von *Endmemberkandidaten* an. Aufgrund der Ergebnisse des PPI wurde die Lage der potentiellen *Endmemberpixel* im Originalbild identifiziert und die spektralen Kurven dieser Pixel zu extrahiert. Im spektralen Merkmalsraum befinden sich die *Endmemberkandidaten* in den Extrembereichen der Punktwolke. Die finalen Bildendmember wurden aufgrund ihrer Lage im spektralen Merkmalsraum des Bildes, auf Basis der spektralen Kurven sowie aus dem Bildkontext abgeleitet. So wird der *Endmember* Boden mit unbefestigten Straßen assoziiert, grüne Vegetation mit grünen Weiden, Schatten mit dunklen Wasserkörpern (Souza et al. 2003) bzw. mit dem Wert 0 in allen Bändern (Souza et al. 2005a, 2005b) und NPV mit alternder Vegetation (z.B. alterndes Gras auf einer Weide). Haas (2009) wandte vor der Durchführung des PPI eine MNF Transformation an, um die Datendimension und das Bildrauschen zu verringern. Die Bestimmung der *Endmembersignaturen* erfolgte im Merkmalsraum der ersten beiden MNF Bänder und anhand des Bildkontextes. Die Ergebnisse des PPI wurden nur unterstützend herangezogen. Da der *Endmember* NPV in Landsatdaten nur schwer aufzufinden ist, basierte die SMA lediglich auf den drei *Endmember* Boden, Schatten und grüne Vegetation. Der *Endmember* für Boden wurde dabei mit unbefestigten Straßen, GV mit Wiederbewuchsflächen oder aufgegebenen Holzstraßen und Schatten mit schattigen Reliefbereichen assoziiert. Auch Souza und Barreto (2000) verwendeten nur die drei *Endmember* Boden, Schatten und GV für die spektrale Entmischung und erzielten ebenso gute Ergebnisse. Um die *Endmembersignaturen* multitemporal anwenden zu können, führten Souza et al. (2005a, 2005b) eine relative radiometrische Kalibrierung der Szenen durch. Als Referenz wurde jene Szene herangezogen, auf Basis deren die *Endmember* abgeleitet wurden.

Verwendung von Anteilbildern (fraction images)

Die aus der SMA resultierenden Anteilbilder pro *Endmember* (*fraction images*) geben die anteilmäßige Bedeckung des jeweiligen *Endmembers* in jedem Pixel wieder und verbessern dadurch die Erkennbarkeit von Degradationserscheinungen. Die Bodenfraktion erleichtert die Detektion von Straßen, Holzwegen und Holzplätzen und auch kleine abgeholzte Bereiche sind in dieser Fraktion gut erkennbar. Zerstörte Waldbereiche werden anhand der NPV Fraktion hervorgehoben, während die GV-Fraktion sensibel für Lücken in der Überschildung ist (Souza et al. 2009). Generell wird Degradation mit einem Anstieg der Boden- und NPV-Anteile und einem Rückgang der GV-Fraktion assoziiert. Im Zuge der Regeneration des Waldes steigen die GV-Anteile wieder an, während die Boden- und NPV Anteile zurückgehen und nach einiger Zeit gänzlich verschwinden (Souza et al. 2005b).

Cochrane und Souza (1998) klassifizierten auf Basis der SMA verbrannte Waldflächen im östlichen Amazonasgebiet. Die NPV Fraktion, welche auf abgestorbene Vegetation schließen lässt, lieferte dabei die beste Trennbarkeit von unverbranntem, kürzlich verbranntem und bereit seit längerem (> 1 Jahr) verbrannten Waldflächen. Souza et al. (2003) bestätigten die gute Trennbarkeit von Degradation zu intaktem Wald in der NPV Fraktion und wiesen auch auf deren Beständigkeit über die Zeit hin. In stark verbrannten bzw. stark abgeholzten Arealen beobachteten Souza et al. (2003) einen Anstieg in der NPV und Schattenfraktion bei einer Abnahme des grünen Vegetationsanteiles. Intakte Wälder hingegen wiesen geringe NPV Werte bei hohen Anteilen an grüner Vegetation und Schatten auf. Wiederbewuchsflächen resultieren in einem Rückgang des Schattenanteils bei einem Anstieg der grünen Vegetation.

Souza et al. (2005b) führten eine Klassifizierung von intaktem Wald, nicht-mechanisierter Abholzung, gemanagter Abholzung, konventioneller Abholzung sowie abgeholzten und verbrannten Flächen im südlichen Amazonasgebiet durch. Dabei zeigte sich, dass in der GV-Fraktion intakter Wald nur schwer von nicht-mechanisierter Abholzung und gemanagter Abholzung zu trennen ist, während die Trennung dieser Klassen von konventioneller Abholzung sowie abgeholzten und verbrannten Flächen sehr gut funktioniert. In den Fraktionen NPV, Boden und Schatten verhielt sich die Trennmöglichkeit ähnlich. Die Kombination der *Endmemberfraktionen* NPV und Boden ermöglichte eine noch bessere Trennung der Klassen als die jeweiligen individuellen Fraktionen. Veränderungen sind in der GV Fraktion nicht länger als ein Jahr erkennbar, in der NPV Fraktion jedoch bis zu zwei Jahre. Weniger intensive Waldstörungen (ausgelöst durch nicht-mechanisierte Abholzung und gemanagte Abholzung) sind schwieriger zu erkennen, auch innerhalb des Jahres in dem die Abholzung stattgefunden hat. In diesem Zusammenhang ist die Erkennung der Abholzungsinfrastruktur wichtig, um diese Formen der selektiven Abholzung von anderen Waldstörungen zu unterscheiden. Zwei bis drei Jahre nach dem Abholzungsereignis beobachteten Souza et al. (2005b) ein signifikantes Regenerationssignal (Anstieg an GV und Schatten) in den Fraktionsbildern, welches durch den Unterholzwiederbewuchs und den Kronenschluss entsteht. In abgeholzten und verbrannten Gebieten ist das Regenerationssignal auch im vierten Jahr nach dem Einschlag noch präsent. Die Ergebnisse von Haas (2009) in Kamerun zeigten, dass Wiederbewuchs am besten in der GV-Fraktion detektiert werden kann, während Degradation am besten durch den Bodenanteil repräsentiert wird. Negron-Juarez et al. (2011) untersuchten die Sensitivität von spektral entmischten Landsatdaten (*Endmember* GV, NPV und Schatten) zur Erkennung von Lücken gefällter Bäume im Amazonasgebiet nördlich von Manaus. Diese konnten durch die jährliche Veränderung in den NPV-Anteilen in einer Größenordnung bis zu 100m^2 detektiert werden. Wenn Lücken an der Grenze zwischen zwei oder mehreren Pixel liegen, teilt sich das Signal auf mehrere Pixel auf, wodurch dieses unter dem Detektionsschwellwert liegt. Kleinere Lücken schließen sich sehr rasch, größere sind innerhalb eines Jahres erkennbar.

Normalized Difference Fraction Index (NDFI)

Um die Intensität von Degradation stärker hervorzuheben, entwickelten Souza et al. (2005a) den *Normalized Difference Fraction Index (NDFI)*. Dieser auf der SMA basierende Index berechnet sich aus den Fraktionen grüne Vegetation (GV), Schatten, nicht-photosynthetische Vegetation (NPV) und Boden wie folgt:

$$NDFI = \frac{GV_{Schatten} - (NPV + Boden)}{GV_{Schatten} + (NPV + Boden)}$$

Wobei $GV_{Schatten}$ die Schatten-normalisierte GV Fraktion gegeben durch

$$GV_{Schatten} = \frac{GV}{100 - Schatten}$$

darstellt. Die Werte des NDFI liegen zwischen -1 und 1. Intakter Wald ist dabei durch hohe NDFI Werte (um 1) gekennzeichnet, da sich dieser aus hohen Werten im Bereich der GV und Schatten zusammensetzt und geringe Werte an NPV und Boden aufweist. Mit Zunahme der Degradation steigen die Anteile der NPV und des Bodens, wodurch die NDFI Werte relativ zu intaktem Wald abnehmen. Der Vorteil des NDFI ist die Kombination von allen relevanten Informationen der verschiedenen Endmember Fraktionen in einem synthetischen Band (Souza et al. 2005 a). Darüber hinaus ist dieser Index nach Souza et al. (2005a) sensibler für zerstörte Kronen als jede individuelle Fraktion. Auch Haas (2009) erzielte mit diesem Ansatz gute Ergebnisse. Da Haas (2009) die spektrale Entmischung auf Basis von nur drei *Endmembers* (Boden, Schatten, GV) durchführte, modifizierte er den NDFI dementsprechend und ersetzte den Term (Boden + NPV) durch Boden.

2.3.2.5. Klassifikationsmethoden

Automatische Klassifikationsverfahren ordnen Pixel bzw. Bildsegmente nach deren Eigenschaften automatisch einer oder mehreren Klassen zu. Während bei objektbasierten Verfahren Pixel zu Objekten zusammengefasst und semantischen Klassen zugewiesen werden, erfolgt bei pixelbasierten Verfahren die Zuordnung zu thematischen Klassen aufgrund des Grauwertes der Pixel. Darüber hinaus wird bei der automatischen Klassifikation zwischen unüberwachten und überwachten Verfahren unterschieden. Ersteres ordnet die Pixel aufgrund deren spektraler Eigenschaften einer vordefinierten Anzahl an Clustern zu, wobei der Mensch zwar die Anzahl der Klassen vorgibt, jedoch keinen Einfluss auf die Zuordnung zu den Clustern hat. Er kann diesen erst im Nachhinein eine Bedeutung zuweisen. Überwachte Klassifizierungsverfahren hingegen erfordern Informationen über die spektralen Charakteristika der jeweiligen Klassen in Form von Trainingsgebieten. Die Pixel werden dabei jener Klasse zugewiesen, welcher sie aufgrund der gewählten Entscheidungsregel am nächsten liegen (Sulzer 2009, Schardt 2010).

Im Hinblick auf die Degradationskartierung werden in den recherchierten Studien pixelbasierte Ansätze mit unüberwachten als auch überwachten Klassifikationsverfahren angewandt. Als Klassifikationsalgorithmen für die überwachte Klassifikation werden in den Studien folgende herangezogen:

- **Schwellwertverfahren:** Bestimmung der Zugehörigkeit eines Pixels zu einer Klasse durch den Vergleich des Grauwertes oder eines anderen eindimensionalen Merkmals.
- **Decision Tree:** Zuordnung der Pixel in Klassen erfolgt durch die hierarchische Aufspaltung der Daten nach einem Set an Regeln bzw. Schwellwerten.
- **Maximum Likelihood:** Bestimmung der Wahrscheinlichkeit der Zugehörigkeit eines Pixels zu einer Klasse aufgrund von statistischen Kenngrößen unter der Voraussetzung einer Normalverteilung der Klassen. Genauer ausgedrückt berechnet der Algorithmus die Mahalanobisdistanz und ordnet die Pixel jener Klasse zu, zu welcher die geringste Distanz besteht. Die Klassenausbreitung wird über die Angabe einer a-priori Wahrscheinlichkeit festgelegt, wobei die Varianz der Klassen unterschiedlich stark gewichtet werden kann.
- **Subpixel Klassifikator:** Aufbau einer Signatur für ein spezielles Material (*Material of Interest*, kurz MOI) und Überprüfung eines jeden Pixels, ob das gesuchte MOI enthalten ist. Die Pixel werden je nach detektiertem Anteil des gesuchten Materials den entsprechenden Klassen zugewiesen (Priemer und Lohmann 2001, Sulzer 2009, Schardt 2010). Im Gegensatz zur SMA (beschrieben in Kapitel 2.3.2.4) sucht der Subpixel Klassifikator nach dem Anteil des MOI in den Pixeln, nicht nach n szenenspezifischen Materialien. Als Ergebnis wird die Menge des MOI zurückgegeben, wohingegen die SMA n Fraktionsbilder für n szenencharakteristische Materialien liefert. Bei der Klassifikation von mehreren MOIs wird der Prozess für jedes MOI wiederholt (ERDAS 2012).

Stone und Lefebvre (1998) testeten im Rahmen ihrer Studie in Paragominas (Pará, Brasilien) sowohl eine unüberwachte, als auch eine überwachte Klassifikation mit *Maximum Likelihood* Klassifikator, um Degradationserscheinungen auf Basis von Landsatdaten zu kartieren. Die Klassen umfassten intakten Wald, offene Wasserflächen und Flüsse, Felder und Weideland, Wolken sowie Wolkenschatten. Eine automatische Klassifizierung der selektiven Abholzungserscheinungen als auch die Kartierung des Sekundärwaldes war nicht möglich. Auch in einem weiteren Testgebiet gelang es nicht, eine separate spektrale Klasse für selektiv abgeholzte Waldgebiete zu definieren.

Hussin und Atmopawiro (2004) versuchten mittels *Maximum Likelihood* und Subpixel Klassifikator auf Basis von Landsat ETM+ Daten illegale Abholzung in Berau, Indonesien zu erkennen. Die Trainingsgebiete für die jeweiligen Klassen wurden aus Referenzdaten von Felderhebungen abgeleitet. Der *Maximum Likelihood* Klassifikator lieferte unter Verwendung der beiden Klassen neue Abholzungsplätze und Andere akzeptable Ergebnisse. Der Einsatz von den drei Klassen Wald, Nicht-Wald und neue Abholzungsplätze sowie sechs Klassen (vier verschiedenen Waldklassen, nicht Wald, neue Abholzungsplätze) verschlechterte die Ergebnisse. Für den Subpixel Klassifikator

wurde eine automatische Ableitung der Signaturen aus den Trainingsgebieten gewählt. Die Klassifikation wurde für acht Klassen, so genannten *Materials of Interest* (MOI) durchgeführt, wobei eine Klasse die neuen Abholzungsstellen bildeten. Im direkten Vergleich der beiden Klassifikationsmethoden stellte sich das Ergebnis der Subpixel Klassifikation bei der Erkennung von gefälltten Einzelbäumen als wesentlich genauer heraus, als jenes der *Maximum Likelihood* Methode. Dies erklärten Hussin und Atmopawiro (2004) durch den unterschiedlichen Signaturableitungsprozess der beiden Methoden. Während der *Maximum Likelihood* Klassifikator Signaturen aus der Kombination der Spektren aus den Trainingsgebieten, welche die Zusammensetzung aller Materialien im Testgebiet beinhalten, ableitet, extrahiert der Subpixel Klassifikator jenes Pixelspektrum, welches im Trainingsgebiet am meisten vorkommt. Abgesehen davon identifiziert der Maximum Likelihood Klassifikator Pixel mit denselben spektralen Eigenschaften als die Signatur als zugehörig zu dieser Klasse. Der Subpixel Klassifikator hingegen berechnet und entfernt den Subpixelhintergrund und vergleicht das verbleibende Spektrum mit der Signatur (Hussin und Atmopawiro 2004).

Schwellwert- und *Decision Tree* Verfahren wurden in den recherchierten Studien zur Klassifikation der Ergebnisse aus der SMA eingesetzt. So wandten beispielsweise Cochrane und Souza (1998), Souza und Barreto (2000), Monteiro et al. (2003), Asner et al. (2005c), Souza et al. (2005a) sowie Matricardi et al. (2010) Schwellwerte auf die Anteilsbilder der SMA an, um Abholzungsinfrastruktur wie Straßen, Rückegassen und Holzlagerplätze, degradierte Waldbereiche oder Wiederbewuchsflächen zu klassifizieren. Zur Klassifikation von zerstörten Baumkronen anhand des NDFI wählten Souza et al. (2005a) ebenso das Schwellwertverfahren. Aufbauend auf Schwellwertklassifikationen von Fraktionsbildern führten Souza und Barreto (2000), Monteiro et al. (2003) und Asner et al. (2005b), Kontextanalysen durch (siehe Kapitel 2.3.2.6).

Souza et al. (2003) setzten zur Klassifizierung ihrer Ergebnisse aus der SMA einen *Decision Tree Classifier* (DTC) ein. Auf Basis der einzelnen Fraktionsbilder (Boden, NPV, Schatten, GV) definierten Souza et al. (2003) mittels Schwellwerten ein Set an Regeln, um die Waldklassen intakter Wald, degradiertes Wald, regenerierender Wald und abgeholzter Wald zu unterscheiden. Während der DTC im Terra Firme Wald von Pará im östlichen Amazonasgebiet gute Ergebnisse erzielte (Souza et al. 2003), waren diese in den Übergangswäldern im südlichen Amazonasgebiet nur wenig zufriedenstellend. Zurückzuführen ist dies vermutlich auf die offenere Natur der Übergangswälder im Vergleich zu den dichten Terra Firme Wäldern (Souza et al. 2005a).

Weitere gängige Klassifikationsalgorithmen (Sulzer 2009, Schardt 2010) wie

- **Minimum Distance** (Berechnung des Abstandes der zu klassifizierenden Pixel zu den Mittelpunkten der verschiedenen Klassen mittels euklidischer Distanz, keine Berücksichtigung der Streuung der Klassen),
- **Parallelepiped** (Annäherung der Klassen durch n-dimensionale Quader bzw. Rechtecke im zweidimensionalen Fall, die Größe der einzelnen Quader bzw. der

Rechtecke wird durch die Minima und Maxima oder durch die Standardabweichung der Trainingsgebiete bestimmt), oder

- **Mahalanobis Distance** (Berechnung der Mahalanobis Distanz und Zuweisung der Pixel zu jener Klasse, zu derer die Distanz am geringsten ist. Die Varianz der Klassen wird dabei berücksichtigt. Voraussetzung ist die Normalverteilung der Grauwerte)

werden im Zuge der Klassifizierung von Degradation in der recherchierten Literatur nicht angewandt. Auch *Fuzzy Classifiers*, welche Pixel nicht binär einer Klasse zuordnen, sondern Zwischenwerte zulassen (Oczipka 2007), wurden in diesen Studien nicht in Betracht gezogen. Fraktionsbilder der SMA, welche Anteilswerte enthalten, werden in den untersuchten Studien, wie bereits erwähnt, entweder mittels Schwellwertverfahren (Cochrane und Souza 1998, Souza und Barreto 2000, Monteiro et al. 2003, Asner et al. 2005c, Souza et al. 2005a, Matricardi et al. 2010) oder mittels eines *Decision Tree* Ansatzes (Souza et al. 2003) binär klassifiziert.

2.3.2.6. Kontextanalyse

Kontextanalysen gehen über den per-Pixel Ansatz der bereits beschriebenen Methoden hinaus und beziehen auch den räumlichen Kontext in die Kartierung von Degradation mit ein. Dieser wird in der Regel durch die Infrastruktur, wie unbefestigte Straßen und Holzlagerplätze, welche Indiz für selektive Abholzung sind, hergestellt. Durch die Einbeziehung dieser Zusatzinformation ist es beispielsweise möglich, anthropogene Waldschäden von natürlichen Störungen zu unterscheiden. Die Anwendungen reichen dabei von Holzentnahme-Radien ausgehend von Holzlagerplätzen über kontextbasierte Klassifikationen bis hin zu automatischen Analysesystemen.

Holzentnahme-Radius um Holzlagerplätze

Wie in Kapitel 1.2 bereits angesprochen, erfordert selektive Abholzung eine gewisse Infrastruktur für die Lagerung und den Abtransport des Holzes. Unter der Annahme, dass selektive Abholzung nur innerhalb eines gewissen Umkreises von Holzstraßen und Holzlagerplätzen durchgeführt wird, kann ein Radius zur Berechnung der maximalen Eingriffsfläche bestimmt werden. Souza und Barreto (2000) verfolgten diesen Ansatz und führten auf Basis von Holzlagerplätzen eine Kontextanalyse durch, um selektiv abgeholzte Terra Firme Wälder in der Region Paragominas im östlichen brasilianischen Amazonasgebiet zu detektieren. Die Holzlagerplätze wurden aus Bodenanteilsbildern, welche mittels SMA aus Landsat TM Daten berechnet wurden, extrahiert und bestehen aus Gruppen von einem bis drei zusammenhängenden Pixeln mit einem Bodenanteil von mehr als 20 Prozent. Der Schwellwert wurde statistisch aus 100 visuell detektierten Holzlagerplätzen aus dem Bodenanteilsbild bestimmt. Auf die identifizierten Holzlagerplätze wurde ein Puffer angewandt, um die potentielle, von selektiver Abholzung betroffene Waldfläche zu ermitteln. Um die Reichweite eines Holzlagerplatzes und somit den Radius des Puffers zu berechnen, wurde das gesamte abgeholzte Gebiet durch die Anzahl an Holzlagerplätzen geteilt. Daraus ergab sich ein durchschnittlicher Radius von 162m. Dieser wurde auf ein Vielfaches der räumlichen

Auflösung von Landsatdaten (30m) und somit auf 180m aufgerechnet. Durch den raschen Wiederbewuchs konnten bereits nach einem Jahr nur mehr 6 von 10 identifizierten Holzlagerplätzen anhand der Landsatszene detektiert werden, drei Jahre danach keiner mehr. Daher ist nach Souza und Barreto (2000) ein jährliches Monitoring unumgänglich, um Fehlklassifikationen von selektiv abgeholzten Wäldern als intakten Wald zu vermeiden.

Monteiro et al. (2003) wandten dieselbe Methode zur Kartierung von selektiv abgeholzten Waldflächen auf Übergangswälder im südlichen Amazonasgebiet an. Als Holzentnahme-Radius wurde die Hälfte der maximal gemessenen Distanz zwischen zwei Holzlagerplätzen angenommen, woraus sich ein Radius von 350m ergab. Den größeren Radius im Vergleich zu Terra Firme Wäldern führten Monteiro et al. (2003) auf eine geringere Dichte an kommerziell wertvollen Bäumen in Übergangswäldern zurück. Des Weiteren können auch unterschiedliche Abholzungspraktiken und Berechnungsmethoden ausschlaggebend für differierende Radien sein.

Contextual Classification Algorithm

Souza et al. (2005a) entwickelten den *Contextual Classification Algorithm (CCA)* um Schäden in der Überschirmung, verursacht durch selektive Abholzung und Waldbrände, von natürlichen Störungen unterscheiden zu können. Der Algorithmus verwendet dabei detektierte Holzlagerplätze als räumliche Kontextinformation, um auf Basis deren zerstörte Kronen anhand des NDFI zu detektieren. Holzlagerplätze und Straßen werden mittels eines Schwellwertes von >10 Prozent aus dem Bodenanteilsbild (Berechnung durch SMA) extrahiert. Regionen mit einer Fläche von ein bis vier zusammenhängenden Pixeln werden dabei als Holzlagerplätze identifiziert. Diese werden wiederum als Startpunkte für einen *region growing* Prozess im NDFI Bild herangezogen. Wenn der NDFI Wert der benachbarten Pixel zwischen 0 und 0,75 liegt, wird dieser Pixel mit zerstörten Baumkronen assoziiert und der Region hinzugefügt. Dieser Prozess wiederholt sich bis keiner der umgebenden Pixel dieses Kriterium erfüllt. Der Nachteil in der Anwendung des Algorithmus ist, dass die Schwellwerte nicht auf größere Gebiete, wie etwa die gesamte Amazonasregion, angewandt werden können, sondern stets auf den jeweiligen Waldtyp angepasst werden müssen (Souza et al. 2005a).

2.3.2.7. Carnegie Landsat Analysis System (CLAS)

Das Carnegie Landsat Analysis System (CLAS) ist ein von Asner et al. (2005c) entwickelter automatischer Verarbeitungsprozess zur Detektion und Quantifizierung von Walddegradation auf Basis von Landsat ETM+ Daten. Der Prozess beinhaltet eine atmosphärische Korrektur der Satellitenbilddaten, eine SMA basierte Berechnung der PV-, NPV- und Bodenanteile zur Detektion von intakter Überschirmung, abgestorbener Vegetation und bloßen Oberflächen, eine Ausmaskierung von Wolken, Wolkenschatten, Wasserkörpern und nicht-Waldgebieten sowie einen Mustererkennungsalgorithmus zur Kartierung von Degradation. Die spektrale Entmischung der Bildpixel in die einzelnen

Bedeckungsarten (PV, NPV und Boden) ist voll automatisiert und verwendet einen *Monte Carlo Unmixing* Zugang. Die Endmember werden dabei in einem iterativen Prozess aus spektralen Bibliotheken ausgewählt. Diese beinhalten alle gewöhnlichen *Endmember*-Ausprägungen des brasilianischen Amazonasgebietes und wurden anhand von Feldmessungen bzw. aus Satellitenbilddaten erhoben (nähere Informationen dazu siehe Kapitel 2.3.2.4) (Asner 2005b, c). Auf die berechneten Fraktionsbilder wird ein Mustererkennungsalgorithmus angewandt, welcher für die Kartierung von selektiv abgeholzten Gebieten verantwortlich ist. In einem ersten Schritt werden Veränderungen, welche auf Degradation hinweisen, mit einem zeitlichen Abstand von etwa einem Jahr anhand von PV- bzw. NPV- Fraktionsbildpaaren detektiert. Degradation wird dabei mit einem Rückgang des PV Anteiles bei einem gleichzeitigen Anstieg des NPV Anteiles verbunden. Danach erfolgt eine automatische Detektion von Holzplätzen über die Suche nach Pixel mit starkem Rückgang des PV-Anteils im Zentrum eines 7x7 Pixelkernels. In Gebieten mit willkürlicher Abholzung, geringer oder extrem hoher Degradation, oder wo Straßen selbst als Lager- und Ladezonen für Holz benützt werden, sind Holzlagerplätze nicht immer unterscheidbar. In diesem Fall werden Rückegassen zur Erkennung von selektiver Abholzung herangezogen, da diese in allen Gebieten mit selektiver Abholzung vorkommen. Rückegassen sind ebenso wie Holzplätze durch starke Rückgänge der PV-Anteile sowie anhand ihrer linearen oder nahezu linearen Muster erfassbar. Um die Konzentration von Rückegassen und Hilfsstraßen für den Abtransport der Hölzer zu detektieren, wird ein sich bewegendes 6x6 Pixelkernel auf das PV-Fraktionsbild angewandt, wodurch die lineare Featureextraktion begünstigt wird. Nachdem die lineare und die Holzplatz-Mustererkennung vollendet sind, integriert der Algorithmus die verschiedenen Ergebnisse, um damit die räumliche Dichte von wahrscheinlicher Abholzungsaktivität zu identifizieren (Asner et al. 2005c).

