

Goethe–Universität Frankfurt a. M.

Fachbereich 11
Geographie / Geowissenschaften
Institut für Physische Geographie

Diplomarbeit zum Thema:

Räumliche Differenzierung von Vegetationsparametern auf
landwirtschaftlichen Flächen auf Grundlage hyperspektraler
Fernerkundungsdaten und *groundtruth* – Informationen

Vorgelegt von:

Christine Staudt

Gutachter:

Prof. Dr. Jürgen Wunderlich
Goethe-Universität, Frankfurt a.M.

Dr. Angela Lausch
Helmholtz-Zentrum für Umweltforschung UFZ, Leipzig

Frankfurt a.M., Dezember 2009

INHALT

ABBILDUNGSVERZEICHNIS	III
TABELLENVERZEICHNIS	VI
ABKÜRZUNGSVERZEICHNIS.....	VIII
1 EINLEITUNG	1
1.1 Einleitung und Problemstellung.....	1
1.2 Forschungsstand.....	3
1.3 Vorgehensweise	5
2 UNTERSUCHUNGSGEBIET UND DATENGRUNDLAGEN.....	7
2.1 Untersuchungsgebiet	8
2.2 <i>groundtruth</i> - Daten.....	9
2.2.1 Bodeninformationen	10
2.2.2 Vegetationsparameter	11
2.3 Abbildende Hyperspektraldaten zur Analyse von Vegetation.....	12
3 METHODEN	17
3.1 Vegetationsindizes	17
3.2 Bi- und Multivariate Regression	20
3.3 Überwachte Klassifikation	25
3.3.1 Spectral Angle Mapper (SAM)	28
3.3.2 Künstliche Neuronale Netze (NN).....	29
3.3.3 Support Vector Machine (SVM)	32
4 ERGEBNISSE.....	35
4.1 Zeitliche Variabilität von Vegetationsparametern auf Getreideflächen	35
4.2 Räumliche Variabilität von Vegetation auf den Untersuchungsflächen	38
4.3 Berechnung der Vegetationsindizes.....	41
4.4 Ergebnisse der Regressionsanalyse.....	43
4.4.1 Leaf Area Index	44
4.4.2 Chlorophyll	55

4.4.3	Wuchshöhe	60
4.5	Ergebnisse der Klassifikation.....	68
4.5.1	Pflanzenwasser.....	69
4.5.2	Vergleich der Methoden anhand von Wuchshöhe.....	76
5	DISKUSSION.....	79
5.1	Variabilität auf den Untersuchungsflächen.....	79
5.2	Ergebnisse der Regression mit abbildenden Hyperspektraldaten	80
5.2.1	LAI.....	82
5.2.2	Chlorophyll	84
5.2.3	Wuchshöhe	85
5.3	Klassifikation von Pflanzenwasser	86
5.4	Vergleich des Regressions- und Klassifikationsansatzes	89
6	ZUSAMMENFASSUNG UND AUSBLICK.....	91
	LITERATURVERZEICHNIS	95
	ANHANG	103

ABBILDUNGSVERZEICHIS

Abb. 1: Vorgehen zur Bestimmung verschiedener Vegetationsparameter	6
Abb. 2: Untersuchungsgebiet bei Grimma (Sachsen). Winterweizen (2009).	9
Abb. 3: Typische Spektrale Reflektion von Vegetation und Boden	14
Abb. 4: Beispiel für die phänologische Entwicklung von Winterweizen.	15
Abb. 5: Schematische Darstellung des Prinzips der Klassifikation mit Spectral Angle Mapper.	29
Abb. 6: Schematische Darstellung eines feed-forward Neuronalen Netzes.	30
Abb. 7: Schematische Darstellung der Klassifikation mit einer Support Vektor Machine.	32
Abb. 8: Entwicklung von Vegetationsparametern bei Wintergerste und Winterroggen über die Vegetationsperiode 2008	37
Abb. 9: Spektrale Profile von a) Wintergerste, b) Winterraps.	39
Abb. 10: Zusammenhang zwischen VIs berechnet aus abbildenden Hyperspektraldaten (AISA) und Feldspektrometerdaten (ASD)	42
Abb. 11: Zusammenhänge zwischen in VIs verwendeten Wellenlängenbereichen von AISA- und ASD Daten.	42
Abb. 12: a) LAI und TVI mit allen Daten und b) getrennt nach Pflanzenart.	45
Abb. 13: Zusammenhang zwischen LAI und den Indizes REIP und PSRI für Wintergerste.	47
Abb. 14: Vergleich von modelliertem und groundtruth-LAI für Wintergerste mit jeweiligem Bestimmtheitsmaß (R^2).	48
Abb. 15: Zusammenhang zwischen LAI und ausgewählten Vegetationsindizes für Winterroggen.	49
Abb. 16: Vergleich von modelliertem und groundtruth-LAI für Winterroggen mit jeweiligem Bestimmtheitsmaß (R^2).	50
Abb. 17: Zusammenhang zwischen LAI und ausgewählten Vegetationsindizes für Winterraps.	51
Abb. 18: Vergleich von modelliertem und groundtruth-LAI bei Winterraps mit jeweiligem Bestimmtheitsmaß (R^2).	52

Abb. 19: Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterweizen.	53
Abb. 20: Vergleich von modelliertem und groundtruth-LAI für Winterweizen mit jeweiligem Bestimmtheitsmaß (R^2)	54
Abb. 21: Ergebniskarten der empirischen Modellierung von LAI.	55
Abb. 22: a) Lineare und quadratische Funktion zur Beschreibung des Zusammenhangs von Blattchlorophyll und Triangular Vegetationindex (TVI) bei Winterraps und Winterweizen. b) Zusammenhang zwischen LAI und Chlorophyll bei Winterraps.....	56
Abb. 23: Zusammenhänge zwischen Blattchlorophyll und ausgewählten Vegetationsindizes für Winterraps.	57
Abb. 24: Vergleich von modelliertem und groundtruth-Blattchlorophyll für Winterraps mit jeweiligem Bestimmtheitsmaß (R^2)	58
Abb. 25: Vergleich von modelliertem und groundtruth-Blattchlorophyll für Winterweizen mit jeweiligem Bestimmtheitsmaß (R^2)	59
Abb. 26: Ergebniskarte der empirischen Modellierung von Chlorophyll	60
Abb. 27: Wuchshöhe vs. NDVI getrennt nach Fruchtarten.	61
Abb. 28: Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Wintergerste.	62
Abb. 29: Vergleich zwischen modellierter und groundtruth-Wuchshöhe für Wintergerste mit jeweiligem Bestimmtheitsmaß (R^2).	63
Abb. 30: Zusammenhang zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterroggen.	64
Abb. 31: Vergleich von modellierter und groundtruth-Wuchshöhe für Winterroggen mit jeweiligem Bestimmtheitsmaß (R^2).....	64
Abb. 32: Zusammenhang zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterraps.	65
Abb. 33: Vergleich von gemessener und groundtruth-Wuchshöhe für Winterraps mit jeweiligem Bestimmtheitsmaß (R^2).....	66
Abb. 34: Zusammenhang zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterweizen.	67
Abb. 35: Vergleich von gemessener und groundtruth-Wuchshöhe für Winterweizen mit jeweiligem Bestimmtheitsmaß (R^2).....	67

Abb. 36: Ergebniskarten der empirischen Modellierung von Wuchshöhe..	68
Abb. 37: Trainingsspektren (Endmember Collection Spectra) für die Klassifikation von Winterweizen (a) und Winterraps (b).....	70
Abb. 38: RMS Fehlerreduktion bei Wiederholung des Trainings des Neuronalen Netzes zur Klassifikation von Pflanzenwasser bei Winterweizen.....	72
Abb. 39: Klassifikation von Pflanzenwasser [kg/m ²] in Winterraps und Winterweizen. a) SAM, b) SVM, c) NN.....	73
Abb. 40: Klassifikation von Pflanzenwasser in Wintergerste mit unterschiedlichen Trainingsspektren für Klasse 3.....	74
Abb. 41: Trainingsspektren und Verlauf der RMS-Fehlerreduktion für die Klassifikation mit unterschiedlichen Trainingsspektren	75
Abb. 42: Klassifikationsergebnisse von Pflanzenwasser mit der Methode künstlicher Neuronaler Netze	76
Abb. 43: Pflanzenwassergehalt von Wintergerste durch a) empirische Modellierung, b) Klassifikation mit Neuronalen Netzen.	77

TABELLENVERZEICHNIS

Tab. 1: Bewirtschaftungsform auf den Untersuchungsflächen im Aufnahmejahr und Makrostadium zum Aufnahmezeitpunkt mit zugehörigem Code der BBCH-Skala.....	7
Tab. 2: Bemessene Parameter und Messdesigns	12
Tab. 3: Makrostadien von Wintergerste und Winterroggen über die Vegetationsperiode 2008.....	38
Tab. 4: Gütekriterien für den Zusammenhang zwischen LAI und ausgewählten Vegetationsindizes für Wintergerste.	47
Tab. 5: Gütekriterien für die Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterroggen.	49
Tab. 6: Gütekriterien für die Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterrraps.	51
Tab. 7: Gütekriterien für die Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterweizen.	53
Tab. 8: Gütekriterien der Zusammenhänge zwischen Blattchlorophyll und ausgewählten Vegetationsindizes für Winterrraps.	57
Tab. 9: Gütekriterien für die Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Wintergerste.	62
Tab. 10: Gütekriterien für die Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterroggen.	64
Tab. 11: Gütekriterien der Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterrraps.	65
Tab. 12: Gütekriterien für die Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterweizen.	67
Tab. 13: Gesamtgenauigkeit (overall accuracy) der Klassifikationen von Pflanzenwasser (EWT) mit Neuronalen Netzen, Spectral Angle Mapper und Support Vector Machine.	71
Tab. 14: Gesamtgenauigkeit der Klassifikation von Pflanzenwasser (EWT) mittels Neuronaler Netze.....	77

Tab. 15: Vergleich der Klassengrößen durch Klassifikation (NN) und empirische Modellierung für Pflanzenwasser.78

ABKÜRZUNGSVERZEICHNIS

AISA	Airborne Imaging Spectrometer for Application
ASD	verwendeten Feldspektrometer
Cook's D	Cook's Distance – Bootstrapping-Verfahren zur statistischen Detektion von Ausreißern
DGM	Digitales Geländemodell
DVI	Difference Vegetationindex
EWT	Equivalent Water Thickness
GWC	Gravimetric Water Content
IMU	Inertial Measurement Unit
LAI	Leaf Area Index (Blattflächenindex)
MMK	mittelmaßstäbige landwirtschaftliche Standortkartierung
NDVI	Normalized Difference Vegetation Index
NIR	nahes Infrarot (700-1400 nm)
NN	künstliches Neuronales Netz
PLMR	Polarimetric L-Band Multibeam Radiometer
PVI	Perpendicular Vegetationindex
Rededge	Rot-Infrarot Anstieg der Reflektion von Vegetation
SAM	Spectral Angle Mapper (Klassifikationsmethode)
SR	Simple Ratio (Vegetationsindex)
SVAT	soil-vegetation-atmosphere-transfer-Modell
SVM	Support Vector Machine (Klassifikationsmethode)
SWIR	kurzwelliges Infrarot (shortwave infrared, 1400-3000 nm)
UFZ	Helmholtz – Zentrum für Umweltforschung
VI	Vegetationsindex
VIS	sichtbarer Wellenlängenbereich

Weitere Abkürzungen für Vegetationsindizes in Anhang 1.

1 EINLEITUNG

1.1 EINLEITUNG UND PROBLEMSTELLUNG

Die Landwirtschaft sieht sich durch zunehmenden ökonomischen Druck hohe Erträge zu erzielen und gleichzeitig starken Auflagen zur Minimierung von Umweltbelastungen neuen Anforderungen ausgesetzt. Das neu entstandene Forschungsfeld der Präzisionslandwirtschaft beschäftigt sich mit der Erarbeitung neuer Verfahren zur Untersuchung kleinräumiger Heterogenität innerhalb einzelner landwirtschaftlich genutzter Flächen, um Düngestrategien zu optimieren. Zur Erkennung der Variabilität innerhalb von Ackerschlägen wird flächenhafte Information über die Verbreitung von Standortfaktoren und Bestandsparametern (z.B. Blattfläche, Chlorophyll, Pflanzenwassergehalt) benötigt (ERASMI 2002).

Nicht nur für die Landwirtschaft sind kleinräumige Informationen von Oberflächenparametern von Bedeutung, sie werden z.B. in Wachstumsmodellen, Klimamodellen, Ernteertragsmodellen und soil-vegetation-atmosphere-transfer-Modellen (SVAT) eingesetzt. Prozessorientierte Studien zu Stoff- und Energiekreisläufen erfordern quantitative Informationen der Einflussvariablen (BACH 1995). Somit stellen einzelne Vegetationsparameter wichtige Variablen in der Generierung verschiedener Modelle dar.

Für räumliche Analysen von Vegetation gilt Fernerkundung seit längerem als erfolgreiches Werkzeug. Neue Sensoren und Auswertverfahren ermöglichen neben bisherigen qualitativen Informationen über die Landoberfläche auch quantitative Berechnungen von Objektgrößen. Die Physiologie von Pflanzen, die sich durch biochemische und strukturelle Charakteristika ausdrückt, ändert sich während verschiedener Lebensabschnitte und stressbedingt. Dies zeigt sich in Änderungen der spektralen Signatur, die durch Fernerkundung erfassbar sind (KNEUBÜHLER 2002). So lässt sich auch die Variabilität der Vegetation auf Feldskala mittels Fernerkundung erfassen. Flugzeuggetragene abbildende Hyperspektraldaten verfügen über einen hohen Informationsgehalt und eignen sich zur Differenzierung und flächenhaften Berechnung von biochemischen und strukturellen Vegetationsparametern. Dazu werden im Allgemeinen spezielle Spektralindizes angewendet, die durch Verwendung bestimmter Wellenlängenbereiche sensibel auf einzelne Vegetationsparameter reagieren. Die zunehmende Verwendung von spektral

1. Einleitung

und räumlich hochauflösenden Sensoren steigert die Erwartung an die Fernerkundung, Vegetationsmerkmale besser trennen zu können.

Die vorliegende Arbeit ist eingebunden in ein Projekt des Helmholtz – Zentrums für Umweltforschung (UFZ) zur Ableitung oberflächennaher Bodenfeuchte aus Mikrowellenradiometerdaten auf landwirtschaftlichen Flächen. Vegetation reduziert die Sensitivität von Algorithmen zur Ableitung von Bodenfeuchte durch einen eigenen Emissionsbeitrag der entsprechend untersuchten Wellenlänge. Diese Signaldämpfung variiert räumlich in Abhängigkeit verschiedener Vegetationsparameter. Vegetationsinformationen aus räumlich und spektral hochauflösenden Fernerkundungsdaten sollen zur Interpretation von PLMR-Daten (Polarimetric L-Band Multibeam Radiometer) mit 50 Meter räumlicher Auflösung beitragen. Um kleinräumige Heterogenität der Vegetation auf den Untersuchungsflächen zu erkennen, wurde das Gebiet mit einem Airborne Imaging Spectrometer for Application (AISA) befliegen. Durch parameterspezifische Subpixelanalyse soll der Anteil der Vegetation am Mikrowellensignal herausgefiltert werden, um Bodenfeuchte zu modellieren.

Ziel dieser Arbeit ist es daher,

- die Vegetationsparameter Blattflächenindex (LAI), Blattchlorophyll, Wuchshöhe und Pflanzenwasser aus abbildenden Hyperspektraldaten (AISA) und *groundtruth* flächendeckend herzuleiten, um Informationen zur räumlichen Variabilität auf den Untersuchungsflächen zu erhalten.
- Weiterhin soll untersucht werden, wie sich die räumliche Variabilität der Vegetation auf den Untersuchungsflächen darstellt und welche Faktoren sie bedingen.
- Für eine weitere Anwendung von Methoden zur Herleitung von Vegetationsparametern ist von Interesse, welche der Parameter gut aus den vorliegenden Hyperspektraldaten extrahierbar sind
- und welche, aus der großen bestehenden Auswahl an Vegetationsindizes, die einzelnen Parameter der Anbaupflanzen Wintergerste, Winterroggen, Winterraps und Winterweizen in unterschiedlichen Phänologiestadien am Besten beschreiben.
- Bestehende Methoden sollen getestet werden, um quantitative Informationen von Vegetationsparametern auch bei geringem Umfang an *in-situ* Messungen gewinnen zu können.

Zur Differenzierung der Vegetationsparameter werden empirische Modelle verwendet, die aus Regression von spektralen Vegetationsindizes und *groundtruth* des jeweiligen Parameters gebildet werden. Vegetationsindizes stellen dabei eine Parametrisierung des spektralen Signals von Vegetation dar. Da nicht ausreichend *groundtruth* zur empirischen Modellierung von Pflanzenwasser aufgenommen wurde, wird außerdem Klassifikation als Methode zur Quantifizierung von Vegetationsparametern auf Feldskala aus abbildenden Hyperspektraldaten getestet.

1.2 FORSCHUNGSSTAND

Untersuchungen zum spektralen Verhalten von Pflanzenparametern wurden bereits in den 1970er Jahren durchgeführt (z.B. TUCKER 1977, TUCKER 1979). In den 80er und 90er Jahren beschäftigte sich die Forschung mit der Anwendung der Fernerkundung zur Ableitung biochemischer und biophysikalischer Parameter (z.B. BARET & GUYOT 1991, ROUJEAN & BREON 1995, GITELSON & MERZLYAK 1996). Ein wesentlicher Teil des heutigen Verständnisses der Reflektionseigenschaften von Vegetation beruht jedoch auf Modellierungen mit Strahlungstransfermodellen (PROSPECT und SAIL), wie sie z.B. von HABOUDANE et al. (2004), BROGE & LEBLANC (2000), DAUGHTRY et al. (2000) und MERONI et al. (2004) verwendet werden. Einen Überblick über die Arbeit mit PROSPECT und SAIL geben JACQUEMOUD et al. (2009).

Im Allgemeinen wird eine Parametrisierung des spektralen Signals durch bestimmte, von Vegetation beeinflusste Wellenlängenbereiche (meist Rot und nahes Infrarot) verwendet. Diese Vegetationsindizes haben sich als geeignet zur Beschreibung von Vegetationsmerkmalen erwiesen (z.B. TUCKER 1977). Neue hyperspektrale Sensoren sind in der Lage sehr schmale Spektralbänder innerhalb eines bestimmten Wellenlängenbereichs (z.B. 400-970 nm) aufzunehmen. Dies ermöglicht die Verwendung bestimmter, auf biochemische und biophysikalische Parameter sensibel reagierender Wellenlängen. BROGE & LEBLANC (2000) verglichen verschiedene Multi- und Hyperspektralindizes und untersuchten ihre Sensibilität auf externe Einflussfaktoren, wie Boden und Aufnahmewinkel.

Einen Überblick neuerer Methoden zur Berechnung von biophysikalischen Oberflächenparametern gibt LIANG (2007). KNEUBÜHLER 2002 u.a. testeten verschiedene empirische und semi-empirische Modellansätze. Meist werden zur flächenhaften

Berechnung einzelner Vegetationsmerkmale empirische Modelle verwendet, die aus Regression von spektralen Vegetationsindizes und am Boden gemessener *groundtruth* des zu untersuchenden Parameters gebildet werden. Bisher basieren Studien mit Hyperspektraldaten jedoch hauptsächlich auf simulierten Daten. In einer Reihe von Arbeiten wurde die Anwendung solcher Indizes-basierter Algorithmen zur Bestimmung von LAI und Chlorophyll untersucht. GITELSON et al. (2003) und HABOUDANE et al. (2004) z.B. konzipierten Indizes, die gute Ergebnisse zur Beschreibung von LAI lieferten, während GITELSON & MERZLYAK (1996) und HABOUDANE et al. (2002) gute Algorithmen zur Bestimmung von Chlorophyllgehalt erarbeiteten. Zur Herleitung von Wuchshöhe existieren nur wenige Arbeiten; erfolgreiche Berechnungen führten z.B. PAYERO et al. (2004) und ANDERSON et al. (2004) durch. Die Berechnung von Pflanzenwassergehalt wird meist anhand spezieller Wasserindizes durchgeführt (z.B. PEÑUELAS et al. 1993), bereits TUCKER (1977) stellte jedoch auch einen engen Zusammenhang zu Wellenlängen des Roten und nahen Infraroten fest.

Die Ergebnisse der großen Anzahl an Arbeiten zur Gewinnung einzelner Vegetationsparameter aus Hyperspektraldaten zeigen, dass die Wahl des verwendeten Vegetationsindex stark von dem gesuchten Parameter, verfügbaren Daten, Pflanzenart und Phänologie, sowie externen Faktoren (z.B. Aufnahmecharakteristika) abhängig ist. In dieser Arbeit werden 34 aus der Literatur bekannte Indizes auf ihre Beschreibung bestimmter Eigenschaften der Anbaupflanzen Wintergerste, Winterroggen, Winterraps und Winterweizen in unterschiedlichen Phänologiestadien getestet. Dabei werden sie durch Regressionsanalyse gegen *groundtruth* ausgewählter Vegetationsparameter validiert. Außerdem soll das Potential der Parameter LAI, Chlorophyll, Wuchshöhe und Pflanzenwasser zur Gewinnung von Informationen über räumliche Variabilität auf Feldskala untersucht werden.

Ein häufig genanntes Problem stellt der Mangel an ausreichend großen Datensätzen dar. Die Erhebung von *groundtruth* in großem Umfang ist sehr schwer durchführbar, da Messungen meist auf ein enges Zeitfenster begrenzt sind und eines hohen Einsatzes an Arbeitskräften bedürfen. Da auch hier nicht für alle benötigten Vegetationsparameter ausreichend Daten erhoben werden konnten, sollen verfügbare Methoden auf die Problematik weniger *groundtruth*-Messungen hin getestet werden. JÜRSCHIK (1999) nennt unter anderem die Klassifikation als Methode zur Erfassung kleinräumiger Heterogenität. Mittels *groundtruth* werden hierbei im Luftbild ermittelte Objektklassen Merkmalsklassen zugeordnet. Klassifikation ist die am häufigsten gebrauchte Methode in der

Fernerkundung, es existieren jedoch kaum Studien zur Anwendung von Klassifikation auf Feldskala (z.B. VOß 2005). Etwas häufiger wurde Klassifikation zur Detektion unterschiedlicher Nutzungen auf Agrarflächen angewendet (z. B. WASKE 2007, FOODY & MATHUR 2004, ARORA & FOODY 1997). Mit der möglichen Reduzierung von großen Trainingsdatensätzen oder der Auswirkung der Trainingssetgröße auf Klassifikationsgenauigkeiten beschäftigen sich hingegen schon eine Vielzahl von Arbeiten (vgl. FOODY & MATHUR 2004, z.B. ARNOFF, ARORA & FOODY 1997). Um mögliche Potentiale der überwachten Klassifikation zur Gewinnung räumlicher Informationen von Vegetationsparametern auf Feldskala zu erkennen, werden in der vorliegenden Arbeit verschiedene Klassifikationsmethoden getestet und im Hinblick auf geringe Trainingsdaten für einen hyperspektralen Datensatz untersucht.

Viele neuere Studien zeigten, dass nicht-parametrische Klassifikationsmethoden höhere Genauigkeiten erzielten als konventionelle statistische Methoden (Foody & Mathur 2004, Arora & Foody 1997). Foody und Mathur (2004) zeigten, dass für diese Methoden außerdem ein weniger umfassender Trainingsdatensatz benötigt wird, der die vollständige spektrale Signatur der Klassen beschreibt. In dieser Arbeit werden die Klassifikationsmethoden Spektral Angle Mapper und die neueren, häufig als genauer eingestuftes Klassifikationsmethoden Künstliche Neuronale Netze und Support Vektor Maschine auf ihre Eignung zur quantitativen Differenzierung einzelner Vegetationsparameter anhand des vorliegenden Datensatzes getestet.

1.3 VORGEHENSWEISE

In der vorliegenden Arbeit wird zunächst die Datengrundlage für *groundtruth* und abbildende Hyperspektraldaten näher erläutert und ein Überblick über die spektralen Eigenschaften von Vegetation gegeben, die sich die Fernerkundung zu nutzen macht (Kap. 2). Nach der genaueren Beschreibung der verwendeten Methoden (Kap. 3) folgt in Kap.4 schließlich die Analyse der räumlichen Variabilität auf den Untersuchungsflächen. Zur Erklärung wie sich räumliche Variabilität bemerkbar macht, werden zunächst die Änderungen der Vegetationsparameter von Wintergerste und Winterroggen über die Vegetationsperiode untersucht. Die Betrachtung der zeitlichen Variabilität einzelner Vegetationsmerkmale soll dazu beitragen, Rückschlüsse auf räumliche Variabilität ziehen zu können. Da der Zustand von Pflanzen stark an Standortfaktoren gebunden ist, werden außerdem Strukturen in der Vegetationsbedeckung mit Bodenmustern und Relief

1. Einleitung

verglichen. Auf Grundlage von Bodenkarten und einem Geländemodell wird versucht Faktoren herauszuarbeiten, die für die Variabilität auf Feldskala verantwortlich sind.

Die eigentliche flächenhafte Darstellung einzelner Vegetationsparameter erfolgt auf Grundlage von Regressionsschätzungen. Lineare Regression mit Vegetationsindizes als unabhängige Variable ermöglicht die Modellierung der Vegetationsparameter Blattflächenindex (LAI), Blattchlorophyll und Wuchshöhe (vgl. Abb.1). Da der Pflanzenwassergehalt einen entscheidenden Einfluss auf Mikrowellensignale nimmt (Anderson et al. 2004, Burke et al. 2001), jedoch nicht ausreichend *groundtruth* zur Verfügung steht, um Pflanzenwasser für Wintergerste und Winterroggen empirisch zu modellieren, werden drei Klassifikationsmethoden auf ihr Potential zur quantitativen Darstellung einzelner Vegetationsmerkmale bei kleinen Datensätzen getestet. Die beste Klassifikationsmethode wird zur Modellierung von Pflanzenwasser verwendet. Um die Methoden der empirischen Modellierung und überwachter Klassifikation bewerten zu können, wird die gewählte Klassifikation außerdem für Wuchshöhe durchgeführt und die Ergebnisse anschließend verglichen (vgl. Abb. 1).

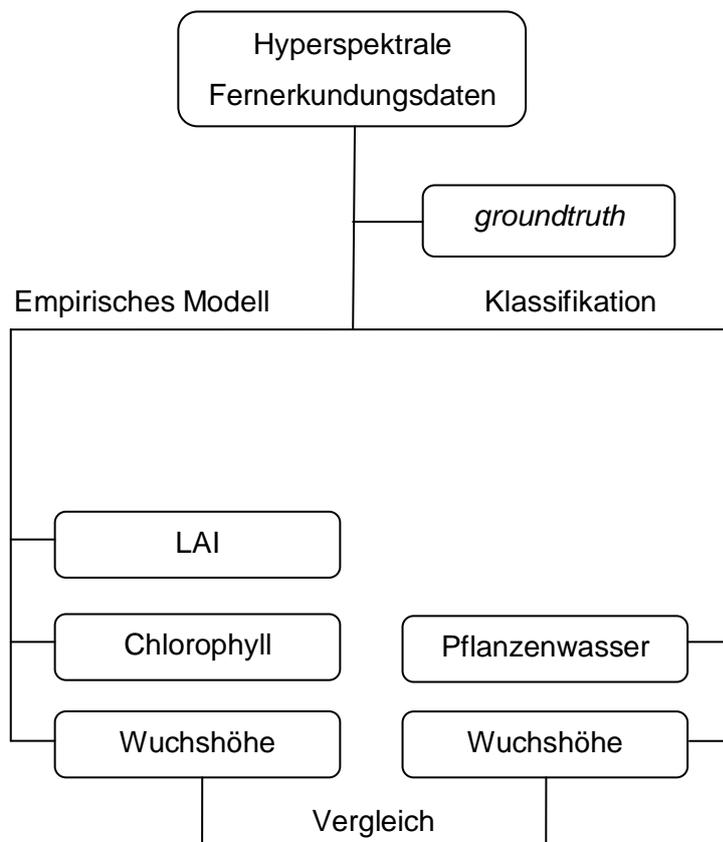


Abb. 1: Vorgehen zur Bestimmung verschiedener Vegetationsparameter durch empirische Modelle und Klassifikation aus Hyperspektraldaten

2 UNTERSUCHUNGSGBIET UND DATENGRUNDLAGEN

Die Fernerkundung ist die einzige Methode, um flächendeckende Informationen über Pflanzenzustände und Heterogenität innerhalb von Monokulturen zu erhalten. Neuere Sensoren ermöglichen hyperspektrale Fernerkundungsaufnahmen, mit denen genaue Aussagen über die Verteilung von biochemischen und biophysikalischen Vegetationsparametern getroffen werden können. Bandbreiten im Nanometerbereich lassen Blattpigmente und die Bedeckungsstruktur aus Reflektionen der Landoberfläche in bestimmten Spektralbereichen erkennen. Um Vegetationsparameter auf den Untersuchungsflächen herzuleiten wurde das Gebiet mit einem flugzeuggetragenen abbildenden Hyperspektralsensor (AISA-Eagle) aufgenommen. Zur Untersuchung kausaler Zusammenhänge zwischen Pflanzenparametern und Fernerkundungsdaten, wurden zum Befliegungszeitpunkt *groundtruth*- Daten der zu untersuchenden Parameter am Boden gemessen.

Die Untersuchungsflächen stellen drei landwirtschaftlich genutzte Schläge dar. Die Felder wurden im Juni 2008 und im April 2009 befliegen und bemessen. Tab. 1 gibt eine Übersicht über Bewirtschaftungsform und Phänologiestadium auf den Feldern zu den beiden Aufnahmezeitpunkten.

Kampagnendatum	Bewirtschaftung	Phänologie
10.6.2008	Wintergerste (Schlag 12)	Fruchtentwicklung (73)
	Winterroggen (Schlag 8)	Fruchtentwicklung (73)
24.4.2009	Winterraps (Schlag 8 u. 12)	Entwicklung der Blütenanlage bis Blüte (57-64)
	Winterweizen (Schlag 9)	Blattentwicklung (13-14)

Tab. 1: Bewirtschaftungsform auf den Untersuchungsflächen im Aufnahmejahr und Makrostadium zum Aufnahmezeitpunkt mit zugehörigem Code der BBCH-Skala.

2.1 UNTERSUCHUNGSGEBIET

Das Untersuchungsgebiet befindet sich südöstlich von Leipzig in Sachsen und gehört seit der Kreisreform 2008 zum Leipziger Land. Die landwirtschaftlichen Flächen, mit denen sich die Arbeit beschäftigt, liegen südwestlich der Stadt Grimma. Die Felder grenzen dabei östlich direkt an das Ortsgebiet von Großbardau. Sie werden von der Kleinbardau Landwirtschafts GmbH (KÖG) bewirtschaftet.

Das Gebiet zählt zum Einzugsgebiet der Parthe. Es steht als Modellregion für regionale Auswirkungen des Klimawandels verschiedener Studien des Projektes TERENO (TERrestrial ENvironmental Observatories). In diesem Langzeitprojekt werden mehrere Gebiete unterschiedlicher physiographischer Ausstattung hinsichtlich regionaler Einflüsse des Klimawandels untersucht. Die Gebiete werden aufgrund ihrer starken klimatischen Gradienten als besonders sensibel für Klimaänderungen eingestuft.

Naturräumlich ist das Gebiet dem Nordsächsischen Platten- und Hügelland zuzuordnen (MANNSFELD & RICHTER 1995). Das glazial überprägte Gebiet ist aufgrund geringmächtiger Sandlöße überwiegend landwirtschaftlich geprägt. Diese erreichen im Untersuchungsgebiet Lößanteile von bis zu 40%, hinter denen Sand mit 10% zurücktritt. Substratbedingt ergeben sich daraus Braunerden oder Böden mit Fahlerdecharakter und stellenweise staunasse Böden. In Trockenjahren können Ertragsminderungen vorkommen. Das Klima ist mäßig trocken bis schwach kontinental mit höheren Niederschlägen im Sommerhalbjahr. Die langjährigen Niederschlagsmittel umliegender Wetterstationen betragen etwa 570 mm/a unkorrigiert und 650 mm korrigiert (Werte für Brandis 1981-1997). Für die Variabilität des Zustands der Vegetationsbedeckung innerhalb eines Ackerschlags ist zu erwähnen, dass die Bodenart in der gleichen Gebietsgröße variiert.

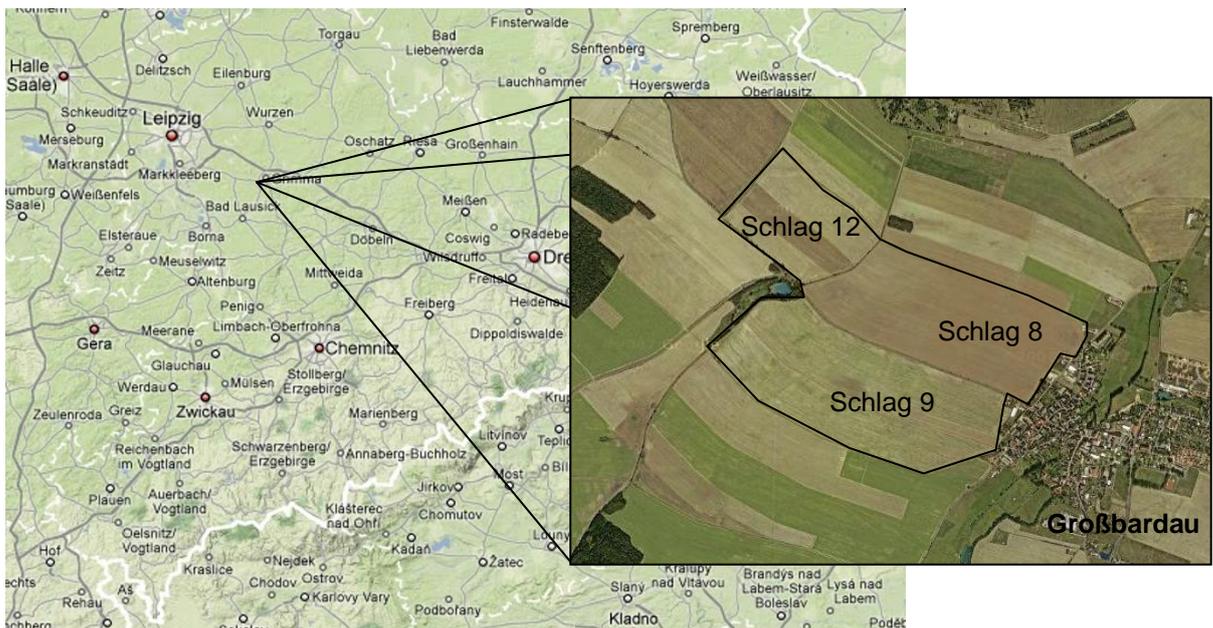


Abb. 2: Untersuchungsgebiet bei Grimma (Sachsen). Bei den untersuchten Flächen handelt es sich um drei Felder. Links oben: Wintergerste (2008), Winterroggen (2009); rechts oben: Winterroggen (2008), Winterraps (2009); unten: Winterweizen (2009). (Karten: Googlemaps)

2.2 GROUNDTRUTH-DATEN

Zur Validierung der hyperspektralen Fernerkundungsdaten wurden parallel zu den Befliegungen Referenzdaten der zu untersuchenden Vegetationsparameter, sowie zur Bodenfeuchte, auf den gewählten landwirtschaftlichen Flächen gesammelt.

Während der Messkampagne 2008 wurden auf Schlag 8 *groundtruth*-Informationen in zwei, auf Schlag 12 in drei parallelen Reihen an georeferenzierten Punkten durchgeführt. Die zwei untersuchten Flächen wurden im Messzeitraum 2008 mit Getreide bewirtschaftet. Auf Schlag 8 konnte somit in diesem Jahr die Entwicklung von Winterroggen, auf Schlag 12 von Wintergerste, beobachtet werden. Daten für Bodenfeuchte, Wuchshöhe und LAI wurden an jedem zweiten der georeferenzierten Messpunkte aufgenommen, während Chlorophyllgehalt und Biomasse, bzw. der daraus errechnete Pflanzenwassergehalt, sechs mal pro Feld gemessen wurden.

Als Standardmonitoring wurden über den Vegetationszeitraum von März bis Juli 2008 verschiedene Vegetationsparameter, sowie Bodenfeuchte gemessen. Die Datenerhebung

fand in Abständen von etwa zwei Wochen statt. Für Wintergerste endete sie mit der Ernte zum Messdatum 23. Juni 2008, während Winterroggen bis zum 7. Juli 2008 bemessen werden konnte und somit ein weiterer Datensatz zur Verfügung steht.

Des Weiteren wurde am 26. Mai 2008 eine spezielle Kampagne in Verbindung mit der Erhebung von PLMR-Daten durchgeführt. An diesem Tag wurden insbesondere Chlorophyll, Bodenfeuchte und LAI nach Möglichkeit an allen georeferenzierten Punkten gemessen.

Im darauffolgenden Jahr waren beide Felder mit Raps bewirtschaftet, der zum Zeitpunkt der Befliegung bereits größtenteils in Blüte stand. Die Erhebung der *groundtruth*-Daten für die Befliegung im April 2009 erfolgte an ausgewählten, durch unterschiedliche Vegetationsentwicklung charakterisierten Stellen. Aufgrund der Erfahrungen aus der Datenerhebung des vorangegangenen Jahres wurde die Messmethodik optimiert. Die Bindung an den Befliegungszeitpunkt macht die Erhebung ausreichender Stichproben als Referenzdaten nur in einem begrenzten Umfang möglich. Um dennoch die Variabilität des Feldes darin wiederzugeben, wurden zufällige Messungen mit Vorkenntnissen aus älteren Luftbildern kombiniert (vgl. ERASMI 2002). Die Messpunkte wurden entlang von Transekten durch das Feld gesetzt, wobei darauf geachtet wurde eine möglichst breite Wertespanne zu erhalten. Dabei wurden an jedem Messpunkt alle 4 Vegetationsparameter aufgenommen. Zusätzlich wurden Messungen auf Schlag 9 durchgeführt, der zu diesem Zeitpunkt mit Winterweizen bewirtschaftet wurde und sich zur Zeit der Aufnahme in einem frühen Phänologiestadium befand (vgl. Tab. 1). Für die Fruchtarten Winterraps und Winterweizen wurden nur zum Befliegungszeitpunkt *groundtruth*-Daten erhoben. Ein Monitoring, wie für Wintergerste und Winterroggen, über einen längeren Zeitraum wurde nicht durchgeführt.

2.2.1 Bodeninformationen

Kausale Zusammenhänge von Boden und Vegetation sollen Aufschluss über Vegetationsmuster auf den untersuchten Getreideflächen geben. Die Voraussetzung für räumliche Variabilität der Vegetation bildet kleinräumige Heterogenität des Bodens bzw. seiner Qualität (SCHRÖDER 1999).

Die gemessene Bodenfeuchte dient der Validierung von Radardaten zur Herleitung von Bodenfeuchte, erfüllt für die vorliegende Arbeit jedoch eher informative Funktionen. Um

Informationen zu den Eigenschaften des Bodens zu erhalten wurden ein Digitales Geländemodell (DGM), die Bodenkarte der Mittelmaßstäbigen Landwirtschaftlichen Standortkartierung (MMK, 1:100 000) und die Reichsbodenschätzung (1:1 000 bis 1:2 000) hinzugezogen. Das DGM25 ist mit einer Gitterweite von 20m und einer Höhengenaugigkeit von +/- 2m zurzeit das bestaufgelöste Geländemodell, das für dieses Gebiet zur Verfügung steht. Die MMK wird aufgrund ihrer Bearbeitung vor 1990 mit Hilfe eines Schlüssels auf Basis der Bodenkundlichen Kartieranleitung (KA 5) betrachtet.

