



Hochschule Neubrandenburg
University of Applied Sciences

Hochschule Neubrandenburg
Fachbereich Landschaftswissenschaften und Geomatik
Studiengang Geodäsie und Geoinformatik

**Beitrag zur Ermittlung des Bodensignals zur
verbesserten Ableitung des Vegetationssignals
aus Fernerkundungsdaten**

MASTERARBEIT

vorgelegt von *Sophie Kühnlenz*

URN: urn:nbn:de:gbv:519-thesis2016-0557-4

Erstprüfer: Prof. Dr.-Ing. Andreas Wehrenpfennig
Zweitprüfer: Dr. rer. nat. Erik Borg
Abgabedatum: 03. März 2017

Danksagung

An dieser Stelle möchte ich mich bei all denen bedanken, die mich bei meiner Masterarbeit sowohl fachlich als auch persönlich unterstützt haben.

Ein großer Dank geht an Herrn Prof. Dr.-Ing. Andreas Wehrenpfennig, der mich während meines Studiums an der Hochschule Neubrandenburg stets bestärkt hat und mir bei vielen Projekten sowie bei der Anfertigung der Masterarbeit konstruktiv und motivierend mit Rat und Tat zur Seite stand. Ich danke ihm für seine offene und faire Art sowie für seine Bemühungen, jegliche Probleme aus der Welt zu schaffen.

Des Weiteren bedanke ich mich bei Herrn Dr. rer. nat. Erik Borg für den Kontakt zum DLR Neustrelitz sowie die Bereitstellung des Themas und die fachliche Betreuung der Masterarbeit. Der Kollegin Stefanie Holzwarth des DLR-Standorts Oberpfaffenhofen danke ich für die Aufbereitung der zur Verfügung gestellten Daten sowie für ihre Hilfsbereitschaft zur Beantwortung meiner Fragen.

Ein besonderer Dank geht an Herrn Prof. Dr. rer. nat. habil. Gerd Teschke, der mir bei den mathematischen Problemstellungen mit zahlreichen Anregungen und richtungsweisenden Ideen den Weg geebnet und somit wesentlich zum Gelingen der Arbeit beigetragen hat. Darüber hinaus möchte ich mich auch bei Herrn Prof. Dr. Eike Stefan Dobers und Frau Prof. Dr. habil. Sandra Rose-Meierhöfer für die fachlichen Hilfestellungen zum Thema Landwirtschaft bedanken.

Außerdem danke ich all meinen Freunden, die mir während der Zeit der Erstellung dieser Arbeit seelisch und moralisch zur Seite standen sowie meinen Eltern für ihre Unterstützung in jeder Hinsicht.

Nicht zuletzt danke ich meinem Freund für seine Geduld und die vielen motivierenden Worte sowie für die hilfreichen und wertvollen Hinweise, mit denen die Arbeit an vielen Stellen bereichert werden konnte.

Kurzfassung

Zahlreiche Studien befassen sich mit der Ableitung von Pflanzenparametern anhand von spektralen Vegetationsindizes und deren Anfälligkeit gegenüber wesentlichen Störfaktoren, wie zum Beispiel dem Einfluss des Bodenhintergrunds. Die Korrektur der Vegetationsindizes beziehungsweise des Vegetationssignals hinsichtlich des Bodeneinflusses stellt eine in der Fernerkundung seit langer Zeit bekannte Herausforderung dar und ist insbesondere im Bereich der Landwirtschaft für eine zuverlässige Abschätzung bedeutender Pflanzenparameter von großem Interesse. In Anbetracht dessen beschäftigt sich die vorliegende Arbeit mit einer Methode zur direkten Ableitung des Bodensignals aus luftgestützten Fernerkundungsdaten landwirtschaftlich genutzter und vegetationsbedeckter Flächen, mit der die Korrektur des Vegetationssignals von Pflanzenbeständen in einer übergeordneten Zielstellung ermöglicht werden kann. Die Extraktion des Bodensignals erfolgt durch einen wissensbasierten Modellansatz zur linearen spektralen Entmischung der Fahrgassen unter Zuhilfenahme eines Fahrspurmodells. Eine exemplarische Umsetzung dieser Methodik umfasst unter anderem eine Fahrgassenselektion sowie einen geometrischen Ansatz zur Modellierung der Fahrspuren auf Subpixel-Niveau. Es wird ein nicht-lineares alternierendes Optimierungsverfahren zur Entmischung der Fahrgassenpixel vorgestellt, mit dem wesentliche Modellunsicherheiten reduziert werden können und die Bestimmung von Referenzspektren entfällt. Eine Bewertung der Entmischungsergebnisse und eine Einschätzung der resultierenden Methode ist aufgrund fehlender Validierungsdaten nicht möglich und erfordert weiterführende Untersuchungen. Die Übertragbarkeit der Methode unterliegt einigen Einschränkungen, bedingt durch die geometrische und spektrale Auflösung der Daten sowie das Untersuchungsgebiet selbst. Unter geeigneten Bedingungen verspricht dieser Ansatz nichtsdestotrotz, eine Möglichkeit zur Abschätzung der Bodenreflexion und somit eine verbesserte Ableitung des Vegetationssignals gewährleisten zu können.

Abstract

Numerous studies are dealing with the estimation of vegetation parameters using spectral vegetation indices, considering their sensitivity to substantial disturbing factors, such as the influence of the soil background. Correcting vegetation indices or a remotely sensed vegetation signal for the soil background effect outlines a well-known challenge in the field of remote sensing and plays a key role for reliably receiving important plant parameters in agricultural applications. In this context, a method for directly deriving soil reflectance from remotely sensed data of agricultural crops during the growing season is presented, to enable the correction of crop reflectance in a subsequent objective. A knowledge-based modelling approach of linear spectral unmixing is used for extracting the reflectance of bare soil within the track lanes, applying a track lane model. An implementation of the observed method includes an automatic selection of the tracks as well as a geometrical analysis for modelling the single track lanes at subpixel level. For unmixing the identified track pixels a non-linear optimization technique is demonstrated, that reduces significant uncertainties of the simplified model approach and that doesn't require any reference spectra. An appropriate evaluation of the unmixing results as well as of the resulting method couldn't be achieved because of missing validation data and needs further research. The application of the acquired method can be restricted by the spatial and spectral resolution of the data and also by the investigation area. Yet, the method introduces a possibility for estimating soil reflectance of agricultural fields and promises to improve the derivation of crop reflectance.

Inhaltsverzeichnis

Abbildungsverzeichnis	VI
Abkürzungsverzeichnis	IX
Symbolverzeichnis	XI
1 Einleitung	1
1.1 Motivation	1
1.2 Zielstellung	2
2 Grundlagen	3
2.1 Einflüsse auf das Fernerkundungssignal	3
2.1.1 Atmosphäre	3
2.1.2 Reflexionseigenschaften des Geländes	6
2.1.3 Sensoreigenschaften	7
2.2 Reflexionsverhalten natürlicher Materialien	9
2.2.1 Vegetation	9
2.2.2 Boden	12
2.3 Vegetationsindizes	15
2.3.1 Klassifizierung von Vegetationsindizes	16
2.3.2 Ableitung von Pflanzenparametern	22
2.4 Spektrale Entmischung	25
2.4.1 Lineares spektrales Entmischungsmodell	26
2.4.2 Bestimmung von Endmembern	28
2.4.3 Grenzen der spektralen Entmischung	32
3 Konzeption der Methodik	34
3.1 Datengrundlage	34
3.2 Charakteristik des Untersuchungsgebiets	35
3.3 Vorbetrachtungen	36
3.4 Entwurf eines Fahrspurmodells	39
3.5 Prozesskette	40
4 Analyse und Umsetzung	41
4.1 Vorverarbeitung	42
4.1.1 Spektrale Glättung	42
4.1.2 Datenreduktion	44
4.2 Segmentierung des Untersuchungsgebiets	44
4.3 Selektion der Fahrgassen	46
4.3.1 Erzeugung eines binären Kantenbilds	48
4.3.2 Detektion der gesuchten Strukturen	55

4.4	Spektrale Entmischung der Fahrgassenpixel	64
4.4.1	Abschätzung der Abundanzen	65
4.4.2	Ermittlung des Bestandsreferenzsignals	68
4.4.3	Ableitung des Bodensignals	70
4.5	Räumliche Interpolation des Bodensignals	85
5	Diskussion	88
5.1	Vorverarbeitung	88
5.2	Segmentierung des Untersuchungsgebiets	89
5.3	Selektion der Fahrgassen	89
5.4	Spektrale Entmischung der Fahrgassenpixel	93
5.5	Räumliche Interpolation des Bodensignals	99
6	Zusammenfassung und Ausblick	101
	Literatur- und Quellenverzeichnis	XV
A	Spezifikation des HySpex-Sensorsystems	XXVII
B	Log-Datei ATCOR-4	XXVIII
C	Ergebnisse lokaler Selektionsfilter im Vergleich	XXXI
D	Ergebnisse zur Erzeugung des binären Kantenbilds	XXXII
E	Ergebnisse der Laufzeitmessung	XXXIV
F	Inhaltsverzeichnis der beiliegenden CD	XXXV

Abbildungsverzeichnis

1	Spektraler Transmissionsgrad τ_λ der Atmosphäre in Abhängigkeit der Wellenlänge λ mit Kennzeichnung der dominierenden Absorber H_2O , CO_2 und O_3 (Albertz 2001, S. 14).	4
2	Schematische Darstellung der Strahlungsverhältnisse in der Atmosphäre bei der Erhebung von Fernerkundungsdaten (Albertz 2001, S. 15).	5
3	Schematische Darstellung des funktionalen Zusammenhangs zwischen Beobachtungs- und Beleuchtungsgeometrie (Albertz 2001, S. 23).	6
4	Charakteristische Reflexionskurven verschiedener Oberflächenmaterialien (verändert nach Lillesand und Kiefer 1994, S. 18).	9
5	Typische Reflexionskurve grüner Blätter mit Kennzeichnung der pflanzenspezifischen Einflussfaktoren sowie der Wasserabsorptionsbänder (Hildebrandt 1996, S. 33).	10
6	Beispiele für zustandsabhängige Reflexionskurven von Buchenblättern: (1) Sonnenblatt (2) Schattenblatt (3) vergilbtes Blatt (4) fünf hintereinander angeordnete Buchenzweige (Hildebrandt 1996, S. 36).	11
7	Reflexionskurven eines Sandbodens bei unterschiedlicher Bodenfeuchte (Hildebrandt 1996, S.62).	13
8	Fünf repräsentative Reflexionskurven von Böden: (A) hoher Gehalt organischer Substanzen (B) minimaler Gehalt organischer Substanzen und geringer Eisengehalt (C) mäßiger Gehalt an organischen Substanzen und an Eisen (D) mittlerer Gehalt organischer Substanzen und geringer Eisengehalt (E) mittlerer Gehalt organischer Substanzen und hoher Eisengehalt (verändert nach Stoner und Baumgardner 1981).	14
9	Graphische Veranschaulichung des <i>Tasseld Cap</i> in Abhängigkeit der Bodenlinie (<i>soil line</i>) und des Punktes höchster Vegetationsdichte (GVP) im Rot-NIR-Merkmalsraum.	17
10	Beispiel für die lineare spektrale Zusammensetzung eines Mischpixels (Schowengerdt 2012).	25
11	Graphische Darstellung des linearen Zusammenhangs dreier Endmember (hier \vec{s}_1 , \vec{s}_2 und \vec{s}_3) in einem dreidimensionalen Merkmalsraum (Schramm 2010).	28
12	Lage des Testfelds DEMMIN (Borg et al. 2009).	34
13	Beispiel einer Fahrgasse mit Pflanzenbestand zwischen den beiden Fahrspuren (Agrarservice MVP GmbH & Co.KG o. J.).	35
14	Relevante Größen zur Ableitung des Blattflächenindex und des Bedeckungsgrads nach Clevers 1988, Monsi und Saeki 1953 und Bouman et al. 1992 aus Klisch et al. 2001.	38
15	Schematische Darstellung der Parameter des Fahrspurmodells (Draufsicht) in Anlehnung an Borg 2016.	39

16	Prozesskette der zu untersuchenden Methode.	40
17	Praktische Umsetzung der Prozesskette in MATLAB (gestrichelte Module ausstehend).	41
18	Lokaler Polynomfit (grün) mit $\tilde{M} = 2$ und $p = 2$ am Beispiel eines Pixelspektrums (blau) der gegebenen Daten.	43
19	RGB-Darstellung der segmentierten Schläge.	45
20	Ergebnisse verschiedener Kantendetektoren am Beispiel von Schlag 1.	47
21	Verrauschte Erscheinung der Fahrgassen und des Bestands am Beispiel von Schlag 1.	48
22	Ergebnisse spektraler Vegetationsindizes.	50
23	Ergebnisse der getesteten lokalen Selektionsfilter.	51
24	Vergleich verschiedener Filtergrößen des lokalen Selektionsfilters B	53
25	Lokaler Selektionsfilter B mit $N = 7$ (NDSI-Auswertung).	53
26	Ergebnisse der Schwellwertbildung.	55
27	Veranschaulichung der Hough-Transformation (verändert nach Burger und Burge 2015).	56
28	Geometrische Bedeutung der Linienparameter in MATLAB.	57
29	Ergebnisse der Hough-Transformation am Beispiel von Schlag 1.	58
30	Selektion der Linien in Vorzugsrichtung.	59
31	Abweichung der detektierten Linien zu den tatsächlichen Fahrgassen im Kantenbild (links) und in der RGB-Darstellung (rechts).	60
32	Approximation der detektierten Linien	60
33	Extremwertanalyse des Grauwertprofils einer ausgewählten Linie zur Bestimmung der neuen Linienendpunkte.	61
34	Einfache Korrektur der Linienendpunkte.	62
35	Erweiterte Anpassung der Linienendpunkte anhand des Grauwertprofils am Beispiel einer ausgewählten Linie.	62
36	Erweiterte Korrektur der Linienendpunkte.	63
37	Ergebnis der Fahrgassenselektion für Schlag 3 mit angepasstem Fahrspurmodell.	63
38	Mögliche Flächenverteilung eines Fahrgassenpixels.	64
39	Geometrische Verschiebung einer mittleren Fahrgassenlinie um δ_1 und δ_2 entlang der x-Achse zur Modellierung der Fahrspurgeometrie.	66
40	Fallunterscheidung der geometrischen Verschneidung eines Pixels (grün) mit den Fahrspurlinien (braun) und den resultierenden Schnittpunkten (rot) sowie den ergänzenden Polygonpunkten (orange).	67
41	Detektion der Bestandpixel (grün) zu beiden Seiten eines Fahrgassenpixels (blau) unter Berücksichtigung einer definierten Pixelumgebung (gelb).	68
42	Optimierungsansatz 1 am Beispiel eines Fahrgassenpixels mit 32% Fahrspuranteil.	73

43	Optimierungsansatz 1 am Beispiel eines Fahrgassenpixels mit 17% Fahrspuranteil.	73
44	Optimierungsansatz 1 am Beispiel eines Fahrgassenpixels mit 5% Fahrspuranteil.	74
45	Berechnung des mittleren Bodenspektrums mit bekannten Größen des Spektralmodells.	75
46	Berechnung des mittleren Bodenspektrums mit fehlerbehafteten Bestandspektren.	75
47	Berechnung des mittleren Bodenspektrums mit fehlerbehafteten Flächenanteilen.	75
48	Abwandlung des Optimierungsansatzes 1 am Beispiel eines Fahrgassenpixels mit 32% Fahrspuranteil.	77
49	Abwandlung des Optimierungsansatzes 1 am Beispiel eines Fahrgassenpixels mit 17% Fahrspuranteil.	78
50	Abwandlung des Optimierungsansatzes 1 am Beispiel eines Fahrgassenpixels mit 5% Fahrspuranteil.	78
51	Optimierungsansatz 2 mit $\mu_E = 0$ und $\mu_a = 0$	82
52	Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 0$	83
53	Optimierungsansatz 2 mit $\mu_E = 0.1$ und $\mu_a = 0$	83
54	Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 1000$	84
55	Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 10000$	84
56	Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 100000$	85
57	Einteilung der Semivarianzen anhand von 9 Lags zur Erzeugung eines empirischen Semivariogramms (verändert nach Wackernagel 2003, S. 47).	86
58	Ergebnisse der lokalen Selektionsfilter für die NDVI-Auswertung mit einer Filtergröße von $N = 3$	XXXI
59	Ergebnisse der lokalen Selektionsfilter für die NDSI-Auswertung mit einer Filtergröße von $N = 3$	XXXI
60	Ergebnisse der Teilschritte zur Erzeugung des binären Kantenbilds für Schlag 1.	XXXII
61	Ergebnisse der Teilschritte zur Erzeugung des binären Kantenbilds für Schlag 2.	XXXII
62	Ergebnisse der Teilschritte zur Erzeugung des binären Kantenbilds für Schlag 3.	XXXIII

Abkürzungsverzeichnis

AAMW	Automatisches Agrarmeteorologisches Wetternetz
ARVI	Atmospherically Resistent Vegetation Index
BLUE	Best Linear Unbiased Estimator
BRDF	Bidirectional Reflectance Distribution Function
CCD	Canopy Chlorophyll Density
CLAIR	Clevers Leaf Area Index by Reflectance
DLR	Deutsches Zentrum für Luft- und Raumfahrt
DN	Digital Numbers
EM	Endmember
EVI	Enhanced Vegetation Index
EVI2	Two-Band EVI
fAPAR	Fraction of Absorbed Photosynthetic Active Radiation
FOV	Field Of View
FPA	Focal Plane Array
GEMI	Global Environment Monitoring Index
GESAVI	General SAVI
GSD	Ground Sample Distance
GVP	Green Vegetation Point
HT	Hough-Transformation
InVeKoS	Integriertes Verwaltungs- und Kontrollsystem
LAI	Leaf Area Index
MESMA	Multiple Endmember Spectral Unmixing Analysis
MSAVI	Modifed Soil Adjusted Vegetation Index
MVSA	Minimum Volume Simplex Analysis
MIR	Mid Infrared
NDSI	Normalized Difference Soil Index
NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared

NPCI	Normalized Pigment Chlorophyll Index
OSAVI	Optimized SAVI
PPI	Pixel Purity Index
PSNDI	Pigment Specific Normalized Difference Index
PVI	Perpendicluar Vegetation Index
REP	Red Edge Position
RGB	Rot Grün Blau
RVI	Ratio Vegetation Index
SAM	Spectral Angle Mapper
SARVI	Soil-Adjusted and Atmospherically Resistant Vegetation Index
SAVI	Soil Adjusted Vegetation Index
SG	Savitzky-Golay
SISAL	Simplex Identification via Split and Augmented Lagrangian
SMACC	Sequential Maximum Angle Convex Cone
SNR	Signal-to-Noise Ratio
SWIR	Short Wavelength Infrared
TSARVI	Transformed Soil-Adjusted and Atmospherically Resistant Vegetation Index
TSAVI	Transformed Soil Adjusted Vegetation Index
VI	Vegetationsindex
VIS	Visible Light
VNIR	Visible and Near-Infrared
WDVI	Weighted Difference Vegetation Index

Symbolverzeichnis

Symbol	Bedeutung	Dimension
A	Matrix der Abundanzen a_1^k eines Spektralmodells mit $k = 1 \dots M$	
A_0	Initiale Matrix der geschätzten Abundanzen \hat{a}_1^k eines Spektralmodells mit $k = 1 \dots M$	
B	Bedeckungsgrad	
C	Bodenspezifische Konstante beim WDV	
CO_2	Chemisches Symbol für Kohlenstoffdioxid	
C_1, C_2	Koeffizienten zur Eliminierung der Aerosol-Effekte beim EVI	
D	Bilddiagonale	$[px]$
E	Matrix der Endmemberspektren \vec{e}_1 und \vec{e}_2	
F	Fläche bei der Polygonberechnung	$[px]$
F_{Pix}	Gesamtfläche eines Pixel-Quadrats der Größe $S \times S$	$[px]$
G	Verstärkungsfaktor beim EVI	
H_2O	Chemisches Symbol für Wasser	
L	Bodenkorrekturfaktor beim SAVI, MSAVI, OSAVI und EVI	
L_i	Strahldichte der aus Richtung (φ_i, ϑ_i) einfallenden Strahlung	$[Wm^{-2}sr^{-1}nm^{-1}]$
M	Anzahl der Pixel in einem Spektralmodell	
N	Filtergröße eines zweidimensionalen Filters der Größe $N \times N$	
O_3	Chemisches Symbol für Ozon	
P	Absorbierte Strahlung des photosynthetisch aktiven Wellenlängenbereichs	
R	Matrix der Pixelspektren \vec{r}_F^k eines Spektralmodells mit $k = 1 \dots M$	
S	Skalierungsfaktor bei der Flächenabschätzung	
VI	Vegetationsindex	
VI_S	Vegetationsindex des blanken Bodens	
VI_∞	Asymptotischer Grenzwert eines Vegetationsindex bei hoher Vegetationsdichte	
V_Z	Zentraler Grauwert einer $N \times N$ Pixelmatrix	
V_{max}	Maximaler Grauwert einer $N \times N$ Pixelmatrix	
V_{med}	Median der Grauwerte einer $N \times N$ Pixelmatrix	

Symbol	Bedeutung	Dimension
V_{min}	Minimaler Grauwert einer $N \times N$ Pixelmatrix	
W	Gewichtungsmatrix	
$WDVI_{\infty}$	Asymptotischer Grenzwert des WDVI bei hoher Vegetationsdichte	
X	Bodenkorrekturfaktor beim TSAVI	
$Z(u)$	Messwert an der Stelle u	
$Z^*(u_0)$	Schätzwert an der Stelle u_0	
Z_S	Bodenkorrekturfaktor beim GESAVI	
Φ, Φ_c	Zielfunktion des einfachen bzw. abgewandelten Optimierungsansatzes 1	
Ψ_E, Ψ_a	Zielfunktionen bei Optimierungsansatz 2	
α	Winkel einer durch die Hough-Transformation extrahierten Linie	[°]
β_{SAM}	Winkel des Spectral Angle Mapper	[rad]
δ_1, δ_2	Abstandsmaße zur Modellierung der Fahrgassen	[px]
η	Korrekturfaktor beim GEMI	
$\gamma(h)$	Semivarianz zweier Stichproben im Abstand h	
$\gamma(h_k)$	Gemittelte Semivarianz aller einer Lag-Distanz h_k zugehörigen Stichproben-Paare	
γ_A	Aerosolspezifische Konstante beim ARVI	
γ_{Nugget}	Nugget-Varianz	
$\hat{\vec{a}}$	Vektor der geschätzten Abundanzen \hat{a}_1^k eines Spektralmodells mit $k = 1 \dots M$	
$\hat{\vec{e}}_1$	Bestandsreferenzspektrum	
\hat{a}_1, \hat{a}_2	Geschätzter Flächenanteil des Pflanzenbestands bzw. der Fahrspuren eines Fahrgassenpixels	
$\kappa_{\hat{\alpha}}$	Winkelabhängiger Faktor zur Berechnung der Abstandsmaße δ_1 und δ_2	
λ	Wellenlänge	[nm]
\mathbb{M}	Matrix der Endmemberspektren \vec{e}_i im linearen spektralen Entmischungsmodell mit $i = 1 \dots m$	
$\mathbb{1}$	Hilfsvektor zur Beschreibung des Spektralmodells bei Optimierungsansatz 2	
μ, μ_c	Kontrollparameter des einfachen bzw. abgewandelten Optimierungsansatzes 1	
μ_E, μ_a	Kontrollparameter des Optimierungsansatzes 2	
ω	Kriging-Gewicht	
ρ_R	Reflexionsvermögen im roten Spektralbereich	
ρ_B	Reflexionsvermögen im blauen Spektralbereich	

Symbol	Bedeutung	Dimension
$\rho_{NIR,soil}$	Reflexionsvermögen des blanken Bodens im NIR	
ρ_{NIR}	Reflexionsvermögen im NIR	
$\rho_{R,soil}$	Reflexionsvermögen des blanken Bodens im roten Spektralbereich	
ρ_{RB}	Reflexionsvermögen des atmosphärenkorrigierten roten Spektralbereichs	
σ_j, σ_m	Spektrale bzw. mittlere Varianz des mittleren Bodenspektrums \tilde{e}_2	
τ_λ	Wellenlängenabhängiger Transmissionsgrad der Atmosphäre	[%]
\tilde{M}	Filtergröße eines eindimensionalen Filters der Länge $2\tilde{M} + 1$	
\tilde{V}_Z	Gefilterter zentraler Grauwert einer $N \times N$ Pixelmatrix	
$\tilde{\alpha}$	Um 90° verschobener Winkel α	[°]
$\tilde{\alpha}_V$	Winkel der Vorzugsrichtung	[°]
\tilde{e}_2	Mittleres Bodenspektrum	
\tilde{n}	Anzahl aller Schnitt- bzw. Eckpunkte zur Flächenberechnung eines Polygons	
$\tilde{t}_1, \tilde{t}_2, \tilde{t}_3$	Fahrspurbreite, Fahrgassenbreite, Fahrgassenabstand	[px]
φ_i, φ_r	Azimutwinkel der einfallenden bzw. der reflektierten Strahlung	[rad]
ϑ_i, ϑ_r	Zenitwinkel der einfallenden bzw. der reflektierten Strahlung	[rad]
\vec{v}	Hilfsvektor zur Definition der Zielfunktion Ψ_E	
$\vec{\epsilon}$	Vektor des Restfehlers im linearen spektralen Entmischungsmodell	
\vec{a}	Vektor der Abundanzen a_i im linearen spektralen Entmischungsmodell mit $i = 1 \dots m$	
\vec{a}_1	Vektor der Abundanzen a_1^k eines Spektralmodells mit $k = 1 \dots M$	
\vec{b}	Modellfunktion zur Optimierung des Bodenspektrums bei Optimierungsansatz 2	
\vec{c}	Konstante Mittelwertfunktion beim abgewandelten Optimierungsansatz 1	
\vec{d}_{12}	Differenzvektor der Spektren \vec{e}_1 und \vec{e}_2	
\vec{e}	Endmemberspektrum	
\vec{e}_1	Spektrum des Pflanzenbestands im Fahrgassenpixel	

Symbol	Bedeutung	Dimension
\vec{e}_2	Spektrum der Fahrspuren im Fahrgassenpixel	
\vec{r}	Pixelspektrum	
\vec{r}_F	Spektrum eines Fahrgassenpixels	
\vec{w}	Vektor der wellenlängenabhängigen Gewichte w_i mit $i = 1 \dots n$	
$d\Omega$	Raumwinkelement der einfallenden Strahlung	$[sr]$
d	Senkrechter Abstand einer Geraden zum Koordinatenursprung gemäß der Hess'schen Normalenform	$[px]$
dL_r	Strahldichte des Anteils der aus der Richtung (φ_i, ϑ_i) einfallenden und in Richtung (φ_r, ϑ_r) reflektierten Strahlung	$[Wm^{-2}sr^{-1}nm^{-1}]$
f_r	Bidirektionale Reflexionsverteilungsfunktion	$[sr^{-1}]$
h	Abstand zweier Stichproben	$[m]$
h_k	Lag-Distanz	$[m]$
k	Kombination aus Extinktions- und Streukoeffizienten zur Ableitung des LAI nach dem CLAIR-Modell	
k_S	Extinktionskoeffizient der solaren Einstrahlung zur Ableitung des Bedeckungsgrads B	
k_P	Extinktionskoeffizient zur funktionalen Beschreibung $VI(P)$	
k_{VI}	Extinktionskoeffizient zur funktionalen Beschreibung $VI(LAI)$	
m	Anzahl der Endmember im linearen spektralen Entmischungmodell	
m_k	Anzahl der im experimentellen Semivariogramm einem Lag zugehörigen Stichprobenpaare	
n	Anzahl der Spektralbänder	
n_k	Anzahl benachbarter Stützstellen, die in die Kriging-Interpolation eines Schätzwertes $Z^*(u_0)$ eingehen	
p	Polynomgrad des Savitzky-Golay-Filters	
s_1, s_2	Koeffizienten der Bodenlinie im NIR-Rot-Merkmalraum	
t_1, t_2, t_3	Fahrspurbreite, Fahrgassenbreite, Fahrgassenabstand	$[m]$
x	x-Koordinate	
x_{E1}, x_{E2}	x-Koordinaten der Linienendpunkte	
y	y-Koordinate	
y_{E1}, y_{E2}	y-Koordinaten der Linienendpunkte	

1 Einleitung

1.1 Motivation

In den letzten Jahren hat sich die Fernerkundung im Bereich der Landwirtschaft zunehmend etabliert. Mit der Auswertung von luftgestützten Fernerkundungsdaten stehen effektive Möglichkeiten zur Verfügung, die eine schnelle zerstörungsfreie Erfassung pflanzenspezifischer Informationen für weitläufige Ackerflächen ohne großen Aufwand ermöglichen. Ein weit verbreiteter Ansatz zur Analyse vegetationsbedeckter Oberflächen stellt die Verwendung von spektralen Vegetationsindizes dar. Unter Ausnutzung des markanten Reflexionsverhaltens grüner Vegetation ermöglichen diese Indizes eine Abschätzung bedeutender biochemischer und biophysikalischer Pflanzenparameter. Diese Pflanzenparameter sind in der Landwirtschaft von großer Bedeutung und werden unter anderem zur Überwachung des Pflanzenbestands sowie zur Ertragsabschätzung genutzt. Sie erlauben Rückschlüsse auf das Pflanzenwachstum, einen möglichen Wasser- oder Nährstoffmangel sowie das Auftreten von Pflanzenstress und -krankheiten. Mit diesen Kenntnissen können Bewirtschaftungsmethoden sowie der Betriebsmitteleinsatz gezielt optimiert werden. Eine ausreichende geometrische sowie zeitliche Auflösung ermöglicht darüber hinaus auch die Unterstützung von Aktivitäten der Teilschlagbewirtschaftung (*Precision Farming*).

Bei der Analyse von Pflanzenbeständen wird das von Fernerkundungssensoren erfasste Vegetationssignal jedoch durch zahlreiche Faktoren beeinflusst. Neben variierenden atmosphärischen Bedingungen sowie der Beobachtungs- und Beleuchtungsgeometrie hat die Bodenreflexion einen wesentlichen Einfluss auf das Reflexionsverhalten von Pflanzenbeständen. Die Bodenreflexion selbst variiert ebenfalls in Abhängigkeit verschiedener Faktoren, wie der Bodenfeuchte oder dem Anteil an organischer Substanz, und kann in Folge dessen sehr großen zeitlichen und räumlichen Schwankungen unterliegen. Dies erschwert die Interpretation von Vegetationsindizes und demnach auch mögliche Rückschlüsse auf die erwähnten Pflanzenparameter. Mit dem Ziel, den Bodeneinfluss zu reduzieren, wurden verschiedene bodenkorrigierende Indizes entwickelt, wobei das Spektralverhalten des Bodens häufig ohne Berücksichtigung der räumlichen und zeitlichen spektralen Variabilität modelliert wird. Demzufolge lassen sich diese Ansätze nur bedingt übertragen und sind bei geringen Bedeckungsgraden oftmals trotzdem durch einen signifikanten Bodeneinfluss geprägt.

Eine flächenhafte Abschätzung des Bodensignals einer Fernerkundungsszene mit direktem Orts- und Zeitbezug zum Pflanzenbestand verspricht hingegen, eine adäquate Modellierung der Bodenreflexion zu gewährleisten. Ist die Bodenreflexion eines Pflanzenbestands an jeder Stelle bekannt, so besteht die Möglichkeit, das Vegetationssignal hinsichtlich des Bodenuntergrunds zu korrigieren und eine zuverlässige Ableitung von Pflanzenparametern sicherzustellen. Ein solcher Ansatz soll mit der vorliegenden Arbeit untersucht werden.

1.2 Zielstellung

Es gilt eine Methode zu erarbeiten, mit der das Bodensignal für eine landwirtschaftliche Fläche während der Wachstumsperiode anhand von luftgestützten Fernerkundungsdaten extrahiert und flächenhaft abgeleitet werden kann. Die Anregung zur Bearbeitung dieser Thematik sowie die grundlegende Idee zur Umsetzung stammen von Herrn Dr. rer. nat. Erik Borg vom Deutschen Zentrum für Luft- und Raumfahrt (DLR) Neustrelitz. Im Rahmen dieser Zusammenarbeit werden vom DLR hyperspektrale Testdaten zur Verfügung gestellt, welche typischerweise durch eine sehr hohe spektrale Auflösung geprägt sind. Zur Extraktion des Bodensignals soll ein Ansatz untersucht werden, der sich auf die Ausnutzung des unbedeckten Bodens der Fahrgassen bezieht. Aufgrund der ausgeprägten Mischpixelcharakteristik der gegebenen Daten handelt es sich dabei um eine Entmischungsproblematik, die eine geeignete Subpixelanalyse erfordert. Dies soll durch eine geometrische Modellierung der Fahrgassen und einen modifizierten spektralen Entmischungsansatz erfolgen. In Anbetracht dessen grenzt sich die zu erarbeitende Methode klar von der Auswertung geometrisch höher aufgelöster Fernerkundungsdaten ab, bei denen keine spektrale Entmischung notwendig ist und das gesuchte Bodensignal stattdessen direkt aus den reinen Fahrgassenpixeln extrahiert werden kann.

In Hinblick auf eine möglichst automatisierte und maßstabsunabhängige Methode gilt es, eine exemplarische Prozesskette zu entwickeln und jeden Prozessschritt ausführlich zu untersuchen. Es sollen mögliche Ansätze zur Umsetzung aufgezeigt und anhand der Testdaten und unter Verwendung von MATLAB¹ demonstriert werden. Dies umfasst unter anderem eine geeignete Vorgehensweise zur Fahrgassenselektion, mit der die gesuchten Fahrgassenpixel identifiziert werden können. In einer abschließenden Diskussion sollen die Erkenntnisse der Untersuchungen sowie offene Fragestellungen zusammenfassend dargelegt und die gewählten Ansätze bewertet werden. Zudem soll das Erweiterungs- und das Automatisierungspotential beleuchtet werden, um zu klären, inwieweit sich die Methodik auch auf andere Daten übertragen lässt. Mit dieser Arbeit soll prinzipiell eine erste Grundlage zur Bearbeitung der Thematik geschaffen werden, wobei das methodische Vorgehen im Vordergrund steht.

¹MATLAB ist eine kommerzielle Software der Firma MathWorks zur Lösung numerischer Probleme, die unter anderem verschiedene Toolboxes zur Signal- und Bildverarbeitung bereitstellt.

2 Grundlagen

Dieses Kapitel gibt eine Einführung in die für die Arbeit relevanten Grundlagen der Fernerkundung, die sich in Anbetracht der Zielstellung ausschließlich auf passive optische Fernerkundungssysteme unter Verwendung von abbildenden digitalen Scannern beziehen. Nach der Erläuterung möglicher Störeinflüsse bei der Erfassung des Fernerkundungssignals wird das Prinzip spektraler Signaturen anhand der Reflexionscharakteristik von Vegetation und Boden erläutert. Anschließend werden einige bedeutende Vegetationsindizes vorgestellt und deren Potential zur Ableitung spezifischer Pflanzenparameter dargelegt. Der letzte Abschnitt beschäftigt sich mit der linearen spektralen Entmischung, wobei das zugrunde liegende mathematische Modell sowie wesentliche Herausforderungen und Grenzen einer solchen spektralen Analyse thematisiert werden.

2.1 Einflüsse auf das Fernerkundungssignal

Bei der passiven optischen Fernerkundung wird die von der Erdoberfläche natürlich reflektierte elektromagnetische Strahlung im Bereich des sichtbaren Lichts bis zum mittleren Infrarot durch den Einsatz geeigneter Sensoren erfasst. Aus der gemessenen elektromagnetischen Strahlung, dem Fernerkundungssignal, können Messgrößen abgeleitet werden, die Rückschlüsse auf den Zustand der zu untersuchenden Objekte erlauben. Dies ermöglicht die indirekte und berührungslose Beobachtung von Objekten und Phänomenen der Erdoberfläche zur Analyse von natürlichen oder durch den Menschen verursachten Zustandsveränderungen oder Wechselbeziehungen (Albertz 2001).

Das Fernerkundungssignal unterliegt auf dem Weg von der Energiequelle bis zum Sensor stets einigen Einflussfaktoren, welche die Intensität und die spektrale Zusammensetzung der zu messenden Strahlung beeinflussen können und die es bei der Auswertung zu berücksichtigen gilt. Dazu zählen insbesondere der Einfluss der Atmosphäre, die Reflexionseigenschaften des Geländes sowie sensorspezifische Eigenschaften, die im Folgenden näher erläutert werden.

2.1.1 Atmosphäre

Die auf die Erdatmosphäre eintreffende extraterrestrische Sonnenstrahlung wird durch die Beschaffenheit und den Zustand der Atmosphäre wesentlich beeinflusst, wobei ein Teil der Strahlung bereits an der oberen Schicht reflektiert wird. Der verbleibende in die Atmosphäre eintretende Teil der Strahlung unterliegt Absorptions- und Streuvorgängen, die jeweils eine abschwächende Wirkung haben und zusammenfassend auch als Extinktion bezeichnet werden (Hildebrandt 1996).

Die Absorption der solaren Einstrahlung wird durch die wellenlängenabhängigen Absorptionseigenschaften der in der Atmosphäre befindlichen Gase bestimmt, wobei insbesondere Wasserdampf, Kohlendioxid und Ozon maßgebend sind. Der absorbierende Einfluss dieser Gase bedingt somit auch den wellenlängenabhängigen Transmissionsgrad

τ_λ der Atmosphäre (Abb. 1). Die Spektralbereiche hohen Transmissionsgrades werden als atmosphärische Fenster bezeichnet, welche sich die Fernerkundung zu Nutze macht.




Abbildung 1: Spektraler Transmissionsgrad τ_λ der Atmosphäre in Abhängigkeit der Wellenlänge λ mit Kennzeichnung der dominierenden Absorber H_2O , CO_2 und O_3 (Albertz 2001, S. 14).

Als Folge der Wechselwirkungen der einfallenden oder bereits gestreuten Sonnenstrahlung mit den in der Atmosphäre vorhanden Materialteilchen (Aerosolen) treten zudem abschwächende Streuvorgänge auf. Entscheidend sind dabei Art und Größe der Teilchen (zum Beispiel Dunst, Staub, Wassertropfen) sowie die Wellenlänge der eintreffenden Strahlung (Campbell und Wynne 2011).

Das Ausmaß der Extinktion ist somit wellenlängenabhängig und an den Zustand der Atmosphäre (Trübung, Art und Menge der Aerosole beziehungsweise Spurengase) gekoppelt. Bei gleichbleibendem Atmosphärenzustand ändert sich die abschwächende Wirkung jedoch ebenfalls in Abhängigkeit des Sonnenstands, wobei eine zunehmende Weglänge der Strahlung durch die Atmosphäre eine Verstärkung der Extinktion zur Folge hat (Hildebrandt 1996).

Während die durch die Atmosphäre absorbierte Strahlung in Wärme oder andere Energieformen umgewandelt wird, trägt der gestreute Strahlungsanteil zum diffusen Himmelslicht bei (Hildebrandt 1996). Die diffuse Himmelsstrahlung erhellt den ganzen atmosphärischen Raum und stellt somit eine sekundäre Energiequelle zur Beleuchtung der Erdoberfläche dar. In Abhängigkeit der atmosphärischen Trübung ändern sich die Intensität und die Charakteristik des Himmelslichts, das bei klarem Himmel zum Beispiel durch einen hohen blauen kurzwelligen Anteil geprägt ist. Unter der Globalstrahlung wird die Gesamtheit der auf die Erdoberfläche eintreffenden Strahlungsenergie aufgefasst, die sich additiv aus der direkt einfallenden Strahlung und dem diffusen Himmelslicht zusammensetzt. Intensität und spektrale Zusammensetzung dieser Globalstrahlung ist letztendlich an den Trübungszustand der Atmosphäre, die Sonnenhöhe sowie die Geländeeigenschaften (Höhe über dem Meeresspiegel, Hangneigung und Orientierung, etc.) gekoppelt (Albertz 2001).

Die an der Erdoberfläche reflektierte Strahlung unterliegt denselben abschwächenden Prozessen der Absorption und Streuung wie die solare Einstrahlung. Als Folge der Streuung wird die reflektierte Strahlung durch das diffuse in Richtung des Sensors wirkende




Abbildung 2: Schematische Darstellung der Strahlungsverhältnisse in der Atmosphäre bei der Erhebung von Fernerkundungsdaten (Albertz 2001, S. 15).

Luftlicht überlagert. Hinzu kommt die Überlagerung durch das so genannte Falschlicht, das auf die Reflektion benachbarter Objekte zurückzuführen ist. Diese beiden Fremdstrahlungen sind durch einen hohen Anteil blauer kurzwelliger Strahlung geprägt und haben eine kontrastmindernde Wirkung auf die Fernerkundungsszene, der durch den Einsatz geeigneter Filter bei der Aufnahme oder durch eine nachträgliche Datenmanipulation entgegengewirkt wird. Der Zuwachs der Fremdstrahlung wirkt dabei dem Maß der Extinktion entgegen, wobei die spektrale Zusammensetzung jedoch deutlich beeinflusst wird.

Das Ausmaß der Extinktion der reflektierten Strahlung sowie der Zuwachs durch Fremdstrahlung sind demnach wellenlängenabhängig und werden durch den Zustand der Atmosphäre sowie durch die Weglänge beeinflusst, welche wiederum von der Flughöhe und dem Öffnungswinkel des Aufnahmesystems abhängt (Hildebrandt 1996).

Da der Einfluss der Atmosphäre eine wesentliche Verfälschung des am Sensor eintreffenden Signals bewirken und zudem sowohl räumlich als auch zeitlich sehr variabel sein kann, ist eine Korrektur dieser Atmosphäreneinflüsse unabdingbar. Dazu werden die am Sensor gemessenen Strahldichten in Reflexionsgrade überführt, die neben dem Einfluss der Atmosphäre auch an die Reflexionseigenschaften des Geländes gekoppelt sind. Gängige Korrekturverfahren basieren auf Strahlungstransfermodellen, mit denen die komplexen Strahlungsvorgänge in der Atmosphäre unter Berücksichtigung wesentlicher Parameter, wie zum Beispiel der Intensität und Richtung der Einstrahlung, dem Zustand der Atmosphäre (Wasserdampf, Aerosole, Ozon, Wolken) sowie der Geländetopographie, simuliert werden können. Neben der Verwendung fest definierter Standardatmosphären, können auch Zusatzdaten, wie aktuelle satellitengestützte Klimadaten oder aus den Daten selbst abgeleitete Informationen zum Aerosol- und Wassergehalt, hinzugezogen werden (Hildebrandt 1996).

2.1.2 Reflexionseigenschaften des Geländes

Die auf die Erdoberfläche einfallende solare Strahlung wird zu einem Teil reflektiert und zum anderen absorbiert und transmittiert. Art und Anteil der Reflexion werden dabei vor allem durch die Objekteigenschaften, die Oberflächencharakteristik sowie die Aufnahme- und Beleuchtungsgeometrie bestimmt (Albertz 2001).

Der objektspezifische Reflexionsgrad ist in erster Linie an die chemischen und physikalischen Eigenschaften der Oberflächenmaterialien gekoppelt und kann mit der Wellenlänge sehr stark variieren. Zwei wellenlängenabhängige Reflexionscharakteristika natürlicher Materialien werden in Kapitel 2.2 am Beispiel von Vegetation und Boden näher erläutert.

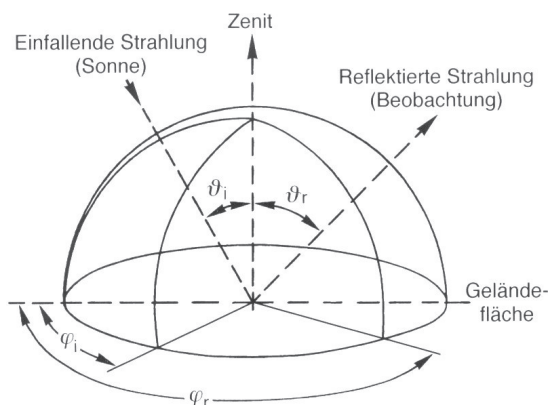


Abbildung 3: Schematische Darstellung des funktionalen Zusammenhangs zwischen Beobachtungs- und Beleuchtungsgeometrie (Albertz 2001, S. 23).

In Abhängigkeit der Oberflächenrauigkeit wird des Weiteren zwischen spiegelnder und diffuser Reflexion unterschieden. Bei natürlichen Oberflächen ist jedoch überwiegend eine Mischform dieser beiden Reflexionsarten zu beobachten, deren Intensität von der Richtung abhängig ist. Dieses anisotrope Reflexionsverhalten wird durch die Beobachtungs- und Beleuchtungsgeometrie bestimmt (Abb. 3) und kann mit der bidirektionalen Reflexionsverteilungsfunktion (engl. bi-directional reflectance distribution function, BRDF)

$$f_r(\vartheta_i, \varphi_i, \vartheta_r, \varphi_r, \lambda) = \frac{dL_r(\vartheta_i, \varphi_i, \vartheta_r, \varphi_r, \lambda)}{L_i(\vartheta_i, \varphi_i, \lambda) \cdot \cos(\vartheta_i) \cdot d\Omega} \quad [sr^{-1}]$$

beschrieben werden (Nicodemus et al. (1977)). In Abhängigkeit der Wellenlänge λ setzt diese Funktion den Anteil der aus Richtung (ϑ_i, φ_i) einfallenden und in Richtung (ϑ_r, φ_r) reflektierten Strahldichte dL_r ins Verhältnis zu der aus Richtung (ϑ_i, φ_i) einfallenden Strahldichte L_i bezüglich des Raumelements $d\Omega$. Bei der Auswertung von Fernerkundungsdaten kann die Berücksichtigung der gerichteten Reflexion von Oberflächenmaterialien entweder durch sehr aufwändige spektrometrische Messungen oder anhand statistischer Modellansätze erfolgen. In den meisten Fällen wird der Einfluss des gerichteten Reflexionsverhaltens jedoch vernachlässigt.

Bei stark ausgeprägten Oberflächenstrukturen können sich in Folge einer variierenden Beobachtungs- und Beleuchtungsgeometrie ebenfalls wechselnde Mit- und Gegenlichtverhältnisse ergeben. Dadurch werden die Schattenanteile bestimmt, die jedoch auch von der Charakteristik der Globalstrahlung (diffus oder direkt) abhängen und unterschiedlich stark ausgeprägt sein können (Albertz 2001).

2.1.3 Sensoreigenschaften

Mit dem Einsatz digitaler Fernerkundungssensoren kann die von der Erdoberfläche natürlich reflektierte elektromagnetische Strahlung erfasst und in Sensorsignale (Digital Numbers, DN) überführt werden. Gängige Fernerkundungssensoren können anhand ihrer geometrischen, spektralen, radiometrischen und zeitlichen Auflösung differenziert werden. Diese Auflösungen entsprechen entscheidenden Kriterien bei der Interpretation und Auswertung von Fernerkundungsdaten.

Mit der geometrischen Auflösung ist die Größe der Flächeneinheit auf der Erde definiert, die durch ein einzelnes Pixel abgedeckt wird. Diese geometrische Bodenauflösung (ground sampling distance, GSD) wird von der Pixelgröße und dem Blickwinkel des Sensors sowie der Flughöhe des Aufnahmesystems bestimmt. Demzufolge entspricht das Messsignal eines Pixels stets einem Integrationswert der Oberflächenreflexion über die durch das Pixel abgedeckte Fläche (Hildebrandt 1996). Nach Ehlers 2002 lassen sich Fernerkundungssensoren hinsichtlich der geometrischen Auflösung in sechs Klassen unterteilen, wobei die Grenzen dieser Klassifizierung durch sehr hoch auflösende Systeme mit einer geometrischen Auflösung $< 1m$ und sehr gering auflösende Systeme mit einer Bodenauflösung $> 250m$ definiert werden. Die geometrische Auflösung gilt als Indikator für die Detailtreue einer Aufnahme und ist entscheidend für die Erkennbarkeit und Separation von Objekten.

Unter der spektralen Auflösung wird die Fähigkeit des Sensors aufgefasst, elektromagnetische Strahlung in mehreren separaten Wellenlängenbereichen aufzuzeichnen. Maßgebend sind die Anzahl der Spektralbänder beziehungsweise –kanäle, die Breite der dadurch abgedeckten Wellenlängenbereiche sowie die Wellenlängenunterschiede. Es wird zwischen panchromatischen (1 Kanal), multispektralen (2 bis circa 20 Kanäle) und hyperspektralen (20 bis mehrere 100 Spektralbänder) Sensoren unterschieden (Ehlers 2002). Während die panchromatischen und multispektralen Sensoren mit einigen wenigen und breiten Kanälen eine geringe spektrale Auflösung aufweisen, sind die Hyperspektralsensoren durch eine besonders hohe spektrale Auflösung geprägt. Diese Sensoren entsprechen einer Kombination aus Bildaufzeichnung und spektroradiometrischer Messung, weshalb sie auch als abbildende Spektrometer bezeichnet werden (Albertz 2001). Sie verfügen über zahlreiche sehr schmale und eng benachbarte Spektralbänder, mit denen die Reflexionscharakteristik von Oberflächenmaterialien nahezu kontinuierlich er-

fasst werden kann. Eine solche hohe spektrale Auflösung ermöglicht die Identifikation und Separation von Oberflächenmaterialien anhand von spektralen Analysen. Die Messungen von Fernerkundungssensoren mit ähnlicher oder gleicher spektraler Auflösung können sich allerdings aufgrund der sensorspezifischen spektralen Übertragungsfunktion deutlich unterscheiden, was bei der Interpretation und insbesondere beim Vergleich von multisensoralen Daten zu beachten ist.

