

Aus der Professur für Geodäsie und Geoinformatik
der Agrar- und Umweltwissenschaftlichen Fakultät

**Analyse der Vegetation und Ableitung von
Pflanzenparametern in Feuchtgebieten aus multisensoralen
Fernerkundungsdaten unbemannter Flugsysteme**

Dissertation

zur Erlangung des akademischen Grades
Doktor der Ingenieurwissenschaften (Dr.-Ing.)

an der Agrar- und Umweltwissenschaftlichen Fakultät
der Universität Rostock

vorgelegt von Diplom-Geograph Florian Beyer
Rostock

Rostock, den 1. November 2021

Gutachter:

Prof. Ralf Bill (Erstgutachter), Universität Rostock
Agrar- und Umweltwissenschaftliche Fakultät
Geodäsie und Geoinformatik

Prof. Stephan Glatzel, Universität Wien
Fakultät für Geowissenschaften, Geographie und Astronomie
Institut für Geographie und Regionalforschung

Prof. Georg Bareth, Universität Köln
Mathematisch-Naturwissenschaftliche Fakultät
Geographisches Institut

Dr. Gerald Jurasinski, Universität Rostock
Agrar- und Umweltwissenschaftliche Fakultät
Landschaftsökologie und Standortkunde

Jahr der Einreichung: 2020

Jahr der Verteidigung: 2021

Danksagung

Mein fachlicher Dank gilt ...

Prof. Dr.-Ing. Ralf Bill, der mir die Möglichkeit gegeben hat, in seiner interdisziplinären Arbeitsgruppe und im gesellschaftsrelevanten Forschungsprojekt WETSCAPES arbeiten zu dürfen. Ich bedanke mich für das stets entgegengebrachte Vertrauen und für seine konstruktive Kritik zu meiner Arbeit.

Dr. Görres Grenzdörffer, von dem ich so viel neue Aspekte über meinen Beruf und meine Leidenschaft, der Fernerkundung, gelernt habe. Seine Begeisterung für alles, was mit Drohnen und Photogrammetrie zu tun hat, hat auch mich stets mitgerissen. Ohne seine Unterstützung wäre die vorliegende Arbeit nicht möglich gewesen.

den Gutachtern meiner Arbeit. Dr. rer. nat. Gerald Jurasinski war, neben der Begutachtung dieser Arbeit, auch Integrator des Projektes WETSCAPES und hatte stets ein offenes Ohr für fachliche Fragen. Mein Dank gilt auch den externen Gutachtern Prof. Dr. Georg Bareth und Prof. Dr. sc. agr. Stephan Glatzel.

Martin Kanning, der nicht nur ein Kollege sondern auch ein sehr guter Freund ist. Ich bedanke mich vor allem für seine ehrliche (oft harte) aber immer konstruktive Kritik. Ich genieße immer wieder die Mischung unserer privaten und beruflichen Gespräche.

Dr.-Ing. Nils Koldrack, Matthias Naumann & Dr.-Ing. Ferdinand Vettermann für die schönen Jahre in einem angenehmen Kollegium und für deren Unterstützung bei der Anfertigung dieser Arbeit. Besonders werde ich ihre Unterstützung am *White Board* vermissen.

allen Kollegen aus dem Projekt WETSCAPES. Die Interdisziplinarität des großen Verbundprojektes war beeindruckend und ich bin glücklich darüber, dass ich die Relevanz der Wiedervernässung von Mooren in unseren oft sehr intensiven Kolloquien so facettenreich kennengelernt durfte.

allen Kollegen der GG. Besonders möchte ich hier Enno und Andy hervorheben, die mir stets bei allen (teils nervigen) Anfragen weitergeholfen haben.

Mein privater Dank gilt ...

Lisa-Marie Petereck ♡. Es gibt nicht genug Worte, um meiner Dankbarkeit im vollen Maß Ausdruck zu verleihen! Vielen Dank, dass du mir stets und besonders in den letzten Monaten so den Rücken freigehalten hast. Danke das du unseren süßen Spatz geboren hast und danke für die schöne dissertationsfreie Zeit, die wir zukünftig haben werden.

Monika und Arno Beyer. Meine Eltern haben das alles möglich gemacht, durch ihre mir entgegengebrachte Liebe und stetige Unterstützung in allen Lebenslagen.

Zusammenfassung

Feuchtgebiete haben, aufgrund ihrer ökologischen Funktionen, eine herausragende Bedeutung für den Klima- und Hochwasserschutz.

Moore bilden den größten terrestrischen Kohlenstoff-Speicher der Erde und üben erhebliche Rückkopplungseffekte auf das Klimasystem aus. Unter den massiven anthropogenen Störungen hat sich das globale Moorbiom von einer Netto-Senke zu einer Quelle von Treibhausgasen verschoben. Die Wiedervernässung ist eine gängige Maßnahme, die Moorökosysteme wiederherzustellen. Um den Erfolg der Wiedervernässung zu überprüfen ist daher ein kontinuierliches Monitoring notwendig.

Marschen erfüllen eine Vielzahl an Funktionen, darunter Küstenschutz, Sturmflutabmilderung, Sedimentrückhaltung, Erhaltung der Wasserqualität sowie Kohlenstoffsequestrierung. Gegenüber dem technischen Uferschutz ermöglicht dieses Ökosystem eine bessere Anpassung an den Meeresspiegelanstieg. Die anthropogene Landnutzung und der Anstieg des Meeresspiegels sind die größten Bedrohungen für diese Ökosysteme. Um deren Ökosystemleistung zu erheben und deren Entwicklung zeitlich zu verfolgen ist ein flächenhaftes Monitoring notwendig.

Die vorliegende Arbeit untersucht das Potential von multisensoralen Drohnen-daten, bestehend aus RGB-, Multispektral- und Thermal-daten und daraus generierten weiteren Produkten. Dafür wurde die Vegetationszusammensetzung in drei wiedervernässten Niedermooren mit einem *Random Forest*-Klassifikator erfasst und ökosystem-relevante Pflanzenparameter in zwei tide-beeinflussten Flussmarschen mithilfe der *Partial Least-Squares Regression* abgeleitet. Dabei hat die Arbeit sowohl einen ökologisch-anwendungsorientierten als auch einen fernerkundlich-methodischen Fokus.

Die Klassifikationen der komplexen Vegetationsgesellschaften ergaben durchgehend sehr präzise Genauigkeiten zwischen 88,3 und 97,5 %. Für die Flussmarschen wurden die wichtigen Parameter Geländehöhe, Pflanzenhöhe, Wassergehalt der Pflanzenbestände und der photosynthetisch aktiven Strahlung direkt (r^2 : 0,7–0,9), sowie Stängeldurchmesser und Trockenmasse indirekt (r^2 : 0,5–0,8) über eine sekundäre lineare Regression abgeleitet.

Der zweite Fokus der Arbeit lag auf der Bewertung der Relevanz der einzelnen Eingangsvariablen der Sensortypen und deren abgeleitete Produkte. Als herausragender Mehrwert für die durchgeführten Analysen hat sich das Digitale Oberflächenmodell (DOM) herausgestellt, welches aufgrund des flachen Charakters der Untersuchungsgebiete als Pflanzenhöhenmodell interpretiert werden kann. Dieser Datensatz war in allen Analysen der wichtigste Einzeldatensatz. Weitere wichtige Datensätze waren Texturindizes, die Infrarotkanäle sowie spektrale Indizes, an denen der Infrarotbereich beteiligt ist. Einer der zentralen Erkenntnisse der Arbeit ist, dass eine Fusion aus DOM, Textur und Infrarotinformation einen wertvollen Beitrag zum präzisen Monitoring dieser teilweise schwer zugänglichen, sensiblen und klimarelevanten Ökosysteme erlaubt.

Abstract

Wetlands are of outstanding importance due to their ecological functions, for instance in climate and flood protection.

Peatlands constitute the largest terrestrial carbon reservoir on earth and exert considerable feedback effects on the climate system. Under the massive anthropogenic disturbances, the global peatland biome has shifted from a net sink to a source of greenhouse gases. Rewetting is a common measure to restore the peatland ecosystems. To verify the success of rewetting, continuous monitoring is therefore required.

Marshes fulfill a variety of functions, including coastal protection, storm surge mitigation, sediment retention, water quality maintenance and carbon sequestration. Compared to technical shore protection, this ecosystem enables a better adaptation to sea level rise. Anthropogenic land use and sea-level rise are the greatest threats to these ecosystems. To assess their ecosystem services and to follow their development over time, extensive monitoring is necessary.

The present thesis investigates the potential of multisensoral drone data, consisting of RGB, multispectral and thermal data and other data types generated from these data. For this purpose the vegetation composition of three rewetted fens was recorded with a *Random Forest* classifier and ecosystem relevant parameters were derived in two tide-influenced river marshes with the help of *Partial Least-Squares Regression*. The study has a focus on both ecological applications and remote sensing methods.

The classifications of the complex vegetation communities consistently yielded very precise accuracies between 88.3 and 97.5 %. For the river marshes the important parameters ground elevation, plant height, water content of plant stands and photosynthetically active radiation were derived directly (r^2 : 0.7–0.9), and stem diameter and dry matter indirectly (r^2 : 0.5–0.8) using a secondary linear regression.

The second focus of the work was to evaluate the importance of the individual input variables of the sensors and their derived products. The Digital Surface Model (DSM), which can be interpreted as a plant height model due to the flat character of the study areas, proved to be an outstanding added value for the conducted analyses. This data set was the most important single data set in all analyses. Further important data sets were texture indices, the infrared bands and spectral indices in which the infrared range is involved. One of the central findings of the work is that a fusion of DSM, texture and infrared information allows a valuable contribution to the precise monitoring of these partly difficult to access, sensitive and climate-relevant ecosystems.

Inhaltsverzeichnis

| | | |
|----------|------------------------------------------------------------|-----------|
| 1 | Einführung | 1 |
| 1.1 | Motivation — Feuchtgebiete und Fernerkundung | 1 |
| 1.1.1 | Feuchtgebiete | 1 |
| | Moore | 2 |
| | Marschen | 3 |
| 1.1.2 | Fernerkundung | 4 |
| 1.2 | Ziele und Aufbau der Arbeit | 7 |
| 2 | Stand der Forschung | 9 |
| 2.1 | Moore und Fernerkundung | 9 |
| 2.2 | Marschland und Fernerkundung | 10 |
| 3 | Grundlagen, Projekte, Gebiete | 17 |
| 3.1 | Niedermoore, Entwässerung und Wiedervernässung | 17 |
| 3.1.1 | Projekt WETSCAPES | 20 |
| 3.1.2 | Untersuchungsgebiete der Niedermoore | 20 |
| | Durchströmungsmoor Tribsees | 21 |
| | Küstenüberflutungsmoor Karrendorfer Wiesen | 23 |
| | Versumpfungsmoor Hütelmoor | 24 |
| 3.2 | Flussmarschen | 28 |
| 3.2.1 | Projekt TIBASS | 31 |
| 3.2.2 | Untersuchungsgebiete der Tideelbe | 31 |
| | Balje | 32 |
| | Hollerwettern | 33 |
| 4 | Instrumentierung und Datengrundlage | 37 |
| 4.1 | UAS und on-board-Sensoren | 37 |
| 4.1.1 | RGB-Kamera | 38 |
| 4.1.2 | Multispektralsensor | 40 |
| 4.1.3 | Thermalsensor | 41 |
| 4.2 | Aufnahme der UAS-Bilddaten | 42 |
| 4.3 | Vegetationskartierungen und Probennahme | 43 |
| 4.3.1 | Vegetationsaufnahmen für Tribsees und Karrendorf | 43 |
| 4.3.2 | Vegetationsaufnahmen für das Hütelmoor | 46 |
| 4.3.3 | Vegetationsaufnahmen für Balje und Hollerwettern | 48 |
| 5 | Methoden | 51 |
| 5.1 | Vorprozessierung | 51 |
| 5.1.1 | Postprozessierung der GNSS-Daten | 51 |

| | | |
|----------|-----------------------------------------------------------------------------------------------|-----------|
| 5.1.2 | Generierung der Orthomosaike | 53 |
| 5.1.3 | Co-Registrierung der Bildmosaike | 54 |
| 5.1.4 | Indizes | 55 |
| 5.1.5 | Konvertierung, Zuschnitt und Stapelung | 56 |
| 5.2 | Klassifikationsverfahren | 57 |
| 5.2.1 | Klassifikationsalgorithmus — Random Forest | 58 |
| | Entscheidungsbäume | 59 |
| | Entropie | 59 |
| | Gini Index | 61 |
| | Random Forest aus Entscheidungsbäumen | 61 |
| | Bagging | 62 |
| | Mehrheitsentscheidung | 62 |
| | Messung des Vorhersagefehlers | 62 |
| 5.2.2 | Unabhängige Validierung | 62 |
| 5.2.3 | Kanalrelevanz | 64 |
| 5.3 | Regressionsverfahren | 64 |
| 5.3.1 | Regressionsalgorithmus — Partial Least-Squares | 64 |
| | Funktionsweise der Partial Least-Squares Regression | 66 |
| | Latente Variablen | 67 |
| | Innere Beziehung | 67 |
| | Qualitätsmaße der Regression | 68 |
| | Kreuzvalidierung | 69 |
| | Kanalrelevanz | 70 |
| 6 | Ergebnisse und Diskussion | 71 |
| 6.1 | Ergebnisse der Vorprozessierung | 71 |
| 6.2 | Klassifikation von Moorvegetation | 74 |
| 6.2.1 | Klassifikation der Vegetationsbestände in Tribsees und Karrendorf | 74 |
| | Parametertuning | 74 |
| | Training | 75 |
| | Vorhersage / Klassifikation | 77 |
| | Validierung | 80 |
| | Kanalrelevanz | 84 |
| 6.2.2 | Klassifikation der Vegetationsbestände im Hütelmoor zur Untersuchung der Dürre 2018 | 90 |
| | Training | 90 |
| | Klassifikation und Analyse der Dürreauswirkungen | 91 |
| | Validierung | 93 |
| | Kanalrelevanz | 93 |
| 6.2.3 | Erweiterung des multisensoralen Datensatzes | 97 |
| | Ergebnisse des erweiterten multisensoralen Datensatzes | 99 |
| | Vorselektion wichtiger Indexcluster | 103 |
| | Erweiterter Datensatz für Tribsees und Karrendorf | 108 |
| 6.3 | Ableitung von Pflanzenparametern | 109 |
| 6.3.1 | Statistische Voruntersuchungen zu den Geländemessungen | 109 |

| | | |
|----------|---------------------------------------------------------------------------------|------------|
| 6.3.2 | Partial Least-Squares Regression zur Ableitung von Pflanzenparametern | 114 |
| | Zusammensetzung der multisensoralen Datensätze | 114 |
| | Ergebnisse der Partial Least-Squares Regression | 116 |
| | Relevanzen der Kanäle | 132 |
| 6.3.3 | Ableitung weiterer Karten mittels linearer Regression | 135 |
| 6.4 | Synoptische Auswertung der Kanalrelevanzen | 148 |
| 7 | Zusammenfassung und Ausblick | 153 |
| 7.1 | Potential multisensoraler UAS-Daten | 153 |
| 7.1.1 | Klassifikation von Mooren | 153 |
| 7.1.2 | Regression in Marschen | 155 |
| 7.2 | Kanal- und Sensorrelevanz der multisensoralen UAS-Daten | 157 |
| 7.3 | Synergieeffekte, Erkenntnisse und Ausblicke | 159 |
| | Literatur | 161 |
| | Abbildungsverzeichnis | 183 |
| | Tabellenverzeichnis | 191 |
| A | Anhang | 195 |
| A.1 | Pflanzennamen | 195 |
| A.2 | Kartierungsdaten vom Hütelmoor | 197 |
| A.3 | Photogrammetrischer Prozess | 199 |
| A.4 | Software Maptor | 203 |
| A.5 | Python | 205 |
| A.6 | Orthomosaike | 207 |
| A.7 | Mittelwertspektren | 213 |
| A.8 | Indizes für die Klassifikation vom Hütelmoor | 217 |
| A.9 | Erweit. multisens. Datens. für Tribsees und Karrendorf | 219 |
| A.10 | Statistik für Balje und Hollerwettern | 229 |
| A.11 | Erweit. multisens. Datens. für Balje u. Hollerwettern | 233 |
| A.12 | Struktur der digital verfügbaren Daten | 243 |

Abkürzungsverzeichnis

Fremdsprachige Wörter werden in der Arbeit *kursiv* geschrieben.