2.2.2 Vegetationsparameter

Für die zu untersuchenden Vegetationsparameter wurden Referenzdaten zu LAI, Wuchshöhe, Blattchlorophyll und Biomasse aufgenommen. Die Messungen 2008 erfolgten an zufälligen Punkten entlang paralleler Transekte, die Messungen 2009 an ausgewählten Punkten mit möglichst verschiedener Ausprägung der Vegetation entlang von Transekten.

Punktuelle Datenerhebungen können die Variabilität innerhalb einer Fläche immer nur in beschränktem Maße wiedergeben. Die Erhebung von *groundtruth* in der gewünschten Auflösung ist in der Regel nicht durchführbar (ERASMI 2002). Die Messungen waren aufgrund der nötigen Gleichzeitigkeit zu den Befliegungen auf ein enges Zeitfenster beschränkt. Es wurde versucht eine möglichst hohe Anzahl an Referenzdaten zu erheben. Dennoch konnten insbesondere während der Kampagne 2008 nur wenige Messungen von Chlorophyll und Biomasse durchgeführt werden.

Da es sich um tatsächlich landwirtschaftlich genutzte Flächen handelt, wurden keine destruktiven Methoden angewandt. Alle Messungen erfolgten durch Feldmessgeräte, ausgenommen Biomasse. So wurde beispielsweise LAI mit einem LAI 2000 gemessen und nicht aus der Trockenmasse ermittelt. Für Biomasse wurden einzelne Pflanzenproben entnommen und keine Flächenrohdung durchgeführt. Eine Übersicht, der gemessenen Parameter und Messmethoden ist in Tab. 2 aufgeführt. Zusätzlich zu den abbildenden Hyperspektraldaten wurden Referenzspektren mit einem Feld-Spektrometer durchgeführt.

Aufgrund von Lücken zwischen den Befliegungstreifen der Fernerkundungsszenen fallen bei den Daten von 2008 einige *groundtruth*-Punkte aus. Für Chlorophyll und Biomasse bzw. Pflanzenwasser sind daher nicht alle sechs gemessenen Werte für die Auswertung verwendbar.

2. Untersuchungsgebiet und Datengrundlagen

Vegetationsparameter	Messmethode	Groundtruth-Messungen
LAI	LAI-2000, Licor	Wintergerste: 20
	Mittelwert aus 3x3 Messungen auf 1 m ²	Winterroggen: 15
	Einheit: LAI (Wertebereich 1-10)	Winterraps: 19
		Winterweizen: 13
Chlorophyll	SPAD-502, Konica Minolta	Wintergerste: 5
	Mittelwert aus 8 o. 10 Messungen auf 1 m ²	Winterroggen: 3
	Einheit: SPAD-Wert, ohne Referenzeinheit	Winterraps: 19
		Winterweizen: 13
Wuchshöhe	Zollstock	Wintergerste: 20
	Mittelwert aus 3 repräsentativen Pflanzen	Winterroggen: 15
	Einheit: cm	Winterraps: 19
		Winterweizen: 13
Pflanzenwasser	aus Nass-/ Trockenbiomasse und Standdichte (durch Pflanzenzählung auf 1 m ²)	Wintergerste: 5
	Mittelwert aus 3 Biomasseproben	Winterroggen: 3
	Einheit: kg/m ² (EWT), % (GWC)	Winterraps: 19
		Winterweizen: 13
Reflektanz	ASD Field Spec Pro	Winterraps: 10
	Wellenlängenbereich 350-2500 nm	Winterweizen: 11
	Mittelwert aus 3 x 3 Messungen	

Tab. 2: Bemessene Parameter und Messdesigns

2.3 ABBILDENDE HYPERSPEKTRALDATEN ZUR ANALYSE VON VEGETATION

Um räumliche Informationen über Heterogenität der Vegetation auf den untersuchten landwirtschaftlichen Flächen zu erhalten wurden abbildende Hyperspektraldaten eingesetzt. Der flugzeuggetragene Sensor ist vom Typ AISA (Airborne Imaging Spectrometer for Application, Specim). Als Plattform zur Datenaufnahme diente 2008 ein Ultraleichtflugzeug, 2009 ein Flugzeug des Typs Cessna. Aufgrund unterschiedlicher

Flughöhen konnte 2008 eine räumliche Auflösung von 1,5 m, 2009 sogar 1 m Pixelgröße erreicht werden. Die Befliegungen wurden bei Strahlungswetterlage um die Mittagszeit durchgeführt. Die spektrale Auflösung liegt bei 252 Kanälen im Wellenlängenbereich von 400 – 970 nm. Die Postprozessierung wurde mit der Software GaliGeo durchgeführt, die als Zusatz mit der Software ENVI verwendet wird. Der Prozess beinhaltet radiometrische Korrektur, sowie geometrische Korrektur. Bei den anschließenden Analysen wurde mit Radianzen gearbeitet.

Um eine geometrische Korrektur durchführen zu können, ist das System mit einem GPS/INS RT3100 ausgestattet und wird von einer Inertial Measurement Unit (IMU) unterstützt. Diese zeichnet kontinuierlich die Position zwischen GPS-Signalen nach. Aufgrund von Fehlausrichtungen der IMU weisen die Daten Driftphänomäne auf (RIES et al. 2002), die sich in optisch kenntlichen, wellenartigen Verzerrungen zeigen. Dieser Fehler ist in einigen Bändern stärker ausgeprägt als in anderen und wird in Bezug auf die Berechnung von Vegetationsindizes in der Arbeit mitdiskutiert. Eine zusätzliche allgemeine Drift erforderte eine erneute Georeferenzierung auf ein Orthofoto.

Auf der Fernerkundungsszene von 2008 ist auf Schlag 8 (Winterroggen) eine Änderung der Radianz vom westlichen zum östlichen Streifenrand ersichtlich. Dieser Fehler zeigt sich durch Albedounterschiede, also einer Verschiebung der Signalstärke in einen höheren Radianzwert über das gesamte Spektrum.

Der Sensor nimmt das Signal, der an der Oberfläche reflektierten elektromagnetischen Strahlung, flächenhaft auf und bildet die Landbedeckung ab. Die spektrale Signatur von Pflanzen hat eine typische Erscheinung, die durch Reflektion, Absorption und Transmission in den Blattzellen bestimmt wird. Für die Lichtabsorption spielen Pigmente in Vakuolen und Chloroplasten eine besondere Rolle. Das in den Blattzellen lokalisierte Chlorophyll (a+b) absorbiert photosynthetisch aktive Strahlung im roten und blauen Bereich des sichtbaren Spektrums (VIS) (vgl. Abb. 3). Dabei werden bis zu 70% des sichtbaren Lichts von Pigmenten absorbiert (SCHELLENBERG 1990).

Eine weitere stark absorbierende Oberfläche stellt Wasser dar. Für das Wasser in Blättern, liegt das Absorptionsmaximum im Wellenlängenbereich von 1450 nm und 1950 nm (SCHELLENBERG 1990). Diese Wellenlängen liegen außerhalb des Erfassungsbereichs des AISA-Sensors. Ein weiteres Wasserabsorptionsband liegt im Bereich von 920-980 nm (PEÑUELAS et al. 1993, JENSEN 2000).

2. Untersuchungsgebiet und Datengrundlagen

Die spektrale Signatur eines Bestandes ist stark von Struktur und Zustand des Gewebes abhängig und variiert somit nach Pflanzenart und Phänologie. Wie erwähnt sind im sichtbaren Licht vor allem Pigmente bestimmend für Änderungen des Absorptionsverhaltens. Im NIR hingegen sind vor allem Blattdicke und Zellstruktur ausschlaggebend für das Reflektionsniveau. Im NIR hat Absorption keinen wesentlichen Einfluss. Nicht direkt an der Blattoberfläche reflektierte Strahlung wird innerhalb des Blattes an den Zellwänden diffus reflektiert oder transmittiert. Die Reflektion von NIR wirkt sich also unsensibel auf Änderungen der Chlorophyllkonzentration aus, ist jedoch stark vom Grad der Blattbedeckung, also von LAI beeinflusst. Nicht direkt an der Oberfläche reflektierte Strahlung wird transmittiert und an der darunter liegenden Blattschicht ebenfalls reflektiert oder transmittiert. Somit dringt NIR tiefer in den Vegetationsbestand und bildet in seinem Reflektionsniveau Zell- und Bedeckungsstruktur ab, während sichtbares Licht größtenteils bereits von den Pigmenten der obersten Blattschicht absorbiert wird (vgl. Abb. 3).

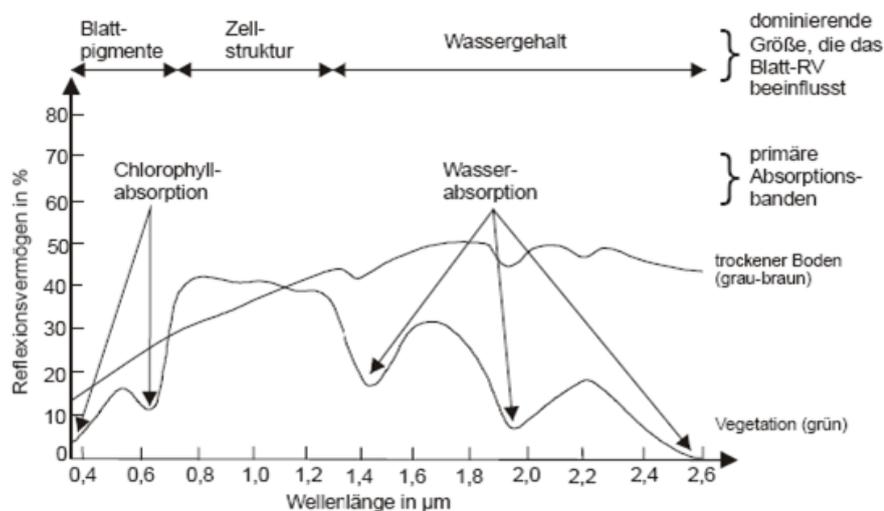


Abb. 3: Typische Spektrale Reflektion von Vegetation und Boden (KLISCH 2003)

Bei Alterung der Pflanze wird Chlorophyll abgebaut und das Reflektionsverhalten im VIS verändert sich. Die typische Absorption nimmt ab, rotes und blaues Licht werden stärker reflektiert und nähern sich einer einheitlich ansteigenden Reflektion über den gesamten sichtbaren Spektralbereich an (vgl. Abb. 4). Erst wenn die Chlorophyllkonzentration abnimmt, treten Carotinoide und Xantophylle hervor, die vorher überdeckt wurden und den Pflanzen die typische braune Farbe verleihen. Auch Wasser nimmt während der Seneszenz ab, weshalb die Absorption im Infrarotbereich aufgehoben wird. Wassergehalt

und Blattdicke haben dabei jedoch einen engen Zusammenhang und üben Einfluss auf das gesamte Spektrum aus (SCHELLBERG 1990). Den Phänologieverlauf für Winterweizen zeigt Abb. 4 mit einem Beispiel der Reflektanzänderung von Vegetation bei einsetzen der reproduktiven Phase für Raps. Die phänologischen Stadien verschieben sich leicht für deutsche Klimaverhältnisse. So gilt als langjähriges Mittel für den Beginn des Ährenschiebens bei Winterweizen in Sachsen der 2.6., für die Ernte der 4.8. (DWD 2009).

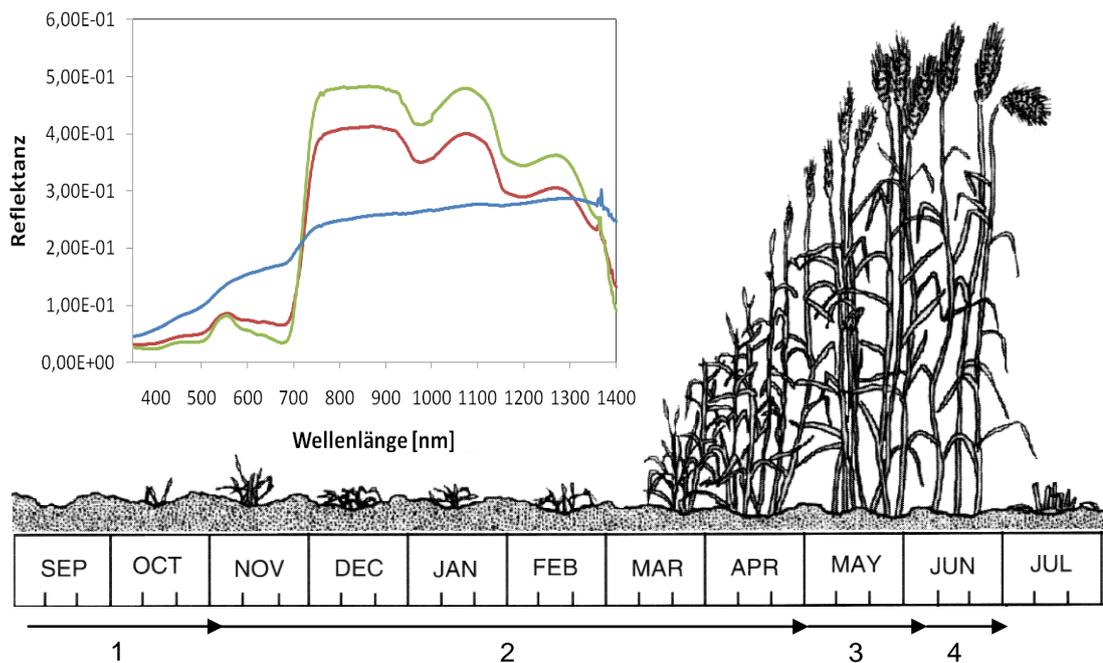


Abb. 4: Beispiel für die phänologische Entwicklung von Winterweizen in den Great Plains, USA (verändert nach JENSEN 2000). 1. Keimungsphase, 2. vegetative Phase (Entwicklung, Wachstum), 3. generative/ reproduktive Phase (Blüte), 4. Seneszenz (nach LARCHER 2001). Und spektrale Profile eines Winterrapsbestandes als grüne Vegetation (grün) und zu Beginn der reproduktiven Phase (rot) und von Boden (blau); aufgenommen mit dem ASD-Feldspektrometer.

Aus der Änderung von Pigmentmuster oder Bestandsarchitektur ergibt sich auch eine Verschiebung des Rot-Infrarot Anstiegs (Rededge), an der Alterung oder Stress der Pflanzen erkannt werden können. Je länger eine Pflanze über einen assimilierenden Blattapparat verfügt, desto höher ist die Ertragserswartung. Das bedeutet, dass anhand der Änderung der Reflektion von Vegetation der Zeitpunkt einsetzender Seneszenz erkannt werden kann und vorzeitige Prognosen über Erträge gemacht werden können. Auch Heterogenität innerhalb eines Bestandes aufgrund von Stress kann vorzeitig erkannt werden. Dies macht sich die Präzisionslandwirtschaft zu nutzen. Das Pflanzenwachstum ist stark von Wasser- und Nährstoffverfügbarkeit abhängig. Studien zum Einfluss von

2. Untersuchungsgebiet und Datengrundlagen

Stickstoffverfügbarkeit auf das spektrale Verhalten von Pflanzen wurden z.B. von WALBURG et al. (1981) durchgeführt.

Die späte Altersphase verschlechtert die Beziehung zwischen Spektraldaten und Pflanzenparametern, aufgrund der indifferenten Blatthaltung und verstärkten Bodeneinflüsse. Boden kann, je nach Bedeckungsgrad, starken Einfluss auf das Reflektionssignal nehmen. Dies wirkt sich in Fernerkundungsdaten durch Mischpixel aus. Diese bilden keine einzelnen Blätter ab, sondern vereinen meist verschiedene Oberflächen im Bereich der Größe eines Pixels. Dabei sind auch Bodenfarbe und – feuchte von Bedeutung. Im Allgemeinen hat feuchter Boden eine niedrige Reflektanz im Rot und NIR, während trockener höher in diesen Bereichen reflektiert (JENSEN 2000).

3 METHODEN

Die digitale Erfassung von schlagspezifischen Strukturen erfordert die Umwandlung von Fernerkundungsdaten in thematische Daten. Häufig wird zur Analyse von Vegetation mit Indizes gearbeitet und Vegetationsparameter aus Zusammenhängen mit *groundtruth* gewonnen. In dieser Arbeit werden zwei verfügbare Methoden zur Gewinnung räumlicher und quantitativer Informationen biophysikalischer Parameter getestet und diskutiert: empirische Modelle und überwachte Klassifikation. Die Berechnungen wurden mit der Fernerkundungs-Software ENVI (ITT Visual Information Solutions, Version 4.7) durchgeführt.

3.1 VEGETATIONSINDIZES

Vegetationsindizes (VIs) bilden häufig die Grundlage für Vegetationsuntersuchungen. Die Indizes parametrisieren die spektralen Eigenschaften von Vegetation und führen so zu einer Vereinfachung der Unterscheidung zwischen verschiedenen Bedeckungsgraden oder -arten. Häufig werden dazu Reflektions- und Absorptionsmaxima von grüner Vegetation verwendet. Bereits in den 70er Jahren wurden Differenzen zwischen Rot und NIR zur Untersuchung der Vegetation mit Fernerkundungs- und Spektrometerdaten verwendet (z.B. Tucker 1979). Dabei kann zum Beispiel aus dem Absorptions- (Rot) und Reflektionsmaximum (NIR) von Chlorophyll der Bedeckungsgrad oder der Zustand von Vegetation bestimmt werden. Welche Vegetationseigenschaften tatsächlich durch VIs beschrieben werden, bleibt weiterhin etwas strittig. Die Anzahl an Literatur und Studien hierzu ist unübersichtlich umfangreich. Offensichtlich stellen sie einen Indikator für Pflanzenwachstum, so z.B. für Biomasse, LAI und photosynthetisch absorbierte Strahlung dar. Seit den 1970er Jahren, vermehrt in den letzten Jahren, wurde eine Vielzahl von Vegetationsindizes entwickelt. Die neuere Entwicklung geht zunehmend in Richtung hyperspektraler Indizes, sogenannter *narrowband*-Indizes (z.B. MCARI, TriangularVI). Auch ältere *broadband*-Indizes werden als *narrowband*-Indizes bei Hyperspektraldaten angewendet. Durch die Verwendung schmaler Bänder können genauere Informationen über Photosyntheseaktivität und Biomasse gewonnen werden. Einen Nachteil birgt jedoch die hohe Anfälligkeit für externe Einflüsse (BROGE & LEBLANC 2000).

3. Methoden

Durch das Testen der Auswirkungen von Änderungen einzelner Vegetationsparameter auf VIs, anhand zumeist simulierter Daten, wurde die Sensibilität bestehender VIs in Bezug auf die jeweiligen Parameter untersucht (z.B. BROGE & LEBLANC 2000, BARET & GUYOT 1991) . Außerdem wurden spezielle Indizes entwickelt, die bestimmte Bestandseigenschaften abbilden und zur Prognose von z.B. LAI oder Chlorophyll eingesetzt werden (z.B. HABOUDANE et al. 2002 u. 2004, GITELSON & MERZLYAK 1996, GITELSON et al. 2003, VINCINI et al. 2008).

BARET & GUYOT (1991) u.a. unterscheiden zwischen Ratio- oder Differnce-Indizes und Orthogonalen Indizes. BROGE & LEBLANC (2000) führen zusätzlich den Begriff der Hybrid-Indizes, die eine Kreuzung der erstgenannten darstellen, an. Während der erste Typ Vegetation durch einfache arithmetische Verknüpfungen zweier Bänder parametrisiert, wird bei den orthogonalen Indizes eine Bodenlinie einbezogen. Diese beschreibt die spektrale Charakteristik des Bodens und setzt die gemessene Reflektanz mit dieser in Bezug.

Die bekanntesten VIs sind Simple Ratio (SR) und Normalized Difference Vegetation Index (NDVI) des erstgenannten Indextypus. Sie bilden sich aus Bändern im NIR und Rot in folgender Form:

$$SR = \frac{R_{NIR}}{R_{RED}}$$

$$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$$

Diese Indizes verstärken den Kontrast zwischen Boden und Vegetation und minimieren Beleuchtungseffekte. Sie zeigten sich jedoch als sensibel gegenüber Unterschieden in der Bodenfarbe (BARET & GUYOT 1991, BROGE & LEBLANC 2000). Der NDVI ist dabei der bekannteste und meist verwendete Index und gilt als relativ robust bei sehr unterschiedlichen Bedingungen. Ein Nachteil besteht darin, dass er bei hohem LAI Sättigungseffekte zeigt und somit keine lineare Beziehung zu LAI aufweist. Zur Verbesserung der Linearität wurde eine Reihe neuer Indizes entwickelt (z.B. HUETE et al. 1997, HABOUDANE et al. 2004, GITELSON et al. 2003). Ein geeigneter Algorithmus zur Bestimmung von LAI >2 scheint jedoch noch nicht konzipiert worden zu sein (GITELSON et al. 2003).

Um die Bodeneinflüsse zu minimieren, entwickelten RICHARDSON & WIEGAND (1977) den Perpendicular Vegetation Index (PVI):

$$PVI = \frac{1}{\sqrt{a^2 + 1}} (R_{NIR} - a \cdot R_{RED} - b)$$

Da hierbei jedoch Informationen über die Parameter der Bodenlinie (a,b) gegeben sein müssen, wird in dieser Arbeit der Difference Vegetation Index (DVI) verwendet. Der DVI ergibt sich aus PVI, wenn die Bodenparameter $a=1$ und $b=0$ ist (BROGE & LEBLANC 2000).

$$DVI = R_{NIR} - R_{RED}$$

Hybrid-Indizes sind aus zwei Indizes zusammengesetzt und vereinen somit die Vorteile beider. Der Soil Adjusted Vegetation Index (SAVI) von HEUTE (1988) bildet, abgeleitet vom NDVI, durch Einführen der Konstante L einen Index zur Minimierung von Bodeneinflüssen.

$$SAVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED} + L} (1 + L)$$

L : Wert für Boden, muss bekannt sein, $L=0,5$ für eine breite Reihe an Bedingungen

Für Vegetation mit mittlerem Bedeckungsgrad stellte sich $L=0,5$ als beste Anpassung heraus (BARET & GUYOT 1991). Verbesserte Versionen des SAVI (z.B. TSAVI, OSAVI) wurden entwickelt, um mehr Resistenz gegenüber Boden auch in spärlichem oder dichtem Bewuchs zu erreichen. Auch neuere Kombinationen von Indizes werden in dieser Arbeit verwendet. So z. B. der RDVI von ROUJEAN & BREON (1995), der die Vorteile von NDVI und DVI für geringen bis dichten Bewuchs vereinen soll.

HABOUDANE et al. (2002) zeigten, dass eine Kombination aus dem Chlorophyll Index TCARI und dem bodenresistenten Index OSAVI verbesserte Zusammenhänge zu Blattchlorophyll aufweisen.

Neuere Studien beschäftigen sich vor allem mit der Entwicklung neuer Indizes, die nicht nur die *greenness* der Vegetationsbedeckung abbilden, sondern sensibel auf einzelne Vegetationsparameter reagieren. So bieten gerade hyperspektrale Daten und die Anwendung von *narrowband*-Indizes das Potenzial zur quantitativen Bestimmung von Blattpigmenten.

Bestimmte Indizes wurden also entwickelt, um die einzelnen Faktoren grüner Blattmasse besser zu differenzieren. Chlorophyll-Indizes stellen zum Beispiel CARI (KIM et al. 1994) oder seine neueren Versionen, wie MCARI (DAUGHTRY et al. 2000) oder CVI (VINCINI et al. 2008) dar. Diese Algorithmen berücksichtigen von Chlorophyll beeinflusste Wellenlängenbereiche (vgl. Kap.2.3.1). Andere Indizes wurden entwickelt, um LAI zu beschreiben, wie die Gitelson-Indizes (GITELSON et al. 2002, 2003, GITELSON & MERZLYAK 1996).

Jedoch nicht nur zur Beschreibung grüner Vegetation wurden Indizes entwickelt. So zum Beispiel zeigen bestimmte Indizes Pflanzenseneszenz (z.B. PSRI) oder Pigmente wie Carotinoide und Xantophylle an (z.B. SIPI). Auch zur Bestimmung von Pflanzenwasser wurde eine Reihe von Indizes entwickelt, von denen jedoch hier nur jene getestet werden konnten, die den wasserempfindlichen Wellenlängenbereich um 920-980 nm berücksichtigen (z.B. WBI, PEÑUELAS et al. 1993).

Vegetationsindizes funktionieren mit verschiedenen Wellenlängenbereichen, von denen NIR und Rot die meist verwendeten sind. Jedoch auch der grüne Spektralbereich wird in einigen Chlorophyll-Indizes genutzt. Zunehmende Bedeutung gewinnt die Rededge, die den typischen Anstieg der Reflektion von Rot zu NIR beschreibt. In dieser Arbeit wurde außerdem der REIP, ein Index zur Parametrisierung der Rededge, einbezogen.

Um kausale Zusammenhänge zu den untersuchten Vegetationsparametern zu finden, wurden verschiedene bereitgestellte VIs verwendet. Eine Liste aller bei der Analyse berücksichtigter VIs befindet sich im Anhang.

DARVISHZADEH et al. (2008) kritisieren an der Arbeit mit Vegetationsindizes die Vernachlässigung anderer spektraler Bereiche, die wichtige Informationen zur Vegetation liefern können.

3.2 BI- UND MULTIVARIATE REGRESSION

Die empirische Erhebung von flächendeckenden Informationen über Vegetationsparameter ist selbst mit einem hohen Arbeitsaufwand nicht möglich. Zur Bestimmung unterschiedlicher Vegetationsparameter für größere Flächen stützt sich die Fernerkundung auf Vegetationsindizes. Die angewendeten Methoden sind empirische und

semi-empirische Modelle, die auf *groundtruth* aus umfangreichen Messkampagnen beruhen.

Empirische Modelle werden durch Regression aus dem Zusammenhang zwischen Vegetationsindizes und dem betrachteten Vegetationsparameter gebildet. Es handelt sich bei dieser Methode um ein häufig angewandtes Verfahren sowohl für Wald- als auch landwirtschaftliche Flächen (z.B. WIEGAND et al. 1990, BACH 1995, HABOUDANE et al. 2004). Der Nachteil empirischer Modelle besteht darin, dass sie orts- und datensatzspezifisch sind, keine allgemeine Anwendbarkeit bieten und daher für jeden Datensatz erneut aufgestellt werden müssen.

Semiempirische Modelle sind physikalisch begründet, wobei die empirischen Daten nur teilweise zur Bestimmung der Eingangsparameter verwendet werden (z.B. BARET & GUYOT 1991). Auf einem solchen Ansatz zur Berechnung des LAI beruht z.B. das CLAIR-Modell (CLEVERS 1986, KLISCH 2003).

In dieser Arbeit sollen empirische Modelle zur flächendeckenden und quantitativen Berechnung von Vegetationsparametern verwendet werden. Die Grundlage bildet eine Regressionsanalyse, bei der der beste Zusammenhang zwischen *groundtruth* und Vegetationsindizes festgestellt werden soll. Verschiedene Autoren haben unterschiedliche, bekannte Indizes als beste Prädiktoren der einzelnen Vegetationsparameter festgestellt oder neue Indizes entwickelt (z.B. BARET & GUYOT 1991, BROGE & LEBLANC 2000, HABOUDANE et al. 2002, 2004, DAUGHTRY et al. 2000). An der großen Auswahl an Indizes wird die Bindung empirischer Modelle an bestimmte Fernerkundungsszenen und Feldkampagnen deutlich. Die meisten Arbeiten auf Feldskala beschäftigen sich mit der Herleitung von Chlorophyllgehalt und LAI. Bisher enthalten sie jedoch fast ausschließlich als Grundlage simulierte Spektraldaten aus den Strahlungstransfermodellen PROSPECT und SAILH, eher selten kommen tatsächliche Fernerkundungsdaten zum Einsatz oder werden nur zur Validierung, nicht jedoch zur Modellkalibrierung verwendet. COLOMBO et al. (2002) fanden bessere Ergebnisse für empirische Modellierung als für inverse Modelle mit PROSPECT & SAILH.

Es wird davon ausgegangen, dass Vegetationsindizes die zu untersuchenden Vegetationsparameter, für die sie konzipiert wurden, gut beschreiben und zur Gewinnung flächendeckender Informationen über LAI, Blattchlorophyll, Wuchshöhe und Pflanzenwassergehalt dienen können. Mittels statistischer Methoden soll ein

3. Methoden

Regressionsmodell erstellt werden, dass eingesetzt wird, um die Vegetationsparameter für einzelne Indexwerte zu berechnen.

Obwohl für eine statistische Analyse die zufällige Verteilung der Stichproben Voraussetzung ist, wurde in der zweiten Feldkampagne darauf geachtet, eine mögliche Heterogenität, also breite Streuung der Stichproben zu erhalten. Dies war notwendig, um trotz relativ geringen Stichprobenumfangs einen möglichst großen Gradienten zur Modellierung der Parameter in allen Wertebereichen zu gewährleisten. Ein weiterer Grund für dieses Vorgehen war die Untersuchung einzelner Extremstellen. Die Erhebung eines größeren Stichprobenumfangs war im Rahmen der Kampagnen nicht möglich. Als Grundlage zur weiteren Datenauswertung wurden die Daten im Vorfeld mittels des Kolmogorov-Smirnov-Tests auf Normalverteilung geprüft und visuell durch Darstellung der Gauss'schen Kurve bewertet.

Die Regressionsanalyse findet ihren primären Anwendungsbereich in der Untersuchung von kausalen Zusammenhängen zweier oder mehrerer Variablen. Da im Falle eines Zusammenhangs Änderungen in der abhängigen Variablen „y“ Wirkungen von Änderungen der unabhängigen Variablen „x“ sind, können Regressionsmodelle zur quantitativen Bestimmung von Auswirkungen genutzt werden (BACKHAUS et al. 2006). Im einfachsten Fall haben zwei Variablen eine lineare Beziehung und y lässt sich aus der Gleichung

$$y = a + b x$$

mit:

- y - abhängige Variable
- x - unabhängige Variable
- a - Konstante
- b - Regressionskoeffizient

berechnen.

Die Gleichung beschreibt die Regressionsgerade, die als Schätzung versucht, sich den empirischen Punkten möglichst genau anzupassen. Dabei gibt der Regressionskoeffizient (b) die Steigung der Geraden an und gibt damit Auskunft, um wieviele Einheiten sich y ändert, wenn sich x um eine Einheit ändert. Die durch die Regressionsfunktion nicht beschriebenen Abweichungen der empirischen Werte von der Schätzung werden als Residuen bezeichnet.

Da hier das Regressionsmodell als Prognoseverfahren der Vegetationsparameter auf Grundlage von Vegetationsindices verwendet werden soll, ist die abhängige Variable die

groundtruth der einzelnen Vegetationsparameter (y) und die unabhängige Variable der diese am besten beschreibende Vegetationsindex (x). Tragen mehrere Indizes zur Erklärung von y bei, wird das multiple Regressionsmodell durch folgende Formel beschrieben:

$$y = a + b_1 x_1 + b_2 x_2 + b_3 x_3 \dots \dots b_n x_n$$

Der Residualwert kann sich hierbei verbessern, da mehrere Wirkfaktoren zur Erklärung herangezogen werden. Zum Vergleich werden die Regressionskoeffizienten standardisiert (Beta-Wert). Der höchste standardisierte Regressionskoeffizient spiegelt den größten Einfluss wider. Um Multikollinearität auszuschließen, wird auch der Zusammenhang der Indizes untereinander untersucht.

Für das Modell wird der beste Zusammenhang zwischen *groundtruth* und Vegetationsindex gewählt. Am besten eignet sich zur Anwendung des Modells eine lineare Beziehung, da diese aufgrund ihrer linearen Eigenschaften tatsächlich jedem Indexwert nur einen bestimmten Parameterwert zuweist. Somit ist die Prognose eines solchen Modells am Sichersten und wird auch in der Literatur angestrebt (z.B. HABOUDANE et al. 2003). Außerdem reicht meist ein lineares Modell zur Bestimmung von Objekteigenschaften in der Reflektionsspektroskopie aus, auch wenn das zu beschreibende Merkmal nicht immer linearer Natur ist (ERASMI 2002). Nicht lineare Beziehungen können auf Sättigungseffekte oder Wachstumsphänomene zurückzuführen sein (BACKHAUS et al. 2006).

Die Güte eines Regressionsmodells wird durch verschiedene Tests überprüft und angegeben. Zur Prüfung einer Regressionsfunktion muss zunächst das Regressionsmodell, d.h. wie gut y durch das Modell erklärt wird, untersucht werden. Außerdem wird im Falle eines multivariaten Modells der Einfluss einzelner Variablen auf y überprüft, um die erklärenden Variablen herauszufiltern.

Als Gütemaße für die Regressionsfunktion fungieren

- Bestimmtheitsmaß (R^2),
- Standardfehler
- Cook's Distance und zentrierte Leverage.

3. Methoden

In dieser Arbeit wurden zur Bewertung der Modelle Bestimmtheitsmaß und Signifikanz herangezogen, weshalb auf andere Kriterien nicht eingegangen wird.

Das Bestimmtheitsmaß ist das Verhältnis aus erklärter Streuung zur Gesamtstreuung. Die erklärte Streuung ist die Summe der quadrierten erklärten Abweichung, also des Abstands der geschätzten y -Werte zur x -Achse, d.h. zu $y=0$. Die Gesamtstreuung ist die Summe der quadrierten Gesamtabweichung aller Beobachtungen, also der empirischen Werte zu $y=0$. Mit weiteren Regressoren werden weitere Erklärungsansätze hinzugefügt. Dabei nimmt das Bestimmtheitsmaß ab, auch wenn die Variablen irrelevant sind (BACKHAUS et al. 2006).

Da es sich bei der Regressionsfunktion um ein stochastisches Modell handelt, muss berücksichtigt werden, dass die Stichproben bei Wiederholung um den wahren Wert schwanken. Wichtig zur Bewertung der Güte eines Regressionsmodells ist das Signifikanzniveau, das in diesem Zusammenhang festgelegt wird. Es beschreibt die Irrtumswahrscheinlichkeit des Tests. Diese ergibt sich aus der Wahrscheinlichkeit, dass der Test im Falle der Richtigkeit der Nullhypothese (d.h. es besteht kein Zusammenhang zwischen den Variablen) mit 95% zu einer Annahme dieser führt. Dementsprechend ist die Wahrscheinlichkeit, dass die Nullhypothese abgelehnt wird, 5%. Daraus ergibt sich ein Signifikanzniveau von $\alpha=0,5$. Das bedeutet, bei einem Signifikanzniveau von unter 0,5 kann davon ausgegangen werden, dass ein Zusammenhang nicht zufälliger Natur ist und nicht allein durch die zufällige Auswahl von Stichproben gegeben ist.

Aufgrund des geringen Stichprobenumfangs ist die Rückhaltung eines Teils der *groundtruth*-Daten zur Validierung des Modells nicht möglich. Das Modell wird stattdessen durch Residuenanalyse überprüft (BACKHAUS et al. 2006). Um die Stabilität und eventuelle Einflüsse durch Ausreißerwerte auszuschließen, werden auch die Kriterien Cook's Distance und zentrierte Leverage zur Bewertung der Modelle herangezogen (z.B. JANN 2009, GOERKE 2009).

Besonders bei kleinen Stichproben besteht die Gefahr, dass die Schätzung sehr stark von einzelnen Extremwerten beeinflusst wird. In diesem Zusammenhang geben Cook's Distance und zentrierte Leverage Aufschluss über das Vorkommen einflussreicher Datenpunkte und stehen somit für die Stabilität des Modells. Der Leverage-Wert, beschreibt die „Hebelwirkung“ eines Datenpunktes. D.h. er gibt an, wie stark ein Wert die gesamte Steigung einer Schätzfunktion verzerrt und somit Einfluss auf die Vorhersagewerte y ausübt. In SPSS wird der Centered Leverage berechnet. Als

Schwellenwert für die zentrierte Leverage bei kleinen Stichproben gilt die Faustregel (GOERKE 2009):

$$Le > 2(k + 1) / n$$

wobei :

k = Anzahl der Regressoren

n = Anzahl der Stichproben

Um Ausreißer zu identifizieren werden zudem standardisierte und studentisierte Residuen herangezogen. Als Schwellenwert werden Werte zwischen 2 und 4 genannt (GOERKE 2009).

Der Gesamteinfluss von Leverage und Residuen wird durch Cook's Distance ausgedrückt. Somit dient sie der Identifikation des globalen Einflusses, d.h. des Einflusses auf das gesamte Modell. Es handelt sich um eine Eliminationsstatistik, die eine Form des Bootstrapping ist. Zur Bestimmung des Grenzwertes gibt JANN (2009) die Formel $Di > 4/n$.

Anhand der genannten Kriterien wurde das beste Regressionsmodell zur Berechnung der Vegetationsparameter herausgearbeitet. Die Analyse erfolgte mit dem Statistikprogramm SPSS. Es wurde jeweils der Mittelwert der Nachbarschaften aus 9 Pixeln verwendet.

3.3 ÜBERWACHTE KLASSIFIKATION

Als wichtigstes Instrument der Fernerkundung, um thematische Karten zu generieren gilt die Zusammenfassung der Bildinformationen in Klassen (VOß 2005, FOODY & MATHUR 2004). Der Grundgedanke liegt darin, auf Basis ähnlichen spektralen Verhaltens alle Bildelemente Klassen zuzuordnen. Häufige Anwendung findet die Klassifikation vor allem in der Untersuchung von Landnutzung. Tatsächlich wird jedoch bei der Einteilung von Oberflächenstrukturen in Landnutzungsklassen die Landbedeckung erfasst (VOß 2005, RICHARDS & JIA 2006). Arbeiten zur Klassifikation des Zustands der Vegetationsbedeckung auf Feldskala liefert z.B. VOß (2005), für Vegetationsschäden in Waldgebieten REINARTZ (1989). Dabei stellt die geringe spektrale Unterscheidung der Klassen eine besondere Herausforderung dar (REINARTZ 1989). Es handelt sich bei den Klassen um die gleichen Objekte, deren Signatur jedoch z. B. durch Schädlingsbefall oder Stress voneinander abweichen.

3. Methoden

Die Klassenzugehörigkeit von Spektren bzw. Pixeln muss bekannt sein, um eine sinnvolle Klassifikation durchzuführen und die Ergebnisse interpretieren zu können (CANTY 1999). Daher ist die üblicherweise verwendete Methode Überwachte Klassifikation, bei der die Spektren mit ausgewählten Trainingspektren verglichen und den entsprechenden Klassen zugeordnet werden.

Die Methode der Klassifikation soll auf ihre Anwendbarkeit bei geringen *groundtruth*-Daten getestet werden. Informationen über den Pflanzenwassergehalt zum Zeitpunkt der Datenaufnahme im Juli 2008 werden benötigt, um ihren Anteil am Mikrowellensignal ermitteln zu können. Da jedoch zu wenig *groundtruth* zur Verfügung steht, um empirische Modelle anzuwenden, müssen alternative empirische Methoden in Betracht gezogen werden. Hier soll die Klassifikation von Pflanzenwassergehalt unter Verwendung nur eines Trainingspektrums getestet werden, um Potentiale der Methodik erkennen zu können. Dazu werden in der Software ENVI bereitgestellte Klassifikationstechniken anhand der Daten von 2009 getestet, da für diese Szene *groundtruth* zur Bewertung der Methode zur Verfügung steht. Im Anschluss wird die beste Klassifikationstechnik auf die Fernerkundungsszenen von 2008 angewendet. Außerdem wird die Methode zur Klassifikation von Wuchshöhe angewendet, um die Ergebnisse mit denen der modellierten Wuchshöhe zu vergleichen.