Die radiometrische Auflösung entspricht der Anzahl möglicher Abstufungen, anhand der sich die Intensitäten des gemessenen Signals unterscheiden lassen. Maßgebend ist die Wortbreite, also die Anzahl der für die Quantisierung des Messsignals zur Verfügung stehenden Bit, die den möglichen Wertebereich und somit den Dynamikumfang des Sensors bestimmt. Häufig verfügen digitale Aufnahmesysteme über eine radiometrische Auflösung von 8 Bit, womit 256 Intensitätsabstufungen pro Pixel differenziert werden können. Die Spannweite der radiometrischen Auflösung gängiger Fernerkundungssensoren reicht von < 6 Bit bis zu sehr hoch auflösenden Systemen von > 12 Bit (Ehlers 2002). Große Wortbreiten resultieren in einen höheren Dynamikumfang und ermöglichen damit eine feinere Auflösung des Messsignals. Ein weiteres Maß für die Qualität der gemessenen Signale ist durch das Signal-Rausch-Verhältnis (Signal-to-Noise Ratio, SNR) eines Sensors gegeben. Das Signal-Rausch-Verhältnis entspricht dem Störabstand zwischen Nutzsignal und Rauschsignal. Sensorbedingtes Rauschen kann in Abhängigkeit der verwendeten Sensortechnik sowie der Signalverarbeitung neben dem Quantisierungsrauschen zum Beispiel auch auf den Dunkelstrom der lichtempfindlichen Elemente zurückgeführt werden. Als Folge von Alterserscheinungen kann die radiometrische Genauigkeit zudem durch eine mögliche Degradation des Sensors beeinflusst werden. In Anbetracht dessen müssen Sensoren gegebenenfalls wiederholt radiometrisch kalibriert werden. Die radiometrische Kalibrierung ordnet den Sensorwerten eindeutige physikalische Größen der Strahldichte zu und ermöglicht somit quantitative Messungen der eintreffenden Signale. Im Fall von satellitengestützten Aufnahmesystemen kann eine solche Verschlechterung des Sensors trotz geeigneter Instrumente an Bord nicht immer vollständig korrigiert werden (Wang et al. 2012).

Die zeitliche Auflösung beschreibt den Zeitraum, nach dem ein Fernerkundungssensor ein und dasselbe Gebiet auf der Erdoberfläche wiederholt aufzeichnet. Dies spielt insbesondere im Fall von multitemporalen Analysen eine wichtige Rolle. Diese stützen sich oftmals auf satellitengestützte Aufnahmesysteme, deren Repetitionsrate im operationellen Betrieb unter anderem durch die Parameter der Umlaufbahn bestimmt wird und zusätzlich auch vom Breitengrad des Untersuchungsgebiets abhängt (Albertz 2001).

2.2 Reflexionsverhalten natürlicher Materialien

Die natürlichen Oberflächenmaterialien der Erde weisen in der Regel ein objekt- und zustandsspezifisches wellenlängenabhängiges Reflexionsverhalten auf, das an die chemischen und physikalischen Eigenschaften sowie die Oberflächenbeschaffenheit der Objekte gekoppelt ist (Hildebrandt 1996). Daraus ergeben sich charakteristische Reflexionskurven, so genannte spektrale Signaturen, welche sich die Fernerkundung zur Identifikation und Separation von Oberflächenmaterialien zu Nutze macht (Abb. 4).




Abbildung 4: Charakteristische Reflexionskurven verschiedener Oberflächenmaterialien (verändert nach Lillesand und Kiefer 1994, S. 18).

Nachfolgend werden die für die Arbeit relevanten Reflexionscharakteristika von Vegetation und Boden im Bereich von $0.4\mu\text{m}$ bis $2.5\mu\text{m}$ näher erläutert. Die Kenntnis über das spektrale Verhalten natürlicher Oberflächenmaterialien basiert größtenteils auf Labormessungen unter bekannten Bedingungen oder auch auf Feldmessungen. Aufgrund abweichender Beobachtungsbedingungen insbesondere in Bezug auf die bereits erläuterten externen Einflussfaktoren und variierenden Sensoreigenschaften (vgl. Kapitel 2.1) sind die daraus abgeleiteten Zusammenhänge nur teilweise auf das Fernerkundungssignal übertragbar (Hildebrandt 1996).

2.2.1 Vegetation

Die spektrale Signatur von Vegetation ist hauptsächlich durch die Absorptions-, Streu- und Transmissionsvorgänge an den Blättern der Pflanzen geprägt und weist für grüne gesunde Blätter ein sehr markantes Reflexionsverhalten auf (Abb. 5). In Bezug auf die vorherrschenden Strahlungsvorgänge, welche durch die biochemischen und biophysikalischen Eigenschaften der Pflanze bedingt sind, lässt sich die Reflexionskurve in drei signifikante Spektralbereiche untergliedern (Hildebrandt 1996).

Im Bereich des sichtbaren Lichts (VIS, $0.4\mu\text{m}$ bis $0.7\mu\text{m}$) dominiert die Absorption der Strahlung durch die Blattpigmente (zum Beispiel Chlorophylle und Carotine), die in Abhängigkeit der Art und Menge der Pigmente ungefähr zwischen 70% und 95% der Einstrahlung liegen kann. Die Pigmentabsorption überwiegt im Bereich des

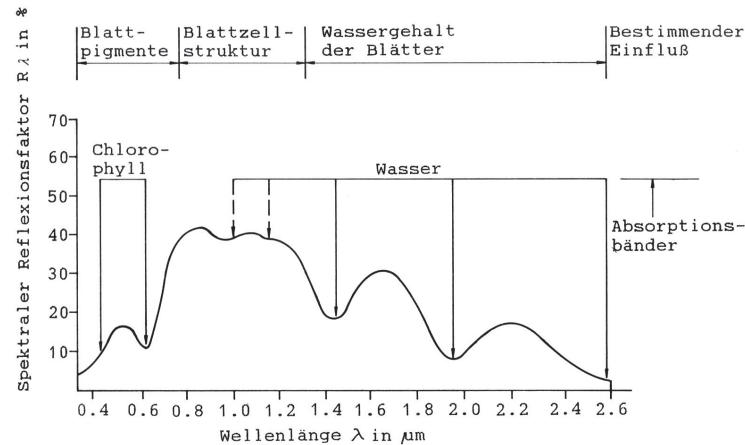


Abbildung 5: Typische Reflexionskurve grüner Blätter mit Kennzeichnung der pflanzenspezifischen Einflussfaktoren sowie der Wasserabsorptionsbänder (Hildebrandt 1996, S. 33).

blauen und roten Lichts, wodurch sich ein relatives Reflexionsmaximum im grünen Wellenlängenbereich bei ungefähr $0,55\mu\text{m}$ ergibt (Hildebrandt 1996).

Der anschließende Spektralbereich des nahen Infrarot (NIR, $0,7\mu\text{m}$ bis $1,3\mu\text{m}$) ist insbesondere durch Reflexions- und Streuungseffekte geprägt, die auf die Zell- und Gewebestrukturen der Blätter zurückzuführen sind. Dabei sind unter anderem die Anordnung, die Größe und die Form der Pflanzenzellen sowie die Verteilung von luft- oder wassergefüllten Hohlräumen maßgebend. Mit steigendem Wassergehalt verringert sich das Maß der multiplen Streuung an den Zellwänden und die Reflexion im NIR-Bereich nimmt ab. In Folge dessen können sich im Bereich von $0,98\mu\text{m}$ und $1,2\mu\text{m}$ schwache Wasserabsorptionsbanden ausprägen (Eismann 2012).

Zwischen $0,69\mu\text{m}$ und $0,72\mu\text{m}$ weist die Reflexionskurve einen sehr charakteristischen steilen Anstieg auf, der auch als rote Kante (*red edge*) bezeichnet wird (Kumar et al. 2002). Dieser ist durch die starke Pigmentabsorption im Rot-Bereich und die starke Reflexion im NIR-Bereich bedingt. Der markante Unterschied des Reflexionsverhaltens von Vegetation zwischen VIS und NIR wird bei der Berechnung von Vegetationsindizes ausgenutzt (siehe Kapitel 2.3).

Im mittleren Infrarotbereich (MIR, $1,3\mu\text{m}$ bis $2,5\mu\text{m}$) ist das Spektralverhalten von Vegetation hauptsächlich durch die Wasserabsorption geprägt, die zu deutlichen Abschwächungen der Reflexion im Bereich von $1,45\mu\text{m}$, $1,94\mu\text{m}$ und $2,5\mu\text{m}$ führen kann (Kumar et al. 2002). Die Ausprägung dieser Wasserabsorptionsbanden verstärkt sich mit zunehmendem Wassergehalt der Pflanze. Biochemische Inhaltsstoffe, wie Lignin, Zellulose oder Pektin, haben im MIR ebenfalls einen absorbierenden Effekt. Die daraus resultierenden Absorptionsbanden sind jedoch deutlich geringer ausgeprägt und werden bei frischen Blättern durch die Wasserabsorptionsbanden maskiert. Bei trockenen Blättern mit geringem Wassergehalt hingegen kommen die spektralen Charakteristika dieser biochemischen Stoffe deutlich zum Vorschein.

Das Reflexionsverhalten von Pflanzen unterliegt sowohl räumlichen als auch zeitlichen Schwankungen (vgl. Abb. 6). Neben dem Typ und dem Alter der Pflanze sind dabei vor allem der Vitalitäts- und Gesundheitszustand sowie phänologische Erscheinungen entscheidend (Kumar et al. 2002). Der Vitalitäts- und Gesundheitszustand kann unter anderem durch den Wassergehalt der Pflanze, die Ausprägung der Zellstruktur sowie den Pigmentgehalt charakterisiert werden. Das Auftreten von Schäden und Krankheiten spielt dabei ebenfalls eine Rolle. Aufgrund der Phänologie kann sich die spektrale Signatur einer Pflanze zudem in Abhängigkeit der Jahreszeiten deutlich ändern. Einen wesentlichen Einfluss hat der Belaubungszustand, der über Art und Menge der Blattpigmente bestimmt wird. Kurzzeitige Veränderungen des Reflexionsverhaltens können zum Beispiel auch während der Blütezeit oder der Zeit des Fruchttragens auftreten (Hildebrandt 1996).




Abbildung 6: Beispiele für zustandsabhängige Reflexionskurven von Buchenblättern: (1) Sonnenblatt (2) Schattenblatt (3) vergilbtes Blatt (4) fünf hintereinander angeordnete Buchenzweige (Hildebrandt 1996, S. 36).

Des Weiteren sind die Pflanzenarchitektur und die Oberflächenbeschaffenheit der Blätter maßgebend für das Reflexionsverhalten einer Pflanze (Hildebrandt 1996). Die Pflanzenarchitektur wird durch die Größe der Blattfläche, die Blattwinkelverteilung sowie den Aufbau des Sprosses und die Belaubungsdichte bestimmt. Die Blattoberfläche kann in Abhängigkeit des Vorkommens von Behaarung, Wachsschichten, Belägen (zum Beispiel Pilze) oder Blattverschmutzungen auch unterschiedliche Reflexionseigenschaften aufweisen (Kumar et al. 2002).

Die spektrale Reflexion von Pflanzenbeständen ist neben den pflanzenspezifischen Faktoren in Abhängigkeit der durch das Aufnahmesystem bestimmten Integrationsfläche pro Pixel ebenfalls an die strukturellen Gegebenheiten der Umgebung gekoppelt. Dazu zählt vor allem die Bestockungs- beziehungsweise Bestandsdichte, welche das Verhältnis der reflektierenden Komponenten bestimmt. Bei diesen Komponenten kann es sich um die Blätter der Pflanzen selbst, andere Pflanzenteile (zum Beispiel Stängel), nicht-

photosynthetisch aktives Material oder den durchschimmernden Boden handeln (Hildebrandt 1996). Die Bodenreflexion stellt dabei eine bedeutende Störquelle dar, die das Reflexionsverhalten von Pflanzenbeständen insbesondere bei geringen Bedeckungsgraden wesentlich beeinflussen kann. In Abhängigkeit der Beleuchtungssituation sowie der Wuchshöhe und der vertikalen Struktur des Bestands können die einzelnen Komponenten zudem von Schatten überlagert werden. Aufgrund der komplexen Struktur von Pflanzenbeständen ist das Reflexionsverhalten häufig durch Mehrfachstreuungen geprägt und kann mitunter deutlich richtungsabhängig sein. Die sich überlagernden Blattschichten führen zudem zu vermehrten Reflexionsvorgängen, wodurch die Reflexion im NIR gegenüber einzelnen Blättern deutlich höher ausfallen kann (Kumar et al. 2002). Eine weitere wichtige Rolle spielt die Artenzusammensetzung, also die Art und Form der Vergesellschaftung. Im Falle von landwirtschaftlichen Kulturen haben zum Beispiel auch die Orientierung und der Abstand der Saatreihen sowie die Art der Bewirtschaftung einen Einfluss auf das Reflexionsverhalten von Pflanzenbeständen (Hildebrandt 1996). Im Vergleich zu natürlichen heterogenen Pflanzenbedeckungen kann die räumliche spektrale Variabilität von Pflanzenbeständen hingegen deutlich geringer ausfallen.

2.2.2 Boden

Die Zusammensetzung von Böden ist durch die festen Bestandteile (Minerale, organische Substanzen, Bodenorganismen) sowie die mit Luft oder Wasser gefüllten Hohlräume (Poren) geprägt. Bei der Bodenbildung spielen das Ausgangsgestein, die durch das Klima bedingten Verwitterungserscheinungen, die Topographie, die vorherrschende Flora und Fauna sowie die anthropogene Nutzung eine bedeutende Rolle (Ben-Dor et al. 1999, Munzert und Frahm 2006). In Folge der komplexen Interaktion der genannten Faktoren können die Eigenschaften und somit auch das Reflexionsverhalten von Böden sowohl räumlich als auch zeitlich sehr stark variieren. Dabei wird die Bodenreflexion lediglich durch die obere Bodenschicht bestimmt, weshalb sich aus spektralen Messungen keine Informationen über tiefer liegende Bodenschichten ableiten lassen.

Die in Abbildung 7 dargestellten charakteristischen Reflexionskurven eines Sandbodens unterscheiden sich augenscheinlich von der spektralen Signatur der Vegetation und sind im Bereich von $0.4\mu\text{m}$ bis $1.2\mu\text{m}$ (VNIR) durch einen kontinuierlichen Anstieg geprägt (Eismann 2012). Der Spektralbereich des mittleren Infrarot (MIR) wird, wie auch das Vegetationsspektrum, durch die charakteristischen Wasserabsorptionsbanden beeinflusst. In Abhängigkeit einiger maßgebender Faktoren kann das Reflexionsverhalten von Böden jedoch deutlich variieren. Neben der Korngrößenverteilung und der Oberflächenbeschaffenheit sind dabei insbesondere die Bodenfeuchte, der Anteil an organischen Substanzen sowie die Mineralzusammensetzung von großer Bedeutung.

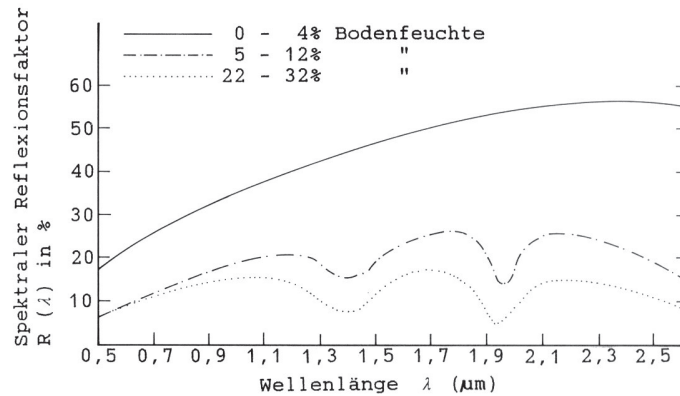


Abbildung 7: Reflexionskurven eines Sandbodens bei unterschiedlicher Bodenfeuchte (Hildebrandt 1996, S.62).

Die Bodenfeuchte hat einen beträchtlichen Einfluss auf die spektrale Reflexion des Bodens und kann in Abhängigkeit von Niederschlagsereignissen großen zeitlichen Schwankungen unterliegen (Bach 1995). Mit zunehmendem Wassergehalt des Bodens verringert sich die Reflexion über den gesamten Spektralbereich (Abb. 7), wobei sich starke Wasserabsorptionsbanden bei $1,45\mu\text{m}$ und $1,95\mu\text{m}$ und etwas schwächere bei $0,97\mu\text{m}$, $1,2\mu\text{m}$ und $1,77\mu\text{m}$ zunehmend ausprägen (Baumgardner et al. 1986). Von der Verteilung und der Form der Wasserabsorptionsbanden kann auf das Vorkommen von flüssigem Wasser oder Hydroxyl-Ionen sowie auf die Anordnung der Wassermoleküle geschlossen werden. Die reflexionsmindernde Wirkung stagniert bei ansteigendem Wassergehalt bei ungefähr 10-12% Bodenreflexion und ist zudem auch an die Konzentration organischer Substanzen, die Korngrößenverteilung und die Mineralzusammensetzung gekoppelt (Hildebrandt 1996).

Eine hohe Anreicherung organischer Substanzen (insbesondere Humusstoffe) wirkt auf die spektrale Signatur von Böden ebenfalls reflexionsmindernd. Maßgebend sind Art, Menge und Zusammensetzung der organischen Substanzen sowie auch der Zersetzungszustand. Das Vorkommen dieser Stoffe ist eng an die mineralischen Bestandteile des Bodens gekoppelt (Hildebrandt 1996). Bereits geringe Mengen ($> 2\%$) bewirken einen starken Effekt, wodurch andere Absorptionsmuster verdeckt werden können (Baumgardner et al. 1986). Bei einer Konzentration von mehr als 5% wird die Reflexionskurve soweit beeinflusst, dass sie anstatt eines sonst konvexen einen konkaven Verlauf im Bereich zwischen $0,5\mu\text{m}$ und $1,4\mu\text{m}$ aufweist (vgl. Abb. 8 Kurve A). Eindeutige charakteristische Absorptionsbanden zur Identifikation organischer Substanzen sind nicht bekannt (Bach 1995).

Bei einer hohen Konzentration bodenbildender Minerale wird die Bodenreflexion qualitativ durch deren artspezifische Reflexionseigenschaften bestimmt (Hildebrandt 1996). Diese Reflexionseigenschaften resultieren aus den charakteristischen Absorptionsban-

den der Minerale und sind überwiegend im mittleren Infrarot ausgeprägt (Bach 1995). Zu den bedeutenden Mineralen der Erdkruste zählen Silikate, Quarz, Karbonate und Tonminerale (Munzert und Frahm 2006). Aufgrund der Vielfalt an Mineralen und Mineralgemenge in Kombination mit unterschiedlichen Partikelgrößen ergeben sich diverse spektrale Reflexionskurven für Böden. Hunt 1977 liefert eine ausführliche Zusammenfassung zum spektralen Reflexionsverhalten bekannter Minerale. Untersuchungen haben gezeigt, dass die am häufigsten beobachteten spektralen Eigenschaften der Minerale an das Vorkommen von Eisen und Hydroxylgruppen gebunden sind. Ein hoher Eisen- beziehungsweise Eisenoxidgehalt zeichnet sich insbesondere durch einen steilen Anstieg der Reflexionskurve vom blau-violetten Spektralbereich zum NIR ab (vgl. Abb. 8 Kurven C und E). Zudem erscheinen bei $0.7\mu\text{m}$, $0.87\mu\text{m}$ und $1.0\mu\text{m}$ für Eisen charakteristische Absorptionsbanden, die durch Elektronenübergänge der Eisen-Ionen bedingt sind. Die spektrale Charakteristik von Hydroxylgruppen kommt durch die Absorptionsbanden im Bereich von $1.4\mu\text{m}$ und $1.9\mu\text{m}$ zum Ausdruck, die bei hohem Wassergehalt jedoch durch die Wasserabsorptionsbanden maskiert werden können (Bach 1995).

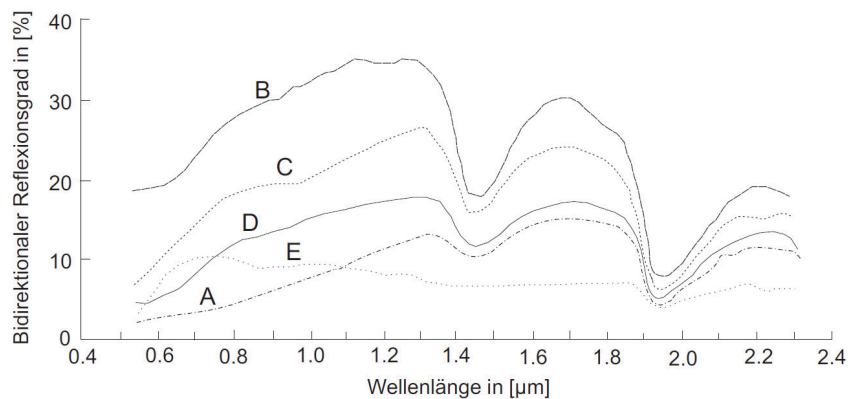


Abbildung 8: Fünf repräsentative Reflexionskurven von Böden: (A) hoher Gehalt organischer Substanzen (B) minimaler Gehalt organischer Substanzen und geringer Eisengehalt (C) mäßiger Gehalt an organischen Substanzen und an Eisen (D) mittlerer Gehalt organischer Substanzen und geringer Eisengehalt (E) mittlerer Gehalt organischer Substanzen und hoher Eisengehalt (verändert nach Stoner und Baumgardner 1981).

Der Zusammenhang zwischen Korngröße der Bodenteilchen und der Bodenreflexion gestaltet sich äußerst komplex und lässt sich nicht allgemeingültig beschreiben. Maßgebend sind neben der Form und der Größe der Bodenteilchen unter anderem auch die Art der beteiligten Bodensubstrate sowie die Aggregierungseigenschaften des Bodens. Generell wird bei abnehmender mittlerer Partikelgröße eine Zunahme der Reflexion für alle Wellenlängen beobachtet. In Folge dessen können auch andere feine spektrale Merkmale unterdrückt werden (Baumgardner et al. 1986). Ein entgegengesetztes Verhalten tritt bei Substraten mit geringer Reflexion auf, wobei sich die Bodenreflexion durch zunehmende Partikelgrößen erhöht. Bei Böden, die zur Bildung von Aggregaten tendieren, sind Form und Größe dieser Aggregate ausschlaggebend für das Reflexionsverhalten.

Deswegen erscheinen zum Beispiel Lehmböden trotz kleinerer Partikelgröße dunkler als Sandböden, die im Vergleich gröbere Körner aufweisen (Bach 1995).

Einen weiteren wesentlichen Einfluss auf das Reflexionsverhalten des Bodens hat die Oberflächenbeschaffenheit, die unter anderem durch den Steingehalt der Erdoberfläche, verwendete Bodenbearbeitungstechniken oder Niederschlagsereignisse beeinflusst werden kann. Die in der Landwirtschaft eingesetzten Bodenbearbeitungsverfahren (Pflügen, Eggen, Walzen) erhöhen in der Regel die Rauigkeit und führen zu einem fein strukturierten Relief des Bodens, wodurch der Schattenanteil zunimmt und die Bodenreflexion im Mittel reduziert wird (Hildebrandt 1996). In Folge wiederholter Überfahrten mit schweren Landmaschinen wird der Boden der Fahrgassen zudem zunehmend verdichtet, wodurch das Reflexionsverhalten ebenfalls beeinflusst wird. Eine Verdichtung des Bodens kann jedoch auch durch starke Niederschläge verursacht werden (Bach 1995). Im Gegensatz dazu kann ein Wassermangel zur Austrocknung des Bodens führen, wobei sich Risse und Verkrustungen ausbilden. Die Oberflächenstruktur eines Bodens ist demzufolge eng an die klimatischen Bedingungen, die Geländetopographie sowie die Art der Bodennutzung gekoppelt.

2.3 Vegetationsindizes

Bei der Interpretation von Fernerkundungsdaten stellen Vegetationsindizes (VI) ein bedeutendes Mittel zur qualitativen und quantitativen Analyse von vegetationsbedeckter Erdoberfläche dar. Die Indexberechnung erfolgt anhand geeigneter Kombinationen signifikanter Kanäle beziehungsweise Bänder, um Vegetation gegenüber vegetationsfreien Flächen hervorzuheben. Unter Ausnutzung des markanten spektralen Reflexionsverhaltens von Vegetation, beziehen sich diese Indizes in den meisten Fällen auf den Rot- und NIR-Bereich.

Vegetationsindizes spielen eine wichtige Rolle beim Monitoring und der Analyse der natürlichen oder durch anthropogene Einflüsse bedingten Entwicklung der Vegetationsbedeckung der Erde und kommen zum Beispiel bei Untersuchungen von Landnutzungsänderungen, phänologischen Erscheinungen oder zur Bestimmung des Bedeckungsgrads sowohl auf regionaler wie auch globaler Ebene zum Einsatz (Huete et al. 1994, Bannari et al. 1995). Darüber hinaus ermöglichen sie die Ableitung bedeutender Pflanzenparameter, die Rückschlüsse auf die Biomasseproduktion sowie den Vitalitätszustand der Pflanzen erlauben. Dies ist insbesondere in der Landwirtschaft von großer Bedeutung und ermöglicht Prognosen zum Ertrag landwirtschaftlicher Bestände oder die Optimierung von Bewirtschaftungsmethoden und des Betriebsmitteleinsatzes.

Die Aussagekraft der Vegetationsindizes ist jedoch sehr eng an das Fernerkundungssignal gekoppelt, das einigen Störeinflüssen unterliegt. Zu den Hauptfaktoren zählen die atmosphärischen Bedingungen, die Beobachtungs- und Beleuchtungsgeometrie sowie sensorspezifische Eigenschaften, wie die spektrale Übertragungsfunktion oder eine

Degradation des Sensors. Hinzu kommt der Einfluss des Bodenhintergrundsignals, der in Abhängigkeit der Bodenfarbe, -helligkeit und -feuchtigkeit variieren kann (Bannari et al. 1995). In Anbetracht dieser Störeinflüsse sowie einer möglichst guten Interpretation der VIs, sollte ein idealer Vegetationsindex maximale Sensitivität gegenüber grüner Vegetation aufweisen, unempfindlich gegenüber äußeren Störgrößen sein, den Einfluss des Bodenhintergrundsignals minimieren, einem globalen Maß entsprechen, um räumliche und zeitliche Vergleiche zu ermöglichen, und zusätzlich mit biochemischen und biophysikalischen Pflanzenparametern korrelieren (Huete et al. 1994). Gemäß dieser Anforderungen wurden seit den 70er Jahren zahlreiche Vegetationsindizes entwickelt, die mitunter sehr anwendungsspezifisch und aufgrund bestimmter Vor- und Nachteile oftmals nur bedingt übertragbar sind.

Nachfolgend werden einige bedeutende Vegetationsindizes vorgestellt, die sich in vier Gruppen unterteilen lassen. Anschließend erfolgt eine Erläuterung des Zusammenhangs zwischen den Vegetationsindizes und relevanten Pflanzenparametern sowie bekannter Ansätze zur Ableitung dieser Parameter.

2.3.1 Klassifizierung von Vegetationsindizes

In der Literatur sind verschiedene Möglichkeiten zur Einteilung von Vegetationsindizes zu finden (Bannari et al. 1995). Die folgende Übersicht ausgewählter Indizes nimmt eine Klassifizierung in vier Gruppen vor. Dazu zählen die frühen Entwicklungen, welche in die *Ratio Indizes* und die *orthogonalen Indizes* unterteilt werden können. Mit der fortschreitenden Kenntnis über bedeutende Störeinflüsse legte sich der Fokus bei der Entwicklung der VIs zunehmend auf die Eliminierung externer Faktoren, woraus die *boden- und atmosphärenkorrigierenden Vegetationsindizes* hervorgingen. Die zunehmende Verfügbarkeit hyperspektraler Daten führte schließlich zur Entwicklung schmalbandiger *hyperspektraler Vegetationsindizes*, die eine exaktere spektrale Analyse bestimmter Pflanzenparameter versprechen.

Ratio Indices

Zu den bekanntesten *Ratio Indizes* zählen der Ratio Vegetation Index (RVI; Pearson und Miller 1972)

$$RVI = \frac{\rho_R}{\rho_{NIR}}$$

sowie der bis heute am weitesten verbreitete Normalized Difference Vegetation Index (NDVI; Rouse Jr 1974, Rouse Jr 1972)

$$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}, \quad (2.1)$$

wobei ρ_R der Reflexion im roten Spektralbereich und ρ_{NIR} der Reflexion im NIR-Bereich entspricht. Diese beiden Indizes bewirken eine Kontrastverstärkung zwischen Boden und Vegetation, während der Einfluss durch variierende Beleuchtungsbedingungen (bedingt

durch Wolkenschatten, Topographie) minimiert wird (Baret und Guyot 1991). Sie gelten jedoch als anfällig für die optischen Eigenschaften des Bodenhintergrunds sowie für variierende atmosphärische Bedingungen und sind insbesondere bei geringer Vegetationsdichte schwer interpretierbar (Bannari et al. 1995, Rondeaux et al. 1996). Ein großer Nachteil liegt in dem sättigenden Verhalten bei hohem Biomassegehalt, wodurch Variationen des Vegetationssignals nicht mehr differenziert werden können.

Orthogonale Indizes

Die Entwicklung der orthogonalen Indizes erfolgte mit dem Ziel, den Effekt des Bodens zu minimieren. Dies erfolgt durch die Parametrisierung der spektralen Bodenlinie (*soil line*) im Rot-NIR-Merkmalraum. Kauth und Thomas 1976 sowie Richardson und Wiegand 1977 haben gezeigt, dass sich blanke Bodenpixel im Rot-NIR-Raum größtenteils entlang einer definierten Geraden, ausgehend vom Ursprung, ansammeln. Demzufolge kann die Bodenlinie für die Reflexion des Bodens im roten Spektralbereich $\rho_{R,soil}$ und im NIR-Bereich $\rho_{NIR,soil}$ anhand der Koeffizienten s_1 und s_2 mit

$$\rho_{NIR,soil} = s_1 \cdot \rho_{R,soil} + s_2 \quad (2.2)$$

beschrieben werden. Die Pixel hoher Vegetationsdichte sammeln sich hingegen im Bereich hoher NIR- und niedriger Rot-Werte an und werden im *Green Vegetation Point* (GVP) zusammengefasst (Abb. 9). Die graphische Veranschaulichung dieser Theorie entspricht einem Dreieck, aufgespannt vom GVP und der Bodenlinie, das auch als *Tasseld Cap* bezeichnet wird (Kauth und Thomas 1976). Alle Pixel zwischen der Bodenlinie und dem GVP sind demnach teilweise von Boden und Vegetation bedeckt, wobei der zunehmende Abstand zur Bodenlinie mit einer höheren Vegetationsdichte einhergeht.




Abbildung 9: Graphische Veranschaulichung des *Tasseld Cap* in Abhängigkeit der Bodenlinie (*soil line*) und des Punktes höchster Vegetationsdichte (GVP) im Rot-NIR-Merkmalraum.

Unter Berücksichtigung der spektralen Bodenlinie entwickelten Jackson et al. 1980 den Perpendicular Vegetation Index (PVI)

$$PVI = \frac{\rho_{NIR} - s_1 \cdot \rho_R - s_2}{\sqrt{s_1^2 + 1}},$$

der den senkrechten Abstand zu einer empirisch ermittelten oder modellierten Bodenlinie im NIR-Rot-Raum beschreibt. Einen weiteren Ansatz lieferte Clevers 1989 mit dem Weighted Difference Vegetation Index (WDVI)

$$WDVI = \rho_{NIR} - C \cdot \rho_R \quad (2.3)$$

unter Verwendung der bodenspezifischen Konstante $C = \rho_{NIR,soil} / \rho_{R,soil}$, die sich aus den Reflexionen des Bodens im Rot- und NIR-Bereich berechnet. Dieser Ansatz beruht auf der Annahme, dass das Verhältnis der Bodenreflexion zweier Spektralbereiche unabhängig von der Bodenfeuchte ist.

Diese Indizes liefern im Gegensatz zu den *Ratio Indizes* zwar zuverlässigere Ergebnisse bei geringen Bedeckungsgraden, jedoch unterliegen sie dennoch einem signifikanten Einfluss des Bodensignals (Rondeaux et al. 1996). Ursache hierfür ist die Annahme einer universellen Bodenlinie zur Beschreibung verschiedener Bodentypen und -zustände, wobei die räumliche und zeitliche spektrale Variabilität des Bodens nicht berücksichtigt werden kann (Bannari et al. 1995). Die orthogonalen Indizes weisen zudem ein eher lineares Verhalten und keine erheblichen Sättigungsprobleme auf (Richardson und Wiegand 1977).

Boden- und atmosphärenkorrigierende Indizes

Die Korrektur des Bodeneinflusses gewann bei der Entwicklung der Vegetationsindizes zunehmend an Bedeutung. In Folge dessen etablierte sich eine ganze Familie bodenkorrigierender VIs, dessen Grundstein Huete 1988 mit dem Soil Adjusted Vegetation Index (SAVI)

$$SAVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R + L} \cdot (1 + L)$$

legte. Dabei handelt es sich um eine Kombination aus NDVI und PVI, wobei der Einfluss des Bodens durch die Verwendung des Bodenkorrekturfaktors L reduziert wird. Für geringe Bedeckungsgrade wird $L = 1$ und bei hohen Vegetationsdichten hingegen $L = 0$ angenommen, womit der SAVI dem NDVI entspricht. Bei dazwischenliegenden unbekanntem Mischverhältnissen hat sich eine Korrektur von $L = 0.5$ als geeignet erwiesen.

Mit Bezug auf die charakteristische Bodenlinie (Gl. 2.2) wurde der Transformed Soil Adjusted Vegetation Index (TSAVI; Baret et al. 1989)

$$TSAVI = \frac{s_1 \cdot (\rho_{NIR} - s_1 \cdot \rho_R - s_2)}{\rho_R + s_1 \cdot (\rho_{NIR} - s_2) + X \cdot (1 + s_1^2)}$$

konzipiert, wobei der Einfluss des Bodens mit $X = 0.08$ minimiert werden kann (Baret und Guyot 1991). SAVI und TSAVI gelten als geeignete und vom Sensortyp unabhängige Indikatoren, um sowohl die Variationen der Vegetation sowie des Bodens zu beschreiben. Der TSAVI erweist sich unter Berücksichtigung der Bodenlinie jedoch als besserer

Indikator bei geringen Vegetationsdichten (Bannari et al. 1995). Eine weitere Abwandlung des SAVI lieferte Qi et al. 1994 mit dem Modified Soil Adjusted Vegetation Index (MSAVI)

$$MSAVI = \frac{2 \cdot \rho_{NIR} + 1 - \sqrt{(2 \cdot \rho_{NIR} + 1)^2 - 8 \cdot (\rho_{NIR} - \rho_R)}}{2},$$

wobei der Bodenkorrekturfaktor L dynamisch mit

$$L = 1 - 2 \cdot s_1 \cdot NDVI \cdot WDVI$$

und unter Verwendung des Koeffizienten s_1 der Bodenlinie (Gl. 2.2) modelliert wird. Rondeaux et al. 1996 hat in einer Studie gezeigt, dass die bodenkorrigierenden Vegetationsindizes (SAVI, TSAVI, MSAVI) den Einfluss des Bodens gegenüber dem klassischen NDVI reduzieren, bei geringen Vegetationsdichten jedoch trotzdem Ungenauigkeiten aufweisen. Das Hauptproblem liegt unter anderem auch hier in der Verwendung einer universellen Bodenlinie, die aufgrund der spektralen Variabilität des Bodens keine geeignete Repräsentation darstellt. Einen weiteren großen Einfluss hat die Wahl des Bodenkorrekturfaktors, der im Zuge der Untersuchungen optimiert wurde und woraus der Optimized SAVI (OSAVI) mit $L = 0.16$ hervorging.

Einen relativ jungen Ansatz lieferte Gilabert et al. 2002 mit dem General SAVI (GESAVI)

$$GESAVI = \frac{\rho_{NIR} - s_1 \cdot \rho_R - s_2}{\rho_R + Z_S},$$

der sich auf ein vereinfachtes Modell zur Beschreibung der Strahlungsvorgänge bei sich überlagernden Vegetationsschichten bezieht. Auf der Grundlage dieses Modells und der Bestimmung der Bodenlinie (Gl. 2.2) erfolgt die Berechnung des Bodenkorrekturfaktors Z_S . Die Untersuchungen haben gezeigt, dass die Ergebnisse eng an die ermittelte Bodenlinie geknüpft sind, die sich allerdings nur schlecht modellieren lässt.

Analog zu den bodenkorrigierenden Ansätzen erfolgte die Entwicklung der Vegetationsindizes ebenfalls in Hinblick auf die Reduktion des Einflusses atmosphärischer Bedingungen. Einen Ansatz lieferten Kaufman und Tanre 1992 mit dem Atmospherically Resistent Vegetation Index (ARVI)

$$ARVI = \frac{\rho_{NIR} - \rho_{RB}}{\rho_{NIR} + \rho_{RB}}.$$

Dabei handelt es sich um eine Modifikation des NDVI, wobei der Rot-Kanal ρ_R durch $\rho_{RB} = \rho_R - \gamma_A \cdot (\rho_B - \rho_R)$ ersetzt wird. Der Blau-Kanal ρ_B ist anfälliger für die wellenlängenabhängigen Aerosol-Effekte und wird hier neben der aerosolspezifischen Konstante γ_A verwendet, um den Rot-Kanal hinsichtlich variierender Atmosphärenbedingungen zu korrigieren. Die Autoren haben gezeigt, dass der ARVI einen ähnlichen

Dynamikumfang wie der NDVI aufweist, jedoch vier Mal weniger anfällig gegenüber atmosphärischen Effekten ist. Kaufman und Tanre 1992 empfehlen darüber hinaus die Kombination aus ARVI und SAVI: Soil-Adjusted and Atmospherically Resistant Vegetation Index (SARVI) und analog dazu die Kombination aus ARVI und TSAVI: TSARVI, um die atmosphärischen Effekte und gleichzeitig den Einfluss des Bodens zu korrigieren. Myneni und Asrar 1994 haben in einer vergleichenden Analyse gezeigt, dass die individuellen Korrekturen von SAVI und ARVI jedoch besser ausfallen, als die simultane Korrektur mit SARVI.

Einen alternativen Ansatz zur gekoppelten Korrektur der atmosphärischen Effekte sowie des Einflusses des Bodensignals lieferten Pinty und Verstraete 1992 mit dem nicht-linearen Global Environment Monitoring Index (GEMI)

$$GEMI = \eta \cdot (1 - 0.25 \cdot \eta) - \left(\frac{\rho_R - 0.125}{1 - \rho_R} \right)$$

$$\text{mit } \eta = \frac{2 \cdot (\rho_{NIR}^2 + \rho_R^2) + 1.5 \cdot \rho_{NIR} + 0.5 \cdot \rho_R}{\rho_{NIR} + \rho_R + 0.5}.$$

Dieser Index gilt als zuverlässiger Indikator bei hohen Vegetationsdichten und als unempfindlich gegenüber atmosphärischen Effekten, lässt sich aufgrund der komplexen Berechnung jedoch nur schwer interpretieren (Huete et al. 1994, Rondeaux et al. 1996). Der GEMI ist zudem anfällig für den Einfluss des Bodens und gilt für geringe Vegetationsdichten als nicht sehr zuverlässig (Bannari et al. 1995).

Ein weiterer boden- und atmosphärenkorrigierender Ansatz ist mit dem Enhanced Vegetation Index (EVI)

$$EVI = G \cdot \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + C_1 \cdot \rho_R - C_2 \cdot \rho_B + L}$$

gegeben, der speziell zur Verbesserung der Sensitivität für hohe Vegetationsdichten konzipiert wurde (Liu und Huete 1995, Huete et al. 1997). Dieser Index wurde als ein Standardprodukt des Moderate Resolution Imaging Spectroradiometer (MODIS) entwickelt (Justice et al. 1998). In die Berechnung fließen der Verstärkungsfaktor G , die Bodenkorrektur L und die Koeffizienten C_1 und C_2 zur Eliminierung der Aerosol-Effekte ein. Gemäß dem Konzept von Kaufman und Tanre 1992 erfolgt auch hier eine Korrektur des Rot-Kanals unter Verwendung des aerosolanfälligen Blau-Kanals. In der Literatur sind die Empfehlungen $G = 2.5$, $L = 1$, $C_1 = 6$ und $C_2 = 7.5$ zu finden, die sich bei der Untersuchung realer Daten wie auch in Modellsimulationen als robust erwiesen haben (Justice et al. 1998).

Im Vergleich zum NDVI erweist sich der EVI als deutlich unempfindlicher gegenüber dem Bodenhintergrund, nicht-photosynthetischem Material sowie atmosphärischen Effekten, und gilt auch bei hohem Biomassegehalt als sensitiv gegenüber Variationen der Vegetationsdichte (Huete et al. 2002). Ein wesentlicher Nachteil ist die Verwendung des

Blau-Kanals, der nicht bei jedem Sensorsystem gegeben ist (zum Beispiel AVHRR). Dieses Problem lösten Jiang et al. 2008 durch die Einführung des two-band EVI (EVI2), der sich ausschließlich auf das Rot- und NIR-Band bezieht, wodurch auch Langzeitanalysen zum Vegetationsmonitoring mit Satellitendaten vergangener Zeit ermöglicht wurden.

Hyperspektrale Indizes

Das mit der Zeit zunehmende Aufkommen von Hyperspektraldaten hat die Entwicklung von Vegetationsindizes wesentlich beeinflusst. Die hohe spektrale Auflösung ermöglicht eine deutlich differenziertere Analyse biochemischer und biophysikalischer Pflanzenparameter, die durch charakteristische Absorptionseigenschaften zum Ausdruck kommen und durch die Verwendung einzelner schmaler Bänder explizit angesprochen werden können. Einige Ansätze erfolgen in Anlehnung an die klassischen breitbandigen Indizes oder als deren Erweiterung, wobei der Schwerpunkt in der Wahl geeigneter Spektralbänder für die Indexberechnung liegt. Dies kann zum Beispiel anhand empirischer Messungen oder durch geeignete Korrelationsanalysen bezüglich des hervorzuhebenden Pflanzenparameters erfolgen (Thenkabail et al. 2012, Hansen und Schjoerring 2003). Zahlreiche Studien untersuchen die Korrelation bestimmter Bänder mit wichtigen Blattpigmenten (Chlorophylle, Carotinoide, Anthocyane), woraus spezielle hyperspektrale Vegetationsindizes hervorgegangen sind, die in verschiedenen Untersuchungen miteinander verglichen werden (Daughtry et al. 2000, Blackburn 1998a, Bannari et al. 2007, Haboudane et al. 2008). Dazu zählen zum Beispiel der Normalized Pigment Chlorophyll Index (NPCl; Peñuelas et al. 1994) und der Pigment Specific Normalized Difference Index (PSNDI; Blackburn 1998b). Andere Ansätze untersuchen die Abschätzung von Stickstoff, Lignin und Cellulose anhand von Regressionsanalysen (Kokaly und Clark 1999) oder die Bestimmung geeigneter Bänder zur Identifikation von Wassermangel und Pflanzenstress (Strachan et al. 2002). Alternative Ansätze basieren auf der Parametrisierung der roten Kante und der Bestimmung der *red edge position* (REP), die den steilsten Anstieg indiziert und unter anderem mit dem Chlorophyllgehalt korreliert (Horler et al. 1983, Blackburn 1998a). Eine Verschiebung des REP hin zu kürzeren Wellenlängen (*blue shift*) ist mit einer geringeren Pigmentabsorption im VIS und somit einer Abnahme des Chlorophyllgehalts verbunden, wohingegen die Verschiebung des REP hin zu den größeren Wellenlängen (*red shift*) eine Zunahme der Chlorophyllkonzentration indiziert (Broge und Mortensen 2002).

In der Literatur sind zahlreiche Empfehlungen hyperspektraler Vegetationsindizes zu finden, die oftmals aus sehr daten- und problemspezifischen Untersuchungen hervorgehen und sich somit auch nur bedingt übertragen lassen. Einige zusammenfassende Übersichten sind in den Arbeiten von Bannari et al. 2007, Stagakis et al. 2010 und Agapiou et al. 2012 zu finden.

2.3.2 Ableitung von Pflanzenparametern

Ein weit verbreiteter Ansatz zur Ableitung von Pflanzenparametern stützt sich auf die Verwendung von Vegetationsindizes. In zahlreichen Studien konnte die Korrelation zwischen verschiedenen Indizes und bedeutenden Pflanzenparametern, wie zum Beispiel dem Blattflächenindex (leaf area index, LAI), empirisch belegt werden. Der Blattflächenindex ist durch das Verhältnis der einseitigen grünen Blattfläche in Bezug auf eine horizontale Flächeneinheit definiert (Clevers und Verhoef 1993). Darüber hinaus werden häufig auch der Bedeckungsgrad, der Chlorophyllgehalt (Canopy Chlorophyll Density, CCD) sowie der für die Photosynthese zur Verfügung stehende und von der Pflanze absorbierte Strahlungsanteil (Fraction of Absorbed Photosynthetic Active Radiation, fAPAR) mit Hilfe von Vegetationsindizes abgeschätzt. Diese Parameter ermöglichen Rückschlüsse auf die Biomasseproduktion, das Pflanzenwachstum oder den Zustand der Pflanzen sowie auf Gasaustauschprozesse zwischen Oberfläche und Atmosphäre (Baret und Guyot 1991, Broge und Mortensen 2002, Yang et al. 2006), was beim Monitoring verschiedener Ökosysteme sowie in der Landwirtschaft von großer Bedeutung ist.

Neben den empirischen Ansätzen unter Verwendung von Vegetationsindizes gibt es auch physikalisch basierte Verfahren, die sich mitunter auf die Inversion von Strahlungstransportmodellen stützen (Verhoef 1984, Jacquemoud und Baret 1990) oder Ansätze der linearen spektralen Entmischung verfolgen (Settle und Drake 1993, Lelong et al. 1998), hier jedoch nicht näher betrachtet werden. In verschiedenen Studien, wie zum Beispiel in der von North 2002, werden die genannten Verfahren vergleichend gegenübergestellt.

Der Zusammenhang zwischen Vegetationsindizes und Pflanzenparametern wird üblicherweise anhand von spektralen Feld- oder Labormessungen und des Einsatzes von Regressionsanalysen empirisch ermittelt. In Folge dessen etablierten sich zahlreiche verschiedene funktionale Zusammenhänge, die sowohl linearer, quadratischer oder exponentieller Natur sind als auch durch Potenzfunktionen beschrieben werden können. Verschiedene mathematische Modelle wurden zum Beispiel von Wiegand et al. 1990 und Wiegand et al. 1992 zur Ableitung des LAI und der fAPAR für ausgewählte Vegetationsindizes am Beispiel von Mais und Weizen untersucht. Ähnliche Untersuchungen wurden auch für Gras sowie Laub- und Nadelwälder vorgenommen (Turner et al. 1999, Goetz 1997, Chen und Cihlar 1996). Andere Ansätze untersuchen zum Beispiel die empirische Abschätzung des Bedeckungsgrads anhand von linearen oder polynomialen Regressionsanalysen (Elvidge und Chen 1995, Bouman et al. 1992, Purevdorj et al. 1998).

Diese empirisch ermittelten Zusammenhänge variieren allerdings in Abhängigkeit des Pflanzentyps und sind oftmals sehr stark an die Aufnahmebedingungen (Sensortyp, Beobachtungs- und Beleuchtungsgeometrie, Atmosphäre, Bodenfeuchte) sowie an die regionsabhängigen pflanzenspezifischen Eigenschaften der spektralen Messungen gebunden, weshalb sie sich nur bedingt übertragen lassen.

In Anlehnung an das oftmals asymptotische Sättigungsverhalten von Vegetationsindizes entwickelten sich einige semi-empirische Ansätze unter Verwendung eines physikalischen Modells. Dabei wird üblicherweise der Zusammenhang zwischen spektralen Vegetationsindizes und dem LAI betrachtet, welcher in der Regel durch eine logarithmische Funktion beschrieben werden kann (Clevers 1986, Clevers 1988, Price 1992, Price und Bausch 1995, Baret und Guyot 1991). Ein häufig angewandtes Modell ist das von Baret und Guyot 1991, wobei der LAI als Funktion eines beliebigen Vegetationsindex VI aufgefasst wird

$$LAI = -\frac{1}{k_{VI}} \ln \left(\frac{VI - VI_{\infty}}{VI_{\infty} - VI_S} \right). \quad (2.4)$$

Der funktionale Zusammenhang wird mit Hilfe des Vegetationsindex von blankem Boden VI_S , des asymptotischen Grenzwerts des Vegetationsindex VI_{∞} sowie dem Extinktionskoeffizienten k_{VI} modelliert. Der Extinktionskoeffizient k_{VI} berücksichtigt die durch die Pflanzenschicht bedingte Abschwächung der Strahlungsvorgänge. Die Modellparameter VI_{∞} und k_{VI} sind abhängig von der Beleuchtungsstärke, der Beobachtungsgeometrie sowie der Blattwinkelverteilung und müssen wie auch die Bodenreflexion VI_S empirisch ermittelt werden. Broge und Mortensen 2002 untersuchen diesen Modellansatz zur Ableitung des Blattflächenindex und des Chlorophyllgehalts anhand einer Vielzahl verschiedener breitbandiger und hyperspektraler Vegetationsindizes, wobei sich der umgekehrte exponentielle Zusammenhang nur für den RVI (Pearson und Miller 1972) nicht bestätigt hat.