| | |
|----------------|--------------------------------------------------------------------|
| BBA | Bündelblockausgleichung |
| BEIDOU | Chinesisches Satellitennavigationssystem |
| BfG | Bundesanstalt für Gewässerkunde |
| CART | <i>Classification And Regression Trees</i> |
| DGM | Digitales Geländemodell |
| DNG | <i>Digital Negative</i> |
| DOM | Digitales Oberflächenmodell |
| DOP | Digitales Orthophoto (-mosaik) |
| DT | <i>Decision Trees</i> |
| FOV | <i>Field Of View</i> |
| GALILEO | Europäisches globales Satellitennavigations- und Zeitgebungssystem |
| GCP | <i>Ground Control Points</i> |
| GI | Gini-Index |
| GIS | Geo-Informationssystem |
| GLCM | <i>Gray Level Co-occurrence Matrix</i> |
| GLONASS | <i>Globalnaja Nawigazionnaja Sputnikowaja Sistema</i> |
| GNSS | <i>Global Navigation Satellite System</i> |
| GPS | <i>Global Positioning System</i> |
| GrI | <i>Greenness Index</i> |
| GSD | <i>Ground Sampling Distance</i> |
| IMU | <i>Inertial Measurement Unit</i> |
| IQB | Interquartilbereich |
| LAI | <i>Leaf Area Index</i> |
| LOOCV | <i>Leave-One-Out Cross Validation</i> |
| MAE | <i>Mean Absolute Error</i> |
| MIM | <i>Multi-ray Image Matching</i> |
| ML | <i>Machine Learning</i> |
| MS | Multispektral |
| MSE | <i>Mean Squared Error</i> |
| MThw | Mittleres Tidehochwasser |

| | |
|--------------|----------------------------------------------------------|
| MV | Mecklenburg-Vorpommern |
| MW | Mittelwert |
| NIR | Nahes Infrarot |
| NDVI | <i>Normalized Difference Vegetation Index</i> |
| OAA | <i>Overall Accuracy</i> |
| OOB | <i>Out-of-Bag-Error</i> |
| PA | <i>Producer's Accuracy</i> |
| PLSR | <i>Partial Least-Squares Regression</i> |
| PPK | <i>Post Processing Kinematic</i> |
| RE | <i>Red Edge</i> |
| RF | <i>Random Forest</i> |
| RGB | Rot-Grün-Blau |
| RINEX | <i>Receiver Independent Exchange Format</i> |
| RMSE | <i>Root-Mean-Square Error</i> |
| RPD | <i>Ratio Of Performance To Deviation</i> |
| RTK | <i>Real Time Kinematic</i> |
| SAPOS | Satellitenpositionierungsdienst |
| SIFT | <i>Scale Invariant Feature Transform</i> |
| STD | Standardabweichung |
| SURF | <i>Speed-up Robust Features</i> |
| THG | Treibhausgas |
| UA | <i>User's Accuracy</i> |
| UAS | <i>Unmanned Aerial System</i> |
| UAV | <i>Unmanned Aerial Vehicle</i> |
| UPGMA | <i>Unweighted Pair Group Method With Arithmetic Mean</i> |

1 Einführung

1.1 Motivation — Feuchtgebiete und Fernerkundung

1.1.1 Feuchtgebiete — Moore und Marschen

Feuchtgebiete sind Biotope mit besonderer Bedeutung hinsichtlich ihrer ökologischen Eigenschaften, des Klima- und des Hochwasserschutzes. Schon am 02. Februar 1971 wurde, angestoßen von der UNESCO, die RAMSAR-Konvention zum Schutz von Feuchtgebieten geschaffen [RAMSAR 1994; ZEDLER und KERCHER 2005; ERWIN 2009]. Deutschland hat dieses „Übereinkommen über den Schutz von Feuchtgebieten (...) von internationaler Bedeutung“ im Jahr 1976 ratifiziert [RAMSAR 2019]. Bis heute haben sich 171 Staaten dieser Konvention angeschlossen [ebd.]. Im Verlaufe der Präzisierung der Pläne wurden Konventionsziele und Maßnahmen zum Erhalt der biologischen Vielfalt und Verbesserung des ökologischen Zustandes der Feuchtgebiete formuliert.

Als Hauptursachen für Degradierung und Verlust an wertvollen Feuchtgebieten wurden damals das Bevölkerungswachstum und der steigende Flächenverbrauch durch wachsende wirtschaftliche Interessen identifiziert. Verlust, Degradierung und Fragmentierung der Feuchtgebiete werden hauptsächlich durch Landwirtschaft, Infrastrukturausbau und Aufforstung vorangetrieben [RAMSAR 1994].

Neben diesen Prozessen wurde der Klimawandel in den letzten Jahrzehnten als weitere schwerwiegende Ursache aber auch als Folge der Degradation von Feuchtgebieten identifiziert [SANDI et al. 2020]. Feuchtgebiete reagieren sehr sensibel gegenüber sich langfristig verändernden Temperaturen. Der rezente Klimawandel zeigt sich vor allem durch Veränderungen in Niederschlagsregimen und der Temperaturen sowie in extremen Wetterereignissen. Mobile Vegetationsarten können mit der Temperaturveränderung mitwandern, jedoch nicht statische Arten, die besonders in Feuchtbiotopen zu finden sind [MALAK und HILARIDES 2016].

Gegen die Degradation und den Verlust der verschiedenen Feuchtgebietstypen (u.a. Auen, Feuchtwiesen, Moore, Ried, Marschland) wurden in den letzten Dekaden eine Vielzahl von Maßnahmen entwickelt und deren Umsetzung begonnen. Oft sind diese Maßnahmen jedoch langwierige Anpassungsprozesse und der Erfolg kann erst nach deren Beendigung abschließend festgestellt werden [POULIOT et al. 2011]. Um jedoch den Kurs während der Regenerierungsphase bewerten zu können ist eine regelmäßige Kontrolle, ein sogenanntes Monitoring, von fundamentaler Bedeutung [KNOTH et al. 2013]. Zur Umsetzung ist es oft Status quo kosten-, zeit- und personalintensive Feldbegehungen durchzuführen, deren punkthafte Probennahmen

durch interpolative Verfahren auf die Gesamtfläche übertragen werden, oder Kartierer müssen wissenschaftsbasiert und somit subjektiv für große Flächen schätzen.

Die vorliegende Arbeit konzentriert sich auf zwei Feuchtgebietstypen, anhand deren die Notwendigkeit flächenhafter Untersuchungen gezeigt werden soll. Dabei liegt der Fokus auf der Fernerkundung, weil sie ein ideales Werkzeug ist, um die Monitoringaufgaben flächenhaft, objektiv, sowie automatisierbar durchzuführen und gleichzeitig durch ihren berührungslosen Einsatz keine destruktiven Störungen in den sensiblen Ökosystemen verursacht. Es werden zum einen Vegetationszusammensetzungen in verschiedenen wiedervernässten Niedermooren untersucht, zum anderen werden in Flussmarschen verschiedene Pflanzenparameter abgeleitet.

Moore

Moore bilden den größten terrestrischen Kohlenstoffspeicher der Erde und üben erhebliche Rückkopplungseffekte auf das Klimasystem aus [FROLKING und ROULET 2007; YU et al. 2010]. Unter den massiven anthropogenen Störungen der letzten Jahrzehnte hat sich das globale Moorbiom von einer Netto-Senke zu einer Quelle von Treibhausgasen [LEIFELD et al. 2019] verschoben. Die Verschiebung der Klimafunktion von Mooren ist in erster Linie das Ergebnis einer ausgedehnten Entwässerung. Wenn der Wasserspiegel sinkt, löst die Verfügbarkeit von Sauerstoff eine Kaskade des Abbaus organischer Substanz aus, die in der Zersetzung von Torf gipfelt [FREEMAN et al. 2004; FENNER und FREEMAN 2011]. Auf diese Weise werden Torfgebiete durch die Drainage von Kohlenstoffdioxid (CO₂)-Senken zu CO₂-Quellen. Von den Mooren in Mitteleuropa sind 90 % entwässert worden, die meisten davon für landwirtschaftliche Zwecke [PFADENHAUER und GROOTJANS 1999; MOEN et al. 2017]. Dränierte Moore zählen in vielen europäischen Ländern zu den größten CO₂-Quellen aus der Land- und Forstwirtschaft, auch wenn sie nur einen kleinen Prozentsatz der nationalen Flächen [TIEMEYER et al. 2016; TUBIELLO et al. 2016] abdecken. Eine Reduzierung dieser Emissionen ist dringend erforderlich um die globale Erwärmung unter 2° C zu halten, da entwässerte Moore 10–41 % des verbleibenden Emissionsbudgets verbrauchen [LEIFELD et al. 2019].

Die Wiedervernässung ist eine gängige Maßnahme, nicht nur um die natürliche Lebensraumfunktion von Moorökosystemen wiederherzustellen, sondern auch um CO₂-Emissionen zu stoppen und dadurch den Klimawandel [LEIFELD und MENICHETTI 2018] abzuschwächen. Die Erhaltung und Wiedervernässung von Mooren gilt daher als eine der wichtigsten natürlichen Lösungen [GRISCOM et al. 2017; LEIFELD und MENICHETTI 2018] und als Schlüsselmaßnahme, um das terrestrische Ökosystem zu einer natürlichen CO₂-Senke [HUMPENÖDER et al. 2020] zurück zu transformieren.

Die erfolgreiche Durchführung der Wiedervernässung von Torfgebieten kann eine Herausforderung darstellen, da die durch die Entwässerung hervorgerufenen Degradationsprozesse weitgehend irreversibel sind. Unter intensiver landwirtschaftlicher Verdichtung und Zersetzung kann sich die Torfoberfläche für mehrere Dezimeter [LEIFELD et al. 2011] absenken und wiedervernässte Niedermoorflächen können sich leicht zu flachen Seen [STEFFENHAGEN et al. 2012] entwickeln. Eine langsame oder stagnierende Vegetationsentwicklung verhindert die großflächige Ausbreitung von

Torfmoorarten, was die Voraussetzung für die CO₂-Aufnahme und C-Akkumulation ist [TIMMERMANN et al. 2009; KOCH et al. 2017]. Um den Erfolg von Wiedervernäsungsprojekten zu überprüfen ist daher ein kontinuierliches Monitoring notwendig, um zum einen neu entstehende moortypische Vegetation nachzuweisen und zum anderen deren Entwicklung über die Zeit zu verfolgen.

Marschen

Marschen sind vegetationsbestandene flache Landschaftseinheiten an Küsten und Flussufern auf Höhe des Meeresspiegels, die gezeitenbedingt aus angeschwemmten Sedimenten bestehen. Sie erfüllen eine Vielzahl an Funktionen, darunter Küstenschutz, Sturmflutabmilderung, Sedimentrückhaltung, Erhaltung der Wasserqualität sowie Kohlenstoffbindung und die Erhaltung von ökologischen Nischen, die von verschiedenen Organismen genutzt werden [WOODWARD und WUI 2001]. Besonders in Ästuaren gelten sie als biologisch sehr produktive Ökosysteme. Neben seltenen Pflanzenarten und -gesellschaften sind sie Habitate, die wichtige ökologische Funktionen für diverse Fischarten und Wasservögel erfüllen [MUSSEAU et al. 2018].

Der erhöhte Druck auf die Marsch-Ökosysteme, der Verlust oder die Degradation von Lebensräumen und der Klimawandel gehören zu den wichtigsten Faktoren, die die Biodiversität im aktuellen Kontext des globalen Wandels beeinflussen [BUTCHART et al. 2010; PEREIRA et al. 2010]. Weltweit nimmt die Degradation dieser Küstenökosysteme zu. Je nach Szenario wird prognostiziert, das in den nächsten 100 Jahren weltweit 20–60 % an Küstenökosystemen vom Verschwinden bedroht sind [CRAFT et al. 2009; WONG et al. 2014]. Dabei sind die Marschen in Ästuaren besonders gefährdet [EDGAR et al. 2000; MUSSEAU et al. 2018]. RILO et al. [2013] zeigen, dass die anthropogene Landnutzung und der Anstieg des Meeresspiegel die größten Bedrohungen für diese Ökosysteme darstellen.

Dabei schützt die Marschvegetation durch die Reduzierung von Strömungen und Wellenenergie Ufer und Deich vor der Zerstörungskraft von Sturmfluten. Die Überschwemmungsrisiken an den Küsten werden jedoch in den kommenden Jahrzehnten aufgrund globaler und regionaler Veränderungen zunehmen [TEMMERMAN et al. 2013]. Dies ist begründet durch zunehmende Sturmintensitäten [LIN et al. 2012], einen beschleunigten Anstieg des Meeresspiegels und Landabsenkungen [SYVITSKI et al. 2009]. Mindestens 40 Millionen Menschen und 3.000 Milliarden US-Dollar an Vermögenswerten befinden sich heute in hochwassergefährdeten Küstenstädten, und es wird erwartet, dass diese bis 2070 auf 150 Millionen Menschen und 35.000 Milliarden US-Dollar ansteigen werden [NICHOLLS et al. 2007]. Konventionelles Küsteningenieurwesen, wie der Bau von Deichen und Dämmen, wird weithin als die ultimative Lösung zur Bekämpfung von Überschwemmungsrisiken angesehen [TEMMERMAN et al. 2013]. Diese Schutzmaßnahmen werden jedoch an vielen Orten ernsthaft in Frage gestellt, da ihre kontinuierliche und kostspielige Instandhaltung sowie ihre Erhöhung und Verbreiterung nicht mehr tragfähig sind, um mit dem zunehmenden Hochwasserrisiko Schritt zu halten [ebd.]. Gegenüber dem technischen Uferschutz ermöglicht die Ökosystemleistung von Marschland eine bessere Anpassung an den Meeresspiegelanstieg durch resultierende Sedimentablagerungen [HEUNER et al. 2015] und mitwachsenden Vegetationsgürteln [TEMMERMAN et al. 2013].

Wie wirksam die Reduzierung von Strömungen und Wellenenergie in Marschen ist, hängt von Pflanzenmerkmalen, hydrodynamischen Kräften und der Sedimentzufuhr ab [HEUNER 2016]. Zu den Pflanzenmerkmalen gehören Stammdichte, Pflanzenhöhe, Biomasse, Blätter und Pflanzensteifigkeit/-steifigkeit. Blätter und Stängel erhöhen die Beirauhigkeit und den Luftwiderstand. Mehr Biomasse vergrößert auch die Pflanzenoberfläche und leitet mehr turbulente kinetische Energie über die Marschoberfläche ab. Eine höhere Steifigkeit des Stängels erhöht auch den Widerstand, was wiederum die Strömungsgeschwindigkeit verringert [BOUMA et al. 2005]. Um diese Ökosystemleistung erheben und deren Entwicklung zeitlich zu verfolgen ist ein flächenhaftes Monitoring notwendig.

1.1.2 Fernerkundung

Aus den beiden beschriebenen Szenarien und Herausforderungen in Moorlandschaften und Marschen ergibt sich ein Bedarf, die Entwicklung dieser vulnerablen Ökosysteme zu überwachen und zu bewerten. Auch in der RAMSAR-Konvention wurde schon das langfristige Monitoring von Feuchtgebieten als einer der zentralen Faktoren formuliert [RAMSAR 1994].

Eine gängige Praxis sind Feldbegehungen, in denen Pflanzenkartierungen, punkt-hafte Probenahmen und das Abernten von Vegetationsbeständen durchgeführt werden. Dauerbeobachtungsflächen und wissenschaftliche Sensoren werden direkt im Gelände eingerichtet, um Messungen auf die Gesamtfläche zu extrapolieren. Punkt-hafte Messungen werden durch Interpolationsverfahren auf die Fläche übertragen. Das diese Praxis einen großen Einfluss auf die sensiblen Ökosysteme haben kann, zeigt Abbildung 1.1. Die obere Reihe an Bildern zeigt den selben Ausschnitt eines wiedervernässten Durchströmungsmoores zu verschiedenen Zeitpunkten. Am 21.08.2018 wurde eine bodenkundliche Feldkampagne durchgeführt, in der rund 100 Proben in einer Rasterbeprobung genommen wurden. Wenige Monate später (10.10.2018) sind die Spuren dieses Feldeinsatzes noch immer deutlich zu sehen. Um ein lückenloses Monitoring durchzuführen, müssen solche Feldbegehungen in gewissen zeitlichen Abständen wiederholt werden. Dabei stellt sich die Frage, welche Auswirkungen solch ein Eingriff in das quasi natürliche Ökosystem langfristig hat.

Im zweiten Beispiel (untere Reihe in Abbildung 1.1) ist eine Dauerbeobachtungs-stelle in den gleichen Zeitschnitten zu sehen, die auf einem entwässerten Küstenüber-flutungsmoor eingerichtet wurde. Die Fläche wird als extensives Grünland genutzt und die gesamte Messapparatur ist innerhalb der Beobachtungsfläche installiert. In den Sommermonaten sind die visuellen Unterschiede noch kaum zu identifizieren, jedoch zeigt sich im Oktober, dass die Nutzung der Fläche als Weide einen bedeutenden Unterschied zum Zustand der Vegetation innerhalb der Beobachtungsfläche aufweist. Hier stellt sich ebenfalls die Frage, inwiefern die Messungen auf der Dau-erbeobachtungsfläche noch repräsentativ für die Gesamtfläche sind.

Die Fernerkundung stellt diesen Problemen eine wissenschaftliche Mess- und Aus-wertemethodik gegenüber, die eine für das Ökosystem verträglichere Alternative sein könnte, vor allem hinsichtlich der ökosystemaren Störung [ESPRIELLA et al. 2020;




Abbildung 1.1: Auswirkungen und Effekte auf sensible Ökosysteme. Rasterprobennahmen (obere Reihe, vorher, während der Probennahme und danach) in einem wiedervernässten Moor. Repräsentationsprobleme einer Dauerbeobachtungsflächen (untere Reihe) in einem entwässerten Niedermoor, welches außerhalb der Untersuchungsfläche beweidet wird.

PINTON et al. 2020]. Hier sind entscheidende Vorteile gegenüber klassischer Herangehensweisen (Feldbegehungen und räumliche Interpolationen zwischen Punktmessungen) zu nennen:

Flächenhaft Statt sporadisch oder systematisch verteilte Punkte im Gelände, besitzen fernerkundliche Datensätze über das gesamte Untersuchungsgebiet an jedem Punkt multiple Pixelwerte (bspw. Reflexionswerte in verschiedenen Bereichen des elektromagnetischen Spektrums), die als Indikatoren genutzt werden können, klassifikative Einordnungen oder statistisch-regressive Parameter abzuschätzen.