Die überwachte Klassifikation wurde in folgenden Schritten durchgeführt:

- Auswahl der Klassifikationsverfahren
- Auswahl der Klassen
- Auswahl der Trainingspektren
- Kalibrierung der Klassifikationsmethode und Training
- Klassifikation
- Ergebnisprüfung

Ein klarer Vorteil der Klassifikation gegenüber der empirischen Modellierung ist die Durchführung auch mit relativ geringem Referenzdatenumfang. Insbesondere nicht-parametrische Klassifikationsmethoden liefern auch bei weniger umfangreichen und repräsentativen Trainingsdatensätzen gute Ergebnisse (FOODY & MATHUR 2004). Neben dem Spectral Angle Mapper (SAM) wurden daher die nicht-parametrischen Klassifizierer

künstlicher Neuronaler Netze (NN) und Support Vektor Maschine (SVM) angewandt. Bei der Auswahl der Methoden wurde darauf geachtet, dass alle 252 Bänder der Hyperspektraldaten bei der Klassifikation berücksichtigt werden. Die nicht-parametrischen Techniken stellten sich für die Anwendung bei nicht-merkmalsreduzierten Hyperspektraldaten als geeignet heraus (MELGANI & BRUZZONE 2004). Auch hier wurden die Methoden an Daten getestet, bei denen keine Hauptkomponentenanalyse zur Reduktion der Dimensionalität durchgeführt wurde. Verfahren wie der häufig verwendete Maximum Likelihood Classifier bedürfen einer Überbestimmung der Trainingspektren. Sie benötigen also mehr Trainingspektren als zur Klassifikation verwendete Bänder und wurden daher nicht zur Analyse herangezogen (RICHARDS & JIA 2006). Alle drei verwendeten Techniken lassen spektral sehr hoch aufgelöste Daten, wie sie hier verwendet wurden, zu.

Die Festlegung der Klassen erfolgte auf Basis des Wertebereichs der *groundtruth* des zu untersuchenden Merkmals. Die Klassen wurden dabei so eingeteilt, dass im Anschluss jeweils ausreichend Daten zur Qualitätsprüfung zur Verfügung standen. Somit werden klassenbedingte Unterschiede in der Ergebnisprüfung aufgrund von zu kleinen oder zu großen Klassen verhindert. Kleinere Klassen sind bei der Genauigkeitsprüfung benachteiligt (RICHARDS & JIA 2006). Aufgrund der Datenlage, wurden 3 Klassen gebildet, für die jeweils ein repräsentatives Trainingspektrum gewählt wurde.

Der schwierigste Teil der Klassifikation liegt in der Festlegung geeigneter Trainingsgebiete. Hierbei sind fachliche Kenntnisse über das spektrale Verhalten der zu untersuchenden Objektklassen von Vorteil. Trainingsdaten und Trainingseinstellungen können mehr Einfluss auf die Klassifikationsergebnisse ausüben als die Klassifikationsmethode selbst. Die Trainingsdaten sollten die jeweilige Klasse repräsentativ beschreiben und sich möglichst voneinander absetzen, um eine eindeutige Klassenzuordnung zu ermöglichen (z.B. VOß 2005). Ein Vergleich der Spektren der einzelnen Klassen gibt dabei Aufschluss über mögliche Klassenabgrenzungen. Dabei erfolgt die Auswahl nicht auf statistischer Ebene, da dies auch bei dem kleineren Datensatz von 2008 nicht möglich ist und die Genauigkeit der Klassifikationen auf dieser Basis untersucht werden soll. Es werden Trainingspektren durch den Mittelwert einer Nachbarschaft aus 9 Pixeln gebildet.

Im Vorfeld der letztendlichen Klassifikation erfolgte eine Justierung der veränderbaren Parameter der in die Software ENVI implementierten Algorithmen, um möglichst hohe Klassifikationsgenauigkeiten zu erhalten. Pixel-basierte Klassifikationsmethoden

berücksichtigen Zusammenhänge zwischen umliegenden Pixeln nicht. Daher neigen sie zu Überbestimmung und kleinräumigeren Abgrenzungen als gewünscht (KAMAGATA et al. 2008). Ein gewisses Maß an Generalisierung ist daher erwünscht und kann durch bestimmte Einstellungen angepasst werden. Die Parameter der jeweiligen Klassifikationstechniken werden im folgenden Abschnitt beschrieben. Auf die Parametereinstellung folgt das Training des Algorithmus auf Grundlage der Trainingspektren.

Die Bewertung der Genauigkeit der Klassifikationsmethode und die Feststellung des besten Algorithmus für diese Anwendung wird üblicherweise anhand von Pixeln durchgeführt, deren Klassenzuordnung bekannt ist, die jedoch nicht beim Training verwendet wurde (FOODY & MATHUR 2004). Die Genauigkeit der Klassifikationsmethoden wurde mittels Fehlermatrizen ermittelt. Die *confusion matrices* stellen die übliche Methode zur Evaluierung von thematischer Genauigkeit dar (z.B. BANKO 1998, ARNOFF 1982, CONGALTON 1991). Ein besonders schnelles und häufig verwendetes Entscheidungskriterium stellt die *overall accuracy*, in Bezug auf einzelne Klassen die *user-* bzw. *producer accuracy* dar. Sie werden auch in dieser Arbeit zur Erfolgsprüfung der Klassifikationsverfahren herangezogen. Fehlklassifizierungen geben Aufschluss darüber, welche der getesteten Klassifikationstechniken sich am besten zur Gewinnung von Informationen über die quantitative Verteilung von Vegetationsparametern eignet. Diese soll zukünftig eine schnelle Auswertung der Daten ermöglichen, insbesondere bei geringen Kapazitäten Bodeninformationen zu erheben. ARNOFF (1982) u.a. legen als äquivalent zu gewünschten 95 % Vertrauenswahrscheinlichkeit eine durch die *confusion matrix* ermittelte Gesamtgenauigkeit der Klassifikation von 85% fest. Das tatsächliche Minimum kann jedoch stark mit dem Umfang verfügbarer Validierungswerte und der damit verbundenen erlaubten Anzahl an Fehlklassifikationen variieren.

3.3.1 Spectral Angle Mapper (SAM)

Der Spectral Angle Mapper ist eine physikalisch basierte Klassifikationsmethode. Sie erlaubt eine schnelle Darstellung spektraler Ähnlichkeit zu Referenzspektren (KRUSE et al. 1993). Die Zuordnung eines Pixels zu einem Referenzspektrum erfolgt durch die Berechnung des Winkels zwischen den zwei Punkten als Vektoren in einem Merkmalsraum mit Dimension gleich der Anzahl der spektralen Kanäle, vom

Koordinatenursprung ausgehend (vgl. Abb. 5). Für die AISA-Szenen bedeutet dies, dass in diesem Merkmalsraum 252 Kanäle berücksichtigt werden.

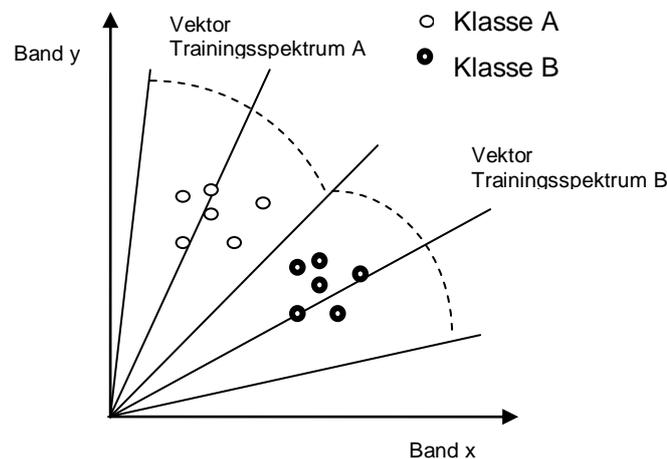


Abb. 5: Schematische Darstellung des Prinzips der Klassifikation mit Spectral Angle Mapper.

Die Technik des Spectral Angle Mapper setzt als Basis zur Klassifikation Reflektanzen voraus (KRUSE et al. 1993). Der Fehler bei der Verwendung von Radianzen ist jedoch nicht signifikant, da der Ursprung dennoch nahe Null liegt (ITT Visual Information Solutions 2009). Wenig beleuchtete Pixel liegen näher am Ursprung als Pixel mit der gleichen Signatur, aber stärkerer Beleuchtung. Da die Winkel hierbei gleich bleiben, ist die Methode relativ resistent gegenüber topographisch bedingten Beleuchtungseffekten (KRUSE et al. 1993) und Sonnenstand. Ein weiterer Vorteil ist, dass ein Vergleich von Labor- und Fernerkundungsspektren möglich ist (KRUSE et al. 1993). SAM wurde für geologische Anwendungen entwickelt und kommt daher in der Kartierung relativ homogener Oberflächen zum Einsatz. Durch Veränderung der Grenzwerte einzelner Klassen kann der Winkel vergrößert werden, in dem Pixel als einer Klasse zugehörig erkannt werden.

3.3.2 Künstliche Neuronale Netze (NN)

Das Prinzip der künstlichen Neuronen Netze ist ein überwachtetes Lernverfahren und leitet sich aus synoptisch verknüpften Neuronen der Biologie ab. Die Verknüpfung eines

Netzes durch Neuronen, die durch einen Lernprozess trainiert werden, bildet ein nicht-lineares Modell. Neuronale Netze dienen in ihrer Anwendung zur Klassifikation von Fernerkundungsdaten der Bestimmung von Parametern für Diskrimantenfunktionen, d.h. der Funktionen zur Abgrenzung von Klassen im n-dimensionalen Merkmalsraum. Die Abgrenzung erfolgt auf Grundlage der ausgewählten Trainingsspektren. Eine genaue Beschreibung des Verfahrens zur Anwendung bei Fernerkundungsdaten und eine mathematische Auseinandersetzung geben RICHARDS & JIA (2006) und CANTY (1999).

Abb. 6 zeigt den Aufbau eines künstlichen Neuronalen Netzes. Die Eingangssignale (x_1, \dots) werden dazu mit Gewichten (ω_1, \dots) multipliziert. Die Summe erscheint am Ausgang und gilt als Aktivierungsfunktion des Neurons. Die Gewichtung ω_0 hat die Funktion eines Vorspannungsgewichtes (*bias weight*) und verhindert, dass die trennende Gerade durch den Achsenschnittpunkt verlaufen muss. Die Ausgabe muss hierbei keine lineare Funktion darstellen. Für gewöhnlich bietet sich zu Klassifikationszwecken eine logistische Funktion an. Diese soll nicht nur eine Diskriminierung der beiden Klassen ermöglichen, sondern auch a-posteriori Wahrscheinlichkeiten der Klassenzugehörigkeit anderer Pixel ermöglichen (CANTY 1999).

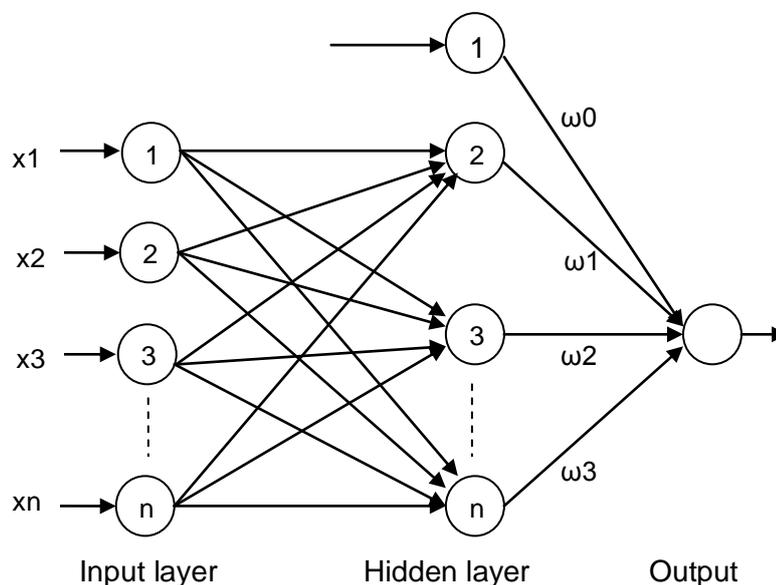


Abb. 6: Schematische Darstellung eines feed-forward Neuronalen Netzes (verändert nach CANTY 1999).

Vor der Klassifikation wird also das Netzwerk trainiert. Die in ENVI implementierte Klassifikation Neuronaler Netze nutzt dabei eine *Standard Backpropagation* Technik. Während des Lernprozesses werden die Gewichtungen optimiert, um den Unterschied zwischen *output* und gewünschtem *output* zu minimieren. Beim Verfahren der *Backpropagation* wird dazu der mittlere quadratische Fehler (RMS-Fehler - *root mean square error*) durch das Netz zurückverfolgt. Dabei werden die Gewichtungen solange angepasst, bis der RMS-Fehler einen bestimmten Wert erreicht und der *output* dem Ziel entspricht.

Für die Durchführung einer Klassifikation mit Neuronalen Netzen bedeutet dies, dass nach Einstellung der Modellparameter in einem ersten Schritt willkürliche Gewichte gelegt werden. Nacheinander werden die Trainingspixel in das Netz gespeist. Zunächst ist mit einem inkorrekten *output* zu rechnen. D.h. aufgrund der willkürlichen Gewichte werden die Trainingsdaten falschen Klassen zugeordnet (RICHARDS & JIA 2006). Die Gewichte werden angepasst, bis eine geeignete Funktion gefunden ist. Dazu wird der RMS-Fehler des *output* durch das Netz zurückverfolgt, woher die Bezeichnung *Backpropagation* stammt. Dieser Vorgang wird wiederholt, bis sich der RMS-Fehler auf einen akzeptablen Wert reduziert hat und die Trainingsdaten den richtigen Klassen zugewiesen werden. Nachdem das Netz trainiert wurde, kann die Klassifikation durchgeführt werden.

ENVI verwendet ein *multilayer feed-forward network*. Der Aufbau eines *feed-forward* Neuronalen Netzes zeichnet sich durch die Verknüpfung aller *input*-Perzeptronen mit denen des folgenden *Layers* aus (ITT Visual Information Solutions 2009). Die Layeranzahl kann frei bestimmt werden, es zeigte sich jedoch, dass ein 3-Layer-Netzwerk für die meisten Anwendungen ausreicht (RICHARDS & JIA 2006). Die *Training Threshold Contribution* gibt die Größe der Verteilung der internen Gewichte unter Berücksichtigung des Aktivierungslevels des Neurons an. Setzt man die Verteilung gleich 0, werden die Gewichtungen nicht angepasst. Eine Anpassung der *Training Threshold Contribution* kann zu besseren Klassifikationsergebnissen führen, zu viele Gewichtungen können jedoch zu wenig generalisierend sein. Die Trainingsrate bestimmt den Umfang der Anpassung der Gewichte. Eine hohe Rate ermöglicht ein schnelleres Training, führt jedoch häufig zu Schwankungen während des Trainings und kann seinen Erfolg verhindern. Das *Trainingsmomentum* hingegen kann das Risiko von Schwankungen auch bei höheren Trainingsraten herabsetzen. Eine höheres *Trainingsmomentum* trainiert mit größeren Schritten, dabei wird die Änderung von Gewichten stabilisiert (ITT Visual Information Solutions 2009).

3.3.3 Support Vector Machine (SVM)

Support Vector Machines sind zwar ein gebräuchliches Maschinenlernverfahren, in der Fernerkundung finden sie jedoch erst seit einigen Jahren Anwendung. Zur Klassifikation werden sie vor allem in neueren Studien vermehrt genutzt, unter anderem von WASKE (2007), FOODY & MATHUR (2004), HUANG et al. (2002).

Im Wesentlichen wird bei Klassifikation mit SVM eine die Klassen optimal trennende *hyperplane* auf Trainingsdaten angepasst. Dabei wird ähnlich einer Regression die gerade gesucht, die genau zwischen den Trainingsvektoren im Merkmalsraum liegt. Für die Anpassung der trennenden *hyperplane* werden jedoch nur die Trainingsdaten verwendet, die genau an der Grenze der Klassen liegen. Diese sind die sogenannten *support vectors* (Abb. 7). Die übrigen Trainingsdaten werden bei der Anpassung der Klassengrenzen nicht berücksichtigt.

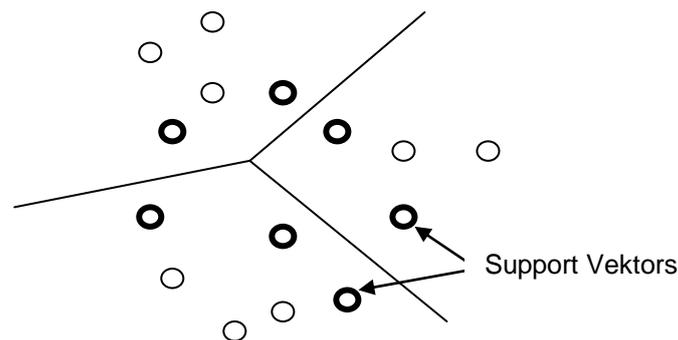


Abb. 7: Schematische Darstellung der Klassifikation mit einer Support Vektor Maschine.

Ein Vorteil der Methode besteht darin, dass sie ein gewisses Maß an Fehlklassifikationen zulässt. Durch Einführen einer Schlupfvariablen können nicht linear trennbare Klassen einzelne Vektoren auslassen, die nicht bei Anpassung der *hyperplane* berücksichtigt werden. Dies ist z.B. im Falle von Messungenauigkeiten ein Vorteil.

Bei nicht separierbaren Klassen können die Daten aus diesem Basisansatz der SVM in einen höher dimensionalen Raum überführt werden, was die lineare Trennung vereinfacht. Diese transformierte Hyperebene wird von einer Kernelfunktion gestützt, die eine Rücktransformation in die dadurch nicht mehr lineare Hyperebene ermöglicht. ENVI bietet *lineare*, *polynomiale*, *radial basis function* und *sigmoid* Kernelfunktion an. SVM ist

eigentlich ein binäres Verfahren, wurde aber zur Multiklassifikation ausgeweitet. Einen guten Überblick über Klassifikation mit SVM in der Fernerkundung und die mathematischen Grundlagen der Methode geben z.B. RICHARDS & JIA 2006, HUANG et al. 2002 und FOODY & MATHUR 2004.

Eine Erhöhung des *Penalty Parameter* erschwert Fehlklassifikationen und führt damit zu einem exakteren Modell, kann jedoch auch fehlende Generalisierung und Überbestimmung zur Folge haben. Das Hinzufügen von *Pyramid Levels* setzt die Nummer der Hierarchien zur Transformation in höhere Dimensionen. FOODY & MATHUR 2004 fanden heraus, dass für SVM keine statistische Auswahl der Trainingsgebiete mehr nötig ist, wie es für konventionelle statistische Verfahren wie Maximum Likelihood der Fall ist.

4 ERGEBNISSE

In diesem Kapitel werden die Ergebnisse der Gewinnung von LAI, Chlorophyll und Wuchshöhe auf den Untersuchungsflächen durch empirische Modelle vorgestellt. Die Modelle werden auf Grundlage von Regressionen zwischen *groundtruth* und Vegetationsindizes erstellt. Zur Gewinnung von Pflanzenwassergehalt, der eine besondere Rolle für den Zustand von Vegetation und deren Einfluss auf Mikrowellensignale spielt, werden Klassifikationsalgorithmen getestet, da nicht ausreichend *groundtruth* zur Kalibrierung eines empirischen Modells zur Verfügung steht. Im Vorfeld werden Eigenschaften von Getreide während ihres Lebenszyklus betrachtet, um aus phänologiespezifischen Unterschieden von Vegetationsparametern auf Merkmale räumlicher Variabilität schließen zu können. Außerdem werden Standortfaktoren betrachtet, die unterschiedliche Zustände von Vegetation auf den Untersuchungsflächen erklären könnten. Da die Fernerkundungsdaten, wie in Kap. 2.3 dargestellt, Fehler aufweisen, werden die verwendeten Vegetationsindizes optisch auf ihre Sensibilität gegenüber solcher Faktoren geprüft, bevor sie durch Regressionsanalyse statistisch auf ihre Eignung zur Beschreibung der vier Parameter untersucht werden.

4.1 ZEITLICHE VARIABILITÄT VON VEGETATIONSPARAMETERN AUF GETREIDEFLÄCHEN

Ursachen, für auf den Fernerkundungsszenen sichtbare Heterogenität, können Reife oder spärlicher Bewuchs sein. Wie in Kapitel 2.3 dargestellt erhöht sowohl Boden als auch abgestorbene bzw. reife Pflanzenmasse die Reflektion im sichtbaren Wellenlängenbereich und reduziert sie im NIR. Daher ist eine Unterscheidung zwischen Bodensignal und seneszenten Pflanzenmasse in den Fernerkundungsaufnahmen schwierig.

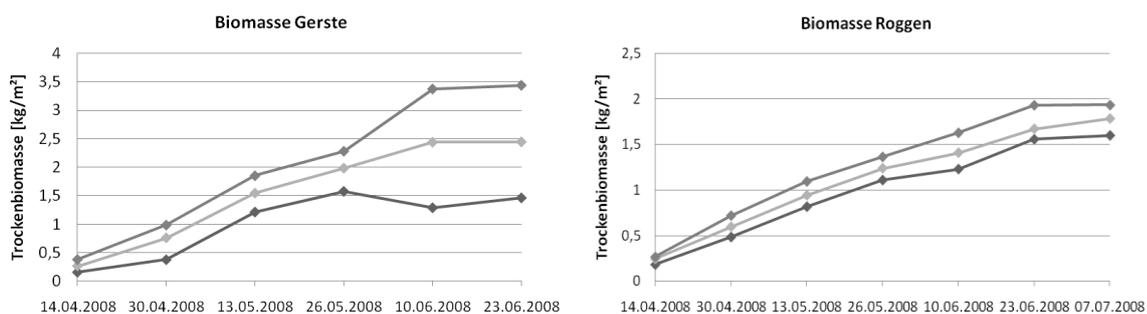
Biophysikalische und biochemische Parameter entwickeln sich sehr unterschiedlich über die Vegetationsperiode. Wasser- und Stickstoffstress führen zu physiologischen und phänologischen Änderungen der Pflanze und zu reduzierter Vitalität. Die Vitalität ist verantwortlich für Trockenmasse und Ertrag einer Pflanze, da von ihr auch die photosynthetische Aktivität abhängt (KNEUBÜHLER 2002). Innerhalb der

4. Ergebnisse

landwirtschaftlichen Flächen kann standortbedingte Heterogenität gegeben sein und unterschiede in der Phänologie bewirken. Bestimmte Schlüsselparameter könnten somit Rückschlüsse auf stressbedingte Unterschiede in der Entwicklung der Pflanzen zum Aufnahmezeitpunkt der abbildenden Hyperspektraldaten zulassen. Einzelne Vegetationsparameter wurden über die Vegetationsperiode 2008 gemessen und können anhand von Zeitreihen für die Entwicklung von Getreide zurückverfolgt werden. Abb. 8 zeigt Änderungen der Pflanzenparameter über die Vegetationsperiode. Wintergerste wurde bereits vor dem 7.7.2008 geerntet, weshalb für dieses Datum nur Winterroggen bemessen werden konnte.

Beide Pflanzenarten zeigen eine ähnliche Entwicklung. Die Biomasse nimmt von der vegetativen Phase an zu, stagniert jedoch fast bei Einsetzen der reproduktiven Phase. Der Blattflächenindex (LAI) hingegen geht ab Entwicklung der Blüte, also Beginn des reproduktiven Stadiums, zurück. Dies sind die Auswirkungen von Änderungen in der Blattarchitektur. Die Zunahme von LAI bei Roggen zum letzten Messtag (7.7.) ist auf Windwurf zurückzuführen. Chlorophyll hat schon von Beginn an fast seine Höchstkonzentration und bleibt bis zur Blüte relativ konstant. Zur Bildung der Blüte wird Chlorophyll verwertet und abgebaut, die Konzentration im Blatt sinkt. Nachdem EWT (Pflanzenwasser des Bestands, kg/m^2) mit Zunahme der Biomasse steigt, nimmt auch dieser nach der Blüte mit einsetzender Alterung ab. GWC (Pflanzenwassergehalt, %) hingegen sinkt über die gesamte Vegetationsperiode. Die Wuchshöhe verhält sich dem LAI ähnlich und zeigt mit der Reife eine Abnahme, was mit Änderungen der Zellstruktur und Wasserverlust zusammenhängt.

EWT nimmt bereits vor den übrigen Parametern ab, weshalb er als Schlüsselparameter für den Zeitpunkt einsetzender Reife angesehen werden kann und als interessanter Parameter für Ernteprognosen. Für Roggen ist diese Aussage nicht ganz eindeutig zu treffen, dabei ist jedoch zu beachten, dass die Anzahl repräsentativer Stichproben sehr gering ist und an den Messtagen jeweils unterschiedliche Punkte bemessen wurden.



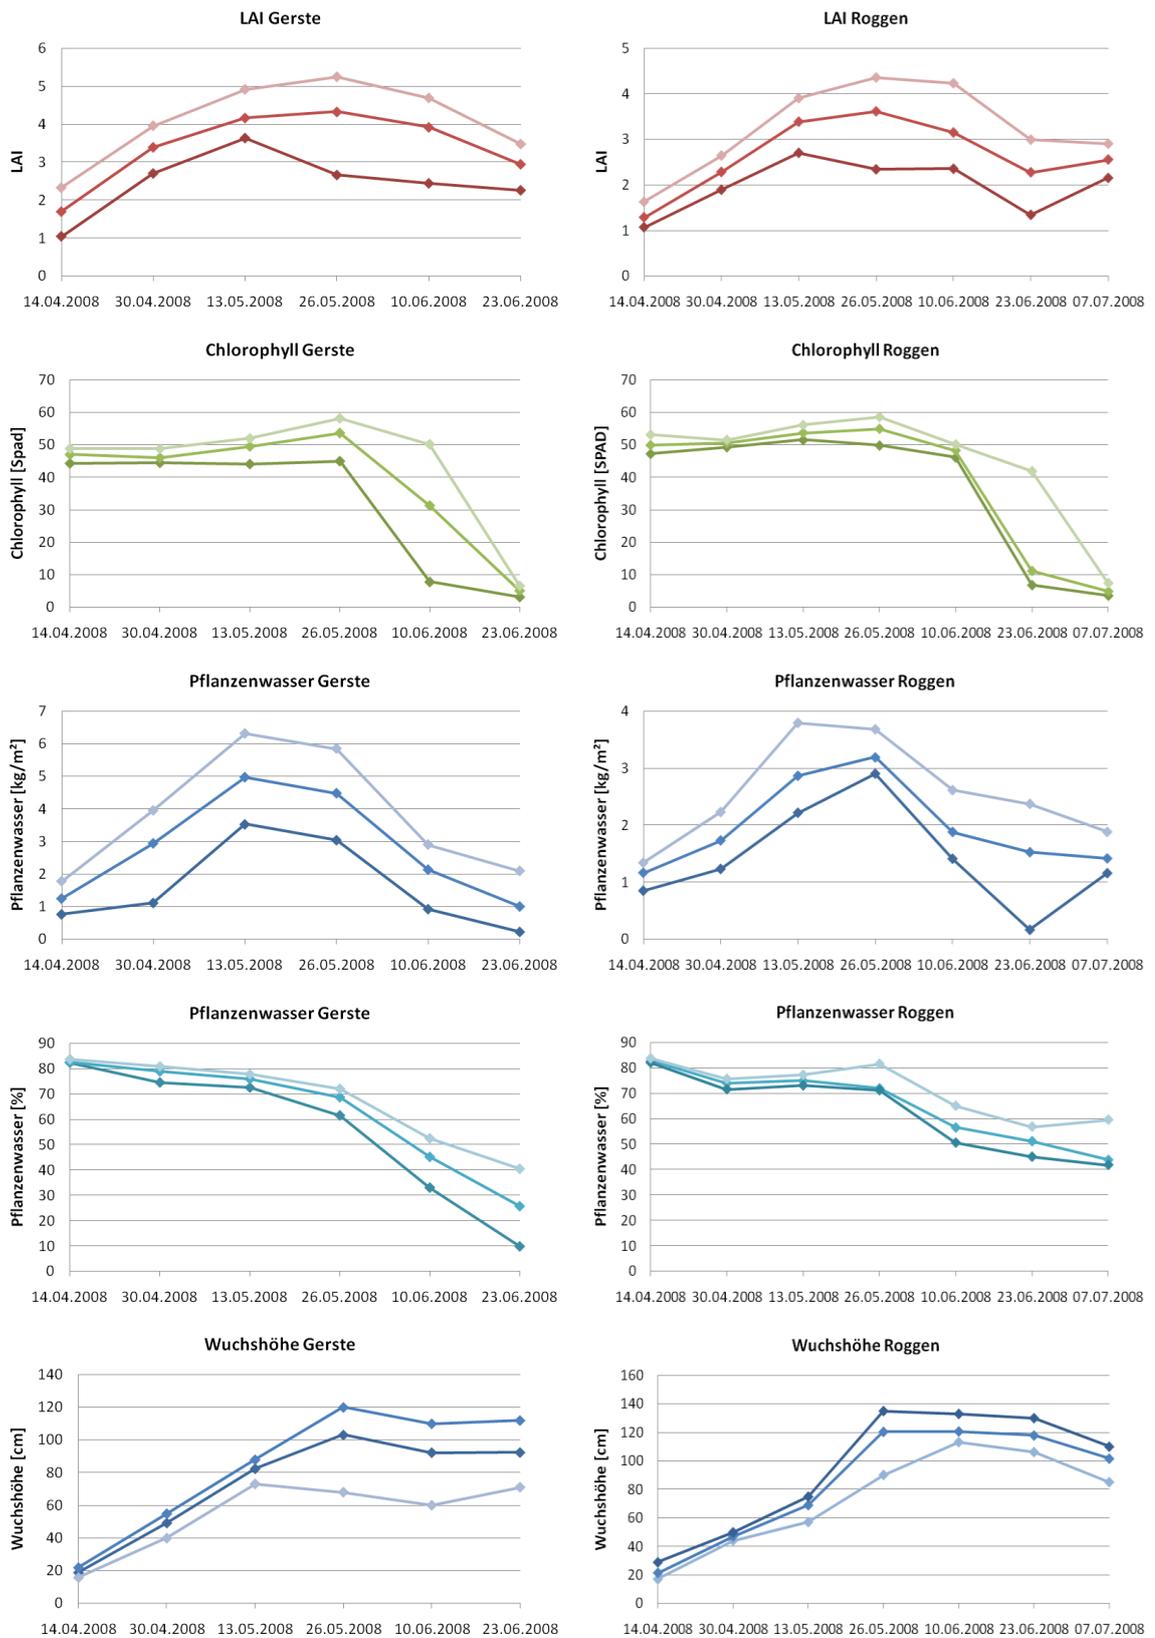


Abb. 8: Entwicklung von Vegetationsparametern bei Wintergerste und Winterroggen über die Vegetationsperiode 2008

4. Ergebnisse

Datum	Entwicklungsstadium	BBCH- Code
26.3.	Blattentwicklung	13
14.4.	Bestockung	23
30.4.	Schossen	30
13.5.	Ähren-/Rispenbildung	57
26.5.	Blüte	65/69
10.6.	Fruchtentwicklung	73
23.6.	Frucht- und Samenreife	85
7.7.	Frucht- und Samenreife	89

Tab. 3: Makrostadien von Wintergerste und Winterroggen über die Vegetationsperiode 2008

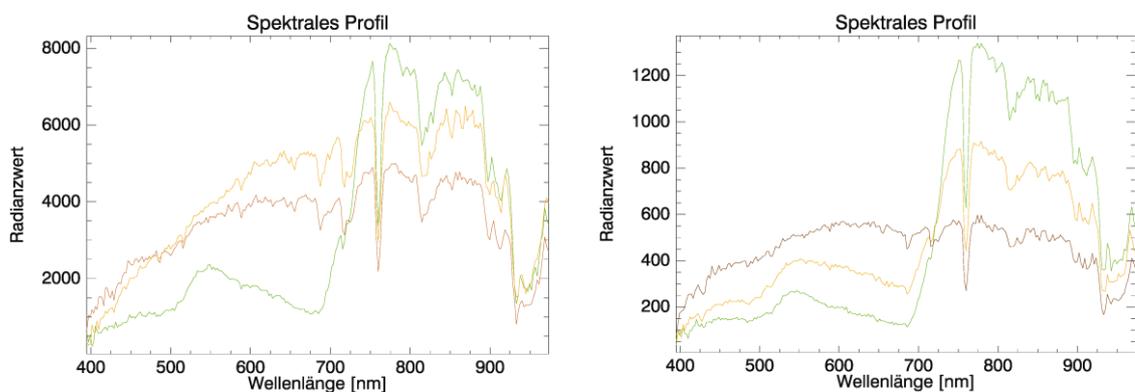
4.2 RÄUMLICHE VARIABILITÄT VON VEGETATION AUF DEN UNTERSUCHUNGSFLÄCHEN

Bevor die räumliche Verteilung von Vegetationsparametern quantitativ ermittelt wird, stellt sich die Frage, in welcher Form sich Variabilität innerhalb der Bestände darstellt und welche Faktoren diese auslösen. Zunächst wurden NDVI-Karten mit Bodenkarten und DGM verglichen um Informationen über die Standorteigenschaften und entsprechende Variabilität innerhalb der Monokulturen zu erhalten. Im Anschluss wurden Zusammenhänge zwischen den verschiedenen Vegetationsparametern untersucht.

Muster in der Vegetation sind größtenteils boden- und reliefbedingt. Insbesondere die Reichsbodenschätzung zeigt, dass die Bodenart eine wichtige Rolle spielt, in Bezug auf Wasser- und Nährstoffversorgung unterschiedlicher Standorte. Bei Betrachtung der Geländegegebenheiten und der kleinräumigen Bodenvariabilität fällt auf, dass vor allem sandige Kuppen mit niedrigen NDVI-Werten korrespondieren. Bereiche mit Ackerzahlen unter 40 weisen meist auch geringe Indexwerte auf. Die MMK lässt solch feine Strukturen wenig erkennen. Auf Schlag 12 (Wintergerste, Winterraps) werden besonders hohe Indexwerte in Nähe des Schnellbachs erreicht, der zwischen den Untersuchungsflächen entlang führt und einen Reliefabfall bedingt. Auf den anderen Flächen ist dies nicht der Fall. Auf Schlag 8 (Winterroggen, Winterraps) haben sich bachnah Gleye ausgebildet, weshalb diese Bereiche keine hohen Indexwerte aufweisen. Die Felder zeigen in den beiden Aufnahmejahren ähnliche, aber doch leicht abweichende Muster in der

Vegetationsbedeckung. Diese machen sich jedoch vor allem durch stärkere Ausprägung der Unterschiede im Bestand des seneszenten Getreides 2008 bemerkbar. Unterschiede in der Vegetationsdecke sind hier viel stärker ausgeprägt, was auf das späte Entwicklungsstadium zurückzuführen ist. Die Pflanzen in Kuppenbereichen waren bereits stark ausgetrocknet. Unterschiedliche Entwicklungen der Vegetation in früheren Phänologiestadien kommen nicht so stark zum Ausdruck.

Abb. 9 zeigt die spektralen Profile von Wintergerste und Winterraps für Bereiche mit geringen und hohen NDVI-Werten. Es wird deutlich, dass die Differenz aus NIR und rotem Wellenlängenbereich bei grüner Vegetation höhere Indexwerte ergibt. Auch zeigt Abb. 9 dass die spektralen Charakteristika grüner und seneszenten Vegetation für Wintergerste aufgrund des fortgeschrittenen Stadiums stärker ausgeprägt sind als für Winterraps. Die seneszenten Bereiche des Wintergerstebestandes weisen nicht mehr die typische Absorption im sichtbaren Licht auf und das Signal ähnelt stark der Reflektion von Boden (Abb. 9a). Die einzige Unterscheidung bietet eine erhöhte Reflektion im NIR seneszenten Vegetation im Vergleich zu Boden.



a)

b)

Abb. 9: Spektrale Profile von a) Wintergerste, b) Winterraps. Braun: Boden, grün: grüne Vegetation (hohe NDVI-Werte), orange: seneszente/spärliche Vegetation (niedrige NDVI-Werte). Unterschiede in den Radianzwerten für Wintergerste und Winterraps ergeben sich aus der Skalierung bei der radiometrischen Korrektur.

Da es sich bei den abbildenden Hyperspektraldaten um Mischpixel handelt, wird die Unterscheidung zwischen spärlichem Bewuchs, der den Effekt des Bodenhintergrunds verstärkt und seneszenten, trockener und gelber Vegetation schwieriger.

4. Ergebnisse

Es existieren positive Zusammenhänge zwischen den Parametern Biomasse, LAI, Pflanzenwasser und Wuchshöhe. Bei allen Pflanzenarten zeigen die Wuchshöhe und LAI moderate Zusammenhänge mit R^2 zwischen 0,42 und 0,62. Sie weisen jedoch stärkere exponentielle Zusammenhänge mit R^2 bis zu 0,77 auf. Da ausreichend *groundtruth* von Biomasse und Chlorophyll nur 2009 erhoben wurde, können Zusammenhänge mit Chlorophyll, Biomasse und Pflanzenwasser nur für Winterraps und Winterweizen untersucht werden. Dabei weisen alle Parameter gute Zusammenhänge auf, mit Ausnahme von Chlorophyll. Chlorophyll zeigte keine signifikanten Zusammenhänge mit anderen Parametern. Lediglich zwischen der Wuchshöhe oder LAI und Chlorophyll für Raps konnte ein schwacher negativer Zusammenhang festgestellt werden (linear: $R^2=0,27$ bzw. $0,24$). Allgemein sind die Zusammenhänge von LAI mit den übrigen Parametern gut. Die höchsten Korrelationen ergeben sich jedoch bei EWT. Der Bestandwassergehalt (EWT) hat deutlich bessere Zusammenhänge mit LAI und anderen Parametern als Pflanzenwassergehalt (GWC). Chlorophyll hingegen zeigt einen geringfügig besseren Zusammenhang mit GWC verglichen mit EWT. Es wird deutlich, dass die Zusammenhänge stark abhängig sind von der Ebene der Aufnahmemethode. Die Messwerte von Chlorophyll und GWC repräsentieren Parameter auf Blatt- bzw. Pflanzenebene, während die übrigen Parameter die Vegetation auf Bedeckungsebene beschreiben.

Zusammenfassend lässt sich sagen, dass Variabilität innerhalb der Monokulturen größtenteils boden- und reliefbedingt ist. Vor allem auf sandigen Kuppen zeichnet sich die Vegetation durch geringeren LAI, geringere Wuchshöhe, geringere Biomasse und geringeren Pflanzenwassergehalt aus. Aussagen über die Verteilung von Chlorophyll lassen sich schwer treffen, für Raps besteht jedoch ein leichter inverser Zusammenhang mit LAI und somit die Tendenz zu höheren Konzentrationen in Bereichen mit spärlicher Vegetation.

Die Vegetation auf weniger wasserversorgten Standorten zeigt sich bei reifem Getreide (Daten 2008) bereits vertrocknet und somit in einem älteren Stadium als in anderen Bereichen. Die Kulturpflanzen von 2009 (Winterraps, Winterweizen), die in einem früheren Phänologiestadium waren, weisen in den schlecht versorgten Bereichen eine geringere phänologische Entwicklung auf.

4.3 BERECHNUNG DER VEGETATIONSINDIZES

Die abbildenden Hyperspektraldaten wurden als Radianzen verwendet. Einflüsse der Atmosphäre, wie Streuung und Absorption des Lichts, sind hierbei nicht korrigiert und haben Einfluss auf das spektrale Signal, das den Sensor erreicht. Durch Parametrisierung der Spektren mittels Vegetationsindizes, wird in dieser Arbeit hauptsächlich mit relativen Werten gearbeitet. Um Atmosphäreneinflüsse auf Vegetationsindizes abschätzen zu können, wurden Indizes aus abbildenden Hyperspektraldaten (AISA) mit Indizes aus Reflektanzen der Feldspektrometerdaten (ASD) verglichen (Abb. 10).