Einen weiteren semi-empirischen Ansatz lieferte Clevers 1986 und Clevers 1988 mit dem CLAIR-Modell (Clevers Leaf Area Index by Reflectance). Demnach wird der LAI mit Hilfe des WDVI (siehe Gl. 2.3) modelliert

$$LAI = -\frac{1}{k} \ln \left(1 - \frac{WDVI}{WDVI_{\infty}} \right), \quad (2.5)$$

wobei der Parameter k einer Kombination aus Extinktions- und Streukoeffizienten entspricht, den es zusammen mit dem asymptotischen Grenzwert $WDVI_{\infty}$ empirisch zu bestimmen gilt. Bouman et al. 1992 untersuchte die Abschätzung des LAI mit dem Modell von Clevers für unterschiedliche Bodentypen und Bodenfeuchten sowie Wachstumsbedingungen und ermittelte die Parameter $WDVI_{\infty}$ und k für verschiedene Fruchtarten (Kartoffeln, Rüben, Gerste, Weizen, Hafer). In einer Sensitivitätsanalyse wurde gezeigt, dass mit diesem Modell wesentliche Einflüsse, wie das Bodenhintergrundsignal sowie die Beleuchtungs- und Beobachtungsgeometrie, deutlich reduziert werden können, die Blattwinkelverteilung hingegen einen starken Einfluss auf die Ableitung des LAI haben kann (Clevers und Verhoef 1993).

Mit dem bekannten physikalischen Modell von Monsi und Saeki 1953 kann der Bodenbedeckungsgrad B mit

$$B = 1 - e^{(-k_S \cdot LAI)} \quad (2.6)$$

in Abhängigkeit des LAI und mit Hilfe des Extinktionskoeffizienten der solaren Einstrahlung k_S abgeleitet werden. Dieser Ansatz wurde in zahlreichen Studien aufgegriffen und konnte unter anderem für verschiedene landwirtschaftliche Fruchtarten belegt werden (Bouman et al. 1992, Clevers 1986, Baret et al. 1993).

Baret und Guyot 1991 leiten darüber hinaus auch einen physikalisch begründeten Zusammenhang zwischen der fAPAR und den Vegetationsindizes her. Dies erfolgt in Anlehnung an verschiedene empirische Modelle, welche die fAPAR häufig als exponentielle Funktion des LAI beschreiben, und in Kombination mit dem in Gleichung 2.4 beschriebenen Zusammenhang. Die absorbierte Strahlung P des photosynthetisch aktiven Wellenlängenbereichs (400 - 700nm) berechnet sich nach diesem semi-empirischen Modell mit

$$P = P_{\infty} \left[1 - \left(\frac{VI_{\infty} - VI}{VI_{\infty} - VI_S} \right)^{\frac{k_P}{k_{VI}}} \right]$$

in Abhängigkeit der absorbierten Strahlung bei sehr hoher Pflanzendichte P_{∞} , des Vegetationsindex von blankem Boden VI_S , des asymptotischen Grenzwertes VI_{∞} sowie der Extinktionskoeffizienten k_P und k_{VI} , die den exponentiellen Zusammenhang zwischen $P(LAI)$ beziehungsweise $VI(LAI)$ beschreiben. Die Untersuchungen von Baret und Guyot 1991 haben gezeigt, dass der Zusammenhang $P(VI)$ im Gegensatz zu $LAI(VI)$ auch bei hoher Pflanzendichte eine zuverlässige Abschätzung ermöglicht.

Mit dem Aufkommen hyperspektraler Indizes und unter der Ausnutzung signifikanter schmaler Bänder etablierten sich weitere empirische Ansätze zur Abschätzung mitunter ganz spezieller Pflanzenparameter, wie dem Chlorophyll-, Carotenoid- oder Wassergehalt (vgl. Hyperspektrale Indizes in Kapitel 2.3.1). Vergleichende Untersuchungen haben gezeigt, dass die Verwendung hyperspektraler Indizes keine wesentlichen Vorteile gegenüber herkömmlichen breitbandigen Indizes mit sich bringt, die Wahl des VI in Abhängigkeit des abzuschätzenden Parameters allerdings durchaus entscheidend sein kann (Elvidge und Chen 1995, Broge und Leblanc 2001, Thenkabail et al. 2000, Broge und Mortensen 2002). Zudem kann mit den Ansätzen zur Parametrisierung der roten Kante der Einfluss des Bodens sowie der Atmosphäre gegenüber klassischen Vegetationsindizes deutlich reduziert werden (Broge und Leblanc 2001, Elvidge und Chen 1995).

Die hier vorgestellten empirischen und semi-empirischen Modelle zur Ableitung von Pflanzenparametern konnten mit zahlreichen Studien belegt werden, jedoch unterliegen sie einigen Limitierungen, die einen operationellen Einsatz erschweren. Ein großer Nachteil liegt in der variablen Funktionsbeschreibung zur Modellierung der Pflanzenparameter sowie in der Verwendung empirisch ermittelter Koeffizienten, die in erster Linie vom Pflanzentyp abhängen (Qi et al. 2000). In Folge dessen gibt es keine universelle Funktion, die den Zusammenhang eines Pflanzenparameters für verschiedene

Vegetationstypen beschreiben kann. Darüber hinaus unterliegt das Reflexionsverhalten von Pflanzenschichten zahlreichen Einflüssen, was die Interpretation der Vegetationsindizes und somit eindeutige Rückschlüsse auf Pflanzenparameter erschwert. Dazu zählen unter anderem die pflanzenunspezifischen Einflüsse der Beleuchtungs- und Beobachtungsgeometrie, atmosphärischer Effekte sowie des Bodenhintergrundsignals, die durch die Verwendung geeigneter Indizes nur teilweise reduziert werden können. Des Weiteren ändert sich das Reflexionsverhalten in Abhängigkeit verschiedener struktureller und pflanzenspezifischer Faktoren, wie zum Beispiel der Pflanzenarchitektur, der Vergesellschaftung, der Blattwinkelverteilung, dem Schattenanteil und den optischen Eigenschaften der Blätter sowie anderer Pflanzenteile (Huete et al. 2002, Baret und Guyot 1991). Eine weitere Limitierung bei der Verwendung von VIs liegt in dem typischen asymptotischen Sättigungsverhalten bei hohem LAI, was keine ausreichende Differenzierung dichter Vegetation ermöglicht (Haboudane et al. 2004). Dieser Effekt kann hingegen durch die Verwendung von hyperspektralen Indizes reduziert werden, die eine bessere Sensitivität bei hohen LAI-Werten aufweisen (Thenkabail et al. 2012).

2.4 Spektrale Entmischung

Die spektrale Entmischung umfasst Methoden zur Analyse spektraler Signaturen unterschiedlicher Oberflächenbestandteile von Mischpixeln auf Subpixelniveau. Dies spielt bei der Auswertung geometrisch grob aufgelöster Fernerkundungsdaten, insbesondere in der Hyperspektralfernerkundung, eine wichtige Rolle. Ein Pixelspektrum setzt sich stets aus der Überlagerung mehrerer spektraler Signaturen zusammen, wobei die Anteile der durch ein Pixel abgedeckten Oberflächenmaterialien in Abhängigkeit der Bodenauflösung bestimmt werden (Abb. 10). Die in einem Mischpixel vorkommenden reinen Oberflächenmaterialien werden als Endmember (EM) bezeichnet.

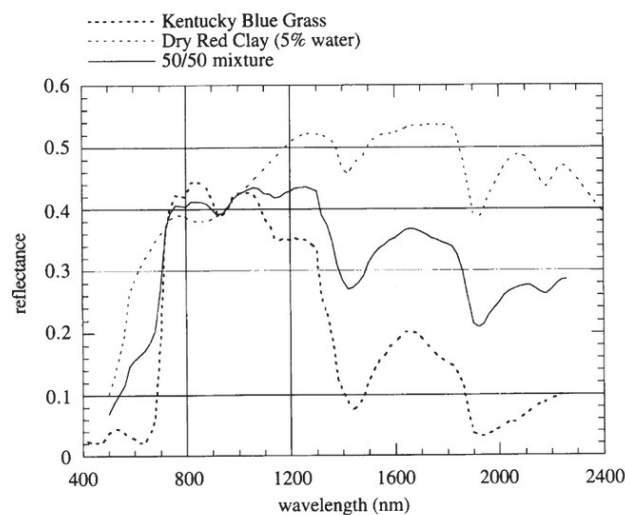


Abbildung 10: Beispiel für die lineare spektrale Zusammensetzung eines Mischpixels (Schowengerdt 2012).

Das Ziel der spektralen Entmischung ist die Identifizierung der im Pixel auftretenden Endmember sowie die Abschätzung ihrer relativen Flächenanteile innerhalb des Pixels (Abundanzen). Dabei wird zwischen linearen und nicht-linearen Entmischungsmodellen unterschieden. Die linearen Modelle stellen einen vereinfachten Ansatz dar, bei dem davon ausgegangen wird, dass die Photonen der einfallenden Strahlung jeweils lediglich mit einem Oberflächenmaterial interagieren. Nicht-lineare Entmischungsmodelle basieren hingegen auf den physikalischen Strahlungsvorgängen des Lichts unter Berücksichtigung multipler Streuung mit mehreren Materialien. Die Modellierung dieser komplexen Streu- und Reflexionsvorgänge birgt einige Herausforderungen und erfordert einen deutlichen Mehraufwand in der Umsetzung. Eine Übersicht verschiedener Ansätze zur nicht-linearen Entmischung liefert Bioucas-Dias et al. 2012 mit weiterführenden Literaturhinweisen. Die Thematik erhielt in bisherigen Studien allerdings weniger Aufmerksamkeit und gilt im Vergleich zur linearen Entmischung als unzureichend erforscht. Die lineare spektrale Entmischung fand hingegen in unzähligen wissenschaftlichen Untersuchungen Anwendung und wird trotz vereinfachter Darstellung der Lichtstreuungsvorgänge als akzeptabler Ansatz mit ausreichender Genauigkeit angesehen (Bioucas-Dias et al. 2012). Zudem wird der Einfluss nicht-linearer Faktoren oftmals als vernachlässigbar betrachtet und soll auch im Rahmen dieser Arbeit nicht weiter berücksichtigt werden.

Nachfolgend wird das Modell der linearen spektralen Entmischung vorgestellt und wichtige Aspekte bei der Bestimmung der für die Entmischung notwendigen Endmember erläutert. Abschließend erfolgt eine kurze Zusammenfassung der Thematik, wobei die Grenzen des linearen spektralen Entmischungsansatzes aufgezeigt werden.

2.4.1 Lineares spektrales Entmischungsmodell

Bei der linearen spektralen Entmischung wird ein Pixelspektrum als eine Linearkombination der Einzelspektren aller beteiligten Endmember aufgefasst. Die Gewichtung der Einzelspektren erfolgt jeweils proportional zum korrespondierenden relativen Flächenanteil im Pixel. Somit setzt sich die gemessene Reflexion r_j im Spektralband j aus der Summe der Reflexionswerte der Endmember e_{ij} zusammen, die jeweils durch ihren Flächenanteil a_i gewichtet werden

$$r_j = \sum_{i=1}^m a_i \cdot e_{ij} + \varepsilon_i .$$

Der Term ε_i entspricht dem Restfehler des Modells, der unter anderem auf nicht-lineare Einflüsse zurückzuführen ist.

Für alle n Spektralbänder eines Pixels und m Endmember ergibt sich demnach folgendes Gleichungssystem

$$\begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_n \end{pmatrix} = \begin{pmatrix} e_{11} & e_{12} & \dots & e_{1m} \\ e_{21} & e_{22} & \dots & e_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ e_{n1} & e_{n2} & \dots & e_{nm} \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_m \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

und somit

$$\vec{r} = \mathbb{M} \cdot \vec{a} + \vec{\varepsilon},$$

wobei die gemessenen Reflexionswerte r_j ($j = 1 \dots n$) im Vektor \vec{r} und die beteiligten Endmemberspektren \vec{e}_i ($i = 1 \dots m$) der Länge n in den Spalten der Mischungsmatrix \mathbb{M} zusammengefasst werden. Die Flächenverteilung der in dem Pixel vorherrschenden Endmember ist für jedes Spektralband gleich und wird durch den Vektor der Abundanzen \vec{a} beschrieben. Der Fehler des Modells wird durch den Fehlervektor $\vec{\varepsilon}$ ausgedrückt.

Im Rahmen der linearen spektralen Entmischung gilt es, geeignete Referenzspektren für die beteiligten Endmember zu bestimmen, die eine ausreichend gute Modellierung des Pixelspektrums ermöglichen. Diese Referenz- beziehungsweise Eingangsspektren bilden das so genannte Endmember-Modell. Mit der Kenntnis über diese Endmemberspektren \vec{e}_i können die Flächenanteile a_i durch Inversion des Modells bestimmt werden vorausgesetzt, es liegen mehr Beobachtungen als Unbekannte vor ($n > m$). In den meisten Fällen übersteigt die Zahl der zur Verfügung stehenden Spektralbänder jedoch deutlich die Anzahl der zu modellierenden Endmember ($n \gg m$). Somit handelt es sich um ein überbestimmtes Gleichungssystem, das einen Optimierungsansatz erfordert und zum Beispiel mit einem Ausgleichungsverfahren gelöst werden kann. Das Optimierungsproblem kann zudem durch weitere Nebenbedingungen ergänzt werden. Dazu zählen üblicherweise die Summenbedingung $\sum_{i=1}^m a_i = 1$ oder auch die Eingrenzung des Wertebereichs der Flächenanteile $0 \leq a_i \leq 1$ ($i = 1 \dots m$). Die Berücksichtigung der zweiten Bedingung wird in den Standardansätzen zur linearen spektralen Entmischung allerdings oftmals vernachlässigt, da die Behandlung von Ungleichungen in der Ausgleichungsrechnung ein komplexes Problem darstellt (Schramm 2010). Die lineare Unabhängigkeit der Eingangsspektren stellt einen wichtigen Aspekt bei der Inversion des Gleichungssystems dar. Stark korrelierte Spektren führen zu einer schlecht bedingten Mischungsmatrix \mathbb{M} . In Folge dessen ist das Modell viel anfälliger gegenüber Rauschen, was zu starken Genauigkeitsverlusten bei der Flächenabschätzung führen kann (Bioucas-Dias et al. 2012).

Abbildung 11 zeigt eine graphische Veranschaulichung des linearen Mischungsmodells für das Beispiel von drei Endmembers in einen dreidimensionalen Merkmalsraum (aufgespannt durch drei Kanäle). Innerhalb des Merkmalsraums befindet sich der durch




Abbildung 11: Graphische Darstellung des linearen Zusammenhangs dreier Endmember (hier \vec{s}_1 , \vec{s}_2 und \vec{s}_3) in einem dreidimensionalen Merkmalsraum (Schramm 2010).

die drei Endmember aufgespannte zweidimensionale Unterraum. Die Eckpunkte (rot) dieses Unterraums entsprechen den Endmemberspektren, die jeweils eine Referenz für ein pures Oberflächenmaterial darstellen. Innerhalb des Unterraums befinden sich alle Pixelspektren, die sich aus den drei Endmemberspektren zusammensetzen. Die relativen Anteile der einzelnen Endmember in einem Pixel ist durch die Lage des Pixelvektors und somit durch dessen Abstand zu den einzelnen Endmemberspektren bestimmt. Liegt dieser Vektor zum Beispiel auf einer der Kanten des Unterraums, so setzt sich das Pixelspektrum lediglich aus zwei Endmemberspektren zusammen. Demzufolge spannt ein Entmischungsmodell mit m Endmemberspektren einen $(m-1)$ -dimensionalen Unterraum auf, der sich innerhalb eines n -dimensionalen Merkmalsraums mit n Spektralbändern beziehungsweise Kanälen befindet. Dieser Unterraum stellt einen Simplex dar, dessen Eckpunkte den Endmemberspektren entsprechen und innerhalb dessen alle möglichen Mischpixelspektren liegen.

Neben sensorspezifischen Fehlern und möglichen Modellierungsfehlern aufgrund nicht-linearer Einflüsse hat die Wahl der Endmemberspektren den wohl größten Einfluss auf die Genauigkeit der Flächenabschätzung (Somers et al. 2011). Deswegen liegen die Herausforderungen der linearen spektralen Entmischung insbesondere in der Bestimmung der Endmember, wobei die Berücksichtigung der spektralen Variabilität einen sehr wichtigen Faktor darstellt.

2.4.2 Bestimmung von Endmembers

Die Bestimmung der Endmember umfasst die Identifizierung der Anzahl der im Pixel vorkommenden Oberflächenmaterialien sowie deren Referenzspektren. Dabei gilt es, einige wichtige Aspekte zu berücksichtigen, welche die Genauigkeit der Endmemberspektren und somit auch die Genauigkeit des daraus resultierenden Entmischungsmodells grundlegend beeinflussen.

Anzahl der Endmember

Eine Unter- oder Überschätzung der Anzahl der zu modellierenden Endmember kann zu erheblichen Fehlern bei der Flächenabschätzung führen. „Wird eine zu geringe Endmemberzahl zu Grunde gelegt, wird der Anteil von nicht modellierten Endmembers auf die modellierten und auf die Residuen aufaddiert. Bei zu vielen Endmembers wird das Modell anfällig für Sensorrauschen und die natürliche Variabilität der Spektren, so dass Anteile der Residuen fälschlicherweise als Endmemberanteile modelliert werden und die Genauigkeit des Ergebnisses zu optimistisch geschätzt wird“ (Schramm et al. 2008). Einige Ansätze zur Bestimmung der optimalen Endmemberzahl basieren entweder auf manuellen Tests oder vereinfachten Annahmen, wie der Minimierung der Endmemberanzahl (Zare und Ho 2014). Weitere Verfahren basieren auf speziellen Methoden zur Reduktion des Merkmalsraums und der Identifikation der Eigenvektoren, welche den signifikanten Unterraum aufspannen und somit ein Indiz für die Anzahl der vorkommenden Endmember darstellen (Bioucas-Dias und Nascimento 2008 und Chang und Du 2004). Die Untersuchungen dieser Ansätze erfolgten größtenteils daten- und problemspezifisch, wodurch deren Übertragbarkeit nur bedingt möglich ist. Die Wahl von drei bis fünf Endmembers pro Pixel hat sich allerdings in vielen Untersuchungen als geeignet erwiesen (García-Haro et al. 2005).

Art der Bestimmung

Zur Modellierung des Pixelspektrums gilt es, möglichst genaue Referenzspektren zu definieren. Diese Referenzspektren können entweder durch Feld- und Labormessungen sowie Spektralbibliotheken gegeben sein oder auch aus dem Datensatz selbst abgeleitet werden.

Bei der Verwendung von punktuellen Feld- und Labormessungen erfolgt in den meisten Fällen keine Berücksichtigung der zeitlichen und räumlichen spektralen Variabilität der Oberflächenmaterialien. Zudem können die Aufnahmegeometrie, variierende Beleuchtungsverhältnisse oder unerwünschte Hintergrundsignale erhebliche Messschwankungen bewirken. Ähnliche Probleme ergeben sich bei der Verwendung spektraler Bibliotheken (zum Beispiel USGS, ASTER), die oftmals auf Labor- und Feldmessungen beruhen. Zudem umfassen diese Bibliotheken häufig regional vorkommende Oberflächenmaterialien einer bestimmten Klimazone, was dessen Übertragbarkeit auf andere Untersuchungsgebiete und Problemstellungen einschränkt (Schramm 2010).

Hinsichtlich einer unüberwachten Extraktion der Endmember besteht die Möglichkeit, die Referenzspektren direkt aus dem Datensatz abzuleiten. Dazu gibt es verschiedene geometrische Ansätze, die größtenteils auf der Annahme beruhen, dass sich die Pixelspektren innerhalb des von den Endmembers aufgespannten Simplex befinden. Demzufolge können die Endmember durch die Identifizierung der Eckpunkte des Simplex bestimmt werden (Bioucas-Dias et al. 2012). Andere geometrische Ansätze setzen voraus, dass alle Endmember als reine Pixel im Datensatz vorliegen. Dazu zählen zum

Beispiel Pixel Purity Index (PPI, Boardman et al. 1995), Sequential Maximum Angle Convex Cone (SMACC, Gruninger et al. 2004) oder N-Finder (Winter 1999). Diese Voraussetzung muss bei anderen geometrischen Algorithmen wie MVSA (minimum volume simplex analysis, Li und Bioucas-Dias 2008) oder SISAL (simplex identification via split and augmented lagrangian, Bioucas-Dias 2009) hingegen nicht erfüllt sein. Einen alternativen Ansatz zur unüberwachten linearen spektralen Entmischung liefert Schramm 2010. Hier erfolgt die Bestimmung der Endmember durch die Ausnutzung der Pixelnachbarschaften und unter der Annahme, dass benachbarte Pixel im gleichen Unterraum liegen.

Spektrale Variabilität

Eine möglichst genaue Modellierung des Endmember-Modells erfordert zudem die Berücksichtigung der spektralen Variabilität. Abweichungen der spektralen Signatur von Oberflächenbestandteilen können auf verschiedene Ursachen zurückgeführt werden. Dazu zählen unter anderem wechselhafte Beleuchtungsverhältnisse, atmosphärische und temporale Bedingungen sowie intrinsische Eigenschaften des Materials selbst. In Folge dessen kann die spektrale Signatur von Oberflächenmaterialien innerhalb eines Datensatzes räumlich sehr stark variieren (Zare und Ho 2014).

Bei der Endmember-Bestimmung kann zwischen spektraler Variabilität innerhalb von EM-Klassen (*intra-class*) und zwischen den EM-Klassen (*inter-class*) unterschieden werden. Eine EM-Klasse beschreibt dabei eine Menge variierender spektraler Signaturen, die ein und demselben Oberflächenmaterial zugehörig sind. Eine hohe *inter-class* Variabilität der zu modellierenden Endmember führt zu gut aufgestellten Beobachtungsgleichungen und begünstigt die spektrale Entmischung. Eine hohe *intra-class* Variabilität erschwert hingegen die Bestimmung geeigneter Referenzspektren (Somers et al. 2011).

Im Fall der konventionellen linearen spektralen Entmischung wird die räumliche Endmember-Variabilität aufgrund der Verwendung eines festen Endmember-Sets für den gesamten Datensatz nicht berücksichtigt. Dies kann insbesondere bei heterogenen klein strukturierten Daten zu erheblichen Fehlern bei der Abschätzung der Abundanzen führen (Zare und Ho 2014). In Zuge dessen wurden zahlreiche Ansätze entwickelt, die den Fokus auf die Berücksichtigung der spektralen Variabilität bei der Endmember-Bestimmung setzen. Ein weit verbreiteter Ansatz ist das von Roberts et al. 1998 vorgestellte Verfahren MESMA (multiple endmember spectral unmixing analysis). Dieses Verfahren erlaubt eine Variation der Anzahl der Endmember und der Endmembertypen pro Pixel. Unter Verwendung von Spektralbibliotheken werden in einem iterativen Prozess pro Pixel verschiedene EM-Kombinationen gebildet und hinsichtlich ihrer Modellgenauigkeit miteinander verglichen. Die EM-Kombination, welche die geringsten Residuen zwischen gemessenem und rekonstruiertem Signal aufweist, wird als das optimale Modell bestimmt und zur Entmischung verwendet. Dabei kann die Anzahl der zu modellie-

renden Endmember variieren, wobei eine maximale Anzahl eingehalten wird. In einigen Ansätzen erfolgt zudem eine Eingrenzung der möglichen Endmember mit Hilfe von Vorwissen, wobei die Genauigkeit des Modells erhöht werden kann. Der MESMA-Ansatz bietet somit die Möglichkeit, mehr Endmember innerhalb eines Datensatzes zu modellieren als Kanäle beziehungsweise Bänder zur Verfügung stehen. Zudem kann die spektrale Variabilität eines Oberflächenmaterials durch die Verwendung verschiedener Referenzspektren berücksichtigt und Ungenauigkeiten durch schlecht geschätzte Endmemberanzahlen aufgrund der räumlichen Anpassung des Modells verringert werden. Die zeitliche spektrale Variabilität kann darüber hinaus zum Beispiel durch die zusätzliche Einbindung von zeitlich unterschiedlichen Messungen in die Spektralbibliothek berücksichtigt werden. Mit zunehmendem Umfang dieser Bibliotheken steigt allerdings auch der Rechenaufwand zur Untersuchung aller möglichen Endmember-Kombinationen. Zudem erhöht es die Wahrscheinlichkeit, dass mehrere Spektren zur gleichen Modellgenauigkeit führen, was die Bestimmung eines optimalen Referenzspektrums erschwert (Schramm 2010).

Neben der Verwendung multipler Endmember gibt es einige weitere Ansätze zur Reduktion beziehungsweise Berücksichtigung der spektralen Variabilität. Dazu zählt zum Beispiel die Verwendung von so genannten Endmember-Bundles (Bateson et al. 2000). In diesem Fall werden die einzelnen Endmember jeweils durch eine Menge von Spektren repräsentiert, wobei die Flächenabschätzung unter Berücksichtigung der minimal und maximal möglichen Flächenanteile erfolgt. Andere Methoden basieren hingegen auf der Gewichtung bestimmter signifikanter Spektralbänder oder einer Transformation der Endmemberspektren, um deren Anfälligkeit gegenüber der spektralen Variabilität zu verringern. Einen weiteren Ansatz stellen stochastische Entmischungsmodelle dar, wobei die Endmemberspektren als multivariate statistische Verteilungen angesehen werden. In der Literatur gibt es verschiedene Kategorisierungen dieser und weiterer Methoden. Zusammenfassende Übersichtsarbeiten liefern zum Beispiel Somers et al. 2011, Zare und Ho 2014 sowie Drumetz et al. 2016.

Schatten

Eine weitere Herausforderung bei der Endmember-Bestimmung liegt in der Berücksichtigung von Schatten. Bedingt durch den Sonnenstand sowie die Topographie des Geländes können variierende Beleuchtungsverhältnisse auftreten, die das Spektralverhalten der Oberflächenbestandteile beeinflussen. Ein möglicher Ansatz stellt die Modellierung der Schattenanteile durch einen zusätzlichen Endmember dar. Die Schwierigkeit liegt dabei in der Definition des Referenzspektrums, welches stets an das darunterliegende Oberflächenmaterial gekoppelt ist. In einigen Untersuchungen wird ein konstantes Schattenspektrum von 0% oder 10% Reflexion verwendet (Luciano et al. 1998, García-Haro et al. 2005), wobei die spektrale Variabilität des Schattens allerdings nicht berücksichtigt wird. Diese ist neben den Reflexionseigenschaften der darunter liegen-

den Materialien auch an die Transmissions- und Reflexionsprozesse darüberliegender Materialien gekoppelt. In Folge dessen kann die Reflexion beschatteten Bodens innerhalb eines Pflanzenbestands zum Beispiel räumlich sehr stark variieren (García-Haro et al. 2005). Des Weiteren kann die Verwendung einer Schattenkomponente zu einer Fehlinterpretation des Entmischungsmodells führen, wenn der berechnete Schattenanteil lediglich der mathematischen Lösung des Optimierungsproblems zur Einhaltung der Summenbedingung entspricht (Gruninger et al. 2001).

Lu und Weng 2004 liefern einen alternativen Ansatz zur Modellierung der Schattenkomponente, bei dem das Schattenspektrum mit dem von klarem tiefem Wasser gleichgesetzt wird. Die Anwendung dieser Methode beschränkt sich allerdings auf Datensätze, die dementsprechend auch geeignete Referenzflächen zur Bestimmung der Wasserreflexion aufweisen.

2.4.3 Grenzen der spektralen Entmischung

Die spektrale Entmischung stellt eine sehr bedeutende und lang erforschte Problematik im Rahmen der Subpixelanalyse von Fernerkundungsdaten dar. Im Laufe der Zeit wurden unzählige Ansätze zu dieser Thematik entwickelt, wobei sich die Mehrzahl der Arbeiten auf lineare spektrale Entmischungsmodelle stützt. Zahlreiche Studien haben gezeigt, dass die Genauigkeit dieser Modelle sehr stark an die Wahl der Endmemberspektren sowie die Endmemberzahl gekoppelt ist. Bisherige Untersuchungen zur Bestimmung der optimalen Endmemberzahl erlauben jedoch keine allgemeingültige Schlussfolgerung, da sie größtenteils empirisch oder datenspezifisch erfolgen. Eine Möglichkeit zur Reduktion dieser Ungenauigkeit besteht hingegen durch die Verwendung von Vorwissen über das potentielle Auftreten der Endmember (Schramm 2010). Die Genauigkeit der Endmemberspektren stellt im Rahmen der spektralen Entmischung die wohl größte Ungenauigkeit dar. Dabei wird die Qualität der zur Verfügung stehenden Referenzspektren in erster Linie durch die Art der Bestimmung bedingt, wobei die gängigen Vorgehensweisen allesamt bestimmten Einschränkungen unterliegen. Die Bereitstellung beziehungsweise Erhebung von Feld- oder Labormessungen kann zum Beispiel nicht für jeden Fernerkundungsdatensatz und die darin enthaltenen Oberflächenmaterialien gewährleistet werden. Weitere Einschränkungen ergeben sich aus den bereits genannten Problemen in Hinblick auf die spektrale Variabilität und die Anfälligkeit für Messschwankungen. Bei der Verwendung von Spektralbibliotheken ist die Genauigkeit der spektralen Entmischung sehr stark an die in der Bibliothek enthaltenen Oberflächenmaterialien sowie die spektrale Diversität dieser Referenzspektren gekoppelt. Die Analyse sehr umfangreicher Spektralbibliotheken stellt wiederum hohe Anforderungen an die Rechenleistung und erhöht die Wahrscheinlichkeit der linearen Abhängigkeit zwischen den in der Bibliothek enthaltenen Spektren. Die Endmember-Extraktion aus den Daten selbst ist in Abhängigkeit des gewählten Verfahrens aufgrund notwendiger Voraussetzungen auch nicht immer möglich. Sollten diese Voraussetzungen jedoch erfüllt sein, so ist die Genauigkeit der

Endmember-Bestimmung immer noch von der Wahl des Verfahrens sowie den gegebenen Daten abhängig, wobei die Bestimmung unerwünschter oder falscher Endmember nicht ausgeschlossen werden kann.

Letztendlich entspricht die Berücksichtigung der spektralen Variabilität einer sehr großen Herausforderung, der in der Literatur mit vielen verschiedenen Ansätzen begegnet wird. Nichtsdestotrotz gibt es viele ausstehende Probleme, die es mit weiteren Studien zu untersuchen gilt. Dazu zählen unter anderem die Berücksichtigung nicht-linearer Einflüsse, physikalisch korrekte Methoden zur Modellierung von Schatten, die Reduktion des Rechenaufwands sowie robuste stabile Ansätze zur Automatisierung (Zare und Ho 2014).

Die Möglichkeiten der spektralen Entmischung von Multispektraldaten können in Abhängigkeit der spektralen Auflösung eingeschränkt werden. Im ungünstigsten Fall erlauben die wenigen durch die Multispektralsensoren zur Verfügung stehenden Kanäle keine ausreichende Differenzierung verschiedener Oberflächenmaterialien. Der damit verbundene Genauigkeitsverlust führt zu einer Homogenisierung der im Pixel enthaltenen Endmember, wodurch keine genaue Subpixel-Analyse möglich ist. Dieser Effekt kann bei Oberflächenmaterialien mit kleinräumig stark variierenden spektralen Signaturen allerdings auch von Vorteil sein (Schramm 2010). Bei grob strukturierten Multispektraldaten liefert die spektrale Entmischung dennoch ausreichend genaue Ergebnisse, was in vielen Studien erfolgreich demonstriert wurde. Dies ist allerdings immer an die geometrische Auflösung sowie die Heterogenität des Untersuchungsgebiets gekoppelt.

3 Konzeption der Methodik

In diesem Kapitel erfolgt die Konzeption der zu erarbeitenden Methode anhand der gegebenen Ausgangsproblematik, welche durch die Datengrundlage sowie die Charakteristik des Untersuchungsgebiets bestimmt wird. Die grundlegende Idee zur Extraktion des Bodenspektrums sowie der angestrebte Entmischungsansatz werden in den Vorüberlegungen vorgestellt. Daran anschließend erfolgt der Entwurf eines Fahrspurmodells, welches dem Entmischungsansatz zugrunde gelegt wird. Abschließend wird die allgemeine Vorgehensweise der Methodik als Übersicht in einer Prozesskette zusammengefasst.

3.1 Datengrundlage

Die zur Verfügung stehenden Daten stammen von einer Befliegung des Testfelds DEMMIN unter dem Einsatz eines Hyperspektralsensors. Bei diesem Testfeld handelt es sich um den Kalibrations- und Validationsstandort des DLR Neustrelitz, der für wissenschaftliche Anwendungen in der Fernerkundung genutzt wird (Gerighausen et al. 2009, Borg et al. 2009). Er befindet sich in Mecklenburg-Vorpommern nahe der Stadt Demmin mit einer Ausdehnung von circa $50\text{km} \times 50\text{km}$ und umfasst überwiegend landwirtschaftlich genutzte Ackerflächen (Abb. 12).

Mit der Durchführung von Messkampagnen und durch das Automatische Agrarmeteorologische Wetternetz (AAMW) werden in dem Testfeld in-situ-Daten erhoben, die der Validierung von Fernerkundungsdaten dienen. Im Rahmen der Messkampagnen werden an verschiedenen landwirtschaftlichen Kulturen unter anderem der Chlorophyllgehalt, der Blattflächenindex, die Sonneneinstrahlung sowie die Wuchshöhe und der Bedeckungsgrad gemessen. Zu den angebauten Fruchtarten zählen überwiegend Wintergetreide wie zum Beispiel Winterweizen, -gerste und -roggen sowie Mais, Zuckerrüben und Kartoffeln.

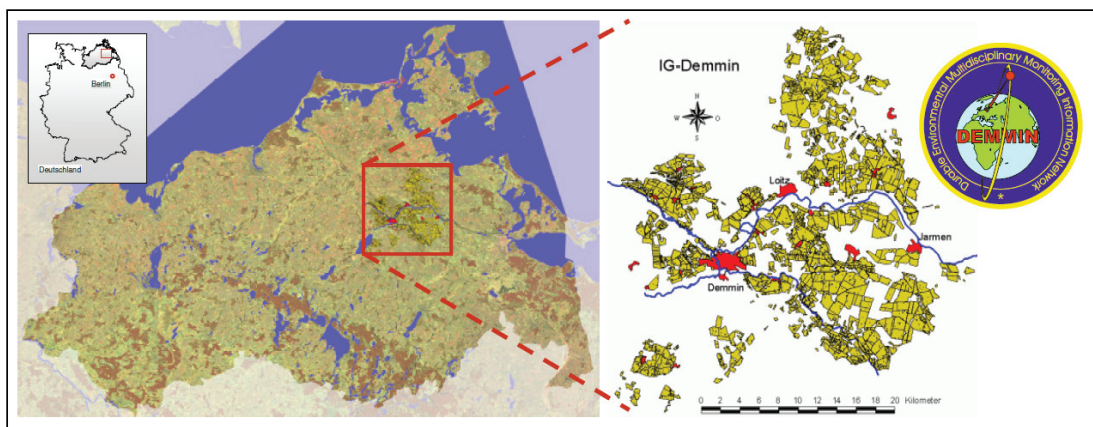


Abbildung 12: Lage des Testfelds DEMMIN (Borg et al. 2009).

Die gegebenen Hyperspektraldaten wurden am 11. Juli 2014 unter Verwendung des luftgestützten Sensorsystems HySpex (Köhler 2016) aufgenommen. Dieses System umfasst

die zwei Sensoren *HySpex VNIR-1600* und *HySpex SWIR-320m-e* des Herstellers *Norsk Elektro Optikk*. Mit dieser Kombination werden insgesamt 416 Spektralbänder im Bereich zwischen $400nm$ und $2500nm$ aufgezeichnet, deren Bandbreiten zwischen $4.4nm$ und $6nm$ variieren. Die Befliegung erfolgte in einer Höhe von circa $2600km$ und die daraus resultierende geometrische Bodenauflösung beträgt $4m$. Weitere Sensordaten sind der technischen Spezifikation des HySpex-Sensorsystems zu entnehmen (Anhang A).

Die Aufbereitung der Daten erfolgte durch die Kollegin Frau Stefanie Holzwarth des DLR-Standorts Oberpfaffenhofen unter Verwendung des Atmosphärenkorrekturprogramms ATCOR 4 (Version 7.0, Build 109). Bei der Prozessierung wurde eine Umrechnung der Sensor-Rohdaten (Digital Numbers) zu den am Sensor gemessenen Strahllichtwerten (Radianzen) vorgenommen. Anschließend wurden die Radianzen durch die Korrektur der Atmosphäreinflüsse zu scheinbaren Reflexionsgraden der Erdoberfläche überführt. Die Beseitigung geometrischer Verzerrungen erfolgte mit Hilfe einer direkten Georeferenzierung. Schatten, Dunst, Sonnenschimmern und Cirruswolken wurden bei der Prozessierung nicht entfernt. Die expliziten Arbeitsschritte der Datenaufbereitung können Richter und Schläpfer 2016, unter Berücksichtigung der verwendeten Prozessparameter (siehe Log-Datei, Anhang B), entnommen werden. Des Weiteren wurden die überschüssigen Bänder des Überlappungsbereichs der beiden HySpex-Sensoren zwischen $968nm$ und $986nm$ entfernt, wodurch insgesamt 412 Bänder für die Datenauswertung zur Verfügung stehen.

3.2 Charakteristik des Untersuchungsgebiets

Bei den potentiellen Untersuchungsgebieten zur Extraktion des Bodensignals handelt es sich um landwirtschaftliche Flächen während der Wachstumsperiode, die allesamt eine typische strukturelle Charakteristik aufweisen. Eine zusammenhängend landwirtschaftlich genutzte Fläche zum Anbau von Kulturpflanzen wird auch als Acker oder Schlag bezeichnet und setzt sich aus dem Pflanzenbestand, den Fahrgassen sowie möglichen Strukturelementen zusammen.



Abbildung 13: Beispiel einer Fahrgasse mit Pflanzenbestand zwischen den beiden Fahrspuren (Agrarservice MVP GmbH & Co.KG o. J.).

Die Fahrgassen dienen der Bewirtschaftung des Pflanzenbestands und ermöglichen ein weitgehend überlappungsfreies Ausbringen von Pflanzenschutz- und Düngemitteln, wobei der Schaden am Bestand durch die Gerätschaften möglichst gering gehalten wird. Eine Fahrgasse besteht aus zwei pflanzenfreien Fahrspuren (Lichtschächten) und einem dazwischenliegenden Streifen, auf dem sich ebenfalls Pflanzenbestand befinden kann (Abb. 13). Das Anlegen der Fahrgassen erfolgt in der Regel parallel zur Seite der größeren räumlichen Ausdehnung des Schlags und in einem Abstand, der durch die größte Arbeitsbreite der verwendeten Landmaschinen bestimmt wird. Bei der Arbeitsbreite handelt es sich um die Spannweite einer Landmaschine, die bei der Bewirtschaftung des Schlags (Düngen, Pflanzenschutz, etc.) zum Einsatz kommt. Der Bereich am Ende einer Fahrgasse, in dem die Landmaschinen wenden, um die nächste Fahrgasse zu erreichen, wird als Vorgewende bezeichnet. Auch innerhalb des Schlags können Vorgewende, auch Wendeschleifen genannt, zum Richtungswechsel der Landmaschinen auf ein und derselben Fahrgasse auftreten. Solche Wendeschleifen werden allerdings selten gefahren, um den Schaden am Bestand zu vermeiden und eine Schädigung des Bodens durch Verdichtung zu minimieren. Innerhalb sowie am Rand eines Schlags können sich Strukturelemente befinden, welche die zu bewirtschaftende Fläche eingrenzen und von den Landmaschinen umfahren werden müssen. Diese Strukturelemente können in Elemente der Kulturlandschaft, wie zum Beispiel Sölle, Hecken, Feldgehölze sowie Felldraine, und in anthropogene Elemente, wie Strommasten und Windräder, unterteilt werden.

3.3 Vorbetrachtungen

Anhand der gegebenen Datengrundlage sowie der Charakteristik des Untersuchungsgebiets gilt es, eine geeignete Vorgehensweise zur Extraktion des Bodensignals zu erarbeiten. Da die Entwicklung und Untersuchung der Methodik im Rahmen dieser Arbeit im Vordergrund steht, werden dabei keine anwendungsspezifischen Anforderungen gestellt. Hinsichtlich des übergeordneten Ziels der hier zu untersuchenden Methode soll bei der Ermittlung des Bodensignals jedoch ein möglichst guter Orts- und Zeitbezug zu dem zu korrigierenden Vegetationssignal des Pflanzenbestands hergestellt werden, um sowohl die räumliche als auch die zeitliche spektrale Variabilität des Bodens zu berücksichtigen. In Folge dessen wird die Verwendung zusätzlicher Datenprodukte desselben Untersuchungsgebiets, aber unterschiedlicher Zeitpunkte (zum Beispiel spektrale Messungen des blanken Bodens nach der Ernte), ausgeschlossen. Stattdessen soll das Bodensignal direkt aus den zu untersuchenden Fernerkundungsdaten, also während der Wachstumsperiode, abgeleitet werden.

Eine Möglichkeit stellt die Detektion einer Referenzfläche mit unbedecktem Boden in der Nähe des Schlags dar. Die Existenz ausreichend großer Referenzflächen ist jedoch an das Untersuchungsgebiet sowie die geometrische Auflösung der Daten gekoppelt und kann nicht in jedem Fall garantiert werden. Des Weiteren entspricht ein solches ortsspezifisches Bodensignal keiner guten Referenz für den Boden innerhalb des Schlags, welcher

mitunter einer sehr kleinräumigen spektralen Variabilität unterliegen kann. Besser geeignet erscheint der unbedeckte Boden der Fahrspuren, die sich aufgrund der typischen Charakteristik landwirtschaftlicher Flächen über den gesamten Schlag ausdehnen. Da mit der Ausnutzung der Fahrspuren ein möglichst guter Orts- und Zeitbezug zu dem zu korrigierenden Pflanzenbestand hergestellt wird, soll dieser Ansatz im Rahmen der Arbeit aufgegriffen werden. Dies unterliegt der Annahme, dass der Boden innerhalb des Bestands mit dem Signal der Fahrspuren ausreichend gut angenähert werden kann. In der Realität ist jedoch mit Unterschieden des Spektralverhaltens zu rechnen, da der Boden der Fahrspuren mitunter deutlich anderen Umwelteinflüssen ausgesetzt ist. So wirken sich zum Beispiel Niederschlagsereignisse auf den Boden der blanken Fahrspuren deutlich anders aus, als auf dem pflanzenbedeckten Untergrund im Bestand. In Folge der Bewirtschaftung kann der Boden des Pflanzenbestands zudem einer deutlich erhöhten Zufuhr von Nährstoffen und Chemikalien unterliegen, während die Fahrspuren aufgrund wiederholter Überfahrten mit großer Wahrscheinlichkeit durch Verdichtung sowie eine ausgeprägte Oberflächenstruktur der Fahrrinnen geprägt sind. Mit der Aussicht, anhand der Fahrspuren trotzdem ein ausreichend genaues Bodensignal ermitteln zu können, sollen mögliche Abweichungen des Reflexionsverhaltens bei der Erarbeitung der Methode zunächst vernachlässigt werden.

Bei der geometrischen Auflösung der zur Verfügung stehenden Hyperspektraldaten erscheinen die Fahrspuren beziehungsweise Fahrgassen in Form von Mischpixeln, bestehend aus Fahrspur und angrenzendem Pflanzenbestand. Demzufolge liegt der Schwerpunkt der Methode zur Extraktion des Bodensignals in einer geeigneten Subpixelanalyse der Fahrgassenpixel. Dies kann in Anbetracht der hohen spektralen Auflösung der gegebenen Daten durch einen spektralen Entmischungsansatz erfolgen. Da die gängigen Methoden zur linearen spektralen Entmischung jedoch wesentlichen Ungenauigkeiten unterliegen können und sich oftmals nicht so einfach übertragen lassen (vgl. Kapitel 2.4.3), soll hier auf der Grundlage von Borg 2016 ein modifizierter Ansatz betrachtet werden. Dieser Ansatz basiert auf vereinfachten Modellannahmen und setzt die Kenntnis über die zu entmischenden Fahrgassenpixel sowie die Fahrspurgeometrie voraus. Mit der Identifikation der Fahrgassenpixel kann das lineare Entmischungsmodell auf zwei Oberflächenmaterialien, den Boden der Fahrspuren und den Pflanzenbestand, vereinfacht und fixiert werden. Die Modifikation des Ansatzes liegt darin, dass die Flächenverteilung der Mischpixel als gegeben vorausgesetzt wird und das Ergebnis der Entmischung das gesuchte Bodenspektrum liefert. Somit gilt es lediglich, die Referenzspektren für den anteiligen Pflanzenbestand in den Fahrgassenpixeln zu bestimmen, welche direkt aus den Daten abgeleitet werden können. Die Flächenverteilung soll mit Hilfe eines Fahrspurmodells und durch eine geometrische Analyse der Fahrgassenpixel abgeschätzt werden. Mit den daraus resultierenden Abundanzen und einem aus den Daten abgeleiteten Bestandsreferenzsignal verspricht eine Umkehrung des mathematischen Modells der linearen spektralen Entmischung das Bodenspektrum bestimmen zu können.

Eine erfolgreiche Umsetzung dieses Ansatzes mit anschließender räumlicher Interpolation des extrahierten Bodensignals bietet nach dem Modell von Clevers 1988 (gemäß Gl. 2.5) schließlich eine Möglichkeit zur verbesserten Abschätzung des Blattflächenindex und darüber hinaus des Bedeckungsgrads (gemäß Gl. 2.6) nach Monsi und Saeki 1953 (siehe Abb. 14). Mit der Kenntnis über die flächenhafte Bodenreflexion lässt sich die bodenspezifische Konstante und somit auch der WDVI für jede Stelle beziehungsweise jedes Pixel der Ackerfläche bestimmen. Im Vergleich zur Verwendung einer empirisch ermittelten Bodenlinie, wird damit eine bessere Modellierung des Bodens unter Berücksichtigung der zeitlichen und räumlichen spektralen Variabilität erwartet. Unter der Annahme, dass die Bodenreflexion möglichst gut angenähert und der Bodeneinfluss bei der Berechnung des WDVI somit weitestgehend reduziert werden kann, ist nach dem Modell von Clevers demnach mit einer zuverlässigeren Abschätzung der beiden Pflanzenparameter zu rechnen. Dies erfordert allerdings trotzdem die empirische Ermittlung der Modellparameter k und $WDVI_{\infty}$, die in Abhängigkeit der Fruchtart sowie weiteren Faktoren variieren und sich deswegen oftmals nicht auf andere Untersuchungsgebiete oder Wachstumsperioden übertragen lassen. Nichtsdestotrotz verspricht die Kenntnis über das Bodensignal eine bessere Modellierung des Bodeneinflusses und in Folge dessen eine genauere Interpretation des Vegetationsindex.

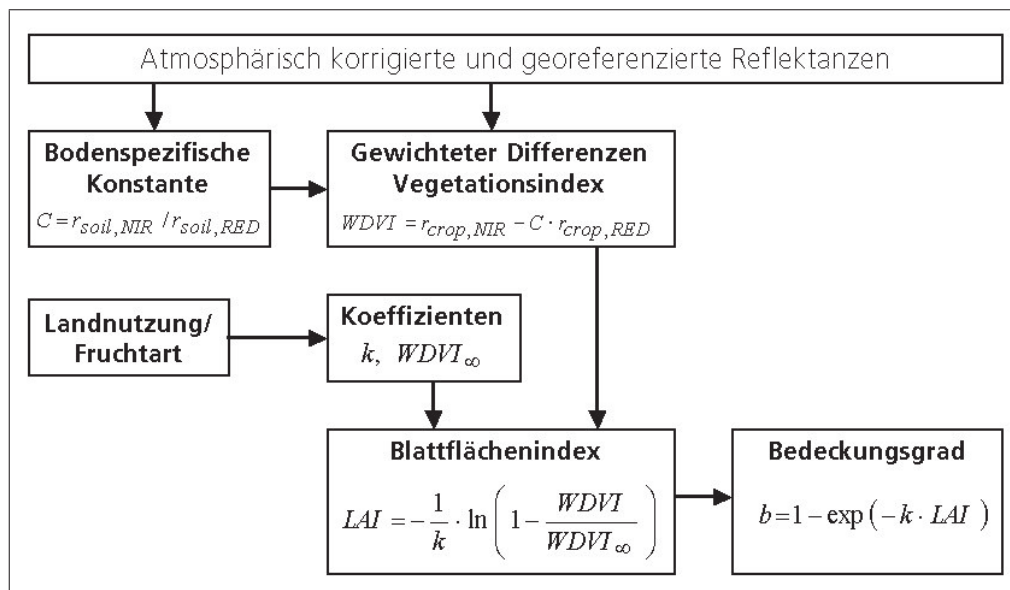


Abbildung 14: Relevante Größen zur Ableitung des Blattflächenindex und des Bedeckungsgrads nach Clevers 1988, Monsi und Saeki 1953 und Bouman et al. 1992 aus Klisch et al. 2001.