Nichtdestruktiv Die Datenaufnahme von Fernerkundungsdaten geschieht berührungslos [JONES und VAUGHAN 2010] und hinterlässt dadurch keine destruktiven und dauerhaften Schädigungen des zu beobachtenden und bewertenden Gebietes. Dabei kann die Fernerkundung zwar die Feldbegehung und -beprobung nicht komplett ersetzen, jedoch deren zeitliche Frequenz deutlich verringern.

Multitemporal Erdbeobachtungssatelliten haben eine bestimmte Wiederholrate. Das heißt sie überfliegen das Untersuchungsgebiet regelmäßig in bestimmten Zeitintervallen ab. Befliegungen mit Flugzeugen und vor allem Drohnen

sind dabei noch anpassungsfähiger, weil auf Wetterbedingungen und phänologische Ereignisse individuell reagiert werden kann.

Objektiv Die Interpretation von Fernerkundungsdaten erfolgt stets auf Basis von mathematisch-statistischen Verfahren, die das gesamte Untersuchungsgebiet mit der gleichen Methodik analysieren. Somit können subjektive Schätzung, wie es beispielsweise bei Kartierern im Gelände auftreten kann, auf ein gewisses Maß minimiert werden.

Automatisierbar Ist einmal eine Prozessierungskette aufgebaut, kann diese für Folgeuntersuchungen, unter bestimmten Rahmenbedingungen, bspw. räumliche und zeitliche Übertragbarkeit, automatisiert werden.

Großflächige Analysen, bis zur globalen Ebene, werden mit Daten von Erdbeobachtungssatelliten durchgeführt. Eine große Abdeckung bedeutet aber auch immer einen Kompromiss einzugehen zwischen der räumlichen Auflösung und einem höheren Abstraktionsgrad der Aufgabenstellung. Sehr feingliedrige und räumlich heterogene Gebiete, wie Moore und Marschen, sind durch diese Art an Fernerkundungsdaten jedoch nur schwer abbildbar.

Während der letzten Dekade erlebte die Fernerkundung durch die Entwicklung von kleinen unbemannten Flugsystemen, sogenannten *Unmanned Aerial Systems* (UAS)¹ und durch die Miniaturisierung ihrer diversen Sensortypen eine enorme Ausweitung ihres Potentials [COLOMINA und MOLINA 2014; TOTH und JÓZKÓW 2016]. UAS beginnen den Unterschied in der räumlichen Auflösung und Detailliertheit zwischen traditionellen Fernerkundungsmethoden und bodengebundenen Feldtechniken zu überbrücken [MURFITT et al. 2017]. Die Möglichkeit, bedarfsgerecht kostengünstige Plattformen und Sensoren zu nutzen, um flächenhafte Daten zu erheben, bietet neue Möglichkeiten im Bereich der Ökologie, Muster und Prozesse besser zu verstehen. Das Fliegen in geringerer Höhe (< 100 m) als herkömmliche Fernerkundungssysteme ermöglicht die Datenerfassung mit feinerer räumlicher Auflösung im Zentimeterbereich. Außerdem steigt die Zahl an potentiellen Flugtagen im Jahr, weil unter der Wolkendecke geflogen wird. Dies hat noch einen positiven Nebeneffekt, dass bei gleichmäßig bedecktem Himmel keine störenden Schattenwürfe in den prozessierten Bildern berücksichtigt werden müssen. Diese Vorteile ermöglichen die rasche Erfassung hochauflösender Daten in genau festgelegten zeitlichen Maßstäben, wodurch sich UAS zu einem wichtigen Instrument für die Bewertung und Überwachung der Umwelt entwickelt haben [ebd.].

In den letzten Jahren wurden immer mehr Sensoren entwickelt, womit UAS bestückt werden können. Neben den standardmäßig hochaufgelösten Rot-Grün-Blau (RGB)-Sensoren sind hier unter anderem Multispektral- und Hyperspektralsensoren für vielkanalige Reflexionsspektren im optischen Bereich des elektromagnetischen Spektrums zwischen 350 nm bis 1000 nm, Thermalkameras für Oberflächentemperaturen und Laserscanner zu nennen [YAO et al. 2019]. Dabei kommt besonders den Multispektral- und Thermal-Sensoren mittlerweile eine besondere Bedeutung und Vielseitigkeit an Anwendungen zu. So wurden UAS mit den verschiedenen Sensoren in der Landwirtschaft [TSOUROS et al. 2019; LIBRÁN-EMBED et al. 2020], Umweltwissenschaften [NOWAK et al. 2019], Forstwissenschaften [TANG und SHAO 2015;

¹Englische Begriffe werden in der Arbeit *kursiv* geschrieben.

TORRESAN et al. 2017], urbanen Studien [MOHD NOOR et al. 2018] sowie in der Geologie und Geomorphologie [CIGNETTI et al. 2019; TÖRÖK et al. 2020] eingesetzt.

YAO et al. [2019] kritisieren jedoch, dass meistens diese neue Art an Daten und deren Potential nicht hinreichend ausgeschöpft werden. Stattdessen benutzen die veröffentlichten Studien eine klassische Herangehensweise der Fernerkundung. Beispielsweise konzentrieren sich die meisten der vorhandenen Methoden zur Bildklassifikation normalerweise auf die Extraktion von zweidimensionalen Bildmerkmalen, während bei der Klassifikation von UAS-basierten Bildprodukten das oft verfügbare Digitale Oberflächenmodell (DOM) integriert werden kann und die Klassifikationsgenauigkeit konsequent verbessert, was auch bspw. durch BENDIG et al. [2015] oder ZHANG et al. [2015] bestätigt wurde. Außerdem sind Drohnen oft in der Lage verschiedene Sensoren zu tragen. Dadurch entsteht das Potential multisensorale Analysen durchzuführen und den Mehrwert eines solchen Ansatzes zu testen.

1.2 Ziele und Aufbau der Arbeit

Für die vorliegende Arbeit werden verschiedene Sensoren auf einem UAS genutzt. Dies beinhaltet eine für die Photogrammetrie optimierte hochauflösende RGB-Kamera, einen Multispektral (MS)-Sensor und eine Thermalkamera. Aus den Daten der drei Sensoren werden multisensorale Datensätze generiert. Diese Datensätze bestehen nicht nur aus den Rohdaten der Sensoren, sondern auch aus daraus abgeleiteten Produkten, wie dem DOM und Indizes verschiedener Art.

Die multisensoralen Datensätze werden auf mehreren Feuchtgebieten mit verschiedenen Fragestellungen getestet. Dabei werden, zum einen, auf drei Niedermoorstandorten in Mecklenburg-Vorpommern (MV) klassifikative Arbeiten zur Erfassung heterogener Pflanzengesellschaften durchgeführt. Zum anderen werden zwei Marschgebiete im Tideästuar der Elbe untersucht. Zur Beurteilung von Marschen als natürlicher Uferschutz werden hier Pflanzenparameter regressiv aus dem multisensoralen Datensatz abgeleitet.

Daraus ergeben sich folgende Forschungsfragen, die in der Arbeit beantwortet werden sollen:

1. **Welches Potential hat die Fusion verschiedener Sensoren zu einem multisensoralen UAS-Datensatz für das Monitoring in schützenswerten Feuchtgebieten ...**
 - a) ... bei der Klassifikation von feingliedrigen komplexen Strukturen von Pflanzengesellschaften in Niedermooren?
 - b) ... bei der Regression bzw. Ableitung von Parametern für die Beurteilung der Widerstandsfähigkeit von Pflanzen in tidebeeinflussten Marschländern gegenüber Wellenschlag und Sturmfluten?
2. **Welche Daten bzw. Eingangsvariablen sind die relevantesten für die Beantwortung der vorgestellten Themenkomplexe ...**
 - a) ... hinsichtlich der drei eingesetzten Sensortypen?
 - b) ... hinsichtlich abgeleiteter Produkte aus den Originaldatensätzen der drei Sensoren?

3. Reichen die Daten eines Sensors aus oder werden erst durch die Fusion verschiedener Datentypen sinnvolle und zufriedenstellende Ergebnisse erreicht?

Die Arbeit versucht dabei die beiden *Welten* anwendungsorientiert-ökologischer Forschungsergebnisse und fernerkundlich-methodischer Erkenntnisse gerecht zu werden, indem beides parallel betrachtet und ineinander verflochten wird.

Aufbau der Arbeit

Nach dem nun in Kapitel 1 **Einführung** das Thema motiviert und Forschungsfragen aufgeworfen wurden, ist die Arbeit wie folgt aufgebaut:

Zunächst werden in Kapitel 2 **Stand der Forschung** bisherige Arbeiten in Mooren und Marschen aus fernerkundlicher Sicht aufgearbeitet.

In Kapitel 3 **Grundlagen, Projekte, Gebiete** werden ökologische Grundlagen zur Wiedervernässung von Niedermoores und zu den tide-beeinflussten Flussmarschen geschaffen, sowie die Projekte beschrieben, die die Grundlage dieser Arbeit bilden. Außerdem werden die Untersuchungsgebiete der beiden Feuchtgebietstypen vorgestellt.

In Kapitel 4 **Instrumentierung und Datengrundlage** werden alle verwendeten Geodaten vorgestellt. Das umfasst zum einen die UAS-Daten der verschiedenen Sensoren, sowie die im Gelände aufgenommenen Vegetationsdaten.

Im Kapitel 5 **Methoden** wird der gesamte methodische *Workflow* der vorliegenden Arbeit aufgezeigt. Neben der Vorprozessierung der unterschiedlichen UAS-Daten, liegt dabei der zentrale Fokus auf den beiden verwendeten Verfahren zur Klassifikation und zur Regression.

In Kapitel 6 **Ergebnisse und Diskussion** werden schließlich alle Ergebnisse zusammengetragen und diskutiert.

Am Ende werden in Kapitel 7 **Zusammenfassung und Ausblick** die Forschungsfragen nochmals aufgegriffen in jeweiligen Unterabschnitten behandelt. Die Arbeit schließt mit einem Ausblick auf mögliche Anschlussstudien, die sich während der Arbeit ergeben haben.

Alle hier verwendeten Ausgangs- und Ergebnisdatensätze, die Arbeit als PDF-Dokument und L^AT_EX-Projekt, sowie die Abbildungen sind auf einem digitalen Datenträger gespeichert. Dieser ist auf dem inneren, hinteren Buchdeckel zu finden. Die Verzeichnisstruktur ist in Anhang A.12 (Seite 243) schematisch dargestellt.

2 Stand der Forschung

Feuchtgebiete im Allgemeinen wurden in der Vergangenheit und werden stets sehr intensiv erforscht. Zusammenfassende Übersichtsstudien sind unter anderem bei MITSCH und GOSSELINK [2000], ZEDLER und KERCHER [2005], DUDGEON et al. [2006] und LEPAGE [2011] zu finden. Auch im Bereich der Fernerkundung wurden Feuchtgebiete im Allgemeinen und die verschiedenen Subtypen intensiv bearbeitet. Auch hier sind eine Vielzahl von zusammenfassenden Überblickspublikationen zu finden: DAVIDSON und FINLAYSON [2007], HENDERSON und LEWIS [2008], ADAM et al. [2010], KLEMAS [2011, 2013a,b] und DRONOVA [2015] und GUO et al. [2017].

TINER et al. [2015] geben in ihrem Lehrbuch einen allgemeinen Überblick über Fernerkundung in Feuchtgebieten. Die folgenden Ausführungen konzentrieren sich auf fernerkundliche Untersuchungen auf Moor- und Marschstandorten.

2.1 Moore und Fernerkundung

Bisher lag der Fokus fernerkundlicher Forschung auf großräumigen Analysen hauptsächlich in borealen bzw. auf Moorlandschaften der nördlichen Breiten, weil hier global betrachtet der Hauptanteil an Mooren zu finden ist [JOOSTEN 2009; JOOSTEN et al. 2012]. Dabei wurden zahlreiche Arbeiten zu den Themenfeldern Kohlenstoffspeicher [SHENG et al. 2004; AKUMU und McLAUGHLIN 2014], Treibhausgasemissionen [BUBIER et al. 1995; LEES et al. 2018], der Klassifikationen unterschiedlicher Moortypen [AMANI et al. 2018; ARROYO-MORA et al. 2018] oder vegetationspezifische Fragestellungen [BUBIER et al. 1997; THOMAS et al. 2003; SONNENTAG et al. 2007] durchgeführt.

Jedoch existieren nur wenige fernerkundliche Studien, die sich mit der Vegetationsentwicklung wiedervernässter Moore beschäftigen [FRICK et al. 2011; KNOTH et al. 2013; DABROWSKA-ZIELINSKA et al. 2014; KOCH et al. 2017]. PENGRA et al. [2007] identifizierten *Phragmites spec.* auf Basis hyperspektraler Hyperion-Daten. Aufgrund der sehr groben räumlichen Auflösung dieses Satellitensensors (*Ground Sampling Distance* (GSD) = 30 m) konzentrierte sich die Arbeit auf die Unterscheidung großer Bestände. BECKER et al. [2007] klassifizierten Vegetation von Küstenmooren mit hyperspektralen Flugzeugscannerdaten. Sie resümierten in der Studie, dass eine räumliche Auflösung von unter zwei Metern notwendig sei und identifizierten sechs wichtige Spektralbereiche im optischen Spektrum, die entscheidend sind um verschiedene Pflanzenarten voneinander zu trennen. FRICK et al. [2011] nutzten MS-Satellitendaten mit sehr hoher räumlicher Auflösung (QuickBird, WorldView 1, SPOT) um verschiedene Pflanzenarten zu unterscheiden. Dabei wurden moderne Entscheidungsbaum-Verfahren aus dem maschinellen Lernen, wie dem *Random Forest* (RF) oder *AdaBoost* verwendet. Sie kamen auf Klassifikationsgenauigkeiten von 85 % bis 90 %.

UAS sind in der Lage *ultra* hohe räumliche Auflösungen (1 cm – 20 cm laut ZHANG et al. [2017] und FERNÁNDEZ-GUISURAGA et al. [2018]) mit verschiedensten Sensortypen aufzunehmen. Hinsichtlich der temporalen Auflösung erschließen sie neue Möglichkeiten und Einsatzfelder aufgrund ihrer relativen Unabhängigkeit von Wolkenbedeckung und schnellen Einsatzmöglichkeit. Jedoch wurden bisher wenige UAS-Untersuchungen auf Moorflächen durchgeführt, z.B. LEHMANN et al. [2016], SIMPSON et al. [2016], KALACSKA et al. [2017b], RAHMAN et al. [2017], LOVITT et al. [2018], BEYER et al. [2019b] und SCHOLEFIELD et al. [2019]. Unter diesen Wenigen finden sich kaum Publikationen zum Thema Identifikation und Unterscheidung von moortypischen Pflanzenarten.

KNOTH et al. [2013] haben drei Pflanzenarten im Hochmoor und offen anstehendem Torf mit einer RGB- und einer umgebauten Infrarotkamera auf zwei Multikoptern klassifiziert. Sie nutzten einen objektbasierten Ansatz und erreichten Klassifikationsgenauigkeiten von 84 % bis 95 %. KOCH et al. [2017] verwendeten ebenfalls einen kombinierten Segmentierungs-/ Klassifizierungsansatz, um mit RGB- und daraus generierten Textur-Parametern vier unterschiedliche Vegetationsklassen in einem wiedervernässten Küstenversumpfungsmoor zu unterscheiden. CLUTTERBUCK et al. [2018] untersuchten zwei Hochmoore in England mit RGB-Infrarot-Daten, generierten Oberflächenmodellen und terrestrischem Laserscanning. Sie beschrieben in ihrer Arbeit verschiedene Pflanzengesellschaften, morphologische Bedingungen und Erosionsformen. PALACE et al. [2018] trainierten ein künstliches neuronales Netz zur Klassifizierung von Vegetation in subarktischen Mooren in Nordschweden. Sie nutzten die RGB-Daten und daraus generierte Textur-Indizes um acht Pflanzentypen zu unterscheiden und erhielten Klassifizierungsgenauigkeiten von 68 %. SCHOLEFIELD et al. [2019] nutzten RGB-Daten, daraus generierte Oberflächenmodelle und abgeleitete Indizes wie Oberflächenneigung (*Slope*) und Hangausrichtung (*Aspect*) um verschiedene Habitattypen (vier Hochmoortypen, Wasser, offener Torf), Kohlenstoffverluste und Erosionsformen in Moorlandschaften zu identifizieren.

Bei der Recherche fällt auf, dass bisherige Forschungen ausschließlich auf Hochmooren und meist in den nördlichen Breiten durchgeführt wurden. Einzig FRICK et al. [2011] arbeiteten fernerkundlich in Niedermooren, aber auf grob aufgelöster Satellitenebene. KOCH et al. [2017] haben zwar mit hochaufgelösten UAS-Daten gearbeitet, aber erstens monosensoral (RGB) und zweitens mit nur vier groben Vegetationsklassen. Daher ergibt sich hier ein Forschungspotential auf wiedervernässten Niedermooren die komplexen Dominanzbestände feiner aufgliedert zu klassifizieren und den Mehrwert der multisensoralen Daten zu testen.