Dabei zeigen sich sehr unterschiedliche Ergebnisse. Z.B. zeigen AISA-NDVI und ASD-NDVI einen engen Zusammenhang, während SR keinen guten Zusammenhang aufweist. Beide Algorithmen werden aus den gleichen Wellenlängenbereichen gebildet, weshalb nicht die Verwendung unterschiedlicher Spektralbereiche dafür verantwortlich sein kann. Außerdem haben die einzelnen Bänder, die in den Indizes verwendeten Wellenlängen (Grün, Rot, Rededge und NIR) aus abbildenden Spektraldaten und Feldspektrometerdaten gute Zusammenhänge (vgl. Abb. 11), was die Analyse mit Radianzen, wie sie in der vorliegenden Arbeit durchgeführt wurde, unterstützt. Diese stellen das tatsächlich am Sensor ankommende Signal dar. Aus den Feldspektrometerdaten ergeben sich höhere Indexwerte als aus abbildenden Fernerkundungsdaten, was aufgrund des Strahlungsverlustes in der Atmosphäre nachvollziehbar ist. In Bezug auf die Beschreibung einzelner Vegetationsparameter lässt sich keine klare Aussage treffen. Teils beschreiben AISA-Indizes, teils ASD-Indizes Merkmale der einzelnen Pflanzenarten besser. Dabei ist zu beachten, dass die Oberfläche von den Sensoren in unterschiedlicher räumlicher Auflösung wiedergegeben wird. Das ASD nimmt die Reflektanz auf einer Fläche mit einem Durchmesser von etwa 50 cm auf, während AISA die Radianz eines Gebietes von 3 m² (3x3 Pixel) abbildet.

Abb. 10 zeigt, dass ein einzelner Punkt die Beziehung zwischen den Indizes aus abbildenden Spektren und Feldspektren stark verbessert. Bei diesem Wert handelt es sich um fast reinen Boden. Die übrigen Datenpunkte weisen innerhalb der Monokulturen keine breite Streuung auf.

4. Ergebnisse

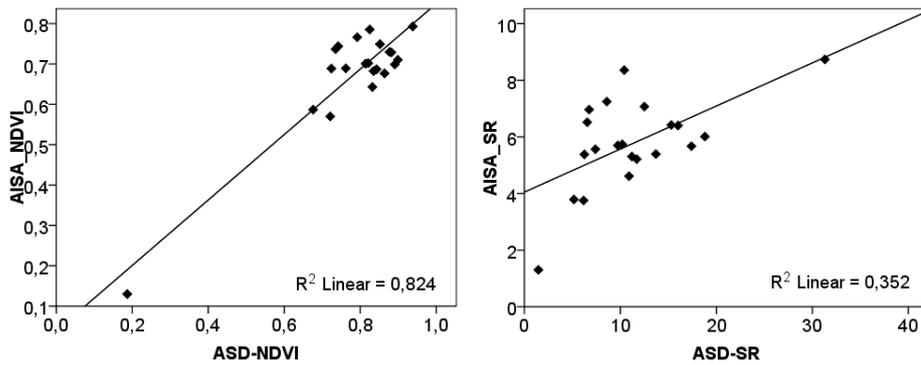


Abb. 10: Zusammenhang zwischen VIs berechnet aus abbildenden Hyperspektraldaten (AISA) und Feldspektrometerdaten (ASD)

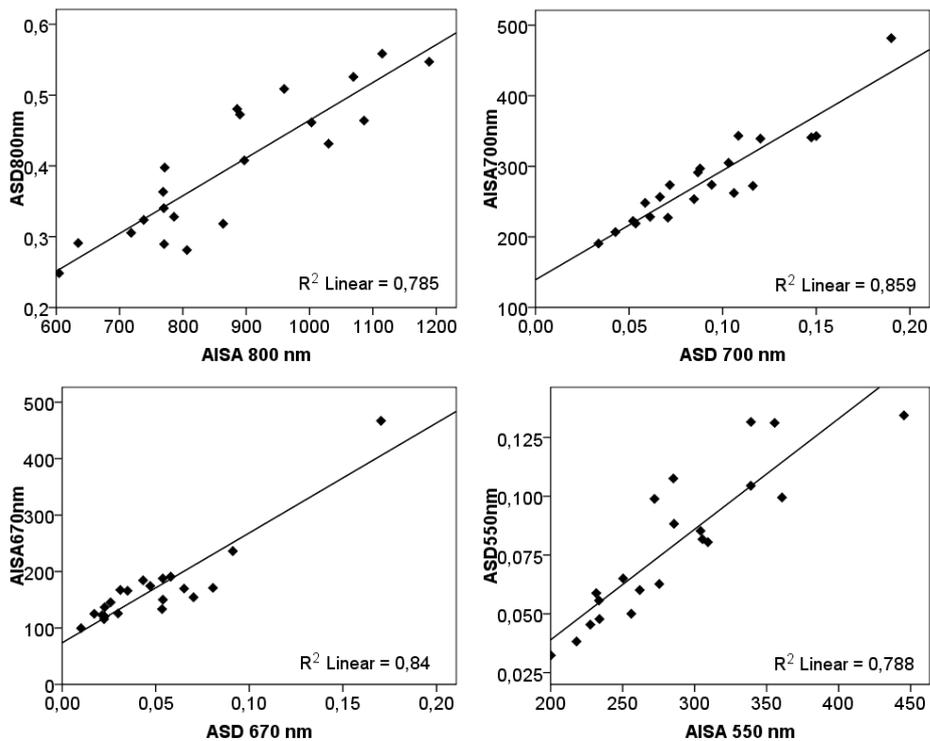


Abb. 11: Zusammenhänge zwischen in VIs verwendeten Wellenlängenbereichen von AISA- und ASD Daten.

Obwohl die vielen existierenden Vegetationsindizes zumeist aus den gleichen Wellenlängenbereichen berechnet werden, sind sie doch für sehr unterschiedliche Anwendungen konzipiert und liefern durchaus stark abweichende Ergebnisse. So zeigten sie sich auch unterschiedlich resistent gegenüber Fehlern der abbildenden Fernerkundungsdaten, die der Fehlausrichtung der IMU zugeschrieben werden. Als robust zeigten sich vor allem Indizes, die zur Minimierung von Bodeneinflüssen konzipiert

wurden (SAVI, OSAVI, MTVI1, MSAVI, MSAVI2, MCARI2/OSAVI). Auch die besonders gebräuchlichen Indizes, wie NDVI und SR waren wenig sensibel. Einige dieser Indizes korrigieren sogar den Radianzunterschied an West- und Ostrand des Befliegungsstreifens für das Winterroggenfeld. Bei der Bildung von Regressionsmodellen zur Schätzung von Vegetationsparametern auf Feldskala wurde dieses Kriterium neben statistischen Größen berücksichtigt und nur Indizes verwendet, die resistent gegenüber diesen Einflüssen waren.

Indizes zur Berechnung des Wassergehalts (z.B. WBI) zeigten keine guten Ergebnisse. Die Radianzen in Wellenlängenbereichen um 970 nm weisen keine deutlichen Charakteristika auf und erzeugen somit ein verrauschtes Bild bei der Berechnung der Indizes.

4.4 ERGEBNISSE DER REGRESSIONSANALYSE

Zunächst wurden die Daten auf Normalverteilung geprüft. Die Daten aller Pflanzenarten für einen Vegetationsparameter sind normalverteilt, mit Ausnahme der Biomasse und der Wuchshöhe. Dies ist in Betracht der unterschiedlichen Physiologie und Phänologie der untersuchten Pflanzenarten erwartungsgemäß. Bei diesen Parametern ist eine Clusterbildung der Stichproben zu erwarten. Die Getreidearten Wintergerste und Winterroggen weisen hingegen zusammen betrachtet in allen Parametern Normalverteilung auf, was aufgrund des gleichen Aufnahmedatums und ähnlicher Physiologie nachvollziehbar ist. Dennoch ist zu beachten, dass die Getreidearten eine Differenz in ihrer Phänologie haben und Wintergerste einen leichten Entwicklungsvorsprung hat.

Der Zusammenhang ausgewählter Vegetationsindizes mit *groundtruth* verschiedener Vegetationsparameter wird untersucht. Anhand statistischer Größen werden die Schätzungen ausgewählt, die den jeweiligen Parameter am besten beschreiben. Im Folgenden werden die Ergebnisse der Regressionsanalyse sowie des Modells nach Parametern getrennt erläutert. Die Zusammenhänge aller untersuchten Vegetationsindizes sind im Anhang aufgelistet.

4.4.1 Leaf Area Index

Die Regressionsanalyse für LAI zeigt sehr unterschiedliche Ergebnisse bei den einzelnen verwendeten Vegetationsindizes. Von anderen Autoren als geeignet ermittelte Indizes beschrieben auch hier LAI gut (z.B. GITELSON et al. 2003, HABOUDANE et al. 2004). Andere reagierten sehr unterschiedlich in Bezug auf verschiedene Pflanzenarten und Phänologiestadien.

Zunächst wurde der Zusammenhang zwischen LAI und den entsprechenden Werten der einzelnen Vegetationsindizes ermittelt. Dazu wurde die gesamte Menge an LAI-Messwerten der vier Kulturpflanzenarten und zwei Aufnahmejahre zusammengefasst betrachtet. Auffällig war, dass Indizes, bei denen eine gute Korrelation zu erwarten war, keine guten Ergebnisse einbrachten (z.B. NDVI ($R^2=0,02$), SAVI ($R=0,02$), MCARI2 ($R^2=0,02$), GI2 ($R^2=0,02$)). Bei Einbezug der Pflanzenart als Variable im Regressionsmodell wurde jedoch deutlich, dass diese einen entscheidenden Erklärungsanteil für LAI liefert. Aufschluss über den Erklärungsanteil der Variablen gaben die standardisierten Regressionskoeffizienten (Beta-Wert). Daraus ist zu schließen, dass die Indizes fruchtartsspezifische Unterschiede abbilden und ein einheitliches Modell für alle vier AISA-Szenen ungeeignet ist. Betrachtet man die LAI-Werte aufgetragen gegen den jeweiligen Index im Merkmalsraum, so wird eine starke Clusterbildung nach Pflanzenart deutlich (vgl. Abb. 12b), was diese Feststellung unterstützt. Trotz relativ guter linearer Korrelationen mit einigen Vegetationsindizes und der gesamten Datenmenge (so z.B. TVI mit R^2 0,5; TransformedVI mit R^2 0,46) konnte in den Daten, getrennt nach einzelnen Pflanzenarten, für diese Indizes keine lineare Korrelation festgestellt werden (vgl. Abb. 12). Die erwähnten Indizes mit geringen Zusammenhängen für den gesamten Datensatz, beschrieben LAI getrennt nach Pflanzenarten hingegen gut. Abb. 12a zeigt außerdem Cluster, bei denen sich die Daten der beiden Kampagnen abgrenzen. So weisen die Daten der Kampagne von Juli 2008 höhere Indexwerte auf als die Daten von April 2009. Dies kann im Falle der Getreidearten durch die unterschiedlichen Phänologiestadien erklärt werden, da hier sowohl LAI- als auch Vegetationsindexwerte je nach Aufnahmezeitpunkt höher oder geringer ausfallen. Raps hingegen zeigt nur geringfügig niedrigere LAI-Werte, die Indexwerte liegen jedoch deutlich unter denen der Getreidearten von 2008. Hier muss die Erklärung in unterschiedlichen Eigenschaften der Pflanzen, die sich im spektralen Signal abzeichnen, liegen. Außerdem wird deutlich, dass Raps und insbesondere Winterweizen eine viel geringere Streuung auf der x-Achse

(Vegetationsindex), jedoch eine breitere Streuung auf der y-Achse (LAI) aufweisen als die Getreidearten von 2008.

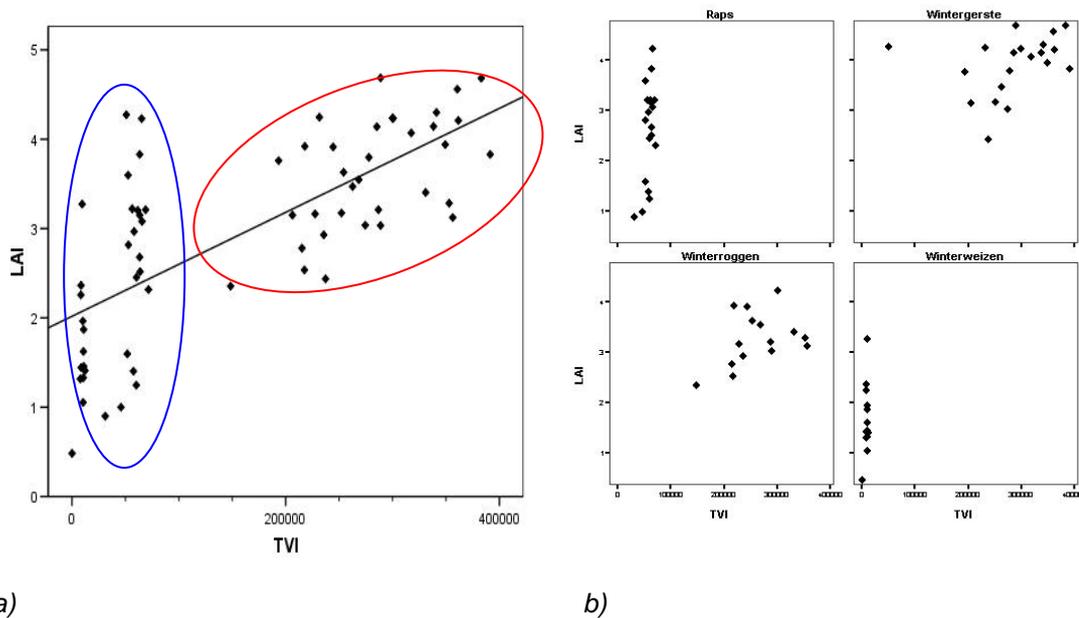


Abb. 12: a) LAI und TVI mit allen Daten und scheinbar guter linearer Korrelation ($R^2=0,50$), Rot: Messkampagne Juli 2008, Wintergerste und Winterroggen im Reifestadium. Blau: Messkampagne April 2009, Raps und Winterweizen. b) LAI und TVI getrennt nach Pflanzenart.

Auch andere Indizes, die für den gesamten Stichprobenumfang der Kampagnen von 2008 und 2009 mit *groundtruth* von LAI keine Korrelationen zeigten (z.B. NDVI), lassen sich in Punktwolken der einzelnen Pflanzenarten trennen. Für die beiden Kampagnen hingegen lassen sich Indexbereiche nicht so deutlich abgrenzen, wie für TVI deutlich wird (Abb. 12).

Aufgrund dieser Feststellungen wurde weiterhin untersucht, ob Wintergerste und Winterroggen (Juni 2008) zusammengefasst in einem Modell beschrieben werden können. Auch hier liefern die nur wenig korrelierenden Indizes keine tatsächliche Aussage über einen linearen Zusammenhang der gesamten Stichprobeneinheit. In dieser kleineren Auswahl zeichnet sich ebenfalls eine starke Clusterbildung ohne intern gleichen linearen Zusammenhang ab, was wiederum auf den leichten phänologischen Rückstand von Wintergerste zurückgeführt werden kann, die etwa zwei Wochen vor Winterroggen geerntet wurde.

4. Ergebnisse

Diese Ergebnisse zeigen die Notwendigkeit für jede der vier Pflanzenarten ein eigenes Modell zur flächendeckenden Berechnung von LAI zu erstellen. Der Nachteil besteht darin, dass sich der Stichprobenumfang zur Modellbildung sehr verkleinert und keine Daten zur Validierung zurückgehalten werden können. Zur Prüfung der Qualität des Modells werden daher anerkannte statistische Verfahren, wie Bootstrapping und Residuenanalyse angewandt (BACKHAUS et al. 2006, GOERKE 2007, JANN 2009). Als Kriterien zur Bewertung des Potentials des jeweiligen Index, LAI zu prognostizieren, wurden insbesondere Bestimmtheitsmaß (R^2) und Signifikanz der linearen Regression herangezogen. Einen Überblick über die Gütemaße der verwendeten Indizes ist im Anhang zu finden.

Die besten Ergebnisse erzielten, abhängig von Index und Pflanzenart, exponentielle und quadratische Kurvenberechnungen. Dies entspricht der häufig erwähnten Sättigung vieler Indizes bei hohem LAI und korrespondiert mit den Ergebnissen von HABOUDANE et al. (2004). Um eine möglichst exakte Berechnung von LAI bei geringer bis dichter Bedeckung zu erhalten, wird ein lineares Modell angestrebt. Generell lässt sich sagen, dass starke Unterschiede der Gütemaße von linearer und quadratischer Regression durch einzelne Stichproben verursacht werden, die nicht auf die Sättigung der Indizes zurückzuführen sind. Dies wird für Winterweizen aufgrund seines frühen Phänologiestadiums deutlich. LAI liegt hier im Bereich von 1, die typische Sättigung betrifft jedoch höhere LAI Bereiche. Durch die Eliminationsstatistik Cook's Distance, die eine Form des Bootstrapping ist, können einzelne Datenpunkte als extremer Ausreißer identifiziert werden (GOERKE 2007, JANN 2009). Zunächst wird die Analyse mit allen vorhandenen Datenpunkten durchgeführt. Dabei wird berücksichtigt, dass bessere Ergebnisse durch nicht-lineare Funktionen auf den geringen Stichprobenumfang zurückgehen können. Bei kleinen Stichproben fallen einzelne Datenpunkte stärker ins Gewicht.

Um die besten Regressionsergebnisse ausfindig zu machen, wurde Schrittweise Multivariate Regression angewendet. Ausschluss von Multikollinearität erfolgte durch korrelieren der Vegetationsindizes gegeneinander, um sie auf die Beschreibung unterschiedlicher Merkmale zu testen.

Die Auswertung verschiedener Regressionsmodelle für Wintergerste zeigt, dass der geringe Zusammenhang zwischen Vegetationsindizes und LAI, auf einen extremen Ausreißer zurückzuführen ist, der die Schätzung aller Modelle stark verzerrt. Der kritische Wert für Cook's D wurde von diesem Datenpunkt deutlich überschritten. Eine Betrachtung des Wertes und seiner Lage auf dem Feld zeigt, dass es sich um einen Messfehler

handeln muss. Zur weiteren Analyse von LAI wurde dieser Datenpunkt eliminiert, um einer Verfälschung der Ergebnisse entgegenzuwirken.

Folgende Regressionsmodelle zeigten die besten Ergebnisse für LAI bei Wintergerste (ausgewählt anhand von Bestimmtheitsmaß und Signifikanz):

$$REIP \quad (R^2 = 0,59): \quad y = - 9,633 + 0,022 \cdot REIP$$

$$REIP+MTVI2 \quad (R^2 = 0,73): \quad y = - 34,978 + 0,07 \cdot REIP - 6,692 \cdot MTVI2$$

$$EVI \quad (R^2 = 0,59): \quad y = 5,413 - 0,00005 \cdot EVI$$

$$MCARI/OSAVI \quad (R^2 = 0,52): \quad y = 7,601 - 0,001 \cdot MCARI/OSAVI$$

$$PSRI \quad (R^2 = 0,49): \quad y = 4,637 - 6,845 \cdot PSRI$$

Demnach bildet eine Kombination von REIP und MTVI2 LAI für Wintergerste am besten ab. Die Anwendung der Modelle zeigt jedoch, dass andere Faktoren zur Auswahl des geeignetsten Modells berücksichtigt werden müssen. So kommt es bei Anwendung des multivariaten Modells aus REIP und MTVI2 zu einer starken Ausprägung der optischen Fehler in der AISA-Szene. Am wenigsten sensibel auf diese Fehler reagierten die Modelle mit REIP und PSRI. Der inverse Zusammenhang zwischen PSRI und LAI zeigt, dass PSRI nicht grüne Blattmasse abbildet, sondern auf Pigmente reagiert, die erst durch Seneszenz hervortreten (Carotinoide, Xantophylle) (vgl. Abb.13).

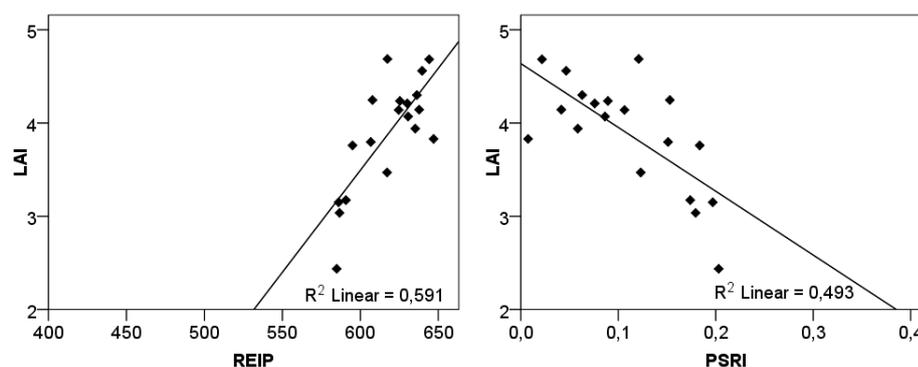


Abb. 13: Zusammenhang zwischen LAI und den Indizes REIP und PSRI für Wintergerste.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
LAI vs. REIP	0,59	0,000	0,49	0,14
LAI vs. PSRI	0,49	0,001	0,48	0,15

Tab. 4: Gütekriterien für den Zusammenhang zwischen LAI und ausgewählten Vegetationsindizes für Wintergerste.

4. Ergebnisse

Abb. 14 zeigt den Zusammenhang zwischen modelliertem LAI und *groundtruth*-LAI mit jeweiligem Bestimmtheitsmaß (R^2). Die Werte für das Modell mit REIP+MTVI2 liegen am nächsten an der eins-zu-eins-Linie ($R^2=0,74$), was aufgrund des deutlich höheren Zusammenhangs bei der vorangegangenen Schätzung nicht verwunderlich ist. Das Modell weist eine leichte Tendenz zur Überschätzung im Bereich von LAI = 4 auf. Die Schätzwerte von EVI, PSRI und REIP zeigen gute lineare Beziehungen zu den *groundtruth*-Daten, mit leichten Sättigungstendenzen im oberen Wertebereich.

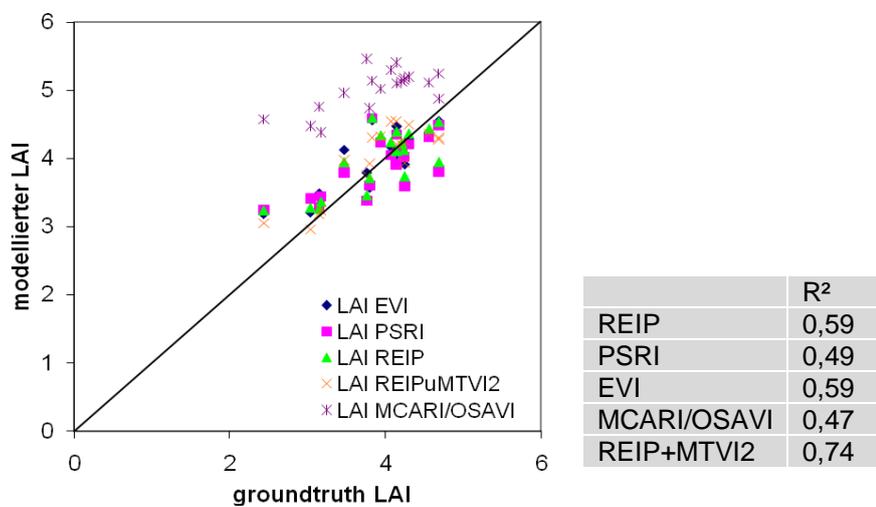


Abb. 14: Vergleich von modelliertem und *groundtruth*-LAI für Wintergerste mit jeweiligem Bestimmtheitsmaß (R^2)

Aufgrund der statistischen Gütemaße R^2 , Signifikanz, Standardfehler, Cook's Distance, zentrierte Leverage und der Resistenz gegenüber Störeinflüssen wurden die Regressionsmodelle von PEIP und PSRI ausgewählt (Tab. 4).

Um die Modelle auf Verletzung von Prämissen zu prüfen und die Stabilität und globale Güte des Modells zu evaluieren wurden im Anschluss Residuenanalysen durchgeführt. Dabei konnte Normalverteilung und eine homogene Varianz um Null bei den standardisierten Residuen bestätigt werden. Keines der Modelle unterliegt einer Prämissenverletzung, sie sind somit als stabil anzusehen.

REIP weist für den Zusammenhang mit LAI statistisch bessere Gütemaße auf. Bei Anwendung der Modelle ergeben sich für PSRI jedoch plausiblere Ergebnisse. Die Schätzung für LAI aus der Regression mit REIP zeigt bei niedrigem LAI eine

Unterberechnung. So werden für 5 % der Pixel Werte unter Null berechnet. Da Kenntnisse über den Bewuchs auf dem Wintergerstefeld bestehen und LAI unter Null nicht existiert, können derartige Ergebnisse für unplausibel erklärt werden. PSRI liefert Ergebnisse, die den Kenntnissen über die Vegetation auf dem betrachteten Schlag besser entsprechen.

Für Winterroggen erzielten folgende Regressionsanalysen die besten Ergebnisse:

$$PSRI \quad (R^2 = 0,56): \quad y = 3,369 - 17,717 \cdot PSRI$$

$$PSRI+REIP \quad (R^2 = 0,73): \quad y = 76,353 - 50,386 \cdot PSRI - 0,113 \cdot REIP$$

$$MTVI2 \quad (R^2 = 0,50): \quad y = -1,035 + 5,381 \cdot MTVI2$$

$$MTVI2+REIP(R^2 = 0,75): \quad y = 110,319 + 23,807 \cdot MTVI2 - 0,195 \cdot REIP$$

$$SAVI \quad (R^2 = 0,43): \quad y = 0,666 + 2,699 \cdot SAVI$$

Für das MTVI2+REIP-Modell wurde ein extremer Ausreißer mittels Cook's D detektiert, der im Anschluss eliminiert wurde. Exponentielle Regressionsmodelle lieferten nur geringfügig bessere Ergebnisse, so dass dies zu vernachlässigen ist.

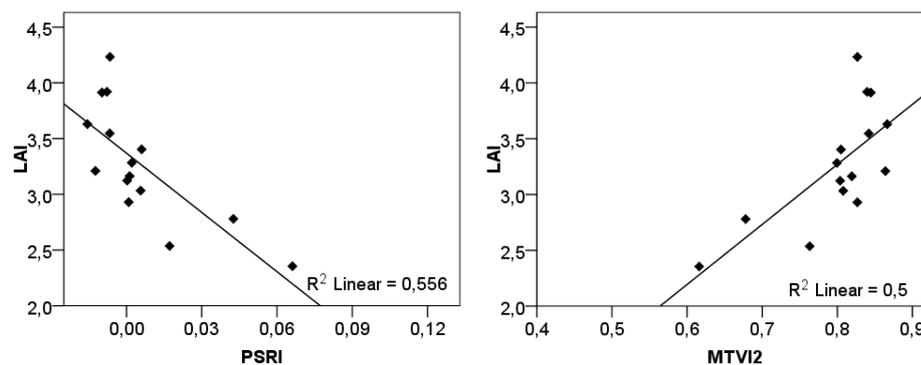


Abb. 15: Zusammenhang zwischen LAI und ausgewählten Vegetationsindizes für Winterroggen.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
LAI vs. PSRI	0,56	0,001	0,39	0,55
LAI vs. MTVI2	0,50	0,003	0,20	0,52
LAI vs. SAVI	0,43	0,008	0,27	0,36

Tab. 5: Gütekriterien für die Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterroggen.

4. Ergebnisse

Auch hier kommen bei Anwendung der multivariaten Modelle optische Fehler sehr stark raus. Generell sind in dieser AISA-Szene Fehler stärker sichtbar. SAVI ist am resistantesten gegenüber diesen Fehlern und dem Radianzverlauf auf dem Befliegungstreifen.

Der Vergleich von modelliertem und *groundtruth*-LAI zeigt eine Sättigung bei allen Modellen im oberen Wertebereich (vgl. Abb. 16). Die Sättigung ist im Falle der multivariaten Modelle weniger stark ausgeprägt, bei PSRI+REIP ist sie kaum erkennbar. Dies spiegelt sich für die übrigen Modelle in besseren quadratischen Zusammenhängen zwischen modelliertem und *groundtruth*-LAI wider, mit R^2 bis zu 0,77. PSRI+REIP zeigt den besten linearen Zusammenhang zwischen modelliertem und *groundtruth*-LAI. Während die übrigen Modelle LAI im Bereich von ca. 3 - 4 überschätzen, liegen die Werte dicht an der 1-zu-1-Linie, unterschätzen LAI jedoch ein wenig.

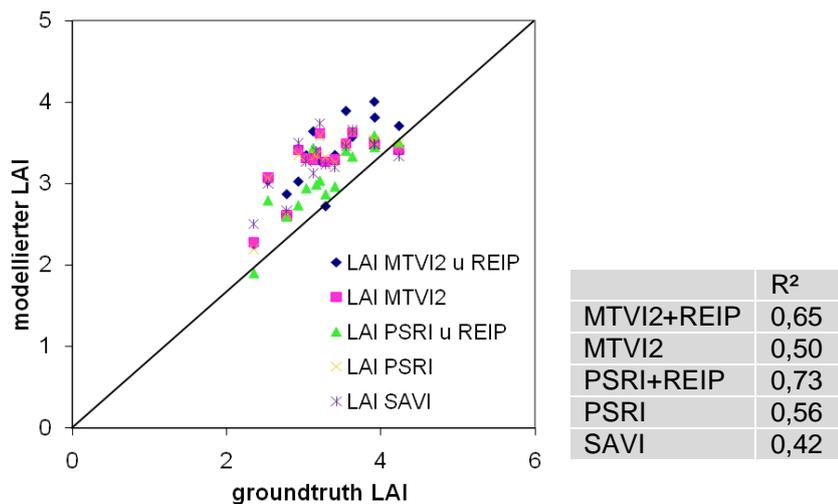


Abb. 16: Vergleich von modelliertem und *groundtruth*-LAI für Winterroggen mit jeweiligem Bestimmtheitsmaß (R^2)

Aufgrund der optisch stark auftretenden Fehlerausprägung wurden, trotz der besseren Modellgüte mit anderen Indizes, die Modelle aus MTVI2 und SAVI ausgewählt (Abb. 15, Tab. 5).

Obwohl SAVI die optischen Fehler noch besser reduziert, wird MTVI2 aufgrund seiner höheren statistischen Güte für die Modellierung ausgewählt (Tab. 5). MTVI2 stellt dabei nach Cook's D das stabilste Modell dar, bei dem der kritische Wert nicht überschritten

wird. Der Grenzwert für die zentrierte Leverage wird in beiden Modellen etwas überschritten. In der Anwendung zeigen beide Modelle eine Unterschätzung von LAI in den oberen Wertebereichen, wie auch aus Abb. 16 deutlich wird. MTVI2 berechnet für einige Pixel Werte unter 0. Diese werden als vegetationsfrei maskiert.

Die Residuenanalyse für das Modell aus MTVI2 zeigt Normalverteilung und homogene Streuung der standardisierten Residuen um 0. Es werden keine Modellprämissen verletzt.

Folgende Regressionen bilden den besten Zusammenhang zur Modellierung von LAI bei Winterraps:

$$GI\ 2 \quad (R^2 = 0,66): \quad y = -0,979 + 1,485 \cdot GI\ 2$$

$$CI \quad (R^2 = 0,56): \quad y = -3,725 + 12,431 \cdot CI$$

$$SR \quad (R^2 = 0,50): \quad y = -0,565 + 0,535 \cdot SR$$

$$SR+PSRI \quad (R^2 = 0,66): \quad y = 1,948 + 0,729 \cdot SR + 19,711 \cdot PSRI$$

$$MCARI2/OSAVI \quad (R^2 = 0,51): \quad y = 15,174 - 11,611 \cdot MCARI2/OSAVI$$

In den Modellen mit GI 2 und SR+PSRI wurde ein Ausreißer eliminiert. Exponentielle Funktionen erzielten etwas bessere Zusammenhänge als lineare.

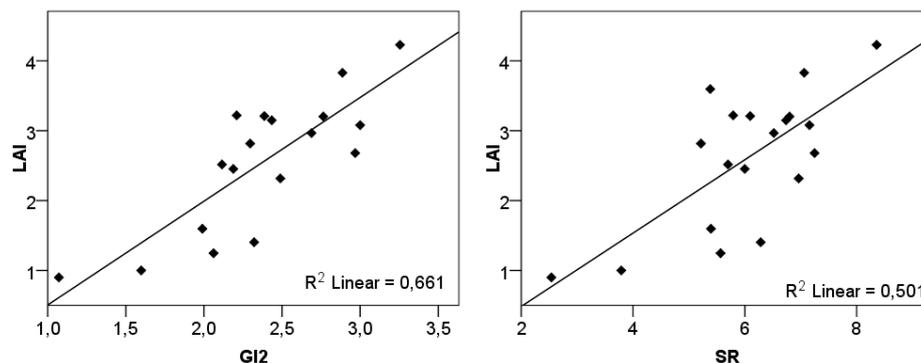


Abb. 17: Zusammenhang zwischen LAI und ausgewählten Vegetationsindizes für Winterraps.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
LAI vs. GI 2	0,66	0,000	0,15	0,36
LAI vs. CI	0,56	0,000	0,28	0,44
LAI vs. SR	0,50	0,001	0,14	0,40

Tab. 6: Gütekriterien für die Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterraps.

4. Ergebnisse

Das beste Modell zur Prognose von LAI für Raps bildet eine einfache Regression mit GI2 (Tab.6). Nach Elimination eines Ausreißers beschreibt GI2 LAI für Raps gut (als Qualitätsmaße wurden R^2 , Signifikanz und Stabilität durch Cook's D herangezogen). GI2 und SR bilden die stabilsten Modelle, bei denen weder Cook's D, noch standardisierte Residuen oder studentisierte Residuen die kritischen Werte überschritten (Tab. 6). Der kritische Wert der zentrierten Leverage wird in allen Modellen leicht überschritten, was die Vorhersage beeinträchtigen kann, da solche Ausreißer die Schätzung des Modells verzerren. Ein Ausschluss des Wertes trägt jedoch nicht zur Verbesserung des Modells bei, weshalb er beibehalten bleibt.

Der Vergleich von modelliertem und *groundtruth*-LAI zeigt ähnliche Ergebnisse bei allen Modellen. GI2 berechnet LAI etwas geringer als die übrigen Indizes (vgl. Abb. 18). Dies zeigt sich auch in den LAI-Karten, bei denen insbesondere auf Schlag 8 geringere LAI-Werte modelliert werden. Durch das Modell wird LAI bis unter 0 geschätzt. Diese Pixel werden als vegetationsloser Boden ausmaskiert, was der Verteilung von unbewachsenem Boden aus Beobachtungen im Feld entspricht. Bei Anwendung der Modelle zeigt sich, dass das multivariate Modell aus SR und PSRI Bereichen mit LAI um 0 hohe LAI Werte von bis zu LAI=4 zuweist. Die Residuen geben keinen Anlass zur Annahme von Prämissenverletzung. Die Gültigkeit der Modelle kann also bestätigt werden.

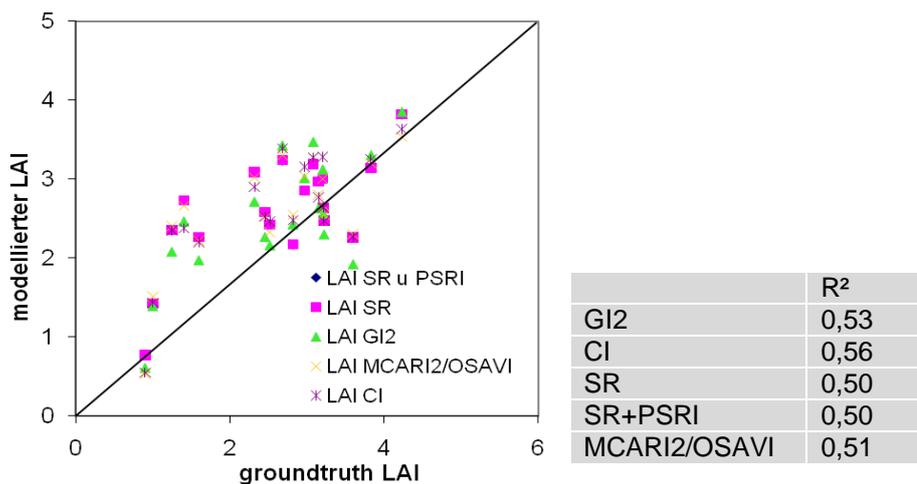


Abb. 18: Vergleich von modelliertem und *groundtruth*-LAI bei Winterraps mit jeweiligem Bestimmtheitsmaß (R^2)

Die besten Modelle zur Schätzung von LAI für Winterweizen wurden von folgenden Vegetationsindizes und Indexkombinationen gebildet:

$$GI2 \quad (R^2 = 0,69): \quad y = 0,044 + 0,742 \cdot GI2$$

$$SR \quad (R^2 = 0,62): \quad y = -0,028 + 0,305 \cdot SR$$

$$CI+SAVI \quad (R^2 = 0,78): \quad y = -0,466 + 23,810 \cdot CI - 9,318 \cdot SAVI$$

$$CI+PSRI \quad (R^2 = 0,70): \quad y = -4,573 + 12,857 \cdot CI + 16,372 \cdot PSRI$$

$$CVI \quad (R^2 = 0,65): \quad y = -3,271 + 2,806 \cdot CVI$$

Die besten Zusammenhänge werden durch exponentielle Funktionen beschrieben. Der Vergleich von modelliertem und groundtruth-LAI zeigt bei allen Modellen ähnlich gute Ergebnisse mit linearen Korrelationen von $R^2 = 0,6$ bis $0,7$ (Abb. 20).

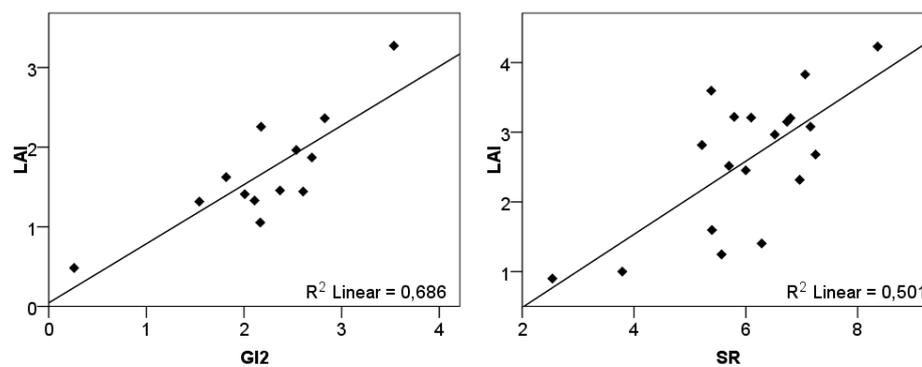


Abb. 19: Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterweizen.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
LAI vs. GI2	0,69	0,000	0,40	0,53
LAI vs. SR	0,62	0,001	0,78	0,49

Tab. 7: Gütekriterien für die Zusammenhänge zwischen LAI und ausgewählten Vegetationsindizes für Winterweizen.

Aufgrund der starken optischen Hervorhebung der Fehler im AISA-Bild bei LAI Karten wurden CI+SAVI, CI+PSRI und CVI nicht verwendet. GI2 und SR erzielten, ähnlich wie bei Raps, die besten Schätzungen und erwiesen sich als relativ resistent gegenüber Fehlern in den Fernerkundungsszenen.

4. Ergebnisse

Cook's D und zentrierte Leverage überschreiten die kritischen Werte bei beiden Indizes (Tab. 7). Dies ist aufgrund des geringen Stichprobenumfangs nicht zu umgehen, da durch Eliminierung der Ausreißer keine bessere Stabilität erreicht werden kann.