Der CLAS Algorithmus wurde von Asner et al. (2005c) erfolgreich auf das gesamte Amazonasgebiet Brasiliens angewandt. Oliveira et al. (2007) übertrugen den Algorithmus auf das peruanische Amazonasgebiet, welches durch kleinräumigere Degradation gekennzeichnet ist, und erweiterten diesen um die Detektion von Entwaldung. Um CLAS auch für nicht-Experten zugänglich zu machen, entwickelten Asner et al. (2009) eine Desktop Version des Algorithmus mit der Bezeichnung CLASlite. Diese bietet eine rasche, vollautomatische Kartierung von Waldbedeckung, Entwaldung und Degradation unter Verwendung verschiedenster Sensoren wie Landsat TM und ETM+, SPOT, ASTER, ALI und MODIS Daten. Der Prozess verwendet im Wesentlichen die Komponenten von CLAS und bietet neben der vollautomatischen Detektion von Veränderungen zwischen zwei Zeiträumen auch eine Analyse von Einzelbildern zur Kartierung von Waldbedeckung. CLASlite wurde in den tropischen Regenwäldern des peruanischen Amazonasgebietes und Borneos sowie auf Hawaii getestet.

2.3.3. Hot-Spot Mapping

Aufgrund der geringen räumlichen Auflösung (250m - 1km) werden grob auflösende optische Daten wie MODIS, AVHRR oder SPOT Vegetation im Kontext von REDD für ein *Hot-Spot Mapping* zur Identifizierung von Gebieten mit Degradationserscheinungen eingesetzt, um in Folge die betroffenen Gebiete mit Daten mittlerer Auflösung weiter zu analysieren (Olander et al. 2008, GOFC-Gold 2011).

Lucas et al. (2000) kartierten sich regenerierenden Wald in Südkamerun unter Verwendung von *Advanced Very High Resolution Radiometer* (AVHRR) Daten, welche täglich Daten mit einer Auflösung von 1,1 km liefern. Dabei konnte eine signifikante negative Korrelation zwischen der Streuung im mittleren Infrarotkanal (AVHRR Band 3) und den Waldeigenschaften (Dichte und Grundfläche auf Brusthöhe, Biomasse) beobachtet werden. Roy (2005) entwickelte auf Basis von MODIS Zeitreihendaten mit einer Auflösung von 250 m eine Methode zur Kartierung von Waldbränden betroffenen Flächen/verbrannten Waldflächen. Koltunov et al. (2009) untersuchten die Beziehung zwischen selektiver Abholzung und der Phänologie im brasilianischen Regenwald von Mato Grosso unter Verwendung von MODIS Daten mit einer räumlichen Auflösung von 1km. Für die Berechnung des Feuchtigkeitsgehaltes und der Grüne der Vegetation wurden der *Enhanced Vegetation Index*, welcher sich auf das Grün der Vegetationsdecke bezieht, sowie der *Normalized Difference Water Index* herangezogen. Letzterer ist sensibel für den Feuchtigkeitsgehalt der Vegetation. Dabei stellte sich heraus, dass geringe Beschädigungen des Kronenschlusses im Ausmaß von 5-10 Prozent signifikante, mehr als drei Jahre andauernde Änderungen in der Phänologie des Waldes bewirken. Abholzung reduziert dabei stufenweise den Feuchtigkeitsgehalt und das Grün während der Trockenzeit. Unterberger (2011) untersuchte die Eignung von MODIS Daten für eine Degradationskartierung im Norden der Republik Kongo. Trotz der täglichen Verfügbarkeit von Daten war es nicht möglich, ausreichend Pixel ohne Wolken, Wolkenschatten oder Aerosolbeeinträchtigungen zu extrahieren, um eine Degradationskartierung auf einem ersten groben Level, im Sinne eines *Hot-Spot Mappings*, durchzuführen. Visuell ist selektive Abholzung in den MODIS Daten nach Unterberger (2011) nicht erkennbar. Eine direkte Methode zur Degradationskartierung anhand von grob auflösenden Daten wird in der Literatur nicht vorgeschlagen.

2.4. Verwendung von SAR-Daten

Synthetic Aperture Radar (SAR) ist ein aktives Aufnahmesystem, welches Strahlen im Mikrowellenbereich (3-70 cm) aussendet, und deren zurückgestreute Strahlung misst. Da Mikrowellen atmosphärische Partikel durchdringen, haben SAR-Systeme den Vorteil, unabhängig von der Wolkenbedeckung Daten aufnehmen zu können. Durch diese Eigenschaft stellen SAR-Daten eine gute Ergänzung zu optischen Daten dar, deren Verwendbarkeit im Bereich des Tropenwaldmonitorings durch die häufige Wolkenbedeckung in tropischen Regionen eingeschränkt ist. Dennoch werden SAR-

Daten meist alleine verwendet und nur selten in Ergänzung zu optischen Daten. Ein weiterer Vorteil von SAR ist, dass Radarwellen je nach Polarisierung und Wellenlänge die Vegetation unterschiedlich stark durchdringen können. Längere Wellenlängen (L-/P-Band) dringen dabei tiefer in die Überschirmung ein als kürzere (C-/X-Band). Das rückgestreute Signal enthält somit nützliche Informationen über die Waldstruktur und die oberirdische Biomasse (GOFC-Gold 2011).

In Bezug auf das Tropenwaldmonitoring wird dem voll polarimetrischen L-Band Sensor PALSAR (Phased Array L-Band Synthetic Aperture Radar) des japanischen Satelliten ALOS (Advanced Land Observing Satellite) eine besondere Bedeutung zugeschrieben. Je nach Aufnahmemodus liefert der Sensor Daten in der Auflösung von 10, 20 und 100m. Des Weiteren sind PALSAR-Daten ideal zur Ergänzung optischer Fernerkundungsdaten geeignet. SAR-Sensoren wie TERRA SAR-X und Cosmo SkyMed operieren mit einer räumlichen Auflösung von 5m und weisen somit ein großes Potential für die Kartierung von Holztransportstraßen und damit verbundene Degradationsmuster dar (GOFC-Gold 2011).

Derzeit werden SAR Daten im Bereich des Tropenwaldmonitorings vor allem für grundlegende Landbedeckungsklassifikationen sowie für die Kartierung von Wald und Nicht-Wald Gebieten herangezogen. Kelldorfer et al. (2007) verwendeten ALOS PALSAR-Daten zur Erstellung einer Waldkarte im Xingu Becken (Mato Grosso, Brasilien). Für die Unterscheidung zwischen Wald und nicht-Wald wurde die horizontal-horizontal Polarisation (HH) dem roten Kanal, die horizontal-vertikale Polarisation (HV) den grünen Kanal und die Differenz der beiden Polarisierungen (HH-HV) dem blauen Kanal zugewiesen. Dutra et al. (2009) führten anhand von ALOS PALSAR-Daten eine Landbedeckungsklassifizierung im Tapajós Nationalpark (Pará, Brasilien) durch. Das duale Polarisationsprodukt HH-HV stellte sich als beste Kanalkombination für die Kartierung der Klassen Primärwald, Sekundärwald, bloßer Boden, Landwirtschaft und degradiertes Wald heraus. Während durch Feuer degradierte Flächen anhand der PALSAR-Daten klar erkennbar waren, konnten Wiederbewuchsflächen nicht identifiziert werden. Santos et al. (2010) analysierten das Potential von TERRA SAR-X Daten für die Klassifikation von Waldbedeckung und Landnutzungsklassen aus menschlichen Aktivitäten im südwestlichen Amazonasgebiet Brasiliens. Dabei konnte aufgezeigt werden, dass TERRA SAR-X Daten für die Abgrenzung von Primärwald, degradiertem Wald, Weideland und landwirtschaftlichen Flächen/bloße Böden geeignet sind und die Daten somit ein Potential für die Bewertung und das Monitoring von tropischen Wäldern aufweisen.

Weitere SAR Anwendungen im Bereich des Tropenwaldmonitorings beziehen sich auf direkte Biomasseabschätzungen. Nach Le Toan et al. (1992) ist der dynamische Bereich der Radarrückstrahlungsintensität im P-Band in Wäldern am größten und nimmt mit zunehmender Frequenz (geringeren Wellenlängen) ab. Die Intensität der Rückstrahlung im P-Band korreliert stark mit der Waldbiomasse sowie weiteren physikalischen Bestandsparametern wie Baumalter, Höhe und BHD (Santos et al. 2003). Während die HV-Polarisation von der Volumenstreuung der Bäume dominiert wird, ist die

Rückstrahlung der HH-Polarisation von der Oberflächenstreuung beeinflusst. Die VV-Polarisation hingegen wird sowohl von der Volumen- als auch von der Oberflächenstreuung beeinträchtigt (Le Toan et al. 2011).

Santos et al. (2004) verwendeten Daten eines flugzeuggetragenen SAR-Sensors zur Biomassekartierung im Amazonasgebiet von Pará, Brasilien. Die Rückstreuung der P-Band Wellen an der Oberfläche (HH-Polarisation) wurde zur Erstellung eines digitalen Höhenmodells (DEM) genutzt, während die Informationen über die Überschirmung im X-Band zur Erstellung eines digitalen Oberflächenmodells herangezogen wurden. Die Differenz der beiden Modelle ergibt die Höhe der Vegetation, woraus Santos et al. (2004) die Biomasse des Primär- und Sekundärwaldes ableiteten.

Le Toan et al. (2011) schlagen die Verwendung von polarimetrischen P-Band SAR Systemen zur Berechnung der Biomasse und deren Veränderung vor. Die Rückstrahlung der HV Polarisation steigt in einem Bereich von einigen wenigen $t\ ha^{-1}$ bis zu $300\ t\ ha^{-1}$. Dieser hohe Kontrast zwischen hohem und geringem Biomasseanteil ermöglicht die Erkennung von Störungen im Wald (z.B. durch Rodungen), als auch ein Monitoring des Wiederbewuchses in den ersten Jahren nach der Abholzung. Die Sensitivität der Rückstrahlung geht jedoch mit höheren Biomasseanteilen zurück. Intakte tropische Regenwälder im Amazonas weisen eine Biomasse von $200-400\ t\ ha^{-1}$ auf, wodurch Methoden, welche nur auf der Rückstrahlung beruhen, nach Le Toan et al. (2011) unzulänglich sind. Durch die Messung der Waldhöhe mittels polarimetrischer Interferometrie wird die Biomasseberechnung in der so genannten gesättigten Region verbessert. Der Vorteil von Pol-InSAR Systemen ist die unabhängige Messung von Höhe und Biomasse durch denselben Sensor. Die Messungen ergänzen sich dabei gegenseitig, denn die Sensitivität von Pol-InSAR für Höhe steigt mit der Höhe (und daher mit der Biomasse), während die Sensitivität für die Biomasseintensität mit der Biomasse sinkt. Pol-InSAR Methoden wurden bereits erfolgreich in tropischen Wäldern (Indonesien) getestet und werden auch im Zuge der so genannten *Biomass Mission*, zur vollständigen Kartierung der weltweiten oberirdischen Biomasse, verwendet.

2.5. Alternative Fernerkundungsdaten - LiDAR

Light Detection and Ranging (LiDAR) ist, wie auch die SAR Systeme, ein aktives Aufnahmesystem, welches Laserimpulse aussendet und das zurückgestrahlte Licht aufzeichnet. Der erste Puls enthält Informationen über die Oberfläche der Vegetation, wodurch beispielsweise Baumhöhen abgeleitet werden können, während der letzte Puls Aufschluss über die darunter liegende Topographie gibt. In Bezug auf Waldanwendungen wird mittels LiDAR die Höhe als auch die vertikale Struktur der Vegetation abgeleitet. Aus diesen Parametern kann wiederum das Biomassevolumen und der Kohlenstoffbestand des Waldes errechnet werden. Für die Ableitung von Waldhöhen und oberirdische Biomasse eignen sich Daten des GLAS Sensors (*Geoscience Laser Altimeter System*), welcher sich an Bord des NASA ICESat (*Ice, Cloud and land*

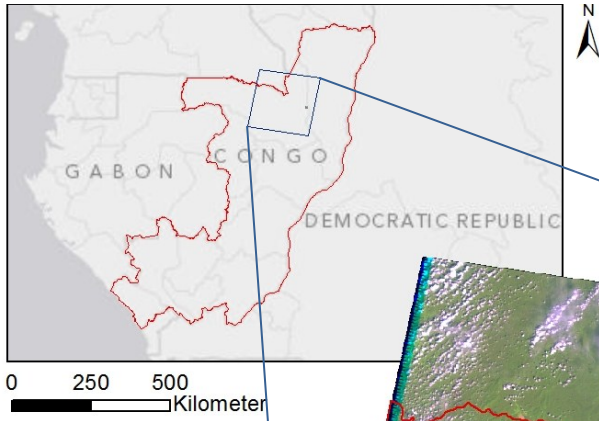
Elevation Satellite) befindet. Anhand dieser Daten wurden Berechnungen der Biomasse und des Kohlenstoffbestandes der gesamten Provinz Quebec, Kanada, durchgeführt. Der Sensor liefert Daten der gesamten Erdoberfläche, ist derzeit jedoch außer Betrieb. Studien über die Biomassebewertung großflächiger Gebiete in tropischen Wäldern gibt es derzeit noch nicht. Untersuchungen mit Daten von flugzeuggetragenen LiDAR-Systemen in tropischen Wäldern zeigen jedoch eine starke Beziehung zwischen der Biomasse (sowie anderen biophysikalischen Eigenschaften) und LiDAR-Daten. LiDAR-Anwendungen gehen somit über die Kartierung von Degradation hinaus und beinhalten Informationen, welche im Kontext des REDD+ Prozesses von Bedeutung sind (GOFC-Gold 2011).

3. Testgebiet und verwendete Satellitenbilddaten

Auf Basis der in den vorangegangenen Kapiteln gewonnenen Erkenntnisse werden im praktischen Teil dieser Masterarbeit die Eignung unterschiedlicher Features zur Degradationskartierung sowie das zeitliche Verhalten von Degradationserscheinungen in einem Testgebiet im Norden der Republik Kongo untersucht. Die Auswahl des Testgebietes wurde im Rahmen des REDD Extension Projektes getroffen, da in diesem Gebiet Degradation in Form von selektiver Abholzung stattfindet und eine ausreichende Datenverfügbarkeit gegeben ist. Einführend in den praktischen Teil dieser Arbeit erfolgt in diesem Kapitel eine kurze Beschreibung des Testgebietes (3.1) und der verwendeten Satellitenbilddaten (3.2).

3.1. Testgebiet

Das Testgebiet, anhand dessen die verschiedenen Features zur Degradationskartierung berechnet und untersucht werden, befindet sich im Norden der Republik Kongo innerhalb der beiden Provinzen *Sangha* und *Likouala*. Das Gebiet grenzt im Norden an Kamerun und ist teilweise von großen Sumpfbereichen geprägt. Für einen kleinen Ausschnitt des Testgebietes (4,5 x 9 km) wurden Referenzdaten aus einer VHR Szene generiert, welche als Referenz sowie zur Validierung der Ergebnisse herangezogen werden. Die folgende Abbildung (Abb. 3) zeigt die Lage des Testgebietes sowie der VHR Szene, innerhalb welcher die Referenzdaten vorliegen.




-  Republik Kongo
-  Abdeckung Landsat p182 r 059
-  Abdeckung Ikonos Szene

Landsat 13.12.2002




RGB

-  Red: Layer_5
-  Green: Layer_4
-  Blue: Layer_3



Ikonos 27.6.2002

RGB

-  Red: Layer_4
-  Green: Layer_3
-  Blue: Layer_2




Abb. 3: Lage des Testgebietes

Quelle: eigene Bearbeitung

Die tropischen Regenwälder im Norden der Republik Kongo nehmen 46 Prozent der Fläche des Landes ein und sind entweder im privaten oder staatlichen Besitz, wobei die staatlichen Wälder in *Forest Management Units* und zum Teil weiter in *Forest Exploitation Units* untergliedert sind. Für letztere werden Konzessionen an multinationale Unternehmen für einen Zeitraum von 15 – 25 Jahren vergeben. Abgeholzt werden lediglich jene Baumarten, welche lukrativ für den Export sind. Im Norden der Republik Kongo ist *Sapelli* das wichtigste Exportholz, welches knapp unter 80 Prozent der Holzproduktion in diesem Gebiet ausmacht. Auch im Bereich des Testgebietes wurden Konzessionen für die Abholzung vergeben, wobei das Untersuchungsgebiet unterschiedlich stark von selektiver Abholzung betroffen ist (Forests Monitor 2012). Unbefestigte Straßen gelten als Indiz für selektive Abholzung, da diese für den Abtransport des Holzes vonnöten sind. Darüber hinaus werden auch Flüsse als Transportwege genutzt.

Durch die geographische Lage am Äquator herrscht ein ganzjährig tropisches Klima mit konstant hohen Temperaturen im Bereich von 25 – 35°C, hohen Niederschlagsmengen (1400 – 2000 mm pro Jahr) sowie einer hohen Luftfeuchtigkeit. Der Jahresgang wird von zwei Hauptregenzeiten geprägt, eine von Jänner bis Mitte Mai sowie eine weitere von Oktober bis Mitte Dezember. Im Norden der Republik Kongo gibt es eine längere Trockenperiode von Dezember bis Februar, die meisten Niederschläge fallen hier zwischen März und Juni sowie zwischen August und November (Transafrika 2012).

Folglich ist in diesen Monaten die Wolkenbedeckung häufiger, wodurch auch die Verfügbarkeit von geeigneten, wolkenfreien optischen Satellitenbilddaten eingeschränkt ist.

3.2. Verwendete Satellitenbilddaten

Ikonos

Um an Bodenverifikationsdaten (*ground-truth*) zu gelangen, wird eine Ikonoszene mit einer Ausdehnung von 10,3 x 9 km, aufgenommen am 27. Juni 2002, herangezogen und visuell interpretiert. *Ikonos* liefert hoch auflösende Daten in einem panchromatischen Band mit einer Auflösung von 82cm im Nadir (1m off-Nadir) und vier multispektralen Bändern (blau, grün, rot und nahes Infrarot) mit einer Auflösung von 3,2m im Nadir (4m off-Nadir). Die Aufnahmen der beiden Sensoren können mittels Bildfusionierung (*Pansharpening*) zu einem Farbbild mit 1m Auflösung fusioniert werden (GeoEye 2012). Weitere Charakteristika von Ikonos sind in folgender Tabelle aufgelistet:

Tab. 5: Ikonos Sensorcharakteristika

Betrieb	seit 09/1999
Räumliche Auflösung	0,82 / 3,2 m (im Nadir), 1 / 4m (off-Nadir)
Spektrale Bänder	0,445 – 0,516 μm (blau) 0,506– 0,595 μm (grün) 0,632–0,698 μm (rot) 0,757–0,853 μm (nahes Infrarot)
Panchromatischer Kanal	0,526 – 0,929 μm
Streifenbreite	11,3 km im Nadir, 13,8 km off-Nadir
Off-Nadir Aufnahme	bis zu 60 Grad
Bahnneigung	98,1 Grad (sonnensynchron)
Flughöhe	681 km

Quelle: GeoEye 2012, Satellite Imaging Corporation 2012

Landsat

Für die Berechnung der verschiedenen Features wird eine Landsat 7 Enhanced Thematic Mapper Plus (ETM+) Szene, aufgenommen am 13.12.2002, herangezogen, da diese den kürzesten zeitlichen Abstand zur VHR Szene ohne Wolkenbedeckung in diesem Gebiet aufweist und somit die zeitlichen Veränderungen möglichst gering gehalten werden können. Anhand einer weiteren Landsat 7 ETM+ Szene im Gebiet von Kamerun (*path* 184, *row* 058), aufgenommen am 18.1.2011, wurde die räumliche Übertragung von *Endmemberwerten* für die SMA getestet.

Für die multitemporale Betrachtung der Degradationsgebiete im Zeitraum von 1990 bis 2010 wurden neben Landsat 7 ETM+ auch Landsat 5 Thematic Mapper (TM) sowie Landsat 4 TM Daten herangezogen, wobei sämtliche Daten im *path* 182, *row* 59 liegen.

Die Aufnahmezeitpunkte sowie der aufnehmende Sensor der für die multitemporale Analyse verwendeten Daten sind aus folgender Tabelle zu entnehmen:

Tab. 6: Aufnahmezeitpunkte der Landsatdaten

Sensor	Aufnahmedatum
Landsat 4 TM	26.11.1990
Landsat 5 TM	16.01.1995
Landsat 7 ETM+	03.11.1999
Landsat 7 ETM+	18.09.2000
Landsat 7 ETM+	09.02.2001
Landsat 7 ETM+	16.05.2001
Landsat 7 ETM+	08.11.2001
Landsat 7 ETM+	13.12.2002
Landsat 7 ETM+	29.12.2002
Landsat 7 ETM+	15.02.2003
Landsat 7 ETM+	25.07.2003
Landsat 7 ETM+	14.11.2003
Landsat 7 ETM+	18.02.2004
Landsat 7 ETM+	03.01.2005
Landsat 7 ETM+	07.02.2006
Landsat 7 ETM+	15.06.2006
Landsat 7 ETM+	18.06.2007
Landsat 7 ETM+	05.08.2007
Landsat 7 ETM+	27.12.2007
Landsat 7 ETM+	29.02.2008
Landsat 7 ETM+	14.01.2009
Landsat 7 ETM+	18.02.2010

Die Landsatsensoren TM als auch ETM+ nehmen jeweils in sechs multispektralen Kanälen (blau, grün, rot, nahes Infrarot, mittleres Infrarot in Band 5 und 7) mit einer Auflösung von 30m sowie einem Thermalkanal mit einer Auflösung von 120m (TM) bzw. 60m ETM+) auf. Landsat 7 Daten verfügen darüber hinaus über einen panchromatischen Kanal mit einer Auflösung von 15m (NASA 2012). Die genauen Spektralbereiche der Bänder sowie weitere Sensorcharakteristika der Landsatsensoren sind in Tab. 7 zusammengefasst.

Tab. 7: Landsat Sensorcharakteristika

	Landsat 4 TM	Landsat 5 TM	Landsat 7 ETM+
Betrieb	07/1982 bis 12/1993	seit 03/1984	seit 04/1999
Räumliche Auflösung	30 Meter (120m thermal)	30 Meter (120m thermal)	30 Meter (60m thermal, 15m panchromatisch)
Spektrale Bänder	(1) 0,45 – 0,52 µm (blau) (2) 0,52 – 0,60 µm (grün) (3) 0,63 – 0,69 µm (rot) (4) 0,76 – 0,90 µm (NIR) (5) 1,55 – 1,75 µm (MIR) (7) 2,08 – 2,35 µm (MIR)	(1) 0,45 – 0,52 µm (blau) (2) 0,52 – 0,60 µm (grün) (3) 0,63 – 0,69 µm (rot) (4) 0,76 – 0,90 µm (NIR) (5) 1,55 – 1,75 µm (MIR) (7) 2,08 – 2,35 µm (MIR)	(1) 0,45 – 0,52 µm (blau) (2) 0,52 – 0,60 µm (grün) (3) 0,63 – 0,69 µm (rot) (4) 0,77 – 0,90 µm (NIR) (5) 1,55 – 1,75 µm (MIR) (7) 2,08 – 2,35 µm (MIR)
Thermalkanal	(6) 10,4 – 12,5 µm	(6) 10,4 – 12,5 µm	(6) 10,4 – 12,5 µm
Panchromatischer Kanal			(8) 0,52 - 0,90 µm
Streifenbreite	185 km	185 km	185 km
Bahnneigung	98,2 Grad (sonnensynchron)	98,2 Grad (sonnensynchron)	98,2 Grad (sonnensynchron)
Flughöhe	705 km	705 km	705 km
Wiederholrate	16 Tage	16 Tage	16 Tage

Quelle: USGS 2012

Zu Landsat 7 ist hinzuzufügen, dass durch einen Ausfall des *Scan Line Correctors* (SLC) im Mai 2003 die Daten nur mehr im *SLC-off* Modus aufgenommen werden, wodurch die Szenen mit Ausnahme des mittleren Bildstreifens streifenartige Datenlücken aufweisen (Satellite Imaging Corporation 2012). Dieses Problem kann durch die Mosaikierung von zwei oder mehreren Bildern desselben Jahres ausgeglichen werden, da sich die Position der Datenlücken in den verschiedenen Aufnahmezeitpunkten ändert.