3.4 Entwurf eines Fahrspurmodells

Mit dem Entwurf eines Fahrspurmodells soll die Fahrspurgeometrie von landwirtschaftlichen Schlägen näherungsweise beschrieben werden. Dies erfolgt durch die Einführung dreier signifikanter Parameter:

- Die **Fahrspurbreite** t_1 umfasst die Breite der pflanzenfreien Lichtschächte in den Fahrgassen.
- Die **Fahrgassenbreite** t_2 ist durch den äußersten Abstand der beiden Fahrspuren bestimmt.
- Der **Fahrgassenabstand** t_3 entspricht dem Abstand zwischen zwei benachbarten Fahrgassen, ausgehend von deren mittlerem Verlauf.

Eine graphische Veranschaulichung der Parameter ist mit Abbildung 15 gegeben. In der Praxis können diese geometrischen Größen deutlich variieren, da sie an die Bewirtschaftungsmethoden sowie die Bauart der verwendeten Landmaschinen gekoppelt sind. Im Vergleich verschiedener Herstellerangaben² wurden die in Tabelle 2 dargestellten Näherungswerte für das Fahrspurmodell definiert.

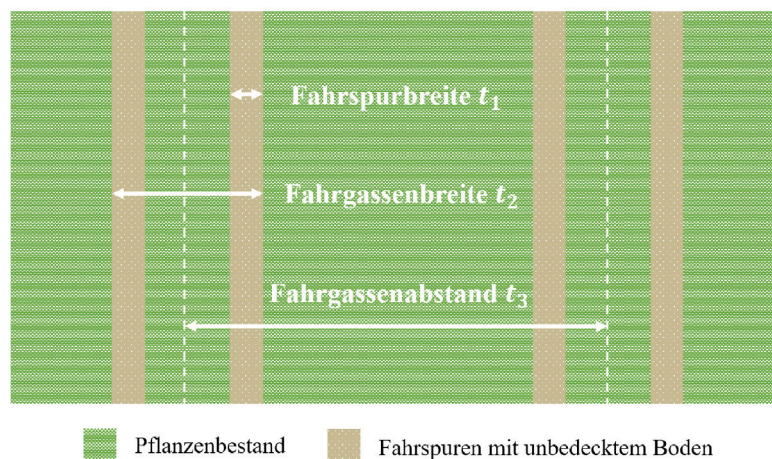


Abbildung 15: Schematische Darstellung der Parameter des Fahrspurmodells (Draufsicht) in Anlehnung an Borg 2016.

Die Fahrspurbreite t_1 lässt sich anhand der Reifenbreite ableiten, welche zwischen 30cm und 70cm variieren kann. Da die Überfahrten mit den Landmaschinen in der Regel nicht exakt gleich erfolgen, wird von einer eher breiteren Ausdehnung ausgegangen. In Abhängigkeit gängiger Achsbreiten ($2\text{...}4\text{m}$) der Landmaschinen wird die Fahrgassenbreite t_2 festgelegt. Der Fahrgassenabstand t_3 kann anhand der Arbeitsbreite der verwendeten Landmaschinen bestimmt werden, die zwischen 10m und 36m liegen können. Dabei ist üblicherweise die bei der Bewirtschaftung eines Schlags größte vorkommende Arbeitsbreite maßgebend.

²John Deere GmbH & Co. KG und CLAAS.

Parameter	Näherungswert [m]
t_1	0.7
t_2	3
t_3	36

Tabelle 2: Näherungswerte der Parameter des Fahrspurmodells.

Auf der Grundlage der hier festgelegten Fahrspurgeometrie können die Fahrspuren eines Schlags modelliert werden, sofern der mittlere Verlauf der Fahrgassen bekannt ist. Dabei wird dem Modell die Annahme zugrunde gelegt, dass die Fahrgassen beziehungsweise Fahrspuren geradlinig und parallel zueinander verlaufen. Mögliche Umfahrungen von Strukturelementen sowie Vorgewende werden nicht berücksichtigt.

3.5 Prozesskette

Die allgemeine Vorgehensweise zur Extraktion des Bodensignals lässt sich mit der gegebenen Datengrundlage und den ersten Vorbetrachtungen in fünf große Prozessschritte untergliedern (Abb. 16). An erster Stelle steht eine obligatorische Vorverarbeitung der Hyperspektraldaten zur Verbesserung der Datenqualität. Mit der anschließenden Segmentierung soll die zu untersuchende landwirtschaftliche Fläche von umgebenden Randstrukturen separiert und die folgende Auswertung vereinfacht werden.

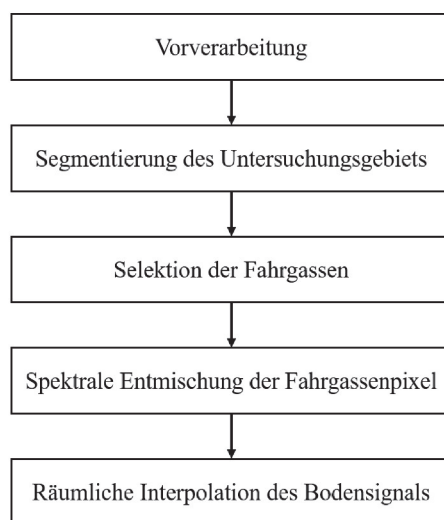


Abbildung 16: Prozesskette der zu untersuchenden Methode.

Darauf folgt die Selektion der Fahrgassen zur Identifizierung der Fahrgassenpixel, aus denen mit dem modifizierten Ansatz zur linearen spektralen Entmischung das gesuchte Bodensignal abgeleitet werden soll. Für die angestrebte Korrektur des Bestandssignals wird das Bodensignal abschließend ausgehend von den Fahrgassen über die gesamte Bestandsfläche räumlich interpoliert.

4 Analyse und Umsetzung

Mit diesem Kapitel erfolgt eine theoretische Analyse und demonstrative Umsetzung der in Kapitel 3 hergeleiteten Prozessschritte anhand der gegebenen Hyperspektraldaten. In Hinblick auf die Erarbeitung einer möglichst automatisierten und maßstabsunabhängigen Methode sollen jeweils mögliche Ansätze sowie Herausforderungen aufgezeigt werden. Die praktische Umsetzung erfolgt mit MATLAB (R2016) und ist den der Arbeit beiliegenden Skripten zu entnehmen (siehe Anhang F), wobei die fünf Prozessschritte jeweils einem separaten Modul entsprechen und die nachfolgend erläuterten Teilschritte durch Methoden abgebildet werden. Abbildung 17 liefert eine zusammenfassende Darstellung der damit umgesetzten Prozesskette.

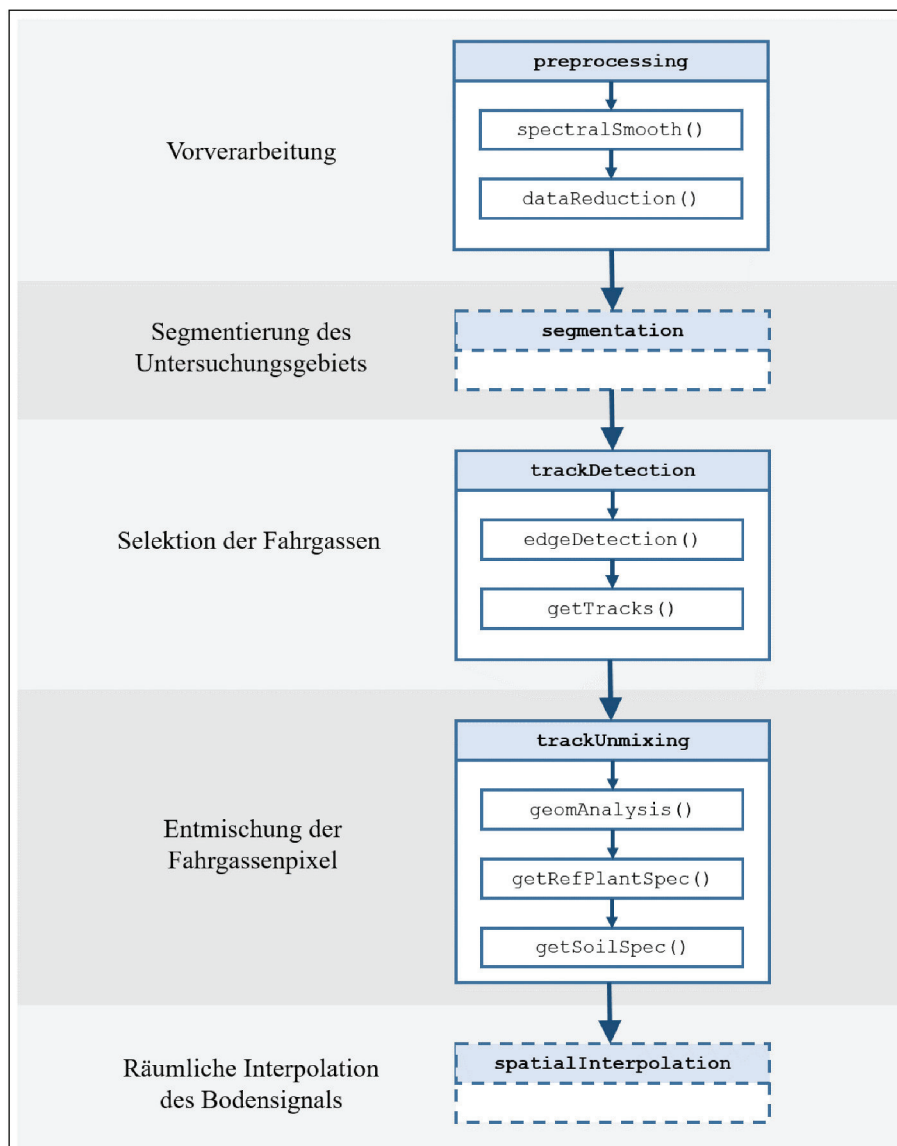


Abbildung 17: Praktische Umsetzung der Prozesskette in MATLAB (gestrichelte Module ausstehend).

4.1 Vorverarbeitung

Eine optimale Analyse von Hyperspektraldaten erfordert nach Holzwarth et al. 2015 einige vorverarbeitende Schritte zur Verbesserung der Datenqualität. Dies umfasst Methoden zur Korrektur von Störeinflüssen sowie zur Entfernung von unerwünschtem Rauschen. Aufgrund der feinen spektralen Auflösung sind Hyperspektraldaten oftmals anfälliger gegenüber atmosphärischer und sensorspezifischer Einflüsse. Des Weiteren führt die große Anzahl der Spektralbänder zu einer hohen Datendimension, wobei benachbarte Bänder oftmals stark korrelieren und somit eine hohe Redundanz aufweisen. Daher spielt auch eine Datenreduktion bei der Vorverarbeitung eine wichtige Rolle, um des Weiteren die Datenanalyse effizienter zu gestalten und den Rechenaufwand zu verringern.

Die hier verwendeten vorverarbeitenden Schritte umfassen eine Atmosphärenkorrektur, eine Geokorrektur sowie eine spektrale Glättung und eine anschließende Datenreduktion. Da die Daten bereits atmosphären- und geokorrigiert vorlagen, werden diese Teilschritte nicht weiter analysiert. Somit erfordert die praktische Umsetzung lediglich die Realisierung der spektralen Glättung sowie der Datenreduktion, was durch das Modul *preprocessing* und die Methoden *spectralSmooth()* und *dataReduction()* erfolgt (vgl. Abb. 17).

4.1.1 Spektrale Glättung

Ein essentieller Schritt bei der Vorprozessierung von Hyperspektraldaten ist die Reduktion des Rauschens. Aufgrund der feinen spektralen Auflösung weisen diese Daten typischerweise ein geringes Signalrauschverhältnis auf. Die schmalen Spektralbänder nehmen nur wenig Energie auf und werden gleichzeitig vom Grundrauschen des Sensors überlagert. Das Sensorrauschen kann unter anderem durch eine ungenaue Kalibration des Sensors, Beleuchtungsvariationen oder auch atmosphärische Faktoren beeinflusst werden. In Folge dessen werden die Signale von Rauschen überlagert, dessen Intensität in Abhängigkeit des Spektralbereichs unterschiedlich stark ausfallen kann. Einige Spektralbänder können aufgrund des Zustands der Atmosphäre auch vollständig „verschluckt“ werden und enthalten dann ausschließlich Rauschen (Miglani et al. 2011).

Bei der spektralen Glättung von Hyperspektraldaten finden verschiedene Filtermethoden Anwendung, die einerseits unerwünschtes Rauschen entfernen und andererseits bedeutende spektrale Merkmale erhalten sollen. Zu den meist verwendeten Filtern zählen der gleitende Mittelwertfilter und der Savitzky-Golay-Filter (Park und Lu 2015). Die Glättung erfolgt durch die Anwendung eines gleitenden Fensters der Länge $2\tilde{M} + 1$, wobei in Abhängigkeit der Filtergröße \tilde{M} jeweils eine Untermenge der Daten verarbeitet wird. Beim gleitenden Mittelwert erfolgt dabei eine Mittelwertbildung, was einen einfachen Ansatz zur Entfernung hochfrequenter Signalanteile darstellt. Der Savitzky-Golay-Filter (SG-Filter) basiert hingegen auf einem lokalen Polynomfit unter Verwendung der Methode der kleinsten Quadrate. Dadurch erfolgt eine lokale Rauschunterdrückung,

während tieffrequente Anteile des Spektrums erhalten bleiben. Spektrale Merkmale wie zum Beispiel die Höhe und die Breite von Absorptionsbändern werden somit weniger stark verzerrt. Des Weiteren überzeugt der SG-Filter aufgrund seiner rechnerisch effizienten Umsetzung. Savitzky und Golay 1964 haben gezeigt, dass die Polynomapproximation numerisch mit einer gewichteten Linearkombination der Datenpunkte gleichzusetzen ist. Diese Gewichtung erfolgt durch Filterkoeffizienten, die unabhängig von den Eingangsdaten nur durch den Polynomgrad p und die Filtergröße \tilde{M} bestimmt und somit im Voraus berechnet werden können. Eine anschauliche Herleitung des Filterkerns wird zum Beispiel in Orfanidis 2010 dargestellt. Die Glättung der Datenpunkte erfolgt schließlich durch eine einfache Faltung mit dem resultierenden linearen Filterkern. Für die Konstruktion des Filterkerns werden üblicherweise Polynome niedriger Ordnung verwendet, um die hochfrequenten Anteile des Rauschens zu entfernen (Ruffin und King 1999).

Die Wahl des Filtertyps und der Filtergröße zählen zu den entscheidenden Kriterien bei der spektralen Glättung, um eine Verfälschung des Originalsignals zu vermeiden. Der Mittelwertfilter entfernt zwar tendenziell mehr Rauschen, doch führt er im Vergleich zu anderen Filtermethoden auch zu einer stärkeren Verzerrung des Originalsignals bei gleicher Filtergröße (Tsai und Philpot 1998). Beim Savitzky-Golay-Filter bleiben spektrale Merkmale wie Absorptionsbänder hingegen besser erhalten, was zum Beispiel bei der Untersuchung von Vegetationsspektren zur Ableitung von physikalischen Parametern sehr wichtig ist. Aufgrund dieser Eigenschaft soll der Savitzky-Golay-Filter auch hier zur spektralen Glättung der HySpex-Daten verwendet werden.

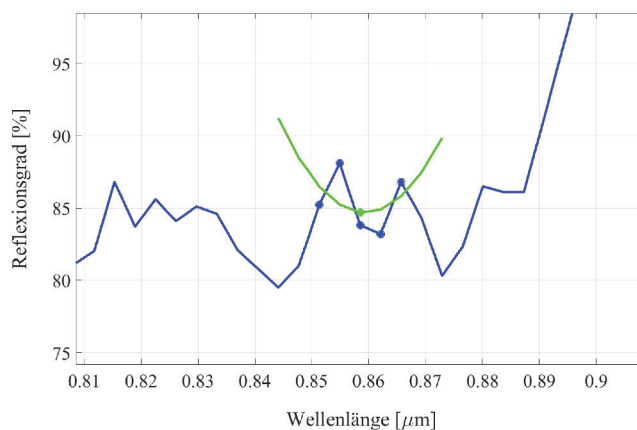


Abbildung 18: Lokaler Polynomfit (grün) mit $\tilde{M} = 2$ und $p = 2$ am Beispiel eines Pixelspektrums (blau) der gegebenen Daten.

Für die Berechnung des Filterkerns wird ein Polynomgrad von $p = 2$ gewählt, was bei der Datenglättung üblich ist (Mather und Koch 2011). Die Filtergröße \tilde{M} wird unter Einhaltung der Bedingung $p \leq 2\tilde{M}$ zur Gewährleistung einer eindeutigen Lösung des Polynomfits mit $\tilde{M} = 2$ festgelegt (Abb. 18). In Abhängigkeit der Filterlänge entfallen jeweils \tilde{M} Werte am Anfang und am Ende des Spektrums, wodurch sich die Anzahl der

Spektralbänder von 412 auf 408 reduziert. Der damit verbundene Informationsverlust kann bei der hohen Anzahl der hier gegebenen Spektralbänder vernachlässigt werden.

4.1.2 Datenreduktion

Die hohe spektrale Dimension hyperspektraler Fernerkundungsdaten liefert aufgrund der starken Korrelation benachbarter Bänder nicht immer einen höheren Informationsgehalt. Daher werden Hyperspektraldaten oftmals in einen Raum geringerer Dimension überführt, der möglichst alle relevanten Informationen enthält und eine effizientere und ressourcenschonende Datenanalyse erlaubt. Neben anderen bekannten Methoden, wie der Merkmalsextraktion oder -selektion, stellt auch das Binning ein Verfahren zur Datenreduktion dar (Holzwarth et al. 2015). Binning bezeichnet die Reduktion der räumlichen beziehungsweise spektralen Auflösung durch Aufsummierung oder Mittelwertbildung benachbarter Pixel beziehungsweise Spektralbänder. Dieses Verfahren wird meistens hardwareseitig direkt am Hyperspektralsensor angewandt, um die Datenübertragung zu beschleunigen und das Signalrauschverhältnis zu verbessern (Park und Lu 2015). Im Zuge der Aufbereitung von Hyperspektraldaten kann das Binning allerdings auch softwareseitig umgesetzt werden und soll auch hier Anwendung finden. Dazu werden die HySpex-Daten durch Mittelwertbildung benachbarter Spektralbänder zu Bändern von circa $16nm$ überführt, wodurch sich die Anzahl von 408 auf 122 Bänder mit Bandbreiten zwischen $15.2nm$ und $18.5nm$ reduziert.

4.2 Segmentierung des Untersuchungsgebiets

Die Segmentierung des Untersuchungsgebiets soll die Bildanalyse dahingehend vereinfachen, dass keine weitere Differenzierung zwischen Schlag und Umgebung vorgenommen werden muss. Im Rahmen der Methodenentwicklung werden zunächst drei Schläge untersucht, die möglichst gute Voraussetzungen zur Ermittlung des Bodensignals liefern (Abb. 19). Diese sind durch gut ausgeleuchtete Fahrgassen und grüne Vegetation gegeben. Die Segmentierung wird manuell mit ENVI (einer kommerziellen Software zur Analyse und Prozessierung von Geodaten) vorgenommen, wobei jeweils der gesamte Schlag extrahiert wird und die umgebenden Randstrukturen weitestgehend entfernt werden.

In der Literatur gibt es verschiedene Ansätze zur automatisierten Segmentierung von landwirtschaftlichen Parzellen, die größtenteils auf Strukturanalysen oder Homogenitätsanalysen unter Ausnutzung der Textur oder spektraler Informationen basieren. In einigen Fällen kommen auch Zusatzdaten, wie Straßenkarten, Geländemodelle oder vorliegende Klassifizierungsergebnisse, zum Einsatz, um die Regionen potentieller Untersuchungsgebiete einzugrenzen.

Eine Segmentierung unter Ausnutzung der Bildstrukturen kann zum Beispiel mit Hilfe kantenbasierter Verfahren (Turker und Kok 2013, Rydberg und Borgefors 2001) oder unter Verwendung der Wavelet-Transformation (Ishida et al. 2004, Ji 1996) erfolgen. Turker und Kok 2013 nutzen zusätzlich die Kenntnis über die oftmals gegebenen




Abbildung 19: RGB-Darstellung der segmentierten Schläge.

regelmäßigen Agrarstrukturen aus, indem sie eine Gruppierung und Auswertung der detektierten Liniensegmente anhand der Gestaltgesetze³ vornehmen. Das Ergebnis solcher Strukturanalysen ist jedoch stets an die geometrische Auflösung der Daten sowie die Erscheinung der zu detektierenden Objekte in der Szene (Größe, Umgebungskontrast) gekoppelt.

Das Zusammenfassen homogener Bildregionen (*region growing*) anhand geeigneter Merkmale stellt ein weiteres gängiges Verfahren der Bildsegmentierung dar. Dieser Ansatz kommt zum Beispiel bei dem universellen multiresoluten Segmentierungsalgorithmus der kommerziellen Software eCognition von Trimble zum Einsatz, der in zahlreichen Untersuchungen zur Extraktion von Agrarflächen erfolgreich Anwendung findet (Darwish et al. 2003, Tian und Chen 2007, Benz et al. 2004). Neben den spektralen Eigenschaften sowie der Textur, werden zudem die Größe und das Verhalten der zu segmentierenden Objekte in unterschiedlichen Maßstäben berücksichtigt. Mit Hilfe von Homogenitätskriterien werden Pixel in einem Optimierungsprozess zu Regionen zusammengefasst. Die resultierenden Bildobjektprimitive lassen sich durch eine anschließende Klassifizierung zu Objekten verbinden, die den in der realen Welt vorkommenden Objekten entsprechen (Baatz und Schäpe 2000). Dieser Algorithmus wird auch in dem zweiskaligen Ansatz von Buck et al. 2011 verwendet, um eine automatisierte Aktualisierung von landwirtschaftlichen Parzellen im Rahmen des Integrierten Verwaltungs- und Kontrollsystems (InVeKoS) vorzunehmen. Dabei erfolgt die Segmentierung mit Hilfe hoch aufgelöster Orthophotos in Kombination mit multitemporalen Satellitenbildern

³Gestaltgesetze beschreiben die aus der Gestaltpsychologie (Koffka 2013) stammenden Prinzipien, nach denen die menschliche Wahrnehmung einzelne Phänome anhand signifikanter Eigenschaften (zum Beispiel Symmetrie, Geschlossenheit) ordnet und in Zusammenhang bringt.

zur Klassifizierung der gesuchten Flächen. Die Vorgehensweise bei der multiresoluten Segmentierung kann an eine sehr aufwändige und komplexe Parametrisierung sowie einen hohen Rechenaufwand gebunden sein. Diesem Problemen entgegen Ursani et al. 2012 mit einem alternativen Ansatz durch die Integration von zwei parallel laufenden unabhängigen Analysen. Dies umfasst einerseits eine spektrale Klassifikation geometrisch geringauflösender multispektraler Daten und andererseits eine Textur-basierte Klassifikation geometrisch hochauflösender panchromatischer Daten. In einigen Fällen liefern die regionsbasierten Verfahren geometrisch ungenaue Konturen der segmentierten Objekte, die zum Beispiel durch den Einsatz so genannter aktiver Konturen (*snakes*) verfeinert werden können (Torre und Radeva 2000, Butenuth et al. 2004 und Tiwari et al. 2009). Dabei handelt es sich um ein Konzept zur Detektion von Objektkonturen, wobei eine initiale Kontur anhand von a-priori Wissen über Form und Position des Objekts an dessen Bildkontur iterativ angepasst wird.

4.3 Selektion der Fahrgassen

Das Ziel der Fahrgassenselektion ist es, die Fahrgassen des zu untersuchenden Schlags zu detektieren und deren Position im Bildkoordinatensystem anhand einer geeigneten Darstellung näherungsweise zu bestimmen. Eine erfolgreiche Detektion setzt eine ausreichend gute Erkennbarkeit der gesuchten Strukturen voraus. Die Erkennbarkeit von Objekten ist bei der Auswertung von Fernerkundungsdaten stets an das komplexe Zusammenspiel verschiedener Einflussfaktoren gekoppelt. Nach Albertz 2001 sind dabei vor allem das Auflösungsvermögen des Aufnahmesystems und die Eigenschaften der zu untersuchenden Objekte (Größe, Form) sowie ihre Umgebungsbedingungen (Kontrastverhältnis) von großer Bedeutung. Demzufolge kann die räumliche Ausdehnung der Fahrgassen in Abhängigkeit der geometrischen Sensorauflösung stark variieren und entweder zu einer linien- oder flächenhaften Erscheinung führen. Des Weiteren kann die Erkennbarkeit der Fahrgassen durch einen geringen Kontrast zu den umgebenden Bestandsflächen oder durch ungünstige Beleuchtungsverhältnisse beeinträchtigt werden. Die ausgewählten Schläge liefern jedoch sehr gute Voraussetzungen zur Detektion der Fahrgassen, welche aufgrund der gegebenen Bodenauflösung in Form von Linien erscheinen. In Anlehnung an diese Ausgangssituation wurde hier ein Ansatz entwickelt, der ausschließlich eine linienförmige Erscheinung der Fahrgassen berücksichtigt und einen hohen Kontrast zwischen Fahrgassen und Bestand voraussetzt.

Eine gängige Vorgehensweise zur Detektion von Kanten und Konturen ist die Erzeugung eines binären Kantenbilds mit anschließender Interpretation zur Identifikation der gesuchten Strukturen. Bei der Binärbilderzeugung können gradientenbasierte Kantendetektoren erster oder zweiter Ordnung zum Einsatz kommen sowie alternative Operatoren, wie der weit verbreitete Canny-Detektor. Für die anschließende Selektion der Kanten gibt es verschiedene Verfahren wie zum Beispiel die sequentielle Verfolgung von Linien unter Verwendung von Suchstrahlen, Suchkreisbögen oder Linienrastern. Die

Schwierigkeiten liegen dabei in der Behandlung von Unterbrechungen, Verzweigungen und anderen Mehrdeutigkeiten im binären Kantenbild, die insbesondere in verrauschten Bildbereichen auftreten (Burger und Burge 2015).

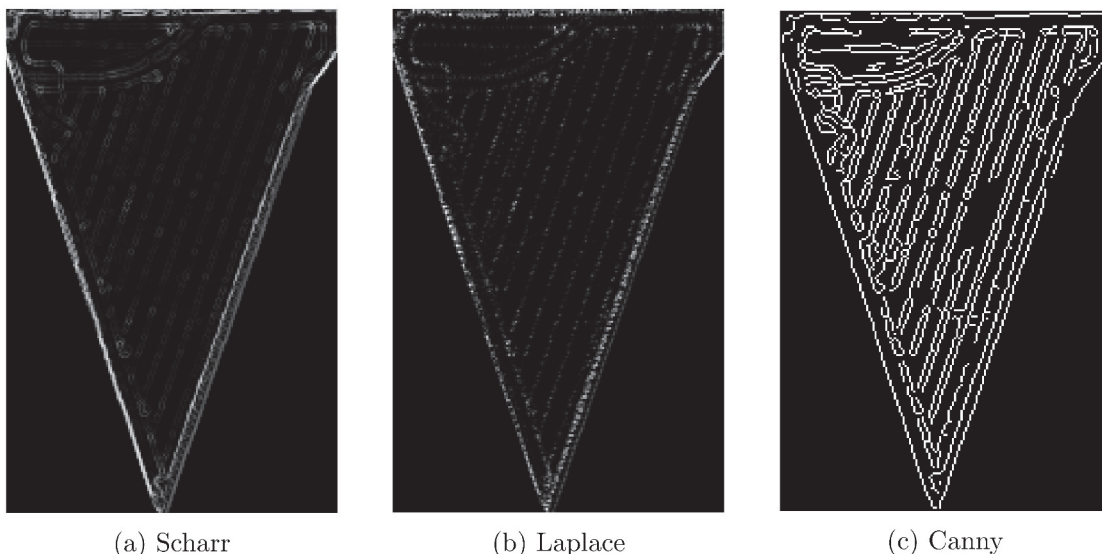


Abbildung 20: Ergebnisse verschiedener Kantendetektoren am Beispiel von Schlag 1.

Der Einsatz von Kantendetektoren hat sich bei den gegebenen Testdaten als ungeeignet erwiesen (Abb. 20). Gradientenbasierte Detektoren, wie der Scharr-Detektor, liefern bei der geometrischen Auflösung der Daten keine eindeutigen Linien. Das beste Ergebnis konnte mit dem Laplace-Operator erzeugt werden, der jedoch für seine Anfälligkeit gegenüber Bildrauschen bekannt ist. Es ist anzunehmen, dass die Ergebnisse solcher Kantendetektoren in Abhängigkeit der geometrischen Auflösung sehr unterschiedlich ausfallen können, was eine differenzierte Interpretation erfordert und eine automatisierte maßstabsunabhängige Auswertung erschwert. In Folge dessen wird ein alternativer Ansatz zur Erzeugung des binären Kantenbilds verwendet.

Die daran anschließende Selektion der Fahrspuren soll hier unter Verwendung der Hough-Transformation erfolgen, die sich insbesondere zur Detektion global auffälliger und einfacher geometrischer Strukturen eignet. Da die Anordnung der Fahrgassen von landwirtschaftlichen Schlägen in der Regel sehr gleichmäßig ist und die Fahrgassen zudem als gerade verlaufende Linien angenommen werden können, stellt die Hough-Transformation eine gute Möglichkeit dar, um zunächst einen Großteil der Fahrgassen zu detektieren. In einer anschließenden Analyse sollen die korrespondierenden Fahrgassen eindeutig identifiziert und approximiert werden. Die Identifikation und Selektion der Fahrgassen kann dabei durch das Auftreten von Strukturelementen, wie Söllen, Feldgehölzen, Strommasten etc. deutlich erschwert werden. Diese Strukturelemente können in jeglicher Form und Häufigkeit innerhalb des Schlags auftreten und zu einem abweichenden Verlauf der Fahrgassen führen. Eine weitere Herausforderung liegt in der Detektion der Vorgewende und Wendeschleifen, deren Umgebungskontrast bei einer niedrigen

Bodenauflösung sehr gering ausfallen kann. Da die Analyse der einzelnen Prozessschritte der zu untersuchenden Methode jedoch im Vordergrund steht, beschränkt sich der hier vorgestellte Ansatz einfachheitshalber zunächst nur auf die geradlinig verlaufenden Fahrgassensegmente. Die praktische Umsetzung zur Selektion der Fahrgassen erfolgt mit dem MATLAB-Modul *trackDetection*, wobei die beiden Teilschritte durch die Methoden *edgeDetection()* und *getTracks()* abgebildet werden (vgl. Abb. 17).

4.3.1 Erzeugung eines binären Kantenbilds

Bei der Erzeugung eines binären Kantenbilds gilt es, die gesuchten Strukturen vom Hintergrund zu trennen und hervorzuheben. Dies wird häufig durch die Überlagerung von Bildrauschen erschwert, wie es auch hier bei der Hervorhebung der Fahrgassen gegenüber dem Bestand der Fall ist. Die durch die geometrische Auflösung bedingte Mischpixelcharakteristik führt bei den gegebenen Daten zu deutlichen Intensitätsunterschieden innerhalb der Fahrgassen (Abb. 21). In Abhängigkeit der Pixel- und Fahrgassengeometrie erscheint die Fahrgassenbreite in Form von einem oder mehreren Pixeln, wobei verschiedene Mischungsverhältnisse mit dem angrenzenden Bestandssignal entstehen. Wird die Fahrgasse nur zu einem geringen Teil im Mischpixel erfasst, scheint sie in der RGB-Darstellung beinahe zu verschwinden.




Abbildung 21: Verrauschte Erscheinung der Fahrgassen und des Bestands am Beispiel von Schlag 1.

Innerhalb des Bestands treten ebenfalls Helligkeitsunterschiede auf, bedingt durch die Heterogenität der Vegetation. Diese kann auf die natürliche Variabilität der spektralen Signatur, Unterschiede in der Bewirtschaftung, einen variierenden Bedeckungsgrad, die Bodenheterogenität oder die topographischen Gegebenheiten (zum Beispiel Hangneigungen) zurückgeführt werden. Die daraus resultierenden regionalen Helligkeitsunterschiede führen zu einem variierenden Kontrastverhältnis zwischen Fahrgassen und Bestand innerhalb des gesamten Schlags, was die Differenzierung dieser Strukturen er-

schwert. Gängige Filter zur Rauschunterdrückung erwiesen sich bei der gegebenen geometrischen Auflösung als ungeeignet, da bereits kleinste Filtergrößen eine unerwünschte Glättung der zu detektierenden Strukturen bewirken. Eine angemessene Reduktion des Rauschens konnte jedoch in einem eigenen Ansatz zur Erzeugung des binären Kantensbilds umgesetzt werden, der auf einer Kontrastverstärkung und einer anschließenden lokalen Filterung heller Strukturen basiert. Dieser Ansatz untergliedert sich in drei Teilschritte.

(1) NDVI- und NDSI-Auswertung

Zur Hervorhebung der gesuchten Strukturen soll zunächst der Kontrast zwischen den Fahrgassen und dem Bestand erhöht werden. Dazu eignet sich die Verwendung von Vegetationsindizes, die den wellenlängenabhängigen Kontrast zwischen Vegetation und unbewachsenem Boden ausnutzen. Aus der Vielzahl von Indizes sollen hier der weitverbreitete Normalized Difference Vegetation Index (NDVI) sowie der Normalized Difference Soil Index (NDSI) untersucht werden. Da der NDVI ursprünglich für breitbandige Fernerkundungsdaten konzipiert wurde, gilt es bei der Verwendung von Hyperspektraldaten, geeignete Bänder für den Rot- und NIR-Bereich zu wählen (vgl. Gl. 2.1). In der Literatur sind dazu verschiedene Empfehlungen zu finden, wie zum Beispiel der von Thenkabail et al. 2012 vorgeschlagene schmalbandige

$$NDVI_{narrowband} = \frac{\rho(860) - \rho(660)}{\rho(860) + \rho(660)},$$

der sich auf die Spektralbänder von $660nm$ (Rot) und $860nm$ (NIR) bezieht und auch hier Anwendung finden soll. Der Normalized Difference Soil Index (NDSI) stellt eine Erweiterung des NDVIs unter Ausnutzung des SWIR-Bereichs⁴ dar (Takeuchi und Yasuoka 2005). Dieser relativ junge Index wurde ebenfalls für breitbandige Sensoren konzipiert und findet in der Literatur bisher bei Landsat TM (Matsuoka et al. 2013), Terra-ASTER (Kouchi und Yamazaki 2007) oder auch MODIS-Daten (Tateishi et al. 2008) Anwendung. In Anlehnung an die Berechnung des NDSI unter Verwendung der MODIS-Bänder 2 ($841...876nm$) und 6 ($1628...1652nm$) sollen hier die mittleren Wellenlängen bei $860nm$ (NIR) und $1640nm$ (SWIR) verwendet werden

$$NDSI = \frac{\rho(1640) - \rho(860)}{\rho(1640) + \rho(860)}.$$

Zur besseren Veranschaulichung werden die resultierenden NDVI- und NDSI-Auswertungen invertiert, so dass die gesuchten Strukturen gegenüber dem Hintergrund heller erscheinen (Abb. 22).

⁴Die Bezeichnung SWIR (Short Wavelength Infrared) wird hier synonym mit MIR verwendet und umfasst den Wellenlängenbereich zwischen $1.3\mu m$ und $2.5\mu m$.

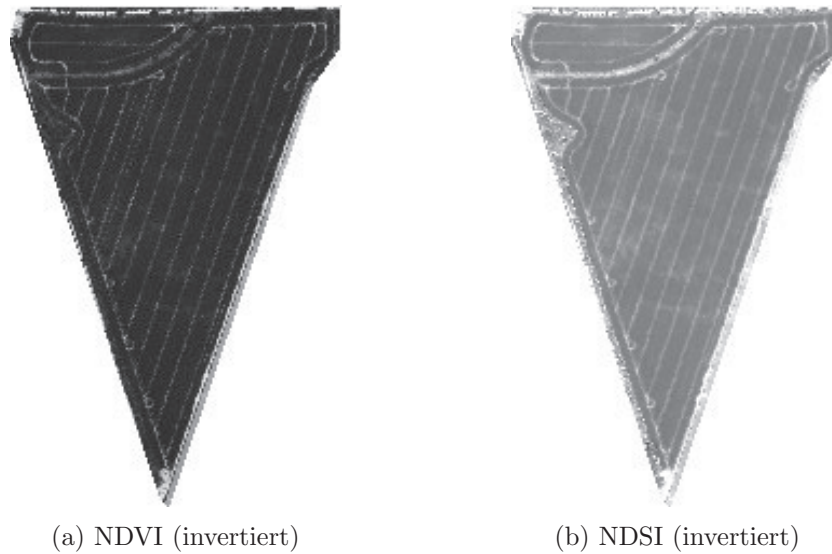


Abbildung 22: Ergebnisse spektraler Vegetationsindizes.

Beide Berechnungen liefern einen sichtlichen Kontrast zwischen Fahrgassen und Bestand, wobei auch kleine Strukturen wie die Wendeschleifen deutlich zu erkennen sind. Im Vergleich ist der Kontrast der NDVI-Auswertung deutlich höher. Beim NDSI hingegen weisen die Fahrgassen nahezu gleichmäßige Intensitäten auf und erscheinen etwas breiter, was sehr gute Voraussetzungen für eine Separation der Linien vom Hintergrund darstellt. Die regionalen Unregelmäßigkeiten innerhalb des Bestands bleiben bei beiden Auswertungen erhalten. Bei der anschließenden Verarbeitung zur Erzeugung des binären Kantenbilds sollen die NDVI- und die NDSI-Auswertung weiterhin parallel betrachtet werden.

(2) Lokaler Selektionsfilter

Die Intensität der Fahrgassen in der invertierten NDVI- beziehungsweise NDSI-Auswertung soll nun durch eine geeignete Filteroperation erhöht werden. Nach der Kontrastverstärkung liegen diese Fahrgassen als helle linienartige Strukturen vor, die sich innerhalb einer Umgebung größerer geometrischer Ausdehnung und geringerer Intensität befinden. Hinsichtlich dieser strukturellen Charakteristik wurden drei verschiedene Filter (*A*, *B* und *C*) untersucht, welche die Fahrgassen unter Betrachtung einer definierten Pixelumgebung lokal gegenüber dem angrenzenden Bestand hervorheben sollen. Die Filteroperationen beziehen sich dabei auf statistische Kenngrößen, wie dem Minimum (V_{min}), dem Maximum (V_{max}) oder dem Median (V_{med}) der Grauwertverteilung innerhalb der definierten Pixelumgebung der Größe $N \times N$ mit dem zentralen Grauwert V_z , wobei N beliebige ungerade Werte größer Eins annehmen kann. Bei allen drei Filtern erfolgt eine Normierung auf den Grauwertumfang, der durch die Differenz des maximalen und minimalen Grauwerts $V_{max} - V_{min}$ definiert ist. Die Ergebnisse liefern den gefilterten Zentralwert \tilde{V}_z der Pixelumgebung, wobei negative Werte auf Null projiziert werden.

In Abbildung 23 werden die Ergebnisse der drei Filter für eine feste Filtergröße von $N = 3$ dargestellt. Im Vergleich sind deutliche Unterschiede bezüglich der Hervorhebung der Fahrgassen zu erkennen, wobei in jedem Fall das Bildrauschen verstärkt wird.

Filter A


$$\tilde{V}_z = \frac{V_z - V_{min}}{V_{max} - V_{min}}$$

Unter der Annahme, dass die hellen Fahrgassen größere Differenzen zum Minimalwert der Pixelumgebung aufweisen als der Bestand, erfolgt mit Filter A eine Differenzbildung zwischen dem Zentralwert V_z und dem Minimum V_{min} . Der Filter bewirkt zwar eine Verstärkung der Fahrgassenpixel, jedoch wird die Intensität der umgebenden Bestandspixel ebenfalls erhöht. Das Ergebnis ist stark verrauscht und ermöglicht keine gute Differenzierung zwischen Bestand und Fahrgassen.

Filter B

$$\tilde{V}_z = \frac{V_z - V_{med}}{V_{max} - V_{min}}$$

In einer Abwandlung des ersten Ansatzes wird mit Filter B die Differenz zwischen Zentralwert V_z und Median V_{med} untersucht. Dabei erfolgt eine Verstärkung der Fahrgassenpixel, da diese eine größere Differenz zum Median aufweisen, der durch die Grauwerte der anteilig größeren Fläche des Bestands in der Pixelumgebung bestimmt wird. Innerhalb des Bestands liegt der Median aufgrund des geringeren Grauwertumfangs dichter am Zentralwert, wodurch die Bestandspixel bei der Differenzbildung unterdrückt werden. In Folge dessen erscheinen Bestand und Fahrgassen in sichtlich abgestuften Intensitäten.



(a) Filter A

(b) Filter B

(c) Filter C

Abbildung 23: Ergebnisse der getesteten lokalen Selektionsfilter.

Filter C

$$\tilde{V}_z = \frac{V_{max} - V_{med}}{V_{max} - V_{min}}$$

Mit Filter C wird die Differenz zwischen Maximalwert V_{max} und Median V_{med} betrachtet, wobei die Fahrgassen in ihrer Intensität zwar hervorgehoben werden, im Ergebnisbild jedoch auch deutlich breiter erscheinen. Bei den Fahrgassen ist eine größere Differenz zwischen Maximalwert und Median zu erwarten, wodurch die Intensität der Fahrgassenpixel erhöht wird. Innerhalb des Bestands fallen diese Differenzen und somit auch die resultierenden Intensitäten aufgrund des geringeren Grauwertumfangs hingegen kleiner aus. Sobald ein Fahrgassenpixel durch die Pixelumgebung erfasst wird, erfolgt eine Verstärkung des Zentralwerts. Demzufolge wird auch die Intensität benachbarter Bestandspixel in einem Abstand von $(N - 1)/2$ erhöht, was zu einer Ausdehnung der Fahrgassen im Ergebnisbild führt. Dieser Effekt wird mit zunehmender Filtergröße verstärkt und erschwert eine möglichst genaue Lokalisierung der Fahrgassen.

Die Filter-Ergebnisse der NDSI-Auswertung weisen sehr ähnliche Charakteristika auf und sind in Anhang C zu finden. Im Vergleich der drei Ansätze erfolgt die Hervorhebung der Fahrgassen mit Filter B in beiden Fällen am besten und liefert gute Voraussetzungen für die Detektion der gesuchten Strukturen. Daran anknüpfend stellt sich die Frage nach einer geeigneten Filtergröße. Eine optimale Verstärkung der Fahrgassenpixel bei Filter B ist bei kleinen Median-Werten zu erwarten, die aus einem geringen Flächenanteil der Fahrgassen innerhalb der Pixelumgebung resultieren. Demzufolge sollten bei der Filterung der Fahrgassenpixel keine weiteren benachbarten Fahrgassen von der Filtermatrix abgedeckt werden. Zudem ist zu beachten, dass der Median auch durch angrenzende Randstrukturen beeinflusst werden kann. Unter Berücksichtigung der variierenden Bestandsbreite zu beiden Seiten der Fahrgassen, kann die Filtergröße N in Abhängigkeit des geschätzten Fahrgassenabstands t_3 mit

$$N < \frac{t_3}{GSD} \quad (4.1)$$

bestimmt werden. Der Näherungswert des Fahrspurmodells von $t_3 = 36m$ führt demnach bei der gegebenen Bodenauflösung GSD von $4m$ pro Pixel zu einem Abstand von 9 Pixeln. Somit kann eine optimale Hervorhebung der Fahrgassen für die nächstkleinere Filtermatrix mit $N = 7$ erwartet werden.

Die Ergebnisse verschiedener Filtergrößen sind in Abbildung 24 zu sehen. Das Rauschen innerhalb des Bestands wird mit zunehmender Filtergröße deutlich stärker unterdrückt, was die nachfolgende Detektion der Fahrgassen begünstigt. Allerdings verringert sich dabei ebenfalls die Intensität einiger relevanter Fahrgassensegmente. Ursache hierfür ist, dass der angrenzende Flächenanteil des Bestands insbesondere am Rand des Schlags geringer ausfallen kann, wodurch sich der Median der Filtermatrix aufgrund

angrenzender heller Randstrukturen erhöht und die Differenz zu den Fahrgassenpixeln geringer ausfällt.




Abbildung 24: Vergleich verschiedener Filtergrößen des lokalen Selektionsfilters B .

Die Filtergröße von 7×7 Pixeln stellt somit einen guten Kompromiss zwischen Rauschunterdrückung und der Hervorhebung der relevanten Strukturen dar. Auch kleine Strukturen wie Wendeschleifen, bleiben bei der Filterung gut erhalten. Angrenzende Randstrukturen heller Intensität werden hingegen ebenfalls verstärkt. Solche unerwünschten Strukturen lassen sich in der folgenden Verarbeitung nur schwer identifizieren und sollten durch eine geeignete Segmentierung im vorherigen Prozessschritt vermieden werden.



Abbildung 25: Lokaler Selektionsfilter B mit $N = 7$ (NDSI-Auswertung).

Das Ergebnis des lokalen Selektionsfilters B mit $N = 7$ der NDSI-Auswertung ist in Abbildung 25 dargestellt. Die Fahrgassen erscheinen, wie im Ausgangsbild, etwas breiter,

wobei das Rauschen innerhalb der Fahrgassen scheinbar verstärkt wird. Im Vergleich zur gefilterten NDVI-Auswertung kommt hier das Rauschen innerhalb des Bestands zudem deutlicher zum Vorschein. Äußere Randstrukturen erscheinen hingegen teilweise in geringerer Intensität, was bei der folgenden Schwellwertbildung von Vorteil ist.

Unter Berücksichtigung der kleinsten möglichen Filtergröße des lokalen Selektionsfilters von $N = 3$ sowie der Einhaltung von Gleichung 4.1, erfordert die Anwendung des Filters somit eine Mindestbodenauflösung von $9m$ pro Pixel.

(3) Schwellwertbildung

Im letzten Schritt zur Erzeugung des binären Kantenbilds erfolgt eine Schwellwertbildung, mit der möglichst viele Fahrgassenpixel und wenige Umgebungspixel erhalten bleiben sollten. Die Schwierigkeit liegt in der Bestimmung eines geeigneten Schwellwertes, der in Abhängigkeit der Eingangsdaten stark variieren kann und trotz Bildrauschen eine gute Trennung von Fahrgassen- und Bestandspixeln ermöglichen sollte. Nach der Selektion der hellen Strukturen im vorherigen Schritt ist anzunehmen, dass die hellsten Pixel im Bild mit großer Wahrscheinlichkeit den Fahrgassenpixeln entsprechen. Eine Abschätzung der Anzahl aller Fahrgassenpixel beziehungsweise der Gesamtfläche der Fahrgassen verspricht demzufolge eine Möglichkeit, einen geeigneten Schwellwert in Abhängigkeit der Eingangsdaten zu ermitteln. Mit einem solchen Näherungswert ließe sich der Schwellwert anhand des Histogramms bestimmen, indem die hellsten Pixel in Richtung der absteigenden Grauwerte aufsummiert werden, bis die geschätzte Anzahl der Fahrgassenpixel erreicht ist.

Eine Abschätzung der Gesamtfläche der Fahrgassen könnte anhand von Näherungswerten für die geometrische Ausdehnung sowie die Anzahl der Fahrgassen erfolgen. In Abhängigkeit der geometrischen Größen des Fahrspurmodells und der gegebenen Bodenauflösung kann zum Beispiel auf die geometrische Ausdehnung der Fahrgassen in der Szene geschlossen werden. Die Bestimmung der Fahrgassenanzahl könnte hingegen unter Berücksichtigung der Größe und der geometrischen Form des Schlags erfolgen, welche durch die Segmentierung näherungsweise bekannt ist. Da nicht alle Fahrgassenpixel eine hohe Intensität aufweisen und einige Pixel des Bestands oder der Randstrukturen ebenfalls sehr hell erscheinen können, gilt es, den Schwellwert etwas niedriger anzusetzen, sodass möglichst viele auch nicht so helle Fahrgassenpixel erhalten bleiben. Dieser Ansatz konnte im Rahmen der Arbeit jedoch nicht weiter untersucht und umgesetzt werden. Stattdessen wurden geeignete Schwellwerte anhand der gegebenen Testdaten empirisch ermittelt, die im Histogramm für alle drei Schläge jeweils an der Grenze zu den hellsten 10% aller Pixel eines segmentierten Schlags liegen. Die resultierenden Binärbilder der gefilterten NDVI- und NDSI-Auswertungen sind in Abbildung 26 dargestellt. In beiden Fällen bleiben die Fahrgassen gut erhalten, wobei das Rauschen im Bestand bei der gefilterten NDSI-Auswertung gleichzeitig stärker unterdrückt wird.




Abbildung 26: Ergebnisse der Schwellwertbildung.

Da die NDSI-Auswertung bessere Voraussetzungen zur Detektion der Fahrgassen liefert, wird ausschließlich dieses Ergebnis bei den folgenden Prozessschritten weiter betrachtet. Die Ergebnisse aller drei untersuchten Schläge zur Erzeugung des binären Kantenbilds sind im Anhang D dargestellt. Der hier vorgestellte Ansatz liefert in allen drei Fällen vergleichbar gute Kantenbilder, in denen die Fahrgassen deutlich hervorgehoben werden. Bei Schlag 3 hingegen scheint die Verwendung des lokalen Selektionsfilters B die außen liegenden Fahrgassen zu unterdrücken, was auf eine ungünstige Filtergröße schließen lässt. Nichtsdestotrotz weisen die Ergebnisse gute Voraussetzungen zur Detektion der Fahrgassen auf.