Bei Anwendung der Modelle zeigt sich, dass GI2 etwas geringere LAI-Werte modelliert als SR. Bei Berechnung der übrigen Modelle treten Fehler in der AISA-Szene optisch sehr stark hervor. Wie vorangehend ebenfalls für Raps festgestellt wurde, weist das multivariate Modell mit PSRI vegetationsfreien Bereichen hohe LAI-Werte zu. Aufgrund des besseren Zusammenhangs wird das GI2-Modell ausgewählt um LAI für Winterweizen zu prognostizieren.

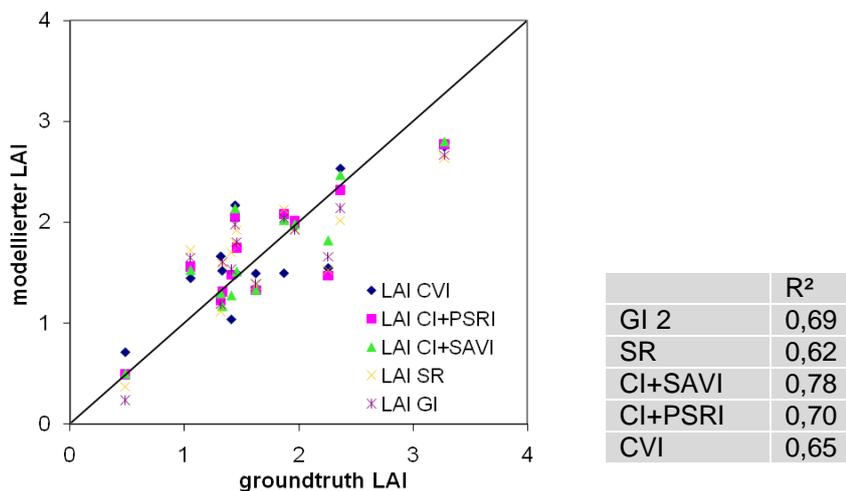


Abb. 20: Vergleich von modelliertem und groundtruth-LAI für Winterweizen mit jeweiligem Bestimmtheitsmaß (R^2)

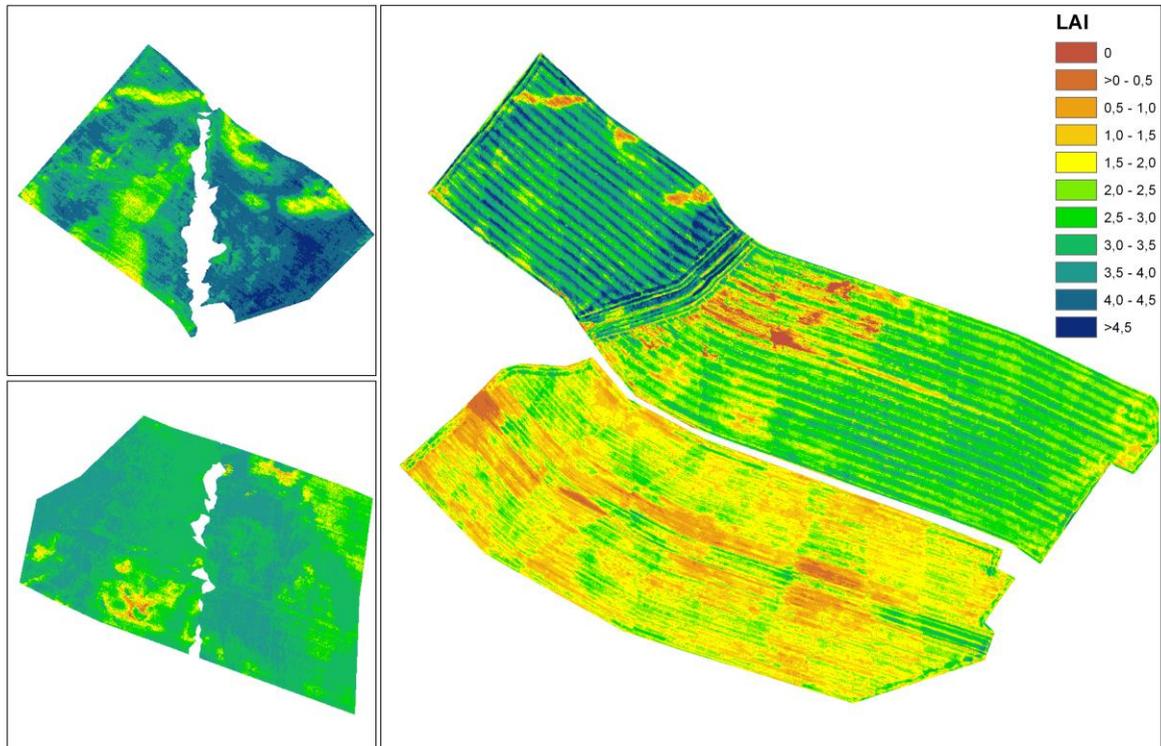


Abb. 21: Ergebniskarten der empirischen Modellierung von LAI. Links oben: Wintergerste, links unten: Winterroggen, rechts oben: Winterraps, rechts unten: Winterweizen.

4.4.2 Chlorophyll

Die Modellierung von Chlorophyll ist aufgrund der geringen Anzahl an Messungen während der Kampagne 2008, nur für Winterraps und Winterweizen möglich. Für die Gesamtheit der Daten sind relativ gute Korrelationen mit TVI festzustellen. Aus Abb. 22a wird deutlich, dass ein lineares Modell mit allen Daten nicht sinnvoll ist, da nicht alle Wertebereiche von *groundtruth*-Chlorophyll abgedeckt werden und die eigentlichen Zusammenhänge nicht erfasst werden. Aus der quadratischen Funktion werden jedoch die Änderungen des Blattchlorophyllgehaltes im Phänologieverlauf erkennbar. Zunächst steigt Blattchlorophyll während der juvenilen Phase (Winterweizen), danach nimmt er mit einsetzen der Blüte und der reproduktiven Phase wieder ab (Winterraps). Die quadratische funktion spiegelt die gegensätzlichen Korrelationen von Blattchlorophyll bei

4. Ergebnisse

Raps und bei Weizen wider. Zwischen LAI und Blattchlorophyll ist kein deutlicher Zusammenhang festzustellen (Abb. 22b).

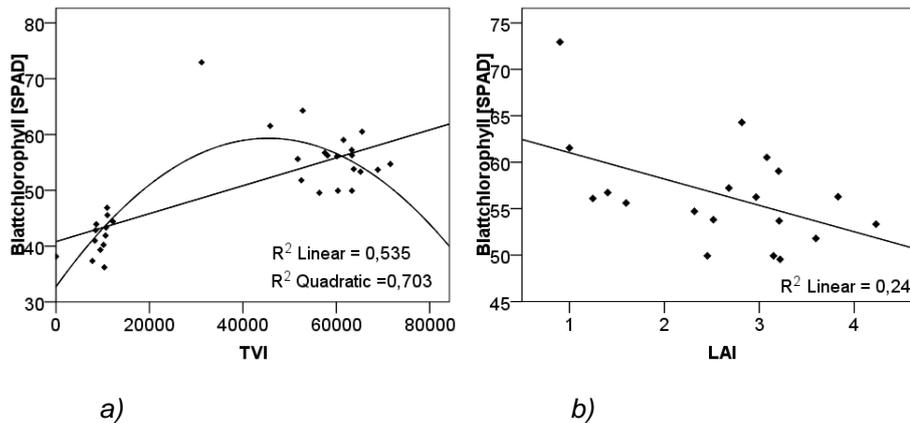


Abb. 22: a) Lineare und quadratische Funktion zur Beschreibung des Zusammenhangs von Blattchlorophyll und Triangular Vegetationindex (TVI) bei Winterraps und Winterweizen. b) Zusammenhang zwischen LAI und Chlorophyll bei Winterraps.

Für Winterraps werden lineare Korrelationen zwischen Blattchlorophyll und Vegetationsindizes von $R^2 = 0,7$ (MCARI) erreicht (vgl. Tab. 8). Raps zeigt einen negativen Zusammenhang zu Vegetationsindizes (ausgenommen PSRI). D.h. der Blattchlorophyllgehalt nimmt mit zunehmendem Indexwert und somit, wie im vorangegangenen Kapitel erläutert, mit zunehmendem LAI, ab. Abb. 22b zeigt den Zusammenhang zwischen LAI und Blattchlorophyll. Es ist nur eine geringe lineare Korrelation gegeben ($R^2 = 0,24$), dennoch ist ein negativer Trend erkennbar.

Ein Problem dieses empirischen Modellansatzes zur Bestimmung von Blattchlorophyll bei einsetzender Seneszenz stellt unbewachsener Boden dar. Aufgrund der negativen Korrelation werden niedrigen Indexwerten hohe Chlorophyllwerte zugeordnet (vgl. Abb). Für die Modellierung in Bereichen mit vegetationslosem Boden bedeutet dies, dass für sie hohe Chlorophyllkonzentrationen modelliert werden. Im Falle des Index MCARI/MSAVI wird dieses Problem gut umgangen, da bereits die Indexkombination gute Resistenz gegenüber Boden zeigt. Bereiche mit unbewachsenem Boden erhalten in der Ergebniskarte geringe Chlorophyllwerte, bis zu Chlorophyll = 0. Das quadratische Modell aus TVI und allen Daten von 2009 zeigt keine brauchbaren Ergebnisse. Wie Abb. 24 zeigt, wird Chlorophyll unterschätzt. Das lineare Modell aus allen Daten erweist sich

schon durch die Umkehrung des realen Zusammenhangs als ungeeignet (vgl. Abb. 22a). Außerdem wird die Varianz der *groundtruth* durch dieses Modell nicht ausreichend abgedeckt.

Die besten linearen Regressionsmodelle für Blattchlorophyll bei Raps bildeten folgende Indizes:

$$MCARI \quad (R^2 = 0,70): \quad y = 75,985 - 0,081 \cdot MCARI$$

$$VARI_{green} \quad (R^2 = 0,69): \quad y = 80,791 - 55,683 \cdot VARI_{green}$$

$$VARI_{green} + MCARI/OSAVI \quad (R^2 = 0,77): \quad y = 83,986 - 34,424 \cdot VARI_{green} + 0,043 \cdot MCARI/OSAVI$$

$$MCARI/MSAVI \quad (R^2 = 0,69): \quad y = 78,456 - 0,076 \cdot MCARI/MSAVI$$

$$MCARI/OSAVI \quad (R^2 = 0,65): \quad y = 78,456 - 0,076 \cdot MCARI/OSAVI$$

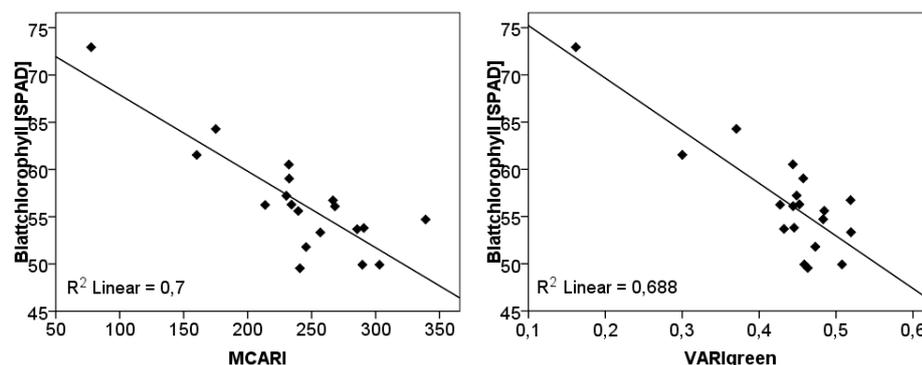


Abb. 23: Zusammenhänge zwischen Blattchlorophyll und ausgewählten Vegetationsindizes für Winterraps.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
Chlorophyll vs. MCARI	0,70	0,000	1,00	0,44
Chlorophyll vs. VARI _{green}	0,69	0,000	0,45	0,60
Chlorophyll vs. VARI _{green} +MCARI/OSAVI	0,77	0,000	0,35	0,60
Chlorophyll vs. MCARI/MSAVI	0,69	0,000	1,17	0,39
Chlorophyll vs. MCARI/OSAVI	0,65	0,000	1,27	0,34

Tab. 8: Gütekriterien der Zusammenhänge zwischen Blattchlorophyll und ausgewählten Vegetationsindizes für Winterraps.

Als bestes Modell stellt sich eine multivariate Regression aus VARI_{green} und MCARI/OSAVI heraus. Auch hier sind, wie in anderen Modellen, Fehler optisch relativ

4. Ergebnisse

stark zu erkennen. Keiner der Indizes, die die besten Zusammenhänge zeigten, war jedoch besonders resistent. Aufgrund der guten Modellergebnisse, mit guter Stabilität (Cook's D) und guten Zusammenhängen zu *groundtruth* (R^2) wurde die multivariate Modellvariante gewählt (Tab. 8). Ein Vorteil des Modells liegt in der Kombination mit dem bodenresistenten Indexratio MCARI/OSAVI. Der Index berechnet für Boden hohe Indexwerte, was in der Anwendung des Modells vorteilhaft ist, wie oben beschrieben. Der Vergleich von gemessenem und *groundtruth*-Chlorophyll zeigt für die linearen Regressionen gute Ergebnisse (Abb. 24). Besonders nah an der eins-zu-eins-Linie liegen die Werte des multivariaten Modells $\text{VAR}_{\text{Igreen}} + \text{MCARI/OSAVI}$.

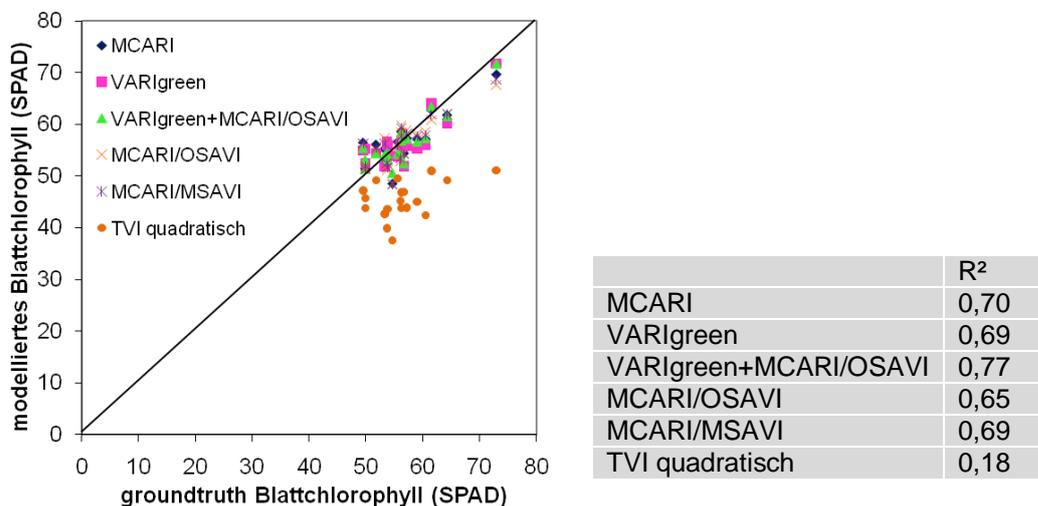


Abb. 24: Vergleich von modelliertem und *groundtruth*-Blattchlorophyll für Winterrapis mit jeweiligem Bestimmtheitsmaß (R^2)

Die Residuenanalyse zeigte sowohl Normalverteilung also auch Unabhängigkeit der standardisierten Residuen, weshalb davon ausgegangen wird, dass keine Modellprämissen verletzt werden.

Eine Modellierung von Blattchlorophyll auf dem Winterweizenfeld ist mit diesem empirischen Modellansatz nicht durchführbar, da kein Zusammenhang mit Vegetationsindizes festgestellt werden kann. Auch die Anwendung der genannten Modelle mit TVI für alle Daten erzielten keine brauchbaren Ergebnisse. Zwar zeigen Chlorophyllkarten plausible Ergebnisse, der Vergleich von modelliertem und *groundtruth*-SPAD-Wert zeigt jedoch, dass die Schätzung nicht die gesamte Wertespanne der

groundtruth abdeckt, weshalb Blattchlorophyll über- oder unterberechnet wird (vgl. Abb. 25).

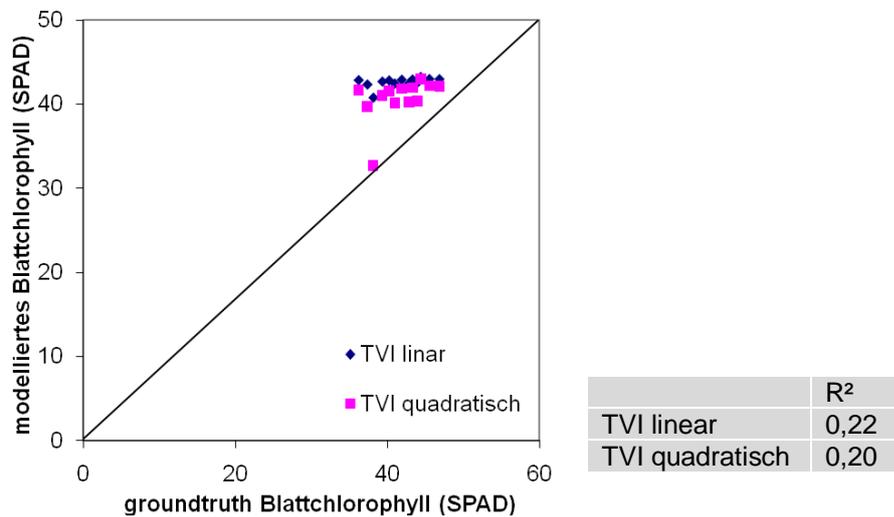


Abb. 25: Vergleich von modelliertem und *groundtruth*-Blattchlorophyll für Winterweizen mit jeweiligem Bestimmtheitsmaß (R²)

Die Korrelation zwischen Schätzwert und *groundtruth* beträgt für beide Modelle $R^2=0,2$. Was die fehlende Korrelation zwischen Chlorophyll und Vegetationsindizes bestätigt. Auch zwischen LAI und Blattchlorophyll ist für Winterweizen im frühen Phänologiestadium kein Zusammenhang erkennbar.

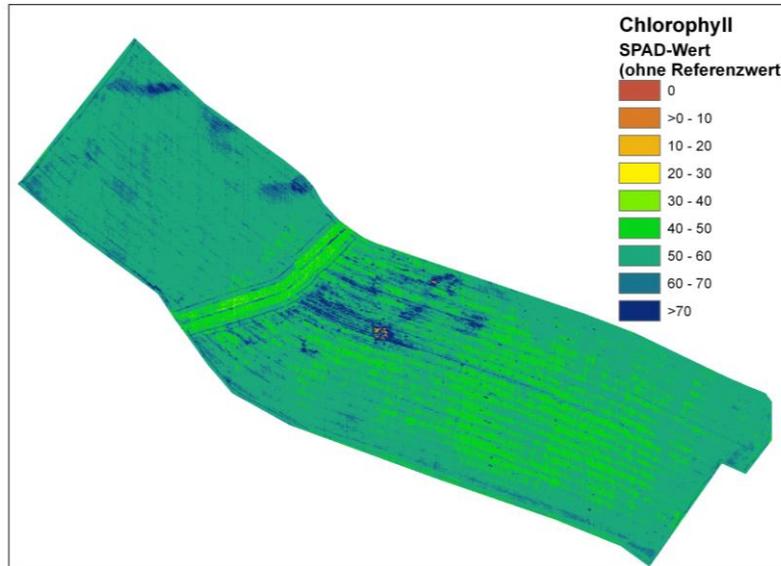


Abb. 26: Ergebniskarte der empirischen Modellierung von Chlorophyll bei Wintererraps

4.4.3 Wuchshöhe

Die Messdaten für die Wuchshöhe ergeben unter Ausschluss von Winterweizen gute Regressionsergebnisse mit verschiedenen Vegetationsindizes. Winterweizen hat aufgrund seines frühen phänologischen Stadiums sehr geringe Wuchshöhen und bietet daher keine Vergleichbarkeit mit den anderen Fruchtarten. Die übrigen drei Pflanzenarten lassen sich gut in einem Regressionsmodell zusammenfassen, mit R^2 bis 0,55 (GI 2).

Das Merkmal Wuchshöhe spiegelt sich nicht direkt im spektralen Signal wider. Vielmehr gibt sie indirekt Auskunft über den Zustand der Vegetation. In der Wuchshöhe zeigen sich neben Stressphänomenen auch Rückstände in der Phänologie. Die Daten werden trotz guter Zusammenhänge ebenfalls unterschieden nach Pflanzenart betrachtet. Aufgrund unterschiedlicher Pflanzen- und Wuchseigenschaften kann aus der spektralen Signatur einer Pflanzenart nicht auf die Wuchshöhe einer anderen geschlossen werden, wie aus Abb. 27 hervorgeht. Der gute Zusammenhang zwischen der Wuchshöhe und Vegetationsindizes ist ein Indiz für die hohe Bedeutung dieses Merkmals in der Erkennung von Heterogenität innerhalb der Bestände.

Gute Korrelationen von Wuchshöhe mit LAI weisen zudem auf die Beschreibung des gleichen Vegetationsmerkmals durch die beiden Parameter hin. Das Bestimmtheitsmaß variiert je nach betrachteter Fruchtart zwischen 0,4 und 0,7. Insgesamt zeigten bewährte Indizes, wie NDVI, SR, SAVI, MSR gute Ergebnisse bei Regressionsanalysen mit der Wuchshöhe.

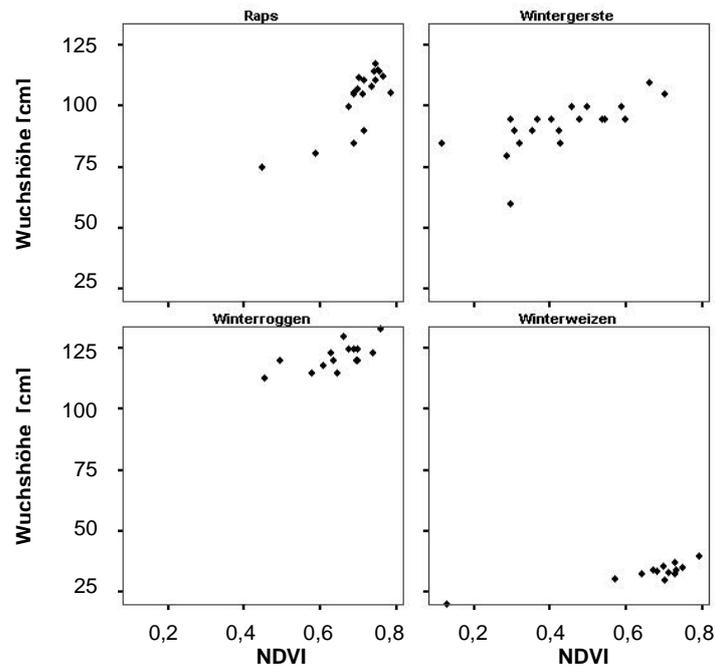


Abb. 27: Wuchshöhe vs. NDVI getrennt nach Fruchtarten.

Bei allen Modellen für Wuchshöhe im Wintergerstefeld wurde der kritische Wert für Cook's D von einem Datenpunkt deutlich überschritten. Dieser wurde zur weiteren Analyse und Modellbildung für die Wuchshöhe eliminiert, um die Stabilität der Modelle zu verbessern.

$$GI2 \quad (R^2 = 0,66): \quad y = 82,086 + 12,493 \cdot GI2$$

$$GI2 + VARI_{rededge} \quad (R^2 = 0,77): \quad y = 34,114 + 26,257 \cdot GI2 - 143,795 \cdot VARI_{rededge}$$

$$MSR \quad (R^2 = 0,63): \quad y = 81,379 + 14,056 \cdot MSR$$

$$GII \quad (R^2 = 0,62): \quad y = 76,735 + 15,605 \cdot GII$$

$$SR \quad (R^2 = 0,62): \quad y = 79,354 + 5,118 \cdot SR$$

4. Ergebnisse

Weitere Indizes, die gute Regressionsergebnisse erzielten waren MCARI1/MSAVI und NDVI und OSAVI. Die Zusammenhänge wurden am Besten durch lineare Funktionen beschrieben.

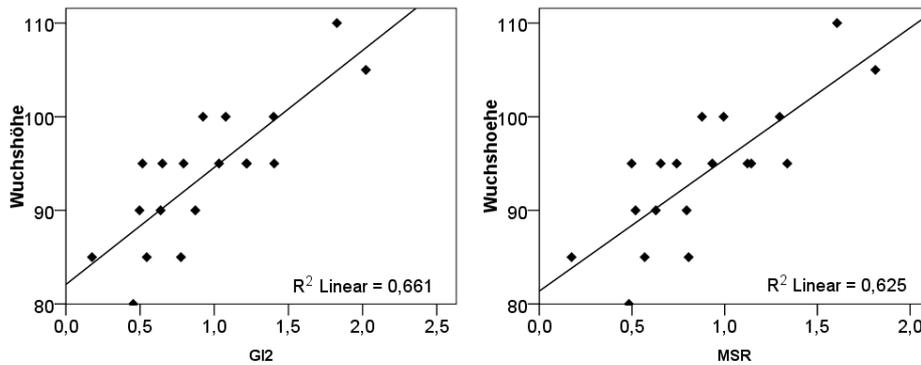


Abb. 28: Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Wintergerste.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
Wuchshöhe vs. GI 2	0,66	0,000	0,27	0,28
Wuchshöhe vs. MSR	0,63	0,000	0,30	0,27
Wuchshöhe vs. SR	0,62	0,000	0,30	0,35

Tab. 9: Gütekriterien für die Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Wintergerste.

Die ausgewählten Modelle, liefern alle gute Ergebnisse mit R² von 0,6. Das multivariate Modell aus GI2 und VARI_{rededge} bildet Fehler im AISA-Bild optisch sehr stark ab. Alle Modelle beschreiben die Wuchshöhe ähnlich gut, wie Tab. 9 zeigt. Aufgrund der besseren Modellkriterien wird GI 2 zur Modellierung der Wuchshöhe verwendet. Cook's D und Leverage überschreiten nur geringfügig die kritischen Werte, das Modell ist also stabil. Die standardisierten Residuen sind Normalverteilt und variieren homogen um 0. Somit ist von der Gültigkeit des Modells auszugehen.

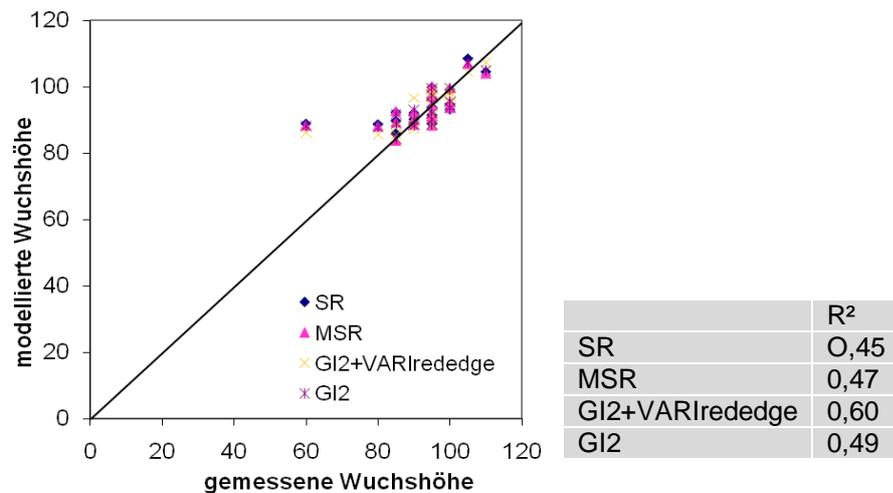


Abb. 29: Vergleich zwischen modellierter und groundtruth-Wuchshöhe für Wintergerste mit jeweiligem Bestimmtheitsmaß (R^2).

Bei der Regressionsanalyse für Winterroggen zeigten sich ähnliche Indizes als gute Prädiktoren für die Wuchshöhe, wie zuvor für Wintergerste.

$$SR \quad (R^2 = 0,48): \quad y = 106,822 + 3,032 \cdot SR$$

$$MSR \quad (R^2 = 0,47): \quad y = 105,066 + 10,540 \cdot MSR$$

$$GII \quad (R^2 = 0,45): \quad y = 107,656 + 6,307 \cdot GI \ 1$$

$$SAVI \quad (R^2 = 0,44): \quad y = 93,719 + 28,951 \cdot SAVI$$

$$NDVI \quad (R^2 = 0,44): \quad y = 93,720 + 43,421 \cdot NDVI$$

Weitere Indizes zeigten nur geringfügig schwächere Zusammenhänge mit der Wuchshöhe (z.B. GI2 und OSAVI). Quadratische Kurvenberechnungen erreichten nur wenig bessere Ergebnisse als lineare, weshalb dies, insbesondere im Hinblick auf die Anzahl der Stichproben, vernachlässigt werden kann.

NDVI und SAVI waren am robustesten in Bezug auf die Fehler in den AISA-Szenen. Da auch die Modellkriterien nicht bedeutend schlechter sind als bei anderen Modellen, werden diese Indizes zur Modellierung verwendet. Die Ergebnisse der beiden Modelle stellen sich als fast identisch heraus, wie auch die statistischen Kriterien in Tab. 10 andeuten.

4. Ergebnisse

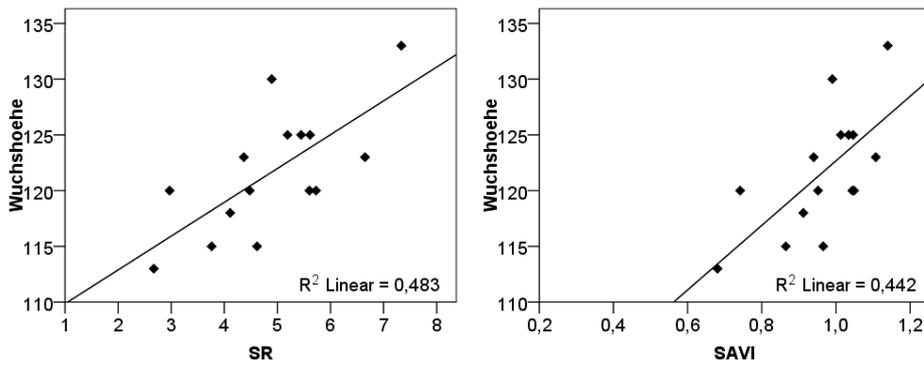


Abb. 30: Zusammenhang zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterroggen.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
Wuchshöhe vs. SR	0,48	0,004	0,35	0,27
Wuchshöhe vs. SAVI	0,44	0,007	0,37	0,36
Wuchshöhe vs. NDVI	0,44	0,007	0,37	0,36

Tab. 10: Gütekriterien für die Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterroggen.

Der Vergleich von modellierter und *groundtruth*-Wuchshöhe zeigt bei allen Indizes ähnlich gute Ergebnisse (Abb. 31). Die Modellgültigkeit konnte durch Residuenanalyse bestätigt werden. Die sehr geringe Varianz in den *groundtruth*-Daten findet sich auch in den modellierten Werten wieder.

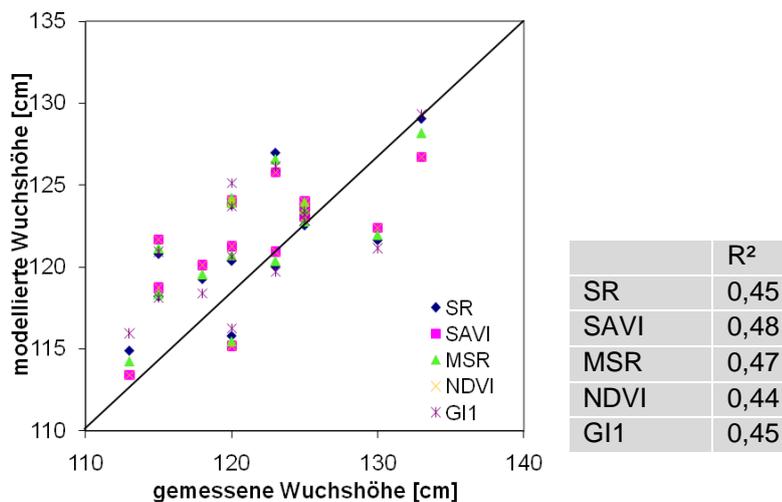


Abb. 31: Vergleich von modellierter und *groundtruth*-Wuchshöhe für Winterroggen mit jeweiligem Bestimmtheitsmaß (R²)

Die Regressionsmodelle für die Wuchshöhe von Wintertraps zeigten gute Ergebnisse. Jedoch nur CI, $VARI_{rededge}$ und RDVI zeichneten sich auch durch Stabilität der Modelle aus. Gute Korrelationen weisen auch REIP, NDVI und SAVI auf. Bei diesen Schätzungen wird der Schwellenwert von Cook's D deutlich überschritten, weshalb die ausgewählten Modelle bevorzugt werden. Die Eliminierung von Ausreißern führt nicht zu besseren Regressionsergebnissen.

$$CI \quad (R^2 = 0,67): \quad y = 16,744 + 171,396 \cdot CI$$

$$VARI_{rededge} \quad (R^2 = 0,66): \quad y = 133,673 + 144,444 \cdot VARI_{rededge}$$

$$RDVI \quad (R^2 = 0,66): \quad y = 31,972 + 2,967 \cdot RDVI$$

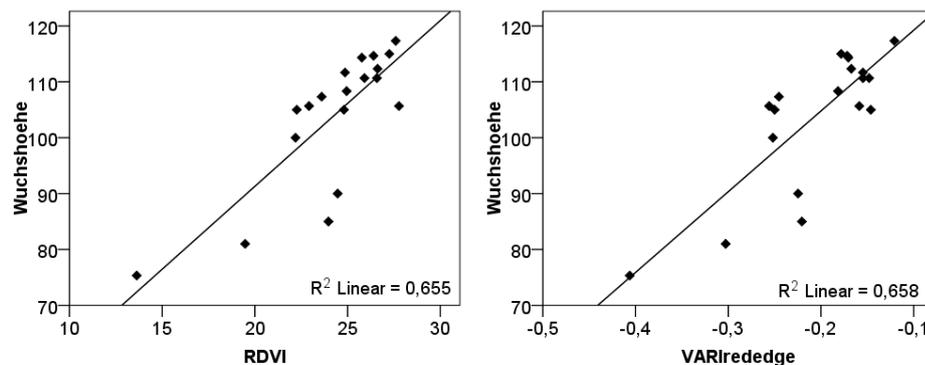


Abb. 32: Zusammenhang zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Wintertraps.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
Wuchshöhe vs. CI	0,67	0,000	0,35	0,44
Wuchshöhe vs. $VARI_{rededge}$	0,66	0,000	0,17	0,47
Wuchshöhe vs. RDVI	0,66	0,000	0,33	0,56

Tab. 11: Gütekriterien der Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Wintertraps.

Quadratische und exponentielle Modelle erzielten geringfügig bessere Ergebnisse. Bei Anwendung des Modells zeigt sich, dass das Modell mit $VARI_{rededge}$ sensibler auf Fehler reagiert als die übrigen Modelle. Aufgrund dessen und wegen der höheren Modellgüte wurde CI für die Modellierung der Wuchshöhe des Wintertrapsbestandes angewendet. Die Modelle bilden die Realität gleich gut ab, wie aus Abb. 33 hervorgeht.

4. Ergebnisse

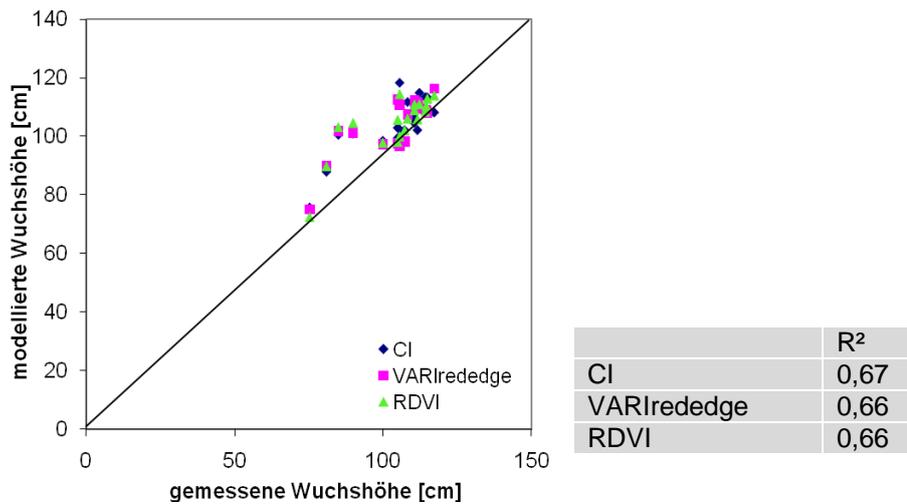


Abb. 33: Vergleich von gemessener und groundtruth-Wuchshöhe für Winterweizen mit jeweiligem Bestimmtheitsmaß (R^2).

Besonders hohe Korrelationen zwischen Vegetationsindizes und der Wuchshöhe zeigten sich für Winterweizen. Folgende Modelle bilden die Wuchshöhe am besten ab:

$$SIPI \quad (R^2 = 0,84): \quad y = 16,844 + 0,028 \cdot SIPI$$

$$DVI \quad (R^2 = 0,84): \quad y = 16,718 + 0,028 \cdot DVI$$

$$RDVI \quad (R^2 = 0,84): \quad y = 16,403 + 0,848 \cdot RDVI$$

$$MSR \quad (R^2 = 0,84): \quad y = 19,562 + 7,782 \cdot MSR$$

$$MCARII \quad (R^2 = 0,84): \quad y = 17,711 + 0,016 \cdot MCARII$$

Exponentielle Funktionen zeigten geringfügig bessere Zusammenhänge. DVI und SIPI weisen sehr ähnliche Ergebnisse auf. Da sie in allen Modellgütekriterien die besten Werte aufweisen, werden sie zur Modellierung der Wuchshöhe auf dem untersuchten Winterweizenfeld verwendet (Tab. 12). Der Vergleich modellierter mit *groundtruth*-Wuchshöhe zeigt bei allen Modellen ähnlich gute Ergebnisse (Abb. 35). Die Residuenanalyse bestätigt die Stabilität der Modelle.

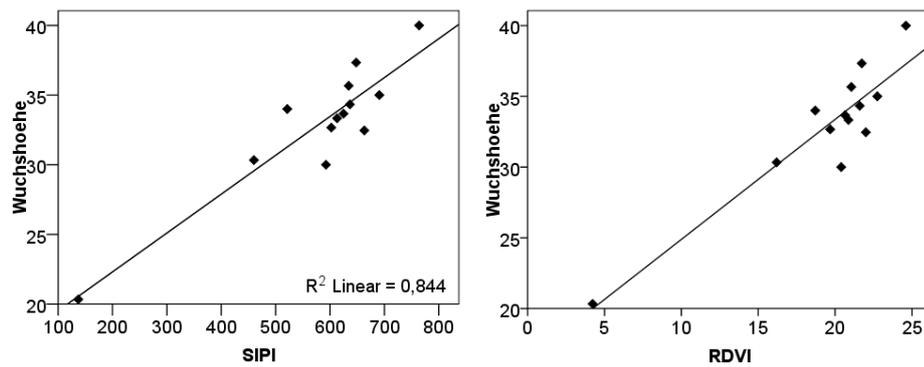


Abb. 34: Zusammenhang zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterweizen.

	R ²	Signifikanz	max. Cook's D	max. Zentr. Leverage
Wuchshöhe vs. SIPI	0,84	0,000	0,16	0,71
Wuchshöhe vs. DVI	0,84	0,000	0,16	0,71
Wuchshöhe vs. RDVI	0,84	0,000	0,64	0,78
Wuchshöhe vs. MSR	0,84	0,000	0,77	0,65
Wuchshöhe vs. MCARI1	0,84	0,000	0,23	0,75

Tab. 12: Gütekriterien für die Zusammenhänge zwischen Wuchshöhe und ausgewählten Vegetationsindizes für Winterweizen.