2.2 Marschland und Fernerkundung

Der zweite Feuchtgebietstyp, der in der Arbeit behandelt wird, ist das Ökosystem Marschland und im speziellen Marschen, die in Flussästuaren unter Einfluss von Tidenhub stehen (nähere Erläuterungen in Abschnitt 3.2). Bisherige Studien behandelten verschiedenste Funktionen und Leistungen dieses Ökosystems, wie die Wachstumsprozesse, räumliche Muster, Verteilung der Vegetationsarten und deren Charakteristik (abiotische und biotische Faktoren) [ENGELS 2010; CARUS und SCHRÖDER 2014; SILINSKI 2015; CARUS et al. 2017a,b; CLIFTON et al. 2018; JØRGENSEN

et al. 2018; OTEMAN et al. 2019], Pflanzen im Marschland als Schutz vor Wellenschlag durch Sturmfluten und Schiffsverkehr [MÖLLER et al. 1999; YANG et al. 2012; HEUNER et al. 2015; SILINSKI et al. 2015; HEUNER 2016], Auswirkungen des Klimawandels auf Marschen [MUSSEAU et al. 2018], Marschland als natur-basierte Lösung gegen den Klimawandel [TEMMERMAN et al. 2013; SCHOUTENS et al. 2019; BOSSIO et al. 2020] und Sedimentationsprozesse in Marschländern [ALLER et al. 2004; HEUNER et al. 2018].

Fernerkundlich wurde mit Satellitendaten der größte Teil der wissenschaftlichen Arbeiten an den salzwasserdominierten tide-beeinflussten Küstenmarschen durchgeführt. Bei der Literaturrecherche konnten dabei vier große Themenkomplexe identifiziert werden, die direkte Klassifikation von Pflanzenarten [BUDD und MILTON 1982; DALE et al. 1986; WANG et al. 2007; BEIJMA et al. 2014; HOOVER und WHELCHER 2015; SINHA et al. 2015], die Klassifikation von Marschen in funktionale bzw. landschaftsgenetische Typen [BERLANGA-ROBLES und RUIZ-LUNA 2002; TIMM und MCGARIGAL 2012; BEIJMA et al. 2014; SUN und ZHU 2017], die Ableitung ökosystemarer Parameter [HLADIK und ALBER 2012; MEDEIROS et al. 2015; MISHRA und GHOSH 2015; KHANNA et al. 2017; VRIELING et al. 2017; OTEMAN et al. 2019] und sedimentologische Arbeiten, meist zum Watt im Vorland von Marschen [RYU et al. 2014; WANG et al. 2016; ADOLPH et al. 2018]. Die sedimentologischen Arbeiten im Wattbereich sind zwar für das Ökosystem Marsch essentiell, werden aber in der vorliegenden Arbeit nicht weiter betrachtet.

Die genannten Arbeiten mit dem Fokus auf Vegetation werden im Folgenden kurz zusammengefasst. BUDD und MILTON [1982] sammelten radiometrische Messungen am Boden von verschiedenen Vegetationsarten (vier Gruppen) in Salzmarschen bei Chichester Harbour (Süd-England) als Vorstudie für die bald darauf startende Landsat 4-Mission mit dem neuen Multispektralsensor TM (*Thematic Mapper*). Sie zeigten in ihrer Arbeit, dass der TM-Sensor mit seiner höheren räumlichen (GSD 30 m) und besseren spektralen (sieben Kanäle) Auflösung (als der bisherige *Multispectral Scanner*(MSS)-Sensor mit vier Kanälen und 80 m GSD) klare Vorteile bei der Klassifikation der verschiedenen Pflanzenarten sowie der Abschätzung an Biomasse besitzt. DALE et al. [1986] verwendeten CIR-Luftbilder, um die Vegetationstypen in einem subtropischen Küsten-Salzmarschland im Südosten von Queensland (Australien) mit Hilfe eines hierarchischen Clusterverfahrens zu identifizieren. Sie testeten unüberwachte und überwachte Klassifikatoren und identifizierten auf Makroebene vier Salzmarsch-Vegetationstypen, auf Mikroebene waren acht Typen erkennbar. WANG et al. [2007] testeten in der Lagune von Venedig (Italien) einen neuen Klassifikator für neuronale Netze, der zur Kartierung halophytischer Vegetationsgesellschaften in tide-beeinflussten Ökosystemen genutzt wurde. Dabei wurden sechs der verfügbaren 15 *Compact Airborne Spectral Imager*(CASI)-Spektralkanäle genutzt um vier Vegetationsarten zu klassifizieren. Die Klassifikationsgenauigkeit belief sich auf 91 %. Um die Bedingungen in Feuchtgebieten besser zu verstehen, verwendeten KUMAR und SINHA [2014] Satellitendaten mit hoher räumlicher Auflösung von QuickBird und Hyperspektraldaten von Hyperion zur Kartierung der Salzmarsch-Vegetationsgemeinschaften von Micalo Island in Australien. Sie fanden heraus, dass mit Hyperion eine bessere Genauigkeit (Gesamtgenauigkeit = 71,1 %) erzielt werden kann, als mit Quickbird (Gesamtgenauigkeit = 59,4 %). HOOVER und WHELCHER [2015] präsentieren einen Weg um Vegetationsbestände in Marschen in

einem mehr-stufigen Ansatz zu segmentieren und zu klassifizieren. Sie verwendeten ein Colorinfrarot-Luftbild und ein Digitales Geländemodell mit einer räumlichen Auflösung von etwa 30 cm (ein Fuß) um die fünf Klassen Niedermarsch, Hochmarsch, *Iva frutescens*, *Phragmites australis*, Sand und Wasser im Marschland am Long Island Sound (USA) zu klassifizieren. Sie erzielten im Mittel Klassifikationsgenauigkeiten von 85,1 %. Diese Arbeiten konzentrierten sich auf die Erkennung einzelner dominanter Pflanzenarten in Marschen.

Eine weitere Herangehensweise war die Marschökosysteme in verschiedene funktionale bzw. genetische Klassen zu unterteilen, wie es auch HOOVER und WHELCHER [2015] schon ansatzweise mit den Klassen Nieder- und Hochmarsch gemacht haben. BERLANGA-ROBLES und RUIZ-LUNA [2002] verwendete sechs Landbedeckungstypen (Mangrove, Lagune, Salzmarsch, Trockenwald, sekundäre Sukzession und Landwirtschaft) aus Landsat-Daten als direkte Indikatoren, um Landschaftsveränderungen im Majahual-Ästuar Mexikos zu erfassen. Sie stellten fest, dass landwirtschaftliche Aktivitäten der Hauptgrund für die Landschaftsveränderung auch in Marschländern waren. TIMM und MCGARIGAL [2012] verwendeten einen RF-Klassifikator um feinskalige (d.h. 1m Pixel-Auflösung) Karten der Salzmarschvegetation an der Küste Cape Cod (USA) zu erstellen. Sie benutzten eine CIR-Luftbildaufnahme, eine multispektrale Satellitenbildaufnahme von QuickBird und ein aus Luftbildern abgeleitetes Höhenmodell, sowie verschiedene Spektral- und Reliefindizes zwischen 0,5 und 5 m räumlicher Auflösung. Allerdings wurden keine speziellen Vegetationsarten klassifiziert, sondern morphologische Marscheinheiten, wie bspw. Nieder- und Hochmarsch, sowie offene Wasserflächen und Riedgras-Marschen. Mit diesem Ansatz erreichten sie eine hohe Gesamtklassifizierungsgenauigkeit von 86,8 %. BELJMA et al. [2014] testeten einen multisensoralen Ansatz zur Klassifikation von Vegetationsarten und Habitatarten auf den Llanrhidian Salzmarschen im Loughor-Ästuar der Nordküste der Halbinsel Gower in Süd-Wales (Großbritannien). Sie nutzten verschiedene fernerkundliche Kanäle, wie spektrale Indizes aus Landsat-Daten, luftgestützte vollpolarmetrisierte S- und X-Band-*Synthetic Aperture Radar*(SAR)-Daten und ein DOM als Prädiktoren in einem RF. Einer der Erkenntnisse war, dass sich das X-Band der SAR-Daten am besten eignet zur Differenzierung von Pflanzenarten und S-Band für die Differenzierung zwischen Habitaten. Eine zweite Erkenntnis war, dass die wichtigsten Prädiktoren zur Klassifikation nicht die SAR-Daten, sondern das DOM und zwei multispektrale Indizes (NDVI) waren. SUN et al. [2018] teilten das Marschland, im Virginia Coast Reserve auf der Halbinsel Delmarva (USA), in die vier Zonen Watt, Niedermarsch, obere Niedermarsch und Hochmarsch ein. Dabei stehen diese Habitatsanordnungen für spezielle Vegetationsgesellschaften. Für das Referenzjahr 2002 wurde eine ganzjährige NDVI-Zeitreihe aus Landsat-5 und -7 generiert, anhand deren sie mittels der Entscheidungsbaum-Klassifikation C5.0 Unterscheidungsregeln für die vier Habitatklassen erstellten. Im Referenzjahr gelang diese Klassifikation mit einer Gesamtgenauigkeit von 89,8 %. Ausgehend von diesem Referenzjahr wurde die Methodik für acht weitere Zeitreihen (zwischen 1984 und 2011) durchgeführt und validiert. Die Genauigkeiten lagen zwischen 77,8 – 86,9 %. Die Hauptidee ist ein starker Rückgang von Niedermarschhabitaten, was die Autoren auf einen steigenden Meeresspiegel zurückführen.

Besonders in den letzten Jahren konzentrierten sich die Arbeiten mit Satellitendaten auf die Ableitung bestimmter Parameter in Marschökosystemen. Die Identifi-

kation wichtiger Treiber dieser Ökosysteme wird in den Arbeiten als entscheidende Information angesehen, die Marschökosysteme besser zu verstehen und deren Anpassungsfähigkeiten an den künftigen globalen Wandel einschätzen zu können. Die Geländehöhe in Marschen ist treibender Faktor für die Art und Verteilung der Pflanzengesellschaften, die sich entwickeln. Daher haben HLADIK und ALBER [2012] getestet, ob sich hochaufgelöste luftgestützte *Light Detection and Ranging* (LIDAR)-Daten bewähren um ein digitales Geländemodell (DGM), im Salzmarschgebiet auf der Insel Sapelo (USA), zu berechnen. Validiert wurden die Ergebnisse mit rund 1800 *Real Time Kinematic* (RTK)-*Global Navigation Satellite System* (GNSS)-Messungen. Die Ergebnisse zeigten teilweise pflanzenspezifisch starke Offsets in der Höhengenaugigkeit des generierten DGMs. Daher wurden für jede vorkommende Vegetationsart ein eigener Korrekturfaktor berechnet um ein finales DGM zu berechnen, welcher den Standard-Fehler von 0,1 +/- 0,12 m auf -0,01 +/- 0,09 m senkte.

Eine sehr großräumige Analyse von Marschland führten MISHRA und GHOSH [2015] am Golf von Mexiko an der Küste der US-Staaten Louisiana, Mississippi, Alabama und Florida durch. Dabei skalierten sie vier Parameter (Chlorophyllgehalt auf Bestandesebene, grüne Biomasse, Blattflächenindex und Vegetationsanteil an der Gesamtfläche) beginnend bei spektrometrischen Messungen im Gelände zunächst auf Landsat-Daten (GSD 30 m) und schließlich für den gesamten Untersuchungsraum auf *Moderate-resolution Imaging Spectroradiometer*(MODIS)-Daten (GSD 250 m und 500 m). Dabei testeten sie verschiedene Vegetationsindizes und inwieweit diese mit den Parametern korrelieren. Der WDRVI ($r^2 \approx 0,82$) und der VARI ($r^2 \approx 0,9$) wurden identifiziert als vielversprechende Indizes. Diese Zwischenergebnisse wurden dann auf eine Zeitreihe angewendet, um die Veränderung über die Zeit im Untersuchungsgebiet festzustellen.

MEDEIROS et al. [2015] integrierte LIDAR-Daten mit Daten von einem passiven optischen Sensor (MODIS) und interferometrischen SAR-Daten, um Verbesserungen in Angriff zu nehmen, die für digitale Höhenmodelle in küstennahen Salzwiesen erforderlich sind. Sie passten anfängliche Schätzungen der Geländehöhen auf der Grundlage der Höhen und Dichten der Vegetationsbestände an, um ein verbessertes Geländemodell für ihr Untersuchungsgebiet im Nordwesten Floridas (USA) zu erzeugen. VRIELING et al. [2017] nutzten RapidEye- und SPOT5-Satellitendaten im Watt-Marschbereich der Insel Schiermonnikoog (Niederlande) um die phänologischen Muster aus Zeitreihen des Spektralindex NDVI zu identifizieren und auszuwerten. Dies geschah für die Monate März bis August 2015. Die Ergebnisse sollten dann verglichen werden, mit einer längeren vierjährigen Zeitreihe bestehend aus fusionierten Daten von verschiedenen Satellitendaten (Landsat-8, MODIS und *Project for On-Board Autonomy Vegetation* (PROBA-V)). Die Autoren zeigen zunächst, dass mit den räumlich hochaufgelösten RapidEye- (5 m) und SPOT5-Daten (10 m) sehr vielversprechende Repräsentationen des phänologischen Verlaufs der Marschflächen modelliert werden können. Sie weisen aber auch darauf hin, dass grob aufgelöste Satellitensensoren wie MODIS und PROBA-V kaum in der Lage sind die Variabilität solch fein skalierten Strukturen von Marschökosystemen abzubilden. Selbst die 30 m GSD von Landsat und die niedrige Wiederholrate in Verbindung mit hoher Wolkendynamik sind hinderlich für phänologische Analysen.

KHANNA et al. [2017] untersuchten die Auswirkungen und Regenerationsfähigkeit von Salzmarschen nach einem Sturmereignis und einer Ölhavarie in der Barataria-

Bucht im Golf von Mexiko (USA). Dafür nutzten sie hyperspektrale Flugzeugscannerdaten des Sensors *Airborne Visible InfraRed Imaging Spectrometer* (AVIRIS) aus den Jahren 2010–2012. Sie berechneten sechs Indizes, sowie neun Landschaftsstrukturmaße und extrahierten auf Basis dieser Variablen die Grenzen der Marschen. Die Ergebnisse zeigten keine klare Eingangsvariable als besonders wichtig für die Analyse der Auswirkung solcher Ereignisse auf die Marschküste. Außerdem konnten kaum starke Einflüsse der beiden Ereignisse auf die Marschen selbst nachgewiesen werden, außer bei den Gebieten, an denen der Marschsaum besonders schmal ist. OTEMAN et al. [2019] nutzen feldspektrometrische Messungen und RapidEye-Satellitendaten in Kombination mit einem physikalisch basierten Reflexionsmodell (*Prosail*) um die Haupttreiber für die räumlichen Muster der Vegetation in Salzmarschen zu identifizieren. Sie prüften dafür die vier Parameter Überflutungsdauer, Wellenstärke, Artenkonkurrenz und Abflussbahnenbildung. Die Autoren identifizieren die Überflutungsdauer als wichtigsten Einflussparameter (um den Faktor drei) auf die Struktur und Verteilung der Vegetation in Salzmarschen.

Im Vergleich zu großflächigen Themenkomplexen, wie bspw. Forst- oder Landwirtschaft, sind fernerkundliche Publikationen über Marschökosysteme im globalen Maßstab relativ wenig vertreten. Dies wird besonders deutlich bei der Recherche von Publikationen zu UAS-basierten Arbeiten in Marschen. Auch hier wurden kaum Studien in Brack- oder Süßwassermarschen angefertigt, sondern beschränken sich, wie bei den Arbeiten mit Satellitendaten, auf Salzwassermarschen an den Küsten. Die Themen dieser Arbeiten sind so heterogen, dass keine allgemeine Klassifikation vorgenommen werden kann. Als einzige Unterscheidung kommt in Frage, ob sie einen Fokus auf Vegetation haben oder andere Fragestellungen behandeln. Zunächst wird mit den Vegetationsarbeiten begonnen.

KELCEY und LUCIEER [2013] identifizierten schon sehr früh, dass trotz der begrenzten Verfügbarkeit an spektraler Information auf UAS, ein hoher Informationsgehalt in der Textur hochaufgelöster RGB-Daten für dominante Vegetationsarten in Salzmarschen steckt. Sie berechneten verschiedene Texturindizes auf Basis eines räumlich 5 cm aufgelösten RGB-Drohnen Datensatzes (Ralphs Bay, Australien) und konnten so mittels der RF-Klassifikation drei Vegetationstypen in einem Salzmarschökosystem voneinander unterscheiden. Klassifikationsgenauigkeiten schwankten dabei zwischen 81 und 87 %. Außerdem haben kürzlich BROUSSARD et al. [2020] eine Arbeit veröffentlicht, in der sie eine umgebaute RGB-Kamera (Ausbau des Infrarotsperfilter) nutzen, um mit Hilfe eines objektbasierten Segmentierungsansatz zwei Vegetationsarten, eine Vegetationsmischklasse und Wasser in einem Salzmarschgebiet (Terrebonne USA) zu klassifizieren und deren mittlere Pflanzenhöhe zu ermitteln. Sie erreichen mit ihrem Ansatz eine Gesamtgenauigkeit von 85 %. MARCACCIO et al. [2016] verglichen das Potential von räumlich hochaufgelösten RGB-Datensätzen zur Klassifikation von vier groben Vegetationsklassen (Gräser, Rohrkolben, Unterwasservegetation, schwimmende Vegetation), aufgenommen von zwei unterschiedlichen Drohnen, einem Multicopter, einem Starrflügler und den staatlich aufgenommenen Luftbilddaten in einem Süßwassermarschland an der Nordküste des Eriesees (Kanada). Die Autoren verglichen die Klassifikationsgenauigkeiten und die Flächenanteile der Vegetation der drei Datensätze und kamen auf Genauigkeiten zwischen 18 und 31 %, wobei die Ergebnisse des Starrflüglers die genauesten und die der beiden Drohnen genauer als die der Flugzeugbefliegung waren. WAN et al. [2014] un-

tersuchten die invasive Ausbreitung des Neophyts *Spartina alterniflora* auf Marschflächen und Magroven in Beihai (China). Dafür nutzten sie RGB-Daten von einem UAS und berechneten daraus eine Vielzahl von unterschiedlichen Indizes aus den spektralen (u.a. Helligkeit, Sättigung, Standardabweichung), texturalen (u.a. Kompaktness, Homogenität) und kontextuellen Informationen (u.a. thematische Karten). Diese Indizes wurden zunächst genutzt für eine Segmentierung und im Anschluss für eine wissensbasierte Schwellwertklassifikation. Der Ansatz ergab Genauigkeiten zwischen 91 und 96 %. DOUGHTY und CAVANAUGH [2019] nutzen multispektrale UAS-Daten aus jeder Jahreszeit im Carpinteria-Salzmarschland (USA) um Biomasse abzuleiten. Für den Test wurden sechs spektrale Indizes berechnet und durch lineare Regressionen mit Geländemessungen kombiniert. Der NDVI lieferte den höchsten statistischen Zusammenhang ($r^2 = 0,67$), allerdings nur im Frühling. Im Jahresdurchschnitt zeigte keiner der Indizes hohe Zusammenhänge.