4. Methoden und Arbeitsschritte

Um das am besten geeignete Feature zur Kartierung von Degradation im Sinne der Detektion von „frischer Degradation“ sowie der Regeneration von Vegetation (Wiederbewuchs) zu eruieren, werden im Rahmen dieser Arbeit die aus Landsatdaten berechneten Features mit den visuell interpretierten Referenzdaten korreliert. In einem ersten Schritt werden dazu Referenzdaten aus einer VHR Szene mittels visueller Interpretation generiert (4.1). Parallel dazu werden in der Literatur vorgeschlagene Features (siehe Kapitel 2.3) für die Landsatdaten berechnet (4.2). Anschließend werden die Features unter Berücksichtigung einer gemeinsamen Analyseeinheit mit den Referenzdaten korreliert (4.3). Daraus resultierend wird jenes Feature mit der höchsten Korrelation für eine monotemporale Degradationskartierung auf Basis von Schwellwerten herangezogen (4.4). Des Weiteren wird die Möglichkeit der räumlichen und zeitlichen Übertragung von *Endmemberwerten* aus der spektralen Endmischungsanalyse im Hinblick auf ein flächendeckendes Monitoring überprüft (4.5). Darüber hinaus erfolgt eine multitemporale Analyse der Degradationserscheinungen von vegetationslosen Lücken und Wiederbewuchsflächen (4.6).

4.1. Generierung von Referenzdaten

Um die Eignung der unterschiedlichen Features zur Erkennung von Degradation und Wiederbewuchs feststellen zu können, werden Referenzdaten benötigt. Da keine Waldinventurdaten im Untersuchungsgebiet vorliegen, werden die Bodenverifikationsdaten mittels visueller Interpretation einer hochauflösenden Ikonosszene gewonnen. Bei der Auswahl der VHR Szene ist auf die klare Erkennbarkeit von Degradationserscheinungen aufgrund selektiver Abholzung, sowie auf die Bildqualität und eine möglichst geringe Wolkenbedeckung zu achten. Da anschließend auch eine multitemporale Analyse auf diese Daten aufgebaut wird, ist ein zeitlich länger zurück liegender Aufnahmezeitpunkt Voraussetzung. Basierend auf diesen Kriterien wurde eine Ikonosszene, aufgenommen am 27. Juni 2002, ausgewählt (siehe Abb. 4). Die Szene weist eine Auflösung von 1m im panchromatischen Kanal und 4m in den multispektralen Kanälen (blau, grün, rot, NIR) auf. Während im nördlichen Bildbereich sichtbare Zeichen von selektiver Abholzung erkennbar sind, sind der westliche sowie der südwestliche Bereich der Szene von Sumpf und Sumpfwäldern geprägt. Da diese nur schwer zugänglich sind, findet in diesen Gebieten in der Regel keine Abholzung statt.




Abb. 4: Ikonosszene, aufgenommen am 27.6.2002 (RGB 432)

4.1.1. Datenvorverarbeitung

Zur besseren visuellen Interpretierbarkeit der Szene wurde eine Bildfusionierung (*Pansharpening*) der multispektralen Kanäle mit dem panchromatischen Kanal mittels Gram-Schmidt Methode durchgeführt, wodurch eine räumliche Auflösung der Daten von 1m erreicht wird (vgl. Kapitel 3.2). Weiters ist für eine Korrelation der Referenzdaten mit den Landsatdaten eine genaue geometrische Anpassung der Inputdaten notwendig, welche mittels einer Polynomialtransformation erster Ordnung durchgeführt wurde. Da die im Rahmen dieser Arbeit verwendeten Landsatdaten geometrisch sehr gut übereinstimmen, wurde die höher auflösende Ikonosszene an die Landsatszene vom 13.12.2002 angepasst.

4.1.2. Digitalisierung

Nach der Datenvorverarbeitung erfolgte die visuelle Interpretation zur Gewinnung von Bodenverifikationsdaten. Diese wurde anhand einer manuellen Digitalisierung im

Maßstab 1:1.500 durchgeführt. Da der Zeitaufwand für eine Digitalisierung sehr hoch ist, wurde diese auf den nördlichen Bereich der Szene mit einer Ausdehnung von 4,5 x 9 km beschränkt. Die Wahl dieses Ausschnittes kann damit begründet werden, dass sich in diesem Gebiet die meisten sichtbaren Aktivitäten von Degradation durch selektive Abholzung befinden. Ein Ausschnitt aus diesem Bereich (Abb. 5) zeigt die für selektive Abholzung typische Zusammensetzung aus intakten Waldbereichen, Wiederbewuchs, vegetationslosen Lücken im Wald, Straßen und Holzlagerplätzen. Hinzu kommen noch Sumpf und Sumpfwaldbereiche, welche für den Norden der Republik Kongo charakteristisch sind.




Abb. 5: Charakteristische Zusammensetzung selektiver Abholzungsgebiete

Basierend auf diesem Wissen wurden bei der Digitalisierung folgende Klassen unterschieden:

- überschirmte Bereiche (Bäume und Baumgruppen),
- Wiederbewuchs mit niedrigen Pflanzen,
- vegetationslose Lücken (Straßen, Holzplätze und Rückegassen),
- Sumpf und Sumpfwälder,
- Wolken und
- Wolkenschatten

Schattenflächen aufgrund des Schattenwurfes der Vegetation wurden den darunter liegenden Klassen zugewiesen, da diese in der Regel klar ersichtlich waren. Für eine bessere Unterscheidung von Wiederbewuchs und Wald wurde die Kanalkombination 4,3,2, entsprechend RGB verwendet. Die minimale Kartierungseinheit wurde mit 5 x 5m oder 25 m² festgelegt. Die Genauigkeit der visuellen Interpretation ist bei der

Verwendung der Daten als Referenz besonders wichtig, da die gesamte Analyse auf diese Daten aufbaut und in der Folge auch die Qualität der Ergebnisse sowie die Erkenntnisse von dieser abhängen. Die folgenden Abbildungen (Abb. 6) zeigen jeweils links den originalen Ausschnitt aus der Ikonosszene und rechts die Digitalisierung, wobei überschirmte Bereiche in dunkelgrün, Wiederbewuchsflächen in hellgrün, Lücken in rot und Sumpfbereiche in blau dargestellt werden.




Abb. 6: Beispiele aus der Digitalisierung der Ikonosszene zur Referenz und Validierung
Links: Originalausschnitt der Ikonosszene (RGB 4,3,2), rechts: Digitalisierung mit den Klassen überschirmte Bereiche (in dunkelgrün), Wiederbewuchs (in hellgrün), Sumpf und Sumpfwälder (blau) und Lücken (rot)

4.1.3. Festlegung der Analyseeinheit

Um die digitalisierten Referenzdaten mit den Features aus den Landsatdaten verschneiden zu können, ist eine gemeinsame räumliche Analyseeinheit notwendig. Dabei muss sowohl die geometrische Auflösung der Features als auch der VHR Szene (Referenz) sowie die geometrische Genauigkeit der Daten berücksichtigt werden. Die spezifizierte Analyseeinheit muss deutlich größer sein, als der Fehler, der durch etwaige geometrische Verschiebungen zwischen den VHR- und den Landsatdaten entsteht. Trotz der geometrischen Anpassung der Daten wurde ein geometrischer Fehler von 15 - 30 m angenommen. Aus diesem Grund wurde die Analyseeinheit mit einer Größe von 90 x 90 m (3 x 3 Landsatpixel á 30m) festgelegt.

In weiterer Folge wurde ein Analyseraster mit einer Zellgröße von 90m, entsprechend der Analyseeinheit, in der Ausdehnung der Ikonosszene generiert. Das Raster wurde auf die Landsatpixel angepasst, um den Informationsgehalt der Features verlässlich weitergeben zu können. Im nächsten Schritt wurden nun für jede Zelle des Analyserasters die Flächenanteile der jeweiligen Klassen aus der Digitalisierung berechnet. Die verlässliche Weitergabe des Informationsgehaltes stellt in diesem Zusammenhang kein Problem dar, da die digitalisierten Referenzdaten im Vektorformat vorliegen.

4.1.4. Erweiterung der Referenz um intakte Waldbereiche

Aufgrund der enormen Degradation im digitalisierten Bildbereich besteht keine Einheit des Analyserasters zu 100 Prozent aus intaktem Wald. Da Bereiche mit intaktem Wald für Signaturanalysen in Bezug auf die Degradationskartierung unumgänglich sind, wurden aus dem südlichen, nicht digitalisierten Bildbereich, visuell jene Zellen des Analyserasters selektiert, welche zu 100 Prozent intakten Wald beinhalten (Abb. 7). Diese Einheiten wurden zu den Referenzdaten hinzugefügt.




Abb. 7: Beispiele für intakte Waldbereiche (90m Einheiten)

Die folgende Abbildung zeigt nun jene Analyserasterzellen, für welche Referenzdaten vorliegen. Die weiß gerahmten Zellen stellen die aus der Digitalisierung resultierenden Referenzdaten dar, während die gelb umrandeten Zellen intakte Waldbereiche markieren. Rasterzellen, welche Wolken und/oder Wolkenschattenbereiche beinhalten,

wurden ausgespart, da in diesen Bereichen keine Referenzinformation interpretiert werden kann. Darüber hinaus wurden auch Sumpfgebiete ausgegrenzt, da diese in der Regel nicht von Abholzung betroffen sind und aufgrund ihrer spektralen Eigenschaften oft zu Fehlklassifikationen führen.



Abb. 8: Vorliegende Referenzzellen

4.1.5. Visuelle Interpretation weiterer Parameter mittels Beispielschlüssel

Abschließend wurden die vorliegenden Referenzdaten des Analyserasters durch eine visuelle Interpretation der Parameter Entwicklungsstufe der Degradation bzw. des Wiederbewuchses, Kronendurchmesser und Erscheinungsbild der Bäume, vervollständigt. Die daraus resultierende Mehrinformation kann im Falle von Unklarheiten bei der Korrelation der Daten sowie im Zuge der multitemporalen Analyse unterstützend miteinbezogen werden. Erleichtert wird die visuelle Interpretation durch einen Beispielschlüssel (siehe Abb. 9, Abb. 10 und Abb. 11). Dieser basiert auf Beispielen der ersten Interpretationen mit gemessenen Werten (Messung des Durchmessers bzw. der Fläche im VHR Bild mittels *Arc Map Measurement Tool* und Berechnung des Anteils

am Gesamtvorkommen) für die jeweiligen Kategorien. Für die weiteren Zellen werden diese Werte mittels visueller Interpretation geschätzt. Die Parameter werden dabei nach der mehrheitlich vorkommenden Kategorie pro Analyseeinheit bestimmt, die vorkommenden Erscheinungsbilder der Bäume werden in 20 Prozent Stufen angegeben.

Bei der Entwicklungsstufe der Degradation bzw. des Wiederbewuchses wird (sofern diese bestimmbar ist) zwischen

- frischer Degradation,
- niedrigem/aktuellem Wiederbewuchs,
- höherem/älterem Wiederbewuchs und
- Sekundärwald

unterschieden, wobei die dominierende Entwicklungsstufe pro Analyseeinheit entscheidend ist.

Entwicklungsstufe der Degradation bzw. des Wiederbewuchses:

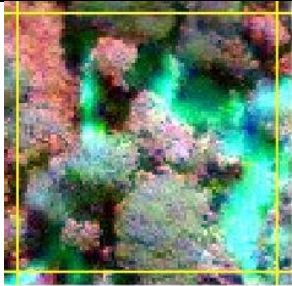

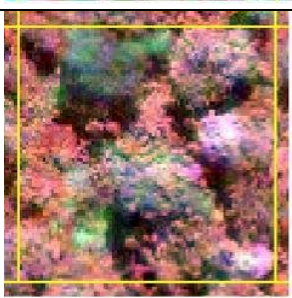
	<ul style="list-style-type: none"> • Frische Degradation • mittelgroße Kronen, • 40 % rote Bäume, 0 % weiße Bäume, 60 % graue Bäume 		<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • kleine Kronen, • 60 % rote Bäume, 0 % weiße Bäume, 40 % graue Bäume
	<ul style="list-style-type: none"> • höherer/älterer Wiederbewuchs • mittelgroße Kronen, • 80 % rote Bäume, 0 % weiße Bäume, 20 % graue Bäume 		

Abb. 9: Beispielschlüssel zur Interpretation der Entwicklungsstufe von Degradation/Wiederbewuchs

Darüber hinaus kann auch der Kronendurchmesser der Bäume Aufschluss darüber geben, ob es sich um einen Primär- oder Sekundärwald handelt. Pro Analyseeinheit wird demzufolge der häufigste Kronendurchmesser angegeben, wobei zwischen

- kleinen Kronen: Durchmesser < 10m,
- mittelgroßen Kronen: Durchmesser 10-25m und
- großen Kronen: Durchmesser > 25m

differenziert wird.

Häufigster Kronendurchmesser:

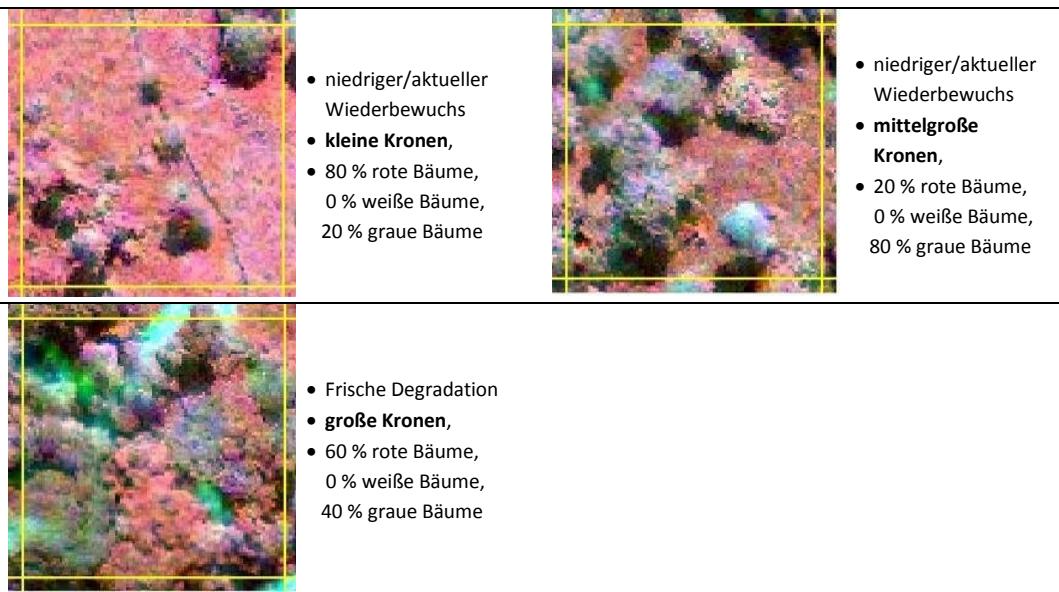



Abb. 10: Beispielschlüssel zur Interpretation des häufigsten Kronendurchmessers

Um eine eventuelle Beeinflussung des spektralen Signals durch die unterschiedlichen Erscheinungsbilder der Bäume feststellen zu können, wird das Erscheinungsbild nach der spektralen Reflexion in der Bandkombination RGB 432 in 20 Prozent Stufen in

- „rote“ Bäume,
- „weiße“ Bäume und
- „graue“ Bäume

untergliedert. Grüne Vegetation reflektiert im NIR sehr stark und erscheint daher rot. Rot erscheinende Bäume können andere Baumarten darstellen als graue Bäume. Des Weiteren könnte das graue Erscheinungsbild von Bäumen auch auf einen besonderen phänologischen Zustand rückführbar sein. Weiß erscheinende Bäume haben zum Zeitpunkt der Aufnahme kein Laub. Dies könnte sowohl auf die natürliche Phänologie, als auch auf abgestorbene Bäume hinweisen.

Dominierendes Erscheinungsbild der Bäume:



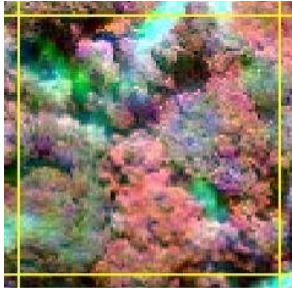
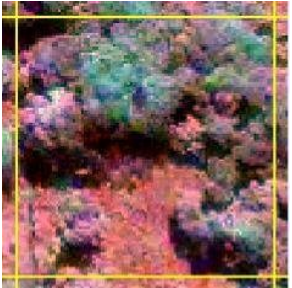
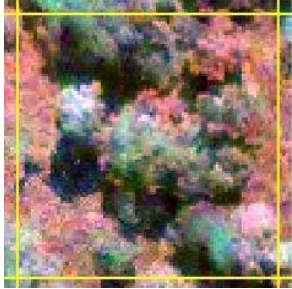
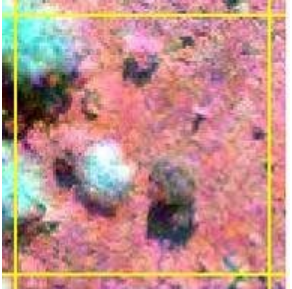
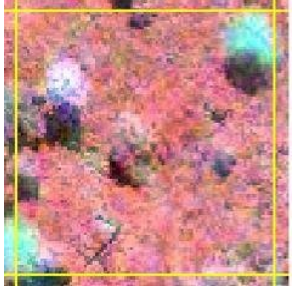
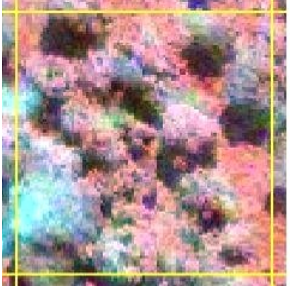
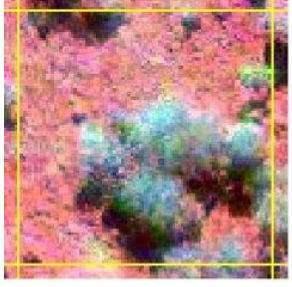
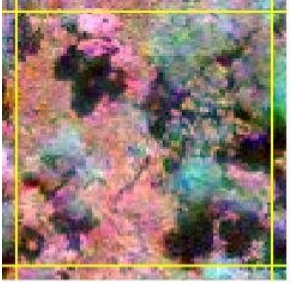
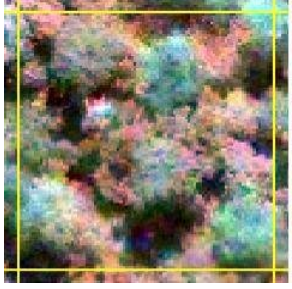
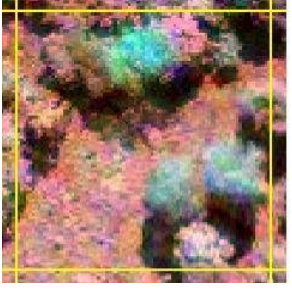
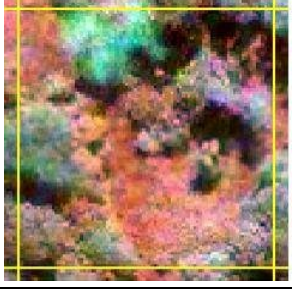
	<ul style="list-style-type: none"> • Frische Degradation • große Kronen, • 60 % rote Bäume, 0 % weiße Bäume, 40 % graue Bäume 		<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 40 % rote Bäume, 0 % weiße Bäume, 60 % graue Bäume
	<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 20 % rote Bäume, 0 % weiße Bäume, 80 % graue Bäume 		<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 20 % rote Bäume, 60 % weiße Bäume, 20 % graue Bäume
	<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 60 % rote Bäume, 40 % weiße Bäume, 0 % graue Bäume 		<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 60 % rote Bäume, 20 % weiße Bäume, 0 % graue Bäume
	<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 0 % rote Bäume, 0 % weiße Bäume, 100 % graue Bäume 		<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 20 % rote Bäume, 0 % weiße Bäume, 80 % graue Bäume
	<ul style="list-style-type: none"> • niedrige/aktueller Wiederbewuchs • mittelgroße Kronen, • 40 % rote Bäume, 0 % weiße Bäume, 60 % graue Bäume 		<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 60 % rote Bäume, 0 % weiße Bäume, 40 % graue Bäume
	<ul style="list-style-type: none"> • niedriger/aktueller Wiederbewuchs • mittelgroße Kronen, • 60 % rote Bäume, 20 % weiße Bäume, 20 % graue Bäume 		

Abb. 11: Beispielschlüssel zur Interpretation des dominierenden Erscheinungsbildes der Bäume

4.2. Generierung von Features

Die Extraktion von Features aus den Landsatdaten soll die Erkennung von Degradation in Form von vegetationslosen Lücken, Rückegassen, Holzlagerplätzen und Straßen als auch die Detektion des Wiederbewuchses auf ehemaligen Degradationsflächen erleichtern. Letztere ist von Bedeutung, um zeitlich länger zurückliegende Degradationsflächen zu identifizieren, da das Signal von Wiederbewuchs länger präsent ist, als jenes der Degradation von vegetationslosem Boden.

Die Auswahl der Features erfolgte auf Basis der vorangegangenen Literaturrecherche (siehe Kapitel 2) sowie auf Grund des Informationsgehaltes in den jeweiligen spektralen Bändern. Analysiert wurden die Features vorerst anhand der Landsatzszenen vom 13.12.2002, da diese Szene, wie bereits erwähnt, den zeitlich kürzesten Abstand zur VHR Szene bei wolkenfreien Bedingungen über dem VHR Gebiet und somit über den Referenzdaten aufweist. Neben der Betrachtung der Reflexion der einzelnen Landsatbänder (4.2.1), wurden Ratio-Indizes, Vegetations- und Infrarotindizes, Tasseled Cap (4.2.2) sowie die spektrale Entmischungsanalyse (4.2.3) als Features herangezogen. Kontextanalysen sind nicht Gegenstand der vorliegenden Arbeit, könnten jedoch als Verfeinerung des Ergebnisses der Degradationskartierung herangezogen werden. Klassifikationen, welche auf die Originalbänder angewandt werden, wurden ebenso vernachlässigt, da diese in der Literatur kaum verwendet werden.

Da die Features für die gesamte Landsatzszenen berechnet werden und diese zum Teil wolkenbedeckt ist, wurden im Vorfeld der Featureberechnungen Wolken- als auch Wolkenschattenbereiche ausmaskiert. Somit können aufwändige manuelle Korrekturen der Ergebnisse bzw. Fehlklassifikationen vermieden werden. Die Klassifizierung der Wolken und Wolkenschatten erfolgte anhand der RSG Software, welche von *Joanneum Research* (JR) entwickelt wurde.

4.2.1. Reflexion

Die Reflexion der einzelnen multispektralen Landsatbänder stellt das einfachste Feature zur Kartierung von Degradation dar und ist zugleich Input für sämtliche weitere Featureberechnungen. Neben der Einbeziehung der einzelnen Bänder wurden auch Kombinationen der unterschiedlichen Bänder getestet, da sich diese im Zuge der Erkennung von Degradation und Wiederbewuchs ergänzen können. Um die Auswahl der Features bzw. der Bänder für die weiteren Features (Indizes und SMA) zu erleichtern, erfolgte eine visuelle Analyse der einzelnen spektralen Bänder. Bänder mit hohem Informationsgehalt in Bezug auf die Unterscheidung von Degradation und Wiederbewuchs wurden in weiterer Folge bei der Berechnung der Features bevorzugt (vgl. Kapitel 4.2.2 und 4.2.3).

4.2.2. Indizes

Anhand der Originalbänder erfolgte die Berechnung von Ratio-Indizes, Vegetations- und Infrarotindizes sowie der Tasseled Cap Transformation.

Ratio-Indizes

Zusätzlich zu dem in der Literatur vorgeschlagenen Ratio-Vegetationsindex Band 4/Band 3, wurden im Rahmen dieser Arbeit auch Ratios zwischen den nahen und mittleren Infrarotbändern in Betracht gezogen, da diese unempfindlicher gegenüber atmosphärischen Einflüssen sind. Ein weiterer Vorteil der mittleren Infrarotbänder ist, dass die Information in diesen Bändern mit jener des roten Kanals (Band 3) korreliert (vgl. Kapitel 2.3.2.2 und Matricardi et al. 2010). Darüber hinaus ergab die visuelle Analyse der einzelnen spektralen Bänder (siehe Kapitel 5.1) einen hohen Informationsgehalt in den Bändern 3, 4, 5 und 7. Daher wurden folgende Ratio-Indizes als Features in Betracht gezogen:

- Band 4/Band 3
- Band 4/Band 5
- Band 4/Band 7
- Band 5/Band 4
- Band 7/Band 4

Vegetations- und Infrarotindizes

In Hinblick auf die Verwendung von Vegetations- und Infrarotindizes wurden die in der Literatur vorgeschlagenen Vegetationsindizes

- NDVI,
- SAVI,
- GEMI

sowie die gegenüber atmosphärischen Einflüssen stabileren Infrarotindizes

- NDII 5 (Band 4, Band 5),
- NDII 7 (Band 4, Band 7),
- mSAVI 5 (Band 4, Band 5),
- mSAVI 7 (Band 4, Band 7)

berechnet. Für die Berechnung der jeweiligen Indizes wird an dieser Stelle auf Kapitel 2.3.2.2 verwiesen. Die verwendeten Bänder in den Indizes entsprechen nach Kapitel 5.1 jenen mit hohem Informationsgehalt hinsichtlich der Erkennbarkeit von Degradation und Wiederbewuchs.

Tasseled Cap

Weiters wurde auch eine Tasseled Cap Transformation (vgl. Kapitel 2.3.2.3) auf die Landsatzenge angewendet. Für eine Degradationskartierung sind jedoch nur die ersten drei Bänder (*brightness*, *greenness* und *wetness*) relevant, da die weiteren drei Bänder zu wenig Informationsgehalt aufweisen.