4.3.2 Detektion der gesuchten Strukturen

Im zweiten Schritt der Fahrgassenselektion sollen die gesuchten Strukturen in dem zuvor erzeugten binären Kantenbild detektiert und für die nachfolgende Prozessierung in geeigneter Form aufbereitet werden. Dazu wird ein vereinfachter Ansatz verwendet, der sich ausschließlich auf gerade verlaufende und linienförmige Fahrgassen bezieht. Unter Ausnutzung der markanten Charakteristik der Fahrgassengeometrie soll die Hough-Transformation zum Einsatz kommen. Das Ergebnis dieser Transformation wird anschließend ausgewertet, um die gesuchten Strukturen zu identifizieren und eine möglichst gute Approximation der Fahrgassen im Bildkoordinatensystem zu erhalten. Abschließend erfolgt eine Korrektur der Linienendpunkte, um fehlerhaft detektierte Strukturen zu vermeiden.


(1) Extraktion gerader Linien mittels Hough-Transformation

Die Hough-Transformation (HT) ist ein Standardverfahren zur Detektion einfacher geometrischer Formen, die durch wenige Parameter beschrieben werden können (zum Bei-


spiel Geraden, Kreise, Ellipsen). Die grundlegende Idee stammt von Hough 1962 und wurde von Duda und Hart 1972 weiterentwickelt. Das Verfahren behilft sich einer geeigneten Parametertransformation der Eingangsdaten, wodurch die Detektion der gesuchten Geometrien erleichtert wird. Die HT zeichnet sich insbesondere durch eine hohe Toleranz gegenüber Bildrauschen sowie teilweise verdeckten Strukturen aus. Die Standard-HT zur Detektion von Geraden basiert auf der Parametrisierung mit der Hesseschen Normalenform

$$d_0 = x \cdot \cos(\alpha_0) + y \cdot \sin(\alpha_0) ,$$

womit eine Gerade vollständig durch den Winkel α_0 und den Abstand d_0 beschrieben werden kann (Burger und Burge 2015). Der Abstand d_0 entspricht dem Betrag des Vektors, der ausgehend vom Koordinatenursprung senkrecht auf der Geraden steht, und der Winkel α_0 liegt zwischen diesem Vektor und der positiven x-Achse (Abb. 27a).



(a) Transformation einer Bildraum-Geraden



(b) Transformation eines Bildraumpunktes

Abbildung 27: Veranschaulichung der Hough-Transformation (verändert nach Burger und Burge 2015).

Die Parametertransformation einer solchen Geraden vom Bildraum (x, y) in den Parameter- beziehungsweise Hough-Raum (d, α) resultiert in einer punkthaften Darstellung an der Stelle (d_0, α_0) . Die Transformation eines einzelnen Bildraumpunktes (x_0, y_0) führt zu einer Sinuskurve im Hough-Raum, die den Abstand d in Abhängigkeit des Winkels α beschreibt und somit alle möglichen Ausrichtungen der Geraden im Bildraum berücksichtigt (Abb. 27b). Im Umkehrschluss entsprechen mehrere auf einer Bildraum-Geraden liegenden Punkte einer Schar aus Sinus-Kurven, die sich in einem Punkt schneiden. Mit der Detektion derartiger Schnitt- beziehungsweise Häufungspunkte im Hough-

Raum können potentielle Geraden des Bildraums identifiziert werden. Dazu wird die aus der Parametertransformation resultierende Hough-Matrix diskretisiert und geeignet gefiltert. Anschließend gilt es, die korrespondierenden Linienendpunkte zu identifizieren, was zum Beispiel mit Hilfe einer Bounding-Box erfolgen kann (Burger und Burge 2015).

Für die praktische Umsetzung der Hough-Transformation werden MATLAB-interne Funktionen verwendet, mit denen die Hough-Matrix für das binäre Kantenbild berechnet wird und anschließend die lokalen Maxima zur Extraktion der Linien identifiziert werden. Das Ergebnis liefert für jede detektierte Gerade die dazugehörigen Linienparameter d und α sowie die Linienendpunkte (x_{E1}, y_{E1}) und (x_{E2}, y_{E2}) . Diese Parameter müssen in Anbetracht der üblichen Darstellung von Bildmatrizen mit Bezug auf den Koordinatenursprung in der linken oberen Bildecke gemäß Abbildung 28 interpretiert werden. Die nachfolgende Auswertung bezieht sich zur besseren Veranschaulichung auf den Winkel $\tilde{\alpha} = 90^\circ - \alpha$.




Abbildung 28: Geometrische Bedeutung der Linienparameter in MATLAB.

Die Hough-Matrix des binären Kantenbilds von Schlag 1 (Abb. 26a) ist in Abbildung 29a und die daraus extrahierten Linien sind in Abbildung 29b dargestellt. In dem Parameterraum werden die resultierenden Sinuskurven für einen Wertebereich von -90° bis $+90^\circ$ für den Winkel α abgetragen. Der Abstand d kann dabei Werte zwischen $-D$ und $+D$ annehmen, wobei D der Diagonalen des Bildraums entspricht. Anhand dieser Parameterdarstellung lassen sich parallel verlaufende Bildraum-Geraden erkennen, da die korrespondierenden Maxima über demselben Winkel, also in derselben Spalte der Matrix, auftauchen. Dies ist auch bei dem hier untersuchten Beispiel der Fall, wobei in der Hough-Matrix zehn übereinanderliegende Maxima bei einem Winkel α von ungefähr 20° gezählt werden können, die den im Kantenbild detektierten parallel verlaufenden Fahrgassen entsprechen.

Mit der Hough-Transformation kann ein Großteil der Fahrgassen detektiert werden, wobei die Linienendpunkte oftmals nicht mit denen der Fahrgassen übereinstimmen. Diese Abweichungen können auf Bildrauschen und die angrenzenden Randstrukturen zurückgeführt werden, die das Ergebnis der HT beeinflussen. Die globale Transformation der Daten führt dazu, dass auch Punkte einer Geraden zugewiesen werden, die räumlich weit voneinander entfernt sind und nicht zu ein und demselben Objekt gehören. In Folge dessen werden auch andere Linien in dem Kantenbild detektiert, die für das

Auge nicht ersichtlich und bei der Selektion der Fahrgassen unerwünscht sind. Aufgrund der vorausgesetzten Segmentierung des Schlags und der typischen Charakteristik der Fahrgassengeometrie kann jedoch davon ausgegangen werden, dass ein Großteil der detektierten Linien den Fahrgassen entspricht. Nichtsdestotrotz gilt es in den folgenden Schritten, die repräsentativen Fahrgassenlinien zu identifizieren und wenn nötig zu korrigieren.

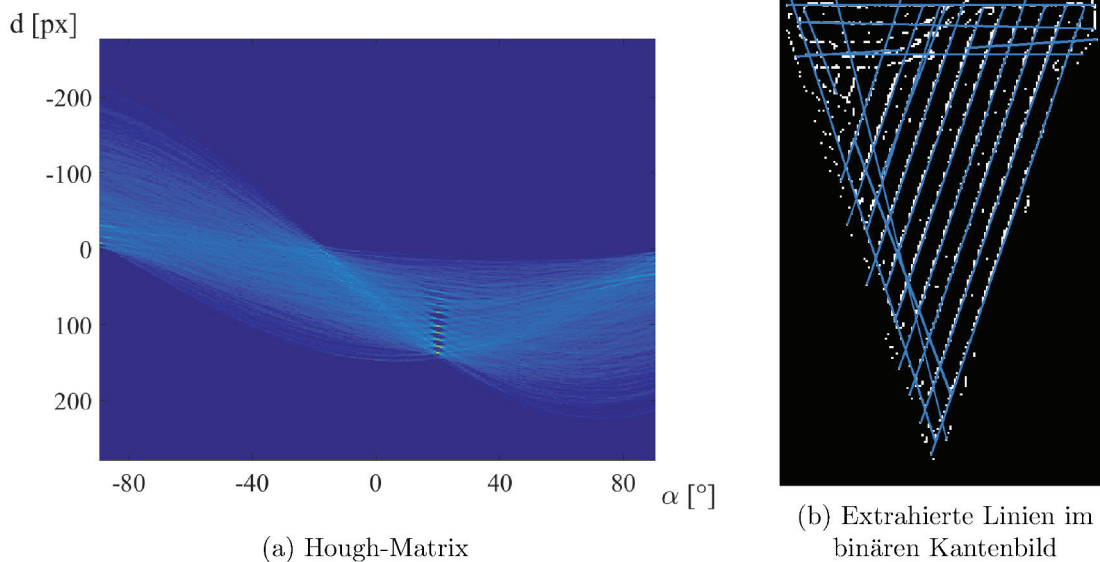


Abbildung 29: Ergebnisse der Hough-Transformation am Beispiel von Schlag 1.

(2) Selektion der Linien in Vorzugsrichtung

Die Identifikation der Fahrgassenlinien erfordert ein geeignetes Kriterium zur eindeutigen Differenzierung der mit der Hough-Transformation extrahierten Linien. Mit der Annahme, dass ein Großteil der Fahrgassen eines Schlags parallel verläuft und somit gleich ausgerichtet ist, bietet sich eine Separation der gesuchten Linien anhand des Winkels $\tilde{\alpha}$ an. Dazu wird eine Vorzugsrichtung $\tilde{\alpha}_V$ definiert, die dem am häufigsten auftretenden Winkel aller detektierten Linien entspricht und durch eine einfache Analyse der Ausrichtungswinkel bestimmt werden kann. Alle Linien, die diese Vorzugsrichtung aufweisen, repräsentieren demnach mit hoher Wahrscheinlichkeit eine Fahrgasse. Da die Ergebnisse der Hough-Transformation keine exakte Darstellung der detektierten Linien garantiert, wird zudem eine zulässige Toleranz festgelegt, mit der auch Linien mit einem zur Vorzugsrichtung gering abweichendem Winkel als Fahrgassenlinie identifiziert werden können. Am Beispiel von Schlag 1 wird eine Vorzugsrichtung von $\tilde{\alpha}_V = 71^\circ$ bestimmt. Mit dieser Vorzugsrichtung und unter einer Toleranz von $\pm 1^\circ$ werden die zehn Linien identifiziert, die bereits in der Hough-Matrix als Parallelen zu erkennen waren und allesamt eine Fahrgasse repräsentieren (Abb. 30).




Abbildung 30: Selektion der Linien in Vorzugsrichtung.

Mit der Voraussetzung einer erfolgreichen Hough-Transformation, verspricht diese Vorgehensweise, stets einen Großteil der geraden Fahrgassen zu identifizieren. Jedoch erfolgt dabei keine Berücksichtigung variierender Ausrichtungen der Fahrgassen aufgrund einer möglichen Unterteilung des Schlags, wie es bei dem Beispiel von Schlag 1 der Fall ist. Folglich kann der Schlag in der nachstehenden Prozessierung nicht flächendeckend analysiert werden.

(3) Approximation der Linien

Bei näherer Betrachtung der detektierten Linien fällt auf, dass diese größtenteils von den im Kantenbild sowie den im RGB-Bild sichtbaren Fahrgassen abweichen (Abb. 31). Diese ungenaue Darstellung kann auf die fehlerbehaftete Detektion der Linienendpunkte zurückgeführt werden, die zu einer schlechten Annäherung der Linien führt. Mit Hilfe einer geeigneten Approximation des mittleren Linienverlaufs sollen die Linienendpunkte korrigiert werden. Dies erfolgt durch einen Polynomfit für alle Pixel, die einer Linie zugehörig sind. Aufgrund der Abweichung der detektierten Linien zu den Kanten im Binärbild gilt es dabei, alle Pixel entlang der Linie innerhalb einer definierten $N \times N$ Umgebung zu berücksichtigen, wobei N beliebige ungerade Werte größer Eins annehmen kann. Diese Pixelumgebung sollte einerseits groß genug sein, um die Verschiebung der Linie zur tatsächlichen Fahrgasse abzudecken, doch andererseits nicht allzu groß, damit die Approximation der Linie nicht durch benachbarte Bestandspixel verfälscht wird. Demnach bietet es sich an, für N den nächstgrößeren ungeraden Wert ausgehend von der Breite der Fahrgassen zu wählen. Gemäß der geschätzten Fahrgassenbreite t_2 von $3m$ und der Bodenauflösung GSD von 4 m , kann davon ausgegangen werden, dass die Fahrgassen im Bild ungefähr ein Pixel breit erscheinen, woraus sich eine Pixelumgebung mit $N = 3$ ergibt. Die Anpassung der Linienendpunkte (x_{E1}, y_{E1}) und (x_{E2}, y_{E2}) erfolgt schließlich jeweils mit Hilfe der berechneten Koeffizienten des Polynomfits.




Abbildung 31: Abweichung der detektierten Linien zu den tatsächlichen Fahrgassen im Kantenbild (links) und in der RGB-Darstellung (rechts).





Abbildung 32: Approximation der detektierten Linien

Die aus diesem Approximationsverfahren resultierenden Linien stellen eine akzeptable Annäherung des Fahrgassenverlaufs dar (Abb. 32). Bei der gewählten Vorgehensweise kann die Detektion unerwünschter Pixel im Fall von fehlerhaften Liniensegmenten nicht ausgeschlossen werden, was die Approximation des Liniensverlaufs beeinträchtigen kann. Nichtsdestotrotz ist das Ergebnis der Approximation an dieser Stelle für alle drei Schläge durchaus ausreichend und liefert gute Voraussetzungen für die nachfolgenden Arbeitsschritte.

(4) Korrektur der Liniendpunkte

Im letzten Schritt zur Detektion der gesuchten Strukturen soll eine Korrektur der detektierten Liniendpunkte erfolgen, um fehlerhafte Selektionen zu vermeiden. Diese Fehler sind sowohl auf die Funktionsweise der Hough-Transformation als auch auf ungünstige Voraussetzungen im Kantenbild zurückzuführen. Aufgrund dessen werden die Fahrgassen teilweise durch zu lange Linien repräsentiert, die über den Bestand oder auch Strukturelemente hinauslaufen.

Für die Korrektur der Fahrgassenlinien bietet sich eine Analyse des Grauwertprofils entlang der detektierten Linien mit Hilfe der in Kapitel 4.3.1 erzeugten gefilterten NDSI-Auswertung (Abb. 25) an. In dieser Grauwertdarstellung können Helligkeitsverläufe besser interpretiert werden als in der binären Darstellung des Kantenbilds. Da die Fahrgassen im Vergleich zum angrenzenden Bestand deutlich heller erscheinen, ist zu erwarten, dass fehlerhaft detektierte Liniensegmente durch signifikante Schwankungen im Grauwertprofil zum Vorschein kommen. Das Grauwertprofil einer Linie ergibt sich durch alle der Linie zugehörigen Pixel zwischen den Liniendpunkten und ihren korrespondierenden Grauwerten. Bei der Ermittlung der Linienpixel werden zudem die Pixelkoordinaten und ein fortlaufender Index erfasst, um später von einer Stelle des Grauwertprofils auf die entsprechenden Pixelkoordinaten im Bild schließen zu können.

Die Grauwertprofile der Linien sind durch starkes Rauschen geprägt, das auf die Intensitätsunterschiede innerhalb der Fahrgassen zurückzuführen ist. Zur besseren Verarbeitung erfolgt eine Glättung der Grauwertverläufe mit einem Mittelwertfilter der Länge $2\tilde{M} + 1$. Die Filtergröße \tilde{M} wird jeweils in Abhängigkeit der Linie bestimmt und beträgt 0.5% der Summe aller Linienpixel, was einem empirisch ermittelten Wert entspricht und sich für die untersuchten Testdaten als geeignet erwiesen hat.

Gängige Analysen eines Grauwertprofils zur Detektion von Helligkeitsschwankungen beziehungsweise Kanten behelfen sich der ersten oder zweiten Ableitung (Jähne 2012). Da die Kanten im Grauwertverlauf den Stellen des steilsten Anstiegs entsprechen, können sie durch die Extremwerte der ersten Ableitung oder durch die Nulldurchgänge der zweiten Ableitung identifiziert werden. Dieser Ansatz soll auch hier genutzt werden, um mögliche Lücken entlang der Linie detektieren zu können. Da die lokalen Helligkeitsschwankungen im Grauwertprofil jedoch zu unzähligen Extremwerten der ersten beziehungsweise zu Nulldurchgängen der zweiten Ableitung führen, gilt es, ein weiteres Kriterium zur eindeutigen Identifikation kritischer Stellen zu definieren. Dazu bietet sich eine Analyse der Extremwerte anhand statistischer Kennwerte an, wobei eine sehr große Varianz auf Unregelmäßigkeiten entlang der Linie zurückgeführt werden kann.

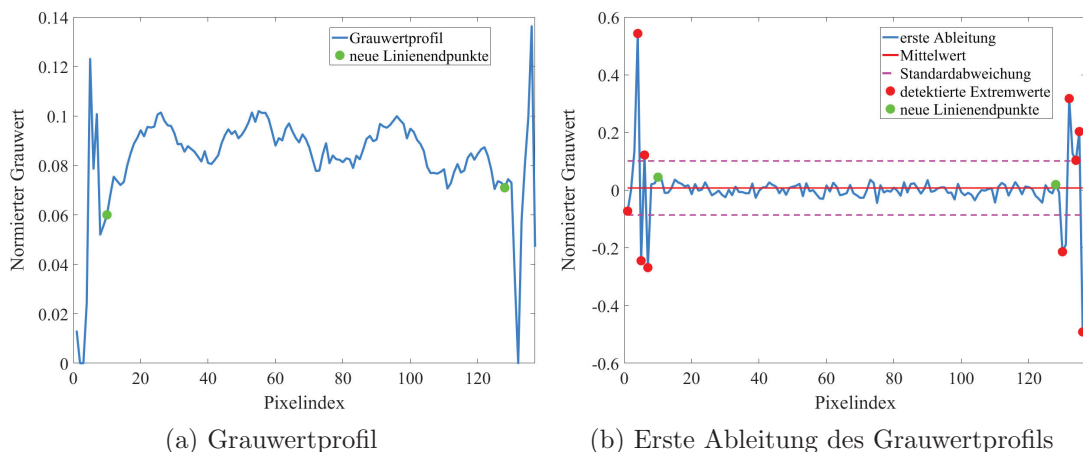


Abbildung 33: Extremwertanalyse des Grauwertprofils einer ausgewählten Linie zur Bestimmung der neuen Linienendpunkte.

Abbildung 33 zeigt das Grauwertprofil einer ausgewählten Linie sowie dessen erste Ableitung und den Mittelwert und die Standardabweichung der ermittelten Extremwerte. Zur Detektion von Unregelmäßigkeiten, werden alle aufeinanderfolgenden Extremwerte bestimmt, deren Grauwertdifferenz über der Standardabweichung liegt. Anhand dieser Extremwerte lässt sich das größte fehlerfreie Liniensegment ohne starke Schwankungen im Grauwertprofil und somit auch die neuen Linienendpunkte bestimmen. In Abbildung 34 werden die daraus resultierenden Linien (grün) im Vergleich zu den ursprünglich detektierten Linien (blau) für alle drei Schläge dargestellt. Im Fall von Schlag 1 können alle Linien korrekt begrenzt werden. Bei den anderen beiden Schlägen ist der Korrekturansatz jedoch nicht für alle Linien erfolgreich.




Abbildung 34: Einfache Korrektur der Linienendpunkte.

Eine nähere Betrachtung der Grauwertprofile einiger bisher unzureichend korrigierter Linien zeigt, dass die Grauwerte der neu definierten Linienendpunkte im Vergleich zu den anderen korrekt begrenzten Linien eine deutlich größere Differenz aufweisen (Abb. 35). Eine Anpassung der Linienendpunkte in Abhängigkeit ihrer Grauwertdifferenz verspricht, das Problem der fehlerhaften Begrenzung zu lösen. Dazu sollen jeweils die Linienendpunkte angepasst werden, deren Grauwertdifferenz über der zuvor ermittelten Standardabweichung der Extremwerte liegt. Für den Endpunkt mit dem niedrigeren Grauwert wird der nächste in Richtung Linienmittelpunkt liegende Extremwert bestimmt, dessen Grauwertdifferenz zum korrespondierenden Linienendpunkt innerhalb der Standardabweichung liegt.




Abbildung 35: Erweiterte Anpassung der Linienendpunkte anhand des Grauwertprofils am Beispiel einer ausgewählten Linie.

Mit dieser nachfolgenden Korrektur der Linienendpunkte können alle Linien der drei Schläge erfolgreich begrenzt werden (Abb. 36). Dabei erfolgt in einigen Fällen erneut eine

Verschiebung der Linien zu den tatsächlichen Fahrgassen aufgrund ungünstig gewählter Endpunkte, was durch eine wiederholte Approximation des mittleren Linienverlaufs angepasst wird. Bei dem hier vorgestellten Ansatz werden zudem auch theoretisch fehlerfreie Liniensegmente entfernt, da die Schwankungen innerhalb der Fahrgassen teilweise sehr groß sind und mit der gewählten Vorgehensweise nicht ausreichend differenziert werden können. Die Unterdrückung solcher relevanter Strukturen wird hier jedoch in Kauf genommen, um auf der anderen Seite mit hoher Wahrscheinlichkeit die Fehlerfreiheit der detektierten Linien garantieren zu können.




Abbildung 36: Erweiterte Korrektur der Linienendpunkte.

Die mit der Fahrgassenselektion ermittelten Fahrgassenabstände betragen bei Schlag 1 und 2 jeweils 9 Pixel beziehungsweise ungefähr $36m$. Für diese Schläge stellt der geschätzte Fahrgassenabstand des Fahrspurmodells somit eine sehr gute Näherung dar. Im Fall von Schlag 3 weisen die selektierten Fahrgassen hingegen einen mittleren Abstand von 7 Pixeln, also ungefähr $28m$ auf. Trotz dieser Abweichung zum geschätzten



Abbildung 37: Ergebnis der Fahrgassenselektion für Schlag 3 mit angepasstem Fahrspurmodell.

Fahrgassenabstand, liefert der Ansatz zur Fahrgassenselektion ein mit den anderen Schlägen vergleichbar gutes Ergebnis. Eine Anpassung des geschätzten Fahrgassenabstands für Schlag 3 mit $t_3 = 28m$ führt zu dem in Abbildung 37 dargestellten Ergebnis. Mit dieser Anpassung konnte die Fahrgassenselektion geringfügig verbessert werden, wobei nun auch die äußerste linke Fahrgasse erkannt wird. Dies kann auf eine günstigere Größe des lokalen Selektionsfilters zurückgeführt werden, der in Abhängigkeit des geschätzten Fahrgassenabstands bestimmt wird und zuvor eine Unterdrückung der äußeren Fahrgassen bewirkt hat. Im Vergleich zum Ergebnis mit $t_3 = 36m$ bleibt hier jedoch die Detektion der äußersten rechten Fahrgasse aus, wobei diese aufgrund des angrenzenden Strukturelements auch fehlerbehaftet sein kann.

4.4 Spektrale Entmischung der Fahrgassenpixel

Anhand der im vorherigen Schritt selektierten Fahrgassen gilt es nun, alle Fahrgassenpixel zu identifizieren und die korrespondierenden Bodenspektren der freiliegenden Fahrspuren zu ermitteln. Dies soll anhand eines Entmischungsansatzes erfolgen, der sich auf das lineare spektrale Mischungsmodell bezieht (siehe Kapitel 2.4.1). Nach diesem Modell setzt sich ein Pixelspektrum aus einer Linearkombination der Einzelspektren zusammen, welche durch ihre Abundanzen im Pixel gewichtet werden. Im vorliegenden Fall wird vereinfacht angenommen, dass sich das Spektrum eines Fahrgassenpixels \vec{r}_F mit

$$\vec{r}_F = a_1 \cdot \vec{e}_1 + a_2 \cdot \vec{e}_2 \quad (4.2)$$

lediglich aus dem Bestand mit der Fläche a_1 und dem Bestandsspektrum \vec{e}_1 sowie den blanken Fahrspuren mit der Fläche a_2 und dem Bodenspektrum \vec{e}_2 zusammensetzt (Abb. 38). Somit besteht das lineare spektrale Mischungsmodell der Fahrgassenpixel aus zwei festen Endmitgliedern ($m = 2$), wobei der Merkmalsraum durch $n = 122$ Komponenten (Spektralbänder) aufgespannt wird. Bei diesem Ansatz erfolgt keine Modellierung möglicher Schattenanteile.




Abbildung 38: Mögliche Flächenverteilung eines Fahrgassenpixels.

Für die spektrale Entmischung der Fahrgassenpixel wird ein modifizierter Ansatz untersucht, der die Flächenverteilung im Mischpixel sowie das Bestandsspektrum als ge-

ben voraussetzt. Die Abundanzen der Fahrgassenpixel sollen durch ein wissensbasiertes Fahrspurmodell und eine geometrische Analyse auf Subpixelniveau geschätzt werden. Das Bestandsspektrum wird anhand der benachbarten puren Bestandspixel direkt aus den Daten abgeleitet. Mit diesen angenäherten Größen soll das gesuchte Bodenspektrum schließlich durch ein geeignetes Optimierungsverfahren und unter Einhaltung notwendiger Nebenbedingungen des linearen spektralen Entmischungsmodells aus den Fahrgassenpixeln abgeleitet werden. In Folge dessen untergliedert sich der Prozessschritt zur Entmischung der Fahrgassenpixel in drei Teilschritte, die nachfolgend näher erläutert werden. Diese Teilschritte werden in der praktischen Umsetzung durch die Methoden *geomAnalysis()*, *getRefPlantSpec()* und *getSoilSpec()* realisiert und in dem Modul *trackUnmixing* zusammengefasst (vgl. Abb. 17).

4.4.1 Abschätzung der Abundanzen

Zur Abschätzung der Abundanzen a_1 und a_2 (Gl. 4.2) werden alle Fahrgassenpixel identifiziert und deren relativer Fahrspuranteil im Pixel näherungsweise bestimmt. In diesem Sinne entspricht ein Pixel einem Fahrgassenpixel, sobald es einen Teil einer Fahrspur abdeckt. Diese Pixel lassen sich durch eine geeignete Modellierung der Fahrspurgeometrie auf Subpixelniveau identifizieren. Die Flächenberechnung erfolgt schließlich mit einer geometrischen Verschneidung zwischen Pixel- und Fahrspurgeometrie.

An erster Stelle steht eine Skalierung der Ausgangsdaten, um eine subpixelgenaue Modellierung und Flächenberechnung zu ermöglichen. Diese Skalierung wird für die selektierten Fahrgassenlinien sowie für eine Referenzmatrix der Größe der segmentierten Szene um den Faktor S vorgenommen. Ein Pixel der Ausgangsmatrix entspricht somit einem Quadrat (Pixel-Quadrat) der Größe $S \times S$ in den skalierten Daten. Für den Faktor S wird ein ungerader Wert gewählt, damit die skalierten Pixel-Quadrate einen eindeutigen Mittelpunkt aufweisen. Mit zunehmendem Skalierungsfaktor kann die Genauigkeit der Flächenberechnung erhöht werden, was jedoch auch mit einem größeren Rechenaufwand einhergeht. Für die untersuchten Testdaten wird ein Faktor S von 11 verwendet, der zu einer Genauigkeit von $0.13 m^2$ in der Flächenberechnung führt.

Die Modellierung der Fahrspurgeometrie erfolgt anhand der skalierten Fahrgassenlinien sowie den geschätzten Fahrspurparametern des Fahrspurmodells (Kapitel 3.4). Dabei gilt es, jeweils die beiden eine Fahrspur eingrenzenden Linien zu modellieren, die nach dem Fahrspurmodell einem streng geradlinigen und parallelem Verlauf folgen. Diese Linien ergeben sich durch eine Verschiebung des mittleren Fahrgassenverlaufs um die Abstände δ_1 und δ_2 zu beiden Seiten (Abb. 39).

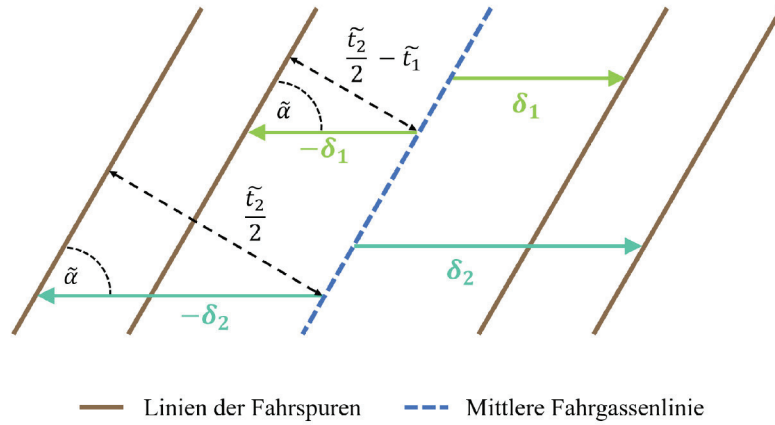


Abbildung 39: Geometrische Verschiebung einer mittleren Fahrgassenlinie um δ_1 und δ_2 entlang der x-Achse zur Modellierung der Fahrspurgeometrie.

Die Abstandsmaße berechnen sich aus den transformierten Werten der Fahrspurbreite \tilde{t}_1 und der Fahrgassenbreite \tilde{t}_2 sowie dem winkelabhängigen Faktor $\kappa_{\tilde{\alpha}}$ mit

$$\delta_1 = \left(\frac{\tilde{t}_2}{2} - \tilde{t}_1 \right) \cdot \kappa_{\tilde{\alpha}}$$

und

$$\delta_2 = \frac{\tilde{t}_2}{2} \cdot \kappa_{\tilde{\alpha}}.$$

Dazu werden die metrischen Größen des Fahrspurmodells t_1 und t_2 mit

$$\tilde{t}_2 = \frac{t_2}{GSD} \cdot S \quad \text{und} \quad \tilde{t}_1 = \frac{t_1}{GSD} \cdot S$$

anhand der Bodenaufösung GSD in Pixelabstände überführt und mit dem Faktor S an die Skalierung der Daten angepasst. Die Verschiebungsrichtung wird in Abhängigkeit des Ausrichtungswinkels der selektierten Fahrgassen $\tilde{\alpha}$ bestimmt. Für $\tilde{\alpha} > 45^\circ$ erfolgt die Verschiebung entlang der x-Achse des Pixelkoordinatensystems mit $\kappa_{\tilde{\alpha}} = (\sin(\tilde{\alpha}))^{-1}$ und für $\tilde{\alpha} < 45^\circ$ entlang der y-Achse mit $\kappa_{\tilde{\alpha}} = (\cos(\tilde{\alpha}))^{-1}$.

Anschließend erfolgt die geometrische Verschneidung der modellierten Fahrspurlinien mit den Pixel-Quadraten der Größe $S \times S$, welche die für die Flächenberechnung erforderlichen Schnittpunkte liefert. Bei der gegebenen geometrischen Auflösung und den geschätzten Fahrspurparametern können dabei vier Fälle unterschieden werden, wobei sich entweder eine Fahrspur in zwei beziehungsweise vier Punkten oder zwei Fahrspuren in sechs beziehungsweise acht Punkten mit einem Pixel-Quadrat schneiden (Abb. 40). In einigen Fällen ist es erforderlich zusätzlich die Eckpunkte zu bestimmen, die den Polygonen der zu berechnenden Flächen zugehörig sind.




Abbildung 40: Fallunterscheidung der geometrischen Verschneidung eines Pixels (grün) mit den Fahrspurlinien (braun) und den resultierenden Schnittpunkten (rot) sowie den ergänzenden Polygonpunkten (orange).

Die Flächenberechnung erfolgt anhand aller \tilde{n} detektierten Schnitt- beziehungsweise Eckpunkte (x_i, y_i) und unter Verwendung der Gauß'schen Trapezformel (Gruber und Joeckel 2011)

$$F = \frac{1}{2} \sum_{i=1}^{\tilde{n}} (y_i + y_{i+1}) \cdot (x_i - x_{i+1}) .$$

Im Fall zweier getrennter Flächen ist der Fahrspuranteil durch die Summe der separaten Polygonflächen mit den korrespondierenden Schnitt- und Eckpunkten definiert. Eine nachfolgende Normierung auf die Gesamtfläche der Pixel-Quadrate ($F_{Pix} = S^2$) liefert schließlich die relativen Flächenanteile.

Die resultierenden geschätzten Fahrspurflächen \hat{a}_2 variieren bei den untersuchten Schlägen zwischen 0.8% und 33.5% (Schlag 1), 23.6% (Schlag 2) beziehungsweise 23.1% (Schlag 3) der Gesamtfläche eines Pixels. In Anbetracht der Summenbedingung des linearen spektralen Entmischungsmodells ist somit auch der angenäherte Flächenanteil des Bestands mit $\hat{a}_1 = 1 - \hat{a}_2$ pro Fahrgassenpixel bekannt.

Mit diesem Ansatz werden somit auch die Fahrgassenpixel identifiziert, die sich aufgrund geringer Fahrspuranteile und in Folge der Mischpixelcharakteristik in der RGB-Darstellung optisch nicht gegenüber dem Bestand hervorheben und die wegen der hohen spektralen Ähnlichkeit zu den Bestandspixeln bei der Erzeugung des binären Kantenbilds auch nicht erkannt werden können. Dieser Modellansatz unterliegt jedoch der Annahme, dass die Fahrspuren an jeder Stelle unbedeckt und frei von Vegetation oder anderen Oberflächenmaterialien sowie für den Fernerkundungssensor sichtbar sind.

4.4.2 Ermittlung des Bestandsreferenzsignals

Der hier zu untersuchende Entmischungsansatz bedarf eines geeigneten Referenzspektrums für den zwischen den Fahrspuren liegenden und den angrenzenden Bestand im Fahrgassenpixel (Abb. 38). Bei dem Bestandssignal handelt es sich um ein Mischsignal, das sich aus der Reflexion des Untergrunds, bestehend aus Boden, abgestorbenen Pflanzenteilen, Steinen etc. sowie aus den Mehrfachreflexionen innerhalb des Pflanzenbestands zusammensetzt. Mit der Annahme, dass dieses Mischsignal ebenfalls innerhalb des Pflanzenbestands vorzufinden ist, soll das Bestandsreferenzsignal anhand von benachbarten reinen Bestandspixeln bestimmt werden. Dies soll individuell pro Fahrgassenpixel und unter Berücksichtigung möglicher regionsabhängiger Unterschiede der spektralen Signatur erfolgen. Diese Unterschiede können zum Beispiel auf unterschiedliche Pflegemaßnahmen im Fall einer Teilschlagbewirtschaftung, die natürliche spektrale Variabilität der Vegetation, topographische Bedingungen oder auch auf die Bodenheterogenität zurückgeführt werden.

Zur Extraktion des Bestandsreferenzsignals gilt es, möglichst geeignete Pixel zu detektieren, die nur Teile des Bestands abdecken und eine hohe Bestandsdichte aufweisen. Unter der Annahme, dass der Bestand in der Mitte zweier Fahrgassen bei optimaler Bewirtschaftung mit großer Wahrscheinlichkeit eine sehr hohe Pflanzendichte aufweist, sollen die mittig zwischen zwei Fahrgassen liegenden Bestandspixel berücksichtigt werden. Die Detektion dieser Pixel erfolgt gemäß der Bewirtschaftung senkrecht und zu beiden Seiten der Fahrgasse. Das Bestandsreferenzsignal ergibt sich schließlich durch die Mittelung der beiden korrespondierenden Spektren und erhält im Folgenden die Notation \hat{e}_1 .

Da die spektrale Signatur des Bestands aufgrund verschiedener Ursachen (zum Beispiel variierende Pflanzendichte, Krankheitsbefall) auch Unregelmäßigkeiten aufweisen kann, erfolgt zusätzlich eine Analyse der detektierten Bestandspixel in Bezug auf eine definierte Pixelumgebung. Somit sollen mögliche Ausreißer erkannt werden, die eine schlechte Referenz für das Bestandssignal im Fahrgassenpixel darstellen.



Abbildung 41: Detektion der Bestandspixel (grün) zu beiden Seiten eines Fahrgassenpixels (blau) unter Berücksichtigung einer definierten Pixelumgebung (gelb).

Die Größe der Analyseumgebung wird in Abhängigkeit der geometrischen Auflösung sowie unter Berücksichtigung eines ausreichend großen Abstands zu den benachbarten Fahrgassen gewählt, so dass ausschließlich der Bestand abgedeckt wird. In Abhängigkeit der geometrischen Auflösung erhält die Pixelumgebung zudem eine größere Ausdehnung entlang der Fahrgassen, um ausreichend viele Bestandspixel zu erfassen. Zusätzlich erfolgt eine Anpassung an die Ausrichtung der Fahrgassen (Abb. 41).

Zur Analyse der detektierten Bestandspixel wird der Spectral Angle Mapper (SAM) gewählt, der ein Maß für die Ähnlichkeit zweier Spektren \vec{r}_1 und \vec{r}_2 darstellt und durch den Winkel

$$\beta_{SAM} = \arccos \left(\frac{\langle \vec{r}_1, \vec{r}_2 \rangle}{\|\vec{r}_1\| \cdot \|\vec{r}_2\|} \right) [rad]$$

definiert ist (Robila 2004). Ein großer Winkel zwischen den Spektren indiziert dabei eine geringe spektrale Ähnlichkeit. Der SAM gilt als unempfindlich gegenüber Beschattungseffekten, wodurch auch unterschiedlich beschattete aber spektral ähnliche Objekte identifiziert werden können (Girouard et al. 2004). Die Verwendung des Spectral Angle Mapper erfordert die Bestimmung eines Referenzspektrums, welches maßgebend für das zu erwartende Bestandsspektrum ist. Dazu wird das Pixel mit dem höchsten NDVI innerhalb der Analyseumgebung gewählt und unter Berücksichtigung möglicher regionaler Variationen für jede Position der Analyseumgebung angepasst. Da die Bestandsspektren nicht identisch sind und stets eine räumliche Variabilität aufweisen, gilt es, einen Schwellwert zu definieren, mit dem mögliche Ausreißer eindeutig bestimmt werden und eine Abweichung vom Referenzspektrum zulässig ist. Dazu wurde eine Toleranz von $0.05rad$ anhand der Testdaten empirisch ermittelt. Bei diesem Wert wurden bei den drei Schlägen alle sichtbaren Unregelmäßigkeiten (zum Beispiel angrenzende Fahrgassenpixel, Wendeschleifen) und möglichst wenige Pixel im Bestand als Ausreißer bestimmt.

Die detektierten Ausreißer werden schließlich bei der Bestimmung des Bestandsreferenzsignals vernachlässigt. Im ungünstigsten Fall sind die Bestandspixel zu beiden Seiten der Fahrgasse ungültig und es kann kein Referenzspektrum ermittelt werden. Solche Lücken werden im Anschluss durch eine Interpolation der Referenzspektren benachbarter Fahrgassenpixel geschlossen.

Der hier vorgestellte Ansatz erfordert mit der Detektion von mittig liegenden Bestandspixeln eine Mindestbodenauflösung, welche in mindestens drei zwischen den Fahrgassen liegenden Pixeln resultiert. Bei einem maximalen Fahrgassenabstand von $36m$ und unter Berücksichtigung des maximalen Pixelabstands bei einer Neigung der Fahrgassen von 45° ergibt sich eine minimale geometrische Auflösung von $8m$ pro Pixel.

4.4.3 Ableitung des Bodensignals

Auf der Grundlage des linearen Entmischungsmodells (Gl. 4.2) soll das Bodenspektrum \vec{e}_2 für alle Fahrgassenpixel mit Hilfe des angenäherten Referenzsignals für das Bestandspektrum \vec{e}_1 und den geschätzten Abundanzen \hat{a}_1 und \hat{a}_2 abgeleitet werden. Die explizite Berechnung des Bodenspektrums anhand der gegebenen Werte und durch eine einfache Umstellung des Modells

$$\vec{e}_2 = \frac{\vec{r}_F - a_1 \cdot \vec{e}_1}{a_2} \quad (4.3)$$

liefert in jedem Fall eine Lösung, wobei der Fehler in Folge vereinfachter Modellannahmen sowie der Verwendung von Näherungswerten in einem beliebigen und fehlerbehafteten Bodenspektrum resultieren kann. Zur Berücksichtigung des Modellfehlers soll ein Ansatz gefunden werden, um das Bodenspektrum durch geeignete Nebenbedingungen zu optimieren. Die Herausforderung liegt hierbei in der Definition der Nebenbedingungen, die es anhand logischer und physikalischer Zusammenhänge der zu untersuchenden Größen zu bestimmen gilt. Gemäß der in der Literatur betrachteten Ausgleichungsansätze bei der gängigen linearen spektralen Entmischung, kann die Summenbedingung

$$\sum_{i=1}^2 a_i = 1 \quad (4.4)$$

sowie eine Eingrenzung des Wertebereichs der Abundanzen

$$0 \leq a_i \leq 1 \quad (i = 1, 2)$$

hinzugezogen werden (vgl. Kapitel 2.4.1). Unter Einhaltung der Summenbedingung kann das Entmischungsmodell aus Gleichung 4.2 mit $a_2 = 1 - a_1$ zu

$$\vec{r}_F = a_1 \cdot \vec{e}_1 + (1 - a_1) \cdot \vec{e}_2 \quad (4.5)$$

vereinfacht werden. Die Einführung der Nebenbedingung

$$e_{1j}, e_{2j} \geq 0 \quad (j = 1 \dots n) \quad (4.6)$$

soll ausschließlich positive Reflexionswerte der Spektren \vec{e}_1 und \vec{e}_2 zulassen, wobei n der Anzahl der Spektralbänder entspricht.

Die hier genannten Nebenbedingungen stellen zunächst eine unzureichende Eingrenzung der gegebenen Problematik dar. Da die mangelnde Kenntnis über das Verhalten des Bodenspektrums jedoch die Definition weiterer Nebenbedingungen erschwert, soll auf einen heuristischen Ansatz zur Optimierung des Bodenspektrums zurückgegriffen werden. Dazu wurden zwei verschiedene Optimierungsansätze untersucht.

Optimierungsansatz 1

Der erste Ansatz beruht auf der Annahme, dass sich das Bodenspektrum \vec{e}_2 innerhalb einer bestimmten räumlichen Distanz nicht sehr stark ändert und es durch ein mittleres Bodenspektrum beschrieben werden kann. Demzufolge soll das gesuchte Spektrum an ein lokales mittleres Bodenspektrum $\tilde{\vec{e}}_2$ angenähert werden, was durch eine weitere eingrenzende Nebenbedingung definiert wird,

$$\vec{e}_2 \approx \tilde{\vec{e}}_2. \quad (4.7)$$

Die Optimierung des Bodenspektrums erfolgt individuell pro Fahrgassenpixel durch den Einsatz eines gleitenden Fensters der Länge M ($M = 2 \cdot z + 1, z \in \mathbb{N}$) entlang der Fahrgassen und dem jeweils gegebenen geschätzten Flächenanteil \hat{a}_1 sowie dem angenäherten Bestandspektrum $\hat{\vec{e}}_1$. Das mittlere Bodenspektrum $\tilde{\vec{e}}_2$ wird dabei pro Fensterposition in Abhängigkeit der M Pixel angepasst, wobei das Pixel an der Stelle $\frac{M+1}{2}$ dem zu optimierenden Fahrgassenpixel entspricht.

Zur Berechnung des mittleren Bodenspektrums wird ein Modellansatz verwendet, wobei M Fahrgassenpixel in einem Spektralmodell zusammengefasst werden. Nach Gleichung 4.5 setzen sich die Pixelspektren \vec{r}_F^1 bis \vec{r}_F^M jeweils aus den Bestandsreferenzsignalen $\hat{\vec{e}}_1^1$ bis $\hat{\vec{e}}_1^M$ und den korrespondierenden geschätzten Flächenanteilen \hat{a}_1^1 bis \hat{a}_1^M sowie dem über alle M Pixel fixierten mittleren Bodenspektrum $\tilde{\vec{e}}_2$ zusammen.

$$\begin{pmatrix} \vec{r}_F^1 \\ \vec{r}_F^2 \\ \vdots \\ \vec{r}_F^M \end{pmatrix} = \begin{pmatrix} \hat{a}_1^1 \cdot \hat{\vec{e}}_1^1 + (1 - \hat{a}_1^1) \cdot \tilde{\vec{e}}_2 \\ \hat{a}_1^2 \cdot \hat{\vec{e}}_1^2 + (1 - \hat{a}_1^2) \cdot \tilde{\vec{e}}_2 \\ \vdots \\ \hat{a}_1^M \cdot \hat{\vec{e}}_1^M + (1 - \hat{a}_1^M) \cdot \tilde{\vec{e}}_2 \end{pmatrix} \quad (4.8)$$

Die Minimierung dieses Gleichungssystems über die Summe der M betrachteten Pixel nach $\tilde{\vec{e}}_2$

$$\min_{\tilde{\vec{e}}_2} \sum_{k=1}^M \left\| \left(\vec{r}_F^k - \hat{a}_1^k \cdot \hat{\vec{e}}_1^k \right) - \left(1 - \hat{a}_1^k \right) \cdot \tilde{\vec{e}}_2 \right\|^2$$

liefert schließlich das mittlere Bodenspektrum

$$\tilde{\vec{e}}_2 = \frac{\sum_{k=1}^M (1 - \hat{a}_1^k) \cdot \left(\vec{r}_F^k - \hat{a}_1^k \cdot \hat{\vec{e}}_1^k \right)}{\sum_{k=1}^M (1 - \hat{a}_1^k)^2}. \quad (4.9)$$

Dieser Ansatz zur Bestimmung eines mittleren Bodenspektrums eignet sich insbesondere bei Fahrgassen, deren Ausrichtung nicht mit der x- beziehungsweise y-Achse des Pixelkoordinatensystems übereinstimmt. Folglich weist die Flächenverteilung aufeinanderfolgender Fahrgassenpixel eine höhere Varianz als bei senkrecht oder waagrecht verlaufenden Fahrgassen auf, wodurch das betrachtete Spektralmodell günstiger konditionierte Gleichungen enthält und sich die Lösungsmenge besser einschränken lässt.

Für das hier betrachtete lineare Optimierungsproblem wird die Zielfunktion $\Phi(\vec{e}_2)$ nach Gleichung 4.5 unter Einhaltung der Summenbedingung (Gl. 4.4) sowie der Berücksichtigung der eingeführten Nebenbedingung aus Gleichung 4.7 mit

$$\Phi(\vec{e}_2) = \|(\vec{r}_F - \hat{a}_1 \cdot \hat{\vec{e}}_1) - (1 - \hat{a}_1) \cdot \vec{e}_2\|^2 + \mu \cdot \|\tilde{\vec{e}}_2 - \vec{e}_2\|^2 \quad (4.10)$$

definiert. Diese Zielfunktion gilt es im Rahmen der Optimierung zu minimieren, wobei der Einfluss der Nebenbedingung $\vec{e}_2 \approx \tilde{\vec{e}}_2$ durch den Kontrollparameter μ geregelt und das resultierende Bodenspektrum unter Einhaltung der Positivität (Gl. 4.6) auf den ersten Quadranten projiziert wird,

$$\min_{\vec{e}_2 \in 1.Q.} \|(\vec{r}_F - \hat{a}_1 \cdot \hat{\vec{e}}_1) - (1 - \hat{a}_1) \cdot \vec{e}_2\|^2 + \mu \cdot \|\tilde{\vec{e}}_2 - \vec{e}_2\|^2 .$$

Das Minimum der Zielfunktion ist durch die Nullstelle der ersten Ableitung definiert und liefert das optimale Bodenspektrum eines Fahrgassenpixels mit der geschätzten Fläche \hat{a}_1 und dem angenäherten Bestandsspektrum $\hat{\vec{e}}_1$ unter der Annahme, dass sich dieses Spektrum an ein mittleres Bodenspektrum $\tilde{\vec{e}}_2$ annähert,

$$\vec{e}_2 = \frac{\vec{r}_F - \hat{a}_1 \cdot \hat{\vec{e}}_1 + \mu \cdot \tilde{\vec{e}}_2}{1 - \hat{a}_1 + \mu} .$$

Ohne den Einfluss der Nebenbedingung ($\mu = 0$) erfolgt damit die explizite Berechnung des Bodenspektrums wie in Gleichung 4.3.

Zur beispielhaften Demonstration dieses Ansatzes werden drei Fahrgassenpixel mit unterschiedlich großem Fahrspuranteil betrachtet. Gemäß der bei der Flächenabschätzung auftretenden Spannweite des Fahrspuranteils wird ein Pixel mit hohem Fahrspuranteil von 32%, ein Pixel mittleren Fahrspuranteils von 17% und eins mit geringem Fahrspuranteil von 5% ausgewählt. In den Abbildungen 42, 43 und 44 wird dazu jeweils die explizite Berechnung des Bodenspektrums mit $\mu = 0$ dem Ergebnis des Optimierungsansatzes mit $\mu = 0.5$ beispielhaft gegenübergestellt. Zur Berechnung des mittleren Bodenspektrums werden hier $M = 21$ Fahrgassenpixel berücksichtigt.

Die spektrale Signatur der Fahrgassenpixel weist in allen drei Fällen eine sehr hohe Ähnlichkeit zur Signatur des Bestandsreferenzsignals auf, deren Verlauf sehr stark durch die spektrale Charakteristik von grüner Vegetation geprägt ist. Mit zunehmendem Fahrspuranteil unterliegt das Pixelspektrum einer verstärkten Abschwächung, wobei sich Pixel- und Bestandsspektrum zunehmend unterscheiden. Der überwiegende Einfluss des Bestandsspektrums auf die Mischpixelcharakteristik ist dabei auf die anteilig größere Fläche des Bestands innerhalb der Fahrgassenpixel zurückzuführen. Die spektrale Signatur des mittleren Bodenspektrums ähnelt ebenfalls der des Pixel- beziehungsweise Bestandsspektrums und liegt wie zu erwarten im VIS und SWIR über und im NIR unter dem Bestandssignal.