ESPRIELLA et al. [2020] schlagen ein großräumiges Monitoringkonzept für tidebeeinflusste Küstenregionen vor. Anhand von UAS-Aufnahmen im Golf von Mexiko (Florida, USA) wurde ein objektorientierter Workflow erstellt um Wattflächen, Salzmarschen und Muschelbänke von einander zu unterscheiden. Die Gesamtgenauigkeit der Klassifikation belief sich auf 79 %.

Die beiden Arbeiten von FARRIS et al. [2019] und DAI et al. [2020] behandeln die Frage, wie die Marschkante aus UAS-Daten identifiziert werden kann. FARRIS et al. [2019] entwickelten zwei Verfahren auf Basis von RGB-UAS-Daten in einem Marsch-Ökosystem auf Plum Island (USA) und verglichen diese mit händisch digitalisierten Referenzdaten. Das eine Verfahren basierte auf der Identifikation der Marschkante aufgrund des abrupten Anstieges der Höheninformation im DOM. Das andere Verfahren basiert auf den Farbkanälen und der Unterscheidung zwischen Vegetation und Nicht-Vegetation. Beide Verfahren lieferten zufriedenstellende Ergebnisse und hatten einen mittleren Fehler von 0,6 m untereinander und 0,43 m zur Referenzkantenlinie. DAI et al. [2020] haben an sechs Marschstandorten an der Küste von Jiangsu (China) die Marschkante detektiert. Dafür haben sie von einem UAS die RGB-Daten und die DOMs genutzt. Durch drei Vergleichsbefliegungen zwischen April 2017 bis Oktober 2018 konnten sie die Veränderungen an der Marschkante zurückführen auf das Sedimentationsgeschehen und die Umlagerungsprozesse auf den Wattflächen.

Die Höheninformationen für das Gelände und der Vegetation sind essentielle Parameter zur Beurteilung der Marschökosysteme. Dafür wurden zwei Grundlagenarbeiten publiziert. KALACSKA et al. [2017a] stellen erstmalig das Potential von DOM generiert aus UAS-Daten gegenüber herkömmlichen gröber aufgelöstem LIDAR-Befliegungen für die Analyse von fein strukturierten Salzmarschländern heraus. Dafür befliegen sie die drei Salzmarschländer Youghall, Beresford und Pt. Carron im Osten Kanadas und generierten daraus die Oberflächenmodelle und Orthomosaik. Parallel dazu wurden RTK-GNSS-Messungen als Referenz an allen Standorten durchgeführt. Die Ergebnisse zeigen auf deskriptive Art, dass die UAS-Daten sehr viel genauer sind als die LIDAR-Befliegungen. Die Generierung von Digitalen Geländemodellen aus LIDAR-Daten von flugzeuggestützten Befliegungen sind aufgrund der zu groben räumlichen Auflösung und der sich daraus ergebenden zu groben Punktdichte in Marschen nicht möglich [PINTON et al. 2020]. Außerdem ist die Hangneigung in diesen Ökosystemen schwer zu berücksichtigen. Daher nutzen PINTON et al. [ebd.] auf der Insel Sapelo (USA) ein UAS mit LIDAR um in einem

Salzmarschland neben der Geländehöhe auch Vegetationsparameter wie Höhe und Dichte zu extrahieren. Der Vorteil bei der UAS-gestützten Datenaufnahme ist die sehr viel dichtere Punktwolke. Die Autoren entwickeln mathematische Modelle um die Parameter ohne weitere Metadaten zu generieren und berücksichtigten dabei auch die Hangneigung.

Fernerkundlich wurden zahlreiche Arbeiten in Salzwasser-Wattbereichen durchgeführt. Diese Arbeiten beruhen beinahe komplett auf Satellitendaten und zielten zum größten Teil auf die Klassifikation von Vegetationsarten, Habitattypen oder Sedimenten im Wattbereich ab.

Ökosystemare Vegetationsanalysen in Brackwasser- bzw. Süßwasser-Flussmarschen wurden bisher international kaum bis gar nicht publiziert (Stand: 05.11.2020). Dies liegt unter anderem an der schmalen Uferausprägung der Marschen und der Heterogenität dieser Ökosysteme, die durch die grobe räumliche Auflösung von Satellitendaten schwer abgebildet werden können. Daher entstehen hier neue Möglichkeiten für UAS-gestützte Daten, die in den letzten Jahren auch genutzt wurden. Jedoch beschränken sich diese Arbeiten auf interpretative und klassifikative Arbeiten. Nur eine Arbeit befasst sich mit der Ableitung von Parametern, wie der Biomasse, aus dem Pflanzenbestand. In der vorliegenden Arbeit werden hingegen verschiedenste Pflanzenparameter auf ihren statistischen Zusammenhang zu den multisensoralen UAS-Daten getestet und bei robusten Regressionsmodellen auf die Fläche übertragen.

3 Ökologische Grundlagen, Projekte und Untersuchungsgebiete

Die Ergebnisse dieser Arbeit wurden im Rahmen von zwei Forschungsprojekten erarbeitet. Dabei sind die klassifikativen Arbeiten zur Niedermoorvegetation im Projekt WETSCAPES (Abschnitt 3.1.1) und die Arbeiten zur multisensoralen multiplen Regression im Projekt TIBASS (Abschnitt 3.2.1) entstanden.

Zunächst wird die Thematik Moore, Entwässerung und Wiedervernässung eingeführt. Anschließend wird kurz das Projekt WETSCAPES beschrieben und die Untersuchungsstandorte im Projekt vorgestellt. Im zweiten Teil werden zunächst Marschlandschaften vorgestellt. Danach wird das Projekt TIBASS und die dazugehörigen Untersuchungsstandorte beschrieben.

3.1 Niedermooere, Entwässerung und Wiedervernässung

Moore sind Landschaften, in denen sich abgestorbene, nur teilweise zersetzte Pflanzenreste zu Torf-Schichten bzw. Horizonten akkumulieren [SUCCOW und JOOSTEN 2001]. Dies geschieht durch permanente Wassersättigung des Bodens und dem damit fehlenden Sauerstoff für Abbauprozesse. Laut deutscher Bodensystematik [AD-HOC-AG BODEN 2015] wird vom Moor gesprochen, wenn die Torfschicht aus mindestens 30 cm organischer Auflage besteht, welche einen Kohlenstoffgehalt von über 30 % besitzt.

Moore sind Regulatoren des Regionalklimas und wichtig für den globalen Klimaschutz. Moore steuern den Wasserhaushalt einer Landschaft und sind wichtig für den Erhalt natürlicher Bodenfunktionen. Sie sind Archiv der Natur- und Kulturgeschichte, besonderer Lebensraum für spezielle Flora und Fauna und natürliche Filterräume für Nährstoffe [SUCCOW und JOOSTEN 2001].

Weil die Pflanzenreste zu 50–60 % aus Kohlenstoff bestehen, enthalten Moore von allen terrestrischen Ökosystemen die höchste Konzentration an Kohlenstoff. Moore bedecken nur etwa 3 % der globalen Landfläche (4 Mio. km²), aber speichern 21–25 % Kohlenstoff aller terrestrischen Ökosysteme [SUCCOW und JOOSTEN 2001; YU et al. 2010; JOOSTEN et al. 2016; CONNOLLY und HOLDEN 2017; LEIFELD und MENICETTI 2018]. Kein anderes Ökosystem speichert mehr Kohlenstoff pro Quadratmeter [DISE 2009], aber dieser Kohlenstoffspeicher reagiert sehr sensibel auf äußere Störungen [TURETSKY et al. 2015]. Die heutigen Störungen sind mehrheitlich anthropogen verursacht [MITSCH und GOSSELINK 2000; JUNK et al. 2013; DAVIDSON

2014; BERHANE et al. 2018]. Die größte anthropogene Störung stellt die großräumige Entwässerung dar, um die Flächen in eine agrarische, forstwirtschaftliche oder Torfstich-Nutzung zu überführen [PARRY et al. 2014]. Die Studienlage geht von einem globalen Flächenverlust von 30–90 % aus. Dadurch haben Moore ihre Funktionen für Nährstoff- und Wasserversorgung, Wasserreinigung und Lebensraum für teils seltene Flora und Fauna verloren [SUCCOW und JOOSTEN 2001; TIMMERMANN et al. 2009]. Dieser Verlust geht einher mit verschiedenen negativen Auswirkungen auf die Biodiversität [LEHOSMAA et al. 2017], Treibhausgasemissionen [CAO et al. 2018; LAINE et al. 2019], Nährstoffauswaschung [KOSKINEN et al. 2011], Erosion [TUUKKANEN et al. 2016] und andere Prozesse wie Versauerung [TORABI HAGHIGHI et al. 2018]. Die weitreichende Entwässerung führte dazu, dass Moore von moderaten Kohlenstoffsenken zu enormen Quellen von Treibhausgas (THG)-Emissionen im globalen Maßstab wurden [BYRNE et al. 2004; KNOTH et al. 2013; CONNOLLY und HOLDEN 2017]. Allein in den letzten 30 Jahren stiegen die Kohlenstoffdioxid-Emissionen um rund 20 % mit zukünftig lang-anhaltendem Trend [JOOSTEN 2009; LEIFELD und MENICETTI 2018]. Weiterführende Literatur über die Degradierung, Entwässerung und deren Auswirkungen sowie den derzeitigen Zustand von Mooren ist zu finden in SUCCOW und JOOSTEN [2001], JOOSTEN [2009], TIMMERMANN et al. [2009] und MOEN et al. [2017].

Moore in Deutschland und Mecklenburg-Vorpommern

Deutschlands Moorflächen haben mit 1,4 Mio. ha (rund 4 %) einen nur sehr geringen Anteil an der Gesamtfläche des Landes (35,7 Mio. ha) und deren Verteilung ist sehr heterogen [MOEN et al. 2017]. Die vier nördlichen Bundesländer (Schleswig-Holstein, Niedersachsen, Mecklenburg-Vorpommern und Brandenburg) haben den größten Flächenanteil an Mooren, wobei in Niedersachsen der Großteil deutscher Hochmoore zu finden ist. Niedermoore sind in allen vier Ländern stark vertreten, wobei MV mit 13 % die höchste Dichte besitzt [LM M-V 2009; FRICK et al. 2011; KOCH und JURASINSKI 2015].

Nur etwa ein Prozent deutscher Moore können noch als naturnah bezeichnet werden. Der Rest ist entwässert und wird als Agrar-, Forst- oder Grünlandfläche genutzt. Historisch sind besonders zwei Phasen zu nennen, in denen Entwässerungen im großen Stil vorgenommen wurden. Zum einen umfasst das eine längere Periode seit Beginn der Industrialisierung ab den 1850er Jahren. Zum anderen betrifft das die Programme zur Komplex-Melioration der *Deutschen Demokratischen Republik* in den 1970/80er Jahren [SUCCOW und JOOSTEN 2001].

Nach der politischen Wende 1989/90 führten in den 1990er Jahren verschiedene Faktoren wie hohe Entwässerungskosten, Landnutzungswandel, wachsendes Umweltbewusstsein und Überproduktion zur Extensivierung der Grünlandwirtschaft auf den landwirtschaftlich suboptimalen Torfböden. Dieser Sachverhalt und die langfristigen negativen Auswirkungen auf das Klima führten und führen auch derzeit zu einem Umdenken in der Nutzung ehemaliger Moorböden. Außerdem leitet sich für Deutschland mit der Unterzeichnung des Pariser Klimaschutzabkommen 2015 das Ziel einer Kohlenstoffneutralität bis spätestens 2050 ab, dass auch im Klimaschutzplan 2050 der Bundesregierung klar benannt wird [ABEL et al. 2019]. Die




Abbildung 3.1: Treibhausgas-Emissionen (in Tonnen CO₂-Äquivalente) in MV pro Jahr (verändert nach HIRSCHMANN et al. [2020])

Berücksichtigung der Moore ist dabei unverzichtbar, weil die 17.800 km² entwässerten, vor allem landwirtschaftlich genutzten Moore mit 51 Mio. t CO₂-Äq. 5,7 % der gesamten deutschen THG-Emissionen produzieren. Für MV konnte gezeigt werden (Abbildung 3.1), dass entwässerte Moore der Hauptverursacher für THG-Emissionen sind [GMC 2019; HIRSCHMANN et al. 2020].

Die wichtigste Maßnahme, um Emissionen aus Mooren zu reduzieren, ist ihre Wiedervernässung. BONN et al. [2016] geben einen weitreichenden Überblick über die Möglichkeiten einer Moor-Renaturierung durch Wiedervernässung. Die permanente oder temporäre Wiedervernässung führt zu nährstoffreichen Feuchtgebieten, wo torfbildende Vegetation durch natürliche Sukzession neu entstehen kann [TIMMERMANN et al. 2006; KOCH und JURASINSKI 2015; TORABI HAGHIGHI et al. 2018]. Die regionalen Renaturierungsziele sind den Torfabbau zu stoppen und ein selbstregulierendes Ökosystem zu kreieren, welches Torf Neubildet und wo sich torfbildende Vegetationsarten neu etablieren [GELBRECHT und ZAK 2004]. Diese Ziele implizieren, dass die Sukzession die Dominanz und Struktur der vorkommenden Vegetation verändert [TIMMERMANN et al. 2006] von überwiegend Grünlandarten hin zu torfbildenden Pflanzen wie *Phragmites spec.* (Schilf), *Typha spec.* (Rohrkolben) oder *Carex spec.* (Seggen). Außerdem hat (neben dem Wasserstand) die Vegetationszusammensetzung eines wiedervernässten Moores einen fundamentalen Effekt auf die THG-Emissionen und somit die Senken- bzw. Quellenfunktion von Kohlenstoff [HOBBIE 1996; COUWENBERG et al. 2011; KNOTH et al. 2013] und ist ein Proxy für die hydrologischen Verhältnisse und die Biodiversität. In der Vergangenheit wurden künstliche Entwässerungsanlagen und die Eindeichung gestoppt, teilweise geplant teils aber auch ungeplant. Seit 1980 wurden in Deutschland etwa 70.000 ha Moore wiederver-

nässt, meist verbunden mit Nutzungsaufgabe und Naturentwicklung [ABEL et al. 2019]. Laut LM M-V [2017] wurden rund 26.000 ha Niedermoore auf diesem Weg in Nordostdeutschland wiedervernässt. Um bis 2050 alle CO₂-Emissionen aus Mooren in Deutschland einzusparen, wäre es laut ABEL et al. [2019] erforderlich, entlang eines Transformationspfades schrittweise ca. 50.000 ha jährlich wiederzuvernässen.

Nach der Wiedervernässung kann die natürliche Sukzession Jahre oder Jahrzehnte in Anspruch nehmen. Erfolg oder Misserfolg von Wiedervernässungsprogrammen können erst nach längerer Zeit überprüft werden [POULIOT et al. 2011], oder die Entwicklung der Flächen wird Schritt für Schritt regelmäßig nach bestimmten Kriterien bewertet [KNOTH et al. 2013]. Daher sollten Monitoringkonzepte entwickelt werden, die eine operationelle, schnelle Durchführung und räumliche Abdeckung gewährleisten [MALAK und HILARIDES 2016] und welche regional angepasst werden [FRICK et al. 2011]. Diese Arbeit prüft daher das Potential von multisensoralen UAS-Daten für diese Aufgabe.

3.1.1 Projekt WETSCAPES

WETSCAPES ist ein Verbundprojekt der Universitäten Rostock und Greifswald. Assoziiert sind weitere Forschungseinrichtungen wie bspw. das Deutsche Zentrum für Luft- und Raumfahrt und das Greifswald Moorzentrum. Im Projekt werden die Themenkomplexe Primärproduktion, Stoffumsetzungen und -verlagerung, Gasaustausch und Torfbildung an Moor-, Feucht- und Küstenstandorten interdisziplinär untersucht. Die Verbundpartner verfolgen das Ziel, wissenschaftliche Grundlagen für eine nachhaltige, schonende Bewirtschaftung der Niedermoore und feuchten Küstenstandorte, speziell degradierter und dann wiedervernässter Flächen, zu erarbeiten. Das Vorhaben wird im Rahmen des Exzellenzforschungsprogramms des Landes Mecklenburg-Vorpommern über einen Zeitraum von vier Jahren und drei Monaten, vom 01.01.2017 bis 31.03.2021, aus dem Europäischen Sozialfonds gefördert (ESF/14-BM-A55-0032/16).