4.2.3. SMA Features

Die *Spectral Mixture Analysis* (SMA) ist der Literatur zufolge das vielversprechendste Feature zur Kartierung von Degradation und Wiederbewuchs (vgl. Kapitel 2.1). Das Prinzip der SMA beruht auf der Berechnung der Anteile der einzelnen Bedeckungsklassen (*Endmember*) für jedes Pixel. Diese umfassen vegetationslosen Boden, grüne Vegetation (GV) und Schatten. In Kapitel 2.3.2.4 wurde der generelle Ablauf der SMA sowie deren Berechnung erläutert. Im Rahmen dieser Arbeit wurde eine SMA auf Basis einer manuellen Bestimmung der *Endmember* aus den Bilddaten (4.2.3.1), sowie ein im Rahmen des REDD Projektes implementierter Workflow (4.2.3.2), welcher mittels *Pixel Purity Index* (PPI) eine automatische Auswahl der *Endmember* trifft, zur Berechnung von Features herangezogen. Darüber hinaus wurde aus den *Endmemberfraktionen* der mNDFI berechnet (4.2.3.3), welcher nach Souza et al. (2005a) Degradationsbereiche noch besser hervorhebt.

4.2.3.1. Spectral Unmixing mit manueller Endmember Selektion

Die Anwendung des *Spectral Unmixing* mit manueller *Endmember* Selektion erfordert folgenden Ablauf:

1. Verringerung der Datendimension

Da bei der manuellen *Endmember* Auswahl *Endmember* im zweidimensionalen Raum einfacher zu bestimmen sind als im mehrdimensionalen Raum, wurde eine Verringerung der Datendimension der Landsatdaten durchgeführt. Diese erfolgte mittels Auswahl zweier Bänder mit hohem Informationsgehalt bzw. durch eine Hauptkomponentenanalyse unterschiedlicher Bandkombinationen im mehrdimensionalen Fall. Die Auswahl der entsprechenden Bänder beruht auf deren Informationsgehalt, welcher im Rahmen der visuellen Analyse der einzelnen spektralen Bänder festgestellt wurde (siehe Kapitel 5.1). Im Hinblick auf diese Ergebnisse wurden als Input für die SMA die folgenden vier Bandkombinationen getestet:

- Band 3 und Band 4 aufgrund deren hohen Informationsgehaltes,
- Band 4 und Band 5, um atmosphärische Einflüsse von Band 3 durch die Verwendung von Band 5 auszugleichen,
- die ersten beiden Hauptkomponenten aus der Bandkombination 2, 3 und 4, da diese laut Literatur (Haas 2009) gute Ergebnisse erzielten sowie
- die ersten beiden Hauptkomponenten aus der Bandkombination 3, 4, 5 und 7, da diese Bänder die meisten Informationen enthalten.

2. Endmember Selektion

Die Selektion der *Endmember* erfolgt auf Basis der Bilddaten unter zu Hilfenahme des spektralen Merkmalsraumes, der von den zwei spektralen Bändern bzw. von den beiden Hauptkomponenten aufgespannt wird. In einem ersten Schritt werden in der Landsatzene potentielle *Endmemberpixel* gesucht. Der *Endmember* Boden wurde dabei mit unbefestigten Straßen, grüne Vegetation (GV) mit Wiederbewuchs oder

aufgegebenen Straßen und Schatten mit topographischen Schattenbereichen assoziiert. Anschließend werden die spektralen Werte der Band- bzw. der Hauptkomponentenpaare, welche für die Berechnung der SMA herangezogen werden, im dazugehörigen spektralen Merkmalsraum visuell überprüft. Die Punktwolke der Daten im spektralen Merkmalsraum bildet dabei optimalerweise eine dreiecksähnliche Form. Jene *Endmemberpixel*, welche sich in den Eckpunkten der Punktwolke befinden, repräsentieren dabei die idealen *Endmember* mit dem maximalen Anteil der jeweiligen Bedeckungsklasse (siehe Abb. 12). Diese werden zur Berechnung der spektralen Entmischung herangezogen. Umgesetzt wird dieser Schritt mithilfe der Signaturanalyse und dem *Feature Space Image* in ERDAS Imagine 2011.




Abb. 12: Spektraler Merkmalsraum von Band 3 und 4 der Landsat-Szene vom 13.12.2002

3. Berechnung der Anteilbilder (*fraction images*) durch den SMA Algorithmus

Die spektrale Entmischung und somit die Berechnung der Anteilbilder (*fraction images*) erfolgt durch den in IMPACT (Image Processing and Classification Toolkit, Softwarebibliothek entwickelt von JR) implementierten *Spectral Unmixing* Algorithmus. Als Input werden zwei Bänder bzw. die ersten beiden Hauptkomponenten der PCA herangezogen und die *Endmemberwerte* eingegeben. Die Anzahl der *Endmember* muss dabei der Anzahl der Bänder + 1 entsprechen. Für die drei *Endmember* Boden, GV und Schatten werden daher zwei Inputbänder benötigt, welche sich bereits aus der Verringerung der Dimensionen zur Auswahl der *Endmember* ergeben. Der Algorithmus beruht auf linearer Algebra zur Lösung des spektralen Mischungsmodells. Die zugrunde liegenden Gleichungen zur Berechnung der *Endmemberfraktionen* C für jeden Pixel lauten

$$\vec{a}_{GV} C_{GV} + \vec{a}_{Boden} C_{Boden} + \vec{a}_{Schatten} C_{Schatten} = \vec{b}$$

$$C_{GV} + C_{Boden} + C_{Schatten} = 1$$

wobei \vec{a} den *Endmembervektor* und \vec{b} den Pixelvektor des ersten und des zweiten Inputbandes darstellt. Die Summe der Fraktionen C wird für jeden Pixel auf 1

beschränkt. Im finalen Schritt werden die Fraktionswerte auf Prozentanteile umgerechnet.

Das Ergebnis enthält vier Bänder; die ersten drei Bänder stellen die Fraktionsbilder für jeden *Endmember* (Boden, GV, Schatten) dar, das vierte Band enthält den jeweiligen Fehleranteil pro Pixel. Der Fehleranteil ergibt sich aus der Formel zur Beschränkung der Summeneinheit auf 1. Hohe Fehleranteile weisen dabei auf eine schlechte Auswahl der *Endmemberwerte* hin. Die Pixelwerte der Fraktionsbilder entsprechen Prozentwerten (0 – 100 Prozent) und repräsentieren den Anteil des *Endmembers* im jeweiligen Pixel.

4.2.3.2. REDD *Spectral Mixture Analysis Workflow* mit automatischer *Endmember* Selektion

Alternativ zur manuellen Ableitung der *Endmember* wurde in IMPACT ein REDD *Spectral Mixture Analysis Workflow* implementiert. Dieser leitet anhand des *Pixel Purity Index* (PPI, siehe auch Kapitel 2.3.2.4) *Endmember* automatisch ab und berechnet daraus die spektrale Entmischung. Eine Reduktion der Datendimensionen ist bei dieser Anwendung nicht zwingend notwendig, da die Auswahl der *Endmember* automatisch erfolgt. Dabei ist zu beachten, dass die Anzahl der *Endmember* durch die Anzahl der Inputbänder + 1 festgelegt wird. Davon abgesehen wurden aus Gründen der Vergleichbarkeit mit den Ergebnissen der SMA auf Basis der manuellen *Endmember Selektion* dieselben vier Bandkombinationen (Band 3 und 4, Band 4 und 5, PCA aus Band 2,3 und 4 sowie PCA aus Band 3,4,5 und 7) als Inputdaten gewählt.

Die Selektion der *Endmember* erfolgt in dieser Anwendung anhand des PPI automatisch. Der Anwender wählt einen Schwellwert für den PPI und somit den Prozentanteil der Pixelreinheit, ab welcher ein Pixel als potentieller *Endmember* herangezogen wird. Des Weiteren wird vom Nutzer die Anzahl an Referenzvektoren definiert, welche für die Berechnung des PPI herangezogen werden. Je höher die Anzahl der Referenzvektoren umso stabiler ist der PPI. Der PPI Algorithmus sucht über Referenzvektoren (Anzahl dieser wird vom Anwender definiert) nach möglichst reinen Pixel (Schwellwert wird vom Anwender bestimmt) und vergibt Markierungen. Jene Pixel mit den meisten Markierungen sind potentielle *Endmemberkandidaten*. Das Ergebnis des PPI wird in weiterer Folge binarisiert und im Merkmalsraum eingetragen. Ein Clusteralgorithmus bestimmt nun mittels Vektoren jene *Endmemberkandidaten*, welche sich in den Extrembereichen der Punktwolke befinden und gibt diese als finale *Endmember* an den *Spectral Unmixing* Algorithmus weiter. Die Berechnung der *Endmemberfraktionen* ist identisch mit jener in der Variante des *Spectral Unmixing mit manueller Endmember* Selektion. Das Ergebnis ergibt bei zwei Inputbändern wiederum drei Fraktionsbilder sowie ein Fehleranteilsbild, deren Pixelwerte wiederum Prozentwerten entsprechen.

4.2.3.3. mNDFI (modified Normalized Difference Fraction Index)

Der von Souza et al. (2005a) entwickelte NDFI basiert auf den vier *Endmember* Boden, nicht photosynthetische Vegetation (NPV), grüne Vegetation (GV) und Schatten (vgl. Kapitel 2.3.2.4). Anhand der Landsat-Szene konnte jedoch kein NPV Endmember abgeleitet werden, da keine Pixel mit hohem NPV Anteil gefunden wurden. Folglich basierte die SMA auf den drei *Endmember* (Boden, GV und Schatten), wodurch im Rahmen dieser Arbeit der von Haas (2009) modifizierte NDFI (mNDFI) berechnet wurde. In diesem wird der Term Boden + NPV durch Boden ersetzt, woraus sich folgende Berechnung des mNDFI aus den *Endmemberfraktionen* ergibt:

$$mNDFI = \frac{GV_{Schatten} - Boden}{GV_{Schatten} + Boden}$$

wobei $GV_{Schatten}$ die Schatten-normalisierte GV Fraktion gegeben durch

$$GV_{Schatten} = \frac{GV}{100 - Schatten}$$

darstellt.

4.3. Korrelation von Referenzdaten und Features

Zur Bestimmung des optimalen Features werden nun die einzelnen Features mit den Referenzdaten in Beziehung gesetzt. Letztere wurden bereits mit dem Analyseraster (90m Zellgröße) verschnitten, wodurch für jede Zelle die Flächenbedeckung der jeweiligen Klassen in Prozent vorliegt (siehe Kapitel 4.1.3). Nun werden auch die einzelnen Features auf das Analyseraster hochgerechnet. Da das Raster an die Landsatpixel angepasst wurde, konnten 3x3 Pixel á 30m pro Zelle gemittelt werden.

Darauf aufbauend wurden die Featurewerte den Referenzwerten gegenübergestellt und die Featurewerte mit den Referenzklassen Lücken und Wiederbewuchs korreliert. Dabei wird von einer linearen Abhängigkeit der Datensätze ausgegangen und das Bestimmtheitsmaß (r^2) berechnet. Die Annahme der Linearität des Zusammenhangs beruht auf der Hypothese, dass mit steigendem Prozentanteil einer Klasse in den Referenzzellen auch die Reflexion dieser Bedeckungsklasse in den Features ansteigt. Untersuchungen von JR im Rahmen des Geoland Projektes in europäischen Ländern bestätigen diese Hypothese. Das Bestimmtheitsmaß repräsentiert den Anteil der Varianz (Streuung) der Variablen, der durch die lineare Regressionsgerade erklärt wird. Indirekt wird damit auch der Zusammenhang zwischen den Variablen gemessen. Die Maßzahl liegt zwischen 0 und 1. Dabei gilt je näher der Wert bei 1, umso stärker ist der lineare Zusammenhang und umso besser lässt sich die Variable durch das lineare

Regressionsmodell erklären. In Zusammenhang mit dieser Arbeit bedeutet dies, je besser der Zusammenhang mit den Klassen Lücken und/oder Wiederbewuchs, umso wahrscheinlicher ist die Eignung des jeweiligen Features zur Degradationskartierung.

4.4. Klassifikation zur monotemporalen Degradationskartierung

Anhand des aus den Korrelationen resultierenden „besten“ Features (vgl. Kapitel 5.2), wird eine monotemporale Degradationskartierung durchgeführt. Als Klassifikationsverfahren wurde das Schwellwertverfahren gewählt, da dieses in der Literatur mehrheitlich zur Klassifikation von Features herangezogen wurde und gute Ergebnisse erzielte (vgl. Kapitel 2.3.2.5). Zudem scheiden weitere gängige Klassifikationsverfahren wie Maximum Likelihood aufgrund der nicht normalverteilten Klassen aus.

Bei der Klassifizierung werden die Klassen degradierte Bereiche, Wiederbewuchs und intakte Vegetation (intakter Wald, Sumpf und Sumpfwald) unterschieden. Die Schwellwerte zur Klassifizierung werden auf Basis einer Signaturanalyse ausgewählt, welche auf Streudiagrammen basiert. Diese stellen die Reflexion von Klassen im zweidimensionalen Raum dar und zeigen die Verteilung der Trainingsgebiete bzw. Klassen in Form von Punktwolken. Die Trainingsgebiete für die verschiedenen Klassen wurden auf Basis der Referenzzellen (vgl. Kapitel 4.1) ausgewählt. Um möglichst reine Klassen zu erhalten, werden für die Darstellung von degradierten Bereichen Zellen mit mindestens 50 Prozent Bodenanteil sowie für Wiederbewuchs Zellen mit mindestens 60 Prozent Wiederbewuchsanteil selektiert. Da keine Zellen zu 100 Prozent aus vegetationslosem Boden bzw. Wiederbewuchs bestehen, stellen diese die „reinsten“ Zellen dar. Einzig für die Repräsentation von intaktem Wald konnten Zellen mit 100 Prozent Überschildung selektiert werden.

Von diesen Zellen werden 80 Prozent für die Signaturanalyse verwendet, während die verbleibenden 20 Prozent der Kacheln für die Verifizierung der Klassifikation herangezogen werden. Die Auswahl der Zellen, welche für die Verifizierung verwendet werden, erfolgt mittels der so genannten *List Sampling* Methode. Hierfür werden die gewählten Zellen pro Klasse nach deren Feature Identifikationsnummer (FID) gelistet und jede fünfte Zelle zur Verifizierung der jeweiligen Klasse herangezogen. Da FID's bei der Generierung des Analyserasters automatisch vergeben wurden, entsteht durch das *Listed Sampling* eine zufällige räumliche Verteilung der Verifizierungszellen, welche anhand von Abb. 13 demonstriert wird. Die schwarz umrahmten Zellen stellen die Verifizierungszellen für Degradationsflächen dar, die gelben jene für Wiederbewuchs und die grünen für intakte Vegetation, repräsentiert durch intakte Überschildung.




Abb. 13: Räumliche Verteilung der Verifizierungszellen

Da keine eindeutigen reinen 90 m Zellen vorliegen, wurde bei der Verifizierung auf 30 m Einheiten zurückgegangen. Das Problem der geometrischen Verschiebung zwischen den beiden Datensätzen, welche bei der Verwendung von 30m Einheiten stärker zum Tragen kommt, ist dabei mit der Verwischung der Ergebnisse bei Verwendung von 90m Einheiten gegenüberzustellen. So könnte bei der Verwendung von 90m Zellen beispielsweise eine Verteilung der Klassen in 40 Prozent Boden, 30 Prozent Wiederbewuchs und 30 Prozent intakter Wald entstehen, wodurch die Zelle der Klasse Boden zugewiesen werden würde. Eine Klassifizierung zu Wiederbewuchs oder intaktem Wald wäre nun in diesem Zusammenhang eine Fehlklassifikation. Eine Verifizierung mit 90 m Zellen wäre somit nur bei vorangegangener Verwendung eines *Soft Classifiers* mit fließenden Klassengrenzen sinnvoll.

Folglich werden die vorliegenden Verifizierungszellen mit einem 30 m Raster, welches auf die Landsatpixel angepasst ist, verschnitten und die Prozentanteile der Referenzklassen für die 30m Zellen berechnet. Dies ist möglich, da die Kartierung auf Basis von Polygonen erfolgte (vgl. Kapitel 4.1.2). Die Klassenmehrheit in den 30m Zellen wird dabei über die Zuordnung zu den Klassen degradierte Flächen, Wiederbewuchs und intakte Bereiche bestimmt. Sämtliche 30m Verifizierungszellen sind nun eindeutig einer Klasse zugewiesen, wodurch diese mit den Ergebnissen der Schwellwertklassifikation

verglichen werden können. Zwei Verifizierungszellen der Klasse Wiederbewuchs, welche eine eindeutige Veränderung zwischen den Aufnahmezeitpunkten der beiden Datensätze erfahren, werden von der Verifizierung ausgeschlossen.

Die eigentliche Verifikation erfolgt durch eine Konfusionsmatrix (auch Fehlermatrix genannt), welche die klassifizierten Pixel der in 30m Zellen vorliegenden Referenz gegenüberstellt. Die Anzahl der Zeilen und Spalten der Matrix ist dabei mit der Anzahl der Klassen gleichzusetzen. Basierend auf dieser Fehlermatrix werden prozentuelle Genauigkeiten berechnet. Die *Overall Accuracy* repräsentiert dabei die mittlere Klassengenauigkeit und somit den Anteil der richtig klassifizierten Pixel aller drei Klassen an der Gesamtpixelanzahl, während die *Mean Accuracy* den Mittelwert aus der Summe der Genauigkeiten (in Prozent) der richtig klassifizierten Pixel angibt. Somit werden auch die Genauigkeiten von flächenmäßig unterrepräsentierten Klassen besser in die Evaluierung miteinbezogen (Lillesand und Kiefer 1994). Die Genauigkeit in den einzelnen Klassen wird durch die Berechnung der *Producer's Accuracy* und der *User's Accuracy* angegeben. Die *Producer's Accuracy* gibt den Anteil der richtig klassifizierten Pixel einer Klasse an den Referenzpixeln in dieser Klasse an, d.h. wie viele Pixel einer Klasse den Referenzdaten zufolge richtig klassifiziert wurden. Die *User's Accuracy* gibt den Anteil der richtig klassifizierten Pixel an der Summe der klassifizierten Pixel in dieser Klasse an, d.h. wie viele der klassifizierten Pixel einer Klasse tatsächlich dieser Klasse angehören (Niemeyer 2009).

4.5. Übertragung von *Endmember*

Um das *Spectral Unmixing* mit manueller *Endmember* Selektion als Feature für eine operationelle, flächendeckende Anwendung zur Degradationskartierung einzusetzen, wäre eine Übertragung der *Endmember* von Vorteil. Diese Möglichkeit würde nicht nur eine Zeitersparnis darstellen, sondern auch Fehlerquellen durch die individuelle *Endmember* Selektion pro Szene minimieren. Daher wurde in dieser Arbeit eine zeitliche, als auch eine räumliche Übertragung von *Endmemberwerten* aus der Landsatzszenen vom 13.12.2002 anhand der in Kapitel 5.2.3 empfohlenen *Spectral Unmixing* Features getestet.

Die räumliche Übertragung der *Endmember* wird anhand einer Landsatzszenen im Gebiet von Kamerun, mit Aufnahmedatum 18.01.2011 getestet. Da diese Szene keinen Überlappbereich mit der Referenzszenen aufweist erscheint eine radiometrische Anpassung der Daten nicht sinnvoll. Die zeitliche Übertragung wird auf eine Landsatzszenen, aufgenommen am 18.02.2010 über dem Testgebiet in der Republik Kongo, angewandt. Im Hinblick auf die zeitliche Übertragung der *Endmember* soll eine radiometrische Anpassung der Szenen an die Referenzszenen (Landsat, 13.12. 2002) die Übertragung der *Endmember* erleichtern. Die Anpassung wurde mit dem IMPACT Tool *Relative Radiometric Calibration* durchgeführt, welches pseudo-invariante Features (PIFs) in das lineare Regressionsmodell mit einbezieht. Als PIFS sind unveränderte

Bereiche in beiden Datensätzen zu verstehen, welche auf Basis eines lokalen Korrelationskoeffizienten identifiziert werden. Anhand dieser PIFs wird in Folge die Regressionsfunktion zur Kalibrierung der Daten aufgebaut, wodurch phänologische Unterschiede als auch Veränderungen in der Landbedeckung zwischen den Datensätzen berücksichtigt werden und sich so nicht negativ auf die Kalibrierung auswirken können.

Eine mögliche Übertragung der *Endmember* wird dabei über die Visualisierung der *Endmember* im spektralen Merkmalsraum überprüft. Liegen diese an den Eckpunkten des Merkmalraumes, so kann von einer Übertragungsmöglichkeit ausgegangen werden. Eine erfolgreiche Übertragung wird anhand der Berechnung der SMA und der visuellen Kontrolle der Ergebnisse überprüft, da gut gewählte *Endmemberwerte* zu guten Ergebnissen der SMA führen. Befinden sich die *Endmember* jedoch nicht in den Extrembereichen des Merkmalraumes, ist eine Übertragung nicht sinnvoll. Generell sind die *Endmemberwerte* von der Radiometrie der Daten abhängig. Im Fall einer perfekten radiometrischen Kalibrierung sollte auch die Übertragung der *Endmember* funktionieren. Die Erkenntnisse aus der zeitlichen Betrachtung der Übertragung der *Endmember* fließen in die Auswahl des Features für eine multitemporale Betrachtung der Degradations- und Wiederbewuchsflächen (vgl. Kapitel 4.6) ein.

4.6. Multitemporale Betrachtung der Degradationsgebiete

In diesem Teil der Arbeit wird die bisher monotemporale Betrachtung von Degradations- und Wiederbewuchsflächen in eine multitemporale Dimension verlagert. Degradation in Form von vegetationslosem Boden ist nur für einen begrenzten Zeitraum von etwa zwei Jahren erkennbar (vgl. Kapitel 2). Da die betroffenen Flächen rasch zuwachsen, erscheint die Berücksichtigung von Wiederbewuchs, deren Signal über die Zeit länger präsent ist, sinnvoll. Durch die Einbeziehung beider Erscheinungen kann anhand eines Bildes aktuelle als auch länger zurückliegende Degradation kartiert werden. Dadurch kann die Anzahl der benötigten Satellitenbilddaten reduziert und folglich mangelnde Datenverfügbarkeit (z.B. aufgrund der häufigen Wolkenbedeckung in den Tropen) ausgeglichen sowie Kosten gespart werden.

Durch das Ableiten von temporalen Kurven hinsichtlich der spektralen Entwicklung von Degradations- und Wiederbewuchsflächen soll festgestellt werden, wie lange Störungen im Mittel erkennbar sind und wie sich deren spektrales Signal über die Zeit verhält. Das erwartete spektrale Verhalten ist ein Anstieg des Bodenanteils in Folge der Degradation und ein Rückgang im Zuge des Wiederbewuchses der Fläche. Mit Einsetzen des Wiederbewuchses steigt das spektrale Signal der Vegetation, welches mit älter werdender Vegetation wieder zurückgeht. In Abb. 14 wird dieses erwartete spektrale Verhalten schematisch dargestellt. Die spektralen Kurven stellen in weiterer Folge eine Basis für eine multitemporale Degradationsklassifizierung dar, welche von JR im Rahmen

des REDDAP (*Reducing Emissions from Deforestation and Degradation in Africa*) Projektes in Kamerun durchgeführt wird.

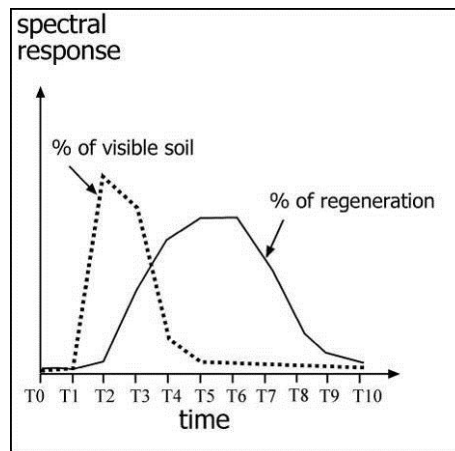


Abb. 14: Schematische Visualisierung des erwarteten spektralen Verhaltens von Boden und Wiederbewuchs über die Zeit

Quelle: Hirschmugl 2011

Für die multitemporale Analyse stehen 22 Landsatzenen im Zeitraum von November 1990 bis Februar 2010 zur Verfügung. Die genauen Aufnahmezeitpunkte können aus Tab. 6 (in Kapitel 3.2) entnommen werden.

Auswahl von Degradations- und Wiederbewuchsflächen aus den Referenzdaten

Die Basis für diese Analyse bilden die Referenzdaten, welche durch die visuelle Interpretation der Ikonosszene vom 27.6.2002 generiert wurden (siehe Kapitel 4.1). Über diese Daten wird ein Raster mit einer Zellgröße von 30m, welches exakt auf die Landsatpixel angepasst ist, gelegt und die Flächenanteile von vegetationslosem Boden und Wiederbewuchs in den Zellen berechnet. Die Verwendung eines 30m Rasters anstatt des zur Korrelation verwendeten 90m Rasters kann damit begründet werden, dass keine 90m Zellen von nur einer Klasse eingenommen werden. Folglich könnte im Rahmen der multitemporalen Anwendung nicht die alleinige Entwicklung des spektralen Signals von Boden bzw. Wiederbewuchs über die Zeit betrachtet werden, sondern lediglich ein Mischsignal von mehreren Klassen.

Jene 30m Rasterzellen, die in den Referenzdaten einen Bodenanteil von 100 Prozent aufweisen und zudem von vier benachbarten Zellen mit mindestens 50 Prozent Bodenanteil (aufgrund möglicher geometrischer Verschiebungen sowie aufgrund der Streuung des Signals) umgeben sind, werden für die Analyse des spektralen Verhaltens von Lücken über die Zeit in Betracht gezogen. Kleinere Lücken mit weniger als 100 Prozent Bodenanteil pro Zelle oder weniger als vier Nachbarn mit 50 Prozent Bodenanteil werden in der Analyse nicht berücksichtigt, da diese durch die Streuung des Signals in den Landsatdaten nicht aussagekräftig sein könnten. Die selektierten Zellen werden mit den Landsatdaten visuell verglichen, um sicherzustellen, dass die Zellen auch in den Landsatdaten vom 13.12.2002 als vegetationslose Pixel identifiziert werden

können und im Jahr 2010 wiederbewachsen sind. Nur wenn dies der Fall ist, kann anhand der Daten festgestellt werden, wie lange eine Störung anhand des gewählten Features erkennbar ist. Auf Basis dieser Kriterien ergeben sich 40 Zellen, welche für die Analyse der Entwicklung von Degradationsflächen herangezogen werden.