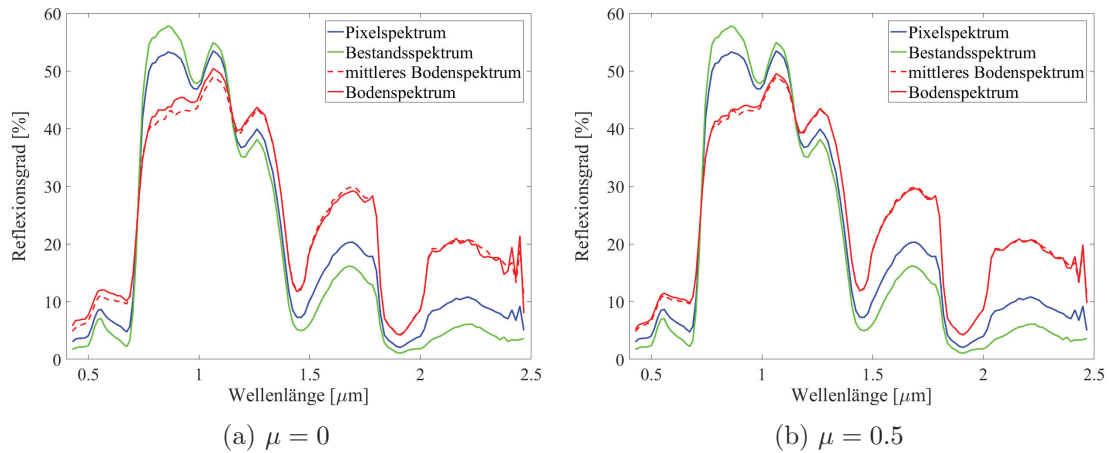


Abbildung 42: Optimierungsansatz 1 am Beispiel eines Fahrgassenpixels mit 32% Fahrspuranteil.

Die explizite Auflösung des Bodenspektrums führt bei dem Fahrgassenpixel mit hohem Fahrspuranteil zu einem dem mittleren Bodenspektrum sehr ähnlichen Ergebnis (Abb. 42a). Mit abnehmendem Flächenanteil der Fahrspuren treten bei der expliziten Berechnung des Bodenspektrums hingegen zunehmend stärkere Schwankungen mitunter sehr hohen sowie negativen Spektralwerten auf, was der physikalischen Natur des Bodens widerspricht (Abb. 43a und 44a). Es wird vermutet, dass die extremen Schwankungen des Bodenspektrums bei einem Fahrspuranteil von 5% auf eine fehlerhafte Annäherung des Fahrspuranteils sowie des Bestandsreferenzspektrums zurückzuführen sind, die aufgrund der geringen Differenz zwischen Pixel- und Bestandsspektrum verstärkt zum Ausdruck kommen.

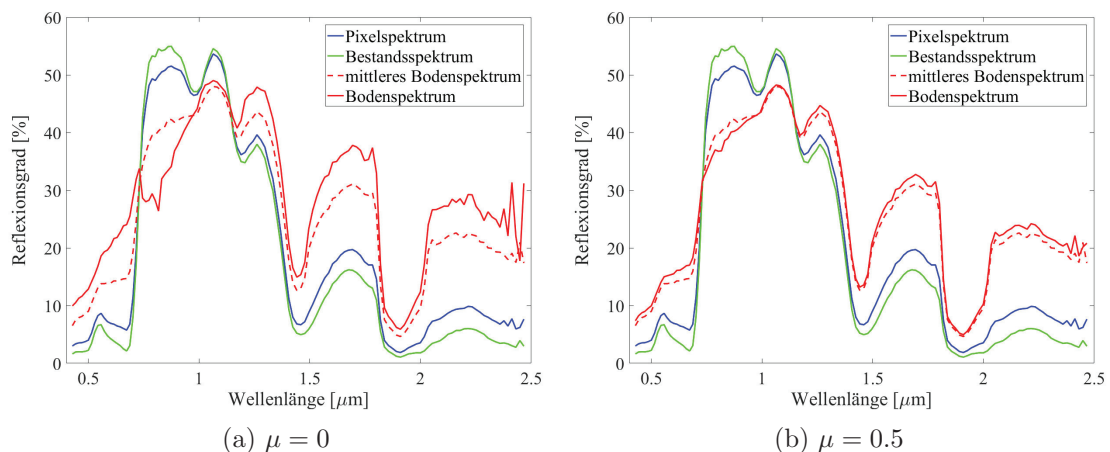


Abbildung 43: Optimierungsansatz 1 am Beispiel eines Fahrgassenpixels mit 17% Fahrspuranteil.

Der Optimierungsansatz, welcher hier exemplarisch mit $\mu = 0,5$ demonstriert wird, liefert in allen drei Fällen unabhängig vom Fahrspuranteil ein bereits an das mittlere Bodenspektrum stark angenähertes Ergebnis. Für eine geeignete Einschränkung der

gesuchten Lösung, gilt es, den Kontrollparameter schließlich so zu wählen, dass sich die Ergebnisse dem mittleren Bodenspektrum zwar annähern, aber trotzdem nicht zu stark an die Nebenbedingung gebunden sind, damit auch Abweichungen zulässig sind. Da das tatsächliche Bodenspektrum hier jedoch nicht bekannt ist, kann keine Aussage über eine geeignete Wahl des Kontrollparameters getroffen und die Richtigkeit der Ergebnisse zudem nicht sichergestellt werden.

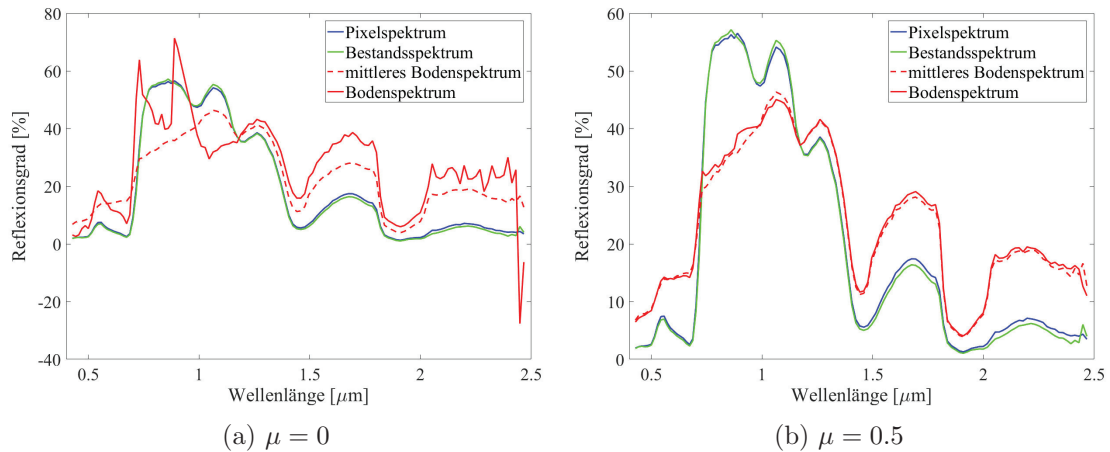


Abbildung 44: Optimierungsansatz 1 am Beispiel eines Fahrgassenpixels mit 5% Fahrspuranteil.

Aufgrund der gewählten Nebenbedingung ist das Optimierungsergebnis bei diesem Ansatz sehr stark an die Qualität des mittleren Bodenspektrums gekoppelt. Die Berechnung dieses mittleren Bodenspektrums unterliegt jedoch nicht zu vernachlässigenden Unsicherheiten, da es auf den Annahmen beruht, dass sowohl der geschätzte Flächenanteil \hat{a}_1 sowie das Bestandsreferenzspektrum \hat{e}_1 eine gute Näherung für die tatsächliche spektrale Mischung eines Fahrgassenpixels darstellen. Deswegen wird vermutet, dass das mittlere Bodenspektrum mit dem verwendeten Ansatz nicht ausreichend gut beschrieben wird und das resultierende Bodenspektrum somit fehlerbehaftet sein kann. Dieser Eindruck wird durch die optimierten Bodenspektren der untersuchten Fahrgassenpixel verstärkt, die aufgrund der starken Ähnlichkeit zu den Pixel- beziehungsweise Bestandsspektren und den ausgeprägten Oszillationen einen deutlich abweichenden spektralen Verlauf von den in der Literatur beschriebenen Bodenspektren aufweisen.

Es stellt sich somit die Frage, wie sich ein möglicher Fehler in der Flächenabschätzung beziehungsweise bei der Bestimmung des Bestandsreferenzsignals auf die Berechnung des mittleren Bodenspektrums auswirkt. Dies kann anhand einer Simulation mit bekannten Ausgangsdaten demonstriert werden. Dazu werden 21 Pixelspektren gemäß des Spektralmodells in Gleichung 4.8 mit beliebigen Bestandsspektren und Flächen sowie eines konstanten synthetisch modellierten Bodenspektrums für \tilde{e}_2 erzeugt. Die Abbildungen 45, 46 und 47 zeigen die Ergebnisse zur Berechnung des mittleren Bodenspektrums im Vergleich zum tatsächlichen vorgegebenen Bodenspektrum für drei verschiedene Fälle.

Zur besseren Veranschaulichung werden jeweils auch ein Pixel- und Bestandsspektrum des Spektralmodells dargestellt. Die Berechnung anhand der bekannten tatsächlichen Größen resultiert exakt in dem vorgegebenen Bodenspektrum und es ist keine Differenz zwischen tatsächlichem und berechnetem Spektrum zu erkennen (Abb. 45).




Abbildung 45: Berechnung des mittleren Bodenspektrums mit bekannten Größen des Spektralmodells.

Fließen andere beliebige Bestandsspektren in die Berechnung ein, so ergeben sich bei dem betrachteten Beispiel erkennbare Abweichungen zwischen berechnetem und tatsächlichem Bodenspektrum im Bereich von $0,8\mu m$ sowie bei $2,5\mu m$ (Abb. 46). Das Ausmaß dieser Abweichungen sowie die betroffenen Wellenlängen sind dabei an die Differenz zwischen den tatsächlichen und den für die Berechnung verwendeten Bestandsspektren gekoppelt.

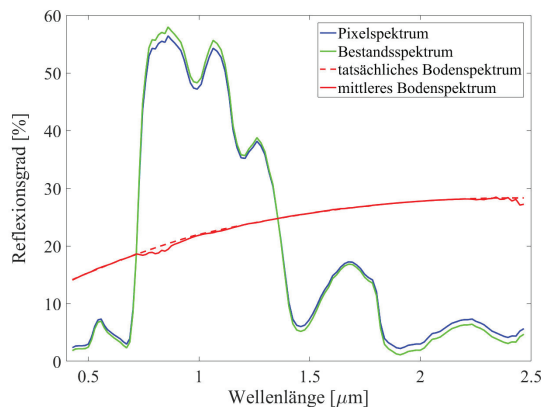


Abbildung 46: Berechnung des mittleren Bodenspektrums mit fehlerbehafteten Bestandsspektren.




Abbildung 47: Berechnung des mittleren Bodenspektrums mit fehlerbehafteten Flächenanteilen.

Zur Simulation eines möglichen Fehlers der geschätzten Flächenanteile werden die tatsächlichen Flächen des simulierten Spektralmodells mit einem additiven zufälligen Fehler zwischen 0 und 0,5 versehen, was in Anbetracht der Ergebnisse der Flächenabschätzung in Kapitel 4.4.1 einem sehr großen Fehler für die gegebenen Fahrgassenpixel entsprechen

würde. Diese fehlerhaften Flächen führen bei der Berechnung des mittleren Bodenspektrums zu starken Schwankungen und einer großen Abweichung zum tatsächlichen Spektrum. Auch hier wird das Ausmaß der Abweichungen durch den Fehler der für die Berechnung verwendeten Flächenanteile bestimmt.

Anhand dieser beispielhaften Simulation wird deutlich, dass die Berechnung des mittleren Bodenspektrums sowohl durch schlechte Näherungswerte für die Flächen sowie ungünstige Bestandsreferenzspektren beeinflusst wird und in einem fehlerbehafteten Bodenspektrum resultieren kann. Dabei ist die Genauigkeit der Näherungswerte für das Ausmaß des Fehlers im Bodenspektrum entscheidend. Über die Genauigkeit der ermittelten Näherungswerte kann jedoch keine Aussage getroffen werden, da einerseits die tatsächliche Fahrspurgeometrie der untersuchten Schläge und andererseits das tatsächliche Spektrum des Vegetation-Boden-Mischsignals in den Fahrgassenpixeln nicht bekannt ist.

In einer Abwandlung des hier betrachteten Ansatzes sollen die beobachteten und mit großer Wahrscheinlichkeit durch Modellunsicherheiten verursachten Schwankungen im Bodenspektrum unterdrückt werden. Dies erfolgt unter der Annahme, dass das Bodenspektrum keinen starken Oszillationen unterliegt und stattdessen einem kontinuierlich ansteigendem Verlauf folgt, wobei jedoch auch wellenlängenabhängige Schwankungen in Form von Absorptionsbanden auftreten können. In einem ersten einfachen Ansatz soll das gesuchte Bodenspektrum \vec{e}_2 nun an die konstante Mittelwertfunktion \vec{c} angenähert werden,

$$\vec{e}_2 \approx \vec{c} \text{ mit } \vec{c}^T = \underbrace{(c \ c \ \dots \ c)}_n.$$

Für die konstante Komponente c wird mit

$$c = \frac{1}{n} \sum_{j=1}^n \tilde{e}_{2j}$$

der Mittelwert des in Gleichung 4.9 berechneten mittleren Bodenspektrums \tilde{e}_2 definiert. Da das Bodenspektrum in bestimmten Spektralbereichen durch Absorptionsbanden geprägt sein kann, erfolgt zusätzlich eine wellenlängenabhängige Gewichtung der Nebenbedingung, wodurch Variationen im Spektrum zugelassen werden können. Damit ergibt sich die Zielfunktion $\Phi_c(\vec{e}_2)$ in Anlehnung an Gleichung 4.10 und unter Berücksichtigung der Nebenbedingung $\vec{e}_2 \approx \vec{c}$ sowie durch die Einführung der Gewichtungsmatrix W mit

$$\Phi_c(\vec{e}_2) = \|(\vec{r}_F - \hat{a}_1 \cdot \hat{\vec{e}}_1) - (1 - \hat{a}_1) \cdot \vec{e}_2\|^2 + \mu_c \cdot \|\vec{c} - \vec{e}_2\|_W^2,$$

womit das Optimierungsproblem durch

$$\min_{\vec{e}_2 \in 1.Q.} \|(\vec{r}_F - \hat{a}_1 \cdot \hat{\vec{e}}_1) - (1 - \hat{a}_1) \cdot \vec{e}_2\|^2 + \mu_c \cdot \|\vec{c} - \vec{e}_2\|_W^2$$

beschrieben werden kann. Der Einfluss der einschränkenden Nebenbedingung wird hier mit dem Kontrollparameter μ_c geregelt. Die Gewichtungsmatrix W ist als Diagonalmatrix der Dimension $n \times n$ mit den wellenlängenabhängigen Gewichten w_j mit $j = 1 \dots n$ in der Hauptdiagonalen definiert. Somit erfolgt eine komponentenweise Gewichtung bei der Minimierung des quadratischen Abstands zwischen \vec{c} und \vec{e}_2 mit

$$\sum_{j=1}^n \mu_c \cdot w_j \cdot (c_j - e_{2j})^2,$$

wobei große Gewichte den Einfluss der Nebenbedingung verstärken und kleine Gewichte stärkere Variationen im Spektrum zulassen. Das Minimum der Zielfunktion $\Phi_c(\vec{e}_2)$ ist schließlich mit

$$\vec{e}_2 = \frac{\mu_c \cdot \vec{w} \cdot \vec{c} + (1 - \hat{a}_1) \cdot (\vec{r}_F - \hat{a}_1 \cdot \hat{\vec{e}}_1)}{(1 - \hat{a}_1)^2 + \mu_c \cdot \vec{w}}$$

definiert, wobei die Gewichtung nun durch \vec{w} mit $\vec{w}_T = (w_1 \ w_2 \ \dots \ w_n)$ erfolgt.

Eine Demonstration des abgewandelten Optimierungsansatzes ist in den Abbildungen 48, 49 und 50 am Beispiel der zuvor betrachteten Fahrgassenpixel zu sehen. Dabei werden ebenfalls $M = 21$ Pixel bei der Berechnung des mittleren Bodenspektrums \vec{e}_2 berücksichtigt, aus dem die Mittelwertfunktion \vec{c} abgeleitet wird. Die Wahl der Gewichte w_j erfolgt in Abhängigkeit der spektralen Varianz σ_j in den Komponenten des Bodenspektrums in Bezug auf die mittlere spektrale Varianz σ_m mit

$$w_j = \frac{\sigma_m}{\sigma_j} \text{ sowie } \sigma_j = c_j - \tilde{e}_{2j} \text{ und } \sigma_m = \frac{1}{n} \sum_{j=1}^n (c_j - \tilde{e}_{2j}) \text{ und } j = 1 \dots n.$$

Demzufolge werden Spektralbänder mit großer Varianz ($\sigma_j > \sigma_m$) mit $w_j < 1$ weniger stark und Spektralbänder mit geringer Varianz ($\sigma_j < \sigma_m$) mit $w_j > 1$ stärker gewichtet.

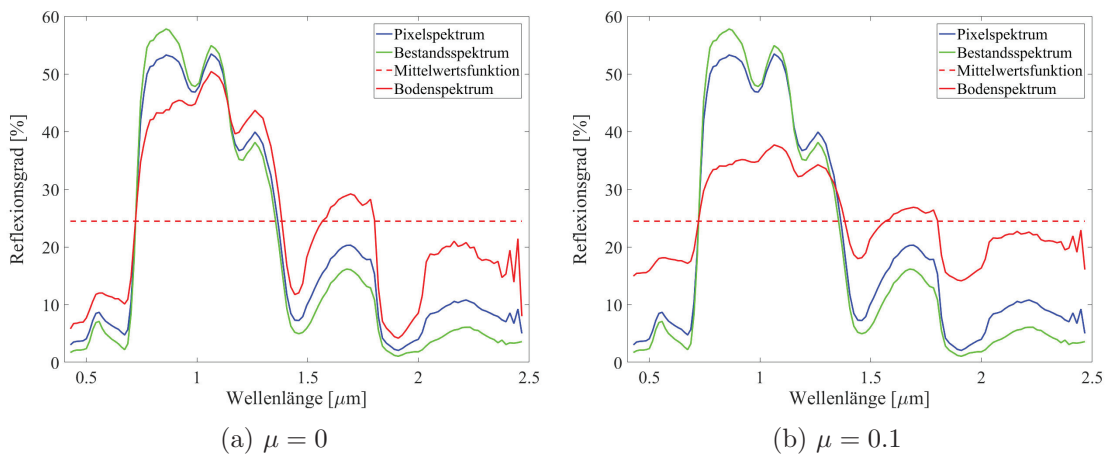


Abbildung 48: Abwandlung des Optimierungsansatzes 1 am Beispiel eines Fahrgassenpixels mit 32% Fahrspuranteil.

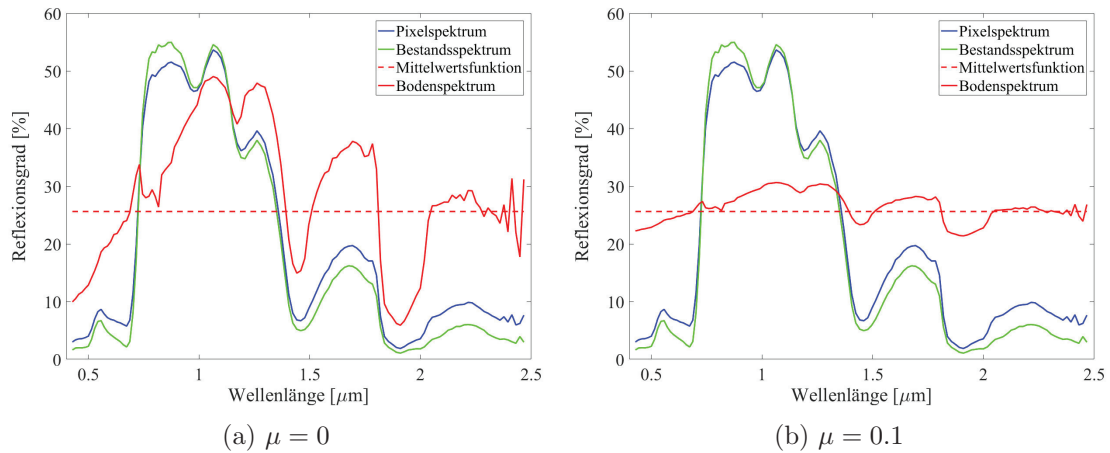


Abbildung 49: Abwandlung des Optimierungsansatzes 1 am Beispiel eines Fahrgassenpixels mit 17% Fahrspuranteil.

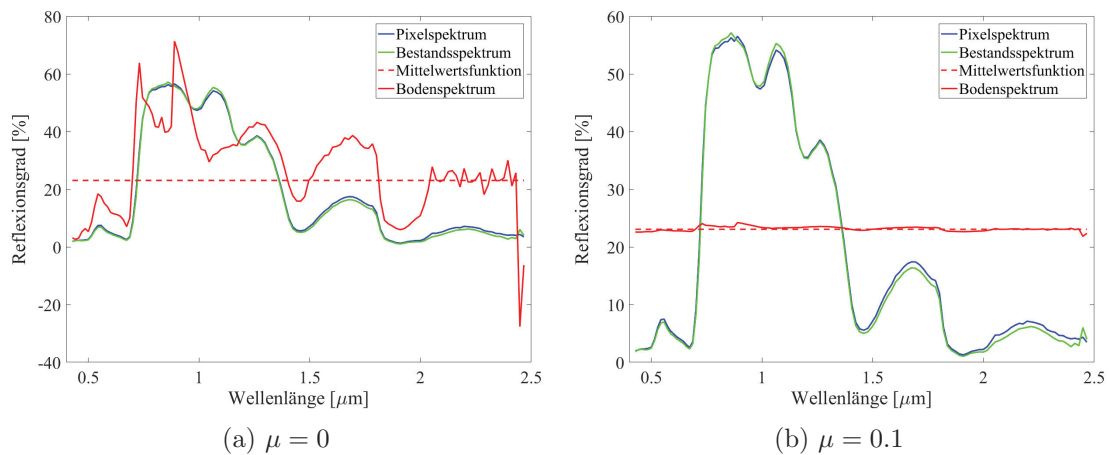


Abbildung 50: Abwandlung des Optimierungsansatzes 1 am Beispiel eines Fahrgassenpixels mit 5% Fahrspuranteil.

Der Einfluss der hier gewählten Nebenbedingung zeichnet sich bei den untersuchten Fahrgassenpixeln am Beispiel von $\mu = 0.1$ deutlich ab. Die resultierenden Bodenspektren werden sichtbar an die Mittelwertsfunktion angenähert, die bei den betrachteten Pixeln zwischen einem Reflexionsgrad von 23% und 26% liegt. Diese Annäherung fällt mit abnehmendem Fahrspuranteil zunehmend stärker aus und liefert bei sehr geringem Flächenanteil ein nahezu konstantes Bodenspektrum (Abb. 50b). Ursache hierfür sind die stark variierenden explizit berechneten Bodenspektren, die aufgrund des Modellfehlers sowohl durch starke Schwankungen sowie negative Spektralwerte geprägt sein können. In Anbetracht dieser stark abweichenden Ausgangsspektren fällt der Effekt der einschränkenden Nebenbedingung mit den hier gewählten wellenlängenabhängigen Gewichten sehr unterschiedlich aus. Zunehmend größere Werte für den Kontrollparameter μ_c bewirken dabei jeweils eine zusätzliche Verstärkung der hier beobachteten Effekte.

Die Abwandlung des Optimierungsansatzes 1 entspricht einer Möglichkeit, um den Modellfehler schlecht gewählter Näherungswerte zu unterdrücken. Dabei liegt die Schwierigkeit jedoch in der Wahl geeigneter wellenlängenabhängiger Gewichte, da die Ausgangsspektren aufgrund der fehlerbehafteten expliziten Berechnung des Bodenspektrums sehr variabel sein können. Eine weitere Herausforderung wird in der Bestimmung geeigneter Kontrollparameter vermutet, da das Maß der erforderlichen Unterdrückung aufgrund der fehlenden Kenntnis über den Modellfehler nicht eindeutig bestimmt werden kann.

Optimierungsansatz 2

In dem zweiten untersuchten Ansatz wird ein nicht-lineares alternierendes Optimierungsverfahren betrachtet, bei dem das Bodenspektrum und die Flächenanteile eines durch mehrere Pixel definierten Spektralmodells abwechselnd geschätzt werden. Dies soll ebenfalls durch den Einsatz eines gleitenden Fensters der Länge M ($M = 2 \cdot z + 1$, $z \in \mathbb{N}$) entlang der Fahrgassen erfolgen. Das dem Ansatz zugrunde liegende Spektralmodell basiert dabei auf der simultanen Betrachtung der durch das gleitende Fenster abgedeckten M aufeinanderfolgenden Fahrgassenpixel, wobei das mittige Pixel an der Stelle $\frac{M+1}{2}$ dem zu optimierenden Pixel entspricht. Da diese Pixel trotz variierender Mischungsverhältnisse in ihrer qualitativen spektralen Zusammensetzung als gleichartig aufgefasst werden können, wird sowohl das Spektrum \vec{e}_1 wie auch das Spektrum \vec{e}_2 innerhalb des betrachteten Modells als konstant angenommen. Die Pixelspektren \vec{r}_F^1 bis \vec{r}_F^M sind gemäß Gleichung 4.5 somit jeweils durch den variierenden Flächenanteil a_1^1 bis a_1^M sowie die als konstant angenommenen Spektren \vec{e}_1 und \vec{e}_2 definiert.

$$\begin{pmatrix} \vec{r}_F^1 \\ \vec{r}_F^2 \\ \vdots \\ \vec{r}_F^M \end{pmatrix} = \begin{pmatrix} a_1^1 \cdot \vec{e}_1 + (1 - a_1^1) \cdot \vec{e}_2 \\ a_1^2 \cdot \vec{e}_1 + (1 - a_1^2) \cdot \vec{e}_2 \\ \vdots \\ a_1^M \cdot \vec{e}_1 + (1 - a_1^M) \cdot \vec{e}_2 \end{pmatrix} \quad (4.11)$$

Nach diesem Modell ist ein einzelnes Pixelspektrum \vec{r}_F^k ($k = 1 \dots M$) durch

$$\vec{r}_F^k = a_1^k \cdot \vec{e}_1 + (1 - a_1^k) \cdot \vec{e}_2$$

beziehungsweise

$$\vec{r}_F^k = a_1^k \cdot (\vec{e}_1 - \vec{e}_2) + \vec{e}_2$$

definiert und führt mit $\vec{d}_{12} = \vec{e}_1 - \vec{e}_2$ zu

$$\vec{r}_F^k = a_1^k \cdot \vec{d}_{12} + \vec{e}_2 .$$

Somit kann das Spektralmodell für M Pixel mit

$$\begin{bmatrix} \vec{r}_F^1 & \vec{r}_F^2 & \dots & \vec{r}_F^M \end{bmatrix} = \begin{bmatrix} \vec{d}_{12} & \vec{e}_2 \end{bmatrix} \cdot \begin{bmatrix} \vec{a}_1^T \\ \mathbb{1}^T \end{bmatrix}$$

beschrieben werden, wobei der Vektor $\vec{a}_1^T = [a_1^1 \ a_1^2 \ \dots \ a_1^M]$ die Flächenanteile a_1^k enthält und für den Vektor $\mathbb{1}^T = \underbrace{(1 \ 1 \ \dots \ 1)}_M$ gilt.

Das Modell kann mit $R = [\vec{r}_F^1 \ \vec{r}_F^2 \ \dots \ \vec{r}_F^M]$ und durch Anwendung der Matrizenmultiplikation mit

$$R = \vec{d}_{12} \cdot \vec{a}_1^T + \vec{e}_2 \cdot \mathbb{1}^T \quad (4.12)$$

und mit $E = [\vec{d}_{12} \ \vec{e}_2]$ und $A = \begin{bmatrix} \vec{a}_1^T \\ \mathbb{1}^T \end{bmatrix}$ ebenfalls in Matrixschreibweise

$$R = E \cdot A \quad (4.13)$$

dargestellt werden.

Auf der Grundlage des hier beschriebenen Spektralmodells soll die gegenseitig bedingte alternierende Schätzung des Bodenspektrums \vec{e}_2 und des Vektors \vec{a}_1 der Flächenanteile iterativ erfolgen. Dies erfordert einen initialen Startwert, wofür sich das Ergebnis der Flächenabschätzung für die Flächenanteile in \vec{a}_1 anbietet. Demzufolge startet das Verfahren mit der Schätzung des Bodenspektrums und dem Vektor der korrespondierenden geschätzten Flächen des betrachteten Spektralmodells

$$\hat{\vec{a}}_1^T = (\hat{a}_1^1 \ \hat{a}_1^2 \ \dots \ \hat{a}_1^M) . \quad (4.14)$$

Der Optimierung des Bodenspektrums wird die Annahme zugrunde gelegt, dass das Bodenspektrum einen relativ kontinuierlich ansteigenden Verlauf und keine enormen Schwankungen aufweist. Demnach ist das Bodenspektrum \vec{e}_2 an eine geeignete Modellfunktion \vec{b} anzunähern,

$$\vec{e}_2 \approx \vec{b} .$$

In einem ersten heuristischen Ansatz soll \vec{b} als konstante Funktion mit

$$\vec{b}^T = \underbrace{(b \ b \ \dots \ b)}_n$$

definiert werden, um mögliche untypische Schwankungen im Bodenspektrum zu unterdrücken. Die Zielfunktion $\Psi_E(E^T)$ wird nach der Modellbeschreibung in 4.13 in Abhängigkeit der Matrix E^T und unter Berücksichtigung der Nebenbedingung $\vec{e}_2 \approx \vec{b}$ sowie dem Hilfsvektor $\vec{v}^T = (0 \ 1)$ durch

$$\Psi_E(E^T) = \|R^T - A^T E^T\|^2 + \mu_E \cdot \|\vec{b}^T - \vec{v}^T E^T\|^2$$

definiert, woraus das Optimierungsproblem mit

$$\min_{E^T \in 1.Q.} \|R^T - A^T E^T\|^2 + \mu_E \cdot \|\vec{b}^T - \vec{v}^T E^T\|^2$$

beschrieben werden kann. Die Minimierung des Optimierungsproblems erfolgt unter Einhaltung der Positivität (Gl. 4.6) durch die Projektion der Spektren \vec{e}_1 und \vec{e}_2 auf den ersten Quadranten und liefert die Berechnungsvorschrift für die optimierte Matrix

$$E^T = (A \cdot A^T + \mu_E \cdot \vec{v} \cdot \vec{v}^T)^\dagger (A \cdot R^T + \mu_E \cdot \vec{v} \cdot \vec{b}^T), \quad (4.15)$$

wobei der Einfluss der einschränkenden Nebenbedingung mit dem Kontrollparameter μ_E geregelt wird. Im ersten Iterationsschritt gilt $A = A_0$, wobei die initiale Matrix

$$A_0 = \begin{bmatrix} \hat{a}_1^T \\ \mathbb{1}^T \end{bmatrix}$$

mit dem Vektor der geschätzten Flächen \hat{a}_1^T (Gl. 4.14) definiert wird. Das Ergebnis fließt anschließend in das Optimierungsproblem von \vec{a}_1 ein.

Die Optimierung der Flächenanteile soll unter der Annahme erfolgen, dass die dem Spektralmodell korrespondierenden geschätzten Flächen \hat{a}_1^k ($k = 1 \dots M$) bereits einer guten Näherung entsprechen, aber nicht zwingend eingehalten werden müssen. Demzufolge soll der Vektor \vec{a}_1 an den Vektor der geschätzten Flächen \hat{a}_1 angenähert werden,

$$\vec{a}_1 \approx \hat{a}_1.$$

Unter Einhaltung dieser Nebenbedingung ist die Zielfunktion $\Psi_a(\vec{a}_1^T)$ nach Gleichung 4.12 durch

$$\Psi_a(\vec{a}_1^T) = \|(R - \vec{e}_2 \cdot \mathbb{1}^T) - \vec{d}_{12} \cdot \vec{a}_1^T\|^2 + \mu_a \cdot \|\hat{a}_1^T - \vec{a}_1^T\|^2$$

und das Optimierungsproblem mit

$$\min_{\vec{a}_1^T} \|(R - \vec{e}_2 \cdot \mathbb{1}^T) - \vec{d}_{12} \cdot \vec{a}_1^T\|^2 + \mu_a \cdot \|\hat{a}_1^T - \vec{a}_1^T\|^2$$

definiert, wobei das Maß der Annäherung an die geschätzten Flächenanteile \hat{a}_1^T über den Parameter μ_a kontrolliert wird. Die Minimierung des Optimierungsproblems liefert schließlich die Berechnungsformel

$$\vec{a}_1^T = \left(\vec{d}_{12}^T \cdot \vec{d}_{12} + \mu_a \right)^\dagger \left(\vec{d}_{12}^T \cdot (R - \vec{e}_2 \cdot \mathbb{1}^T) + \mu_a \cdot \hat{a}_1^T \right).$$

Dabei fließen das Bodenspektrum \vec{e}_2 sowie der Differenzvektor $\vec{d}_{12} = \vec{e}_1 - \vec{e}_2$ aus der zuvor optimierten Matrix E^T in die Berechnung ein. Das Optimierungsergebnis \vec{a}_1^T wird

im folgenden Iterationsschritt schließlich bei der Berechnung von E^T (Gl. 4.15) mit

$$A = \begin{bmatrix} \vec{a}_1^T \\ \mathbb{1}^T \end{bmatrix}$$

aufgegriffen. Somit erfolgt eine wiederholte und gegenseitig bedingte Schätzung der Matrix E^T und des Vektors \vec{a}_1^T , deren Ergebnisse an die Anzahl der gewählten Iterationsschritte gekoppelt sind.

Die Annahmen des Spektralmodells in Gleichung 4.11 ermöglichen hier eine einfache Simulation des vorgestellten Optimierungsansatzes, da lediglich ein beispielhaftes Bodenspektrum erforderlich ist. Dazu wird die Matrix R für $M = 21$ aufeinanderfolgende Fahrgassenpixel mit einem beliebigen Bestandsspektrum aus den gegebenen Daten sowie einem synthetisch modellierten Bodenspektrum erzeugt. Für die tatsächliche Flächenverteilung in dem Spektralmodell werden M aufeinanderfolgende Werte \hat{a}_1^k aus der Flächenabschätzung verwendet, um eine möglichst gute Nachbildung der zu erwartenden Varianz der Flächenverteilung zu erhalten.

Bei der Simulation werden die gewählten tatsächlichen Flächen für die Definition der initialen Matrix A_0 mit einem additiven Fehler versehen, um einen möglichen Fehler durch die Annäherung der Werte im Rahmen der Flächenabschätzung zu berücksichtigen. Demnach soll die Optimierung des Flächenvektors \vec{a}_1 auch durch die Annäherung an diese fehlerbehafteten Flächen erfolgen. Die konstante Modellfunktion \vec{b} wird bei einem Reflexionsgrad von 10% definiert. Für die Demonstration des Verfahrens erfolgt die alternierende Schätzung der beiden Größen exemplarisch in 200 Iterationsschritten.




Abbildung 51: Optimierungsansatz 2 mit $\mu_E = 0$ und $\mu_a = 0$.

Die Optimierungsergebnisse ohne Einfluss der beiden Nebenbedingungen ($\mu_E, \mu_a = 0$) werden in Abbildung 51 im direkten Vergleich zu den simulierten Ausgangsdaten dargestellt. Das Bodenspektrum unterscheidet sich zwar deutlich vom tatsächlichen Spektrum, jedoch weist es durch die gegenseitig bedingte iterative Lösung keine extremen Schwankungen oder andere widersprüchliche Merkmale in der spektralen Signatur auf.

Die optimierte Flächenverteilung weicht teilweise sehr stark von den tatsächlichen Werten ab und enthält außerdem auch Werte $a_1^k > 1$, was in Anbetracht der Modellannahmen physikalisch nicht möglich ist. Der Restfehler des Modells verteilt sich hier somit insbesondere auf das Bodenspektrum sowie die Flächenverteilung, wobei auch eine geringe Abweichung zwischen tatsächlichem und optimiertem Bestandsspektrum zu erkennen ist.

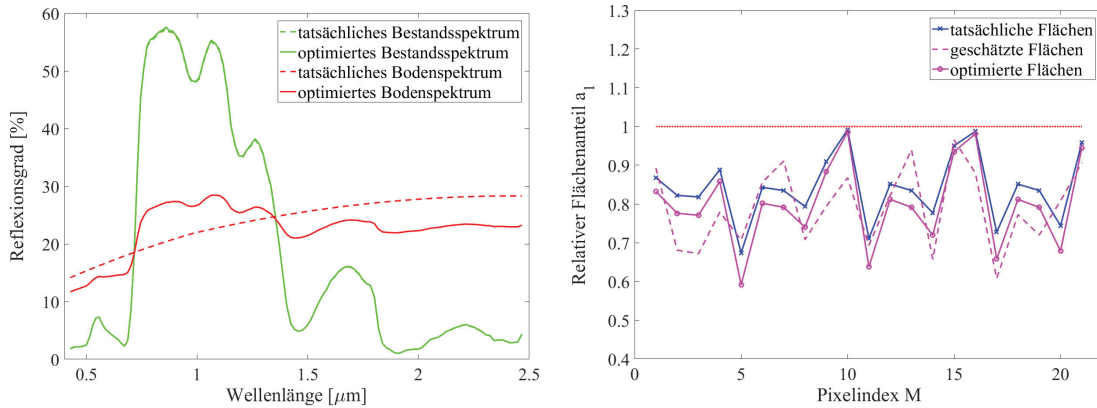


Abbildung 52: Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 0$.

In den Abbildungen 52 und 53 sind die Optimierungsergebnisse für zwei verschiedene Werte des Kontrollparameters μ_E , aber ohne Optimierung der Flächenanteile mit $\mu_a = 0$ zu sehen. Mit zunehmendem Einfluss der Nebenbedingung $\vec{e}_2 \approx \vec{b}$ erfolgt eine verstärkte Abschwächung des optimierten Bodenspektrums. Im Ergebnis werden die Schwankungen stärker unterdrückt und der mittlere Reflexionsgrad nähert sich dem des tatsächlichen Bodenspektrums an. Gleichzeitig verringert sich der Fehler im Bestandsspektrum und die Abweichungen in der Flächenverteilung werden ebenfalls kleiner (Abb. 52). Wird die Nebenbedingung jedoch zu stark forciert, resultiert das Bodenspektrum in einer zunehmend abgeflachten Kurve, die sich der konstanten Modellfunktion bei 10% Reflexion annähert (Abb. 53). In Folge dessen ist ein zunehmender Fehler im Bestandsspektrum sowie in der Flächenverteilung zu beobachten.

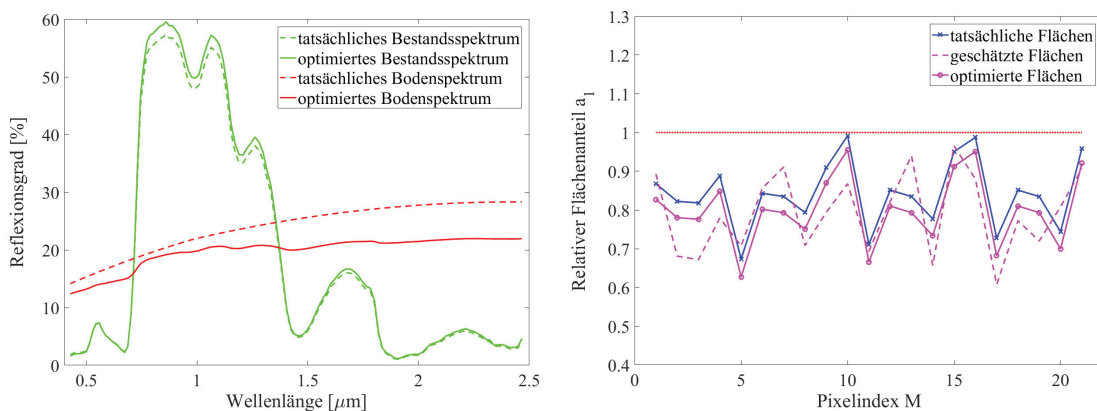
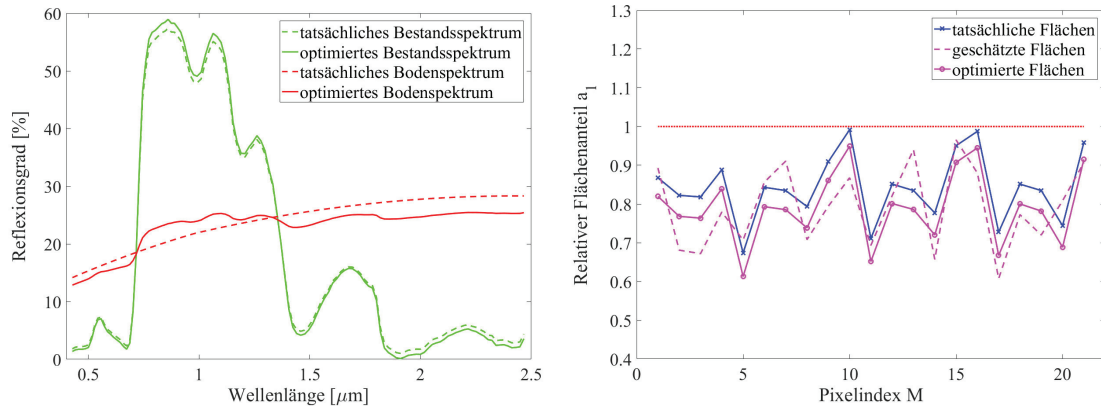
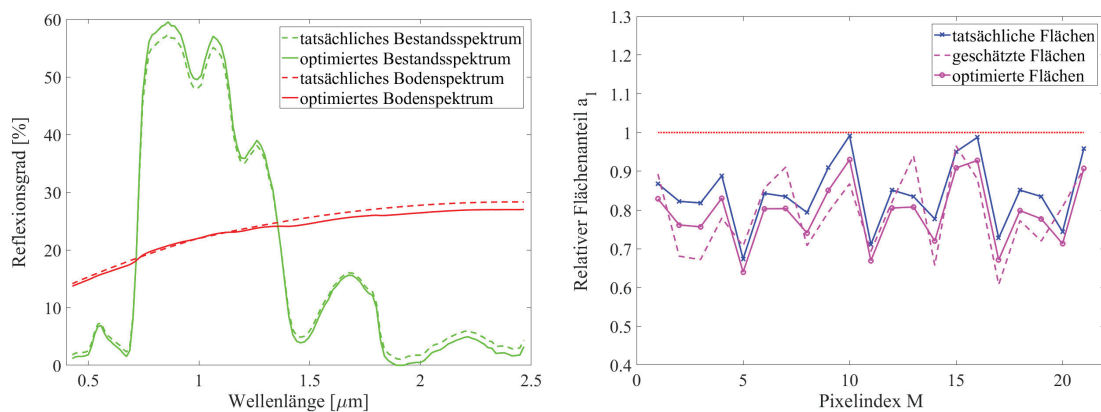


Abbildung 53: Optimierungsansatz 2 mit $\mu_E = 0.1$ und $\mu_a = 0$.

Abbildung 54: Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 1000$.Abbildung 55: Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 10000$.

Der Einfluss der Nebenbedingung $\vec{a}_1 \approx \hat{\vec{a}}_1$ zur Optimierung der Flächenverteilung wird in den Abbildungen 54, 55 und 56 anhand variierender Werte für den Kontrollparameter μ_a demonstriert, wobei hier die Optimierung des Bodenspektrums konstant mit $\mu_E = 0.01$ erfolgt. Ein sichtbarer Effekt dieser einschränkenden Nebenbedingung erfordert dabei sehr große Werte des Kontrollparameters. Der wachsende Einfluss der Nebenbedingung bewirkt zunächst ein zunehmend besseres Optimierungsergebnis für das Bodenspektrum. Die optimierten Flächen nähern sich den geschätzten fehlerhaften Flächen zunehmend an und die Abweichung zur tatsächlichen Flächenverteilung wird größer (vgl. Abb. 54 und 55). In der Folge erhöht sich auch der Fehler des Bestandsspektrums, was mitunter auch zu negativen Spektralwerten führt, die hier jedoch auf Null projiziert werden.

Bei einem zu großen Einfluss der Nebenbedingung (zum Beispiel $\mu_a = 100000$) geht der Fehler der geschätzten Flächen verstärkt in das Verfahren ein und resultiert in einem schlechten Optimierungsergebnis für das Bodenspektrum (Abb. 56), welches dem Ergebnis mit $\mu_E = 0$ und $\mu_a = 0$ sehr ähnlich ist. Für steigende Werte des Kontrollparameters μ_a scheint das Bodenspektrum zu konvergieren, wobei auch hier keine widersprüchlichen Spektren resultieren.

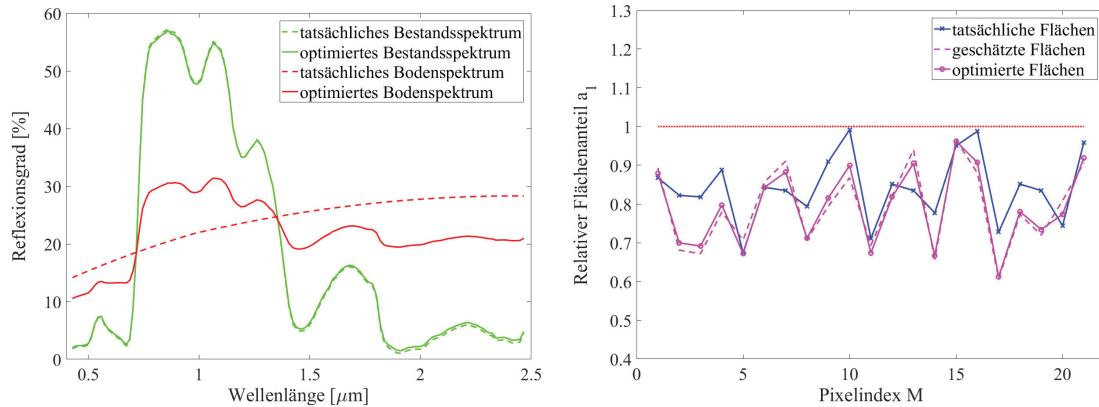


Abbildung 56: Optimierungsansatz 2 mit $\mu_E = 0.01$ und $\mu_a = 100000$.

Anhand dieser Beispiel wird deutlich, dass sich der Modellfehler je nach Wahl der Kontrollparameter unterschiedlich auf das Bestands- beziehungsweise Bodenspektrum sowie die optimierten Flächen verteilt. Die zulässigen Variationen im Bestandsspektrum und in der Flächenverteilung eröffnen der Optimierung des Bodenspektrums dabei einen größeren Spielraum. Zudem wird die Lösungsmenge auch ohne den Einfluss von Nebenbedingungen aufgrund des alternierenden Ansatzes bereits gut eingegrenzt. Auf eine Übertragung dieses Optimierungsansatzes auf reale Daten wird hier vorerst verzichtet, da die Entmischungsergebnisse aufgrund der fehlenden Kenntnis über das gesuchte Bodenspektrum ohnehin nicht angemessen bewertet werden können.

4.5 Räumliche Interpolation des Bodensignals

In Hinblick auf die Korrektur des Vegetationssignals des Pflanzenbestands gilt es, das im vorherigen Prozessschritt extrahierte Bodenspektrum ausgehend von den Fahrgassenpixeln für die dazwischenliegenden Bestandspixel räumlich zu interpolieren. Zur Schätzung ortsabhängiger Variablen bietet sich insbesondere die Verwendung eines geostatistischen Interpolationsverfahrens an, das den räumlichen Zusammenhang der zu schätzenden Größe berücksichtigt und geeignet modelliert. Darüber hinaus liefern diese Verfahren auch eine Angabe zur Unsicherheit der Schätzung (Schätzvarianz). Sie beruhen alleamt auf der Annahme, dass die zu schätzende Variable eine charakteristische räumliche Struktur aufweist (Dutter 1985).

Das wohl bekannteste geostatistische Interpolationsverfahren ist das Kriging, welches eine Reihe von Schätzverfahren umfasst und auch hier bei der Schätzung des Bodenspektrums Anwendung finden soll. Der Kriging-Schätzer wird auch als so genannter BLUE-Schätzer (engl. best linear unbiased estimator) bezeichnet und liefert den bestmöglichen linearen und unverzerrten Schätzwert (Akin et al. 1988). Bei der Kriging-Interpolation ergibt sich ein zu schätzender Wert $Z^*(u_0)$ an der Stelle u_0 mit

$$Z^*(u_0) = \sum_{i=1}^{n_k} \omega_i \cdot Z(u_i) \quad (4.16)$$

aus der Mittelung n_k benachbarter Stützstellen u_i mit den bekannten Werten $Z(u_i)$, welche jeweils mit den optimierten Gewichten ω_i zur Berücksichtigung der räumlichen Korrelation versehen werden. Die Berechnung dieser Gewichte erfolgt in Abhängigkeit der gewählten Kriging-Methode. Es wird unter anderem zwischen dem einfachen (*simple*) Kriging bei bekanntem Erwartungswert und dem normalen (*ordinary*) Kriging bei unbekanntem Erwartungswert unterschieden (Stein 1999). Einen allgemeineren Ansatz bietet das universelle (*universal*) Kriging, bei dem ein variierender Erwartungswert mit einem bestimmten Trend angenommen wird. Das Ordinary Kriging gilt als die am häufigsten verwendete Methode (Wackernagel 2003) und soll auch hier zur räumlichen Modellierung des Bodenspektrums zum Einsatz kommen.