Im Projekt kooperieren die verschiedensten Fachgruppen der Universitäten, dazu zählen Grünland und Futterbauwissenschaften, Bodenphysik, Bodenkunde, Landschaftsökologie und Standortkunde, Geodäsie und Geoinformatik, Moorkunde und Paläoökologie, Bakterienphysiologie, Experimentelle Pflanzenökologie und Ökosystemdynamik.

Das Arbeitspaket WP12, inhaltlich der Fernerkundung zuzuordnen, ist die Grundlage für die vorliegende Arbeit. Im Projekt wurde die Vegetation als der zentrale und wesentliche Proxy identifiziert, um aus Fernerkundungsdaten umweltwissenschaftliche Fragestellungen zu untersuchen. Daher war der erste Schritt ein Monitoringkonzept zu erstellen, um die Vegetationszusammensetzung auf den verschiedenen Niedermoorstandorten zu klassifizieren.

3.1.2 Untersuchungsgebiete der Niedermoore

Im Projekt wurden verschiedene Niedermoor Typen in MV untersucht. In dieser Arbeit werden davon drei Standorte untersucht, ein wiedervernässtes Durchströmungsmoor bei Tribsees, ein Küstenüberflutungsmoor bei Greifswald, welches teilweise

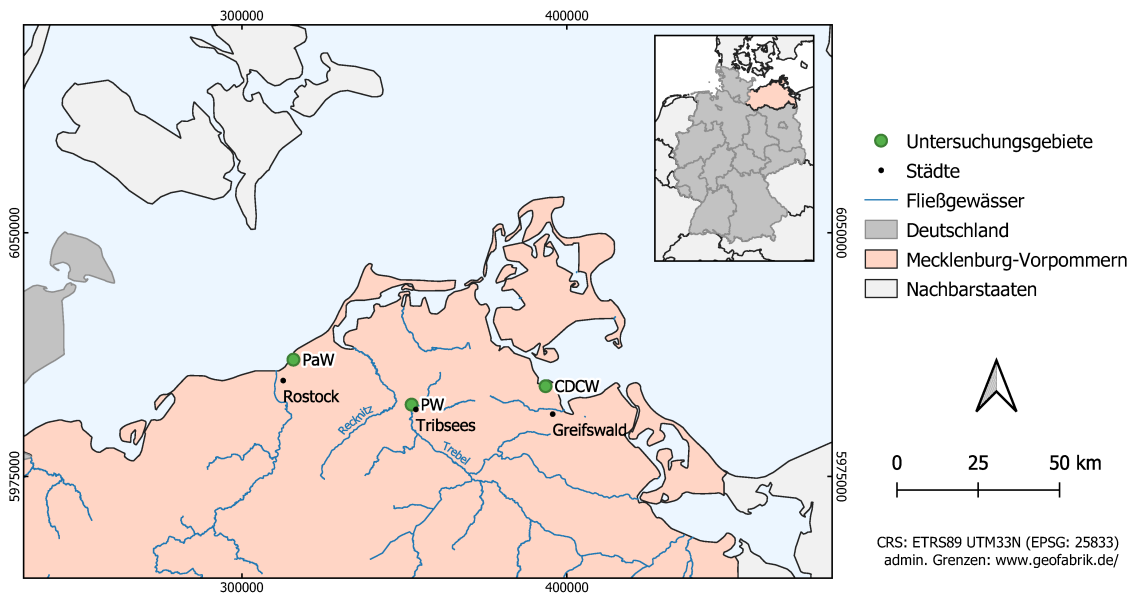


Abbildung 3.2: Übersicht der drei Niedermoor-Standorte an denen klassifikative Vegetationsarbeiten auf Basis von multisensoralen Drohnendaten durchgeführt wurden. PaW = Versumpfungsmoor Hüttelmoor, PW = Durchströmungsmoor, CDCW = Küstenüberflutungsmoor.

entwässert und unter Nutzung steht, sowie teilweise wiedervernässt ist und ein Küstenversumpfungsmoor bei Rostock. Abbildung 3.2 zeigt die geographische Lage der drei Niedermoorstandorte.

Durchströmungsmoor Tribsees (PW)

Das Untersuchungsgebiet PW (*Percolation mire reWetted*, WGS84: N 54.1011°, O 12.7395°) bei Tribsees ist ein wiedervernässtes Durchströmungsmoor im fluvialen Einzugsgebiet der Trebel (Abbildung 3.3). Das Niedermoor liegt unmittelbar benachbart zum Grenztaalmoor, welches direkt auf der Talwasserscheide zwischen dem Fluss Recknitz im Westen und dem Fluss Trebel im Osten liegt (Abbildung 3.2).

Die Fläche von PW beträgt circa acht Hektar. Schon seit dem frühen 19. Jahrhundert wurde die Fläche entwässert. Die Gründe dafür waren zum einen der Torfabbau und zum anderen die intensive Grünlandwirtschaft. Besonders stark wurde in den Jahrzehnten vor der politischen Wende (1989/90) entwässert und die Nutzung intensiviert. Im Zuge der politisch, gesellschaftlichen und wirtschaftlichen Veränderungen nach 1990, wurde die Fläche mehr und mehr extensiv genutzt. PW wurde 1997 als Teil des EU-Förderprogrammes *LIFE* (Flusstalmoore Recknitz und Mittlere Trebel) wiedervernässt [IGAMBERDIEV et al. 2013; LM M-V 2017].

Seit dieser Zeit fanden Forschungsarbeiten auf der Fläche hinsichtlich des Wiedervernässungsfortschritts, der Vegetationsentwicklung, der Treibhausgasemissionen und der Torfbildungsprozesse statt [IGAMBERDIEV et al. 2013; JURASINSKI et al. 2016]. Typische Vegetationsarten wie *Phragmites australis*¹, *Typha latifolia* und ver-

¹Die Tabelle A.1 in Anhang A.1 listet alle, in der Arbeit verwendete, Pflanzennamen in wissenschaftlicher und deutscher Form auf.

3.1. NIEDERMOORE, ENTWÄSSERUNG UND WIEDERVERNÄSSUNG

(a) Untersuchungsfläche PW (weiß), die Ortschaft Tribsees im Hintergrund, Blickrichtung Ost (Schrägbildaufnahme 18.07.2019).



(b) Multispektrale UAS-Aufnahme vom 04.05.2018 (Color-Infrarot-Darstellung).




Abbildung 3.3: Untersuchungsgebiet PW, ein wiedervernässtes Durchströmungsmoor bei Tribsees (MV).




Abbildung 3.4: Untersuchungsgebiet CDCW, ein Küstenüberflutungsmoor auf den Karrendorfer Wiesen (MV). Multispektrale UAS-Aufnahme vom 04.05.2018 (Color-Infrarot-Darstellung)

schiedene *Carex spec.* sind auf der Fläche zu finden und bilden eine typische Patch-Struktur aus (mehr Informationen zum Vegetationsbestand folgen in den Abschnitten 4.3 und 6.2).

Küstenüberflutungsmoor Karrendorfer Wiesen (CDCW)

Das Untersuchungsgebiet CDCW (WGS84: N 54.1576°, E 13.3860°) ist Teil eines größeren Komplexes von aus- und eingedeichten Küstenüberflutungsmooren auf den *Karrendorfer Wiesen* (Abbildung 3.4). Die *Karrendorfer Wiesen* sind eine Halbinsel am Greifswalder Bodden zwischen Greifswald und Stralsund. Die Fläche von CDCW beträgt circa 12 Hektar.

Die *Karrendorfer Wiesen* wurden 1850/51 eingedeicht und in Ackerland bzw. in Grünland überführt. In den 1970er Jahren wurde die Entwässerung nochmals intensiviert. Frühe Satellitenbilder (Abbildung 3.5) aus den 1980er Jahren zeigen, dass die komplette Halbinsel agrarwirtschaftlich genutzt wurde (Abbildung 3.5a). Nach der Ausdeichung großer Teile der Halbinsel, sind nun auch wasserbestandene Flächen entstanden und landwirtschaftliche Strukturen nicht mehr zu erkennen (Abbildung 3.5b). Am Übergangsbereich vom bewirtschafteten Deichhinterland zum ausgedeichten Bereich befindet sich das Untersuchungsgebiet CDCW (gelber Kasten).

Küstenüberflutungsmoore sind das Resultat aperiodischer Überflutungsereignisse und dem erneuten Trockenfallen des Torfkörpers. Dementsprechend wechseln sich

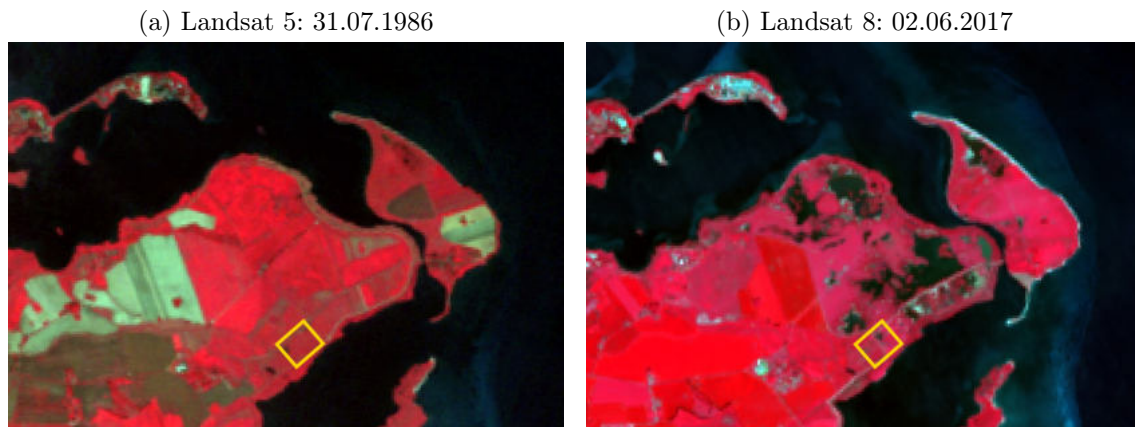


Abbildung 3.5: *Karrendorfer Wiesen* (a) landwirtschaftlich geprägt (Landsat 5-Aufnahme, 31.07.1986, Bandkombination 4|3|2) und (b) ausgedeicht bzw. wiedervernässt (Landsat 8-Aufnahme, 02.06.2017, Bandkombination 5|4|3). Das gelbe Rechteck markiert die Lage des Untersuchungsgebietes.

oft silikatische und organogene Schichten ab. Es bildeten sich hauptsächlich Schilftorfe. Mit einsetzender Beweidung änderte sich aber die Zusammensetzung neuer Torfschichten hin zu mineralstoffreichem Salzwiesentorf [HOLZ et al. 1996].

Im Jahr 1993 wurden die Deiche entfernt und ein neuer Deich wurde im Hinterland gebaut. Dadurch sollten natürliche Flutdynamiken in den ausgedeichten quasi wiedervernässten Flächen CW (*Coastal mire reWetted*) wiederhergestellt werden. CW wird derzeit jedoch gleichzeitig als extensives Weideland genutzt. Hauptvegetationstypen sind unter anderem *Agrostis stolonifera*, *Calamagrostis epigejos* und *Juncus gerardii*.

Der noch eingedeichte quasi *entwässerte* Teil CD (*Coastal mire Drained*) wird weiterhin als Grünland wirtschaftlich genutzt. Dieser Teil zeichnet sich durch eine besonders ausgeprägte Patch-Struktur aus. Typische Arten sind bspw. *Deschampsia cespitosa*, *Juncus effusus* und ebenfalls *Calamagrostis epigejos*.

Versumpfungsmoor Hütelmoor (PaW)

Das Untersuchungsgebiet PaW (*Paludification mire reWetted*, WGS84: N 54.211°, E 12.178°) ist ein Küsten-Versumpfungsmoor im Naturpark *Heiligensee und Hütelmoor*, lokalisiert im Nord-Osten der Stadt Rostock (Abbildungen 3.2 und 3.6). Das Niedermoor hat eine Nord-Süd-Ausdehnung von circa 1.6 km und eine West-Ost-Ausdehnung von etwa 1.4 km. Im südlichen Teil des Untersuchungsgebietes befindet sich ein wenige Hektar großes Hochmoor. Bis 1963 wurde die Fläche episodisch von der Ostsee mit Brackwasser überschwemmt. Danach wurde ein Dünendeich gebaut und das Niedermoor wurde nahezu komplett hydrologisch isoliert vom Salzwasser. Das führte dazu, dass der Vegetationsbestand sich ausschließlich mit Süßwasser entwickelte [KOEBSCH et al. 2013]. Das Gebiet wurde seit den frühen 1960ern und besonders ab den 1970ern stark entwässert (bis zu 1.6 m unter Flur) und als Grasland intensiv genutzt (Abbildung 3.7a). Zweimal im Jahr wurde die Fläche für




Abbildung 3.6: Multispektrale UAS-Aufnahme vom 01.11.2018 vom Untersuchungsgebiet Versumpfungsmoor Hütelmoor.




Abbildung 3.7: *Hütelmoor* (a) landwirtschaftlich geprägt (Landsat 5-Aufnahme, 21.06.1984, Bandkombination 4|3|2) und (b) wiedervernässt (Landsat 8-Aufnahme, 28.06.2018, Bandkombination 5|4|3). Das gelbe Rechteck markiert die Lage des Untersuchungsgebietes.

die Heuproduktion gemächt.

Ökonomische Bedingungen nach der deutschen Wiedervereinigung 1989/90 führten auch im Untersuchungsgebiet zu einer veränderten Nutzung. Die aktive Entwässerung wurde zu dieser Zeit eingestellt, was zu einem Anstieg des Wasserstandes führte. Der mittlere Wasserstand während der Vegetationszeit war zu dieser Zeit nah der Geländeoberkante. Im Winter kam es jedoch oft zur Überstauung, in den Sommermonaten konnte der Wasserstand bis zu 70 cm unter Geländeoberkante sinken. Dies führte in dieser Periode weiterhin zur Mineralisation des Torfkörpers, der 2010 als stark zersetzter Torfboden (sapric Histosol) klassifiziert wurde.

Im Winter 2009/2010 wurde schließlich eine Stauschwelle installiert, um Wasser im Einzugsbereich zu halten. Das Ziel dieser Maßnahme war es die Torfzersetzung zu stoppen, ein selbstregulierendes Ökosystem mit torfbildender Vegetation ohne menschliche Aktivitäten zu schaffen und eine hydrologische Schutzzone für das Hochmoor zu etablieren [SUCCOW und JOOSTEN 2001]. Dabei entstanden nun Zonen ganzjähriger Überstauung (Abbildung 3.7b). Das als *Low Cost*-Projekt geplante Vorhaben hatte keine spezifischen Pläne für spezielle Vegetationstypen. Es wurde vermutet, dass Schilf (*Phragmites australis*) das Gebiet dominieren würde. Mittlere jährliche Wasserstände betragen seit 2011 zwischen 0,27 m bis 0,51 m +/- 0,5 m über der Geländeoberkante mit räumlicher Variabilität. Vor dem Dammbau und der permanenten Überstauung wurde das Gebiet schon dominiert von Hydrophyten mit einer Patch-Struktur. Dazu zählten dichte *Phragmites australis*-Bestände, welche sich um die Entwässerungsgräben ansiedelten. Hinzu kommen große Seggen-Bestände (bspw. *Carex acutiformis*) welche sich in trockenen Zonen entwickelten. Außerdem waren Bestände von Binsen (*Bolboschoenus maritimus* und *Schoenoplectus tabernaemontani* typisch für Brackwasserregime) sowie reichlich Überreste der vorherigen Graslandnutzung zu finden [KOCH et al. 2017]. Letztere treten heute nur noch im Saum zwischen Moorfläche und Waldgebiet auf.

Neben der Klassifikation der vorkommenden Arten am Standort, soll in der vorliegenden Arbeit die Auswirkungen der extremen Sommerdürre 2018 auf das wiedervernässte Moor untersucht werden. Das Dürreereignis hatte einen starken Einfluss auf den Standort, der mithilfe der Fernerkundungsdaten klassifikativ quantifiziert werden soll.