Die Auswahl der Wiederbewuchsflächen erfolgt nach demselben Prinzip: sämtliche Rasterzellen mit einem Wiederbewuchsanteil von 100 Prozent und vier benachbarten Zellen mit mindestens 50 Prozent Wiederbewuchs werden für die multitemporale Analyse ausgewählt. Auch die für die Betrachtung des Wiederbewuchs über die Zeit in Frage kommenden Zellen werden anhand der Landsatdaten überprüft. Die Zellen sollten in der Landsat Szene vom 13.12.2002 von Wiederbewuchs bestimmt sein und im Zeitraum bis 2010 keine Störung erfahren. Daraus resultieren 661 Zellen, anhand derer die Entwicklung des Wiederbewuchs betrachtet wird.

Das spektrale Signal von intakten Waldgebieten dient als Referenz und symbolisiert gewissermaßen den Sollzustand der Vegetation. Die intakten Waldbereiche aus der Referenz (vgl. Kapitel 4.1.4) werden mit den Landsatdaten verglichen, um jene Zellen, welche eine Störung im Zeitraum der multitemporalen Analyse erfahren, auszunehmen. Für eine bessere Vergleichbarkeit werden die intakten Waldbereiche ebenso in 30m Zellen konvertiert. In die Analyse fließen somit 127 Zellen aus intaktem Wald ein.

Vorverarbeitung der Landsatdaten

Um die Veränderung des spektralen Signals über die Zeit untersuchen zu können, müssen die Daten geometrisch genau zueinander passen. Diese Überprüfung wurde visuell durchgeführt, wobei die Daten als geometrisch gut übereinstimmend befunden wurden. Im nächsten Schritt wurden die Daten auf den Ausschnitt der VHR Szene zugeschnitten, da die multitemporale Betrachtung nur für diesen Ausschnitt durchgeführt wird. Falls erforderlich wurden Wolken und Wolkenschatten ausmaskiert. Dies erfolgte mittels der *Cloud Detection Processing* Anwendung, welche in der Software RSG implementiert ist. Darüber hinaus ist für eine multitemporale Analyse des spektralen Verhaltens von Lücken und Wiederbewuchsflächen eine radiometrische Anpassung der Daten Voraussetzung. Die Landsat Szene vom 13.12.2002 gilt als Referenzszenen, an welche die weiteren Landsatdaten angepasst werden. Die Kalibrierung wurde anhand des IMPACT Tools *Relative Radiometric Calibration* durchgeführt. Dieses Tool berücksichtigt, wie bereits in Kapitel 4.5 beschrieben, phänologische Differenzen und Landbedeckungsveränderungen zwischen den einzelnen Datensätzen und bezieht diese nicht in das Regressionsmodell zur Kalibrierung mit ein.

Selektion des geeigneten Features

Anhand der Korrelationsergebnisse, welche in Kapitel 5.2 präsentiert werden, entscheidet sich, welches Feature für die multitemporale Betrachtung der Degradations- und Wiederbewuchsflächen herangezogen wird. Dabei ist zu beachten, dass jene Features, welche unempfindlicher gegenüber atmosphärischen Einflüssen sind, geeigneter zur Durchführung einer multitemporalen Analyse sind. Das aufgrund dieser Kriterien gewählte Feature wird im nächsten Schritt für sämtliche Landsatdaten, welche in die multitemporale Betrachtung einfließen, berechnet.

Analyse

Für die ausgewählten Degradations- und Wiederbewuchszellen werden die anhand des Features berechneten spektralen Werte für jeden Zeitpunkt ermittelt. Um die Streuung des Signals einer jeden Klasse (Lücken, Wiederbewuchs, intakter Wald) zu reduzieren, werden die Werte pro Klasse gemittelt. Somit entsteht für jeden Zeitpunkt ein gemittelter spektraler Wert von Lücken, Wiederbewuchs und intaktem Wald. Diese Werte bilden die Grundlage für die temporalen Kurven.

5. Ergebnisse

In diesem Kapitel werden nun die Ergebnisse aus den im vorangegangenen Kapitel beschriebenen Methoden und Arbeitsschritten vorgestellt und diskutiert.

5.1. Visuelle Betrachtung der spektralen Bänder

Die visuelle Analyse der Landsatbänder der Szene vom 13.12.2002 bildet neben der Literaturrecherche die Basis für die Auswahl der Features bzw. der Bänder für die weiteren Features. In Abb. 15 sind die Grauwertbilder der einzelnen spektralen Bänder für einen Ausschnitt des Testgebietes mit selektiver Abholzung dargestellt.




Abb. 15: Grauwertbilder der Landsatbänder für einen Ausschnitt mit selektiver Abholzung

Band 1 ist aufgrund der mangelnden Erkennbarkeit von vegetationslosen Lücken mit Ausnahme der Straßen sowie dem starken Bildrauschen nur bedingt als Input für ein Feature geeignet. **Band 2** ermöglicht eine bessere Erkennbarkeit von Degradationserscheinungen, diese sind in **Band 3** jedoch noch deutlicher ersichtlicher. Da die Information der Bänder im sichtbaren Bereich meist stark korreliert (linearer Korrelationskoeffizient Band 1 und Band 3 0,94 bzw. Band 2 und Band 3 0,96) wurde Band 3 als Inputband des sichtbaren Wellenlängenbereichs favorisiert (vgl. Asner et al. 2002). Degradationserscheinungen weisen in Band 3 sehr hohe Reflexionswerte auf, wohingegen Vegetation aufgrund der Absorption des Lichtes durch das Blattchlorophyll eine geringe Reflexion aufweist und damit sehr dunkel erscheint. Intakte Vegetation kann in diesem spektralen Bereich jedoch nicht von Wiederbewuchs unterschieden werden. Diese Unterscheidung wird anhand der Information in **Band 4** erleichtert. Aufgrund der stärkeren Photosyntheseaktivität reflektiert Wiederbewuchs stärker als ältere Bestände und somit intakter Wald. Vegetationsloser Boden weist in diesem Band geringe Reflexionswerte auf, kleinere Lücken können in diesem Band jedoch nicht identifiziert werden. Die Visualisierung des spektralen Merkmalsraumes von Band 3 und 4 bestätigt die gute Trennbarkeit der Klassen in diesen Bändern (siehe Abb. 16).




Abb. 16: Spektraler Merkmalsraum von Band 3 und 4

Die Information des mittleren Infrarots (**Band 5** und **Band 7**) korreliert mit jener von Band 3. Vegetationsloser Boden reflektiert in diesen Bändern somit stark, während Vegetation geringe Reflexion aufweist. In der Regel hält Band 5 mehr Information als Band 7, in letzterem sind vegetationslose Öffnungen im Wald jedoch am besten erkennbar.

Zusammenfassend stellen somit Band 3, 4, 5 und 7 wichtige Informationen hinsichtlich der Kartierung von Degradation bereit. Während die Unterscheidung von Wiederbewuchs und intaktem Wald in Band 4 möglich ist, eignen sich die Bänder 3, 5 und 7 zur Detektion von vegetationslosem Boden. Diese Ergebnisse werden durch die Literaturrecherche (siehe Kapitel 2.3.2.1) bestätigt.

5.2. Ergebnisse aus der Korrelation von Referenzdaten und Features

Die Korrelationen der einzelnen Features mit den Referenzdaten zeigen, dass die Reflexion von Band 3 und Band 4 bzw. Bandkombinationen sowie die SMA mit manueller *Endmember Selektion* die besten Features zur Kartierung von Degradation und Wiederbewuchs sind. Wie bereits in Kapitel 4.3 erwähnt, werden die Featurewerte jeweils mit den Referenzklassen vegetationslose Lücken und Wiederbewuchs korreliert. Abb. 17 gibt einen Überblick über die Eignung der berechneten Features zur Degradations- und Wiederbewuchskartierung, welche durch das Bestimmtheitsmaß (r^2) ausgedrückt wird. Indirekt zeigt dieses Maß auch den Grad des Zusammenhangs der einzelnen Features mit den Referenzklassen auf. Je höher der r^2 Wert, umso besser ist der Zusammenhang des Features mit der jeweiligen Referenzklasse und umso geeigneter ist das Feature zur Kartierung von Degradation (rote Balken) und/oder Wiederbewuchs (blaue Balken). Darüber hinaus werden die absoluten r^2 Werte aus den Korrelationen in Tab. 8 aufgelistet.




Abb. 17: Korrelationsergebnisse (Überblick)

Tab. 8: Bestimmtheitsmaß der Korrelationen von den Features mit den Referenzdaten

Feature	vegetationsloser Boden (aus Referenzdaten)	Wiederbewuchs (aus Referenzdaten)
B1	0,34	0,05
B2	0,47	0,03
B3	0,61	0,00
B4	0,01	0,75
B5	0,31	0,22
B7	0,54	0,02
B1, B2	0,47	0,32
B1, B3	0,62	0,19
B1, B4	0,38	0,62
B1, B5	0,37	0,61
B1, B7	0,54	0,31
B2, B3	0,61	0,34
B2, B4	0,56	0,67
B2, B5	0,48	0,60
B2, B7	0,54	0,31
B3, B4	0,62	0,69
B3, B5	0,61	0,61
B3, B7	0,61	0,38
B4, B5	0,57	0,69
B4, B7	0,61	0,70
B5, B7	0,61	0,64
B4/B3	0,26	0,56
B4/B5	0,45	0,19
B4/B7	0,44	0,26
B5/B4	0,53	0,14
B7/B4	0,56	0,15
NDVI	0,32	0,49
SAVI	0,33	0,49
GEMI	0,14	0,69
NDII 5	0,49	0,16
NDII 7	0,53	0,18
mSAVI 5	0,50	0,16
mSAVI 7	0,54	0,17
TC brightness	0,18	0,39
TC greenness	0,19	0,63
TC wetness	0,53	0,01
SMA (B34) (EM manuell)	0,62	0,75
SMA (B45) (EM manuell)	0,60	0,74
SMA (B234) (EM manuell)	0,61	0,75
SMA (B3457) (EM manuell)	0,37	0,67
SMA Workflow (B34)	0,25	0,75
SMA Workflow (B45)	0,62	0,64
SMA Workflow (B234)	0,47	0,72
SMA Workflow (B3457)	0,29	0,64
mNDFI (B34)	0,45	
mNDFI (B45)	0,21	
mNDFI (B234)	0,54	
mNDFI (B3457)	0,05	

Aus der Abbildung sowie der Tabelle ist klar ersichtlich, dass die Verwendung von Band 3 und 4 sowohl in Bezug auf die Reflexion als auch im Zuge der SMA zu bevorzugen sind. Indizes sind als Features in diesem Zusammenhang zu vernachlässigen. Einzige Ausnahme stellt der GEMI dar, welcher gut mit Wiederbewuchs korreliert. In den folgenden Kapiteln werden die Ergebnisse der einzelnen Features (Reflexion, Indizes und SMA) genauer betrachtet sowie entsprechende Ergebnisse anhand von Korrelationsdiagrammen visualisiert. Die Regressionsgerade zeigt dabei den Trend der Daten an.

5.2.1. Reflexion

In Bezug auf die Reflexion der Landsatbänder zeigt sich, dass Band 3 am stärksten mit den aus den Referenzdaten erhobenen Degradationsgebieten korreliert, während Band 4 zur Erkennung von Wiederbewuchs zu favorisieren ist (siehe Abb. 18). Band 4 ist darüber hinaus das einzige unter den sechs Bändern, welches gut mit Wiederbewuchs korreliert und mit den Ergebnissen der SMA mithalten kann (vgl. Abb. 17 und Kapitel 5.2.3).




Abb. 18: Korrelationen von Band 3 und Band 4

Band 5 weist eine geringe Korrelation mit den Referenzklassen Degradation und Wiederbewuchs auf. Die Information in Band 7 korreliert in Bezug auf Degradation stärker als jene in Band 5 und ist nach Band 3 am geeignetsten zur Kartierung von Degradation (vgl. Abb. 19). Die Korrelationsergebnisse entsprechen somit den Erkenntnissen aus der visuellen Betrachtung der einzelnen spektralen Bänder (vgl. Kapitel 5.1).




Abb. 19: Korrelationen von Band 5 und Band 7

Die Ergebnisse aus der multivariaten Regression von jeweils zwei Landsatbändern mit den Referenzklassen bestätigt die gute Eignung von Band 3 in Kombination mit Band 4 zur Degradationskartierung. Die Kombination von Band 2 und Band 4 zeigt ebenso ansprechende Ergebnisse. Dies kann damit begründet werden, dass Band 2 ähnliche Informationen wie Band 3 enthält (vgl. Kapitel 5.1). Trotz der geringen Korrelation von Band 5 mit den Referenzklassen liefert die Kombination mit Band 3 gute Ergebnisse. Diese könnte in Bezug auf Wiederbewuchs auf die gute Differenzierbarkeit von Vegetation zu nicht-Vegetation in Band 3 zurückzuführen sein sowie auf die scheinbar gute Unterscheidung von Wiederbewuchs zu intaktem Wald in Band 5. Die Kombination

von Bändern im Infrarotbereich weist einen hohen Informationsgehalt bezüglich Degradation als auch Wiederbewuchs auf. Sowohl die Kombination von Band 4 und Band 5 als auch die Kombination aus Band 4 und 7 bzw. Band 5 und 7 eignen sich für eine Kartierung. Aufgrund der multivariaten Regression fällt auf, dass Band 5 nur in Kombination mit den Bändern 2, 3, 4 und 7 gute Ergebnisse liefert. Dies könnte auf die schwere Trennbarkeit von Boden und Wiederbewuchs in Band 5 bei gleichzeitiger guter Differenzierung von Boden und Wiederbewuchs zu intaktem Wald zurückzuführen sein. Wird diese Information durch ein Band, welches eine gute Trennung zwischen Boden und Vegetation liefert, ergänzt, ergeben sich daraus gute Korrelationsergebnisse.

Die Abbildung von Diagrammen erscheint im Zusammenhang mit den multivariaten Regressionen nicht sinnvoll, da deren Darstellung in Diagrammform nur schwer zu interpretieren ist.

Zusammenfassend ist bei der Verwendung von den Originalbändern Band 3 (rot) zur Kartierung von Degradation am besten geeignet, während Band 4 (NIR) für die Kartierung von Wiederbewuchs zu empfehlen ist.

5.2.2. Indizes

Anhand der Korrelationen der Ratio-Indizes, Vegetations- und Infrarotindizes sowie der Tasseled Cap Transformation mit den Referenzdaten zeigt sich, dass diese Features nur bedingt zur Kartierung von Degradation und Wiederbewuchs geeignet sind.

Unter den **Ratio-Indizes** wiesen die Features aus Band 5/Band 4 bzw. Band 7/Band 4 den stärksten Zusammenhang zu degradierten Bereichen auf, während Wiederbewuchs am besten durch Band 4/Band 3 beschrieben wird. In Abb. 20 sind die Korrelationsdiagramme der genannten Features dargestellt. Sämtliche weiteren Korrelationen der Ratio-Indizes weisen einen noch geringeren Zusammenhang zu den Referenzklassen auf.

Die berechneten **Vegetationsindizes** NDVI und SAVI korrelieren entgegen den Erwartungen nur mäßig mit Wiederbewuchs, obwohl die Information in Band 3 und 4 durchaus gut ist und auch der RVI von Band 4/Band 3 ansprechende Ergebnisse lieferte. Einzig der GEMI weist unter den Vegetationsindizes einen guten Zusammenhang mit Wiederbewuchs auf. Diese stärkere Korrelation des GEMI könnte auf die Anpassung an atmosphärische Einflüsse, welche in die Berechnung einfließen, zurückzuführen sein. Abb. 21 zeigt die Korrelationsdiagramme der Vegetationsindizes für Wiederbewuchs. Die Featurewerte der **Infrarotindizes** stehen hingegen in Zusammenhang mit Degradation, wobei hier der NDII7 sowie der mSAVI7 die höchsten Korrelationen aufweisen (siehe Abb. 22).

Zusammenfassend sind Indizes (Ratio-Indizes als auch Vegetations- und Infrarotindizes), welche sich aus den nahen und mittleren Infrarotbändern berechnen, geeigneter zur

Kartierung von vegetationslosem Boden, während das rote Band in Kombination mit dem NIR Band Wiederbewuchs besser beschreibt. Diese Features kommen jedoch nicht an die Ergebnisse der SMA Features heran.

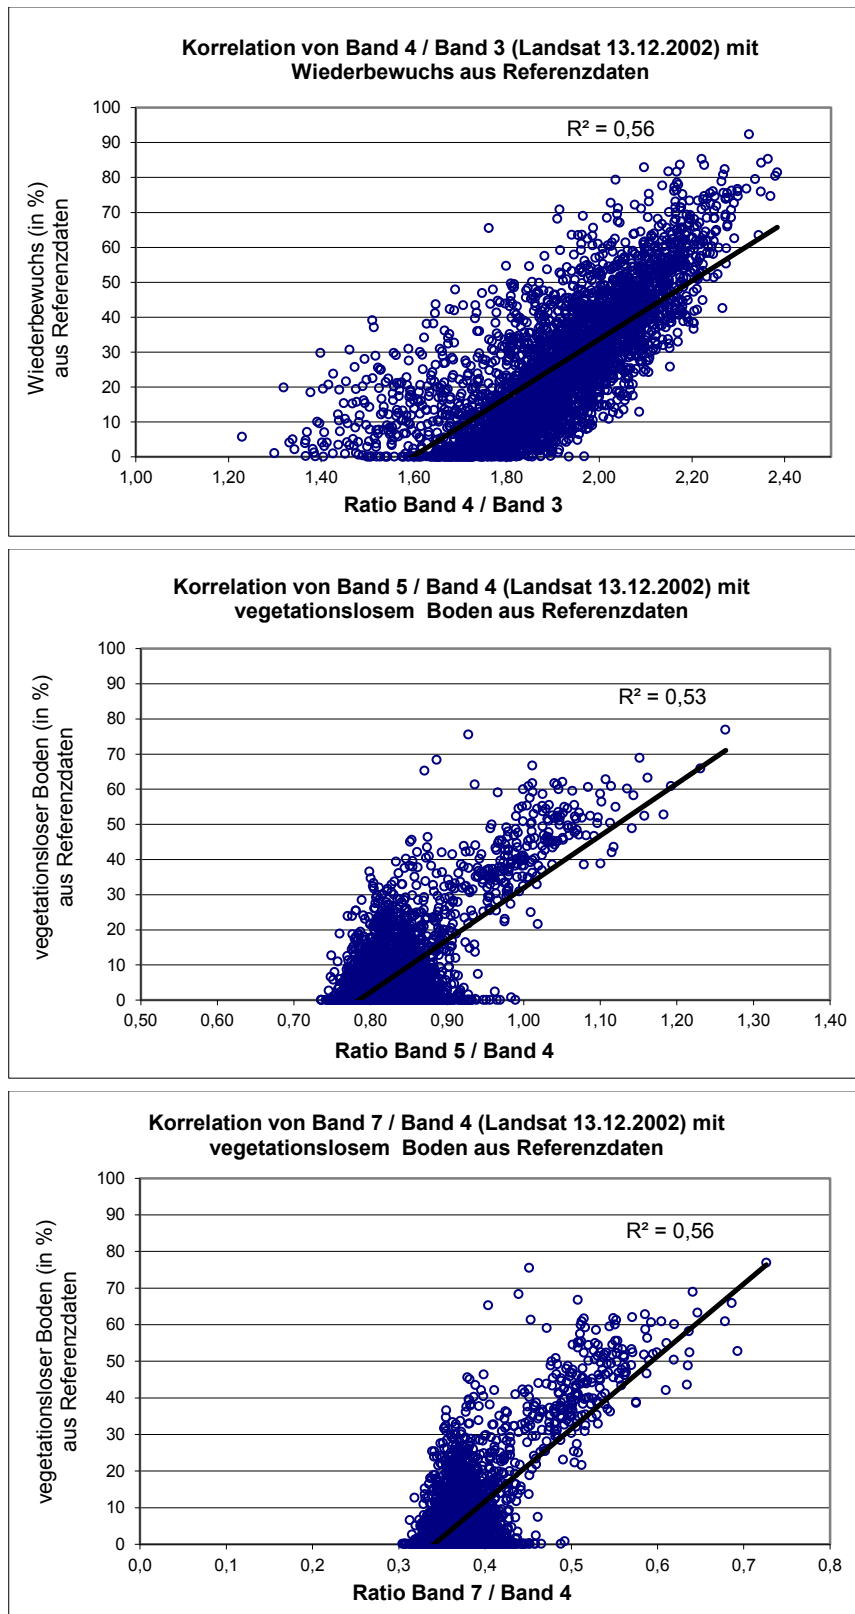


Abb. 20: Korrelationen der Ratio-Indizes Band 4/Band 3, Band 5/Band 4 und Band 7/Band 4






Abb. 21: Korrelationen der Vegetationsindizes NDVI, SAVI und GEMI







Abb. 22: Korrelationen der Infrarotindizes

Die Korrelationen der **Tasseled Cap** Transformation zeigen eine relativ hohe Korrelation von Band 2 (*greenness*) mit Wiederbewuchs sowie von Band 3 (*wetness*) mit vegetationslosem Boden (siehe Abb. 23). Band 1 (*brightness*) weist nur geringe Zusammenhänge mit den beiden Referenzklassen auf, obwohl dieses Band sensibel für Boden sein sollte (vgl. Kapitel 2.3.2.3).

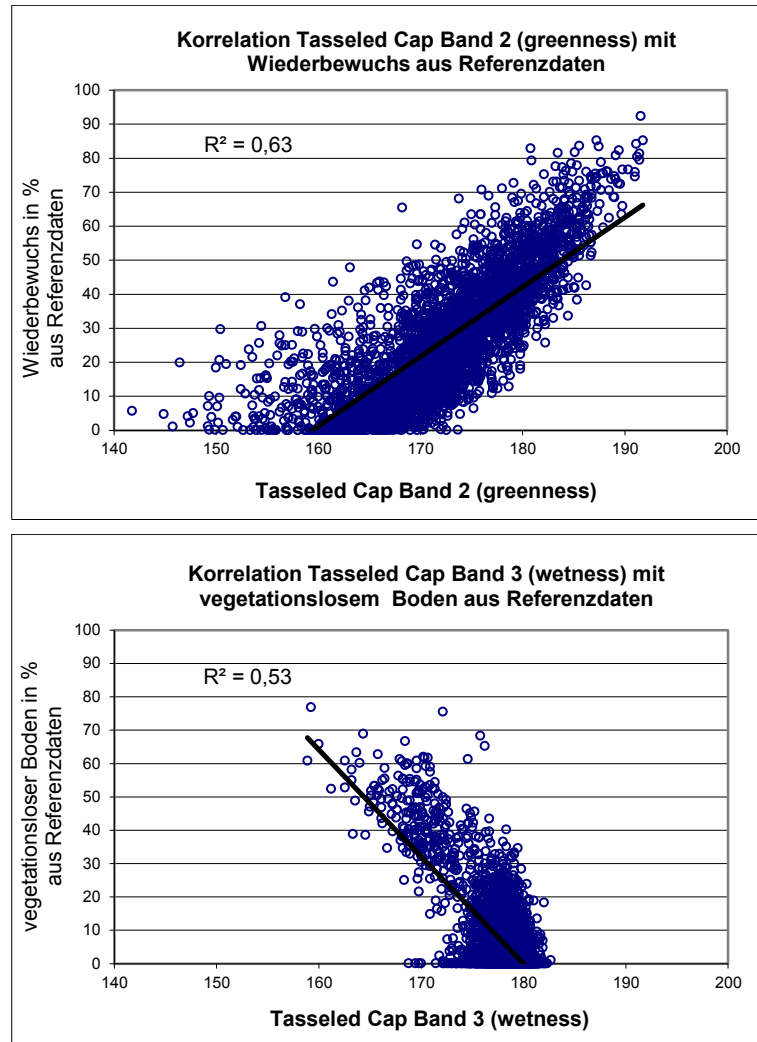




Abb. 23: Korrelationen der Tasseled Cap Bänder *greenness* und *wetness*

5.2.3.SMA Features

Die SMA stellt sich im Zuge der Korrelationen als klar bestes Feature zur Kartierung von Degradation heraus. Während sich das Bodenfraktionsbild gut zur Kartierung von vegetationslosen Lücken und Straßen eignet, kann Wiederbewuchs durch die GV-Fraktion erfasst werden. In Abb. 24 wird dies anhand der Darstellung der einzelnen Fraktionsbilder der SMA von Band 3 und 4 mit manueller *Endmember* Selektion verdeutlicht. Unbefestigte Straßen verfügen über hohe Anteilswerte in der Bodenfraktion (helle Pixel) sowie geringe Anteile in der GV-Fraktion (dunkle Pixel). Wiederbewuchs kann von intakter Vegetation anhand der GV Fraktion unterschieden werden, da Wiederbewuchs höhere GV-Anteile aufweist und somit durch hellere Pixel gekennzeichnet ist. Intakte Vegetation weist hohe Anteile in der Schattenfraktion auf, während Wiederbewuchs und Boden in der Regel sehr geringe Schattenanteile haben. Kleinere Lücken und Wiederbewuchsflächen können jedoch durch den Schattenwurf der umstehenden Bäume bzw. der umgebenden Waldränder höhere Schattenwerte aufweisen, wodurch die Schattenfraktion kritisch zur Detektion von Degradation und Wiederbewuchs zu betrachten ist.