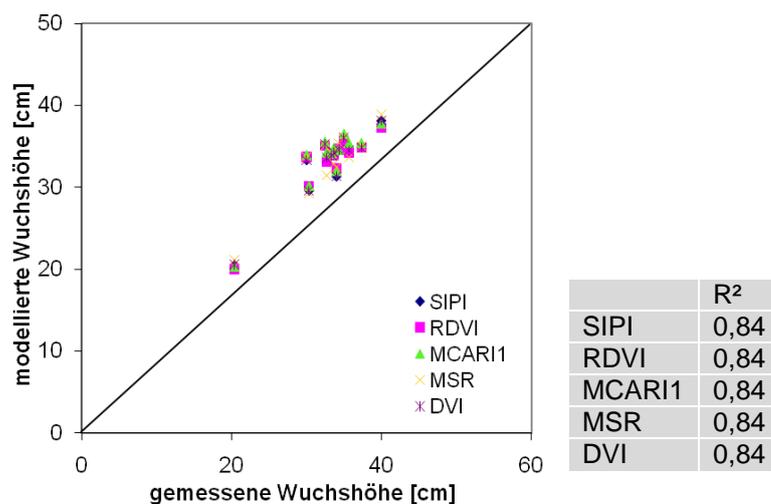


Abb. 35: Vergleich von gemessener und groundtruth-Wuchshöhe für Winterweizen mit jeweiligem Bestimmtheitsmaß (R²).

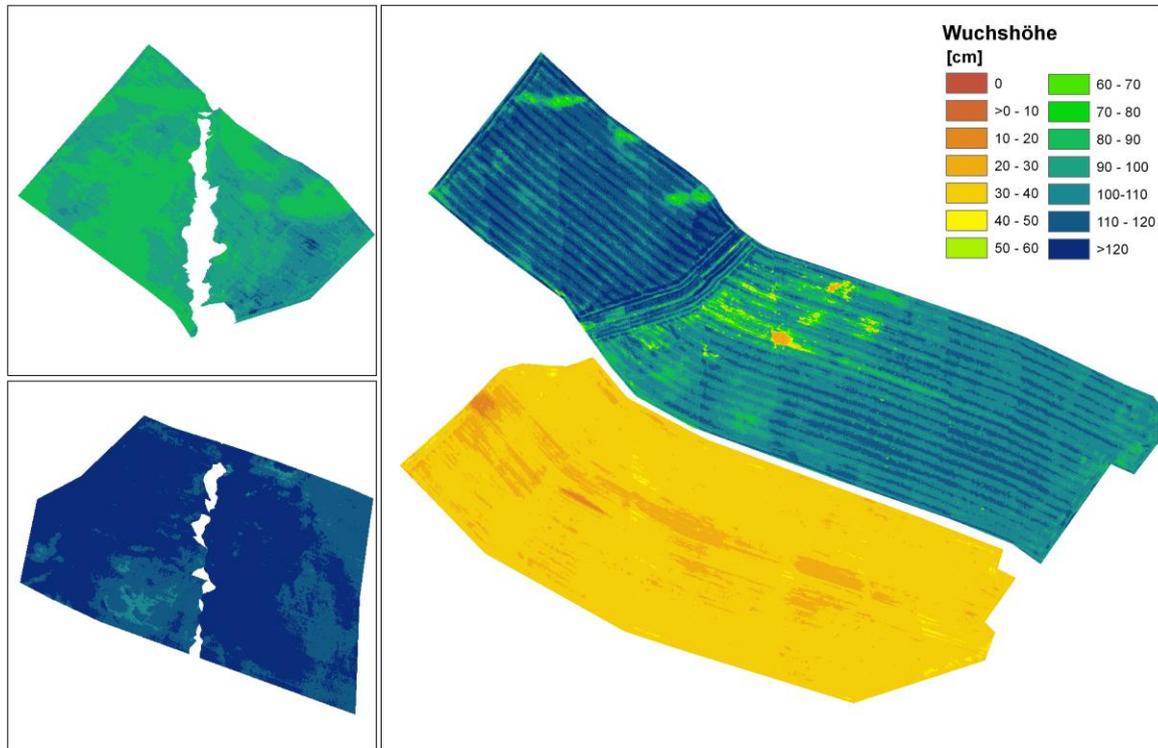


Abb. 36: Ergebniskarten der empirischen Modellierung von Wuchshöhe. Oben links: Wintergerste, unten links: Winterroggen, oben rechts: Winterraps, unten rechts: Winterweizen.

4.5 ERGEBNISSE DER KLASSIFIKATION

Thematische Karten bestimmter Pflanzenparameter werden als Grundlage zur Modellierung von Bodenfeuchte benötigt. Eine Schlüsselrolle spielt der Pflanzenwassergehalt im Mikrowellensignal, weshalb die Verteilung des Wassergehaltes der Pflanzen [kg/m^2] auf den Testflächen benötigt wird. Um flächendeckende Informationen über Pflanzenwassergehalt mittels empirischer Modellierung zu gewinnen ist die Datengrundlage der *groundtruth* nicht ausreichend. Überwachte Klassifikation stellt ein geeignetes Instrument, thematische Karten auf Grundlage von bekannten Objekten durchzuführen. Auf Basis der AISA-Szenen wird *groundtruth* eingesetzt um die Spektren der einzelnen Pixel Pflanzenwasser-Klassen zuzuordnen.

Es werden drei Methoden auf ihre Eignung zur Klassifikation biophysikalischer Parameter auf Feldskala getestet: Spektral Angle Mapper, künstliche Neuronale Netze und Support Vector Machine. Anhand der Daten der Kampagne 2009 werden die Methoden an Winterraps- und Winterweizenkulturen getestet und bewertet. Die beste Methode wird ausgewählt und auf die Daten der Messkampagne von 2008 angewendet um trotz fehlender Validierungsdaten Informationen über die Verteilung von Pflanzenwasser auf dem Wintergerste- und dem Winterroggenfeld zum Aufnahmezeitpunkt zu erhalten. Im Anschluss wird die beste Methode zur Klassifikation der Wuchshöhe angewendet, um die Ergebnisse mit denen der empirischen Modellierung zu vergleichen.

4.5.1 Pflanzenwasser

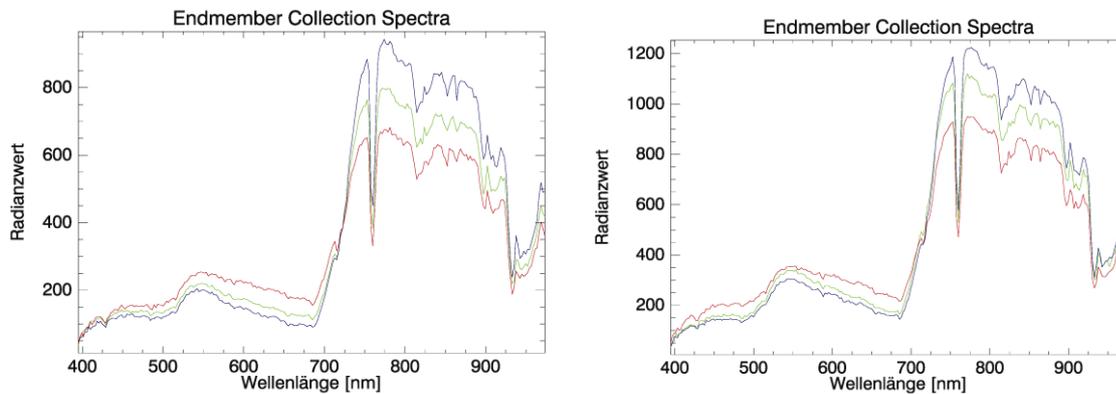
Der Pflanzenwassergehalt wird durch den Spektralbereich des AISA Eagle nur indirekt beschrieben. Wasser absorbiert Strahlung erst in Wellenlängenbereichen des nahen Infrarot (NIR) und kurzwelligen Infrarot (SWIR). Diesen Bereich deckt das Sensorsystem AISA-Eagle nicht ab. Auch die schmale Wasserabsorptionsbande bei 920-980 nm (Peñuelas et al. 1993, Jensen 2000) zeigte keine Zusammenhänge mit dem Pflanzenwasser, weshalb die Zusammenhänge mit anderen Parametern untersucht wurden. Pflanzenwassergehalt weist gute Zusammenhänge mit LAI, Wuchshöhe und Biomasse auf den Untersuchungsflächen und somit mit dem Zustand der Vegetation, grüner Pflanzenmasse und den verschiedenen Vegetationsindizes auf (vgl. Kap. 4.4). Aufgrund der besseren Zusammenhänge mit EWT, wird dieser zur Bestimmung von Pflanzenwasser auf den Untersuchungsflächen herangezogen und GWC vernachlässigt.

Um zu untersuchen, ob Vegetationsindizes trotz der fehlenden Berücksichtigung von Wasserbanden EWT gut beschreiben, wurden auch hier Regressionsanalysen mit den Daten von 2009 durchgeführt. Für Winterraps und Winterweizen steht ausreichend *groundtruth* zur Verfügung. Die Regression zeigte gute Ergebnisse mit R^2 bis zu 0,63 für Winterraps und 0,75 für Winterweizen. Geeignete Indizes zur Detektion von Winterweizen aus Wellenlängen im sichtbaren und nahen Infrarotbereich sind demnach: CI, GI2, GI1, SR und MSR.

Zur Klassifikation wurden die *groundtruth*-Werte für jede Pflanzenart in drei Klassen eingeteilt. Im Anschluss wurden aus den jeweiligen Spektren der AISA-Szene, für die einzelnen Klassen repräsentative Trainingsspektren ausgewählt. Die *Endmember*

4. Ergebnisse

Collection Spectra, also die als Trainingspektren verwendeten Pixel aus der AISA-Szene, sind in Abb. 37 dargestellt. Auch hier wurden 9er Nachbarschaften der Pixel verwendet.



(a)

(b)

Abb. 37: Trainingspektren (Endmember Collection Spectra) für die Klassifikation von Winterweizen (a) und Winterraps (b). Rot: geringer Pflanzenwassergehalt, grün: mittlerer Pflanzenwassergehalt, blau: hoher Pflanzenwassergehalt, bezogen auf die Pflanzenart und ihr jeweiliges Phänologiestadium.

Es wurden 3 verschiedene überwachte Klassifikationsmethoden getestet und miteinander verglichen um möglichst gute Ergebnisse zu erhalten und die Eignung der Methoden zu bewerten. Die ausgewählten Spektren wurden zum trainieren aller Klassifikationsalgorithmen verwendet.

Problematisch stellt sich die korrekte Zuordnung von Pixeln in die jeweilige Klasse insbesondere an Klassengrenzen dar. Die Spektren der *groundtruth*-Pixel unterschiedlicher Klassen weisen Überlappungsbereiche auf, weshalb sich in diesen Bereichen eine eindeutige Klassenzuweisung schwierig gestaltet. Die *accuracy matrices* für Winterweizen und Winterraps sind im Anhang zu finden. In Tab. 13 sind die Gesamtgenauigkeiten der Methoden zusammengefasst dargestellt. Bei Ermittlung der Gesamtgenauigkeit der Klassifikation wurden die Trainingsdaten nicht berücksichtigt. Im Falle von Winterweizen wurden keine großen Unterschiede in den Klassifikationsergebnissen festgestellt. SAM klassifizierte die Testdaten mit 60 % Genauigkeit, sowie SVM. NN ordnete mit 70 % nur einen Testpunkt mehr der richtigen Klasse zu. Die Erklärung für diese wenig genauen Klassifikation ist in der sehr geringen Wertespanne des Pflanzenwassers auf dem jungen Winterweizenfeld zu suchen, durch die Messungenauigkeiten stärker ins Gewicht fallen. Dies erschwert eine exakte

Zuordnung zu einer bestimmten Klasse. Die Klassifikation von Pflanzenwasser bei Raps zeigte bessere Ergebnisse. Mit NN und SVM konnten Gesamtgenauigkeiten von bis zu 93,8% erreicht werden, während SAM nur 87,5% Genauigkeit lieferte.

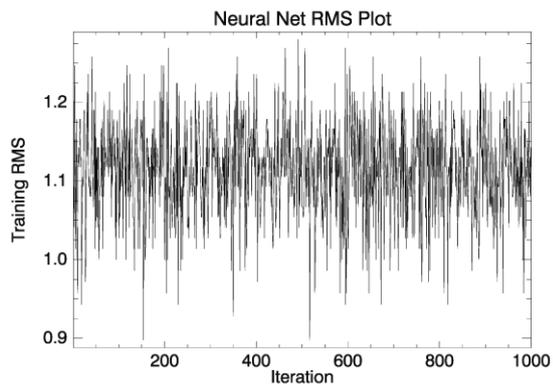
	NN	SAM	SVM
Winterraps	93,8 %	87,5 %	93,8 %
Winterweizen	70 %	60 %	60 %

Tab. 13: Gesamtgenauigkeit (overall accuracy) der Klassifikationen von Pflanzenwasser (EWT) mit Neuronalen Netzen, Spectral Angle Mapper und Support Vector Machine.

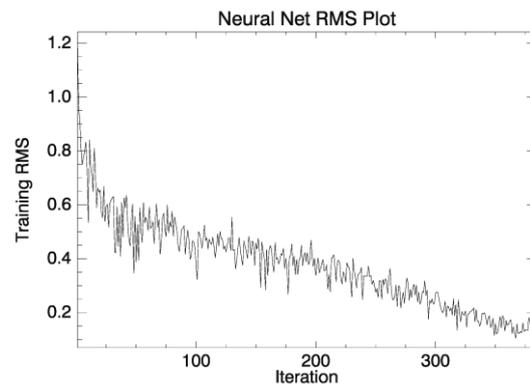
Aufgrund der kleinräumigen Betrachtungsebenen und der in diesem Zusammenhang relativ geringen Anzahl an Referenzdaten, sowie der geringen spektralen Varianz, die innerhalb der Monokulturen gegeben war, zeigten die verwendeten Klassifikationsmethoden nur geringe Unterschiede. Aus der Klassifikation mit SAM ergaben sich unklassifizierte Bereiche, was durch Änderungen der Schwellenwerte für die Winkel, in denen Pixel den einzelnen Klassen zugeordnet werden, verbessert werden konnte. Veränderungen solcher Einstellungen sind aufgrund der unterschiedlich gewählten Klasseneinteilungen für die einzelnen Pflanzenarten nicht auf die Daten von 2008 übertragbar. Eine neue Auswahl der Trainingsdaten führte eher zu Verschlechterungen der Ergebnisse. Die Klassifikationen mit den verschiedenen Methoden sind in Abb. 39 dargestellt.

Die Ergebnisse der Klassifikation mit NN konnten durch Herabsetzen des Trainings Momentum deutlich verbessert werden. Bei hohem Trainings Momentum oszillierte der RMS-Fehler stark und pendelte sich bei einem Wert von etwa 1,1 ein (vgl. Abb. 38a). Schließlich wurden alle Pixel nur einer Klasse zugeordnet. Der hohe RMS-Fehler spiegelt den ausbleibenden Lernerfolg wider. Bei geringerem Trainings Momentum oszillierte der RMS-Fehler weniger extrem und senkte sich bis auf einen Wert von 0,1 ab (Abb. 38b). Die Fehlerminimierung verlief hierbei gleichmäßig. Das Hinzufügen eines neuen *Hidden Layers* erhöhte den RMS-Fehler wieder und führte zu keiner Verbesserung der Klassifikationsergebnisse. Die beste Klassifikation wurde mit nur einem *Hidden Layer* erreicht. Die in ENVI bereitgestellten Standarteinstellungen lieferten die besten Ergebnisse, bei NN wurde jedoch aus genannten Gründen Trainingsmomentum und Trainings Threshold Contribution auf 0,6 herabgesetzt.

4. Ergebnisse

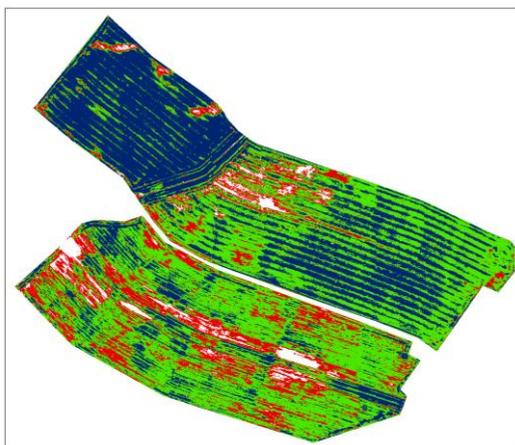


a)

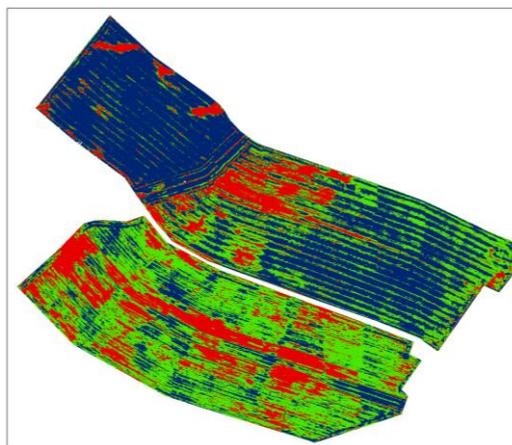


b)

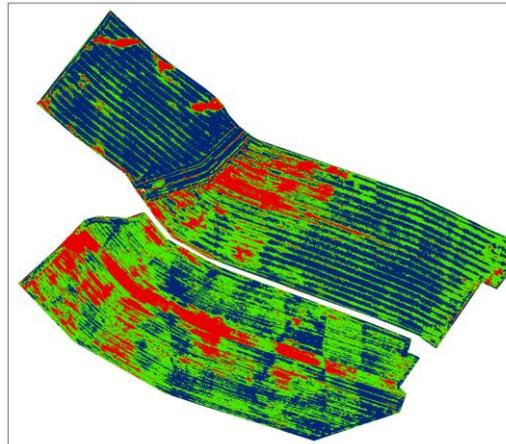
Abb. 38: RMS Fehlerreduktion bei Wiederholung des Trainings des Neuronalen Netzes zur Klassifikation von Pflanzenwasser bei Winterweizen. a) Standardeinstellung mit hohem Trainingsmomentum, b) Trainingsmomentums auf 0,1 herabgesetzt.



a)



b)



c)

Abb. 39: Klassifikation von Pflanzenwasser [kg/m²] in Winterraps und Winterweizen. a) SAM, b) SVM, c) NN. Rot: Klasse1, geringer Pflanzenwassergehalt, grün: Klasse2, mittlerer Pflanzenwassergehalt, blau: Klasse3, hoher Pflanzenwassergehalt

Aufgrund der besseren Gesamtgenauigkeiten wurde NN, unter Verwendung der im vorangegangenen Kapitel dargestellten Parametereinstellungen, zur Klassifikation der Daten von 2008 angewendet. Für das Wintergerstefeld standen 5 *groundtruth*-Punkte zur Verfügung, von denen 3 aufgrund ihrer ähnlichen Werte in die Klasse mit dem höchsten Pflanzenwassergehalt eingeteilt wurden. Die Klassifikationen mit allen möglichen Trainingsdatenkombinationen ergaben sehr unterschiedliche Ergebnisse (vgl. Abb. 40). Das Training des Neuronalen Netzes, mit jeweils anderem Trainingsspektrum für Klasse 3, zeigte starke Unterschiede in den Klassifikationskarten, sowie auch während des Trainings durch Rückverfolgung des RMS-Fehlers. Abb. 40 zeigt die Ergebnisse der drei Klassifikationsvarianten. Es wird deutlich, wie stark die Klassifikation von den gewählten Trainingsspektren abhängt und Messfehler oder Ungenauigkeiten die Ergebnisse beeinflussen. Da bekannt ist, dass der Pflanzenwassergehalt mit der Wuchshöhe, LAI und Vegetationsindizes positiv korreliert ist, kann ein Vergleich mit Vegetationsindexkarten oder den modellierten Wuchshöhen Aufschluss über die Plausibilität der drei Varianten geben. Es zeigt sich, dass die erste Variante (Abb. 40a) die einzigen plausiblen Ergebnisse liefert. Nur bei dieser Klassifikation wird den tiefer gelegenen, bachnahen Bereichen die höchste Pflanzenwasserklasse zugeordnet, während kuppennahe Bereiche niedrigeren Pflanzenwasserklassen zugeordnet werden. Dies stimmt mit den Ergebnissen der Modellierung von LAI und Wuchshöhe überein (vgl. Kap. 4.4). Ein weiterer Aspekt ist

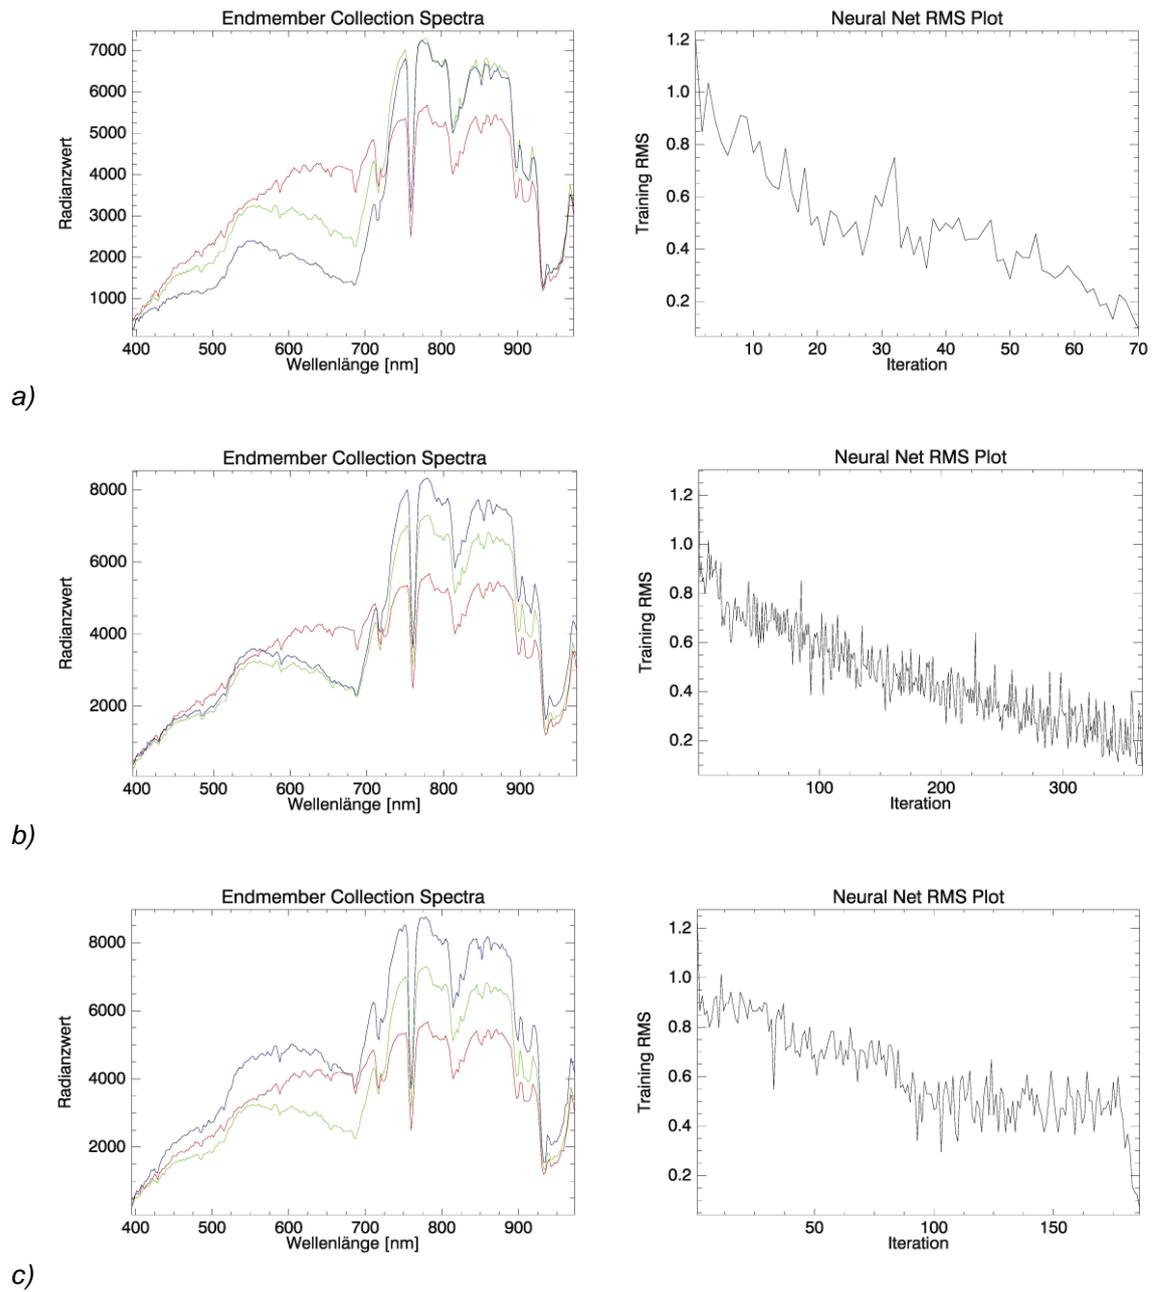


Abb. 41: Trainingsspektren und Verlauf der RMS-Fehlerreduktion für die Klassifikation mit unterschiedlichen Trainingspektren, wie in Abb.40 dargestellt.

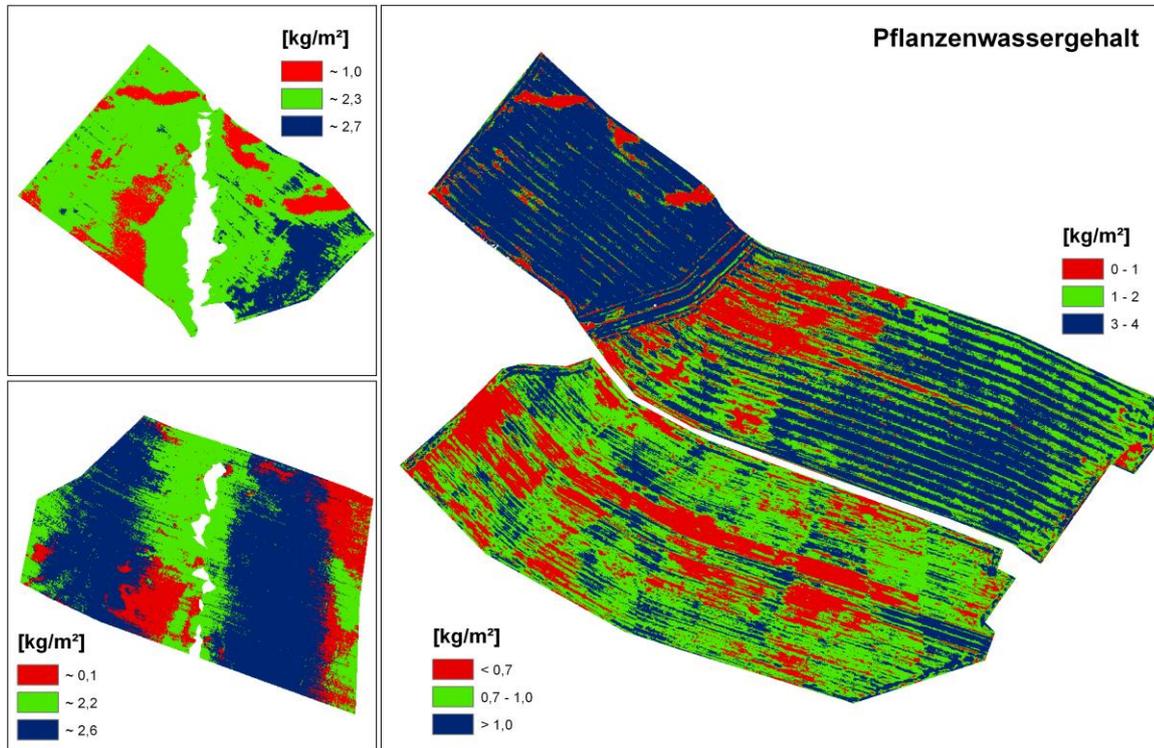


Abb. 42: Klassifikationsergebnisse von Pflanzenwasser mit der Methode künstlicher Neuronaler Netze. Links oben: Wintergerste, links unten: Winterroggen, rechts oben: Winterraps. Rechts unten Winterweizen.

4.5.2 Vergleich der Methoden anhand von Wuchshöhe

Zur Klassifikation der Wuchshöhe wurde die Methode künstlicher Neuronaler Netze verwendet, wie für Pflanzenwassergehalt als bester Algorithmus zur Gewinnung biophysikalischer Parameter für den vorliegenden Datensatz festgelegt wurde. Dazu wurden die gleichen Parameter für NN gewählt, wie im vorangegangenen Kapitel beschrieben.

Die Klassifikation der Wuchshöhe soll dazu dienen die Ergebnisse mit denen des empirischen Modells zu vergleichen. Da für die Wuchshöhe ausreichend *groundtruth* zur Verfügung steht, konnten empirische Modelle für alle vier Pflanzenarten erstellt werden. Die Ergebnisse der modellierten Wuchshöhe wurden auf die gleichen Wertebereiche, wie bei der Klassifikation verwendet, reklassifiziert. Somit wurde ein direkter Vergleich der

Methoden ermöglicht. Der Vergleich wurde für Wintergerste (Datensatz 2008) und Winterraps (Datensatz 2009) durchgeführt. Die Gesamtgenauigkeit der jeweiligen Methode ist in Tab. 14 dargestellt. Aus der Gesamtgenauigkeit lässt sich keine Methode als die Bessere bestimmen. Für Wintergerste weist das empirische Modell höhere Genauigkeiten auf als die Klassifikation durch Neuronale Netze. Für Winterraps hingegen wurden höhere Genauigkeiten durch Klassifikation erreicht.

	Modell	NN
Wintergerste	75%	52,9%
Winterraps	73,7%	93,8%

Tab. 14: Gesamtgenauigkeit der Klassifikation von Pflanzenwasser (EWT) mittels Neuronaler Netze

Tab. 15 zeigt die Zuordnung von Pixeln und Flächenanteile der einzelnen Klassen bei Modellierung und Klassifikation im Vergleich. Es wird deutlich, dass Klassifikation im Falle von Wintergerste deutlich mehr Bereichen hohe Wuchshöhen zuweist als das empirische Modell (siehe auch Abb. 43). Dreißig Prozent der Fläche wurden so bei Klassifikation einer Klasse mit höherem Wuchs zugeordnet als bei empirischer Modellierung. Keine Pixel wurden bei Klassifikation einer niedrigeren Klasse zugeordnet. Auch für Winterraps wurden nur wenige Pixel durch Klassifikation einer niedrigeren Wuchshöheklasse zugeteilt als durch Modellierung (vgl. Tab. 15).

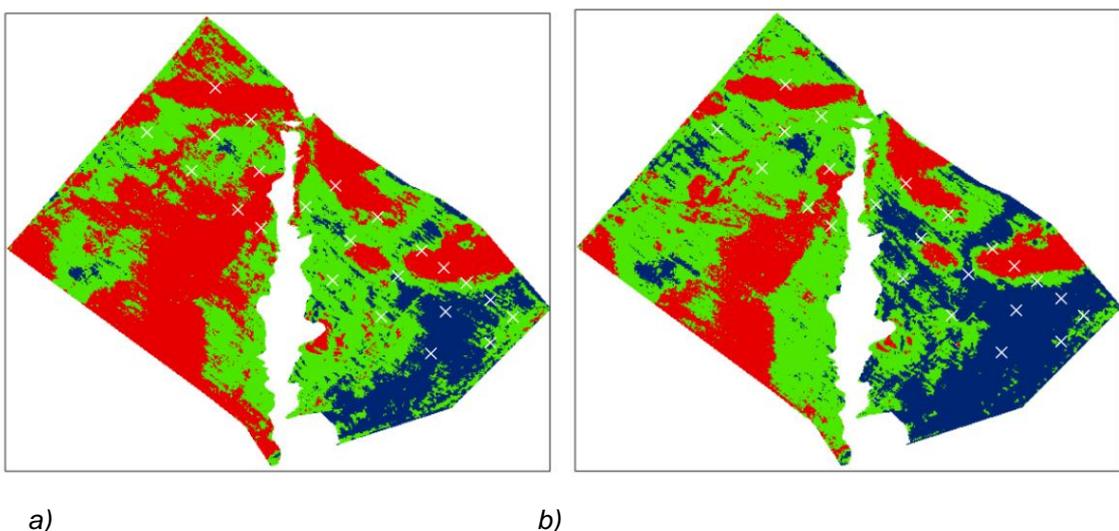


Abb. 43: Pflanzenwassergehalt von Wintergerste durch a) empirische Modellierung, b) Klassifikation mit Neuronalen Netzen.

4. Ergebnisse

Modelliert	Klassifiziert	Pixel	Fläche
1	1	29799	24%
1	2	21064	17%
2	2	39006	32%
2	3	15788	13%
3	3	16783	14%
Gesamtfläche		122440	100%

Modelliert	Klassifiziert	Pixel	Fläche
1	1	72551	8%
1	2	29259	3%
1	3	7	0%
2	1	18992	2%
2	2	203254	21%
2	3	259886	27%
3	2	27600	3%
3	3	350343	36%
Gesamtfläche		961892	100%

a) Wintergerste

b) Winterraps

Tab. 15: Vergleich der Klassengrößen durch Klassifikation (NN) und empirische Modellierung für Pflanzenwasser. Die drei Klassen enthalten für beide Methoden die gleiche Wertespanne und stellen die Nummern in den ersten beiden Spalten dar.

5 DISKUSSION

5.1 VARIABILITÄT AUF DEN UNTERSUCHUNGSFLÄCHEN

Aus den Ergebnissen der vorliegenden Arbeit geht hervor, dass die schlagspezifische Heterogenität landwirtschaftlicher Kulturen (LAI, Wuchshöhe, Biomasse, Pflanzenwasser) weitestgehend geomorphologisch bedingt ist. Die Verteilung von Kuppen und Senken im Gelände, Hangneigung und Exposition sind entscheidend für das Mikroklima, Stoffverlagerungen und den Wasserhaushalt eines Standortes (SCHRÖDER 1999). Diese Parameter bilden die Standortbedingungen und neben der geologischen Ausgangssituation auch die Grundlage für Bodenmuster. Bei der Untersuchung von Standortfaktoren zeigte sich, dass zur Erfassung kleinräumiger Heterogenität des Bodens nur sehr großmaßstäbige Karten relevante Informationen für die Präzisionslandwirtschaft und die Gewinnung von Informationen über die Variabilität in der Vegetationsbedeckung bieten. Dies stimmt mit den Ergebnissen CAPPELLES (1999) überein. So ist die mittelmaßstäbige landwirtschaftliche Standortkartierung Sachsens (MMK) nicht ausreichend um die Bodenheterogenität auf Feldskala mit unterschiedlichem Bewuchs in Zusammenhang zu bringen. Die großmaßstäbigere Reichsbodenschätzung zeigt hingegen deutlich, dass auf sandigen Kuppen spärlichere Vegetation zu finden ist, was sich aus relief- bzw. bodenbedingten Wasser- und Nährstoffverteilungen ergibt.

Auf schlechter wasserversorgten Bereichen zeigte sich das Getreide seneszent und in einem höheren Altersstadium als auf besser versorgten Bereichen (Daten 2008). Die Kulturpflanzen in jüngerem phänologischem Stadium (Daten 2009) waren jedoch in den schlecht versorgten Bereichen rückständig in ihrer Entwicklung. Wie zu Beginn der Arbeit erläutert, ist der Ertrag einer Pflanze davon abhängig, wie lange sie über einen assimilierenden Blattapparat verfügt. Die Pflanzen auf schlecht versorgten Bereichen haben somit zu Beginn des Wachstums ein geringeres Stadium, altern aber auch schneller als in anderen Bereichen. Die Zeit, in der sie ihre Früchte bilden ist also geringer, weshalb mit einem geringeren Ernteertrag zu rechnen ist. Außerdem erklärt sich daraus die geringere Wuchshöhe und Biomasse in diesen Bereichen. Die verfrühte Seneszenz von Getreide bei schlechter Wasserversorgung wird auch als „Notreife“ bezeichnet (KRUPINSKA 2007). Bei dem Vergleich der Phänologie von Raps und Getreide

muss jedoch beachtet werden, dass die verschiedenen Pflanzenarten auch physiologische Unterschiede aufweisen.

Als erstes zeigt EWT eine Abnahme durch Reife. Die übrigen Parameter zeigen kurz darauf ebenfalls einen Rückgang mit zunehmender Seneszenz. EWT kann somit als Schlüsselparameter zur Erkennung einsetzender Reife angesehen werden und erfüllt ähnliche Funktionen, wie das Fahnenblatt. Wegen seiner guten Zusammenhänge zu spektralen Signalen der Vegetation kann er jedoch mit Hilfe von *groundtruth* Flächendeckend hergeleitet werden. So kann er verwendet werden um Heterogenität der Vegetationsbedeckung zu erkennen und zu quantifizieren. Außerdem kann er wichtige Informationen für die Landwirtschaft bereitstellen. Ähnliche Ergebnisse zeigt die Arbeit von KNEUBÜHLER (2002). Der daraufhin einsetzende Rückgang von LAI und Wuchshöhe ist vor allem auf Schrumpfung der Blätter durch Wasserverlust und auf den Rückgang der Blattmasse der unteren Blätter zur Kornreife zurückzuführen. Der Anteil der unteren Blätter an der Gesamtblattmasse bei Getreide nimmt stetig ab (SCHELLBERG 1990). Auch Chlorophyll nimmt mit einsetzender Reife ab, was auf die „Notreife“ trockener Bereiche übertragen werden kann. Auch die höhere Chlorophyllkonzentration in spärlich bewachsenen Teilen des Rapsbestands ist darauf zurückzuführen, dass diese Bereiche noch nicht in Blüte standen. Der Entwicklungsvorsprung der übrigen Pflanzen kann erkannt werden, da Chlorophyll zur Bildung der Blüte bereits abgebaut wurde.

Das zeitliche Zusammenspiel der verschiedenen Vegetationsparameter zeigt sich auch räumlich in guten linearen Zusammenhängen zwischen LAI, Wuchshöhe und Wassergehalt der Vegetation, weshalb festgehalten werden kann, dass alle Parameter zur Erkennung vitaler und grüner Vegetation beitragen. Obwohl Chlorophyllgehalt als direkt mit Photosynthese verknüpft gilt, konnten keine signifikanten Zusammenhänge mit anderen Parametern festgestellt werden. Gründe könnten jedoch auch die Messmethode auf Blattebene sein, während die übrigen Parameter auf Bestandesebene ermittelt wurden oder Ungenauigkeiten bei der Messung mit SPAD-502.

5.2 ERGEBNISSE DER REGRESSION MIT ABBILDENDEN HYPERSPÉKTRALDATEN

Es ist bekannt, dass optische Sensoren die Unterscheidung von Pflanzenarten ermöglichen. Die Ergebnisse der Regressionsanalyse zeigten, dass sogar zwischen

Wintergerste und Winterroggen unterschieden werden kann, bzw. muss um geeignete Modelle zu bilden. VI-Werte an den *groundtruth*-Punkten für Winterroggen lagen unter denen von Wintergerste, was in physiologischen Unterschieden der Getreidearten begründet sein kann. Phänologisch begründet müsste jedoch Wintergerste, aufgrund des leichten Entwicklungsvorsprungs, geringere Werte aufweisen, da der Bestand schon mehr und stärker senescente Bereiche aufweist. Tatsächlich wird bei Betrachtung des Histogramms aller NDVI-Werte für beide AISA-Szenen deutlich, dass die Verteilung bei beiden Getreidesorten ähnlich ist, Gerste jedoch mehr Pixel mit geringen NDVI-Werten hat. Es zeigt sich also ein anderes Bild als bei der reinen Betrachtung der Werte an *groundtruth*-Messstellen, woraus die hohe Zufälligkeit bei Erhebung von *groundtruth* deutlich wird. Diese Problematik könnte durch eine Erhöhung der Stichprobenzahl umgangen werden.