Wie außergewöhnlich das Klimaereignis 2018 war ist in Abbildung 3.8 zu sehen [BEYER et al. 2020]. Anhand der Tagestemperaturen (Abbildung 3.8a) ist kein extremer Trend zu erkennen, jedoch für die anderen gezeigten Parameter. Die Niederschläge (Abbildung 3.8b) waren 2018 bis etwa April durchschnittlich bis temporär sogar überdurchschnittlich, setzten danach jedoch auch überdurchschnittlich aus, sodass am Ende des Jahres für den betrachteten Zeitraum ein Rekordtief von 457 mm erreicht wurde. Das ist eine Differenz von 168 mm zum Durchschnitt des Referenzzeitraum (1999–2017, Mittelwert (MW) = 625 mm, Standardabweichung (STD) = 127 mm). Auch die Globalstrahlung zeigte ein eindeutiges Signal der Dürre 2018 (Abbildung 3.8c). Verließ das Strahlungswetter in der ersten Hälfte des Jahres noch normal, so stieg die Strahlungsbilanz in der zweiten Jahreshälfte überdurchschnittlich an, sodass mit einer kumulativen Strahlungssumme von 2.370 kW/m² ein neuer Rekord gegenüber dem Referenzzeitraum (MW = 2.144 kW/m², STD = 73,5 kW/m²) erreicht wurde. Besonders deutlich wird jedoch die Auswirkung der Dürre beim

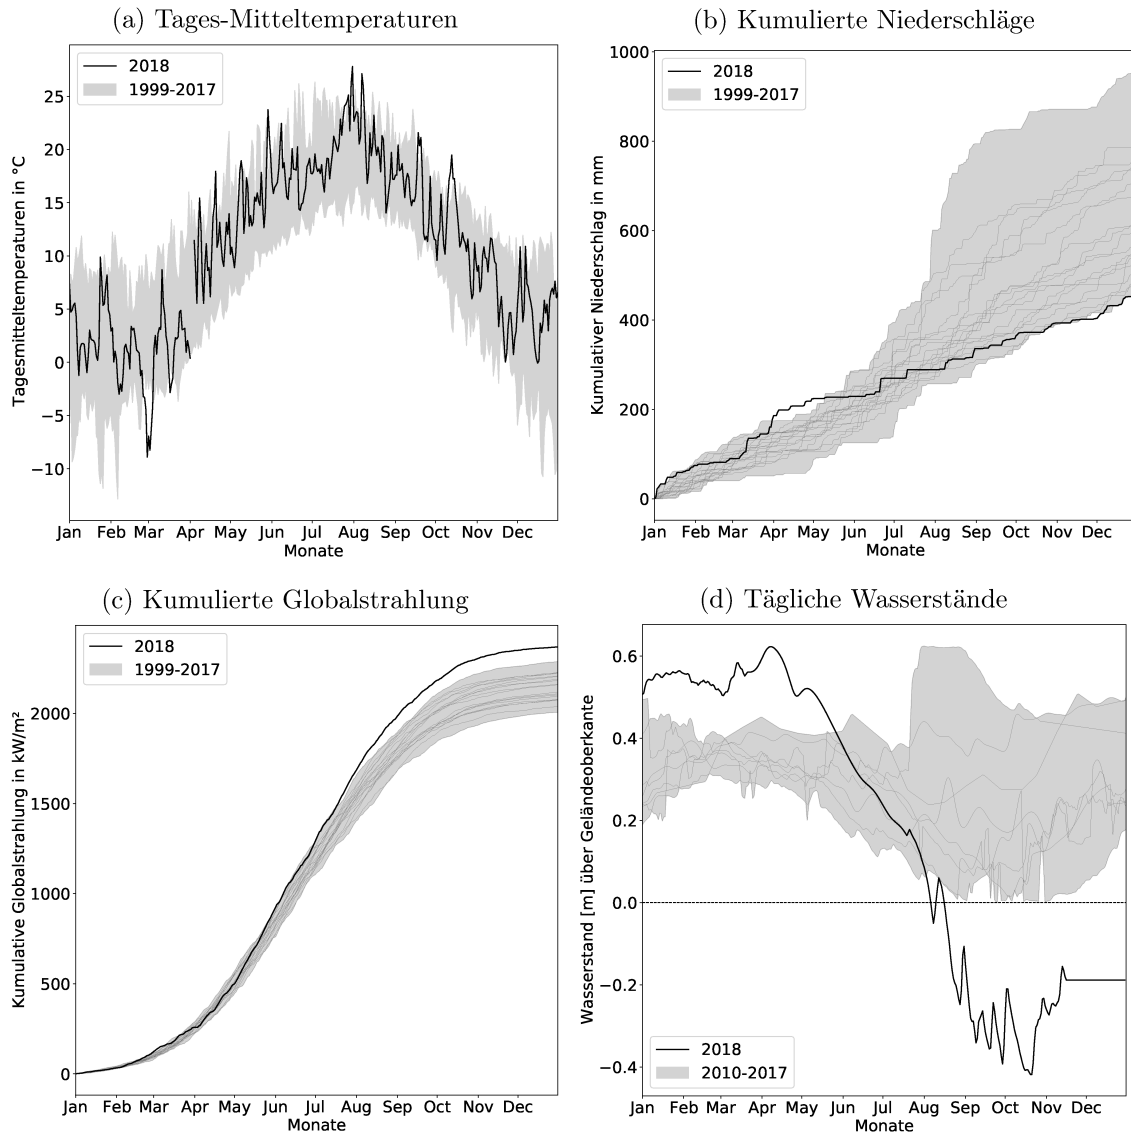


Abbildung 3.8: Tagesmitteltemperaturen (a), kumulierte Niederschläge (b), kumulierte Globalstrahlung (c) und Wasserstände über Geländeoberkante (d) im Jahresverlauf. Die schwarze Linie repräsentiert die Messwerte 2018 und die graue Fläche repräsentiert den Wertebereich (Minimum–Maximum) der Referenzperiode 1999–2017 bzw. 2010–2017 für die Wasserstände. [BEYER et al. 2020].

Vergleich der Wasserstandsmessungen über Geländeoberkante (Abbildung 3.8d) für den Zeitraum 2010 bis 2017 mit denen von 2018. Der Wasserstand war in der ersten Hälfte 2018 ungewöhnlich hoch, da das Jahr 2017 durch sehr hohe Niederschläge geprägt war. So betrug der Niederschlag 2017 746 mm. Ab etwa Mitte April 2018 setzte jedoch ein starker Abfall des Wasserspiegels ein, der sich durch anhaltendes Strahlungswetter und ausbleibende Niederschläge langfristig verstärkte. Ab etwa August fiel der Wasserspiegel unter Geländeoberkante und sank auf ein Rekordtief von -0,42 m, was seit Beginn der Wiedervernässung ein einmaliges Ereignis war.

Um tatsächliche Auswirkungen des Dürrejahres zu beurteilen, werden Vorarbei-

ten aus KOCH et al. [2017] zum Vergleich herangezogen. KOCH et al. [ebd.] haben die ersten vier Jahre nach der Wiedervernässung den Standort PaW kleinräumiger mit klassifikativen Arbeiten basierend auf RGB-Drohnenfotos begleitet, um die Entwicklung der Vegetation zu verfolgen.

3.2 Tide-beeinflusste Flussmarschen Nordwestdeutschlands

Der Begriff *Marsch* wird wissenschaftshistorisch in verschiedenen Ländern unterschiedlich breit abgegrenzt und charakterisiert. In der vorliegenden Arbeit wird die deutsche Definition der Marsch als Landschaftsform nach BEHRE et al. [2002] verwendet. Demnach ist die Marschlandschaft im Allgemeinen ein flaches Gebiet mit sehr niedriger Reliefenergie. Sie besteht aus fluvial oder marin transportierten und abgelagerten Sedimenten und befindet sich auf bzw. sehr nah am Niveau des Meeresspiegels. Marschen entstehen durch tide-bedingte periodische Überschwemmungen (Gezeiten) und damit verbundenen Sedimenttransport sowie -ablagerung. Als Marschland wird die vegetationsbestandene Zone zwischen Watt (meerseitig) und Geest (landseitig) bezeichnet. So beginnt die Marsch bzw. endet das Watt mit dem beginnenden Vegetationsaum, der in etwa auf dem Niveau des mittleren Tidehochwassers (MThw) liegt. Die Marsch ist ein Ökoton, also ein aus bestimmten Vegetationsarten bestehendes Übergangssystem, zwischen aquatischen und terrestrischen Ökosystemen [HEUNER 2016]. Die Vegetation wird in solchen regelmäßig überschwemmten Ökosystemen als azonal eingestuft, da sie hauptsächlich durch nicht-klimatische Faktoren bestimmt wird, während die Verbreitung der zonalen Vegetation hauptsächlich durch die klimatischen Bedingungen begrenzt ist [METZING und GERLACH 2001]. Die Marschvegetation zeichnet sich durch krautige Pflanzen aus, die häufig im Wasser auftreten [KEDDY 2010]. Daher werden diese Pflanzen auch als emergente Makrophyten oder Helophyten bezeichnet. Sie bilden oft monospezifische Pflanzenzonen.

Genetisch werden die Marschen in drei abiotische Gradienten eingeordnet, die auch ihr Sedimentmuster beeinflussen [RAFFAELLI und HAWKINS 1996]:

Vertikaler Gradient Der vertikale Gradient wird auch als Höhengradient bezeichnet und erstreckt sich vom Wasser zum Land. Er spiegelt die Überflutungsdauer und die Überschwemmungshäufigkeit wider.

Horizontaler Gradient Der horizontale Gradient wird auch als Expositionsgradient bezeichnet und erstreckt sich von exponierten zu geschützten Küstenlinien. Dabei wird die Exposition gegenüber windinduzierten Wellen unterschieden von den Wellen, die durch Schiffe verursacht werden.

Longitudinaler Gradient Der longitudinale Gradient wird durch zwei Parameter beschrieben, dem Salzgehalt und des Tidenhubs. Der Salzgehaltsgradient reicht vom Meerwasser an den Salzmarschküsten bis zum Süßwasser in den tide-beeinflussten Ästuaren. Der Gezeitengradient erstreckt sich vom Makrotidal (< 4 m) über das Mesotidal bis zum Mikrotidal (< 2 m) und mündet in reinen Flussverläufen. Daher kann er auch als tide-fluvialer Gradient beschrieben werden.


Marschen werden gemäß dem longitudinalen Gradienten feiner untergliedert in See- bzw. Salzmarschen, Übergangs- bzw. Brackwassermarschen und Fluss- bzw. Süßwassermarschen [BEHRE et al. 2002]. Neben den typischen Seemarschgebieten angrenzend an den nordwestdeutschen, niederländischen und dänischen Wattgebieten, der Nordsee sind hier Flussmarschen der gezeitenbeeinflussten Tideflüsse dieser Region zu nennen. Dazu gehören die Flussästuare der Schelde, Maas, Ems, Weser, Elbe, Oste, Stör, Eider, Varde Å und die Themse. Mit ca. 500 km Längenausdehnung bildet dieses Gebiet global das größte Marschlandvorkommen. Aufgrund des von der Nordsee einströmenden Salzwassers während der Flut kommt es in den Ästuaren zu einer Übergangszone von Salzwasser zu Süßwasser und entsprechenden speziellen Brackwassermarschen. Geologisch betrachtet, sind die norddeutschen Marschböden eine sehr junge (quartäre) Dezimeter bis wenige Meter mächtige Schicht über den pleistozänen Geestablagerungen.

In der Elbe wirkt sich die Tide von Cuxhaven bis nach Geesthacht ins Landesinnere aus [BFG 2018]. Besonders im Bereich zwischen Hamburg und Cuxhaven hat sich im Deichvorland neben der ausgeprägten Grünlandwirtschaft ein schmaler Ufersaum an Röhrichten gebildet. Dieser strukturreiche Lebensraum besitzt zahlreiche schützenswerte Arten der Flora und Fauna, weshalb diese Bereiche oft Vogel-, Naturschutz- und Flora-Fauna-Habitat (FFH)-Gebiete sind. Entlang der ungenutzten Uferzonen bilden sich Röhrichtgürtel bis zum offenen Watt aus. Die Hauptarten *Phragmites australis*, *Bolboschoenus maritimus* und *Schoenoplectus tabernaemontani* bilden dabei Zonen in denen sie dominant auftreten (Abbildung 3.9). Die schematische Darstellung in Abbildung 3.9a zeigt die Entwicklung der drei Zonen in Abhängigkeit zur Geländehöhe und den mittleren Tidewasserständen. Wie auch in den Schrägluftbildern (Abbildungen 3.9b und 3.9c) zu sehen ist, können die Zonen stratigraphisch vom Watt aus abgegrenzt werden, beginnend mit einem unregelmäßigen Verlauf aus *Schoenoplectus tabernaemontani* gefolgt von einer oft breiten Zone aus *Bolboschoenus maritimus* und einer meist scharfen Grenze zu *Phragmites australis*. Außerdem kann sich im Übergang von *Bolboschoenus maritimus* und *Phragmites australis* auch ein patch-artiger Saum aus dominant auftretenden *Phalaris arundinacea* bilden (Abbildung 3.9c).


Die Röhrichte erfüllen dabei neben ihrer schützenswerten ökologischen Funktion, auch eine wichtige Rolle zur Ufersicherung weil sie gut angepasst sind an die täglichen tide-bedingten Überschwemmungen und dem durch Schiffsverkehr verursachten Wellenschlag. Sie halten durch ihre Wurzeln das Sediment am Boden fest, verringern die Strömungsgeschwindigkeit, reduzieren die Wellenhöhe, filtern Schwebstoffe mit Stängeln und Blättern, belüften den Boden, binden Nährstoffe und fixieren CO₂.

Jedoch stehen diese Ökosysteme im Konkurrenzdruck und sind belastet durch diverse Faktoren, wie technische Ufersicherungen, Wellenschlag (Tide und Schifffahrt), Änderungen der Hydromorphologie und durch die Landnutzung (vor allem Landwirtschaft). Flussbegradigung, Fahrrinnenvertiefung, verstärkter Schiffsverkehr sowie klimatische Veränderungen verstärkten den Tidenhub in der Vergangenheit und verursachen stärker werdende hydrodynamische Belastungen. Flutkatastrophen stellten von jeher eine besondere Bedrohung gegenüber küstennahen Siedlungen und insbesondere großen Agglomerationsräumen dar. Im Zuge des globalen Wandels wird diese Gefahr zusätzlich noch durch höhere Frequenzen letztgenannter Ereignisse und steigendem Meeresspiegel verstärkt. TEMMERMAN et al. [2013] zeigen, dass quasi-

(a) Schema Vegetationsgradient in tide-beeinflussten Marschland



(b) Balje (BAL)



(c) Hollerwettern (HOL)



Abbildung 3.9: Schematische Darstellung der stratigraphischen Ausbildung der Vegetationsgürtel der dominanten Pflanzen *Phragmites australis* (PA), *Bolboschoenus maritimus* (BM), *Schoenoplectus tabernaemontani* (ST). (PhA = *Phalaris arundinacea*, W = Watt)

natürliche Ökosysteme wie Marschländer das Potential besitzen die Küste und deren Hinterland vor Flutkatastrophen zu schützen oder wenigstens stark zu mildern. Die dichte, an Nässe angepasste Vegetation reduziert die Intensität der Wellendynamik überproportional mit zunehmender Strecke [HEUNER 2016] und wächst durch kontinuierliche Sedimentation während der periodischen Überschwemmungen sowie mit steigendem Meeresspiegel mit [TEMMERMAN et al. 2013]. Künstliche Ufersicherungen sind zwar platzsparender, müssen jedoch regelmäßig gewartet und den sich verändernden Bedingungen angepasst werden. Außerdem gehen wichtige ökologische Funktionen dieser Ökosysteme bei der Konversion zu künstlichen Bauwerken verloren [ENGELS 2010; TEMMERMAN et al. 2013; HEUNER 2016].

Die Leistung der Wellenreduktion ist stark von der Vegetationsstruktur abhängig [YANG et al. 2012]. Einer der wichtigsten Faktoren ist die Stängeldichte der Pflanzen. Sie korreliert stark mit der Wellenreduktionsleistung, je dichter der Pflanzenbestand desto stärker ist die Reduktion der Wellenhöhe [HEUNER et al. 2015]. Die Stängeldichte steht im engen Zusammenhang mit der Biomasse. Weitere Einfluss-

faktoren sind die Geländehöhe und die Morphologie der dominanten Röhrichtarten. Arten mit flexibleren Stängeln sind gegenüber der Wellenbelastung toleranter, haben dagegen aber auch eine geringere Reduktionsleistung. Arten mit rigiden Stängeln und Blättern können höheren Wellenbelastungen schlechter standhalten, besitzen aber durch die stärkeren Widerstände eine höhere Wellenreduktionsleistung [BOUMA et al. 2005].

3.2.1 Projekt TIBASS

Das Projekt *TIBASS* (*Tidal Bank Science And Services*) war ein Verbundprojekt der Bundesanstalt für Gewässerkunde (BfG), Koblenz, der *Ecosystem Management Research Group* der Universität Antwerpen (Belgien) und dem Institut für Biologie und Umweltwissenschaften der Universität Oldenburg. Es wurden mögliche Vorteile von natürlich bewachsenen Ufern gegenüber technischen Ufersicherungen an verschiedenen Standorten der Elbe untersucht. Im Projekt wurden verschiedene Einflussfaktoren auf die Pflanzengesellschaften, wie der Salzgehalt, der Tidehub, die Strömungsgeschwindigkeiten und die Bodeneigenschaften, größtenteils auf punkthafter Geländeebene, untersucht. Außerdem standen die Wechselwirkungen zwischen den Pflanzen (z. B. Stängelhöhe, -dichte und -durchmesser, Blätter, Nährstoffgehalte) und die Auswirkungen der Pflanzengesellschaften auf die Wellenhöhe, die Strömungsgeschwindigkeiten der Elbe und auf das Erosions- und Sedimentationspotential der Ufer im Fokus. Aus diesen untersuchten Parametern sollte die Widerstandsfähigkeit der Ufer gegenüber hydraulischen Belastungen abgeleitet werden, indem die Wellenreduktion der Pflanzen, ihre Ökosystemfunktionen und notwendige Standortbedingungen quantifiziert werden [BFG 2018].