Landsat (RGB 543)




SMA 34 Fraktionsbilder (rot = Bodenfraktion, grün = GV-Fraktion, blau = Schattenfraktion)



SMA34 Bodenfraktion



SMA34 GV-Fraktion



SMA34 Schattenfraktion

Abb. 24: Fraktionsbilder der SMA Band 3,4 mit manueller *Endmember* Selektion

Das SMA Feature aus der Bandkombination 3 und 4 mit manueller *Endmember* Selektion (beschrieben in 4.2.3.1) weist auch den höchsten Zusammenhang sowohl mit Degradation als auch mit Wiederbewuchs aus den Referenzdaten auf (siehe Abb. 25). Die Basis für dieses vielversprechende Feature bildet bereits die Information in den einzelnen Bändern (vgl. Kapitel 5.1 und Kapitel 5.2.1), welche durch die spektrale Information noch weiter verbessert wird.




Abb. 25: Korrelationen der SMA Fraktionsbilder aus Band 3 und 4 (Berechnung mit manueller *Endmember* Selektion)

Im Zuge des SMA Workflows (beschrieben in 4.2.3.2) weist die Bandkombination 3 und 4 lediglich eine hohe Korrelation mit Wiederbewuchs auf, der Zusammenhang mit Degradation ist in sämtlichen Fraktionsbildern gering. Dies könnte auf den atmosphärischen Einfluss zurückzuführen sein, wodurch Dunstfelder, welche nicht durch das *Cloud Detection* Tool erkannt werden, vom PPI als *Endmember* herangezogen werden. Diese Dunstbereiche liegen in den äußersten Extrembereichen der Punktwolke im Merkmalsraum, während der gewünschte *Endmember* Boden etwas weiter nach innen versetzt liegt (siehe Abb. 26). Durch die manuelle *Endmember* Selektion kann dies berücksichtigt und die *Endmember* dementsprechend gewählt werden.




Abb. 26: Lage von Dunst und Wolken im spektralen Merkmalsraum von Band 3 und 4

Der atmosphärische Einfluss ist in der Bandkombination 4 und 5 geringer, wodurch der PPI den *Endmember* Boden als solchen erkennt und so ein Fraktionsbild diesem *Endmember* zugewiesen werden kann. Weiters kann ein Fraktionsbild der GV zugeordnet werden, der *Endmember* wurde durch den PPI jedoch suboptimal bestimmt. Folglich weist die GV Fraktion eine schwächere Korrelation mit der Referenzklasse Wiederbewuchs auf. Hier liefert die GV-Fraktion der SMA mit manueller *Endmember* Selektion deutlich bessere Korrelationsergebnisse (siehe Abb. 27).

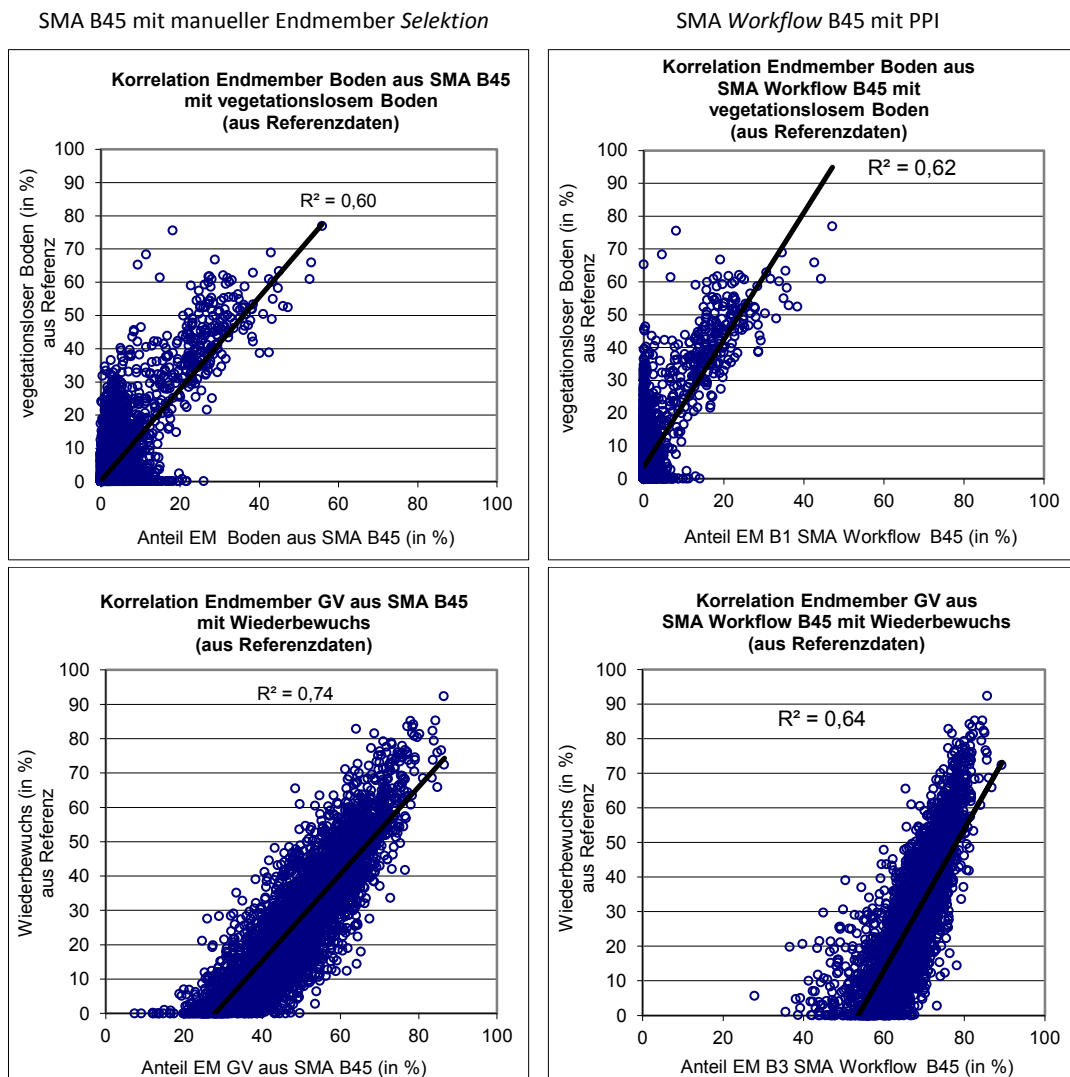


Abb. 27: Korrelationen der SMA Fraktionsbilder aus Band 4 und 5

Die Kombination der Bänder 2, 3 und 4, deren Dimensionen durch eine PCA im Vorfeld der SMA verringert wurden, liefert mittels der manuellen *Endmember* Selektion aus den Hauptkomponenten ebenso gute Korrelationsergebnisse. Im Vergleich zur Bandkombination 3, 4 steigert die Einbeziehung von Band 2 den Zusammenhang mit Degradation und Wiederbewuchs nicht, was auf den atmosphärischen Einfluss in Band 2 zurückzuführen ist. Auch die Bandkombination 3, 4, 5 und 7 mit vorangegangener PCA bewirkt keine Steigerung des Zusammenhangs mit den Referenzklassen. Im Gegenteil, die Korrelation ist mit Abstand am geringsten unter den berechneten SMA Features (siehe Abb. 28). Somit stellt sich die Frage, ob die PCA zur Verringerung der Dimensionen

im Vorfeld einer SMA, entgegen den Aussagen in der Literatur, tatsächlich geeignet ist. Zwar könnte sich in Bezug auf die Verwendung von Band 2, 3 und 4 der atmosphärische Einfluss der Bänder im spektralen Merkmalsraum negativ auf die PCA auswirken, dies rechtfertigt jedoch nicht die schlechten Ergebnisse in der Bandkombination 3, 4, 5 und 7. Zumal die einzelnen Bänder einen durchaus guten Informationsgehalt aufweisen (vgl. Kapitel 5.1).

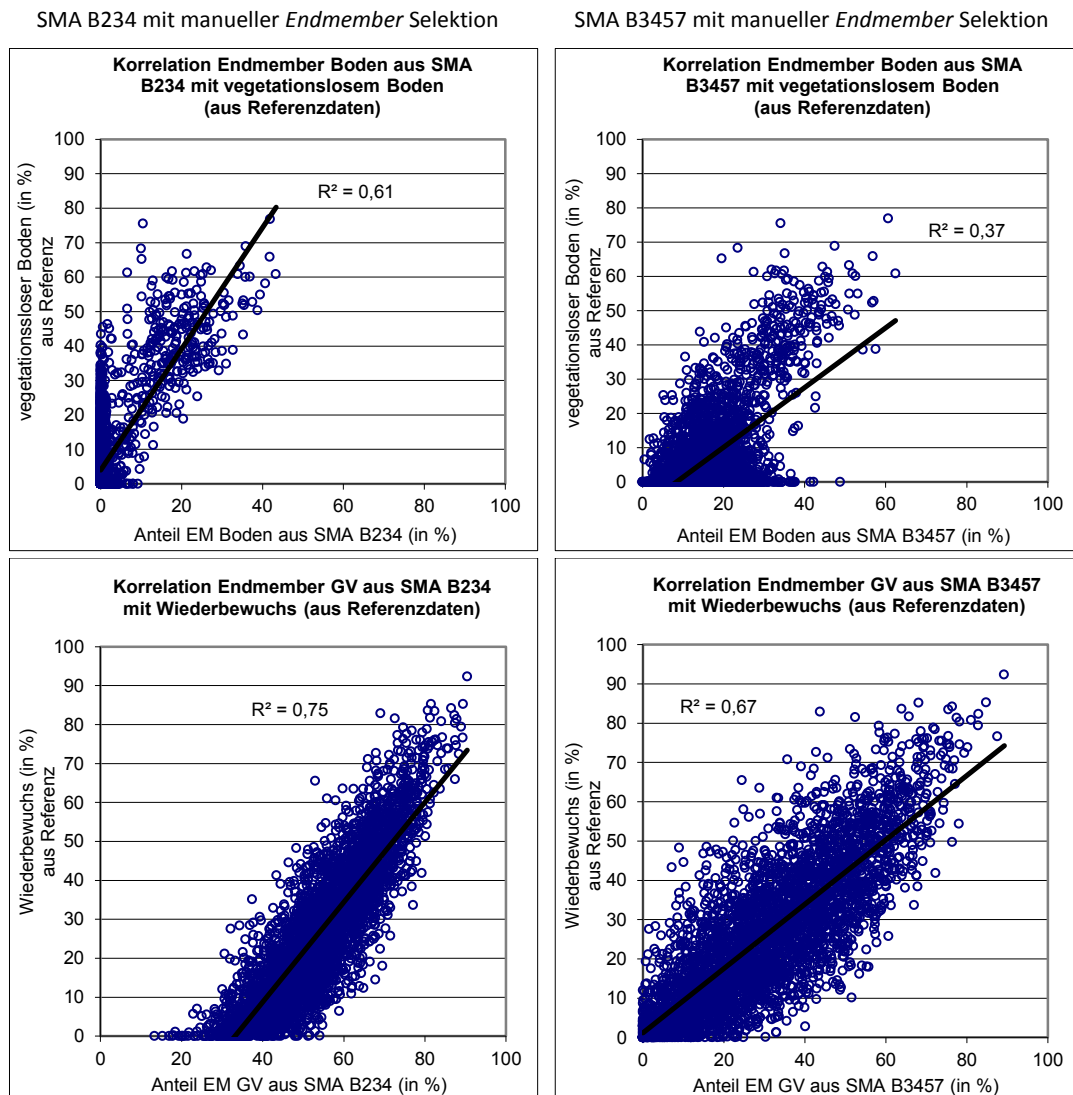


Abb. 28: Gegenüberstellung der Korrelationen der SMA Fraktionsbilder aus B234 und B3457 (Berechnung jeweils mit manueller *Endmember* Selektion)

In weiterer Folge ist zu überlegen, ob die Einbeziehung weiterer Dimensionen und Berechnung der Hauptkomponenten aus diesen als Feature herangezogen werden sollte. Anstatt dessen wird die Verwendung von nur zwei Inputbändern vorgeschlagen. Diese liefern vergleichbare bzw. zum Teil bessere Ergebnisse (vgl. Abb. 17) und würden im Zuge eines operationellen, flächendeckenden Monitorings weitere Arbeitsschritte und somit Zeit ersparen.

Die Fraktionsbilder aus dem SMA Workflow weisen sowohl in der Bandkombination 2,3,4 als auch in 3,4,5,7 einen geringeren Zusammenhang mit vegetationslosen Lücken auf, als jene aus der SMA mit manueller *Endmember* Auswahl. Da auch das Ergebnis aus der Bandkombination 3, 4 eine deutlich schlechtere Korrelation mit dieser Referenzklasse ergab, ist die Verwendung einer automatischen *Endmember* Ableitung mittels PPI in Bildern mit Wolken- und/oder Dunstbereichen zu hinterfragen. In diesem Fall empfiehlt sich eine manuelle *Endmember Selektion* oder die Verwendung von Bändern im nahen und mittleren Infrarot. In Bezug auf die Erkennung von Wiederbewuchs liefern die Fraktionsbilder aus dem SMA Workflow zwar gute Ergebnisse, diese liegen jedoch im Bereich der SMA mit manueller *Endmember* Selektion bzw. etwas darunter.

Aus den Fraktionsbildern der SMA mit manueller *Endmember* Selektion wurde in weiterer Folge der mNDFI berechnet. Von einer Berechnung dieses Index' auf Basis der Fraktionsbilder aus dem SMA Workflow wurde Abstand genommen, da diese weniger Informationsgehalt aufweisen. Die berechneten mNDFIs wiesen nur einen mäßigen Zusammenhang mit vegetationslosem Boden auf (siehe Abb. 29). Möglicherweise würde der Index in seiner ursprünglichen Form unter Einbeziehung des zusätzlichen *Endmembers* NPV (vgl. Kapitel 2.3.2.4) bessere Ergebnisse erzielen. Da anhand der Landsatzenne vom 13.12.2002 jedoch kein *Endmember* NPV abgeleitet werden kann, ist eine Berechnung des NDFI in seiner herkömmlichen Form nicht möglich. Somit wird zur Kartierung von degradierten Flächen aus Landsatdaten die Bodenfraktion der SMA empfohlen.




Abb. 29: Korrelationen des mNDFI aus Band 34 bzw. Band 234

Zusammenfassend eignet sich die SMA aus Band 3 und 4 am besten zur Kartierung von Degradation und Wiederbewuchs. Bei starken atmosphärischen Einflüssen in Band 3 kann alternativ dazu die Bandkombination 4 und 5 zur Kartierung von vegetationslosem Boden und Wiederbewuchs herangezogen werden, da die Bänder im Infrarotbereich unempfindlicher gegenüber atmosphärischen Bedingungen sind. Eine PCA zur Verringerung der Dimensionen erwies sich als wenig gewinnbringend und auch der mNDFI ist als Feature zur Degradationskartierung zu vernachlässigen.

5.2.4. Fazit

Aus den Korrelationen der Features mit den Referenzklassen vegetationsloser Boden und Revegetation können folgende Ergebnisse zusammengefasst werden:

- Bei der Verwendung von Originalbändern kann Band 3 zur Kartierung von vegetationslosen Lücken und Band 4 zur Detektion von Wiederbewuchs empfohlen werden. Einzig diese beiden Bänder können mit den Ergebnissen der SMA Features mithalten.
- In Bezug auf Indizes liefert der Ratioindex Band 7/Band 4 den stärksten Zusammenhang mit vegetationslosem Boden, während der GEMI am geeignetsten zur Kartierung von Wiederbewuchs ist. Die Korrelationsergebnisse der Indizes kommen jedoch nicht an jene der SMA Features heran, wodurch Indizes als Features zur Degradationskartierung eher zu vernachlässigen sind.
- Die SMA Fraktionsbilder erwiesen sich als beste Features in Zusammenhang mit der Degradationskartierung. Das *Spectral Unmixing* mit manueller *Endmember* Selektion von Band 3 und Band 4 lieferte die besten Ergebnisse; sowohl in Hinblick auf die Kartierung von vegetationslosen Lücken als auch von Wiederbewuchs. Als Alternative ist das *Spectral Unmixing* mit manueller *Endmember* Selektion von Band 4 und 5 zu empfehlen, da diese Bandkombination resistenter gegenüber atmosphärischen Einflüssen ist.

5.3. Ergebnisse der monotemporalen Degradationskartierung

Zur monotemporalen Degradationskartierung wurde die SMA aus Band 3 und 4 mit manueller *Endmember* Selektion herangezogen, da sich dieses Feature sowohl in Bezug auf die Korrelation mit vegetationslosem Boden als auch mit Wiederbewuchs, als jenes mit dem besten Zusammenhang zur Referenz erwies. Darüber hinaus wird die SMA auch in der Literatur zur Kartierung von Degradation empfohlen. Im Rahmen der Signaturanalyse (5.3.1), welche vor der Klassifikation durchgeführt wird, können bereits Erkenntnisse über die Verteilung und Trennbarkeit der Klassen gewonnen werden. Die eigentliche Klassifikation und deren Verifizierung (5.3.2) zeigt die Möglichkeiten und Probleme der Degradationskartierung der SMA Fraktionsbilder aus Landsatdaten auf. In diesem Zusammenhang ist zu erwähnen, dass im Zuge der monotemporalen Degradationskartierung keine Prozentverhältnisse analysiert wurden wie im vorangegangenen Kapitel, sondern die reinen Klassen betrachtet wurden.

5.3.1. Signaturanalyse

Die im Vorfeld der eigentlichen Klassifizierung durchgeführte Signaturanalyse erfolgt durch Streuungsdiagramme (vgl. Kapitel 4.4). Dadurch kann die Trennbarkeit der Klassen anhand der Fraktionsbilder beurteilt und in weiterer Folge die Klassengrenzen in Form von Schwellwerten festgelegt werden.

In Abb. 30 werden die Streuungsdiagramme in den verschiedenen Bandkombinationen (Fraktionen) dargestellt. **Intakter Wald** zeichnet sich dabei durch mäßige GV-Anteile im Bereich von 20-50 Prozent bei hohen Schattenanteilen von mehr als 50 Prozent aus. Der Bodenanteil von intaktem Wald liegt richtigerweise um 0. **Wiederbewuchs** weist durch die höhere Photosyntheseaktivität von junger Vegetation wesentlich höhere GV-Anteile (größer 50 Prozent) auf als intakter Wald. Durch die niedrige Vegetation ist der Schattenanteil geringer und liegt unter 50 Prozent. Durch die Streuung des Signals von umgebenden Bäumen kann dieser jedoch verfälscht werden. Der Bodenanteil von Wiederbewuchsflächen ist durch den zum Teil noch dünnen Bedeckungsgrad etwas höher als bei intaktem Wald und liegt im Bereich von 0-10 Prozent. Folglich kann intakter Wald von Wiederbewuchs am besten in der GV-Fraktion, sowie anhand der Schattenfraktion getrennt werden. In der Bodenfraktion ist die Differenzierung von intaktem Wald und Wiederbewuchs nicht möglich. Darüber hinaus kann in den Klassen Wiederbewuchs und intakter Wald eine hohe Korrelation zwischen Schatten- und GV-Anteilen beobachtet werden. **Degradierte Bereiche** weisen höhere Bodenanteile (größer 7 Prozent) auf als intakte Waldbereiche und Wiederbewuchs. Der GV- als auch der Schattenanteil liegen unter 60 Prozent. Degradierte Flächen können durch die Bodenfraktion klar von intaktem Wald und auch von Wiederbewuchs unterschieden werden. Problematisch ist die Differenzierung von aktuellen Wiederbewuchsflächen, welche noch höhere Bodenanteile aufweisen, zu Lücken mit geringem Zerstörungsgrad, da diese ähnliche Werte in der Bodenfraktion aufwiesen.

Auf Basis der erstellten Streuungsdiagramme (Abb. 30) und den Erkenntnissen daraus werden in weiterer Folge die Schwellwerte für die Klassifizierung festgelegt. Diese wurden für Degradation mit einem Bodenanteil >7 Prozent sowie einem GV-Anteil <55 Prozent festgelegt. Wiederbewuchs wird durch einen Bodenanteil von <25 Prozent, einem GV-Anteil von >50 Prozent sowie einem Schattenanteil von <50 Prozent bestimmt. Die verbleibenden Flächen repräsentieren intakten Wald bzw. intakte Vegetationsbereiche.

Verteilung von intaktem Wald, Regeneration und degradiertem Wald
Spectral Unmixing Band 34 (mit manueller *Endmember* Selektion)




Abb. 30: Verteilung von intaktem Wald, Wiederbewuchs und degradiertem Wald in den *Endmemberfraktionen* der SMA B34

5.3.2. Klassifikationsergebnisse

Das Ergebnis der Schwellwertklassifikation spiegelt im Wesentlichen die Erkenntnisse aus der Signaturanalyse wieder. So zeigt sich, dass kleine, vegetationslose Lücken mit einer Fläche von weniger als 3000m² anhand der SMA nur schwer erkannt werden, da das Signal der umgebenden Bedeckungsklassen sehr stark streut. Die Einbeziehung dieser kleinen Lücken durch die Anpassung der Schwellwerte führte zu Fehlklassifikationen in anderen Bereichen, wodurch davon Abstand genommen wurde. Straßen und Holzlagerplätze sind problemlos detektierbar; Fehlklassifikationen entstehen wiederum an den Randbereichen von Straßen und Holzlagerplätzen. Wiederbewuchs wird im Allgemeinen durch die Klassifikation gut beschrieben, doch auch hier entstehen an den Randbereichen zu intakten Waldbereichen Fehlklassifikationen, welche auf die spektrale Streuung oder auf die Geometrie zurückzuführen sind. Ein weiterer interessanter Aspekt ist der teilweise hohe Bodenanteil im Bereich von Sumpf- und Sumpfwäldern, welcher ebenfalls zu Fehlern in der Klassifikation führt. In Abb. 31 wird das Klassifikationsergebnis für den VHR Ausschnitt gezeigt, wobei Degradation in Rot, Wiederbewuchs in hellgrün und intakte Bereiche in dunkelgrün dargestellt sind.






Abb. 31: Klassifikationsergebnis (VHR Ausschnitt)

Abb. 32 zeigt einen Detailausschnitt aus dem Klassifikationsergebnis. Auch hier sind als Degradation klassifizierte Pixel in rot, Wiederbewuchs in hellgrün und intakte Bereiche in dunkelgrün dargestellt. Für einen besseren Vergleich wird derselbe Ausschnitt anhand der Landsatszene in der Kanalkombination RGB 543 dargestellt.



Ergebnis der Schwellwertklassifikation



Landsatszene RGB 543

Abb. 32: Klassifikationsergebnis (Detailausschnitt)

Anhand der Verifizierung mittels einer Konfusionsmatrix (dargestellt in Tab. 9) werden die bereits angesprochenen Schwierigkeiten im Zuge der Klassifizierung verdeutlicht. Die Berechnungsmethoden der Genauigkeiten wurden bereits in Kapitel 4.4 erläutert, worauf hiermit verwiesen wird.

Tab. 9: Konfusionsmatrix der monotemporalen Degradationsklassifizierung

		Referenzdaten				
		Intakter Wald	Wiederbewuchs	Degradation	Σ Pixel (aus Klassifikation)	Users accuracy
Klassifikation	Intakter Wald	138,00	21,00	16,00	175,00	78,86
	Wiederbewuchs	2,00	280,00	15,00	297,00	94,28
	Degradation	1,00	12,00	59,00	72,00	81,94
	Σ Pixel (aus Referenz)	141,00	313,00	90,00	544,00	
	Producers accuracy	97,87	89,46	65,56		

Overall accuracy: 87,68

Mean accuracy: 85,03

Anhand der *Producer's Accuracy* ist ersichtlich, dass die Klassifikation von intaktem Wald sehr gut mit den Referenzdaten übereinstimmt, auch Wiederbewuchs weist eine akzeptable Übereinstimmung auf. In Bezug auf die Degradationsflächen wurden nur etwa zwei Drittel der ausgewiesenen Lücken richtig erkannt.

Die *User's Accuracy* zeigt, dass die Klasse Wiederbewuchs am genauesten klassifiziert werden konnte. 94 Prozent der als Wiederbewuchs klassifizierten Pixel entsprechen tatsächlich dieser Klasse. Einige Flächen entsprechen den Referenzdaten nach Lücken, was auf die spektrale Streuung des Signals von umgebender Vegetation zurückzuführen sein könnte. Umgekehrt gehören als Degradation klassifizierte Pixel eigentlich der Klasse Wiederbewuchs an. Dennoch entsprechen 82 Prozent der als Degradation klassifizierten Pixel tatsächlich dieser Klasse. Intakte Waldbereiche weisen mit nur 79 Prozent die geringste *User's Accuracy* auf. Die falsch klassifizierten Pixel entsprechen in der Realität sowohl Wiederbewuchs- als auch Degradationspixel. Dies könnte auf die spektrale Streuung des Signals von umgebenden Bäumen und Waldrändern zurückzuführen sein. Darüber hinaus ist zu beachten, dass eine minimale geometrische Verschiebung zwischen den beiden Datensätzen eine negative Auswirkung auf das Verifizierungsergebnis haben kann.

In Bezug auf die gesamte Klassifikation ergibt sich eine mittlere Klassengenauigkeit (*Overall Accuracy*) von knapp 88 Prozent. Diese Angabe wird jedoch von der flächenmäßig stärker repräsentierten Klasse Wiederbewuchs beeinflusst. Die *Mean Accuracy*, welche die flächenmäßige Verteilung der Klassen berücksichtigt, ergibt eine mittlere Genauigkeit von 85 Prozent. Bei der Betrachtung dieser Konfusionsmatrix ist jedoch darauf hinzuweisen, dass nur relativ reine Flächen aus der Referenz für die Verifizierung herangezogen wurden (vgl. Kapitel 4.4).