Die Kriging-Interpolation erfolgt generell in mehreren Schritten, wobei zunächst eine Charakterisierung des räumlichen Zusammenhangs der gegebenen Daten anhand statistischer Kenngrößen vorgenommen wird. Diese statistische Beschreibung der Daten wird anschließend an ein geeignetes geostatistisches Modell angenähert, woraus die Kriging-Funktion zur Interpolation der gesuchten Datenpunkte resultiert.

Beim Ordinary Kriging erfolgt die Charakterisierung des räumlichen Zusammenhangs der Stichproben durch die Ermittlung des Variogramms $2\gamma(h)$ beziehungsweise Semivariogramms $\gamma(h)$. Die Semivarianzen entsprechen einem Maß für die Korrelation zweier Stichproben $Z(u_i)$ und $Z(u_i + h)$ in Abhängigkeit des Abstands h . Im so genannten empirischen Semivariogramm werden diese Semivarianzen für Stichproben-Paare gleichen Abstands innerhalb einer Lag-Distanz gemittelt. Die Lag-Distanz h_k bestimmt dabei die schrittweise beziehungsweise Intervallgröße auf der x-Achse. Für eine Lag-Distanz h_k ist die mittlere Semivarianz $\gamma(h_k)$ schließlich mit

$$\gamma(h_k) = \frac{1}{2m_k} \sum_{i=1}^{m_k} (Z(u_i + h) - Z(u_i))^2 \quad \text{mit } h \in h_k$$

durch die halbe mittlere quadratische Abweichung der zugehörigen m_k Stichproben-Paare definiert (Akin et al. 1988).




Abbildung 57: Einteilung der Semivarianzen anhand von 9 Lags zur Erzeugung eines empirischen Semivariogramms (verändert nach Wackernagel 2003, S. 47).

Abbildung 57 zeigt ein Beispiel für die Mittelung der Semivarianzen anhand von 9 Lags ($h_1 \dots h_9$) zur Erzeugung des empirischen Semivariogramms. Das empirische Semivariogramm unterliegt den Bedingungen der intrinsischen Hypothese. Diese setzt einerseits einen konstanten Erwartungswert der zu untersuchenden Größe voraus und besagt, dass für alle Stichproben eine endliche Semivarianz existiert, die nicht von deren absoluter Lage u_i , sondern nur vom Abstand h_k abhängig ist. Beschreiben lässt sich das empirische Semivariogramm (kurz Variogramm) anhand von drei signifikanten Parametern. Die Korrelationsreichweite (*range*) entspricht dem Abstand, bei dem die Variogrammfunktion den Schwellwert (*sill*) erreicht. Stichproben, deren Abstand über diesem Grenzwert liegen, gelten als unabhängig und sind nicht mehr maßgebend zur Beschreibung der räumlichen Struktur der Daten. Im Fall verrauschter Daten tritt der so genannte *Nugget*-Effekt auf, bei dem die Variogrammfunktion nicht im Koordinatenursprung, sondern bei der *Nugget*-Varianz $\gamma(0)_{Nugget} > 0$ beginnt. Mit Hilfe dieser Variogrammparameter erfolgt die Anpassung des empirischen Semivariogramms an ein geeignetes geostatistisches Modell, das den räumlichen Zusammenhang der Daten am besten beschreibt. Dabei kommen üblicherweise das exponentielle, das Gauß'sche oder das sphärische Modell zum Einsatz (Akin et al. 1988). Die Modellapproximation liefert die Kriging-Funktion, welche das so genannte theoretische Variogramm beschreibt.

Die abschließende Interpolation eines gesuchten Datenpunkts $Z^*(u_0)$ erfolgt mit Gleichung 4.16 durch die gewichtete Mittelwertbildung der Stützpunkte $Z(u_i)$, die ausgehend von u_0 innerhalb der ermittelten Korrelationsreichweite liegen. Die korrespondierenden Kriging-Gewichte resultieren aus einem Optimierungsverfahren, bei dem die Schätzvarianz für alle beteiligten Stützpunkte mit Hilfe der Variogrammwerte minimiert wird (Wackernagel 2003). Somit sind die Kriging-Gewichte sowohl von dem räumlichen Zusammenhang der Daten (beschrieben durch die Variogrammfunktion) sowie der Lage der zu interpolierenden Datenpunkte abhängig. Ein entscheidendes Kriterium bei der Kriging-Interpolation ist neben der Wahl des Variogrammmodells auch die Qualität der gegebenen Stichproben. Diese sollten optimalerweise eine ausreichend hohe Anzahl und eine möglichst homogene Verteilung im Untersuchungsgebiet aufweisen. Sind diese Voraussetzungen nicht gegeben, so sind die Stichproben nur bedingt geeignet, um den räumlichen Zusammenhang der zu schätzenden Größe zu modellieren, was zu Fehlinterpretationen bei der Kriging-Interpolation führen kann.

Aufgrund der unzureichenden Beurteilung der Entmischungsergebnisse bei der Ableitung des Bodensignals in Kapitel 4.4.3, wird auf eine demonstrative Umsetzung der räumlichen Interpolation verzichtet.

5 Diskussion

Die in Kapitel 4 gewählten Ansätze zur Umsetzung der Prozesskette werden in diesem Kapitel ausführlich diskutiert und ausgewertet. Dazu sollen Vor- und Nachteile sowie mögliche Schwierigkeiten herausgestellt werden. Des Weiteren werden die grundlegenden Erkenntnisse der durchgeführten Untersuchungen sowie offene Fragestellungen zusammengefasst. Eine Einschätzung des Erweiterungs- und Automatisierungspotentials soll zudem Rückschlüsse auf die Übertragbarkeit der damit erarbeiteten Methode erlauben. In Anhang E sind außerdem auch die Ergebnisse einer Laufzeitmessung zu den praktisch umgesetzten Prozess- und Teilschritten dargestellt, die einen Eindruck für den erforderlichen Rechenaufwand vermitteln sollen.

5.1 Vorverarbeitung

Die spektrale Glättung sowie die Datenreduktion gehören zu den essentiellen vorverarbeitenden Schritten bei der Auswertung von Hyperspektraldaten. Die Auswirkung dieser beiden Verfahren kann jedoch einen entscheidenden Einfluss auf den Informationsgehalt der Daten haben und im ungünstigsten Fall bedeutende spektrale Merkmale unterdrücken, wodurch die Datenanalyse beeinträchtigt werden kann. Eine angemessene Vorverarbeitung ist dabei stets an die Zielstellung der Datenauswertung, die Eigenschaften der gegebenen Daten sowie an die zur Verfügung stehende Rechenkapazität gekoppelt. Deswegen empfiehlt es sich, die Wahl der Parameter bei der Anwendung des Savitzky-Golay-Filters (Filtergröße, Polynomgrad) sowie beim Binning (angestrebte Bandbreite) hinsichtlich der Ergebnisse der spektralen Entmischung zu untersuchen und gegebenenfalls abzustimmen.

In Bezug auf die Auswertung verschiedenartiger Daten bietet sich zudem eine dynamische Parametrisierung der vorverarbeitenden Schritte an. Schließlich können die Eingangsdaten in Abhängigkeit des Sensors sowie der Aufnahmebedingungen unterschiedlich stark verrauscht sein und außerdem auch eine abweichende spektrale Auflösung (Anzahl und Breite der Bänder beziehungsweise Kanäle) aufweisen. Eine Anpassung der Rauschunterdrückung wird jedoch durch die Wahl eines geeigneten Entscheidungskriteriums erschwert und kann womöglich sehr aufwändig sein. Im Fall von Multispektraldaten würde die hier betrachtete Vorverarbeitung entfallen, da eine Datenreduktion oder spektrale Glättung aufgrund der wenigen und breiten Kanäle nicht zwingend erforderlich wäre.

Die Kombination der gewählten Verfahren sowie deren Reihenfolge werfen zudem verbleibende Fragestellungen auf. Aufgrund der Mittelwertbildung beim Binning hat die Datenreduktion ebenfalls den Effekt einer Rauschunterdrückung, wobei das Maß der Glättung im Fall der gewählten Parameter deutlich größer ausfällt, als beim Savitzky-Golay-Filter. Somit kann die Notwendigkeit des vorab angewendeten Savitzky-Golay-Filters beziehungsweise die Wahl des Verfahrens zur Datenreduktion in Frage gestellt

werden. Der Einfluss der gewählten Verfahren sowie deren Kombination und Reihenfolge gilt es demzufolge ebenfalls hinsichtlich der Ergebnisse der spektralen Entmischung genauer zu untersuchen.

5.2 Segmentierung des Untersuchungsgebiets

Eine praktische Umsetzung zur Segmentierung des Untersuchungsgebiets konnte aufgrund des Umfangs im Rahmen dieser Arbeit nicht realisiert werden. Die vorgestellten Ansätze zur Segmentierung landwirtschaftlicher Flächen sind oftmals sehr datenspezifisch und lassen sich somit nur bedingt übertragen. Während gängige Strukturanalysen zum Beispiel sehr stark an die geometrische Auflösung gekoppelt sind, stützen sich die Homogenitätsanalysen oftmals auf weitere Zusatzdaten, deren Verfügbarkeit nicht in jedem Fall garantiert werden kann. Bei einer hohen spektralen Auflösung, wie im Fall der gegebenen Hyperspektraldaten, bieten sich zum Beispiel objektbasierte Segmentierungsalgorithmen unter Ausnutzung der spektralen Information an. Diese Ansätze unterliegen allerdings weiteren nicht zu vernachlässigenden Schwierigkeiten, wie der Interpretation beziehungsweise Identifikation der segmentierten Flächen sowie der Korrektur schlecht detektierter Objektkonturen. Aufgrund dieser und weiterer Herausforderungen kann eine geeignete datenunabhängige Segmentierung unter Umständen eine teilautomatisierte Lösung erfordern.

Im Zuge der Segmentierung des Untersuchungsgebiets, ob automatisiert oder interaktiv, bietet sich weiterführend die Detektion möglicher Strukturelemente auf dem Schlag an. Die Kenntnis über die Lage und Ausdehnung dieser Strukturelemente kann bei der Fahrgassenselektion sowie der Modellierung der Fahrspuren sehr hilfreich sein, um einerseits fehlerhaft detektierte Liniensegmente zu identifizieren und andererseits den abweichenden Fahrgassenverlauf bei der Identifikation der Fahrgassenpixel zu berücksichtigen.

5.3 Selektion der Fahrgassen

Der vorgestellte Ansatz zur Selektion der Fahrgassen entspricht teilweise einer sehr datenspezifischen und vereinfachten Lösung. Die gewählte Umsetzung bietet an der einen oder anderen Stelle auf jeden Fall noch Optimierungspotential sowie einige Erweiterungsmöglichkeiten.

Erzeugung des binären Kantenbilds

Die Erzeugung des binären Kantenbilds erfolgt durch eine geeignete Kontrastverstärkung, gefolgt von einem lokalen Selektionsfilter zur Hervorhebung der Fahrgassen und durch eine abschließende Schwellwertbildung. Dieser Ansatz stützt sich auf das in Kapitel 3.4 eingeführte Fahrspurmodell und konnte anhand der drei untersuchten Schläge erfolgreich demonstriert werden.

Die Analyse der drei Teilschritte hat gezeigt, dass die Kontrastverstärkung durch die NDSI-Auswertung im Fall der untersuchten Schläge sehr gute Voraussetzungen zur Erzeugung des binären Kantenbilds liefert. Mit der Berechnung des NDSI wird somit die Abdeckung des SWIR-Bereichs durch die auszuwertenden Daten vorausgesetzt, was bei der Verwendung von Multispektraldaten nicht immer gewährleistet werden kann. In diesem Fall kann jedoch auf die alternative NDVI-Auswertung zurückgegriffen werden, welche ebenfalls akzeptable Ergebnisse liefert. Der Einsatz von Vegetationsindizes zur Kontrastverstärkung sollte jedoch kritisch betrachtet werden. Das Ergebnis der NDVI-beziehungswise NDSI-Auswertung ist schließlich sehr stark an den Zustand der Pflanzen, den Bedeckungsgrad und weitere Faktoren, wie mögliche Beleuchtungsvariationen innerhalb der Fahrgassen oder des Bestands, gekoppelt. In Folge dessen kann nicht in jedem Fall eine ausreichend gute Kontrastverstärkung garantiert werden, wodurch sich dieser Ansatz nur bedingt auf andere Daten beziehungsweise Untersuchungsgebiete übertragen lässt. Alternativ bietet sich ein automatisierter Vergleich verschiedener Band-Kombinationen hinsichtlich des Kontrastverhältnisses an. Dazu gilt es, ein geeignetes Kriterium zur Beurteilung des Kontrasts zwischen Fahrgassen und Bestand zu bestimmen, was aufgrund des unbekanntens Spektralverhaltens umliegender Randstrukturen erschwert wird. Eine weitere Möglichkeit stellt die Verwendung hyperspektraler Vegetationsindizes dar, die mitunter sehr spezifische Pflanzenparameter ansprechen und somit eine differenziertere Separation der Strukturen ermöglichen könnten. Eine Optimierung und Generalisierung dieses Arbeitsschrittes für verschiedene Daten und Untersuchungsgebiete erfordert demzufolge weitere Untersuchungen unter Berücksichtigung verschiedener Einflussfaktoren, wie zum Beispiel den Zeitpunkt der Wachstumsperiode oder variierende Aufnahmebedingungen.

Zur Hervorhebung der Fahrgassenpixel konnte ein geeigneter lokaler Selektionsfilter entworfen werden, dessen optimale Filtergröße in Abhängigkeit der geometrischen Auflösung sowie der geschätzten Fahrgassenbreite des Fahrspurmodells automatisch bestimmt wird. Diese Vorgehensweise erfordert jedoch eine bestimmte Mindestbenaufauflösung in Abhängigkeit der geschätzten Fahrgassenbreite, die bei dem hier verwendeten Fahrspurmodell bei 9 m pro Pixel liegt und somit zu einer Einschränkung der auswertbaren Daten führt. Im Fall von geometrisch geringer aufgelösten Daten wird die Erkennbarkeit der Fahrgassen jedoch ohnehin in Frage gestellt. Bei einem schlecht gewählten Näherungswert für die Fahrgassenbreite liefert dieser Ansatz trotzdem ausreichend gute Ergebnisse zur Erzeugung des binären Kantenbilds sowie eine erfolgreiche Fahrgassenselektion, was im Fall von Schlag 3 demonstriert werden konnte (siehe Kapitel 4.3.2, S. 63).

Eine automatisierte Schwellwertbildung konnte im Rahmen der Arbeit nicht umgesetzt werden. Die Herausforderung liegt dabei insbesondere in der Bestimmung eines geeigneten Schwellwertes zur Trennung von Fahrgassen- und Bestandspixeln, der einerseits an die Daten, andererseits an das Ergebnis der vorhergehenden Arbeitsschritte gekop-

pelt ist. Eine Abschätzung aller Fahrgassenpixel in Bezug auf die Schlaggröße verspricht das Problem variierender Eingangsdaten zu lösen. Dies setzt jedoch eine erfolgreiche Kontrastverstärkung im ersten sowie eine gute Selektion der hellen Strukturen im zweiten Teilschritt voraus. Trotz dieser damit verbundenen Fehleranfälligkeit vermag dieser Ansatz eine gute Näherung zu liefern, die in ein akzeptables Kantenbild zur Detektion der gesuchten Strukturen resultieren kann. Die Verwendung eines globalen Schwellwertes kann bei regional stark variierendem Bildrauschen jedoch sehr ungeeignet sein, wobei im ungünstigsten Fall relevante Informationen verloren gehen und unerwünschte verrauschte Strukturen erhalten bleiben. Alternativ bietet sich die Bestimmung eines adaptivem lokalen Schwellwertes an, wie zum Beispiel nach den Methoden von *Bernsen* oder *Niblack* (Burger und Burge 2015), womit mögliche regionale Unterschiede berücksichtigt werden können. Die hier genannten Optionen zur Schwellwertbildung können in weiterführenden Untersuchungen näher beleuchtet und miteinander verglichen werden.

Detektion der gesuchten Strukturen

Die Detektion der gesuchten Strukturen erfolgt unter Verwendung der Hough-Transformation und durch eine anschließende Analyse der extrahierten Linien zur Identifikation und Anpassung der gesuchten Fahrgassen. In Anbetracht der gegebenen Daten wurde dieser Ansatz zunächst nur für gerade verlaufende linienförmige Fahrgassen umgesetzt, womit jedoch ein Großteil der Fahrgassen aller drei untersuchten Schläge korrekt detektiert werden kann.

Die Verwendung der Hough-Transformation stellt aufgrund der markanten Charakteristik der Fahrspurgeometrie, sowohl bei linienförmiger als auch bei flächenhafter Erscheinung, ein geeignetes Mittel zur Detektion der Fahrgassen dar. Das Ergebnis ist dabei allerdings sehr eng an die Umsetzung des Hough-Algorithmus sowie die Qualität des binären Kantenbilds gekoppelt. Dies kann im ungünstigen Fall zu weiteren unerwünschten Effekten führen, die bei den untersuchten Testdaten vermieden werden konnten, deren Auftreten im Fall anderer Ausgangsdaten jedoch nicht ausgeschlossen werden kann. Dazu zählt zum Beispiel die Repräsentation einer Fahrgasse anhand mehrerer getrennter Linien, einer einzelnen aber zu kurzen Linie oder sich überlappender Linien mit gering abweichendem Winkel. Diese spezifischen Ergebnisse der Hough-Transformation erschweren somit eine vollständige automatisierte Auswertung der detektierten Linien zur Abdeckung und Korrektur aller potentiellen Fehlerfälle. Das Auftreten möglicher Strukturelemente kommt dabei erschwerend hinzu. Die in dem vorgestellten Ansatz verwendeten Arbeitsschritte zur Auswertung und Korrektur der detektierten Hough-Linien stellen in Folge dessen eine sehr spezifische Lösung dar, welche für die untersuchten Schläge jedoch eine erfolgreiche Anpassung der Linien bewirkt. Der Ansatz zur Selektion der Linien in Vorzugsrichtung entspricht dabei einer ziemlich robusten Methode zur geeigneten Eingrenzung der gesuchten Fahrgassenlinien, sofern das Kantenbild entsprechend gute Voraussetzungen liefert. Im Fall von unterschiedlich

angelegten Fahrgassen innerhalb eines Schlags (vgl. Schlag 1), kann mit der gewählten Vorgehensweise jedoch nur eine Ausrichtung und somit nur ein Teil der Fahrgassen berücksichtigt werden. Die Korrektur der Linienendpunkte erfolgt mit einem stark empirischen Ansatz, der bei einigen Fahrgassenlinien auch zur Unterdrückung fehlerfreier Liniensegmente führt. Eine robuste und korrekte Anpassung der Fahrgassenlinien erfordert demzufolge weitere Untersuchungen zur Optimierung dieses Arbeitsschritts oder die Verwendung einer alternativen Methode.

Die zusätzliche Berücksichtigung flächenhafter Erscheinungen der Fahrgassen könnte durch eine einfache Fallunterscheidung bei der Auswertung der HT-Ergebnisse erfolgen. Dazu gilt es, die nach der Vorzugsrichtung gefilterten Linien lediglich hinsichtlich ihrer Abstände zu analysieren und zu ermitteln, ob eine Fahrgasse durch zwei oder nur durch eine Linie repräsentiert wird. Damit erweitert sich jedoch auch die Anzahl potentieller Fehlerfälle, die es bei der Auswertung zu berücksichtigen gilt. In Folge dessen kann sich eine angemessene Korrektur der Ergebnisse bei einer Abdeckung verschiedener Erscheinungsformen der Fahrgassen letztendlich sehr komplex gestalten.

Abhilfe verspricht die Verwendung eines Kriteriums, mit dem ein Fahrgassenpixel eindeutig identifiziert werden kann. Mit einem solchen Kriterium könnten die detektierten Hough-Linien geprüft und mögliche fehlerhaft detektierte Segmente erkannt und korrigiert werden. Darüber hinaus stellt ein solches Kriterium eine geeignete Möglichkeit dar, um die krummlinigen Fahrgassensegmente im Sinne einer Linienverfolgung zu detektieren. Bei einer hohen spektralen Auflösung bietet sich zum Beispiel eine spektrale Analyse der Pixel an. Diese müssen jedoch ziemlich robust gestaltet werden, da die Fahrgassenpixel oftmals eine dem angrenzenden Pflanzenbestand ähnliche spektrale Signatur aufweisen. Zudem kann die spektrale Charakteristik der Fahrgassenpixel aufgrund variierender beziehungsweise sichtbarer Fahrspuranteile selbst sehr variabel sein.

Eine genauere Betrachtung des binären Kantenbilds am Beispiel von Schlag 1 (Abb. 26) lässt vermuten, dass die Detektion der geradlinigen quer verlaufenden Vorgewende jedoch ausreichend sein kann, um mit einem erweiterten Fahrspurmodell alle Fahrgassenpixel detektieren zu können. Mit einer geeigneten Modellierung der Vorgewende anhand der in Vorzugsrichtung liegenden Fahrgassen und den äußeren eingrenzenden Fahrgassen könnte das Problem der lückenhaften Darstellung krummer Linien im Kantenbild umgangen werden. Die Detektion der äußeren geradlinigen Fahrgassen kann im optimalen Fall durch eine differenzierte Auswertung der Hough-Transformation erfolgen, welche teilweise auch die äußeren Fahrgassenlinien liefert (vgl. Abb. 29b). Da die umrandenden Fahrgassen eines Schlags jedoch nicht in jedem Fall geradlinig verlaufen, verspricht auch dieser Ansatz keine lückenlose Detektion der gesuchten Strukturen.

Es wird deutlich, dass eine vollständige Selektion aller Fahrgassen einigen Herausforderungen unterliegt und durch die hohe Variabilität möglicher Erscheinungsformen der Fahrgassen und der Schläge sowie durch das Auftreten von Strukturelementen erschwert wird. In Anbetracht der Zielstellung stellt sich hingegen die Frage, ob eine vollständige

Detektion aller Fahrgassenpixel notwendig ist oder auch die Detektion der innen liegenden Fahrgassen genügt, um eine ausreichend gute Referenz des Bodensignals zur Korrektur des Vegetationssignals zu erhalten.

5.4 Spektrale Entmischung der Fahrgassenpixel

Für die spektrale Entmischung der Fahrgassenpixel wurde ein wissensbasierter Modellansatz untersucht. Dieser behilft sich einer geometrischen Modellierung der Fahrspuren unter Verwendung des in Kapitel 3.4 definierten Fahrspurmodells. Die nötigen Referenzspektren für den im Fahrgassenpixel anteiligen Pflanzenbestand werden zudem direkt aus den Daten abgeleitet, wodurch die spektrale Variabilität durch den unmittelbaren Orts- und Zeitbezug bestmöglich berücksichtigt wird.

Im Vergleich zu gängigen Methoden der linearen spektralen Entmischung, können mit dem hier betrachteten Ansatz wesentliche Ungenauigkeiten (vgl. Kapitel 2.4.3) vermieden werden. Dazu zählt die Bestimmung der Endmemberanzahl, die aufgrund der Selektion gleichartiger Fahrgassenpixel bekannt ist und auf zwei Endmember fixiert werden kann. Des Weiteren entfallen mögliche Ungenauigkeiten aufgrund schlecht gewählter Referenzspektren, wie bei dem Einsatz von Spektralbibliotheken.

Im Gegenzug können jedoch die getroffenen Modellannahmen kritisch betrachtet werden. Diese umfassen zum Beispiel die Annahme, dass sich die identifizierten Fahrgassenpixel lediglich aus zwei Endmitgliedern zusammensetzen. Damit erfolgt keine Berücksichtigung von Schatten, die insbesondere bei der Betrachtung von Pflanzenbeständen einen hohen Anteil in der Mischpixelcharakteristik haben können. Auch weitere mögliche Oberflächenmaterialien (zum Beispiel Steine, abgestorbene Pflanzenteile, etc.) werden nicht berücksichtigt, wodurch sich der Modellfehler wesentlich erhöhen kann, welcher sich letztendlich auf das gesuchte Bodenspektrum auswirkt. Bei der spektralen Entmischung von Pflanzenbeständen kann die fehlende Berücksichtigung nicht-linearer Einflussfaktoren (zum Beispiel Multiple Streuung, Aufnahmegeometrie) aufgrund der komplexen Streuvorgänge zusätzlich negativ ins Gewicht fallen. Da der in den Fahrgassenpixeln enthaltene Pflanzenbestand jedoch als Mischsignal aufgefasst und durch ein Endmitglied modelliert wird, kann der mögliche Fehler durch die Verwendung eines linearen Entmischungsmodells als vernachlässigbar betrachtet werden.

Abschätzung der Abundanzen

Der vorgestellte Ansatz zur Abschätzung der Abundanzen entspricht einer einfachen abstrakten und modellbasierten Lösung, die einigen Unsicherheiten unterliegt und mitunter sehr rechenaufwändig sein kann.

Die Modellierung der Fahrspuren erfolgt gemäß der Vereinfachung bei der Fahrgassenselektion ausschließlich für gerade verlaufende Fahrgassen. Eine Erweiterung des Fahrspurmodells könnte durch die Modellierung der Vorgewende erfolgen, insofern dies mit dem Ergebnis der Fahrgassenselektion möglich ist. Gemäß der Überlegungen zur

Vervollständigung der Fahrgassenselektion (Kapitel 5.3, S. 92) könnte die Detektion der äußeren den Schlag umrandenden Fahrgassen dafür ausreichen, was jedoch weiteren Schwierigkeiten unterliegt.

Mit der Kenntnis über die Lage und die geometrische Ausdehnung möglicher Strukturelemente, die bei der Segmentierung gewonnen werden könnte, besteht zudem die Möglichkeit, den abweichenden Fahrgassenverlauf von Umfahrungen zu modellieren. Eine solche Modellierung ist jedoch sehr stark an das Segmentierungsergebnis gekoppelt und demnach sowohl bei einer automatisierten als auch interaktiven Umsetzung sehr fehleranfällig. In Folge dessen ist eine zusätzliche Überprüfung der vermeintlichen Fahrgassenpixel, die durch die Modellierung einer Umfahrung bestimmt werden, unerlässlich. Dies unterliegt wiederum der Schwierigkeit, ein eindeutiges Kriterium zur Identifikation von Fahrgassenpixeln zu definieren, wie es auch in Anbetracht einer möglichen Linienverfolgung zur Selektion der Fahrgassen diskutiert wird.

Das Ergebnis der Flächenberechnung ist in erster Linie an die verwendeten Näherungswerte des Fahrspurmodells gekoppelt. Diese Schätzwerte können aufgrund verschiedener Faktoren von der tatsächlichen Fahrspurgeometrie deutlich abweichen, was zu einer fehlerhaften Abschätzung der Abundanzen führt. Eine weitere Unsicherheit resultiert aus der Annahme, dass die Fahrspuren an jeder Stelle unbedeckten Boden aufweisen und für den Fernerkundungssensor sichtbar sind. Die Sichtbarkeit der Fahrspuren kann bei ungünstigen Aufnahmebedingungen in Abhängigkeit der Beleuchtungsverhältnisse sowie der Geländetopographie, aber auch bei zunehmenden Bestandshöhen allerdings deutlich eingeschränkt sein. In Folge dieser Modellannahmen werden im ungünstigsten Fall pure Bestandspixel als Fahrgassenpixel identifiziert, was zu einem erheblichen Modellfehler bei der Entmischung führen kann.

Die Genauigkeit der Flächenberechnung kann darüber hinaus mit zunehmendem Skalierungsfaktor erhöht werden, was jedoch mit einem größeren Rechenaufwand verbunden ist. Im Vergleich zu den anderen Teil- und Prozessierungsschritten handelt es sich bei der Abschätzung der Abundanzen generell um einen sehr rechenintensiven Arbeitsschritt, was auch aus den in Tabelle 4 (Anhang E) aufgeführten Ergebnissen einer Laufzeitmessung hervorgeht. In Anbetracht der zur Verfügung stehenden Rechenkapazität empfiehlt es sich, den Skalierungsfaktor demnach in Abhängigkeit der Eingangsdaten (geometrische Auflösung und Bildgröße) sowie der gewünschten Rechengenauigkeit zur Flächenabschätzung zu bestimmen. Zur Einschätzung der für den Entmischungsansatz erforderlichen Rechengenauigkeit sind jedoch weitere Untersuchungen erforderlich.

Ermittlung des Bestandsreferenzsignals

Das Referenzspektrum für den in den Fahrgassenpixeln enthaltenen Bestand wird anhand purer Pixel des angrenzenden Pflanzenbestands abgeleitet. Dies unterliegt der Annahme, dass das Vegetation-Boden-Mischsignal der Fahrgassenpixel mit einem benachbarten Bestandspixel ausreichend gut angenähert werden kann. Diese Annahme kann

aufgrund der spektralen Variabilität der Vegetation, räumlich variierender Bedeckungsgrade sowie anderer die spektrale Signatur beeinflussender Faktoren jedoch als kritisch betrachtet werden. Im ungünstigsten Fall kann ein schlecht angenähertes Bestandsspektrum zu einem erhöhten Modellfehler bei der Entmischung der Fahrgassenpixel führen und das daraus resultierende Bodenspektrum verfälschen. Mit der vorgestellten Vorgehensweise zur Ermittlung des Bestandsreferenzsignals erfolgt darüber hinaus eine Einschränkung der auszuwertenden Daten, da der Ansatz eine Mindestbodenauflösung in Abhängigkeit des tatsächlichen Fahrgassenabstands erfordert. Diese beträgt bei einem maximalen Fahrgassenabstand von $36m$ einer Bodenauflösung von $8m$ pro Pixel.

Zur Detektion von Ausreißern wurde ein empirischer Ansatz unter Verwendung des Spectral Angle Mapper gewählt, dessen Potential für die gegebenen Testdaten aufgrund fehlender Validierungsdaten nicht beurteilt werden kann. Die Schwierigkeit bei der Verwendung des Spectral Angle Mapper als Ähnlichkeitsmaß liegt insbesondere in der Wahl eines geeigneten Referenzspektrums sowie der Bestimmung einer zulässigen Toleranz für die gewünschte Klassifizierung in Abhängigkeit der Daten. Bei der Betrachtung großer Pflanzenbestände gilt es, dabei zusätzlich mögliche regionale spektrale Unterschiede zu berücksichtigen. Der Einsatz einer lokalen Analyseumgebung unter Verwendung des NDVI zur Bestimmung eines Referenzspektrums kann im Fall großflächiger ungünstiger Ausgangsbedingungen (zum Beispiel geringer Bedeckungsgrad, Krankheitsbefall) jedoch sehr fehleranfällig sein. Aufgrund dieser Unsicherheit kann eine zuverlässige Analyse der detektierten Bestandspixel mit dem gewählten Ansatz nicht sichergestellt werden. Demzufolge empfiehlt sich die Suche nach einer robusteren Möglichkeit zur Bestimmung des Referenzsignals, wobei die Fehleranfälligkeit durch die Betrachtung einer lokalen Analyseumgebung zu reduzieren ist. Alternativ bietet sich auch die Verwendung eines anderen Ähnlichkeitsmaßes an, zumal die Aussagekraft des Spectral Angle Mapper bei der Auswertung von Multispektraldaten aufgrund der geringen Anzahl von spektralen Komponenten in Frage gestellt werden kann.

Ableitung des Bodensignals

Auf der Suche nach einer geeigneten Methode zur Ableitung des Bodensignals wurden zwei verschiedene Optimierungsansätze untersucht, deren Validierung zum Zeitpunkt der Arbeit jedoch noch ausstehend ist. Die Untersuchungen haben gezeigt, dass eine explizite Berechnung des Bodenspektrums unter Verwendung der Näherungswerte für die Flächenverteilung und das Bestandsspektrum sehr fehleranfällig und somit nicht geeignet ist. Bei sehr kleinem Fahrspuranteil und der damit einhergehenden geringen Differenz zwischen Pixel- und Bestandsspektrum führen schon geringe Ungenauigkeiten der Näherungswerte zu wesentlichen Fehlern im Bodenspektrum, was die Notwendigkeit eines Optimierungsverfahrens in Anbetracht der zur Verfügung stehenden Größen verdeutlicht.

Der untersuchte lineare *Optimierungsansatz 1* bezieht sich auf eine separate Betrachtung der Fahrgassenpixel, wobei eine Annäherung des gesuchten Bodenspektrums an ein lokal gemittelttes Bodenspektrum erfolgt. Dies unterliegt der Annahme, dass die Bodenreflexion innerhalb einer bestimmten räumlichen Distanz durch ein mittleres Bodenspektrum beschrieben werden kann, was einem einfachen heuristischen Ansatz entspricht und kritisch betrachtet werden sollte. In einer beispielhaften Demonstration des Ansatzes anhand der gegebenen Testdaten konnte gezeigt werden, dass die Optimierung unabhängig vom Maß des Fahrspuranteils vergleichbare Ergebnisse liefert, wobei jedoch die Qualität des mittleren Bodenspektrums maßgebend ist. Die Berechnung des mittleren Bodenspektrums unterliegt jedoch den Unsicherheiten des Modellansatzes unter Verwendung von Näherungswerten für die Flächenverteilung sowie für das Bestandspektrum. Der Einfluss schlecht gewählter Näherungswerte äußert sich durch fehlerbehaftete Schwankungen im Bodenspektrum, was anhand einer Simulation demonstriert werden konnte. Dabei ist das Ausmaß der Ungenauigkeit entscheidend, welche für die ermittelten Näherungswerte aufgrund der fehlenden Kenntnisse über die tatsächlichen Größen jedoch nicht eingeschätzt werden kann. Demzufolge kann auch keine Aussage über den Fehler im optimierten Bodenspektrum getroffen werden.

Dieser Optimierungsansatz eignet sich somit nur für ausreichend genaue Näherungswerte, mit denen die Berechnung eines repräsentativen mittleren Bodenspektrums sichergestellt werden kann. In weiterführenden Untersuchungen empfiehlt es sich demnach, die erforderliche Genauigkeit der Flächenabschätzung sowie des Bestandsreferenzsignals zu bestimmen und wenn nötig, Ansätze zur Verbesserung dieser Näherungswerte zu finden. Die hier gewählte Vorgehensweise zur Ermittlung des Bestandsreferenzspektrums bietet allerdings wenige Möglichkeiten, um eine höhere Genauigkeit zu erzielen. Alternativ bietet sich der Einsatz von Referenzspektren aus spektralen Bodenmessungen an, was bei dem gewünschten Orts- und Zeitbezug jedoch nicht praktikabel ist. Die Genauigkeit der Flächenabschätzung kann durch eine Optimierung der verwendeten Fahrspurparameter erhöht werden. Da die Fahrspurgeometrie in Abhängigkeit der Bewirtschaftungsmethoden jedoch von Schlag zu Schlag deutlich variieren kann, wird die Definition eines universellen Fahrspurmodells erschwert. Es stellt sich allerdings die Frage, ob mit der Verwendung gemittelter Näherungswerte unter Berücksichtigung zahlreicher Fahrspurgeometrien ausreichend gute Optimierungsergebnisse erzielt werden können. Dazu gilt es, den maximal zulässigen Fehler der Flächenabschätzung sowie die mögliche Varianz der Fahrspurparameter zu bestimmen. Sollte dieser Ansatz nicht zielführend sein, so kann die Genauigkeit der Flächenabschätzung alternativ durch eine wissensbasierte Parametrisierung des Fahrspurmodells in Abhängigkeit des Untersuchungsgebiets erhöht werden. Damit wird jedoch die Kenntnis der tatsächlichen Fahrspurgeometrie vorausgesetzt, was eine Automatisierung des Prozessschrittes erschwert.

Eine Möglichkeit zur Unterdrückung der durch die Modellunsicherheiten verursachten Schwankungen im Bodenspektrum wurde mit der zusätzlich betrachteten *Abwandlung des Optimierungsansatzes 1* untersucht. Dies erfolgt durch einen heuristischen Ansatz, wobei das Bodenspektrum einer konstanten Mittelwertfunktion angenähert wird. Zur Berücksichtigung möglicher Absorptionsbanden erfolgt außerdem eine wellenlängenabhängige Gewichtung der Nebenbedingung. Die Untersuchungen haben gezeigt, dass die Schwankungen im Bodenspektrum mit diesem Ansatz unterdrückt werden können. Dieser Effekt ist jedoch sehr stark an das Ausgangsspektrum sowie die gewählten Gewichte gekoppelt und führt bei den betrachteten Fällen in Abhängigkeit des Fahrspuranteils zu deutlich unterschiedlichen Ergebnissen. Mit diesen Beobachtungen wird die Wahl der Gewichte in Abhängigkeit der spektralen Varianz des mittleren Bodenspektrums als ungünstig beurteilt. Es wird vermutet, dass die Bestimmung dieser Gewichte in Abhängigkeit der Ausgangsspektren für eine angemessene Unterdrückung der Oszillationen im Signal besser geeignet ist, was in weiterführenden Untersuchungen näher beleuchtet werden kann. Aufgrund eines durch die Modellunsicherheiten verursachten möglichen Fehlers im mittleren Bodenspektrum, sollte die Verwendung der daraus abgeleiteten Mittelwertfunktion außerdem als kritisch betrachtet werden. Der mittlere Reflexionsgrad kann durch die auftretenden Schwankungen deutlich beeinflusst werden und somit eine schlechte Referenz darstellen. Es wird jedoch vermutet, dass eine ungünstige Mittelwertfunktion bei einer geeigneten Wahl der Gewichte und einem optimalen Kontrollparameter nicht allzu stark ins Gewicht fällt und das Bodenspektrum durch eine geeignete Unterdrückung der Schwankungen trotzdem ausreichend gut angenähert werden kann. Auch dieser Aspekt kann in weiterführenden Untersuchungen betrachtet werden.

Bei *Optimierungsansatz 2* wurde ein nicht-lineares alternierendes Verfahren untersucht, bei dem sowohl das Bodenspektrum als auch die Flächenverteilung iterativ geschätzt werden. Dies erfolgt durch die simultane Betrachtung mehrerer Pixel in einem Spektralmodell. Eine beispielhafte Demonstration anhand simulierter Daten hat gezeigt, dass sich das gesuchte Bodenspektrum mit diesem Ansatz und der Wahl geeigneter Kontrollparameter für den Einfluss der einschränkenden Nebenbedingungen ziemlich gut annähern lässt. Mit der simultanen Optimierung der Flächenverteilung können die Unsicherheiten des Modells aufgrund einer fehlerbehafteten Flächenabschätzung reduziert werden. Der Ansatz erfordert zudem keine Kenntnis über das Bestandsspektrum, was einen wesentlichen praktischen Vorteil mit sich bringt und wodurch die Einführung einer weiteren Unsicherheit durch die Verwendung von Näherungswerten vermieden werden kann. Die hier zulässigen Variationen im Bestandsspektrum eröffnen zudem mehr Spielraum bei der Optimierung des Bodenspektrums. Daraus resultierende mögliche Verfälschungen der Bestandsspektren sind für das Ergebnis nicht relevant.

Das Optimierungsergebnis ist letztendlich an die Wahl geeigneter Nebenbedingungen gekoppelt. Die Verwendung der geschätzten Flächen als initialen Startwert sowie als Richtwert zur Optimierung der Flächenverteilung stellt hier einen guten Ansatz dar. Dabei gilt es, die Nebenbedingung jedoch nicht allzu stark zu forcieren, damit der Fehler der Flächenabschätzung ausgeglichen werden kann. Der Einsatz einer konstanten Modellfunktion zur Optimierung des Bodenspektrums hat sich ebenfalls als ersten guten Ansatz erwiesen. Alternativ bietet sich auch die Definition einer Modellfunktion an, die den charakteristischen Verlauf des Bodenspektrums geeignet beschreibt. Dies wird jedoch durch die hohe spektrale Variabilität des Bodens und die dadurch mögliche Vielzahl spektraler Reflexionskurven erschwert. Eine Möglichkeit zur Berücksichtigung der spektralen Variabilität besteht hingegen durch die Verwendung einer Spektralbibliothek. Mit der Analyse zahlreicher Bodenspektren, die sich sowohl im mittleren Reflexionsgrad sowie durch charakteristische Absorptionsbanden unterscheiden, könnte ein maßgebendes mittleres Bodenspektrum bestimmt werden, das als Referenzfunktion in das Optimierungsverfahren einfließen kann. Des Weiteren lassen sich aus der Vielzahl von Bodenspektren auch zuverlässige wellenlängenabhängige Varianzen für eine zusätzliche Gewichtung der Nebenbedingung definieren, um so auch mögliche charakteristische Absorptionsbanden im Bodenspektrum zu berücksichtigen. Somit könnten die umfangreichen Informationen einer Spektralbibliothek genutzt werden, ohne ein explizites Referenzspektrum für die Entmischung zu bestimmen, was oftmals hohes Fehlerpotential in sich birgt.

Aufgrund der iterativen Schätzung erfordert der alternierende Ansatz im Vergleich zu dem anderen linearen Verfahren einen größeren Rechenaufwand, der an die Anzahl der Iterationsschritte gekoppelt ist. Die daraus resultierenden Laufzeitunterschiede können für das Beispiel von 200 Iterationsschritten der Tabelle 4 (Anhang E) entnommen werden.

Im Vergleich der untersuchten Optimierungsansätze scheint das alternierende Verfahren aufgrund wesentlicher Vorteile bessere Voraussetzungen zur Ableitung des Bodenspektrums zu liefern. Die zusätzliche Optimierung der Flächenverteilung sowie die zulässigen Variationen im Bestandsspektrum eröffnen mehr Spielraum bei der Optimierung des Bodenspektrums, wobei sich der Modellfehler auf alle variablen Größen verteilt. Zudem unterliegt dieser Ansatz keinen erheblichen Unsicherheiten aufgrund der Verwendung von Näherungswerten, da ein Bestandsreferenzspektrum einerseits nicht von Nöten ist und mögliche Fehler der Flächenabschätzung im Rahmen der Optimierung ausgeglichen werden können. Außerdem kann der durch den Iterationsprozess bedingte erhöhte Rechenaufwand in Anbetracht der Gesamtlaufzeit der Prozessierungskette vernachlässigt werden. Das lineare Optimierungsverfahren hingegen unterliegt wesentlichen Unsicherheiten aufgrund der Verwendung von Näherungswerten, was starke Verfälschungen des Bodenspektrums zur Folge haben kann. Eine geeignete Unterdrückung der daraus resultierenden Schwankungen wird durch die fehlende Kenntnis über das Ausmaß der

Ungenauigkeiten erschwert. Demzufolge muss bei diesem Ansatz eine ausreichende Genauigkeit der Eingangsgrößen sichergestellt werden, was gegebenenfalls nur durch den Einsatz von Zusatzdaten realisiert werden kann.

Die untersuchten Entmischungsansätze können generell auch auf Multispektraldaten übertragen werden, wobei die geringe spektrale Auflösung einen Genauigkeitsverlust bei der Entmischung bewirken kann. Aufgrund des oftmals sehr signifikanten und unterschiedlichen Spektralverhaltens von Vegetation und Boden wird jedoch vermutet, dass auch wenige zur Verfügung stehende Kanäle eine geeignete Trennung der Oberflächenmaterialien ermöglichen. Eine Beurteilung der für ein ausreichend gutes Entmischungsergebnis erforderlichen Kanäle sowie des damit abgedeckten Spektralbereichs erfordert jedoch weitere Untersuchungen.

In einem alternativen Ansatz zur Auswertung von Hyperspektraldaten bietet sich zum Beispiel auch eine Reduktion des Merkmalsraums an, wodurch die Dimension des mathematischen Problems zur spektralen Entmischung verringert und dessen Lösungsmenge besser eingegrenzt werden kann. Mit der Bestimmung signifikanter und bestenfalls schmaler Spektralbänder verspricht dieser Ansatz, eine gezielte Separation der gesuchten Spektren. Dies wird jedoch durch die spektrale Variabilität von Vegetation und Boden und die damit einhergehende teilweise sehr große Varianz des Spektralverhaltens erschwert. Nichtsdestotrotz empfiehlt sich eine nähere Untersuchung dieses Ansatzes sowie der Vergleich zu den betrachteten Verfahren in Hinblick auf den Rechenaufwand und die Genauigkeit der Entmischungsergebnisse.

Die Anwendung einer blinden Dekonvolution (*blind deconvolution*) stellt darüber hinaus eine weitere Möglichkeit zur Entmischung der Fahrgassenpixel dar. Blinde Dekonvolutionsalgorithmen ermöglichen die Rekonstruktion eines gesuchten Signals aus einem Mischsignal ohne genaue Kenntnis über die das Mischverhältnis beeinflussenden Größen. Dies kommt der mathematischen Problemstellung zur Ableitung des Bodenspektrums gleich und kann in weiterführenden Untersuchungen ebenfalls berücksichtigt werden. Solche Algorithmen finden in der digitalen Signal- und Bildverarbeitung zum Beispiel bei der Identifikation einer Bildunschärfe oder auch zur Separation verschiedener Schallquellen eines akustischen Mischsignals bereits erfolgreich Anwendung (Chan und Wong 1998, Bell und Sejnowski 1995).

5.5 Räumliche Interpolation des Bodensignals

Die flächenhafte Ableitung des Bodensignals kann unter Verwendung eines geostatistischen Interpolationsverfahrens wie dem Ordinary Kriging erfolgen. Dieses Interpolationsverfahren setzt eine homogene Verteilung der Stichproben voraus, was durch das extrahierte Bodensignal entlang der Fahrgassen nur unzureichend sichergestellt wird. Demzufolge ist die Qualität der Stichproben für eine geeignete Modellierung der räumlichen Struktur als kritisch zu betrachten. Alternativ bietet sich eine Überführung aller extrahierten Bodensignale zu einem regelmäßigen Raster einzelner Stützstellen an, die

entlang der Fahrgassen in einem Abstand, der im Größenbereich des Fahrgassenabstands liegt, entnommen werden könnten. Somit kann eine geeignete Stichprobenqualität gewährleistet werden. In Abhängigkeit der spektralen Variabilität des Bodens kann sich die Genauigkeit des Interpolationsergebnisses dadurch jedoch wesentlich verringern. Diesen Aspekt gilt es, in weiterführenden Untersuchungen näher zu beleuchten, um die Eignung eines solchen Ansatzes in Hinblick auf die Zielstellung besser beurteilen zu können. Darüber hinaus bieten sich weitere Untersuchungen zur Optimierung der Parametrisierung des Kriging-Verfahrens an. Dies umfasst unter anderem die Wahl der Lag-Distanz zur Bestimmung des empirischen Semivariogramms sowie die Wahl des geostatistischen Modells. Des Weiteren ist zu beachten, dass die Kriging-Interpolation in Abhängigkeit der spektralen Auflösung sowie der Größe des Untersuchungsgebiets mit einem sehr hohen Rechenaufwand verbunden sein kann.

6 Zusammenfassung und Ausblick

Im Rahmen dieser Arbeit wurde eine mögliche Methode zur direkten Ableitung des Bodensignals landwirtschaftlicher vegetationsbedeckter Ackerflächen anhand von spektral hochauflösenden Fernerkundungsdaten erarbeitet und ausführlich untersucht. Die Methodik stützt sich auf die Ausnutzung des unbedeckten Bodens der Fahrgassen, womit in Anbetracht der übergeordneten Zielstellung ein bestmöglicher räumlicher und zeitlicher Bezug zu dem zu korrigierenden Pflanzenbestand hergestellt wird. Zur Extraktion des Bodensignals wurde ein wissensbasierter Modellansatz zur linearen spektralen Entmischung der Fahrgassen entwickelt. Dieser setzt die Identifikation der Fahrgassenpixel sowie die Kenntnis über die Fahrspurgeometrie voraus und verzichtet auf den Einsatz von Spektralbibliotheken. Damit können einige wesentliche Ungenauigkeiten gängiger Methoden zur linearen spektralen Entmischung umgangen werden.

Mit einer exemplarischen Prozesskette wurde die erarbeitete Methode unter Verwendung von MATLAB größtenteils praktisch umgesetzt. Bei den gewählten Ansätzen handelt es sich teilweise um sehr datenspezifische und vereinfachte Lösungen, die am Beispiel von drei untersuchten Schlägen der gegebenen Hyperspektraldaten jedoch erfolgreich demonstriert werden konnten. Schwierigkeiten liegen dabei unter anderem in einer geeigneten Umsetzung zur Segmentierung des Untersuchungsgebiets sowie in einer zuverlässigen Selektion der Fahrgassen. Die Verwendung der Hough-Transformation hat sich zur Detektion geradliniger Fahrgassen als durchaus geeignet erwiesen. Eine Erweiterung des Ansatzes zur vollständigen Selektion aller Fahrgassen wird hingegen als sehr aufwändig eingeschätzt und kann in Hinblick auf die übergeordnete Zielstellung unter Umständen auch vernachlässigt werden. Für die Entmischung der Fahrgassenpixel wurden zwei verschiedene Optimierungsansätze zur Ableitung des Bodensignals untersucht, deren Zuverlässigkeit aufgrund fehlender Validierungsdaten allerdings nicht beurteilt werden kann. Die Untersuchungen haben gezeigt, dass das lineare Verfahren wesentlichen Modellunsicherheiten unterliegt, die zu einer Verfälschung des Bodenspektrums führen können. Dabei liegt die Schwierigkeit in einer ausreichend genauen Abschätzung der Eingangsgrößen, was gegebenenfalls nur durch Zusatzdaten gelöst werden kann. Mit dem zweiten untersuchten nicht-linearen Optimierungsansatz können derartige Modellunsicherheiten hingegen vermieden beziehungsweise reduziert werden. In Folge dessen sowie aufgrund weiterer entscheidender Vorteile verspricht dieser Ansatz eine zuverlässigere Abschätzung des Bodenspektrums. Zur abschließenden flächenhaften Ableitung des Bodensignals bietet sich ein geostatistisches Interpolationsverfahren wie das Ordinary Kriging an, das im Rahmen der Arbeit näher beleuchtet, aber aufgrund der unzureichenden Beurteilung der Entmischungsergebnisse jedoch praktisch nicht umgesetzt wurde.