Nicht nur Vegetation bestimmt die Reflektion elektromagnetischer Strahlung an der Landoberfläche. Auch Bodenuntergrund und Atmosphäreneinflüsse bilden sich im spektralen Signal ab. Um den Einfluss der Atmosphäre auf Vegetationsindizes besser einschätzen zu können wurden Radianzen der abbildenden Fernerkundungsdaten mit Reflektanzen des Feldspektrometers (ASD) verglichen. Einzelne Wellenlängen zeigten gute Zusammenhänge, während einige Wellenlängenkombinationen (Vegetationsindizes) sehr unterschiedliche Ergebnisse für die Sensorsysteme aufzeigten. Die Indexwerte aus AISA-Spektren lagen unterhalb der des ASD. Es ist demzufolge davon auszugehen, dass die Atmosphäre deutliche Einflüsse auf das am AISA-Sensor eintreffende Signal nimmt. PONTIUS et al. (2005) sehen jedoch das Potential in Vegetationsindizes, Effekte der Atmosphäre so korrigieren zu können, dass Daten verschiedener Sensoren direkt verglichen werden können. Die reine Arbeit mit Radianzen oder Reflektanzen wird in zukünftigen Arbeiten durchzuführen sein, um Feldspektrometerdaten und Fernerkundungsdaten vergleichbarer zu machen und zu Methodenentwicklung und Interpretierbarkeit des Signals beizutragen.

Die Einflüsse von Boden auf Spektralsignale, erwirken für dunkle Böden höhere Vegetationsindexwerte (BARET & GUYOT 1991). Da auch Feuchte Einfluss auf die Bodenfarbe nimmt, kommt zu der spärlicheren und trockeneren Vegetation auch das Signal der geringen Bodenfeuchte und somit helleren Böden auf den Sandkuppen hinzu. Dies bedingt geringe Vegetationsindexwerte auf den Sandkuppen, wobei der Anteil des jeweiligen Einflusses an der spektralen Signatur schwer erkennbar wird. Die guten Zusammenhänge zwischen Wuchshöhe und Pflanzenwasser von Winterweizen im frühen

Phänologiestadium könnte durch den Effekt der Bodenfarbe unterstützt werden, da der Bedeckungsgrad noch sehr gering ist und Boden mehr Einfluss auf das spektrale Signal nimmt. Bereiche mit gutem Wuchs weisen demnach, aufgrund des Bodensignals der höheren Bodenfeuchte, besonders hohe Indexwerte auf. Dieser Aspekt könnte verantwortlich für den besonders guten statistischen Zusammenhang zwischen Vegetationsindizes und Wuchshöhe bei Winterweizen sein.

Insgesamt ergeben die Analysen, dass sich Blattstrukturparameter stärker im Spektralsignal abbilden. Einzelne Pigmente, wie Chlorophyll treten dahinter zurück. Dies entspricht den Aussagen von ASNER (1998), der LAI als stärkstes Kontrollparameter auf die Reflektanz von vegetationsbedeckten Flächen ermittelte. Auch KNEUBÜBLER (2002) fand heraus, dass das spektrale Verhalten einer Vegetationsdecke in erster Linie durch grüne Biomasse bestimmt wird (grüner LAI). In der vorliegenden Arbeit zeigten ebenfalls LAI und Trockenbiomasse gute Zusammenhänge mit dem spektralen Signal der Landoberfläche. Beide Parameter repräsentieren hier jedoch aufgrund der Messmethode die gesamte Pflanzenmasse, während fast alle Vegetationsindizes nur grüne Blattmasse abbilden. Da trockene Vegetation nur in einigen Kuppenbereichen für seneszenten Getreide gegeben ist, wirkt sich dies nicht merklich auf die Regressionsanalyse aus.

Außerdem wurde deutlich, dass die Ebene, auf der Feldmessungen durchgeführt wurden, einen starken Einfluss auf Messgrößen und Zusammenhänge zwischen Parametern und VIs haben. Es ist daher zu bedenken, dass Chlorophyll auf Blattebene gemessen wird, während GWT die ganze Pflanze und andere Parameter gar die gesamte Vegetationsdecke beschreiben. Für die Analyse von kausalen Zusammenhängen mit abbildenden Spektraldaten bedeutet dies, dass auch hier bessere Ergebnisse mit Parametern auf Bestandesebene erzielt werden. Dies kann für den Zusammenhang zwischen Chlorophyll und GWT mit Vegetationsindizes bestätigt werden und stimmt auch mit Ergebnissen anderer Studien für Pflanzenwasser überein (KNEUBÜHLER 2002, COLOMBO et al. 2008).

5.2.1 LAI

Die verwendeten Vegetationsindizes reagierten sehr unterschiedlich in Bezug auf Sättigungseffekte bei hohem LAI. Dies stimmt mit den Ergebnissen anderer Untersuchungen überein. So fanden HABOUDANE et al. (2004) exponentielle

Zusammenhänge zwischen verschiedenen Indizes und LAI für synthetische Daten. WIEGAND et al. (1990) zeigten, dass keine bestimmte Funktion die besten Schätzungen für 2-band VIs liefert und quadratische oder exponentielle Funktionen die besten Zusammenhänge für 3- oder 4- Band Indizes abbilden. In Anbetracht der Tatsache, dass stress- oder phänologiebedingte Änderungen der Reflektanz von Blattpigmentkonzentrationen bestimmt werden, LAI dabei jedoch konstant bleiben kann, wird deutlich, dass nicht-lineare statistische Zusammenhänge nicht zwingend nicht-lineare Phänomene beschreiben. So stellen GITELSON et al. (2003) fest, dass das einsetzen der Blüte von Mais eine Zunahme der Reflektanz im sichtbaren Bereich bedingt. Die Änderungen zeigten sich vor allem in einem Anstieg der Reflektanz im Bereich von Rot und Rededge, was zu einer Abnahme der Indexwerte führte, während LAI gleich blieb. Dies erklärt auch den exponentiellen Zusammenhang im Falle von Raps, der zum Aufnahmezeitpunkt nur teilweise in Blüte stand. Blühende Bereiche konnten schon geringere Indexwerte aufweisen, während in diesen bevorteilten Bereichen auch höchster LAI zu finden war. Bei den anderen Pflanzenarten wurden Sättigungsphänomene erkennbar. Diese sind auf Indexeigenschaften zurückzuführen und zeigen sich zum Beispiel für Wintergerste durch quadratische Zusammenhänge. So ist auch die Unterscheidung zwischen LAI und grünem LAI problematisch für die Modellierung. Bei Messungen mit dem LAI 2000 wird das gesamte Blätterdach abgebildet, während VIs nur grüne Blattmasse beschreiben (HABOUDANE et al. 2004). Für die Modellierung von seneszenten Vegetation bedeutet dies, dass Chlorophyll abnimmt und sich dementsprechend die spektralen Eigenschaften ändern, auch wenn LAI gleich bleibt oder nur leicht abnimmt. Anhand dieser Ergebnisse wird deutlich, dass die beste Funktion zur Modellierung von Pflanzenparametern sehr stark von jeweiligem VI, Pflanzenart und Phänologie abhängt und daten- bzw. sensorspezifisch bestimmt werden muss. Aufgrund dessen ist die einheitliche Verwendung von linearen Funktionen hier vorzuziehen. Zudem sind nur geringfügig bessere nicht-lineare Beziehungen gegeben und lineare Modelle als stabilste zu betrachten.

Um die Linearität der Beziehung zu LAI zu verbessern, wurden verschiedene Indizes entwickelt (z.B. HABOUDANE et al. 2004, GITELSON et al. 2003). Der von GITELSON et al. (2003) entwickelte Index $(R_{\text{NIR}}/R_{\text{Green}})-1$ zeigte sich als besonders geeignet zur Berechnung von LAI bei Vegetation in früheren Phänologiestadien (Winterraps, Winterweizen; Daten 2009). Das Konzept des Index besteht darin, dass Vegetation Licht im grünen Wellenlängenbereich weniger stark absorbiert als im roten und daher nicht so sensibel auf Sättigung reagiert.

LAI der Getreidebestände von 2008 zeigte dagegen bei beiden Getreidearten gute Zusammenhänge zu PSRI (MERZLYAK et al. 1999; $(R_{670}-R_{500})/R_{750}$). Dieser Index wurde konzipiert um die Sensibilität auf Carotinoide zu erhöhen und wird zur Erkennung von Pflanzenstress und Fruchtreife eingesetzt. Die Ergebnisse dieser Arbeit zeigen, dass er zur Beschreibung von LAI in Beständen mit reifen Teilbereichen eingesetzt werden kann und somit gut zur Modellierung von nicht-grünem LAI geeignet ist. Zur Modellierung von Winterroggen wurde jedoch MTVI2 (HABOUDANE et al. 2002) verwendet, da dieser gute statistische Zusammenhänge zu LAI aufwies und gleichzeitig resistent gegenüber optisch auftretenden Fehlern reagierte. Dieser Index wurde auch von HABOUDANE et al. (2002) als besonders geeignet zur LAI Berechnung bewertet. Insgesamt stimmen die Berechnungen mit durchschnittlichen LAI-Werten überein. OEHMICHEN (2004) gibt für Getreide $LAI \leq 5$ an.

5.2.2 Chlorophyll

Der Chlorophyllgehalt gilt als guter Indikator von Pflanzenstress wegen seiner direkten Rolle in der Photosynthese. Schmale Wellenlängenbanden reagieren sensibel auf stressbedingte Abnahme der Chlorophyllkonzentrationen (z.B. PONTIUS et al. 2005). Die Beschreibung von Chlorophyll durch Vegetationsindizes und somit die Beschreibung durch Parametrisierung der spektralen Signatur, war jedoch nicht erfolgreich. Das spektrale Verhalten von Vegetation wird demzufolge überwiegend durch LAI und somit durch grüne Biomasse bestimmt. Dies beobachteten u.a. auch KNEUBÜHLER (2002) und ASNER (1998). Andere Studien zeigten enge Zusammenhänge zwischen biochemischen Parametern und LAI auf Blattebene (vgl. KNEUBÜHLER 2002), was hier auf Bestandesebene nicht bestätigt werden konnte.

Der Chlorophyllgehalt von Raps zeigt einen negativen Zusammenhang mit Vegetationsindizes. D.h. Chlorophyll nimmt mit zunehmender Blattmasse ab. Auf Bereichen mit niedrigen Indexwerten (weniger Pflanzenmasse) ist ein Rückstand in der Phänologie zu vermerken. Die Pflanzen in Bereichen mit hohem Indexwert standen bereits in Blüte, woraus sich der Abbau von Chlorophyll erklärt. Die hohen Indexwerte sind also nicht auf Pigmentzusammensetzung zurückzuführen sondern werden überwiegend durch grüne Biomasse bestimmt.

Gründe für geringe Zusammenhänge zwischen Vegetationsindizes und Blattchlorophyll des Winterweizens im frühen Phänologiestadium sind unter anderem in der geringen Wertespanne zu sehen. SPAD Werte variieren auf dieser Fläche nur zwischen 36 und 46, was die Irrtumswahrscheinlichkeit erhöht. Unterschiede in der Chlorophyllkonzentration zeigen sich in diesem Phänologiestadium noch nicht so deutlich, wie auf den anderen Untersuchungsflächen, bei denen bereits die reproduktive Phase eingesetzt hatte. SCHELLENBERG (1990) stellte bei seinen Untersuchungen an Winterweizen fest, dass die Blätter von Weizen schon in ihrer juvenilen Phase die endgültigen Chlorophyllgehalte aufweisen. Ein ähnliches Ergebnis zeigen die Zeitreihen in Kapitel 4.1. In der juvenilen Phase weisen die Messungen von Chlorophyll keine großen Unterschiede auf. Die Varianz nimmt erst im Reifestadium deutlich zu. Zusammenhänge zwischen LAI oder VIs und Chlorophyll sind daher nicht zu finden und Heterogenität innerhalb des Bestandes anhand von Chlorophyll nicht differenzierbar. Es zeigt sich, dass für frühe Phänologiestadien dieser empirische Modellansatz nicht geeignet ist. Hinzu kommt die zwar einfach im Gelände anwendbare Methode des SPAD-502 zur Messung von Blattchlorophyll, die in Abhängigkeit von der genauen Messtechnik jedoch hohe Unsicherheiten birgt.

In der Literatur werden häufig gute Zusammenhänge zwischen speziellen Indizes und Chlorophyll beschrieben. SIMS & GAMON (2002) zeigten hingegen, dass die bereitgestellten Indizes geringe Korrelation zu Blattchlorophyllgehalt aufweisen, wenn sie für verschiedene Pflanzenarten angewendet werden. Dennoch zeigten sich für Blattchlorophyll von Winterraps enge Zusammenhänge mit den Indizes MCARI (DAUGHTRY et al. 2000), VARI_{Green} (GITELSON et al. 2002), MCARI/MSAVI (verändert nach: HABOUDANE et al. 2002), die speziell zur Bestimmung von Blattchlorophyll entwickelt wurden.

5.2.3 Wuchshöhe

Die Wuchshöhe ließ sich sehr gut durch Vegetationsindizes beschreiben. Sie selbst hat keine spektralen Charakteristika. Die engen Zusammenhänge zu den übrigen Parametern LAI, Trockenbiomasse und Pflanzenwassergehalt zeigen jedoch, dass Wuchshöhe stark mit der Vitalität von Pflanzen in Verbindung steht. Die Hauptfaktoren für Pflanzenwachstum und Produktivität sind Stickstoff- und Wasserverfügbarkeit (SERRANO et al. 2000). Neben der Biomasse ist die Wuchshöhe bezeichnend für das

Pflanzenwachstum und steht damit eng mit den Standortbedingungen in Verbindung. Die genannten Parameter beschreiben hierbei das gleiche Phänomen. Die Wuchshöhe wird also nur indirekt vom optischen Sensor aufgenommen. Dennoch stellt sie hier einen besonders geeigneten Parameter zur Differenzierung von kleinräumiger Heterogenität dar. Die engen Zusammenhänge zu VIs und die Möglichkeit sehr einfache und genaue Feldmessungen durchzuführen, bieten ein gutes Potential, flächendeckende Informationen über den Zustand eines Bestandes zu erhalten. Die meisten der verwendeten Indizes zeigten dabei gute Sensibilität gegenüber der Wuchshöhe. Insbesondere für frühe Phänologiestadien und geringe Bedeckung zeigt die Wuchshöhe gute lineare Beziehungen zu VIs, wie die Ergebnisse für Winterweizen mit $R^2=0,84$ zeigen. Dies ist in Anbetracht ihrer geringen Differenzierung im frühen Stadium bei der Beobachtung anderer Getreidearten über die Vegetationsperiode (vgl. Kap. 4.1.) verwunderlich. Payero et al. (2004) stellten fest, dass die Wuchshöhe von Alfalfa besonders enge Beziehungen zu einer Reihe von VIs bei noch relativ geringem Wuchs, aufweisen. Der Einfluss der Bodenfeuchte, durch den höheren Anteil von Boden im Mischpixel könnte ein Erklärungsansatz hierfür sein, wie zu Beginn dieses Kapitel erläutert. Eine Aussage, welche Indizes geeignet sind um die Wuchshöhe zu bestimmen kann nicht getroffen werden und muss für jede Pflanzenart und jedes Stadium spezifisch bestimmt werden (Payero et al. 2004). Als problematisch bei Modellierung der Wuchshöhe stellten sich vegetationsfreie Bereiche dar, denen trotz fehlendem Bewuchs, geringe Wuchshöhen zugeordnet wurden.

5.3 KLASSIFIKATION VON PFLANZENWASSER

Räumliche Variabilität des Wasserhaushaltes eines Bestandes lässt sich vor allem in EWT erkennen. GCW betrachtet zwei voneinander unabhängige Pflanzenvariablen, EWT und Trockenbiomasse. Beide haben einen Einfluss auf die Reflektion des Bestandes (COLOMBO et al. 2008), wie auch starke Zusammenhänge zwischen der Trockenbiomasse und VIs zeigen. Der Zusammenhang zwischen EWT und spektralen Indizes war deutlich stärker, wie auch der zu anderen Vegetationsparametern. Indizes zur Beschreibung von Bedeckungsstruktur und *greenness* zeigten gute Zusammenhänge zu EWT. COLOMBO et al. 2008 fanden jedoch heraus, dass die Zusammenhänge zu diesen Indizes deutlich schwächer sind als zu Wasserindizes. Das Gegenteil stellten CHENG et al. (2008) für Trockengebiete fest und auch in den frühen Arbeiten von TUCKER (1977) konnte

Pflanzenwasser durch diese Wellenlängenbereiche beschrieben werden. CHENG et al. (2008) nennen als Grund die stärkere Absorption von Chlorophyll als von Wasser. Da Chlorophyll und EWT von der Blattfläche (LAI) abhängen, erklärt sich der gute Zusammenhang zwischen Pflanzenwasser und Struktur- oder *greenness*-Indizes. Für Winterraps und Winterweizen (Daten 2009) beschrieben die Indizes GI 2 (GITELSON et al. 2003) und SR (TUCKER 1979) EWT besonders gut, mit R^2 bis über 0,7. Diese Indizes zeigten auch für LAI die besten Zusammenhänge bei Winterraps und Winterweizen, was zeigt, wie eng LAI und EWT auch spektral voneinander abhängen. Dennoch sind Bereiche im kurzwelligen Infrarot (SWIR, 1,4 - 3 μm) weniger sensibel auf Pigmentkonzentrationen (CHENG et al. 2008), weshalb ein Vergleich mit Indizes aus Spektren im SWIR anzustreben ist. Indizes, die aus den schwächeren Wasserabsorptionsbanden um 970 nm gebildet werden zeigten keine Differenzierung für abbildende Spektraldaten. Dieser Wellenlängenbereich ist in den vorliegenden Daten nicht ausschließlich von Pflanzenwasser beeinflusst. Die geringe Sensibilität auf Pflanzenwasser kann durch Einflüsse der Atmosphäre und des Bodens bedingt sein. Andere Studien bestätigen diese Ergebnisse auf Blattebene (vgl. COLOMBO et al. 2008).

Die Ergebnisse der Regressionsanalysen für Pflanzenwasser zeigten, dass EWT aufgrund guter statistischer Zusammenhänge zu abbildenden Hyperspektraldaten und anderer Pflanzenzustandsgrößen ein geeigneter Parameter zur Differenzierung von Vegetationsstatus ist. Bei Kalibrierung eines empirischen Modells von EWT sind gute Ergebnisse zu erwarten. Da jedoch für die Fernerkundungsszenen von 2008 sehr wenig *groundtruth* zur Verfügung steht, wurde die Kartierung des Wasserstatus mittels Klassifikation getestet.

Die Ergebnisse der Klassifikation zeigen, dass die Methode zur Abbildung von Heterogenität innerhalb der landwirtschaftlichen Flächen anwendbar ist. Sie bietet die schnelle Möglichkeit zur thematischen Darstellung quantitativer Verteilung von Vegetationsparametern. Es zeigte sich jedoch auch, dass die Methode aufgrund des sehr kleinen Trainingsdatensatzes sehr anfällig auf die stochastische Natur von Messungen reagiert. Zum einen werden Trainingsdaten benötigt, die die gesamte Wertespanne innerhalb des untersuchten Bestandes wiedergeben, zum anderen spielen Messgenauigkeit, Lagegenauigkeit und abbildendes Spektrum, sowie externe Einflüsse eine große Rolle. Letztendlich ist die Wahl, bzw. die verfügbare Auswahl an Trainingsspektren entscheidend für das Klassifikationsergebnis. Es konnten zwar höhere Klassifikationsgenauigkeiten durch Neuronale Netze erreicht werden, jedoch ist dieses

Ergebnis stark an die geringe Auswahl an Trainings- und Testdaten gebunden. Um Ergebnisse zu erhalten, die auch für weitere Anwendungen verlässlich genug sind ist ein weitaus größerer Datensatz nötig. Auch ARORA & FOODY (1997) konnten NN als beste Klassifikationsmethode feststellen. Dabei nennen sie kleine Trainingsdatensets als Hauptproblem hohe Klassifikationsgenauigkeiten zu erzielen, eine höhere Anzahl an verwendeten Wellenlängen soll Klassifikationen mittels NN jedoch verbessern. Auch FOODY et al. (1995) ziehen NN anderen Methoden mit Diskrimantenanalyse bei kleinem Trainingsdatenumfang vor. Vor- und Nachteile von statistischen Klassifikationsmethoden und NN untersuchten u.a. BENEDIKTSON et al. (1990) und sehen dabei die Komplexität der NN-Methode als problematisch an. Dass die Klassifikationsalgorithmen nicht für die Anwendung mit einem Trainingsspektrum konzipiert sind, wird anhand der SVM deutlich. Die *hyperplane* wird durch *Support Vektoren* gespannt. Diese sind, die der Klassengrenze nächstgelegenen Trainingspektren. Die Geraden der *hyperplane* werden dabei, ähnlich der Methode der kleinsten Quadrate einer Regressionsschätzung, gespannt. Ist jedoch nur ein Trainingsspektrum pro Klasse vorhanden, werden die Diskrimantenfunktionen anhand nur zweier Punkte bestimmt, was der Bildung einer Regression mit zwei Stichproben gleicht und somit willkürliche Ergebnisse liefert.

Die Einteilung der Daten in Klassen erfolgt sehr subjektiv, was einen weiteren Nachteil der Methode darstellt. Der Umfang an *groundtruth* bestimmt Größe und Wertespanne einzelner Klassen.

Außerdem wurde deutlich, dass die Methode für Kulturen im juvenilen Stadium weniger geeignet ist, da die Varianz für Pflanzenwassergehalt aufgrund des allgemein sehr geringen Wachstums gering ist und sich eine exakte Zuordnung zu einer bestimmten Klasse daher schwierig gestaltet.

Die hohe Dimensionalität der Hyperspektraldaten ist in sofern problematisch für die Durchführung einer Klassifikation, als dass die implementierten Algorithmen keine Einblicke in den Umgang mit Diskrimantenfunktionen bzw. *hyperplanes* zulassen. Wie genau die Klasseneinteilung im hochdimensionalen Merkmalsraum stattfindet wird nicht erkennbar und kann somit nicht überprüft werden. Dies lässt insbesondere durch die Verwendung von nur einem Trainingsspektrum eine sehr hohe Irrtumswahrscheinlichkeit zu. Es ist anzunehmen, dass bessere Ergebnisse für künstliche Neuronale Netze, durch eine geringere Bandanzahl erreicht werden könnte. Dennoch zeigten ARORA & FOODY (1997), dass mehr Bänder die Genauigkeit der Ergebnisse von NN erhöhen.

In Anbetracht dessen wird der Vorteil der Klassifikation, auch mit geringem Stichprobenumfang durchführbar zu sein, entkräftet. Mit einem größeren Datenumfang bietet sich bereits wieder die Möglichkeit der empirischen Modellierung, die im Gegensatz zur Klassifikation eine Generierung quantitativer Werte der Parameter für jedes Pixel erlaubt.

5.4 VERGLEICH DES REGRESSIONS- UND KLASSIFIKATIONSANSATZES

Zur räumlichen Darstellung der Variabilität von Vegetationsparametern wurden zwei verschiedene Methoden angewandt: empirische Modelle und Klassifikation.

Die Gesamtgenauigkeit der Klassifikation verglichen mit entsprechend reklassifizierten Ergebnissen der empirischen Modelle für die Wuchshöhe, ließen keine eindeutigen Schlüsse zu. Klassifikation mit NN zeigte für Wintergerste eine sehr geringe Genauigkeit, für Winterraps hingegen ein sehr gutes Ergebnis. Die Genauigkeit der Modellierung lag bei beiden Pflanzenarten mit ca. 75% im Mittelfeld. Die relativ hohe Ungenauigkeit des empirischen Modells ergibt sich aus der Natur der Regressionsschätzung. Aufgrund der Abweichung der Residuen von der Schätzung werden Werte, die an Klassengrenzen liegen, unter- oder überberechnet und somit nach Reklassifikation der falschen Klasse zugeordnet. Die sehr unterschiedlichen Ergebnisse bei der Klassifikation verdeutlichen die starke Zufälligkeit bei Anwendung dieser Methode. Einzelne Spektren, die als Trainingspektren ausgewählt wurden sind verantwortlich für das Ergebnis und somit für Über- und Unterschätzung der Diskrimantenfunktionen bzw. der Klassengrenzen. Das Erklärt auch die Überschätzung der Wuchshöhe im Vergleich zum empirischen Modell.

Allgemein ist das empirische Modell der Klassifikation vorzuziehen. Im Gegensatz zur Klassifikation können absolute Werte für jedes Pixel ermittelt werden. Trotz der Hochskalierung auf die räumliche Auflösung der PLMR-Daten können durch Subpixelanalyse genauere Informationen bereitgestellt werden. Ein weiterer Nachteil der Klassifikation besteht in der subjektiven Klasseneinteilung. Das empirische Modell bezieht die gesamte *groundtruth* ein und wird durch eine kontinuierliche Schätzung gebildet, weshalb z.B. Überschneidungen an Klassengrenzen umgangen werden. Beide Methoden besitzen keine Allgemeingültigkeit und müssen für jeden Datensatz neu kalibriert werden, was einen deutlichen Nachteil darstellt.

5. Diskussion

ERASMI (2002) kritisiert die Übersättigung empirischer Modelle durch eine Überzahl von Wellenlängenkanälen im Vergleich zum Umfang an *groundtruth*. Dies wurde durch die Verwendung von Indizes umgangen. Die Problematik taucht jedoch durch nicht-merkmalsreduzierte Daten bei der Klassifikation wieder auf.

6 ZUSAMMENFASSUNG UND AUSBLICK

In der vorliegenden Arbeit wurde die Heterogenität der Vegetation auf drei landwirtschaftlichen Nutzflächen analysiert und einzelne Vegetationsmerkmale quantitativ und flächendeckend berechnet. Zur Differenzierung der Vegetationsparameter Blattflächenindex (LAI), Chlorophyll, Wuchshöhe und Pflanzenwasser wurden abbildende Hyperspektraldaten mit *groundtruth* validiert und ein empirischer Modellansatz und Klassifikation angewendet. Zwei Datensätze standen dabei zur Verfügung. Die erste Messkampagne wurde im Juni 2008 durchgeführt, als sich Wintergerste und Winterroggen auf den Untersuchungsflächen im Seneszenzstadium befanden. Im April 2009, während der zweiten Kampagne, waren die Flächen mit Winterraps bewirtschaftet, der sich zum Aufnahmezeitpunkt in der reproduktiven Phase befand. Auf einer weiteren Fläche wurde Winterweizen im vegetativen Stadium untersucht.

Vergleiche mit Bodenkarten und einem DGM verdeutlichten, dass die räumliche Variabilität der Vegetation vorwiegend boden- bzw. reliefbedingt ist. So zeigte sich die Vegetation auf sandigen Böden in Kuppenbereichen oder tonigen Senken aufgrund schlechter Bedingungen in Bezug auf die Wasserversorgung spärlich. Die Wasserversorgung gilt neben der Stickstoffverfügbarkeit als Hauptfaktor für Pflanzenstress. Informationen über kleinräumige Bodenmuster, die Heterogenität der Vegetation in den räumlich hochauflösenden Hyperspektraldaten erklären, konnten nur aus sehr großmaßstäbigen Karten gewonnen werden. Die Reichsbodenschätzung (1:1000 bis 1:2000) bildet hier eine geeignete Grundlage, existiert jedoch noch nicht in digitaler Form. Wasserstress zeigt sich bei seneszentem Getreide in sogenannter „Notreife“. Die Pflanzen dieser Bereiche trocknen schneller aus und weisen daher früher die typisch gelbe Färbung der Kornreife auf. Für Winterraps zeigt die Vegetation an schlechteren Standorten einen leichten Entwicklungsrückstand. Während andere Bereiche in Blüte standen hatte die reproduktive Phase in den spärlicheren Bereichen noch nicht eingesetzt. Die Heterogenität im juvenilen Winterweizenbestand zeigte sich in Wuchshöhe und Bedeckungsgrad.

Räumliche Variabilität aller vier Pflanzenarten kam vor allem in Wuchshöhe, LAI und Pflanzenwasser zum Ausdruck. Diese Merkmale sind gut miteinander korreliert und repräsentieren alle die Masse und den Zustand der Vegetation. Daher können diese

Parameter zur Analyse des Anteils der Vegetation an Mikrowellensignalen beitragen. Blattchlorophyll konnte hingegen erst nach Einsetzen der reproduktiven Phase differenziert werden. Im vegetativen Stadium zeigte Chlorophyll weder zu anderen Parametern, noch zu abbildenden Hyperspektraldaten statistische Zusammenhänge. Die Blattchlorophyllkonzentration blieb ab Beginn der vegetativen Phase relativ konstant und veränderte sich erst durch den Abbau bei einsetzender Blüte unterschiedlich stark. Bei Betrachtung von räumlicher Variabilität ist somit auch immer die phänologische Entwicklung der betrachteten Pflanzenarten zu berücksichtigen.

Auch nach Einsetzen der Blüte bestimmte Chlorophyll nicht das spektrale Signal der Vegetationsdecke, wie anhand des Winterrapsbestandes deutlich wurde. Chlorophyll wies einen negativen Zusammenhang zu spektralen Vegetationsindizes auf, d.h. hohe Chlorophyllkonzentrationen waren nicht verantwortlich für hohe Indexwerte. Pigmente treten also im spektralen Signal hinter strukturellen Merkmalen zurück. Die Parameter LAI, Wuchshöhe und Pflanzenwasser ließen sich hingegen gut durch Spektralindizes beschreiben. Besonders gute Ergebnisse wurden hierbei in frühen Vegetationsstadien mit geringer Bedeckung erzielt. Hierbei spielt der Effekt unterschiedlicher Bodenfeuchte eine entscheidende Rolle. Gut wasserversorgte Bereiche wiesen hohe Indexwerte durch Bodenfarbe und grüne Pflanzenmasse auf, was den Zusammenhang mit den Parametern beeinflussen könnte. Es zeigte sich außerdem, dass Parameter, die die Landbedeckung repräsentieren, besser durch Fernerkundungsdaten erfassbar sind als Parameter auf Pflanzen- oder Blattebene. Fernerkundungsdaten nehmen die Landoberfläche als Mischpixel auf, in denen die Signale ganzer Pflanzen, des Bodens und Schatteneffekte vereint sind. So konnte der Bestandswassergehalt (EWT, kg/m²) aus den abbildenden Hyperspektraldaten differenziert werden, während Pflanzenwassergehalt (GWC, %) weniger gut abgebildet wurde.

Besonders gute lineare Zusammenhänge mit LAI für dichte bis spärliche Vegetation zeigte GI2 (GITELSON et al. 2003). Dieser Index wird aus der Reflektion grüner Wellenlängenbereiche und des NIR gebildet um einer Sättigung der Absorption roter Wellenlängenbereiche bei hohem LAI entgegenzuwirken. Für seneszenten Getreide wurden gute Ergebnisse mit PSRI erzielt, einem Index, der sensibel auf Carotinoide reagiert. Auch Pflanzenwasser (EWT) wurde gut von GI2 abgebildet. Es zeigte sich, dass eine Differenzierung von Pflanzenwasser auch durch *greenness*-Indizes (gebildet aus VIS und NIR) möglich ist und nicht unbedingt Wasserabsorptionsbanden im kurzwelligen Infrarot (SWIR) benötigt werden. Obwohl Chlorophyll keine dominanten Einflüsse auf das

Spektralsignal hatte, wurde es durch einige Indizes gut beschrieben, die zur Bestimmung von Chlorophyll konzipiert wurden (MCARI: DAUGHTRY et al. 2000, $VARI_{green}$: GITELSON et al. 2002, MCARI/MSAVI: verändert nach HABOUDANE et al. 2002). Zur Herleitung der Wuchshöhe konnte kein bestimmter Vegetationsindex ausgemacht werden, insgesamt waren jedoch gute Korrelationen zu finden. Die Auswahl eines geeigneten Index ist stark von Pflanzenart und Phänologiestadium abhängig.

Zusammenfassend kann festgehalten werden, dass hyperspektrale Vegetationsindizes die einzelnen Vegetationsparameter gut beschrieben und eine empirische Modellierung trotz geringen *groundtruth*-Umfangs gute Ergebnisse lieferte. Dennoch könnte durch Erhöhung des Stichprobenumfangs die Stabilität der Modelle verbessert werden. Es konnte keine Allgemeingültigkeit in Bezug auf geeignete Spektralindizes gefunden werden. Die Modelle sind stark abhängig von Pflanzenart, Phänologie und Sensoreigenschaften und jeweils datenspezifisch aufzustellen. Der Klassifikationsansatz eignete sich nicht zur Gewinnung quantitativer Informationen einzelner Vegetationsparameter. Die Methode ist sehr stark abhängig von einzelnen Trainingsspektren. Die empirische Modellierung ist der Klassifikation vorzuziehen, auch wenn bei der Klassifikation durch Erhöhung des Stichprobenumfangs ebenfalls bessere Ergebnisse zu erwarten sind.

Die gewonnenen Karten von Vegetationsparametern verdeutlichen die starke Variabilität innerhalb einzelner Schläge und die Notwendigkeit der schlagspezifischen Differenzierung von Vegetation, um räumlich geringer aufgelöste Mikrowellendaten interpretieren zu können. Eine geeignete Methode zur flächenhaften Herleitung von biophysikalischen Vegetationsparametern stellt die empirische Modellierung dar.

Für weitere Arbeiten sollte ein großes Augenmerk auf die Erhebung von *groundtruth* gelegt werden. Ein größerer Datenumfang bedarf eines großen Aufwandes an Arbeitskräften, könnte jedoch die Stabilität empirischer Modelle deutlich erhöhen und den Einfluss zufälliger Mess- und Lageungenauigkeiten ausgleichen. Von Bedeutung ist auch eine möglichst breite Varianz innerhalb der Daten, um alle Situationen auf den Untersuchungsflächen zu erfassen.

Der Vergleich von abbildenden Hyperspektraldaten mit Feldspektrometerdaten zeigte, dass Vegetationsindizes unterschiedlich auf Atmosphäreneinflüsse reagieren. Für ein besseres Signalverständnis und den Ausschluss von Einflüssen der Atmosphäre, wäre ein Vergleich mit atmosphärenkorrigierten Daten erstrebenswert. Auch die Aufnahme von

Vegetation in höheren Wellenlängenbereichen des Infraroten könnte zur Interpretierbarkeit der Daten in Bezug auf Wassergehalt von Pflanzen, Boden und Atmosphäre beitragen. Ein solcher Sensor (AISA-Hawk) wird gerade am UFZ in Betrieb genommen und wird bei zukünftigen Befliegungen zum Einsatz kommen. Um den Einfluss von Chlorophyll auf das spektrale Signal besser einschätzen zu können sollte nach einer Messmethode gesucht werden, die Chlorophyll auf Bestandesebene und somit der Ebene von Fernerkundungsdaten darstellt.

LITERATURVERZEICHNIS

- AG BODEN (2005): Bodenkundliche Kartieranleitung. 5. Auflage. Hannover.
- ALBERS, S., D. KLAPPER, U. KONRADT, A. WALTER & J. WOLF (Hg.) (2009): Ergänzungen zur Methodik der empirischen Forschung. Christian-Albrechts-Universität zu Kiel.
- ANDERSON, M. C., C. M. U. NEALE, F. LI, J. M. NORMAN, W. P. KUSTAS, H. JAYANTHI & J. CHAVEZ (2004): Upscaling ground observations of vegetation water content, canopy height, and leaf area index during SMEX02 using aircraft and Landsat imagery. *Remote Sensing of the Environment*, 92, 447–464.
- ARNOFF, S. (1982): Classification accuracy: A user approach. *Photogrammetric Engineering and Remote Sensing*, 48(8), 1299–1307.
- ARORA, M. K. & G. M. FOODY (1997): Log-linear modeling for the evaluation of the variables affecting the accuracy of probabilistic, fuzzy and neural network classifications. *International Journal of Remote Sensing*, 18, 785–798.
- STAATSBETRIEB GEOBASISINFORMATION UND VERMESSUNG SACHSEN (2008): ATKIS DGM25. Digitales Geländemodell 20x20 m.
- BACKHAUS, K., B. ERICHSON W. PLINKE & R. WEIBER (2006): *Multivariate Analysemethoden. Eine anwendungsorientierte Einführung*. 11. überarb. Aufl., Berlin, Springer.
- BANKO, G. (1998): A review of assessing the accuracy of classifications of remotely sensed data and methods including remote sensing in forest inventory. Interim Report November 1998, International Institute for Applied System Analysis. <http://www.iiasa.ac.at/Admin/PUB/Documents/IR-98-081.pdf>, 23.10.2009.
- BARET, F. & GUYOT G. (1991): Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of the Environment*, 35, 161–173.
- BENEDIKTSSON, J. A., P. H. SWAIN & O. K. ERSOY (1990): Neural network approaches versus statistical methods in classification of multisource remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4), 540–552.
- BLASCHKE, T., S. LANG & G. J. HAY (Hg.) (2008): *Object-based image analysis. Spatial concepts for knowledge-driven remote sensing applications*. Berlin, Springer.
- BROGE, N. H. & LEBLANC E. (2000): Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of the Environment*, 76, 156–172.
- BURKE, E. J., W. J. SHUTTLEWORTH & A. N. FRENCH (2001): Using vegetation indices for soil-moisture retrievals from passive microwave radiometry. *Hydrology and Earth System Sciences*, 5(4), 671–677.
- CANTY, M. J. (1999): *Fernerkundung mit neuronalen Netzen: Theorie-Algorithmen-Programme*. Renningen Malsheim, Expert-Verlag.

- CAPELLE, A. (1999): Die Eignung von Bodenkarten unterschiedlicher Maßstäbe für die Erfassung der kleinräumigen Heterogenität des Bodens. In: Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hg.): Erfassung der kleinräumigen Heterogenität. KTBL/ ATB - Workshop vom 15. bis 16. Januar 1998 in Potsdam, 43–46.
- CHENG, Y. –B, S. L. USTIN, D. RIAÑO & V. C. VANDERBILT (2008): Water content estimation from hyperspectral images and MODIS indexes in Southeastern Arizona. *Remote Sensing of the Environment*, 112, 363–374.
- CLEVERS, J. G. P. W. (1986): Application of remote sensing to agricultural field trials. Agricultural University, Wageningen, Niederlande.
- COLOMBO, R., M. MERONI, A. MARCHESI, L. Busetto, M. ROSSINI, C. GIARDINO & C. PANIGADA (2008): Estimation of leaf and canopy water content in poplar plantations by means of hyperspectral indices and inverse modeling. *Remote Sensing of the Environment*, 112, 1820–1834.
- CONGALTON, R. G. (1991): A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of the Environment*, 37, 35–46.
- DARVISHZADEH, R., A. SKIDMORE, M. SCHLERF, C. ATZBERGER, F. CORSI & M. CHO (2008): Estimation of leaf area index and chlorophyll for a mediterranean grassland using hyperspectral data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVII, Part B7, 471–478.
- DARVISHZADEH, R., C. ATZBERGER & A. K. SKIDMORE (2006): Hyperspectral vegetation indices for estimation of leaf area index. ISPRS Commission VII Mid-term Symposium "Remote Sensing: From Pixels to Processes", Enschede, Netherlands, 8-11 May 2006, 391–396.
- DAUGHTRY, C. S. T., C. L. WALTHALL, M. S. KIM, E. BROWN DE COLSTOUN & J. E. McMURTREY III (2000): Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sensing of the Environment*, 74, 229–239.
- DEUTSCHER WETTERDIENST (DWD) (2009): Aktueller Stand der Phänologie in Deutschland.
http://www.dwd.de/bvbw/appmanager/bvbw/dwdwwwDesktop;jsessionid=nJKrKhFcxVvJKtnC3GGDSSRQITQblDr40WFZv3pmWkPX6YT6cLBx!2826550!1767168939?_nfpb=true&_windowLabel=T94008&_state=maximized&_pageLabel=_dwdwww_klima_umweIt_phaenologie, zuletzt aktualisiert am 15.10.2009, 27.10.2009.
- ERASMI, S. (2002): Analyse spektroradiometrischer in situ Messungen als Datenquelle für die teilflächenspezifische Zustandsbeschreibung von Winterweizenbeständen. Dissertation, Göttingen.
- FOODY, G. M. & MATHUR A. (2004): Toward intelligent training of supervised image classifications: Directing training data acquisition for SVM. *Remote Sensing of the Environment*, 93, 107–117.
- GITELSON, A. & MERZLYAK M. (1994): Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll Estimation. *Journal of Plant Physiology*, 143, 286–292.