Für die Verifizierung der Gesamtfläche wäre diese Methode jedoch nicht geeignet, da jede Verifizierungszelle jener Referenzklasse zugeordnet wird, welche den höchsten Prozentanteil aufweist. Wenn nun eine Zelle beispielsweise zu 50,5 Prozent aus Wiederbewuchs und zu 49,5 Prozent aus intaktem Wald besteht, wird diese Zelle

Wiederbewuchs zugeordnet. Wenn dieser Bereich im Zuge der Klassifikation jedoch als intakter Wald klassifiziert wird, wird dies als Fehlklassifikation gewertet. Somit ist für die Klassifikation der SMA ein *fuzzy* Ansatz mit den zu Grunde liegenden Prozentanteilen zu empfehlen.

5.4. Ergebnisse aus der Übertragung von *Endmember*

Die räumliche (5.4.1) sowie die zeitliche Übertragung (5.4.2) von *Endmemberwerten* zeigen, dass eine optimale radiometrische Anpassung der Daten Voraussetzung für eine Übertragung der *Endmember* ist.

5.4.1. Räumliche Übertragung

So zeigt sich im Rahmen des Versuchs der räumlichen Übertragung der *Endmember*, dass trotz eines ähnlichen Bildinhaltes in Form von degradierten Waldbereichen, Flächen mit Wiederbewuchs und intaktem tropischen Regenwald aufgrund der unterschiedlichen Radiometrie eine Übertragung der *Endmember* nur unzureichende Ergebnisse liefert. Da sich die beiden Datensätze räumlich nicht überlappen, ist eine radiometrische Anpassung, wie bereits in Kapitel 4.5 erwähnt, nicht sinnvoll. In Abb. 33 wird der spektrale Merkmalsraum von Band 3 und Band 4 (links) bzw. Band 4 und Band 5 (rechts) der Landsat-Szene von Kamerun dargestellt. Die Punkte stellen die übertragenen *Endmember* dar, während die Kreise die optimalen *Endmember* Positionen für die Kamerun-Szene symbolisieren.

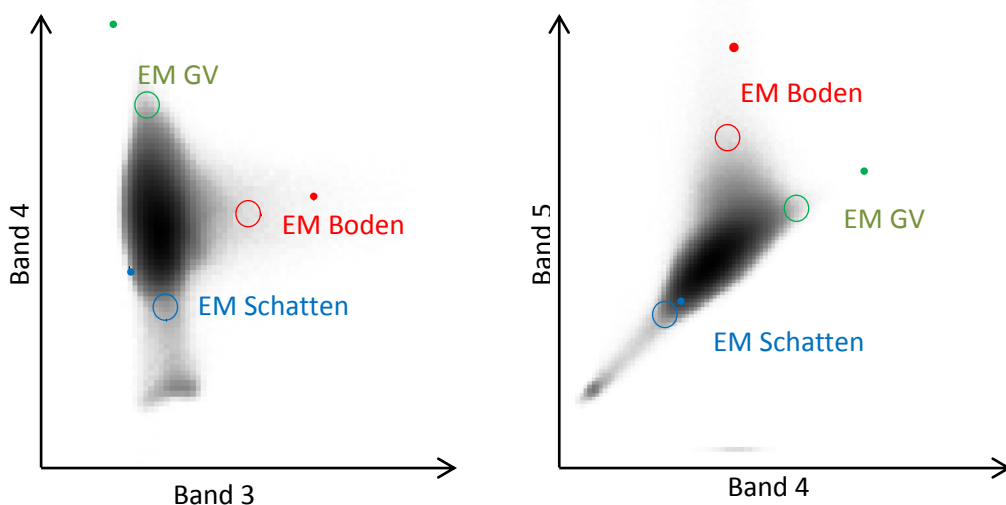




Abb. 33: Spektraler Merkmalsraum Band 3 und 4 bzw. Band 4 und 5 der Landsat-Szene vom 18.01.2011 in Kamerun

Anhand der Darstellung der Merkmalsräume zeigt sich, dass sich die *Endmember* von Band 3 und 4 nicht in den gewünschten Eckpunkten des spektralen Merkmalraumes befinden. Während die *Endmember* GV und Boden sich zu sehr außerhalb der Punktwolke befinden, liegt der *Endmember* Schatten zu weit im Zentrum. Dies führt zu einer Überbestimmung von Schatten, wodurch beispielsweise intakte Wälder sehr hohe Schattenteile bis 100 Prozent aufweisen und Wiederbewuchs nur schwer differenziert werden kann. Der Merkmalsraum von Band 4 und 5 liefert ein tendenziell ähnliches Bild, wenngleich der *Endmember* Schatten nahezu richtig liegt. Dennoch befinden sich die *Endmember* GV und Boden zu weit außerhalb der Punktwolke, um gute Fraktionsbilder zu generieren.


Die Berechnung der SMA mit den übertragenen *Endmemberwerten* und deren visuelle Betrachtung bestätigt diese Erkenntnis (Abb. 34), wobei die SMA aus Band 4 und 5 bessere Ergebnisse aufweist. Durch eine starke Aufspreizung der Bänder (Fraktionen) auf 20 Prozent des Inhaltes kann zwar eine Information aus den einzelnen Fraktionen geholt werden, die Nutzung des gesamten Spektrums von 100 Prozent im Falle einer SMA mit gut gewählten *Endmemberwerten* ist jedoch nicht möglich. Anhand der in Abb. 33 bestimmten optimalen *Endmember* für Band 3 und Band 4 (markiert durch Kreise, optimale *Endmember* liegen im Zentrum der Kreise) wird eine SMA berechnet. Diese erzielt klar bessere Ergebnisse als die SMA auf Basis der übertragenen *Endmember* (vgl. Abb. 34), zumal das gesamte Spektrum von 0-100 Prozent in den Fraktionsbildern ausgeschöpft wird und somit eine bessere Unterscheidung von Degradation zu Wiederbewuchs und intakten Bereichen gegeben ist.




Landsat RGB 543 (18.01.2011, Kamerun)




SMA aus B34 mit optimierten EM
(rot = Bodenfraktion, grün = GV-Fraktion,
blau = Schattenfraktion)




SMA aus B34 mit übertragenen EM
(rot = Bodenfraktion, grün = GV-Fraktion,
blau = Schattenfraktion)



SMA aus B45 mit übertragenen EM
(rot = Bodenfraktion, grün = GV-Fraktion,
blau = Schattenfraktion)



SMA 45 mit übertragenen EM
(optimierte Aufspaltung der Fraktionen,
rot = Bodenfraktion, grün = GV-Fraktion,
blau = Schattenfraktion)



SMA 45 mit übertragenen EM
(optimierte Aufspaltung der Fraktionen,
rot = Bodenfraktion, grün = GV-Fraktion,
blau = Schattenfraktion)

Abb. 34: SMA Ergebnisse mit räumlich übertragenen *Endmember*

5.4.2. Zeitliche Übertragung

Die zeitliche Übertragung der *Endmember* basiert, wie in Kapitel 4.5 bereits beschrieben, auf einer relativen radiometrischen Anpassung der Szene vom 18.02.2010 an die Referenzszene vom 13.12.2002. Durch die Berücksichtigung von Veränderungen zwischen den Datensätzen im Zuge dieser Kalibrierungsmethode kann eine bessere radiometrische Anpassung der Daten erreicht werden, wodurch die Übertragung der *Endmember* erleichtert wird. In folgender Abbildung (Abb. 35) sind die spektralen Merkmalsräume von Band 3 und 4 (links) bzw. Band 4 und 5 (rechts) dargestellt. Die Punkte symbolisieren wieder die übertragenen *Endmemberwerte*, während die Kreise die geeigneten *Endmemberpositionen* für die Szene aus dem Jahr 2010 darstellen.

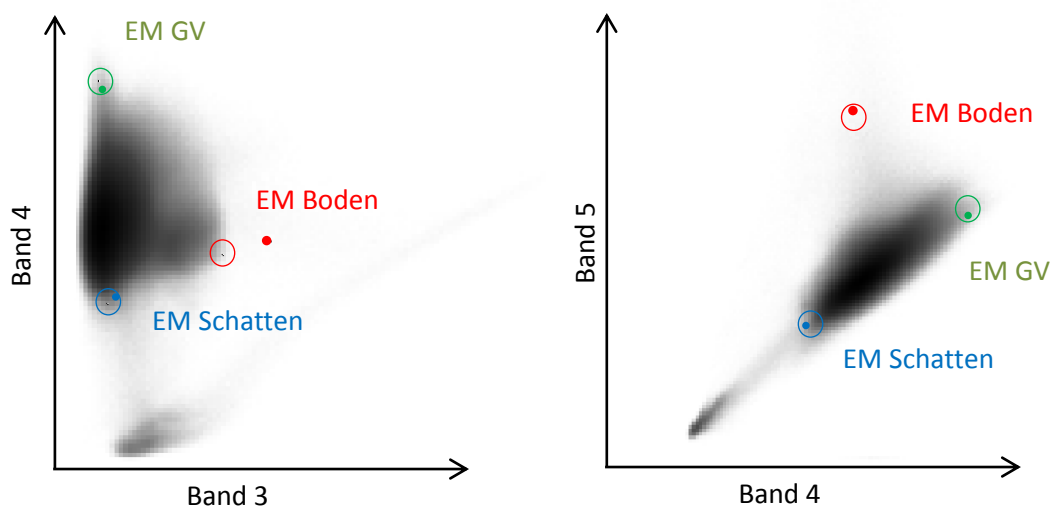



Abb. 35: Spektraler Merkmalsraum Band 3 und 4 bzw. Band 4 und 5 der Landsat Szene vom 18.02.2010 im Testgebiet der Republik Kongo


Aus der Betrachtung der spektralen Merkmalsräume kann bereits abgelesen werden, dass eine Übertragung der *Endmemberwerte* in Band 4 und 5 durchgeführt werden kann. In Bezug auf die Übertragung der *Endmember* von Band 3 und 4 stellt der *Endmember* Boden einen kritischen Faktor dar. Da dieser von der idealen *Endmemberposition* etwas nach außen versetzt liegt, könnte der *Endmember* Boden leicht unterrepräsentiert sein. Zurückzuführen ist dies auf den atmosphärischen Einfluss in Band 3. Die Ergebnisse der SMA werden in Abb. 36 dargestellt. Während anhand der SMA von Band 3 und 4 Lücken und vor allem kleinere Lücken in der Bodenfraktion nicht eindeutig festgestellt werden können, sind diese anhand der SMA aus Band 4 und 5 besser erkennbar indem sie höhere Bodenanteile aufweisen.



Landsat RGB 543 (18.01.2010, Kongo)



SMA B34 mit übertragenen EM
(rot = Bodenfraktion, grün = GV-Fraktion, blau = Schattenfraktion)



SMA B45 mit übertragenen EM
(rot = Bodenfraktion, grün = GV-Fraktion, blau = Schattenfraktion)

Abb. 36: SMA Ergebnisse mit zeitlich übertragenen *Endmember*

5.5. Ergebnisse der multitemporalen Betrachtung der Degradationsgebiete

Obwohl sich die SMA aus Band 3 und 4 als bestes Feature in Bezug auf die Korrelation mit den VHR Daten herausstellte, erschien die Verwendung von Band 4 und 5 im Hinblick auf die multitemporale Analyse stabiler, da diese Bänder resistenter gegenüber atmosphärischen Bedingungen sind (vgl. Kapitel 5.2). Dies zeigt auch der Vergleich der Standardabweichung von Band 3 (2,74) und Band 5 (6,65). Eine geringe Standardabweichung lässt dabei auf einen hohen atmosphärischen Einfluss schließen. Ein weiteres Argument für die Verwendung der SMA von Band 4 und 5 liefert das Ergebnis der zeitlichen Übertragung von Endmember nach vorangegangener radiometrischer Kalibrierung der Daten (vgl. Kapitel 5.4). Demnach ist eine Übertragung in der Bandkombination 4 und 5 erfolgreicher als in der Kombination von Band 3 und 4. Von der Verwendung der Originalbänder für eine temporale Analyse wurde ebenfalls Abstand genommen, da erste Tests zeigten, dass die Streuung des Signals über die Zeit trotz einer radiometrischen Anpassung der Daten zu stark ist und daher keine Entwicklungen anhand dieser Daten abgelesen werden können.

Die Ergebnisse der multitemporalen Analyse von Degradations- und Wiederbewuchsflächen bestätigen die Annahme aus Kapitel 4.6, dass Wiederbewuchs über einen längeren Zeitraum hinweg erkennbar ist als vegetationsloser Boden. Folglich kann die Betrachtung des Signals von Wiederbewuchs die Zeitspanne verlängern, innerhalb welcher Degradation festgestellt werden kann. In Kapitel 5.5.1 wird die zeitliche Entwicklung von vegetationslosen Lücken, welche im Dezember 2002 als solche erkannt wurden, anhand der Boden- sowie der GV-Fractionen untersucht. Im darauffolgenden Kapitel 5.5.2 wird die spektrale Entwicklung von Wiederbewuchs (Wiederbewuchs zum Zeitpunkt Dezember 2002) in der GV-Fraction über die Zeit betrachtet. Berechnet wurden die SMA Fraktionsbilder aus Band 4 und 5 der Landsatdaten (vgl. Kapitel 4.6). Als Vergleichswert wird jeweils das spektrale Signal von intakten Waldbereichen und somit der Idealzustand dargestellt.

5.5.1. Multitemporale Entwicklung von vegetationslosen Lücken

Betrachtung anhand der Bodenfraktion

Die zeitliche Entwicklung von Lücken (Lücken zum Zeitpunkt 13.12.2002) kann anhand von Abb. 37 betrachtet werden. Daraus ist ersichtlich, dass die Bodenfraktion der im Jahr 2002 abgeholzten Flächen in den Jahren vor dem Eingriff (1990-2001) einen ähnlichen spektralen Wert aufweist wie intakter Wald. Der Unterschied von wenigen Prozentwerten entsteht durch die spektrale Streuung der Signale. Da der Bodenanteil in den späteren Degradationsbereichen in der Szene vom 8.11.2001 noch sehr gering ist, ist davon auszugehen, dass ein Großteil der selektiven Abholzung im Zeitraum von November 2001 bis Juni 2002 (Aufnahme der VHR Szene) und weiter bis Dezember 2002

erfolgt ist. Diese Störung ist anhand der Zeitkurve durch einen enormen Anstieg in der Bodenfraktion um mehr als 45 Prozentwerte eindeutig erkennbar (vgl. auch Abb. 38). Der Bodenanteil steigt bis Februar 2003 weiter an und geht in den darauffolgenden Jahren stetig zurück. Das Signal in der Bodenfraktion erlaubt eine Erkennung der Lücken in einem Zeitraum von 3,5 Jahren. Nach 4,5 Jahren lässt sich die Störung nicht mehr von intakten Waldbereichen unterscheiden. Der starke Rückgang der Bodenanteile im Juli 2003 und der darauffolgende Wiederanstieg im November 2003 könnten auf die unterschiedliche Phänologie in diesen Monaten rückführbar sein. Auch die Schwankungen des spektralen Signals von intaktem Wald über die Zeit sind natürlicher Art. Des Weiteren wird im Diagramm (Abb. 37) der Standardfehler der Mittelwerte der Klassen angezeigt. Dieser ist in Bezug auf die Lücken größer, da diese um den Mittelwert stärker streuen als intakter Wald. Zurückzuführen könnte dies auf die Heterogenität von Lücken, ersten spärlichen Wiederbewuchs oder Bodennässe sein. Trotz der starken Streuung der Lücken in der Bodenfraktion ist eine klare Unterscheidung des Signals zu intaktem Wald möglich.




Abb. 37: Entwicklung des spektralen Signals von Lücken in der Bodenfraktion

Die Differenzen zwischen degradierten Bereichen und intaktem Wald werden zur Verdeutlichung in Abb. 38 gesondert dargestellt. Innerhalb eines Jahres nach dem Einschlag liegt die Differenz zwischen dem Mittelwert von intakten Waldbereichen und Lücken bei mehr als 45 Prozentwerten, im zweiten Jahr nach dem Einschlag bei etwa 20 Prozentwerten. Im Zeitraum von 2 bis 3,5 Jahre nach dem Einschlag liegt die Differenz bei 12 bis 22 Prozentwerten. Nach 4,5 Jahren ist keine Unterscheidung zwischen ehemaligen vegetationslosen Lücken und intaktem Wald in der Bodenfraktion mehr möglich. Die Schwankungen zwischen den Zeitpunkten könnten, wie bereits erwähnt, auf die unterschiedlichen phänologischen Stadien in den Aufnahmemonaten zurückzuführen sein.




Abb. 38: Differenz von Lücken und intaktem Wald in der Bodenfraktion

Um die bereits angesprochenen Einflüsse der Phänologie auf die Zeitreihe zu minimieren, wird in folgenden Abbildungen (Abb. 39, Abb. 40) die Entwicklung der Lücken auf Datensätze, welche von November bis Jänner aufgenommen wurden, beschränkt. Die Wahl dieser drei Monate kann damit begründet werden, dass der Referenzdatensatz im Dezember aufgenommen wurde und die Hinzunahme von +/- einem Monat ideal zur Reduzierung der phänologischen Einflüsse erscheint. Anhand dieser auf die Aufnahmemonate November bis Jänner beschränkten Daten ist ein klarer Verlauf der spektralen Entwicklung von Lücken gegeben (Abb. 39). Während die Bodenfraktion vor dem Einschlag mit den Anteilen von intaktem Wald vergleichbar ist, steigt diese im Zeitraum von November 2001 bis Dezember 2002 stark an und bleibt für ein Jahr auf diesem Niveau. Aufgrund des Wiederbewuchses sinken die Bodenanteile in den darauffolgenden Jahren kontinuierlich. Fünf Jahre nach dem Einschlag weisen die Flächen in der Bodenfraktion wieder dieselben Werte auf als intakter Wald. Die Differenz der Mittelwerte (Abb. 40) zwischen Lücken und intaktem Wald in diesen Monaten bestätigt diesen klaren Trend.




Abb. 39: Entwicklung des spektralen Signals von Lücken in der Bodenfraktion unter Berücksichtigung der Phänologie (Zeitreihe mit Daten aus den Monaten November, Dezember, Jänner)




Abb. 40: Differenz von Lücken und intaktem Wald in der Bodenfraktion unter Berücksichtigung der Phänologie
(Zeitreihe mit Daten aus den Monaten November, Dezember, Jänner)

Betrachtung anhand der GV-Fraktion

Da Lücken anhand der Bodenfraktion nur einen Zeitraum von etwa 3,5 Jahren erkennbar sind, wird nun versucht das spektrale Verhalten der Wiederbewuchs auf diesen Flächen anhand der GV-Fraktion zu untersuchen. Bei der Betrachtung der Datensätze in Abb. 41 zeigt sich, dass die GV-Anteile in den Jahren vor dem Einschlag deutlich höher sind als intakter Wald. Dies könnte wiederum auf die spektrale Streuung der Signale zurückzuführen sein. Nach dem Holzeinschlag gehen die GV-Anteile in den Lücken deutlich zurück und liegen für weniger als ein halbes Jahr unter den Werten von intaktem Wald. Im zweiten Jahr nach dem Einschlag sind die GV-Anteile der degradierten Flächen mit jenen von intaktem Wald vergleichbar. In diesem Zeitraum werden die Flächen durch erste Pionierpflanzen wiederbewachsen, eine vollkommene Abdeckung des Bodens ist noch nicht gegeben. Eine verlässliche Unterscheidung der Lücken von intaktem Wald anhand der GV Fraktion kann nach drei Jahren erfolgen, da der Wiederbewuchs erst ab diesem Zeitpunkt deutlich höhere GV-Anteile als intakter Wald aufweist. Diese hohen GV-Anteile sind auf die hohe Photosyntheseaktivität von

junger Vegetation zurückzuführen sowie auf den geringen Schattenwurf der noch niedrigen Pflanzen. Der Boden ist zu diesem Zeitpunkt nahezu vollständig von Pflanzen bedeckt, wodurch auch die Bodenfraktion nach 3,5 Jahren keine Unterscheidung von degradierten Bereichen zu intaktem Wald mehr erlaubt. Im Diagramm werden wiederum die Standardfehler der Mittelwerte angegeben. In Bezug auf intakten Wald sind diese in der GV-Fraktion deutlich höher als bei der Bodenfraktion, da intakte Vegetation in der GV-Fraktion wesentlich stärker streut. Die Schwankungen der Mittelwerte von Lücken und intaktem Wald könnten wiederum auf die jahreszeitlichen Veränderungen zurückzuführen sein, da die Schwankungen in beiden Klassen in ihrer Tendenz ähnlich sind.




Abb. 41: Entwicklung des spektralen Signals von Lücken in der GV-Fraktion

Die Differenzen in der GV-Fraktion erscheinen drei Jahre nach der Abholzung jedoch nur unwesentlich höher als vor dem Einschlag. Um dies besser untersuchen zu können, werden die Differenzen der Mittelwerte beider Klassen gesondert in Abb. 42 dargestellt. Dabei zeigt sich, dass die GV-Fraktion vor dem Einschlag um etwa 4 bis 12 Prozentwerte höher war als jene von intaktem Wald, während die Differenz drei Jahre nach dem Abholzungsereignis auf über 17 Prozent ansteigt. Somit kann eine Unterscheidung des Wiederbewuchses anhand der GV-Fraktion erfolgen, wenngleich die Unterschiede zum Zustand vor dem Einschlag gering sind. Die Schwankungen in den Differenzen könnten, wie bereits mehrmals erwähnt, auf die Phänologie der Vegetation zurückzuführen sein.




Abb. 42: Differenz von Lücken und intaktem Wald in der GV-Fraktion

Auch in Zusammenhang mit der GV-Fraktion zur Betrachtung von Lücken wird versucht, die phänologischen Schwankungen durch die Betrachtung der Monate November bis Jänner zu reduzieren. Die Darstellung des spektralen Signals in diesen Monaten (Abb. 43) zeigt, dass die verbleibenden Schwankungen von intaktem Wald als auch der späteren Lücken nun wesentlich geringer sind. In Abb. 44 werden die Differenzen zwischen Lücken und intaktem Wald in der GV-Fraktion nochmals dargestellt. Die Interpretation der Diagramme deckt sich mit den Aussagen in Bezug auf Abb. 41 und Abb. 42.




Abb. 43: Entwicklung des spektralen Signals von Lücken in der GV-Fraktion unter Berücksichtigung der Phänologie




Abb. 44: Differenz von Lücken und intaktem Wald in der GV-Fraktion unter Berücksichtigung der Phänologie
(Zeitreihe mit Daten aus den Monaten November, Dezember, Jänner)

5.5.2. Multitemporale Entwicklung von Wiederbewuchs

Die Betrachtung des Wiederbewuches (Wiederbewuchs zum Zeitpunkt 13.12.2002) sollte darüber Aufschluss geben, wie lange eine Störung anhand von Wiederbewuchs erkennbar ist und nach wie vielen Jahren sich dieses Signal in der GV-Fraktion wieder mit jenem von intaktem Wald deckt. Bei der visuellen Betrachtung der Landsatdaten als auch in der Zeitkurve (Abb. 45) ist ersichtlich, dass die Wiederbewuchsflächen bereits im Jahr 1990 als solche erkennbar sind. Der GV-Anteil dieser Flächen durchläuft in der Zeitspanne von 1990 bis 2010 zwar zahlreiche Schwankungen, bleibt jedoch stets deutlich über jenem von intaktem Wald. Dies ist auch an Abb. 46 mit den Mittelwertdifferenzen klar ersichtlich. Folglich kann die Frage aufgeworfen werden, ob es sich bei diesen Flächen tatsächlich um Wiederbewuchsflächen oder um natürliches Grasland handelt. Landwirtschaftliche Flächen erscheinen unwahrscheinlich, da keine dementsprechenden Strukturen wie Straßen, Wege oder Siedlungen anhand der hochauflösenden Daten erkennbar sind. Sofern es sich bei den Flächen tatsächlich um Wiederbewuchs handelt, kann aufgrund der bisherigen Erkenntnisse die Aussage getroffen werden, dass die Holzentnahme auf diesen Flächen spätestens im Jahr 1988 erfolgt sein muss, da Störungen in der GV-Fraktion erst 3 Jahre nach dem Einschlag detektiert werden können (vgl. Kapitel 5.5.1). Ausgehend davon, wäre Wiederbewuchs für mehr als 20 Jahre durch eine erhöhte GV-Fraktion von intaktem Wald differenzierbar.




Abb. 45: Entwicklung des spektralen Signals von Wiederbewuchs in der GV-Fraktion




Abb. 46: Differenz von Wiederbewuchs und intaktem Wald in der GV-Fraktion

Die Betrachtung der phänologisch ähnlichen Monate November, Dezember und Jänner (Abb. 47, Abb. 48) glättet den spektralen Verlauf der GV-Anteile von vermeintlichen Wiederbewuchsflächen zwar, lässt jedoch ebenso keinen klaren Trend in der Entwicklung erkennen. Einerseits ist ab dem Jahr 2005 ein stetiger Rückgang in der GV-Fraktion zu beobachten, welche auf eine Entwicklung der Flächen zu Sekundärwald hindeuten könnte. Andererseits waren im Laufe der vorangegangenen 15 Jahre mehrere Tendenzen eines Rückganges in der GV-Fraktion zu beobachten, welche in einem erneuten Anstieg der GV-Anteile resultieren. Folglich können keine Aussagen über eine Entwicklung der Flächen zu Sekundärwald anhand der vorliegenden Daten getroffen werden.