Eine angemessene Bewertung der erarbeiteten Methode ist aufgrund der ausstehenden Validierung der Ergebnisse zum Zeitpunkt der Arbeit nicht möglich. Demzufolge kann das Potential zur Ableitung des Bodensignals und die damit verbundene Korrektur

des Vegetationssignals sehr schlecht eingeschätzt werden. Mögliche Einschränkungen zur Übertragbarkeit der Methode sind jedoch eindeutig durch die geometrische und spektrale Auflösung der Daten, aber auch durch das Untersuchungsgebiet selbst gegeben. In Folge der gewählten Ansätze erfordert die Methode an einigen Stellen eine Mindestbodenauflösung von $8m$ beziehungsweise $9m$ pro Pixel. Da eine ausreichende Erkennbarkeit der Fahrgassen für diesen Größenbereich jedoch ohnehin angezweifelt werden kann, stellt sich vielmehr die Frage nach einer geometrischen Obergrenze, womit sich der Ansatz zur Fahrgassenselektion sicherstellen lässt. Eine Übertragung der Methode auf spektral gering aufgelöste Multispektraldaten wird generell nicht ausgeschlossen, erfordert jedoch weitere Untersuchungen. Diesbezüglich verbleibt die Frage nach einer minimal erforderlichen spektralen Auflösung, die eine ausreichend genaue Entmischung der Fahrgassenpixel ermöglicht. Neben der Anzahl und der Breite der Bänder beziehungsweise Kanäle kann dabei auch der abgedeckte Spektralbereich entscheidend sein. Darüber hinaus wird mit dem untersuchten Ansatz die Sichtbarkeit der Fahrgassen in der Fernerkundungsszene vorausgesetzt, was im Fall ungünstiger Aufnahmebedingungen oder auch bei großen Wuchshöhen ebenfalls zu Einschränkungen führen kann.

In Anbetracht weiterführender Untersuchungen gilt es an erster Stelle, eine Validierung der Methode vorzunehmen, um eine angemessene Bewertung des untersuchten Ansatzes zu gewährleisten und dessen Potential besser einschätzen zu können. Dies erfordert die Auswertung zeitgleich erhobener Fernerkundungsdaten und spektraler Bodennmessungen, wofür das Testfeld DEMMIN aufgrund der regelmäßigen Erfassung von in-situ-Daten sehr gute Voraussetzungen bietet. Eine Validierung kann zum Beispiel unter Verwendung des semi-empirischen Modellansatzes von Clevers und mit Messungen des Blattflächenindex erfolgen, wie es bereits in den Vorbetrachtungen (Kapitel 3.3) erläutert wurde. Im Fall einer erfolgreichen Validierung der vorerst exemplarisch umgesetzten Methode, können anschließend auch die einzelnen Prozessschritte bezüglich der aufgezeigten Optimierungs- und Erweiterungsmöglichkeiten verbessert werden. Dies erfordert weitere Untersuchungen zu den aufgeworfenen Fragestellungen sowie die Suche nach alternativen und robusten Ansätzen zur Umsetzung der offenstehenden Arbeitsschritte. Angesichts einer Konkretisierung möglicher Anwendungsfälle kann dies zudem auch eine Laufzeitoptimierung erfordern, da die erarbeitete Methode teilweise einen sehr hohen Rechenaufwand erfordert.

Hinsichtlich des übergeordneten Ziels zur Verbesserung des Vegetationssignals und der damit einhergehenden zuverlässigeren Ableitung von Pflanzenparametern, sind weitere Untersuchungen zur Übertragbarkeit der Methode auf geometrisch höher aufgelöste Daten (zum Beispiel $0.5m$ bis $1m$ pro Pixel) von besonderem Interesse. Schließlich ist eine kleinräumige Analyse von landwirtschaftlichen Flächen von großem Vorteil, um das Pflanzenwachstum geeignet zu überwachen, Bewirtschaftungsmethoden anzupassen oder auch die Teilschlagbewirtschaftung zu unterstützen.

Literatur- und Quellenverzeichnis

- Agapiou, A., Hadjimitsis, D. G. und Alexakis, D. D. (2012). Evaluation of broadband and narrowband vegetation indices for the identification of archaeological crop marks, *Remote Sensing* **4**(12): 3892–3919.
- Agrarservice MVP GmbH & Co.KG (o. J.). Fahrgassen, Website. Online erhältlich unter <http://agrarservice-mvp.de/lexicon/index.php/Entry/18-Fahrgassen/>; abgerufen am 03.02.2017.
- Akin, H., Siemes, H. und Schaeben, H. (1988). *Praktische Geostatistik: Eine Einführung für den Bergbau und die Geowissenschaften*, Springer Berlin Heidelberg, S. 26-35 / 112-123.
- Albertz, J. (2001). *Einführung in die Fernerkundung: Grundlagen der Interpretation von Luft- und Satellitenbildern*, Wiss. Buchges., S. 1-3 / 9-23 / 57-58.
- Baatz, M. und Schäpe, A. (2000). Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation, *Angewandte Geographische Informationsverarbeitung XII* **58**: 12–23.
- Bach, H. (1995). *Die Bestimmung hydrologischer und landwirtschaftlicher Oberflächenparameter aus hyperspektralen Fernerkundungsdaten*, Münchener Universitätsschriften, Fakultät für Geowissenschaften, Münchener geographische Abhandlungen, Geobuch-Verlag, S. 80-85.
- Bannari, A., Khurshid, K. S., Staenz, K. und Schwarz, J. W. (2007). A comparison of hyperspectral chlorophyll indices for wheat crop chlorophyll content estimation using laboratory reflectance measurements, *IEEE Transactions on Geoscience and Remote Sensing* **45**(10): 3063–3074.
- Bannari, A., Morin, D., Bonn, F. und Huete, A. (1995). A review of vegetation indices, *Remote Sensing Reviews* **13**(1-2): 95–120.
- Baret, F., Andrieu, B. und Steven, M. (1993). Gap frequency and canopy architecture of sugar beet and wheat crops, *Agricultural and Forest Meteorology* **65**(3-4): 261–279.
- Baret, F. und Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment, *Remote Sensing of Environment* **35**(2-3): 161–173.
- Baret, F., Guyot, G. und Major, D. (1989). TSAVI: a vegetation index which minimizes soil brightness effects on LAI and APAR estimation, *Geoscience and Remote Sensing Symposium, 1989. IGARSS'89. 12th Canadian Symposium on Remote Sensing., 1989 International*, Vol. 3, IEEE, S. 1355–1358.

- Bateson, C. A., Asner, G. P. und Wessman, C. A. (2000). Endmember bundles: A new approach to incorporating endmember variability into spectral mixture analysis, *IEEE Transactions on Geoscience and Remote Sensing* **38**(2): 1083–1094.
- Baumgardner, M. F., Silva, L. F., Biehl, L. L. und Stoner, E. R. (1986). Reflectance properties of soils, *Advances in Agronomy* **38**(1): 1–44.
- Bell, A. J. und Sejnowski, T. J. (1995). An information-maximization approach to blind separation and blind deconvolution, *Neural Computation* **7**(6): 1129–1159.
- Ben-Dor, E., Irons, J. und Epema, G. (1999). Soil reflectance, *Man Remote Sens Remote Sens Earth Science* **3**: 111.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I. und Heynen, M. (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of Photogrammetry and Remote Sensing* **58**(3): 239–258.
- Bioucas-Dias, J. M. (2009). A variable splitting augmented Lagrangian approach to linear spectral unmixing, *2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, IEEE, S. 1–4.
- Bioucas-Dias, J. M. und Nascimento, J. M. (2008). Hyperspectral subspace identification, *IEEE Transactions on Geoscience and Remote Sensing* **46**(8): 2435–2445.
- Bioucas-Dias, J. M., Plaza, A., Dobigeon, N., Parente, M., Du, Q., Gader, P. und Chanussot, J. (2012). Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **5**(2): 354–379.
- Blackburn, G. A. (1998a). Quantifying chlorophylls and carotenoids at leaf and canopy scales: An evaluation of some hyperspectral approaches, *Remote Sensing of Environment* **66**(3): 273–285.
- Blackburn, G. A. (1998b). Spectral indices for estimating photosynthetic pigment concentrations: a test using senescent tree leaves, *International Journal of Remote Sensing* **19**(4): 657–675.
- Boardman, J. W., Kruse, F. A. und Green, R. O. (1995). Mapping target signatures via partial unmixing of AVIRIS data, *Summaries 5th JPL Airborne Earth Science Workshop* **95**(1): 23–26.
- Borg, E. (2016). Interne Präsentation, DLR (unveröffentlicht).
- Borg, E., Lippert, K., Zabel, E., Löpmeier, F. J., Fichtelmann, B., Jahncke, D. und Maass, H. (2009). DEMMIN - Teststandort zur Kalibrierung und Validierung von Fernerkundungsmissionen, *15 Jahre Studiengang Vermessungswesen - Geodätisches*

- Fachforum und Festakt*, 16.-17.01.2009, Neubrandenburg, Eigenverlag (Hrsg.: Rebenstorf, R.W.), S. 401–419.
- Bouman, B., Van Kasteren, H. und Uenk, D. (1992). Standard relations to estimate ground cover and LAI of agricultural crops from reflectance measurements, *European Journal of Agronomy* **1**(4): 249–262.
- Broge, N. H. und Leblanc, E. (2001). 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 Environment* **76**(2): 156–172.
- Broge, N. H. und Mortensen, J. V. (2002). Deriving green crop area index and canopy chlorophyll density of winter wheat from spectral reflectance data, *Remote Sensing of Environment* **81**(1): 45–57.
- Buck, O., Peter, B. und Büker, C. (2011). Zwei-skaliger Ansatz zur Aktualisierung landwirtschaftlicher Referenzkulissen (LPIS), *Photogrammetrie-Fernerkundung-Geoinformation* (5): 339–348.
- Burger, W. und Burge, M. J. (2015). *Digitale Bildverarbeitung: Eine algorithmische Einführung mit Java*, X.media.press, 3. Aufl., Springer Vieweg, Berlin, S. 169-182 / 291-304.
- Butenuth, M., Straub, B.-M. und Heipke, C. (2004). Automatic extraction of field boundaries from aerial imagery, *KDNet Symposium on Knowledge-Based Services for the Public Sector*, Vol. 3, S. 14–25.
- Campbell, J. und Wynne, R. (2011). *Introduction to Remote Sensing, Fifth Edition*, Guilford Publications, S. 38-43.
- Chan, T. F. und Wong, C.-K. (1998). Total variation blind deconvolution, *IEEE Transactions on Image Processing* **7**(3): 370–375.
- Chang, C.-I. und Du, Q. (2004). Estimation of number of spectrally distinct signal sources in hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing* **42**(3): 608–619.
- Chen, J. M. und Cihlar, J. (1996). Retrieving leaf area index of boreal conifer forests using Landsat TM images, *Remote Sensing of Environment* **55**(2): 153–162.
- Clevers, J. G. P. W. (1986). *Application of remote sensing to agricultural field trials*, Dissertation, Agricultural University, Wageningen, The Netherlands.
- Clevers, J. G. P. W. (1988). The derivation of a simplified reflectance model for the estimation of leaf area index, *Remote Sensing of Environment* **25**(1): 53–69.

- Clevers, J. G. P. W. (1989). Application of a weighted infrared-red vegetation index for estimating leaf area index by correcting for soil moisture, *Remote Sensing of Environment* **29**(1): 25–37.
- Clevers, J. G. P. W. und Verhoef, W. (1993). LAI estimation by means of the WDVI: A sensitivity analysis with a combined PROSPECT-SAIL model, *Remote Sensing Reviews* **7**(1): 43–64.
- Darwish, A., Leukert, K. und Reinhardt, W. (2003). Image segmentation for the purpose of object-based classification, *International Geoscience and Remote Sensing Symposium*, Vol. 3, S. III–2039.
- Daughtry, C., Walthall, C., Kim, M., De Colstoun, E. B. und McMurtrey, J. (2000). Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance, *Remote Sensing of Environment* **74**(2): 229–239.
- Drumetz, L., Chanussot, J. und Jutten, C. (2016). Variability of the endmembers in spectral unmixing: recent advances, *8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS 2016)*, Aug 2016, Los Angeles, United States. Proceedings of the 8th IEEE Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing.
- Duda, R. O. und Hart, P. E. (1972). Use of the Hough transformation to detect lines and curves in pictures, *Communications of the ACM* **15**(1): 11–15.
- Dutter, R. (1985). *Geostatistik: eine Einführung mit Anwendungen*, Mathematische Methoden in der Technik, Teubner, S. 11–28.
- Ehlers, M. (2002). Fernerkundung für GIS-Anwender-Sensoren und Methoden zwischen Anspruch und Wirklichkeit, *Neue Sensoren-innovative Methoden*. Wichmann Verlag, Heidelberg S. 10–23.
- Eismann, M. (2012). *Hyperspectral Remote Sensing*, Press Monographs, SPIE, S. 163–186.
- Elvidge, C. D. und Chen, Z. (1995). Comparison of broad-band and narrow-band red and near-infrared vegetation indices, *Remote Sensing of Environment* **54**(1): 38–48.
- García-Haro, F., Sommer, S. und Kemper, T. (2005). A new tool for variable multiple endmember spectral mixture analysis (VMESMA), *International Journal of Remote Sensing* **26**(10): 2135–2162.
- Gerighausen, H., Borg, E., Fichtelmann, B., Günther, A., Vajen, H.-H., Wloczyk, C., Zabel, E. und Maass, H. (2009). Validation and calibration of remote sensing data products on test site DEMMIN, *Proc. on 43. Ziolkowski Conference*, Russische Akademie der Wissenschaften, S. 18–33.

- Gilabert, M., González-Piqueras, J., Garcia-Haro, F. und Meliá, J. (2002). A generalized soil-adjusted vegetation index, *Remote Sensing of Environment* **82**(2): 303–310.
- Girouard, G., Bannari, A., El Harti, A. und Desrochers, A. (2004). Validated spectral angle mapper algorithm for geological mapping: comparative study between Quick-Bird and Landsat-TM, *XXth ISPRS Congress, Geo-Imagery Bridging Continents, Istanbul, Turkey*, S. 12–23.
- Goetz, S. (1997). Multi-sensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland site, *International Journal of Remote Sensing* **18**(1): 71–94.
- Gruber, F. und Joeckel, R. (2011). *Formelsammlung für das Vermessungswesen*, Springer Fachmedien Wiesbaden, S. 48.
- Gruninger, J., Fox, M. J. und Sundberg, R. L. (2001). Hyperspectral mixture analysis using constrained projections onto material subspaces, *Proceedings International Symposium on Spectral Sensing Research (ISSSR)*, S. 162–170.
- Gruninger, J. H., Ratkowski, A. J. und Hoke, M. L. (2004). The sequential maximum angle convex cone (SMACC) endmember model, *Defense and Security*, International Society for Optics and Photonics, S. 1–14.
- Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J. und Strachan, I. B. (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 Environment* **90**(3): 337–352.
- Haboudane, D., Tremblay, N., Miller, J. R. und Vigneault, P. (2008). Remote estimation of crop chlorophyll content using spectral indices derived from hyperspectral data, *IEEE Transactions on Geoscience and Remote Sensing* **46**(2): 423–437.
- Hansen, P. und Schjoerring, J. (2003). Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression, *Remote Sensing of Environment* **86**(4): 542–553.
- Hildebrandt, G. (1996). *Fernerkundung und Luftbildmessung: für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie*, Wichmann, S. 14-26 / 30-51 / 62-65.
- Holzwarth, S., Heiden, U., Reichmuth, A. und Pinnel, N. (2015). Identifying Tree Species in the Bavarian Forest National Park, *Workshop on Hyperspectral Imaging and LiDAR*, 30.11.2015, Oslo, Norwegen.
- Horler, D., DOCKRAY, M. und Barber, J. (1983). The red edge of plant leaf reflectance, *International Journal of Remote Sensing* **4**(2): 273–288.

- Hough, P. (1962). Method and means for recognizing complex patterns. US Patent 3 069 654.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X. und Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices, *Remote Sensing of Environment* **83**(1): 195–213.
- Huete, A., Justice, C. und Liu, H. (1994). Development of vegetation and soil indices for MODIS-EOS, *Remote Sensing of Environment* **49**(3): 224–234.
- Huete, A., Liu, H., Batchily, K. v. und Van Leeuwen, W. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS, *Remote Sensing of Environment* **59**(3): 440–451.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI), *Remote Sensing of Environment* **25**(3): 295–309.
- Hunt, G. R. (1977). Spectral signatures of particulate minerals in the visible and near infrared, *Geophysics* **42**(3): 501–513.
- Ishida, T., Itagaki, S., Sasaki, Y. und Ando, H. (2004). Application of wavelet transform for extracting edges of paddy fields from remotely sensed images, *International Journal of Remote Sensing* **25**(2): 347–357.
- Jackson, R., Pinter Jr, P., Reginato, R. und Idso, S. (1980). Hand-held radiometry: A set of notes developed for use at the Workshop of Hand-held radiometry, *ARM-W-19, U. S. Department of Agricultural, Science and Education Administration* S. 66.
- Jacquemoud, S. und Baret, F. (1990). PROSPECT: A model of leaf optical properties spectra, *Remote Sensing of Environment* **34**(2): 75–91.
- Jähne, B. (2012). *Digitale Bildverarbeitung*, SpringerLink : Bücher, Springer Berlin Heidelberg, S. 333-334.
- Ji, C. (1996). Delineating agricultural field boundaries from TM imagery using dyadic wavelet transforms, *ISPRS Journal of Photogrammetry and Remote Sensing* **51**(6): 268–283.
- Jiang, Z., Huete, A. R., Didan, K. und Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band, *Remote Sensing of Environment* **112**(10): 3833–3845.
- Justice, C. O., Vermote, E., Townshend, J. R., Defries, R., Roy, D. P., Hall, D. K., Salomonson, V. V., Privette, J. L., Riggs, G., Strahler, A. et al. (1998). The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research, *IEEE Transactions on Geoscience and Remote Sensing* **36**(4): 1228–1249.

- Kaufman, Y. J. und Tanre, D. (1992). Atmospherically resistant vegetation index (ARVI) for EOS-MODIS, *IEEE Transactions on Geoscience and Remote Sensing* **30**(2): 261–270.
- Kauth, R. J. und Thomas, G. (1976). The tasselled cap – a graphic description of the spectral-temporal development of agricultural crops as seen by Landsat, *LARS Symposia*, S. 159.
- Klisch, A., Borg, E. und Dech, S. (2001). Remote Sensing as an Important Source for Physical-Based Soil Erosion Modelling, *Multidisciplinary Approaches to Soil Conservation Strategies*, ZALF-Bericht Nr. 47, Münchenberg (Hrsg.: Helming, K.), S. 33–40.
- Koffka, K. (2013). *Principles of Gestalt psychology*, Vol. 44, Routledge.
- Köhler, C. H. (2016). Airborne Imaging Spectrometer HySpex, *Journal of Large-Scale Research Facilities JLSRF* **2**(A93): 1–6.
- Kokaly, R. F. und Clark, R. N. (1999). Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression, *Remote Sensing of Environment* **67**(3): 267–287.
- Kouchi, K. und Yamazaki, F. (2007). Characteristics of tsunami-affected areas in moderate-resolution satellite images, *IEEE Transactions on Geoscience and Remote Sensing* **45**(6): 1650–1657.
- Kumar, L., Schmidt, K., Dury, S. und Skidmore, A. (2002). Imaging spectrometry and vegetation science, *Imaging Spectrometry*, Springer, S. 111–155.
- Lelong, C. C., Pinet, P. C. und Poilvé, H. (1998). Hyperspectral imaging and stress mapping in agriculture: a case study on wheat in Beauce (France), *Remote Sensing of Environment* **66**(2): 179–191.
- Li, J. und Bioucas-Dias, J. M. (2008). Minimum volume simplex analysis: A fast algorithm to unmix hyperspectral data, *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*, Vol. 3, IEEE, S. III–250.
- Lillesand, T. und Kiefer, R. (1994). *Remote sensing and image interpretation*, Wiley & Sons, S. 18.
- Liu, H. Q. und Huete, A. (1995). A feedback based modification of the NDVI to minimize canopy background and atmospheric noise, *IEEE Transactions on Geoscience and Remote Sensing* **33**(2): 457–465.
- Lu, D. und Weng, Q. (2004). Spectral mixture analysis of the urban landscape in Indianapolis with Landsat ETM+ imagery, *Photogrammetric Engineering & Remote Sensing* **70**(9): 1053–1062.

- Luciano, J. d. O., Huete, A. R. und Batchily, K. (1998). Using mixture analysis for soil information extraction from an AVIRIS scene at the Walnut Gulch Experimental Watershed-Arizona, *Anais IX Simpósio Brasileiro de Sensoriamento Remoto* S. 1335–1344.
- Mather, P. und Koch, M. (2011). *Computer Processing of Remotely-Sensed Images: An Introduction*, Wiley.
- Matsuoka, M., Miura, H., Midorikawa, S. und Estrada, M. (2013). Extraction of urban information for seismic hazard and risk assessment in Lima, Peru using satellite imagery, *Journal of Disaster Research* **8**(2): 328–345.
- Miglani, A., Ray, S. S., Vashishta, D. und Parihar, J. S. (2011). Comparison of two data smoothing techniques for vegetation spectra derived from EO-1 Hyperion, *Journal of the Indian Society of Remote Sensing* **39**(4): 443–453.
- Monsi, M. und Saeki, T. (1953). Über den Lichtfaktor in den Pflanzengesellschaften und seine Bedeutung für die Stoffproduktion, *Japanese Journal of Botany* **14**: 22–52.
- Munzert, M. und Frahm, J. (2006). *Pflanzliche Erzeugung: Grundlagen des Acker- und Pflanzenbaus und der Guten fachlichen Praxis, Grundlagen der Verfahrenstechnik, Produktions- und Verfahrenstechnik für Kulturpflanzen, Dauergrünland, Sonderkulturen, Nachwachsende Rohstoffe, Ökologischer Landbau, Naturschutz und Landschaftspflege*, Die Landwirtschaft, BLV, S. 25-28 / 286-302 / 325-333.
- Myneni, R. und Asrar, G. (1994). Atmospheric effects and spectral vegetation indices, *Remote Sensing of Environment* **47**(3): 390–402.
- Nicodemus, F. E., Richmond, J. C., Hsia, J. J., Ginsberg, I. W. und Limperis, T. (1977). *Geometrical considerations and nomenclature for reflectance*, Vol. 160, US Department of Commerce, National Bureau of Standards, S. 3-6.
- Norsk Elektro Optikk (o. J.). Hypspec, Website. Online erhältlich unter <http://www.hypspec.no/index.php>; abgerufen am 28.02.2017.
- North, P. R. (2002). Estimation of fAPAR, LAI, and vegetation fractional cover from ATSR-2 imagery, *Remote Sensing of Environment* **80**(1): 114–121.
- Orfanidis, S. (2010). *Introduction to Signal Processing*, Prentice Hall International Editions, Prentice Hall, S. 427-463.
- Park, B. und Lu, R. (2015). *Hyperspectral imaging technology in food and agriculture*, Springer, S. 88-92.
- Pearson, R. L. und Miller, L. D. (1972). Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie, *Remote Sensing of Environment*, *VIII*, Vol. 1, S. 1355.

- Peñuelas, J., Gamon, J., Fredeen, A., Merino, J. und Field, C. (1994). Reflectance indices associated with physiological changes in nitrogen-and water-limited sunflower leaves, *Remote Sensing of Environment* **48**(2): 135–146.
- Pinty, B. und Verstraete, M. (1992). GEMI: a non-linear index to monitor global vegetation from satellites, *Vegetatio* **101**(1): 15–20.
- Price, J. C. (1992). Estimating vegetation amount from visible and near infrared reflectances, *Remote Sensing of Environment* **41**(1): 29–34.
- Price, J. C. und Bausch, W. C. (1995). Leaf area index estimation from visible and near-infrared reflectance data, *Remote Sensing of Environment* **52**(1): 55–65.
- Purevdorj, T., Tateishi, R., Ishiyama, T. und Honda, Y. (1998). Relationships between percent vegetation cover and vegetation indices, *International Journal of Remote Sensing* **19**(18): 3519–3535.
- Qi, J., Chehbouni, A., Huete, A., Kerr, Y. und Sorooshian, S. (1994). A modified soil adjusted vegetation index, *Remote Sensing of Environment* **48**(2): 119–126.
- Qi, J., Kerr, Y., Moran, M., Wertz, M., Huete, A., Sorooshian, S. und Bryant, R. (2000). Leaf area index estimates using remotely sensed data and BRDF models in a semiarid region, *Remote Sensing of Environment* **73**(1): 18–30.
- Richardson, A. J. und Wiegand, C. (1977). Distinguishing vegetation from soil background information. [by gray mapping of Landsat MSS data], *Photogrammetric Engineering and Remote Sensing* **43**: 1541–1552.
- Richter, R. und Schläpfer, D. (2016). Atmospheric/topographic correction for airborne imagery, *ATCOR-4 User Guide* S. 565–02.
- Roberts, D. A., Gardner, M., Church, R., Ustin, S., Scheer, G. und Green, R. (1998). Mapping chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models, *Remote Sensing of Environment* **65**(3): 267–279.
- Robila, S. A. (2004). An analysis of spectral metrics for hyperspectral image processing, *Geoscience and Remote Sensing Symposium, 2004. IGARSS'04. Proceedings. 2004 IEEE International*, Vol. 5, IEEE, S. 3233–3236.
- Rondeaux, G., Steven, M. und Baret, F. (1996). Optimization of soil-adjusted vegetation indices, *Remote Sensing of Environment* **55**(2): 95–107.
- Rouse Jr, J. (1974). Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation.
- Rouse Jr, J. W. (1972). Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation.

- Ruffin, C. und King, R. (1999). The analysis of hyperspectral data using Savitzky-Golay filtering—theoretical basis (Part 1), *Geoscience and Remote Sensing Symposium*, Vol. 28, Hamburg, Germany.
- Rydberg, A. und Borgefors, G. (2001). Integrated method for boundary delineation of agricultural fields in multispectral satellite images, *IEEE Transactions on Geoscience and Remote Sensing* **39**(11): 2514–2520.
- Savitzky, A. und Golay, M. J. (1964). Smoothing and differentiation of data by simplified least squares procedures, *Analytical Chemistry* **36**(8): 1627–1639.
- Schowengerdt, R. (2012). *Remote Sensing: Models and Methods for Image Processing*, Elsevier Science, S. 449.
- Schramm, M. (2010). *Unüberwachte lineare spektrale Entmischung mit Anwendungen für Baumdichteabschätzungen in semiariden Regionen Afrikas*, Fachrichtung Geodäsie und Geoinformatik der Leibniz Univ., S. 15-31.
- Schramm, M., Landmann, T., Lohmann, P. und Heipke, C. (2008). Ein neues Modell für eine spektrale Entmischung ohne genaue Endmemberspektren, *Photogrammetrie Fernerkundung Geoinformation* (5): 351–362.
- Settle, J. und Drake, N. (1993). Linear mixing and the estimation of ground cover proportions, *International Journal of Remote Sensing* **14**(6): 1159–1177.
- Somers, B., Asner, G. P., Tits, L. und Coppin, P. (2011). Endmember variability in spectral mixture analysis: A review, *Remote Sensing of Environment* **115**(7): 1603–1616.
- Stagakis, S., Markos, N., Sykioti, O. und Kyparissis, A. (2010). Monitoring canopy biophysical and biochemical parameters in ecosystem scale using satellite hyperspectral imagery: An application on a *Phlomis fruticosa* Mediterranean ecosystem using multi-angular CHRIS/PROBA observations, *Remote Sensing of Environment* **114**(5): 977–994.
- Stein, M. (1999). *Interpolation of Spatial Data: Some Theory for Kriging*, Springer Series in Statistics, Springer New York, S. 7-9.
- Stoner, E. R. und Baumgardner, M. (1981). Characteristic variations in reflectance of surface soils, *Soil Science Society of America Journal* **45**(6): 1161–1165.
- Strachan, I. B., Pattey, E. und Boisvert, J. B. (2002). Impact of nitrogen and environmental conditions on corn as detected by hyperspectral reflectance, *Remote Sensing of Environment* **80**(2): 213–224.

- Takeuchi, W. und Yasuoka, Y. (2005). Development of normalized vegetation, soil and water indices derived from satellite remote sensing data, *Journal of the Japan Society of Photogrammetry and Remote Sensing* **43**(6): 7–19.
- Tateishi, R., Rokhmatuloh, J. T. und Kobayashi, T. (2008). Global Percent Tree Cover.
- Thenkabail, P., Lyon, J. und Huete, A. (2012). *Hyperspectral Remote Sensing of Vegetation*, CRC Press, S. 19-23 / 76-77 / 187-288 / 309-327.
- Thenkabail, P. S., Smith, R. B. und De Pauw, E. (2000). Hyperspectral vegetation indices and their relationships with agricultural crop characteristics, *Remote Sensing of Environment* **71**(2): 158–182.
- Tian, J. und Chen, D.-M. (2007). Optimization in multi-scale segmentation of high-resolution satellite images for artificial feature recognition, *International Journal of Remote Sensing* **28**(20): 4625–4644.
- Tiwari, P. S., Pande, H., Kumar, M. und Dadhwal, V. K. (2009). Potential of IRS P-6 LISS IV for agriculture field boundary delineation, *Journal of Applied Remote Sensing* **3**(1): 033528–033528.
- Torre, M. und Radeva, P. (2000). Agricultural-field extraction on aerial images by region competition algorithm, *Pattern Recognition, 2000. Proceedings. 15th International Conference on*, Vol. 1, IEEE, S. 313–316.
- Tsai, F. und Philpot, W. (1998). Derivative analysis of hyperspectral data, *Remote Sensing of Environment* **66**(1): 41–51.
- Turker, M. und Kok, E. H. (2013). Field-based sub-boundary extraction from remote sensing imagery using perceptual grouping, *ISPRS Journal of Photogrammetry and Remote Sensing* **79**: 106–121.
- Turner, D. P., Cohen, W. B., Kennedy, R. E., Fassnacht, K. S. und Briggs, J. M. (1999). Relationships between leaf area index and Landsat TM spectral vegetation indices across three temperate zone sites, *Remote Sensing of Environment* **70**(1): 52–68.
- Ursani, A. A., Kpalma, K., Lelong, C. C. und Ronsin, J. (2012). Fusion of textural and spectral information for tree crop and other agricultural cover mapping with very-high resolution satellite images, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **5**(1): 225–235.
- Verhoef, W. (1984). Light scattering by leaf layers with application to canopy reflectance modeling: the SAIL model, *Remote Sensing of Environment* **16**(2): 125–141.
- Wackernagel, H. (2003). *Multivariate Geostatistics: An Introduction with Applications*, Springer Berlin Heidelberg, S. 79-88 / 47.

- Wang, D., Morton, D., Masek, J., Wu, A., Nagol, J., Xiong, X., Levy, R., Vermote, E. und Wolfe, R. (2012). Impact of sensor degradation on the MODIS NDVI time series, *Remote Sensing of Environment* **119**: 55–61.
- Wiegand, C., Gerbermann, A., Gallo, K., Blad, B. und Dusek, D. (1990). Multisite analyses of spectral-biophysical data for corn, *Remote Sensing of Environment* **33**(1): 1–16.
- Wiegand, C., Maas, S., Aase, J., Hatfield, J., Pinter, P. j., Jackson, R., Kanemasu, E. und Lapitan, R. (1992). Multisite analyses of spectral-biophysical data for wheat, *Remote Sensing of Environment* **42**(1): 1–21.
- Winter, M. E. (1999). N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data, *SPIE's International Symposium on Optical Science, Engineering, and Instrumentation*, International Society for Optics and Photonics, S. 266–275.
- Yang, W., Huang, D., Tan, B., Stroeve, J. C., Shabanov, N. V., Knyazikhin, Y., Nemani, R. R. und Myneni, R. B. (2006). Analysis of leaf area index and fraction of PAR absorbed by vegetation products from the terra MODIS sensor: 2000-2005, *IEEE Transactions on Geoscience and Remote Sensing* **44**(7): 1829–1842.
- Zare, A. und Ho, K. (2014). Endmember variability in hyperspectral analysis: Addressing spectral variability during spectral unmixing, *IEEE Signal Processing Magazine* **31**(1): 95–104.

A Spezifikation des HySpex-Sensorsystems

	VNIR-1600	SWIR-320m-e
Spectral Range	0.4–1.0 μm	1.0–2.5 μm
Spatial Pixels	1600	320
F-number	F 2.5	F 2.0
FOV across track	17°	13.5°
Pixel FOV across/along track	0.18 mrad / 0.36 mrad	0.75 mrad / 0.75 mrad
Spectral sampl.	3.7 nm	6 nm
Number of bands	160	256
Binning modes	2, 4, 8	-
Noise floor	40e	-
Peak SNR	> 200	-
Dynamic range	1 000	-
Digitization	12 bit	14 bit
Max frame rate	135 fps	100 fps
Sensor head wgt.	4.6 kg	7.5 kg
Sensor head dim. (lwh in cm)	31.5 x 8.4 x 13.8	36 x 14 x 15.2
Sensor head pwr. cons.	~ 6 W	~ 100 W
FPA cooling T	-	~ 195K

Tabelle 3: Spezifikation der HySpex-Sensoren *VNIR-1600* und *SWIR-320m-e* (Norsk Elektro Optikk o. J.).

B Log-Datei ATCOR-4

```

##### ATCOR-4 LOG FILE #####
# ATCOR 4, Version 7.0, Build 109
# Release Date: Mon Apr 4 21:43:45 2016
#
# (c) DLR; ATCOR and core modules
# authored by Rudolf Richter
#
# Process Started on Fri Jun 3 09:43:01 2016
#
2016-06-03T09:43:01 atcor4f_batch: # *** ATCOR-4f (flat terrain) (Version 7.1.0 Beta 2016) ***
2016-06-03T09:43:02 atcor4f_batch: # Size of Input Image = 721 x 5592 x 416
# (columns x lines x bands)
2016-06-03T09:43:03 atcor4f_batch: # -----
2016-06-03T09:43:03 atcor4f_batch: # Start of ATCOR4-F calculation: Fri Jun 3 09:43:03 2016
2016-06-03T09:43:12 module_const_atm_4f: # Water vapor retrieval running ...
2016-06-03T09:43:39 module_const_atm_4f: # Surface reflectance retrieval ...
2016-06-03T09:43:39 consta_region_4f: # Start of band processing: Fri Jun 3 09:43:39 2016
2016-06-03T09:50:14 consta_region_4f: # Spectral band processing finished: Fri Jun 3 09:50:14 2016
#
# Processing time = 7 min. 10 sec
#
# Relative processing time per major module (%)
# -----
# Masking/Segmentation (cloud, haze, reference pixels) : 1.2
# Visibility iterations : 0.8
# Water vapor map : 6.3
# Scene processing (band loop) : 91.6
# -----
# Total : 100.0
#
# Status : successful
#
# Scale factor reflectance = 100.0
#
# Processing options :
# Variable Visibility (aerosol optical thickness) ..... No
# Variable Water Vapor ..... Yes
# Haze or Sun Glint Removal ..... No
# Shadow Removal (Clouds/Buildings) ..... No
# Value Added Products ..... No
# Cirrus Removal ..... No
#
# Aerosol Type ..... Rural
#
#
I01 ATCOR4f (flat terrain)
I01
I01 Scene acquisition date (dd/mm/year) : 11/07/2014
I01 Solar zenith angle [degree] = 32.5
I01 Solar azimuth angle [degree] = 194.3
I01 Atmosphere : h02595_wv20_rura
I01 Aerosol type : Rural
I01
I01 Constant scene visibility
I01 Input visibility [km] = 25.0
I01 Final visibility [km] = 100.0
I01 Haze removal : no
I02 Atmosphere = h02595_wv20_rura.atmi
I02
#
#
# Scan angle map = /mnt/data1/data_archive/imaging/2014/140711_Demmin/Line02.311934.1/
# DEMMIN32014-7-11_02_VNIR_FULLCUBE_FOVx2_rad_geo_sca.bsq
#
# Sensor = hyspex14_fullcube_recal_2
# Pixel size [m] = 4.00
#
# Atmosphere = h02595_wv20_rura.atmi
#
# Calibration file = /mnt/data1/data_archive/imaging/2014/140711_Demmin/Line02.311934.1/
# DEMMIN32014-7-11_02_VNIR_FULLCUBE_FOVx2_rad_geo_stack_mask.cal

```

```

#
# intpol760      (interpolation of bands in 760 nm O2 region, 0=no, 1=yes) = 1
# intpol725_825 (interpol. of bands in 725/ 825 nm wv region 0=no, 1=yes) = 0
# intpol940_1130 (940/1130 nm: 0=no, 1=nonlinear, 2=linear interpolation) = 1
# intpol1400    (1400/1900 nm: 0=no, 1=nonlinear, 2=linear interpolation) = 1
#
# Adapt path radiance for blue/green band(s) (0=no, 1=yes) = 1
#
# iwv_watermask (water vapor for water pixels) = 1
#               0=water vapor also calculated over water
#               1=average of land wv used for water pixels
#               2=line average of land pixels used for water pixels
# Smooth water vapor map, box size [meter] = 50.0 (13*13 pixels)
# see: /users/holzwardt/.idl/rese/atcor4/preference_parameters.dat
#
# iwv_model (1=water vapor without regression, 2=with band regression) = 2
# Measurement channel(s) used for water vapor retrieval
#   channel      187      188      189      190      191
#   (micron)     1.1237  1.1297  1.1357  1.1416  1.1476
# Ref.=window channel(s) used for water vapor retrieval
#   channel      181      207
#   (micron)     1.0877  1.2436
# Scene-average water vapor column (land pixels) [cm] = 1.29
#
# Start/Stop for interpolation in 940 nm region: 885.0 to 1000.0 nm
# Start/Stop for interpolation in 1130 nm region: 1088.7 to 1195.0 nm
# Start/Stop for interpolation in 1400 nm region: 1300.0 to 1490.0 nm
# Start/Stop for interpolation in 1900 nm region: 1780.0 to 2025.0 nm
#
# cloud reflectance threshold (blue-green region) = 25.0%
# water reflectance threshold (NIR region) = 5.0%
# water reflectance threshold (1600 nm region) = 3.0%
# maximum surface reflectance, cut-off limit = 150%
# ihcw (0=no hcw, 1="hcw" file, 2=hcw + quality) = 1
# Internal pre-classification: /mnt/data1/data_archive/imaging/2014/140711_Demmin/
#   Line02.311934.1/DEMMIN32014-7-11_02_VNIR_FULLLCUBE_FOVx2_rad_geo_stack_mask_out_hcw.bsq
#
# rel. saturation DN(sat) >= b*65535 with b = 1.00
# see: /users/holzwardt/.idl/rese/atcor4/preference_parameters.dat
#
# Water mask : uses NIR / SWIR reflectance thresholds from preference file
#
# Data acquisition (day/month/year) = 11/07/2014
#
# Flight altitude [km asl] = 2.595
# Average ground elevation [km] = 0.000
# Flight heading [degree] = 7.0
# Solar zenith angle [degree] = 32.5
# Solar azimuth angle [degree] = 194.3
#
# Average Visibility [km] = 100.0
#
# Range of adjacency effect [km] = 0.100
# Number of adjacency zones = 1
I03
I03 Cloud cover (%) = 0.0
    (includes saturated pixels in the blue-to-green spectral region)
I03 Cloud shadow (%) = 1.0
I03 Water pixels (%) = 1.2
I03 Snow/ice (cloud) (%) = 0.0
I03
W19
W19 Warning: The following channels have more than 1% of scene pixels with reflectance
    less/equal zero
W19 Possible reasons :
W19 Visibility too low, wrong aerosol type, cloud shadow regions, calibration problem
W19 Channel [nm] Percentage of negative/zero reflectance pixels
W19 1 415.7 21.3 ----> reset to 0.00% reflectance
W19 2 419.3 21.1 ----> reset to 0.00% reflectance
W19 3 422.9 21.1 ----> reset to 0.00% reflectance
W19 4 426.5 21.0 ----> reset to 0.00% reflectance
W19 5 430.1 21.0 ----> reset to 0.00% reflectance
W19 6 433.7 21.1 ----> reset to 0.00% reflectance
W19 7 437.3 21.0 ----> reset to 0.00% reflectance
W19 8 440.9 21.0 ----> reset to 0.00% reflectance
W19 9 444.5 21.0 ----> reset to 0.00% reflectance
W19 10 448.1 21.0 ----> reset to 0.00% reflectance

```

```

W19      11      451.7      21.0      ----> reset to 0.00% reflectance
W19      12      455.3      21.0      ----> reset to 0.00% reflectance
W19      13      458.9      21.0      ----> reset to 0.00% reflectance
W19      14      462.5      21.0      ----> reset to 0.00% reflectance
W19      15      466.1      21.0      ----> reset to 0.00% reflectance
W19      16      469.7      21.0      ----> reset to 0.00% reflectance
W19      17      473.3      21.0      ----> reset to 0.00% reflectance
W19      18      476.9      21.0      ----> reset to 0.00% reflectance
W19      19      480.5      21.0      ----> reset to 0.00% reflectance
W19      20      484.1      21.0      ----> reset to 0.00% reflectance
W19      21      487.7      21.0      ----> reset to 0.00% reflectance
W19      22      491.3      21.0      ----> reset to 0.00% reflectance
W19      23      494.9      21.0      ----> reset to 0.00% reflectance
W19      24      498.5      21.0      ----> reset to 0.00% reflectance
W19      25      502.1      21.0      ----> reset to 0.00% reflectance
W19      26      505.7      21.0      ----> reset to 0.00% reflectance
W19      27      509.3      21.0      ----> reset to 0.00% reflectance
W19      28      512.9      21.0      ----> reset to 0.00% reflectance
W19      29      516.5      21.0      ----> reset to 0.00% reflectance
W19      30      520.1      21.0      ----> reset to 0.00% reflectance
W19 --- Only the first 30 channels are monitored ---
W19
I19
I19 Info :   The following channels have more than 1% of scene pixels with reflectance
             less/equal zero
I19 Possible reasons :
I19 Visibility too low, wrong aerosol type, cloud shadow regions, calibration problem
I19      Channel      [nm]      Percentage of negative/zero reflectance pixels
I19          1      415.7      21.3      ----> reset to 0.00% reflectance
I19          2      419.3      21.1      ----> reset to 0.00% reflectance
I19          3      422.9      21.1      ----> reset to 0.00% reflectance
I19          4      426.5      21.0      ----> reset to 0.00% reflectance
I19          5      430.1      21.0      ----> reset to 0.00% reflectance
I19          6      433.7      21.1      ----> reset to 0.00% reflectance
I19          7      437.3      21.0      ----> reset to 0.00% reflectance
I19          8      440.9      21.0      ----> reset to 0.00% reflectance
I19          9      444.5      21.0      ----> reset to 0.00% reflectance
I19         10      448.1      21.0      ----> reset to 0.00% reflectance
I19         11      451.7      21.0      ----> reset to 0.00% reflectance
I19         12      455.3      21.0      ----> reset to 0.00% reflectance
I19         13      458.9      21.0      ----> reset to 0.00% reflectance
I19         14      462.5      21.0      ----> reset to 0.00% reflectance
I19         15      466.1      21.0      ----> reset to 0.00% reflectance
I19         16      469.7      21.0      ----> reset to 0.00% reflectance
I19         17      473.3      21.0      ----> reset to 0.00% reflectance
I19         18      476.9      21.0      ----> reset to 0.00% reflectance
I19         19      480.5      21.0      ----> reset to 0.00% reflectance
I19         20      484.1      21.0      ----> reset to 0.00% reflectance
I19         21      487.7      21.0      ----> reset to 0.00% reflectance
I19         22      491.3      21.0      ----> reset to 0.00% reflectance
I19         23      494.9      21.0      ----> reset to 0.00% reflectance
I19         24      498.5      21.0      ----> reset to 0.00% reflectance
I19         25      502.1      21.0      ----> reset to 0.00% reflectance
I19         26      505.7      21.0      ----> reset to 0.00% reflectance
I19         27      509.3      21.0      ----> reset to 0.00% reflectance
I19         28      512.9      21.0      ----> reset to 0.00% reflectance
I19         29      516.5      21.0      ----> reset to 0.00% reflectance
I19         30      520.1      21.0      ----> reset to 0.00% reflectance
I19 --- Only the first 30 channels are monitored ---
I19
#
#
2016-06-03T09:50:14      atcor4f_batch: #      Output = /mnt/data1/
                        data_archive/imaging/2014/140711.Demmin/Line02.311934.1/
                        DEMMIN32014-7-11_02_VNIR_FULLLCUBE_FOVx2_rad_geo_stack_mask_atm.bsq
#

```

C Ergebnisse lokaler Selektionsfilter im Vergleich

(a) Filter *A*(b) Filter *B*(c) Filter *C*

Abbildung 58: Ergebnisse der lokalen Selektionsfilter für die NDVI-Auswertung mit einer Filtergröße von $N = 3$.


(a) Filter *A*(b) Filter *B*(c) Filter *C*

Abbildung 59: Ergebnisse der lokalen Selektionsfilter für die NDSI-Auswertung mit einer Filtergröße von $N = 3$.

D Ergebnisse zur Erzeugung des binären Kantenbilds

Schlag 1




Abbildung 60: Ergebnisse der Teilschritte zur Erzeugung des binären Kantenbilds für Schlag 1.

Schlag 2




Abbildung 61: Ergebnisse der Teilschritte zur Erzeugung des binären Kantenbilds für Schlag 2.


Schlag 3

Abbildung 62: Ergebnisse der Teilschritte zur Erzeugung des binären Kantenbilds für Schlag 3.

E Ergebnisse der Laufzeitmessung

Prozess- bzw. Teilschritt	Laufzeit [s]					
	Schlag 1 (35882 Pixel)		Schlag 2 (51678 Pixel)		Schlag 3 (21462 Pixel)	
Vorverarbeitung	20.60		30.57		11.33	
Spektrale Glättung	20.51		30.44		11.27	
Datenreduktion	0.10		0.13		0.06	
Selektion der Fahrgassen	1.12		1.37		0.87	
Erzeugung eines binären Kantenbilds	0.56		0.79		0.36	
Detektion der gesuchten Strukturen	0.56		0.59		0.52	
Spektrale Entmischung der Fahrgassenpixel	786.84 ¹	801.94 ²	1426.26 ¹	1456.29 ²	442.37 ¹	453.52 ²
Abschätzung der Abundanzen	785.59		1424.22		441.37	
Ermittlung des Bestandsreferenzsignals	1.12		1.80		0.88	
Ableitung des Bodensignals	0.14 ¹	15.23 ²	0.24 ¹	30.27 ²	0.12 ¹	11.27 ²
Gesamtlaufzeit	808.57¹	823.66²	1458.20¹	1488.23²	454.58¹	465.72²

Tabelle 4: Mittlere Laufzeiten der praktisch umgesetzten Prozess- und Teilschritte am Beispiel der untersuchten Schläge mit Differenzierung nach Optimierungsansatz 1 und 2. Diese Angaben sind die Ergebnisse einer Laufzeitmessung unter Verwendung eines Standard-PCs (Windows 10 64-bit) mit 8 GB Arbeitsspeicher, DDR4 PC4 17000 @ 2133 MHz und einem Intel(R) Core(TM) i5-6200U CPU @ 2 × 2.30 - 2.80 GHz Prozessor. Die Messungen wurden drei Mal wiederholt und anschließend gemittelt.

F Inhaltsverzeichnis der beiliegenden CD

CD-Rom

- ↳ Verzeichnis: Masterarbeit
 - ↳ Masterarbeit als PDF
- ↳ Verzeichnis: MATLAB
 - ↳ Verzeichnis: data
 - ↳ Hyperspektraldaten der drei segmentierten Schläge
 - ↳ Verzeichnis: moduls
 - ↳ Verzeichnis: loadData
 - ↳ Methoden zum Einlesen der Daten
 - ↳ Verzeichnis: preprocessing
 - ↳ Methoden zur Vorverarbeitung
 - ↳ Verzeichnis: trackDetection
 - ↳ Methoden zur Selektion der Fahrgassen
 - ↳ Verzeichnis: trackUnmixing
 - ↳ Methoden zur spektralen Entmischung der Fahrgassenpixel
- ↳ Zentrales MATLAB-Skript zur Ausführung der Prozesskette

Selbstständigkeitserklärung

Hiermit erkläre ich, dass ich die vorliegende Masterarbeit selbstständig und nur unter Verwendung der angegebenen Quellen und Hilfsmittel angefertigt habe. Diese Arbeit lag in gleicher oder ähnlicher Weise noch keiner Prüfungsbehörde vor und wurde bisher noch nicht veröffentlicht.

Ort, Datum

Unterschrift