- GITELSON, A. & MERZLYAK M. (1996): Signature analysis of leaf reflectance spectra: Algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*, 148, 494–500.
- GITELSON, A. A., Y. J. KAUFMAN, R. STARK & D. RUNDQUIST (2002): Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of the Environment*, 80, 76–87.
- GITELSON, A. A., A. VIÑA, T. J. ARKEBAUER, D. C. RUNDQUIST, G. KEYDAN & B. LEAVITT (2003): Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical Research Letters*, 30(5), 52-1-52-4.
- GOERKE, B. (2009): Ausreißerwerte. In: Albers, S., D. Klapper, U. Konradt, A. Walter & J. Wolf (Hg.): *Ergänzungen zur Methodik der empirischen Forschung*. Christian-Albrechts-Universität zu Kiel, 1–19. <http://www.bwl.uni-kiel.de/bwlinstitute/gradkolleg/new/index.php?L=1&id=267>, 21.10.2009
- HABOUDANE, D., J. R. MILLER, E. PATTEY, P. J. ZARCO-TEJADA & I. B. STRACHAN (2004): Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of the Environment*, 90, 337–352.
- HABOUDANE, D., J. R. MILLER, N. TREMBLAY, P. J. ZARCO-TEJADA & L. DEXTRAZE (2002): Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of the Environment*, 81, 416–426.
- HUANG, C., L. S. DAVIS & J. R. G. TOWNSHEND (2002): An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725–749.
- HUETE, A. R. (1988): A soil-adjusted vegetation index (SAVI). *Remote Sensing of the Environment*, 25, 295–309.
- HUETE, A. R., H. Q. LIU, K. BATCHILY & W. VAN LEEUWEN (1997): A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of the Environment*, 59(3), 440–451.
- ITT VISUAL INFORMATION SOLUTIONS (2009): *ENVI User's Guide*, Vers. 4.7.
- JACKSON, R. D. & HUETE A. R. (1991): Interpreting vegetation indices. *Preventive Veterinary Medicine*, 11, 185–200.
- JACQUEMOUD, S., W. VERHOEF, F. BARET, C. BACOUR, P. J. ZARCO-TEJADA, G. P. ASNER, C. FRANÇOIS & S. L. USTIN (2009): PROSPECT+SAIL models: A review of use for vegetation characterization. *Remote Sensing of the Environment*, 113, Supplement 1, 56–66.
- JANN, B. (2009): Diagnostik von Regressionsschätzungen bei kleinen Stichproben (mit einem Exkurs zu logistischer Regression). In: Kriwy, P. & C. Gross (Hg.): *Klein aber fein! Quantitative empirische Sozialforschung mit kleinen Fallzahlen*. Wiesbaden, VS, Verl. für Sozialwiss., 93–125.
- JENSEN, J. R. (2000): *Remote Sensing of the Environment. An Earth Resource Perspective*. Upper Saddle River, NJ, Prentice-Hall.

- JÜRSCHIK, P. (1999): Grundlagen der Anwendung von Fernerkundungsmethoden für die teilflächenspezifische Bewirtschaftung. In: Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hg.): Erfassung der kleinräumigen Heterogenität. KTBL/ ATB - Workshop vom 15. bis 16. Januar 1998 in Potsdam, 82–92.
- KAMAGATA, N., K. HARA, M. MORI, Y. AKAMATSU, Y. LI & Y. HOSHINO (2008): Object-based classification of IKONOS data for vegetation mapping in Central Japan. In: Blaschke, T., S. Lang & G. J. Hay (Hg.): Object-based image analysis. Spatial concepts for knowledge-driven remote sensing applications. Berlin, Springer .
- KIM, M. S., C. S. T. DAUGHTRY, E. W. CHAPPELLE, J. E. MCMURTREY III & C. L. WALTHALL (1994): The use of high spectral resolution bands for estimating absorbed photosynthetically active radiation (Apar). Proceedings of the 6th Symposium on Physical Measurements and Signatures in Remote Sensing, January 17-21, 1994, Val D`Isere, France, 299–306.
- KLISCH, A. (2003): Ableitung von Blattflächenindex und Bedeckungsgrad aus Fernerkundungsdaten für das Erosionsmodell EROSION 3D. Dissertation, Mathematisch-Naturwissenschaftliche Fakultät der Universität Potsdam.
- KNEUBÜHLER, M. (2002): Spectral assessment of crop phenology based on spring wheat and winter barley. Remote Sensing Series, 38. Dissertation, Zürich.
- KRIWY, P. & GROSS C. (Hg.) (2009): Klein aber fein! Quantitative empirische Sozialforschung mit kleinen Fallzahlen. Wiesbaden, VS, Verl. für Sozialwiss.
- KRUPINSKA, K. (2007): Auch sie haben kein ewiges Leben: Altern und Alter bei Pflanzen. Biologie in unserer Zeit, 37(3), 174–182.
- KRUSE, F. A., A. B. LEFKOFF, J. W. BOARDMAN, K. B. HEIDEBRECHT, A. T. SHAPIRO, P. J. BARLOON & A. F. H. GOETZ (1993): The Spectral Image Processing System (SIPS)-Interactive visualization and analysis of imaging spectrometer data. Remote Sensing of the Environment, 44, 145–163.
- KURATORIUM FÜR TECHNIK UND BAUWESEN IN DER LANDWIRTSCHAFT E.V. (Hg.) (1999): Erfassung der kleinräumigen Heterogenität. KTBL/ ATB - Workshop vom 15. bis 16. Januar 1998 in Potsdam.
- LARCHER, W. (2001): Ökophysiologie der Pflanzen. Stuttgart, Ulmer.
- LIANG, S. (2007): Recent developments in estimating land surface biogeophysical variables from optical remote sensing. Progress in Physical Geography, 31(5), 501–516.
- MANNFELD, K. & RICHTER H. (1995): Naturräume in Sachsen. Trier, Zentralausschuß für deutsche Landeskunde. Forschungen zur deutschen Landeskunde, 238.
- MEIER, U. (Hg.) (2001): Entwicklungsstadien mono- und dikotiler Pflanzen. Die erweiterte BBCH Monographie. 2. Auflage: Biologische Bundesanstalt für Land- und Forstwirtschaft.
- MELGANI, F. & BRUZZONE L. (2004): Classification of hyperspectral remote sensing images with support vector machines. IEEE Transactions on Geoscience and Remote Sensing, 42(8), 1778–1790.

- MERONI, M., R. COLOMBO & C. PANIGADA (2004): Inversion of a radiative transfer model with hyperspectral observations for LAI mapping in poplar plantations. *Remote Sensing of the Environment*, 92, 195–206.
- MERZLYAK, J. R., A. A. GITELSON, O. B. CHIVKUNOVA & V. Y. RAKITIN (1999): Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia Plantarum*, 106, 135–141.
- STAATSBETRIEB GEOBASISINFORMATION UND VERMESSUNG SACHSEN (1980): *Mittellmaßstäbige landwirtschaftliche Standortkartierung 1:100.000*. Dresden.
- OEHMICHEN, G. (2004): *Auf Satellitendaten basierende Ableitungen von Parametern zur Beschreibung terrestrischer Ökosysteme. Methodische Untersuchungen zur Ableitung der Chlorophyll(a+b)-Konzentration und des Blattflächenindex aus Fernerkundungsdaten*. Dissertation, TU Berlin.
- ONKEN, B. & REARDON R. (Hg.) (2005): *Third Symposium on Hemlock Woolly Adelgid in the Eastern United States*. Aheville, North Carolina February 1-2, 2005.
- PAYERO, J. O., C. M. U. NEALE & J. L. WRIGHT (2004): Comparison of Eleven Vegetation Indices for Estimating Plant Height of Alfalfa and Grass. *Applied Engineering in Agriculture*, 20(3), 385–393.
- PEÑUELAS, J., I. FILELLA, C. BIEL, L. SERRANO & R. SAVÉ (1993): The reflectance at the 950-970 nm region as an indicator of plant water status. *International Journal of Remote Sensing*, 14(10), 1887–1905.
- PONTIUS, J., M. MARTIN, L. PLOURDE & R. HALLETT (2005): Using hyperspektral technologies to map hemlock decline: Pre-visual decline assessment for early infestation detection. Onken, B. & Reardon R. (Hg.): *Third Symposium on Hemlock Woolly Adelgid in the Eastern United States*. Aheville, North Carolina February 1-2, 2005, 73–86.
- QI, J., A. CHEHBOUNI, A. R. HEUTE, Y. H. KERR & S. SOROOSHIAN (1994): A Modified Soil Adjusted Vegetation Index. *Remote Sensing of the Environment*, 48, 119–126.
- FINANZAMT GRIMMA (1940): *Reichsbodenschätzung 1:1.000 und 1:2.000*.
- REINARTZ, P. (1989): *Untersuchungen zur multispektralen Klassifizierung von schwer trennbaren Klassen mit Beispielen aus Waldschadensgebieten*. Forschungsbericht, DLR-Deutsche Forschungsanstalt für Luft- und Raumfahrt. Köln, Wiss. Berichtswesen des DLR.
- RICHARDS, J. A. & X. JIA (2006): *Remote Sensing Digital Image Analysis*. 4. Aufl., Berlin, Heidelberg, Springer.
- RICHARDSON, A. J. & WIEGAND C. L. (1977): Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*, 43, 1541–1552.
- RIES, C. H. KAGER & P. STADLER (2002): *GPS/IMU-unterstützte Georeferenzierung der Daten flugzeuggetragener multispektraler Scanner*. Institut für Photogrammetrie und Fernerkundung, TU Wien. http://www.ipf.tuwien.ac.at/publications/DGPF2002_Ries-Kager-Stadler.pdf. 23.10.2009.

- RONDEAUX, G., M. STEVEN & F. BARET (1996): Optimisation of soil-adjusted vegetation indices. *Remote Sensing of the Environment*, 55, 95–107.
- ROUJEAN, J. -L & BREON F. -M (1995): Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of the Environment*, 51, 375–384.
- SHELLENBERG, J. (1990): Die spektrale Reflexion von Weizen - ein Beitrag zur Zustandsbeschreibung landwirtschaftlicher Kulturpflanzenbestände durch Fernerkundung. Dissertation, Rheinische Friedrichs-Wilhelms-Universität, Bonn.
- SCHRÖDER, D. (1999): Strategien zur Erfassung der kleinräumigen Heterogenität. In: Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hg.): Erfassung der kleinräumigen Heterogenität. KTBL/ ATB - Workshop vom 15. bis 16. Januar 1998 in Potsdam, 47–52.
- SCHUMACHER, H. (1991): Untersuchungen zur überwachten Klassifikation von Fernerkundungsaufnahmen. Dissertation, Hannover, Wissenschaftliche Arbeiten der Fachrichtung Vermessungswesen der Universität Hannover Nr. 196.
- SERRANO, L., I. FILELLA & J. PEÑUELAS (2000): Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. *Crop Science*, 40, 723–731.
- SIMS, D. A. & GAMON J. A. (2002): Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of the Environment*, 81, 337–354.
- TUCKER, C. J. (1977): Spectral estimation of grass canopy variables. *Remote Sensing of the Environment*, 6, 11–26.
- TUCKER, C. J. (1979): Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of the Environment*, 8, 127–150.
- VINCINI, M., E. FRAZZI & P. D'ALESSIO (2008): A broad-band leaf chlorophyll vegetation index at the canopy scale. *Precision Agriculture*, 9, 303–319.
- VOß, K. (2005): Beitrag zur skalenabhängigen Erfassung teilschlagspezifischer Pflanzenschäden mit Methoden der Fernerkundung und Geoinformation. Dissertation, Rheinische Friedrich-Wilhelms-Universität Bonn.
- WALBURG, G., M. E. BAUER & C. S. T. DAUGHTRY (1981): Effects of Nitrogen Nutrition on the Growth, Yield and Reflectance Characteristics of Corn Canopies. Technical Report., Purdue University. Laboratory for Applications of Remote Sensing. West Lafayette, Indiana.
<http://docs.lib.purdue.edu/cgi/viewcontent.cgi?article=1021&context=larstech>, 18.10.2009.
- WALTHALL, C., W. DULANEY, M. ANDERSON, J. NORMAN, H. FANG & S. LIANG (2004): A comparison of empirical and neural network approaches for estimating corn and soybean leaf area index from Landsat ETM+ imagery. *Remote Sensing of the Environment*, 92, 465–474.
- WASKE, B. (2007): Classifying multisensor remote sensing data: Concepts, Algorithms and Applications. Dissertation, Rheinische Friedrich-Wilhelms-Universität Bonn.

WIEGAND, C. L. A. H. GERBERMANN K. P. GALLO B. L. BLAD & D. DUSEK (1990): Multisite analyses of spectral biophysical data for corn. *Remote Sensing of the Environment*, 33, 1–16.

ANHANG

Anhang

Anhang 1: Zusammenstellung der verwendeten Vegetationsindizes. Zur Berechnung wurden folgende Wellenlängen verwendet: GREEN: 550, RED: 670, Rededge: 700, NIR: 800, BLUE: 450

Index	Konzept	Formel	Referenzen
CI bzw. RNDVI	Rededge NDVI: Verwendet enge Bänder entlang der Rededge, ist daher besonders sensibel auf Änderungen der Bedeckung und Seneszenz	$= \frac{R_{750} - R_{705}}{R_{750} + R_{705}}$	GITELSON & MERZLYAK (1994) SIMS & GAMON (2002)
CVI	Chlorophyll VI: Ratio mit Grün zur Pigmentbestimmung	$= \frac{R_{NIR}}{R_{GREEN}} \cdot \frac{R_{RED}}{R_{GREEN}}$	VINCINI et al. (2008)
DVI	Difference Vegetation Index: Relativ gut bei geringem LAI; reagiert sensibel auf Boden, wenn LAI steigt	$= R_{NIR} - R_{RED}$	BROGE & LEBLANC (2000)
EVI	Enhanced Vegetation Index: Blaue Reflektanz zur Korrektur von Bodensignal und Minimierung atmosphärischer Einflüsse; gegen Sättigung bei hohem LAI	$= 2,5(R_{NIR} - R_{RED} / R_{NIR} + 6 \cdot R_{RED} - R_{BLUE} + 1)$	HUETE et al. (1997)
GI 1 (2003)	Es wird kein Rot verwendet, um Sättigung bei hoher Bedeckung zu entgehen; zur Bestimmung der gesamten Blattpigmentkonzentration, d.h. LAI	$= (R_{NIR} / R_{REDEGE}) - 1$	GITELSON et al. (2003)
GI 1* (1996)	Sensibel auf Chlorophyll; Verwendung eines sensibel auf Chlorophyll reagierenden Wellenlängenbereichs und eines Referenzbands	$= (R_{REDEGE} / R_{GREEN}) - 1$	GITELSON & MERZLYAK (1996)
GI 2 (2003)	Es wird kein Rot verwendet, um Sättigung zu entgehen Zur Bestimmung der gesamten Blattpigmentkonzentration, d.h. LAI	$= (R_{NIR} / R_{GREEN}) - 1$	GITELSON et al. (2003) WALTHALL et al. (2004)
GI 2* (1996)	Siehe GI 1* (1996)	$= (R_{RED} / R_{GREEN}) - 1$	GITELSON & MERZLYAK (1996)

MCARI	Modified Chlorophyll Absorption Index: Für Chlorophyll konzipiert, zeigt jedoch auch Potential zur LAI Bestimmung	$= [(R_{REDEGE} - R_{RED}) - 0,2(R_{REDEGE} - R_{GREEN})] (R_{REDEGE} / R_{RED})$	DAUGHTRY et al. (2000)
MCARI / MSAVI	Siehe TCARI/OSAVI		geänder t aus: HABOUDANE et al. (2002)
MCARI / OSAVI	Siehe TCARI/OSAVI		geänder t aus: HABOUDANE et al. (2002)
MCARI 1 / MSAVI	Siehe TCARI/OSAVI		geänder t aus: HABOUDANE et al. (2002)
MCARI 1 / OSAVI	Siehe TCARI/OSAVI		geänder t aus: HABOUDANE et al. (2002)
MCARI 2 / MSAVI	Siehe TCARI/OSAVI		geänder t aus: HABOUDANE et al. (2002)
MCARI 2 / OSAVI	Siehe TCARI/OSAVI		geänder t aus: HABOUDANE et al. (2002)
MCARI1	Siehe MCARI 2	$= 1,2[2,5(R_{NIR} - R_{RED}) - 1,3(R_{NIR} - R_{550})]$	HABOUDANE et al. (2004)
MCARI2	Modified Chlorophyll Absorption Index 2: Geringe Sensitivität auf Chlorophyll, mehr auf LAI durch unterdrücken von Rededge/Red und einfügen von NIR, resistenter gegenüber Boden- und Atmosphäreneinflüssen, aus MCARI abgeleitet	$\frac{1,5[2,5(R_{NIR} - R_{RED}) - 1,3(R_{NIR} - R_{GREEN})]}{\sqrt{(2R_{NIR} + 1)^2 - (6R_{NIR} - 5\sqrt{R_{RED}})} - 0,5}$	HABOUDANE et al. (2004)
MSAVI	Modified Soil Adjusted VI: Reduzierung von Bodensignal, linearer Zusammenhang zu LAI	$= \frac{1}{2} \left[2 \cdot R_{NIR} + 1 - \sqrt{(2 \cdot R_{NIR} + 1)^2 - 8(R_{NIR} - R_{RED})} \right]$	Qi et al. (1994) BROGE & LEBLANC (2000) HABOUDANE et al. (2004)

Anhang

MSR	Modified Simple Ratio: Zur Verbesserung der lineareren Abhängigkeit zu Vegetationsparametern, aus SR und RDVI abgeleitet	$= \left(\frac{R_{NIR}}{R_{RED}} - 1 \right) / \sqrt{\left(\frac{R_{NIR}}{R_{RED}} + 1 \right)}$	HABOUDANE et al. (2004)
MTVI1	siehe MTVI 2	$= 1,2[1,2(R_{NIR} - R_{GREEN}) - 2,5(R_{RED} - R_{GREEN})]$	HABOUDANE et al. (2004)
MTVI2	Modified Triangular VI 2: Geringere Sensitivität auf Chlorophyll, mehr auf LAI durch unterdrücken von Rededge/Red und einfügen von NIR, resistenter gegenüber Boden- und Atmosphäreneinflüssen	$= \frac{1,5[1,2(R_{NIR} - R_{GREEN}) - 2,5(R_{RED} - R_{GREEN})]}{\sqrt{(2 \cdot R_{NIR} + 1)^2 - (6 \cdot R_{NIR} - 5 \cdot \sqrt{R_{RED}} - 0,5)}}$	HABOUDANE et al. (2004)
NDVI	Normalized Difference VI: Normalisierte Differenz aus höchstem Reflektions- und Absorptionspunkt von Chlorophyll	$= \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$	TUCKER (1979)
OSAVI	Optimized Soil Adjusted VI: Reduzierung des Bodeneinflusses besonders bei homogener Bedeckung	$= \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED} + L} (1 + L)$	RONDEAUX et al. (1996) ANDERSON et al. (2004)
L: Wert für Boden, 0,6 für homogene Bedeckung, wie Anbaufrüchte			
PSRI	Plant Senescence Reflectance Index: Sensitivität gegenüber Carotinoiden, zur Detektion von Stress, Seneszens- und Reifestadium.	$= \frac{R_{RED} - R_{500}}{R_{750}}$	MERZLYAK et al. (1999)
RDVI	Renormalized Difference Vegetation Index: Hybrid Index, der die Vorteile von NDVI und DVI vereint, zur Verwendung bei hohem und geringem Bedeckungsgrad	$= \frac{R_{NIR} - R_{RED}}{\sqrt{(R_{NIR} + R_{RED})}}$	ROUJEAN & BREON (1995) BROGE & LEBLANC (2000)

REIP	Bestimmung grüner Vegetation aus Rededge inflection point	$R_{REDEGE} = (R_{670} - R_{780})/2$ $REIP = 700 + 40[R_{REDEGE} - R_{700}/R_{740} - R_{700}]$	DARVISHZADEH et al. (2008)
SAVI	Soil Adjusted VI: Reduzierung des Bodeneinflusses durch Bezug zu einer "soil-line"	$= \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED} + L} (1 + L)$ <p>L : Wert für Boden, muss bekannt sein, L=0,5 für eine breites Feld an Bedingungen</p>	HUETE (1988)
SIPI	Structure Insensitive Pigment Index: Sensibel auf Carotenoide, unsensibel auf Struktur; zeigt Stress an	$= \frac{R_{NIR} - R_{BLUE}}{R_{NIR} - R_{RED}}$	PEÑUELAS et al. (1995)
SR	Simple Ratio: Verhältnis aus höchstem Reflektions- und Absorptionspunkt von Chlorophyll	$= \frac{R_{NIR}}{R_{RED}}$	TUCKER (1979)
TCARI / OSAVI	Kombiniert Vorteile zweier Indizes: Sensibel auf Chlorophyll; Resistent gegenüber Boden und nicht-photosynthetischem Material	$= \frac{3[(R_{REDEGE} - R_{RED}) - 0,2(R_{REDEGE} - R_{GREEN})(R_{REDEGE} / R_{RED})]}{[(1 + 1,16)(R_{NIR} - R_{RED}) / (R_{NIR} + R_{RED} + 0,16)]}$	HABOUDANE et al. (2002)
TVI (transformed)	Transformed VI: Entwickelt aus NDVI um negative Werte zu umgehen	$= \sqrt{\frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}} + 0,5$	TUCKER (1979)

Anhang

TVI (triangular)	<p>Triangular VI:</p> <p>Bestimmt das Dreieck zwischen grüner, roter und NIR Reflektanz,</p> <p>Sensibel auf Chlorophyll</p>	$= 0,5[120(R_{750} - R_{GREEN}) - 200(R_{RED} - R_{GREEN})]$	<p>BROGE & LEBLANC (2000)</p> <p>HABOUDANE ET AL. (2004)</p>
VARIGreen	<p>Visible Atmospherically Resistant Index:</p> <p>Durch Verwendung sichtbarer Wellenlängenbereiche geringerer Kontrast der Reflektion, was Sensibilität bei mittlerer bis hoher Bedeckung erhöht; Abgeleitet aus ARVI (Atmospherically Resistant VI) und Wellenlängen sensibel auf „vegetation fraction“</p>	$= \frac{R_{GREEN} - R_{RED}}{R_{GREEN} + R_{RED} - R_{BLUE}}$	<p>GITELSON et al. (2002)</p> <p>GITELSON et al. (2003)</p>
VARirededge	<p>Visible Atmospherically Resistant Index:</p> <p>Siehe VARIGreen</p>	$= \frac{R_{REDEGE} - 1,7 \cdot R_{RED} - 0,7 \cdot R_{BLUE}}{R_{REDEGE} + 2,3 \cdot R_{RED} - 1,3 \cdot R_{BLUE}}$	<p>GITELSON et al. (2002)</p> <p>GITELSON et al. (2003)</p>

Anhang 2: Ergebnisse der Regressionsanalyse von LAI und der verwendeten Vegetationsindizes. Als Bewertungskriterium gelten Bestimmtheitsmaß (R^2) und Signifikanz.

	TransformedVI		TriangularVI		SR		SAVI		RDVI		OSAVI		NDVI	
	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz
Gesamt	0,46	0,00	0,50	0,00	0,03	0,20	0,02	0,27	0,44	0,00	0,03	0,21	0,20	0,25
Wintergerste	0,46	0,00	0,57	0,01	0,25	0,03	0,38	0,01	0,37	0,01	0,39	0,00	0,39	0,00
Winterroggen	0,00	0,96	0,14	0,17	0,31	0,03	0,43	0,03	0,35	0,02	0,42	0,01	0,43	0,01
Winterraps	0,17	0,08	0,32	0,01	0,50	0,00	0,45	0,00	0,42	0,00	0,45	0,00	0,48	0,00
Winterweizen	0,04	0,54	0,13	0,69	0,62	0,00	0,42	0,00	0,44	0,01			0,42	0,02

	MTVI2		MTVI1		MSR		MSAVI		MSAVI2		MCARI2		MCARI1	
	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz
Gesamt	0,15	0,32	0,38	0,00	0,03	0,20	0,01	0,35	0,1	0,34	0,02	0,32	0,43	0,00
Wintergerste	0,45	0,00	0,35	0,01	0,31	0,01	0,44	0,00	0,44	0,00	0,45	0,00	0,35	0,01
Winterroggen	0,50	0,00	0,17	0,13	0,36	0,02	0,44	0,00	0,38	0,01	0,50	0,00	0,17	0,13
Winterraps	0,34	0,01	0,14	0,11	0,49	0,00	0,43	0,00	0,43	0,00	0,34	0,00	0,34	0,00
Winterweizen	0,32	0,05	0,40	0,02	0,55	0,00	0,38	0,03	0,38	0,03	0,32	0,05	0,40	0,02

	GI2 (2003)		GI1 (2003)		DVI		PSRI		VARirededge		VARIgreen		MCARI	
	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz	R^2	Signifikanz
Gesamt	0,02	0,29	0,01	0,44	0,48	0,00	0,05	0,06	0,13	0,01	0,09	0,03	0,47	0,00
Wintergerste	0,33	0,01	0,30	0,02	0,30	0,02	0,49	0,00	0,12	0,15	0,35	0,01	0,18	0,07
Winterroggen	0,24	0,06	0,23	0,07	0,17	0,13	0,56	0,00					0,05	0,35
Winterraps	0,43	0,00	0,51	0,00	0,37	0,01	0,11	0,16	0,34	0,01	0,03	0,02	0,12	0,15
Winterweizen	0,69	0,00	0,68	0,00	0,45	0,01	0,35	0,03	0,16	0,17	0,17	0,02	0,13	0,22

	G11 (1996)		G12 (1996)		EVI		CVI		CI		TCARI/OSAVI		MCARI/OSAVI	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,16	0,02	0,07	0,13	0,34	0,00	0,49	0,00	0,55	0,00	0,33	0,00	0,41	0,00
Wintergerste	0,51	0,00			0,59	0,00	0,30	0,02	0,13	0,13	0,56	0,00	0,52	0,00
Winterroggen	0,16	0,08			0,36	0,59	0,10				0,00	0,86		
Winterraps			0,04	0,40	0,10	0,19	0,26	0,03	0,56	0,00	0,01	0,74	0,03	0,50
Winterweizen	0,44	0,01	0,48	0,00	0,21	0,11	0,65	0,00	0,53	0,00	0,02	0,62	0,05	0,46

	MCARI/MSAVI		MCARI2/OSAVI		MCARI2/MSAVI		MCARI1/OSAVI		MCARI1/MSAVI		SIPI		REIP	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,42	0,00	0,28	0,00	0,01	0,54	0,00	0,62	0,01	0,57	0,46	0,00	0,02	0,27
Wintergerste	0,06	0,29	0,22	0,04	0,56	0,00	0,02	0,27	0,39	0,00	0,30	0,02	0,59	0,00
Winterroggen	0,16	0,14	0,29	0,04	0,08	0,30	0,00	0,90	0,04	0,49	0,17	0,13	0,35	0,02
Winterraps	0,06	0,30	0,51	0,00	0,13	0,14	0,26	0,03	0,36	0,01	0,37	0,01	0,46	0,00
Winterweizen	0,08	0,34	0,35	0,03	0,17	0,17	0,16	0,17	0,34	0,04	0,45	0,01	0,33	0,03

Anhang 3: Ergebnisse der Regressionsanalyse von Blattchlorophyll und den verwendeten Vegetationsindizes. Als Bewertungskriterium gelten Bestimmtheitsmaß (R^2) und Signifikanz.

	TransformedVI		TriangularVI		SR		SAVI		RDVI		OSAVI		NDVI	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,54	0,00	0,42	0,00	0,00	0,10	0,00	0,73	0,10	0,08			0,01	0,66
Winterraps	0,42	0,00	0,17	0,86	0,33	0,01	0,47	0,00	0,41	0,00	0,47	0,00	0,46	0,00
Winterweizen	0,22	0,11	0,00	0,90	0,14	0,22	0,16	1,8	0,18	0,15			0,16	0,18

	MTVI2		MTVI1		MSR		MSAVI		MSAVI2		MCARI2		MCARI1	
	R ²	Signifikanz												
Gesamt	0,01	0,55	0,39	0,00	0,00	0,91	0,01	0,83	0,10	0,59	0,01	0,55	0,15	0,03
Winterraps	0,63	0,00	0,47	0,00	0,39	0,00	0,50	0,00	0,50	0,00	0,62	0,00	0,18	0,07
Winterweizen	0,15	0,18	0,14	0,11	0,16	0,18	0,15	0,20	0,15	0,20	0,15	0,18	0,21	0,11

	GI2 (2003)		GI1 (2003)		DVI		PSRI		VARirededge		VARIgreen		MCARI	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,00	0,83	0,00	0,95	0,21	0,01	0,00	0,91	0,06	0,20	0,01	0,59	0,09	0,10
Winterraps	0,15	0,11	0,19	0,06	0,35	0,01	0,58	0,00	0,48	0,00	0,69	0,00	0,70	0,00
Winterweizen	0,11	0,27	0,09	0,31	0,20	0,13	0,14	0,20	0,15	0,20	0,22	0,11	0,25	0,08

	GI1 (1996)		GI2 (1996)		EVI		CVI		CI		TCARI/OSAVI		MCARI/OSAVI	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt			0,04	0,25	0,26	0,00	0,00	0,88	0,01	0,56	0,26	0,00	0,13	0,04
Winterraps			0,46	0,00	0,08	0,75	0,03	0,49	0,26	0,03	0,42	0,00	0,65	0,00
Winterweizen	0,22	0,11	0,17	0,17	0,13	0,23	0,00	0,97	0,14	0,21	0,15	0,19	0,21	0,12

Anhang

	MCARI/MSAVI		MCARI2/OSAVI		MCARI2/MSAVI		MCARI1/OSAVI		MCARI1/MSAVI		SIPI		REIP	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,11	0,06	0,05	0,21	0,05	0,21	0,47	0,00	0,32	0,00	0,21	0,01	0,06	0,17
Winterraps	0,69	0,00	0,29	0,02	0,17	0,08	0,01	0,66	0,08	0,23	0,35	0,01	0,39	0,00
Winterweizen	0,23	0,10	0,03	0,55	0,12	0,25	0,27	0,07	0,24	0,09	0,20	0,13	0,13	0,23

Anhang 4: Ergebnisse der Regressionsanalyse von Wuchshöhe und den verwendeten Vegetationsindizes. Als Bewertungskriterium gelten Bestimmtheitsmaß (R²) und Signifikanz.

	TransformedVI		TriangularVI		SR		SAVI		RDVI		OSAVI		NDVI	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,17	0,00	0,31	0,00	0,00	0,66	0,02	0,30	0,40	0,00			0,02	0,30
Wintergerste	0,45	0,00	0,33	0,01	0,45	0,00	0,45	0,00	0,42	0,00	0,46	0,00	0,46	0,00
Winterroggen	0,00	0,10	0,09	0,28	0,48	0,00	0,44	0,01	0,36	0,02	0,44	0,00	0,44	0,01
Winterraps	0,41	0,00	0,62	0,00	0,56	0,00	0,64	0,00	0,66	0,00	0,64	0,01	0,64	0,00
Winterweizen	0,12	0,26	0,65	0,00	0,78	0,00	0,82	0,00	0,84	0,00			0,82	0,00

	MTVI2		MTVI1		MSR		MSAVI		MSAVI2		MCARI2		MCARI1	
	R ²	Signifikanz												
Gesamt	0,02	0,32	0,25	0,00	0,01	0,50	0,02	0,22	0,02	0,24	0,02	0,32	0,21	0,00
Wintergerste	0,40	0,00	0,35	0,01	0,47	0,00	0,43	0,00	0,43	0,00	0,40	0,00	0,35	0,00
Winterroggen	0,38	0,01	0,13	0,18	0,47	0,01	0,43	0,01	0,37	0,02	0,38	0,01	0,13	0,18
Winterraps	0,56	0,00	0,25	0,31	0,62	0,00	0,63	0,00	0,63	0,00	0,56	0,00	0,59	0,00
Winterweizen	0,76	0,00	0,84	0,00	0,84	0,00	0,79	0,00	0,79	0,00	0,76	0,00	0,84	0,00

	G12 (2003)		G11 (2003)		DVI		PSRI		VARirededge		VARlgreen		MCARI	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,02	0,22	0,03	0,19	0,28	0,00	0,01	0,42						
Wintergerste	0,49	0,00	0,46	0,00	0,34	0,01	0,45	0,00	0,29	0,01	0,46	0,00	0,29	0,02
Winterroggen	0,44	0,01	0,45	0,01	0,16	0,14	0,39	0,01						
Winterraps	0,56	0,00	0,55	0,00	0,63	0,00	0,18	0,00	0,66	0,00	0,38	0,00	0,35	0,01
Winterweizen	0,78	0,00	0,75	0,00	0,84	0,00	0,76	0,07	0,63	0,00	0,82	0,00	0,65	0,00

	G11 (1996)		G12 (1996)		EVI		CVI		CI		TCARI/OSAVI		MCARI/OSAVI	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt											0,04	0,12	0,08	0,04
Wintergerste	0,44	0,00			0,56	0,00	0,34	0,01	0,14	0,10	0,14	0,10	0,03	0,50
Winterroggen											0,01	0,68		
Winterraps			0,05	0,35	0,24	0,03	0,16	0,09	0,67	0,00	0,04	0,43	0,18	0,07
Winterweizen	0,66	0,00	0,81	0,00	0,60	0,00	0,36	0,03	0,82	0,00	0,41	0,02	0,52	0,01

	MCARI/MSAVI		MCARI2/OSAVI		MCARI2/MSAVI		MCARI1/OSAVI		MCARI1/MSAVI		SIPI		REIP	
	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz	R ²	Signifikanz
Gesamt	0,07	0,03	0,00	0,81	0,01	0,57	0,21	0,00	0,22	0,00	0,18	0,00	0,02	0,21
Wintergerste	0,02	0,67	0,00	0,85	0,11	0,16	0,00	0,79	0,46	0,00	0,01	0,65	0,26	0,02
Winterroggen	0,02	0,46	0,41	0,01	0,00	0,83	0,00	0,93	0,02	0,62	0,16	0,14	0,35	0,02
Winterraps	0,26	0,03	0,63	0,00	0,04	0,44	0,36	0,01	0,50	0,00	0,63	0,00	0,65	0,00
Winterweizen	0,58	0,00	0,14	0,21	0,60	0,00	0,56	0,00	0,79	0,00	0,84	0,00	0,74	0,00

Anhang 5: Accuracy matrices der Klassifikation von Pflanzenwasser für Winterraps und Wintergerste mit NN, SAM und SVM

a) NN Winterraps

Klassen		groundtruth				Users Accuracy %	
		1 0-1 kg/m ²	2 2-3 kg/m ²	3 < 4-5 kg/m ²	gesamt t		
Klassifiziert	1	0-1 kg/m ²	4		1	5	80,0%
	2	2-3 kg/m ²		7		7	100,0%
	3	< 4-5 kg/m ²			4	4	100,0%
		gesamt	4	7	5	16	93,3%
		Producers Accuracy %	100,0%	100,0%	80,0%	93,3%	93,8%

b) SAM Winterraps

Klassen		groundtruth				Users Accuracy %	
		1 0-1 kg/m ²	2 2-3 kg/m ²	3 < 4-5 kg/m ²	gesamt t		
klassifiziert	1	0-1 kg/m ²	3		1	4	75,0%
	2	2-3 kg/m ²	1	7		8	87,5%
	3	< 4-5 kg/m ²			4	4	100,0%
		Gesamt	4	7	5	16	87,5%
		Producers Accuracy %	75,0%	100,0%	80,0%	85,0%	87,5%

c) SVM Winterraps

Klassen		groundtruth				Users Accuracy %	
		1 0-1 kg/m ²	2 2-3 kg/m ²	3 < 4-5 kg/m ²	gesamt t		
klassifiziert	1	< 0,7 kg/m ²	4		1	5	80,0%
	2	0,7-1,0 kg/m ²		7		7	100,0%
	3	< 1,0 kg/m ²			4	4	100,0%
		Gesamt	4	7	5	16	93,3%
		Producers Accuracy %	100,0%	100,0%	80,0%	93,3%	93,8%

d) NN Winterweizen

Klassen		groundtruth				Users Accuracy %	
		1 < 0,7 kg/m ²	2 0,7-1,0 kg/m ²	3 < 1,0 kg/m ²	gesamt		
Klassifiziert	1	< 0,7 kg/m ²	1			1	100,0%
	2	0,7-1,0 kg/m ²	2	5	1	8	62,5%
	3	< 1,0 kg/m ²			1	1	100,0%
		Gesamt	3	5	2	10	87,5%
		Producers Accuracy %	33,3%	100,0%	50,0%	61,1%	70,0%

e) SAM Winterweizen			groundtruth				Users Accuracy %
Klassen			1 < 0,7 kg/m ²	2 0,7-1,0 kg/m ²	3 < 1,0 kg/m ²	gesamt	
klassifiziert	1	< 0,7 kg/m ²	0			0	
	2	0,7-1,0 kg/m ²	2	5	1	8	62,5%
	3	< 1,0 kg/m ²			1	1	100,0%
		nicht Klassifiziert	1			1	0%
		gesamt	3	5	2	10	87,5%
	Producers Accuracy %		0,0%	100,0%	50,0%	50,0%	60,0%

f) SVM Winterweizen			groundtruth				Users Accuracy %
Klassen			1 < 0,7 kg/m ²	2 0,7-1,0 kg/m ²	3 < 1,0 kg/m ²	gesamt	
klassifiziert	1	< 0,7 kg/m ²	1		1	2	50,0%
	2	0,7-1,0 kg/m ²	2	4	1	7	57,1%
	3	< 1,0 kg/m ²			1	1	100,0%
		Gesamt	3	5	2	10	69,0%
		Producers Accuracy %		33,3%	80,0%	50,0%	54,4%

Besonders bedanken mochte ich mich bei:

Prof. Dr. Jürgen Wunderlich für die Erstbegutachtung meiner Diplomarbeit und die hilfreichen Anmerkungen.

Marion Pause für die Vergabe dieses interessanten Themas und ganz besonders für die Geduld und Unterstützung bei allen Problemen.

Dr. Angela Lausch für die Betreuung meiner Diplomarbeit und die hilfreichen Tipps und Anregungen.

Den Mitarbeitern des Departments Landschaftsökologie des UFZ und insbesondere des Arbeitskreises Fernerkundung für die freundliche Hilfe und die Datenbearbeitung und -beschaffung.

Meiner Mutter, meinem Vater und meiner Schwester Heike für die starke Unterstützung in jeglicher Hinsicht während meines gesamten Studiums.

Erklärung:

Hiermit erkläre ich, dass ich die vorliegende Arbeit selbständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel verwendet habe.

Frankfurt am. Main, 15. Dezember 2009

Christine Staudt