Abb. 47: Entwicklung des spektralen Signals von Wiederbewuchs in der GV-Fraktion unter Berücksichtigung der Phänologie
(Zeitreihe mit Daten aus den Monaten November, Dezember, Jänner)




Abb. 48: Differenz von Wiederbewuchs und intaktem Wald in der GV-Fraktion unter Berücksichtigung der Phänologie

6. Zusammenfassung und Ausblick

Ziel dieser Arbeit war es, Features zur Degradationskartierung im tropischen Regenwald in der Republik Kongo zu untersuchen. Die Erkenntnisse dieser Arbeit flossen in das REDD Extension Projekt ein. In diesem führte *Joanneum Research* unter anderem eine Degradationskartierung für jeweils ein Testgebiet in der Republik Kongo und Gabun durch. Darüber hinaus wird die multitemporale Analyse dieser Arbeit im REDDAF (*Reducing Emissions from Deforestation and Degradation in Africa*) Projekt von *Joanneum Research* auf ein Testgebiet in Kamerun umgelegt, woraus weitere Erkenntnisse über die spektrale Entwicklung von Degradationserscheinungen über die Zeit gewonnen werden.

Zusammenfassend können nun folgende wesentliche Erkenntnisse aus dieser Arbeit angeführt werden:

- Im Rahmen der Literaturrecherche stellte sich heraus, dass die Methoden zur Degradationskartierung vielfach zur Erkennung von selektiver Abholzung entwickelt und getestet wurden. Dies ist auch Priorität im Rahmen von REDD. Ein Großteil der Studien zu dieser Thematik wurde im brasilianischen Amazonasgebiet durchgeführt. Die spektrale Entmischung von mittel auflösenden Daten (meist Landsat) gilt bei diesen Studien als bevorzugtes Feature. Um den räumlichen Kontext miteinzubeziehen und natürliche von anthropogenen Schäden unterscheiden zu können, werden Kontextanalysen auf die Features aufgebaut.
- Die Ergebnisse des praktischen Teils dieser Arbeit ergeben, dass die Reflexion der Landsatbänder 3 und 4 bzw. die spektrale Entmischungsanalyse (SMA) die besten Features zur Degradationskartierung in der Republik Kongo sind. Während für die Kartierung von Degradation Band 3 sowie die Bodenfraktion der SMA aus Band 3 und 4 mit manueller *Endmember* Selektion zu bevorzugen sind, empfiehlt sich zur Kartierung von Wiederbewuchsflächen Band 4 als auch die GV-Fraktion der SMA. Indizes sind als Features zur Degradationskartierung eher zu vernachlässigen.
- Features können die Erkennbarkeit von Degradation im Vergleich zu den Originalbändern nur geringfügig (SMA) bis nicht verbessern (Indizes). In weiterer Folge stellt sich die Frage, ob die Verwendung der Reflexion aus den Band 3 und 4 gegenüber der SMA rationeller wäre. Bei der Durchführung der multitemporalen Analyse stellte sich jedoch heraus, dass die SMA im Vergleich zur Reflexion einzelner Bänder stabiler ist. Diese Stabilität der SMA resultiert aus der Bestimmung der *Endmember* durch die Form und Lage der Punktwolke. Somit werden die Fraktionsanteile durch deren relative Lage zu den *Endmember* bestimmt. Eine

Verschiebung der Reflexionswerte verändert zwar die Form und Position der Punktwolke, nicht aber die Anteilswerte der einzelnen Pixel.

- Die monotemporale Klassifizierung zeigte, dass durch eine Schwellwertklassifikation der SMA größere vegetationslose Flächen und Wiederbewuchs klassifiziert werden können, kleinere Lücken können kaum kartiert werden. Folglich ist die Anwendung eines Klassifikationsverfahrens umso erfolgreicher, je intensiver die Degradation ist. Ein alternativer Ansatz wäre eine *Soft Classification* mit fließenden Klassengrenzen. Damit würden die Anteile der einzelnen Endmember Fraktionen berücksichtigt werden und bereits bestehende Information nicht verloren gehen.
- Für eine räumliche oder zeitliche Übertragung von *Endmember* ist eine optimale radiometrische Übereinstimmung der Daten erforderlich. Die Übertragung von *Endmember* aus Bändern im sichtbaren Bereich kann durch atmosphärische Einflüsse beeinträchtigt werden.
- Die multitemporale Analyse der vegetationslosen Lücken ergab, dass diese innerhalb von 3,5 Jahren in der Bodenfraktion der SMA erkennbar sind. Die Einbeziehung von Wiederbewuchs als Hinweis auf eine vorangegangene Degradation erwies sich als sinnvoll, da das Signal von Wiederbewuchs für einen längeren Zeitraum präsent ist als jenes von vegetationslosen Lücken. Die Kartierung von Wiederbewuchs ist erst 3 Jahre nach dem Holzeinschlag in der GV-Fraktion möglich und für mindestens 7 Jahre nach dem Einschlag von intakten Bereichen differenzierbar.
- Die Betrachtung von Wiederbewuchsflächen über die Zeit (19 Jahre) ermöglichte keine Aussage über den Zeitraum, in dem sich Wiederbewuchs zu Sekundärwald entwickelt. Zudem konnte nicht mit Sicherheit festgestellt werden, ob es sich bei besagten Flächen tatsächlich um Wiederbewuchs handelt und nicht um ständiges Grasland. Um diese Frage zu klären, wären Felddaten von Vorteil.

Auf Basis der vorliegenden Arbeit und der Erkenntnisse daraus werden von *Joanneum Research* in Zusammenhang mit REDD Projekten weitere Studien aufgebaut. So wird auf den Erkenntnissen der multitemporalen Betrachtung der spektralen Entwicklung von Degradations- und Wiederbewuchsflächen im Rahmen des REDDAF (*Reducing Emissions from Deforestation and Degradation in Africa*) Projektes eine multitemporale Klassifikation aufgebaut, um Flächen aktueller und früherer Degradation kartieren zu können.

Neben den bereits angesprochenen Ergänzungsmöglichkeiten wäre für zukünftige Anwendungen eine Alternative zu den Landsatdaten zu überdenken. Die streifenartigen Datenlücken in Landsat 7 ETM+ Daten ab Mai 2003, hervorgerufen durch den Ausfall des Scan Line Correctors, stellen einen einschränkenden Faktor bei der Verwendung dieser Daten dar (vgl. auch Kapitel 3.2). Darüber hinaus könnte mit einer höheren räumlichen Auflösung der Daten die Detektion kleinerer Lücken verbessert werden. Geeignet für ein solches Monitoring wären, neben den bereits im REDD Extension Projekt angewandten

SPOT und ALOS AVNIR Daten, Sentinel-2 Daten. Diese zukünftige Satellitenmission sollte 2014 in Betrieb gehen und optische Daten im sichtbaren sowie im nahen und mittleren Infrarotbereich mit einer räumlichen Auflösung von 10m bzw. 20m liefern. Mit zwei Satelliten soll eine Wiederholrate von fünf Tagen im Äquatorbereich erzielt werden, wodurch die Verfügbarkeit von wolkenfreien optischen Daten über den Tropen verbessert wird (ESA 2012).

Eine weitere Möglichkeit zur Verbesserung der Degradationskartierung in den Tropen könnte durch die Einbeziehung von SAR Daten erreicht werden, da die für tropische Regionen häufige Wolkenbedeckung einen einschränkenden Faktor für die Degradationskartierung mit optischen Daten darstellt. Dabei würden sich TERRA SAR X und Cosmo SkyMed Daten, welche über eine räumliche Auflösung von 5m, als Ergänzung zu optischen Daten anbieten. Durch die Stereo und InSAR Kapazität haben diese Daten auch das Potential für eine dreidimensionale Kartierung der Überschirmung. Auch LiDAR Daten wären zur Ergänzung optischer Daten in Betracht zu ziehen. Zumal anhand dieser Daten Biomasseabschätzungen und Berechnungen des Kohlenstoffbestandes erleichtert werden. Diese Parameter sind vor allem in Kontext von REDD+ von Bedeutung. Für ein operationelles Monitoring ist eine Verwendung dieser Daten zu kostenintensiv, da diese durch Befliegungen aufgenommen werden müssten.

Quellenverzeichnis

Al Mohamed, I., 2011: Erfassung und Bewertung von degradierten Böden mit Fernerkundung und GIS in Nordwest-Syrien. Dissertation an der Technischen Universität Dresden, Fakultät für Forst-, Geo- und Hydrowissenschaften, S. 63-73.

Asner, G.P., Keller, M., Pereira, R., Zweede, J.C., 2002: Remote sensing of selective logging in Amazonia. Assessing limitations based on detailed field observations, Landsat ETM+, and textural analysis. *Remote Sensing of Environment*, 80, S. 483-496.

Asner, G.P., Hicke, J.A., Lobell, D.B., 2003: Per-pixel analysis of forest structure: Vegetation Indices, Spectral Mixture Analysis and Canopy Reflectance Modeling. *Remote sensing of forest environments: Concepts and case studies*, S. 209-254.

Asner, G.P., Keller, M., Pereira, R. Jr., Zweede, J.C., Silva, J.N.M., 2004: Canopy damage and recovery after selective logging in Amazonia: Field and satellite studies. *Ecological Applications*, 14, S. 280-298.

Asner, G.P., Knapp, D.E., Broadbent, E.N., Oliveira, P.J.C., Keller, M., Silva, J.N., 2005a: Selective Logging in the Brazilian Amazon. *Science*, 310, S. 480-482.

Asner, G.P., Knapp, D.E., Cooper, A.N., Bustamente, M.M.C., Olander, L.P., 2005b: Ecosystem Structure throughout the Brazilian Amazon from Landsat Observations and Automated Spectral Unmixing. *Earth Interactions*, 9(7), 31 S.

Asner, G.P. 2005c: The Carnegie Landsat Analysis System.

http://dge.stanford.edu/labs/asnerlabhighlights/amazon_logging2/clas.pdf

(Zugriff 20.07.2012)

Asner, G.P., Knapp, D.E., Balaji, A., Páez-Acosta, G., 2009: Automated mapping of tropical deforestation and forest degradation: CLASlite. *Journal of Applied Remote Sensing*, 3, 24 S.

Boardman, J.W., Kruse, F.A., Green, R.O., 1995: Mapping target signatures via partial unmixing of AVIRIS Data. *Summaries of JPL Airborne Earth Science Workshop*.

Brandão Jr., A.O. und Souza Jr., C.M., 2006: Mapping unofficial roads with Landsat images: a new tool to improve the monitoring of the Brazilian Amazon rainforest. *International Journal of Remote Sensing*, 27(10), S. 177-189.

Cochrane, M. A. und Souza Jr., C.M., 1998: Linear mixture model classification of burned forests in the Eastern Amazon. *International Journal of Remote Sensing*, 19 (17), S. 3433-3440.

De Fries, R., Achard, F., Brown, S., Herold, M., Murdiyarto, D., Schlamadinger, B., De Souza Jr., C., 2006: Reducing Greenhouse Gas Emissions from Deforestation in Developing Countries: Considerations for Monitoring and Measuring. Report of the Global Terrestrial Observing System (GTOS), GOF-C-GOLD report 26. www.fao.org/gtos/pubs.html (Zugriff 20.07.2012)

De Wasseige C., und Defourny, P., 2004: Remote Sensing of selective logging impact for tropical forest management. *Forest Ecology and Management*, 188, S. 161-173.

Dutra, L.V., Scofield, G.B., Neta, S.R.A., Negri, R.G., Freitas, C.C., Andrade, D., 2009: Land Cover Classification in Amazon using Alos Palsar Full Polarimetric Data, Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, S. 7259-7264.

ERDAS, 2012: Imagine Subpixel Classifier vs. Linear Spectral Unmixing. White Paper. http://geospatial.intergraph.com/libraries/white_papers/imagine_subpixel_classifier%E2%84%A2_vs_linear_spectral_unmixing.sflb.ashx (Zugriff 20.07.2012)

ESA 2012: ESA's Sentinel satellites. http://www.esa.int/esaLP/SEM097EH1TF_LPgmes_0.html (Zugriff 20.7.2012)

Forests Monitor, 2012: Observation de la mise en application de la loi forestière et de la gouvernance en République du Congo. Annual Report No 1: 2007-2008. http://www.forestsmonitor.org/uploads/2e90368e95c9fb4f82d3d562fea6ed8d/REM_Rpublic_of_Congo_jan_07_apr_08.pdf (Zugriff 20.07.2012)

Gerwing, J.J., 2002: Degradation of forests through logging and fire in the eastern Brazilian Amazon. *Forest Ecology and Management*, 157, S. 131-141.

GeoEye, 2012: Ikonos. www.geoeye.com/CorpSite/products-and-services/imagery-sources/Default.aspx (Zugriff 20.07.2012)

GOF-C-GOLD, 2011: A sourcebook of methods and procedures for monitoring and reporting anthropogenic greenhouse gas emissions and removals caused by deforestation, gains and losses of carbon stocks in forests remaining forests, and forestation. GOF-C-GOLD Report version COP17-1. <http://www.gofc-gold.uni-jena.de/redd/> (Zugriff: 20.07.2012)

Haas, S.A., 2009: Monitoring Forest Degradation for REDD in Cameroon. Diplomarbeit an der Technischen Universität Karlsruhe, 115 S.

- Healey, S.P., Cohen, W.B., Zhiqiang, Y., Krankina, O.N., 2005: Comparison of Tasseled Cap-based Landsat data structures for use in forest disturbance detection. *Remote Sensing of Environment*, 97, S. 301-310.
- Hirschmugl, M., 2011: Draft outline of degradation area mapping efforts. GSE Forest Monitoring REDD Extension Services. Unpublizierter Projektbericht. 15 S.
- Huang, C., Wylie, B., Yang, L., Homer, C., Zylstra, G., 2002: Derivation of a tasseled cap transformation based on Landsat 7 at satellite reflectance.
<http://landcover.usgs.gov/pdf/tasseled.pdf> (Zugriff 20.07.2012)
- Hussin, Y.A., Atmopawiro, V.P., 2004: Sub-pixel and maximum likelihood classification of Landsat ETM+ images for detecting illegal logging and mapping tropical rain forest cover types in Berau, East Kalimantan, Indonesia.
https://www.itc.nl/library/Papers_2004/peer_conf/hussin_sub.pdf (Zugriff 20.07.2012)
- Jackson, R.D., Huete, A.R., 1991: Interpreting vegetation indices. *Preventive Veterinary Medicine*, 11, S. 185-200.
- Kellndorfer, J., Shimada, M., Rosenqvist, A., Walker, W., Kirsch, K., Nepstad, D., Laporte, N., Stickler, C., Lefebvre, P., 2007: New Eyes in the Sky: Cloud-Free Tropical Forest Monitoring for REDD with the Japanese Advanced Land Observing Satellite (ALOS). United Nations Framework Convention on Climate Change. Conference of the Parties (COP), Thirteenth session, 3-14 December 2007, Bali, Indonesien.
- Koltunov, A., Ustin, S.L., Asner, G.P., Fung, I., 2009: Selective logging changes forest phenology in the Brazilian Amazon: Evidence from MODIS image time series analysis. *Remote Sensing of Environment*, 113, S. 2431-2440.
- Laporte, N.T., Stabach, J.A., Grosch, R., Lin, T.S., Goetz, S.J., 2007: Expansion of industrial logging in Central Africa. *Science* 316(5830), S. 1451.
- Le Toan, T., Beaudoin, A., Riom, J., Guyon, D., 1992: Relating forest biomass to SAR Data. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), S. 403-411.
- Le Toan, T., Quegan, S., Davidson, M., Balzter, H., Paillou, P., Papathanassiou, K., Plummer, S., Rocca, F., Saatchi, S., Shugart, H. and Ulander, L., 2011: The BIOMASS Mission: Mapping global forest biomass to better understand the terrestrial carbon cycle. *Remote Sensing of Environment*, 115, S. 2850-2860.
- Lillesand, T., Kiefer, R., 1994: *Remote sensing and image interpretation* (third edition). John Wiley & Sons, Inc., New York, S. 612-613.

Lucas R.M., Honzak, M., Curran, P.J., Foody, G.M., Nguele, D.T., 2000: Characterizing tropical forest regeneration in Cameroon using NOAA AVHRR data. *International Journal of Remote Sensing*, 21(15), S. 2831-2854.

Matricardi, E.A.T., Skole, D.L., Chomentowski, W., Cochrane, M.A., 2001. Multi-Temporal Detection and Measurement of Selective Logging in the Brazilian Amazon Using Landsat Data. http://www.goes.msu.edu/publications/pdfs_ra/RA03-01.pdf (Zugriff 20.07.2012)

Matricardi, E.A.T., Skole, D.L., Cochrane, M.A., Qi, J., Chomentowski, W., 2005: Monitoring Selective Logging in Tropical Evergreen Forests Using Landsat: Multitemporal Regional Analyses in MatoGrosso, Brasil. *Earth Interactions*, 9(24), 24 S.

Matricardi, E.A.T., Skole, D.L., Pedlowski, M.A., Chomentowski, W., Fernandes, L.C., 2010: Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. *Remote Sensing of Environment*, 114, S. 1117-1129.

Monteiro, A.L., Souza, C.M., Barreto, P., 2003: Detection of logging in Amazonian transition forests using spectral mixture models. *International Journal of Remote Sensing*, 24(1), S. 151-159.

NASA, 2012: About Landsat. <http://landsat.gsfc.nasa.gov/about/landsat4.html> (Zugriff 20.07.2012)

Negron-Juarez, R. I., Chambers, J. Q., Marra, D. M., Ribeiro, G. H. P. M., Rifai, S. W., Higuchi, N., Roberts, D., 2011: Detection of subpixel treefall gaps with Landsat imagery in Central Amazon forests. *Remote Sensing of Environment*, 115, S. 3322-3328.

Nepstad, D., Veríssimo, A., Alencar, A., Nobre, C., Lima, E., Lefebvre, P., Schlesinger, P., Potter, C., Moutinho, P., Mendoza, E., Cochrane, M., Brooks, V., 1999: Large-scale impoverishment of Amazonian forests by logging and fire. *Nature*, 398, S. 505-508.

Niemeyer, I., 2009: Digitale Bildverarbeitung. Vorlesungsunterlagen am Institut für Markscheidewesen und Geodäsie der TU Bergakademie Freiberg. http://tu-freiberg.de/fakult3/mage/geomonitoring/teaching/ss2009/slides/fe2_ss09_71.pdf (Zugriff 20.07.2012)

Olander, L. P., Gibbs, H.K., Steininger, M., Swenson, J.J., Murray, B.C., 2008: Reference szenarios for deforestation and forest degradation in support of REDD: a review of data and methods. *Environmental Research Letters*, 3, 11 S.

Oliveira, P.J.C., Asner, G.P., Knapp, D.E., Almeyda, A., Galván-Gildemeister, R., Keene, S., Raybin, R.F., Smith, R.C., 2007: Land-Use Allocation Protects the Peruvian Amazon. *Science*, 317, S. 1233-1236.

Oczipka, M., 2007: Objektbasierte Klassifizierung hochauflösender Daten in urbanen Räumen unter besonderer Berücksichtigung von Oberflächenmodellen. Dissertation an der Freien Universität Berlin, S. 83-91.

Parker, Ch., Mitchell, A., Trivedi, M., Mardas, N., [Hrsg.], 2009: The Little REDD Book. www.globalcanopy.org/sites/default/files/lrb_en.pdf (Zugriff 20.07.2012)

Penman, J., Gytarsky, M., Hiraishi, T., Krug, T., Kruger, D., Pipatti, R., Buendia, L., Miwa, K., Ngara, T., Tanabe, K., Wagner, F., [Hrsg.], 2003: IPCC Report on Definitions and Methodological Options to Inventory Emissions from Direct Human Induced Degradation of Forests and Devegetation of Other Vegetation Types. <http://www.ipcc-nggip.iges.or.jp/public/gpglulucf/degradation.html> (Zugriff 20.07.2012)

Pierce, L, Barros, O., Dobson, C.M., 2002: Detection of Selective Logging and Regrowth with CBERS CCD Imagery. Geoscience and Remote Sensing Symposium, IGARSS'02.2002 IEEE International 4, S. 2072-2074.

Priemer, M., Lohmann P., 2001: Untersuchungen zur Anwendbarkeit der linearen spektralen Entmischung beim Bestandsmonitoring von Waldflächen. Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung, 10, S.441-450.

Qi, J., Wang, C. Matricardi, E., Skole, D., 2002: Improved Selective Logging Detection with Landsat Images in Tropical Regions. Geoscience and Remote Sensing Symposium, 2002. IGARSS'02.2002 IEEE International 4, S. 2078-2080.

Roy, D.P., Jin, Y., Lewis, P.E., Justice, C.O., 2005: Prototyping a global algorithm for systematic fire affected area mapping using MODIS time series data. Remote Sensing of Environment, 97, S. 137-162.

Santos, J.R., Freitas, C.C., Araujo, L.S., Dutra, L.V., Mura, J.C., Gama, F.F., Soler, L.S., Sant'Anna, S.J.S., 2003: Airborne P-band SAR applied to the aboveground biomass studies in the Brazilian tropical rainforest. Remote Sensing of Environment, 87, S. 482-493.

Santos, J.R., Neeff, T., Dutra, L.V., Araujo, L.S., Gama, F.F., Elmiro, M.A.T., 2004: Tropical forest biomass mapping from dual frequency SAR interferometry (X and P-Bands). Twentieth International Society for Photogrammetry and Remote Sensing (ISPRS) Congress: Geolmagery Bridging Continents, Istanbul, 35, S. 1133-1136.

Santos, J.R., Mura, J.C., Kux, H.J.H, Garcia, C.E., Kuntz, S., Brown, I.F., Pantoja, N.V., 2010: Classification of TerraSAR-X imagery for the characterization of Amazon tropical forests. http://www.conferences.earsel.org/system/uploads/abstract/document/1696/c20-a1696-earsel_2010_jrsantos_full_paper.doc (Zugriff 20.07.2012)

- Satellite Imaging Corporation, 2012: Satellite Imaging Sensors.
<http://www.satimagingcorp.com/satellite-sensors.html> (Zugriff 20.07.2012)
- Schardt, M., 2010: Umweltmonitoring mittels Fernerkundung, Vorlesungsunterlagen am Institut für Fernerkundung und Photogrammetrie der TU Graz, 142 S.
- Skutsch, M., Trines, E., 2008: Operationalising Reduced Degradation within REDD. Policy Paper no. 2: Kyoto: Think Global, Act Local project.
<http://www.communitycarbonforestry.org/Degradation.html> (Zugriff 20.07.2012)
- Small, C., 2004: The Landsat ETM+ spectral mixing space. Remote Sensing of Environment 93, S. 1-17.
- Souza Jr., C.M. und Barreto, P., 2000: An alternative approach for detecting and monitoring selectively logged forests in the Amazon. International Journal of Remote Sensing, 21 (1), S. 173-179.
- Souza Jr., C.M., Firestone, L., Moreira Silva, L., Roberts, D., 2003: Mapping forest degradation in the Eastern Amazon from SPOT 4 through spectral mixture models. Remote Sensing of Environment, 87, S. 494-506.
- Souza Jr., C.M. und Roberts, D., 2005: Mapping forest degradation in the Amazon region with Ikonos images. International Journal of Remote Sensing, 26(3), S. 425-429.
- Souza Jr., C.M., Roberts, D.A., Cochrane, M.A., 2005a: Combining spectral and spatial information to map canopy damage from selective logging and forest fires. Remote Sensing of Environment, 98(2-3), S. 329-343.
- Souza Jr., C.M., Roberts, D.A., Monteiro, A.L., 2005b: Multitemporal Analysis of Degraded Forests in the Southern Brazilian Amazon. Earth Interactions, 9(19), 25 S.
- Souza Jr., C.M., Cochrane, M.A., Sales, M.H., Monteiro, A.L., Mollicone, D., 2009: Case Studies on Measuring and Assessing Forest Degradation. Forest Resources Assessment Working Paper 151, Forestry Department FAO, 23 S.
- Stone, T.A. und Lefebvre, P, 1998: Using multi-temporal satellite data to evaluate selective logging in Para, Brazil. International Journal of Remote Sensing 1998, 19(13), S.2517-2526.
- Sulzer, W. 2009: Geographische Fernerkundung 1. Digitale Bildverarbeitung. Vorlesungsunterlagen am Institut für Geographie und Raumforschung der Karl-Franzens Universität Graz, 91 S.
- Transafrika, 2012: Klima in der Republik Kongo.
<http://www.beste-reisezeit.org/pages/afrika/kongo-republik.php> (Zugriff 20.07.2012)

Wertz-Kanounnikoff, S., 2008: Monitoring forest emissions. A review of methods.
http://www.cifor.org/publications/pdf_files/WPapers/WP39Wertz-Kanounnikoff.pdf
(Zugriff 20.07.2012)

UNFCCC, 2011: REDD Background.
http://unfccc.int/methods_science/redd/items/4547.php (Zugriff 20.07.2012)

UN-REDD, 2008: UN Collaborative Programme on Reducing Emissions from Deforestation and Forest Degradation in Developing Countries.
http://www.unredd.net/index.php?option=com_docman&task=doc_download&gid=4&Itemid=53 (Zugriff 20.07.2012)

UN-REDD, 2011: About the UN-REDD Programme.
<http://www.un-redd.org/> (Zugriff 20.07.2012)

Unterberger, M.C., 2011: MODIS for Monitoring Forest Degradation in the Republic of Congo. Master Thesis. Technical University Graz, 91 S.

USGS 2012: Landsat Missions Timeline.
http://landsat.usgs.gov/about_mission_history.php (Zugriff 20.07.2012)