Das Steinbeis-Transferzentrum Geoinformatik Rostock hatte in diesem Rahmen einen Unterauftrag für das Projekt, um das Potential von UAS-Daten mit unterschiedlichen Sensorarten für die Beurteilung der Vegetationsstruktur zu untersuchen und die punkthaften Geländemessungen auf die Fläche zu übertragen. Teile dieser Ergebnisse sind Grundlage für die vorliegende Arbeit.

Ziele der Studie, die auch Teil dieser Arbeit waren, sind:

1. Welche Möglichkeiten bieten UAS-Daten, die punktuell gemessenen Pflanzenparameter in die Fläche zu extrapolieren?
2. Wie können die Zusammenhänge über die Fläche interpoliert werden?
3. Welche Vegetationsindizes können die Zusammenhänge stärken?
4. Welchen Vorteil bietet ein multisensoraler Ansatz, bei dem neben RGB-Daten auch multispektrale, thermale sowie photogrammetrisch abgeleitete Informationen inkludiert werden?

3.2.2 Untersuchungsgebiete der Tideelbe

Die Untersuchungsgebiete liegen an der Tideelbe zwischen Glücksstadt und Cuxhaven (Abbildung 3.10). Die in der Nähe liegenden Ortschaften Hollerwettern (HOL) und Balje (BAL) waren namensgebend für die beiden Gebiete, welche sich an den Elbekilometern 679 (HOL) und 701 (BAL) befinden. Beide liegen in der sogenannten

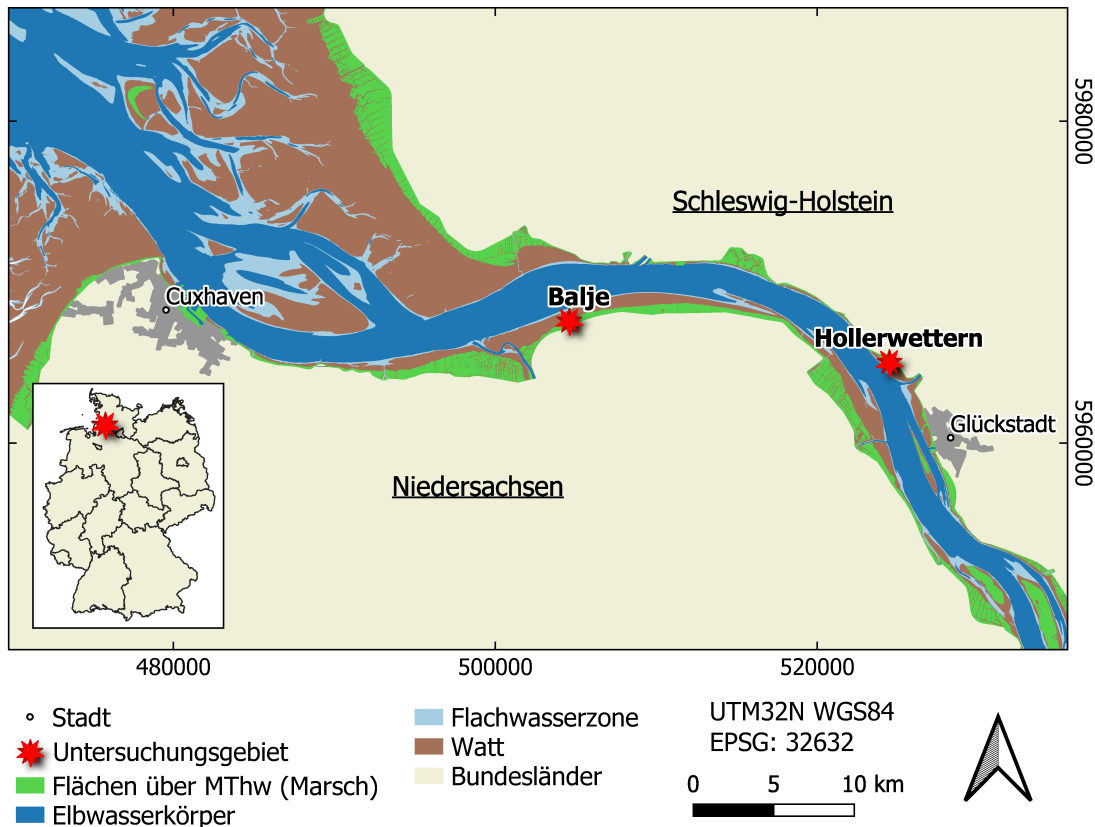


Abbildung 3.10: Untersuchungsstandorte des Projektes *tibass* Balje und Hollerwetteren am tide-beeinflussten Elbe-Ästuar (Datengrundlage: Basisdaten Elbe-Strom vom WASSERSTRASSEN- UND SCHIFFFAHRTSVERWALTUNG DES BUNDES [2020]), Landesgrenzen und Siedlungsflächen DLM250 vom BUNDESAMT FÜR KARTOGRAPHIE UND GEODÄSIE [2020])

mixo-mesohalinen bis polyhalinen Zone wo die Salzgehalte zwischen 5,1 bis 18,1 ‰ erreichen [BFG 2018]. Damit liegen beide Gebiete im Brackwasserbereich (5–30 ‰).

Balje (BAL)

Der Standort Balje (BAL, Abbildung 3.9b) liegt linksseitig an der Elbe (WGS84: N 53,857° O 9,071°). Das Gelände steigt von der Vegetationsgrenze der Elbe ungleichmäßig bis etwa zur Grenze der mittleren Hochwasserlinie an. Das Wattvorland ist bei Niedrigwasser mehrere 100 m breit und sehr flach. Der mergelige Boden der breiten *Bolboschoenus maritimus*-Zone (0,6–1,5 m ü. NHN) ist von einer Vielzahl von ca. 20–50 cm tiefen und etwa 30–60 cm breiten Rinnen durchzogen, die quer zur Hangrichtung verlaufen, was sich aber nicht an der Oberfläche der Pflanzenhöhen ableiten lässt. Anschließend steigt das Gelände kontinuierlich bis auf ca. 2 m ü. NHN zu dem Deich vorgelagerten Grünland an.

Die Vegetationsgrenze liegt bei etwa 0,4–0,5 m ü. NHN. Hauptpflanzenart des Untersuchungsgebiets ist *Bolboschoenus maritimus*. Als Ufervegetation wechseln sich *Schoenoplectus tabernaemontani* und *Bolboschoenus maritimus* ab. Die Breite der *Schoenoplectus tabernaemontani*-Zone variiert inselartig und liegt zwischen 1 und

ca. 20 m (Abbildung 3.9b). Die Pflanzendichte von *Schoenoplectus tabernaemontani* ist gering und der Boden ist oftmals von einem dichten immergrünen Algent Teppich überdeckt (Abbildung 3.11b). Die Pflanzenhöhe von *Bolboschoenus maritimus* steigt innerhalb von 5 m vom Ufer von ca. 70 cm auf 1 m und mehr an (Abbildung 3.11c und 3.11d). Die Vegetationsdichte und der Grad der beginnenden Seneszenz zum Zeitpunkt der Datenerfassung am 09.08.2017 variierte nester- bzw. patchartig (Abbildung 3.9b). An der Grenze zwischen *Bolboschoenus maritimus* und dem Schilfgürtel, die höhenmäßig in etwa mit der Linie der MThw zusammenfällt, kommt es zu Lagerbildung, d.h. *Bolboschoenus maritimus* und teilweise auch *Phragmites australis* sind niedergedrückt. In Abbildung 3.11a ist der Höhenunterschied zwischen *Bolboschoenus maritimus* und *Phragmites australis* zu erkennen. Bei *Phragmites australis* war auf den höheren Messpunkten ein teilweise starker Unterwuchs verschiedener Arten festzustellen (Abbildung 3.11e).

Hollerwettern (HOL)

Das Gelände am Standort Hollerwettern (HOL, Abbildung 3.9c, WGS84: N 53,832°, O 9,372°) steigt beginnend von der Vegetationskante sehr gleichmäßig bis etwa 3 m ü. NHN zum Deich hin an. In der *Bolboschoenus maritimus*-Zone (0,6–1,5 m ü. NHN) sind auch bei HOL eine Reihe von ca. 10–25 cm tiefen und etwa 20–40 cm breiten Rinnen zu beobachten, die quer zur Hangrichtung verlaufen. Auch hier sind die Rinnen im Vegetationskörper nicht erkennbar.

Die Vegetationsgrenze liegt bei etwa 0,40 m ü. NHN. Die Pflanzenarten des Standort HOL wird ebenfalls von den drei Dominanzarten geprägt. Flusseiteig gesehen beginnt die Vegetation mit einem ca. 3–5 m breiten Gürtel aus *Schoenoplectus tabernaemontani*, der sukzessive in eine von *Bolboschoenus maritimus* dominierte Pflanzengesellschaft übergeht (Abbildung 3.9c). *Schoenoplectus tabernaemontani* ist mit 1,10–1,30 m deutlich höher, dichter und breiter als in BAL. Der Bereich von *Bolboschoenus maritimus* ist mit 90–140 m sehr breit. Außerdem unterscheidet HOL von BAL, dass sich im Übergangsbereich zu *Phragmites australis* mehrere, in der Regel runde Nester bzw. Patches mit *Phalaris arundinacea* gebildet haben (Abbildung 3.9). Ab einer Höhe von etwa 1,35–1,60 m über dem Meeresspiegel beginnt die Zone von *Phragmites australis*, die sich bis zum Deich hin ausbreitet. Die Vegetationsverteilung in HOL ist generell somit ähnlich strukturiert wie in BAL, wenn auch die Pflanzen im Schnitt deutlich größer sind.

(a) Marschkante Balje



(b) *Schoenoplectus tabernaemontani*



(c) *Bolboschoenus maritimus*



(d) *Bolboschoenus maritimus*



(e) *Phragmites australis*



Abbildung 3.11: Fotos (GRENZDÖRFFER UND BEYER 2017) vom Untersuchungsgebiet Balje. Der Holzrahmen ist 40 x 40 cm und wurde genutzt um die Parameter an jedem Punkt zu erheben.

(a) Marschkante Hollerwettern



(b) *Bolboschoenus maritimus*



(c) *Bolboschoenus maritimus*



(d) *Phragmites australis*



Abbildung 3.12: Fotos (GRENZDÖRFFER UND BEYER 2017) vom Untersuchungsgebiet Hollerwettern. Der Holzrahmen ist 40 x 40 cm und wurde genutzt um die Parameter an jedem Punkt zu erheben.

4 Instrumentierung und Datengrundlage

Dieses Kapitel besteht aus drei Teilen. Zunächst wird das *Unmanned Aerial Vehicle* (UAV)¹ selbst beschrieben und die Sensoren, die es tragen kann. Danach werden die Daten bzw. Bildflüge behandelt. Im dritten Teil werden die unternommenen Geländekampagnen und die Art der Referenzdatenaufnahme für die fünf Standorte PW, CDCW und PaW (WETSCAPES) sowie BAL und HOL (TIBASS) erläutert.

4.1 UAS und on-board-Sensoren

Das verwendete UAV war ein leichter Starrflügler, eine eBee Plus, der Firma SenseFly (Abbildung 4.1). Das Gewicht der eBee Plus beträgt ca. 1.100 g und die Spannweite 1,1 m (weitere Spezifikationen in Tabelle 4.1). Die Drohne ist trotz ihres geringen Gewichtes resistent gegen Wind (bis 12 m/s). Im Vergleich zu Multicoptern verbraucht sie wenig Strom, da sie aufgrund ihrer Form Auftrieb erzeugt und nur einen Antrieb hat. Außerdem weist die eBee trotz des weichen Materials (Carbon-Skelett und Expandiertes Polypropylen) eine hohe Belastbarkeit auf, was aufgrund ihrer harten Bauchlandung auch notwendig ist [DALL'ASTA et al. 2017]. Mit der Software eMotion ermöglicht SenseFly einen kompletten Workflow, beginnend mit der Flugplanung, über den komplett automatisierten Flug [CHIABRANDO et al. 2018] einschließlich Landung (nur der Start erfolgt manuell durch Werfen) bis hin zur Korrektur der GNSS-Positionsmessungen der Einzelbilder nach dem Flug. Da die GNSS-Rohdaten geloggt werden, also zu jeder Epoche die Beobachtungen des GNSS zu allen empfangenen Satelliten, können die Bildflüge passpunktlos mit einer Absolutgenauigkeit von 3–5 cm durch die *Post Processing Kinematic* (PPK)-Korrektur (siehe Abschnitt 5.1) durchgeführt werden. Dies setzt aber voraus, dass eine lokale Basisstation oder ein Serviceprovider (bspw. Satellitenpositionierungsdienst (SAPOS)) aus einem GNSS-Referenzstationsnetz zur Verfügung steht.

Das UAV kann mit mehreren bildgebenden Sensoren (Abbildung 4.1) bestückt werden. Zusammen mit den Sensoren und allen zusätzlichen Geräten für den photogrammetrischen Flug wird die Drohne als UAS bezeichnet [STROHMAYER 2017]. Die Sensoren decken unterschiedliche Bereiche des elektromagnetischen Spektrums ab. Aufgrund der geringen Tragfähigkeit (*Payload*) des UAS, können die Sensoren jedoch nur einzeln geflogen werden. Die Sensoren werden nachfolgend detaillierter beschrieben.

¹UAV ist die Trägerplattform. Die Trägerplattform zusammen mit Sensoren und angebaute Komponenten wird als UAS bezeichnet.

(a) SenseFly eBee Plus mit eingebauter Parrot Sequoia



(b) SenseFly S.O.D.A.



(c) Parrot Sequoia



(d) SenseFly ThermoMAP.




Abbildung 4.1: Das genutzte UAS war Starrflügler, eine SenseFly eBee Plus, mit den drei einbaubaren Sensoren SenseFly S.O.D.A. (RGB), Parrot Sequoia (Multispektralkamera) und SenseFly ThermoMap (Thermalkamera). Neben der Kamera (unten links) sind auf 4.1c auch noch der Irradianzsensor und die Referenzplatte für die radiometrische Korrektur der Multispektraldaten abgebildet. (Fotos: FLORIAN BEYER 2017/2020)

Von den drei eingesetzten Sensoren (Abbildung 4.1) sind zwei Systeme von der Firma SenseFly. Dies sind die RGB-Kamera und die thermale Kamera. Die multispektrale Kamera für den Nahinfrarotbereich ist eine Sequoia von der Firma Parrot.

4.1.1 Rot-Grün-Blau(RGB)-Kamera

Die im Vergleich zu den anderen beiden Sensoren räumlich am höchsten aufgelöste Digitalkamera (SenseFly S.O.D.A., Abbildung 4.1b) deckt den optischen Bereich des sichtbaren Lichtes mit den drei Farbkanälen Blau, Grün, Rot (ab hier jetzt als RGB-Sensor) ab. Sie arbeitet mit einem Ein-Zoll-Sensor mit 20 Megapixel (Tabelle 4.2). Die Kamera besitzt einen *Global Shutter*, was für photogrammetrische Bildflüge eine Grundvoraussetzung für verzerrungsfreie, „unverschmierte“ Bildmosaik ist [GRENZDÖRFFER 2016]. Aufgrund der hohen Auflösung wird diese Kamera auch

Tabelle 4.1: Technische Spezifikationen für das UAS SenseFly eBee Plus [SENSEFLY 2020].

| | |
|-----------------------------------------------------------------------------------|--------------------------------------------------------------|
| Spannweite | 110 cm |
| Gewicht | 1,1 kg |
| Antrieb | Geräuscharmer, bürstenloser Elektromotor |
| Funkreichweite | 3 km nominell (bis zu 8 km) |
| Abnehmbare Flügel | Ja |
| Sensoren | Austauschbar |
| Flugplanung und -steuerung | eMotion 3 |
| Bildverarbeitung (optional) | Pix4Dmapper |
| Automatische 3D-Flugplanung | Ja |
| Geschwindigkeit | 40–110 km/h (11–30 m/s) |
| Windresistenz | Bis zu 45 km/h (12 m/s) |
| Maximale Flugdauer | 59 Minuten |
| Automatische Landung | Lineare Landung mit einer Genauigkeit von ~ 5 m |
| Passpunkte (GCPs) erforderlich | Nein (RTK/PPK aktiviert), optional (RTK/PPK nicht aktiviert) |
| Handstart (kein Katapult erforderlich) | Ja |
| Nominelle Abdeckung | 220 ha bei 120 m Flughöhe |
| Bodenaufösung (GSD) | bis zu 1 cm/Pixel |
| Absolute Genauigkeit in der x-, y-, z-Achse (RTK/PPK aktiviert oder mit GCPs) | bis zu 3–5 cm |
| Absolute Genauigkeit in der x-, y-, z-Achse (RTK/PPK nicht aktiviert, keine GCPs) | 1–5 m |

Tabelle 4.2: Technische Spezifikationen [SENSEFLY 2020] des RGB-Sensors SenseFly S.O.D.A.

| | |
|----------------------|------------------------------------------------|
| Sensor | 1" RGB |
| GSD bei 75 m | ca. 1,8 cm/pixel |
| RGB-Objektiv | F/2,8–11, 10,6 mm (35 mm äquivalent: 29 mm) |
| RGB-Aufösung | 20 MP 5.472 x 3.648 px (3:2) |
| Belichtungsausgleich | $\pm 2,0$ (1/3 Stufen) |
| RGB-Verschluss | Global EV 1/30–1/2000 s |
| Weißabgleich | Automatisch, sonnig, wolbig, schattig |
| ISO Bereich | 125–6.400 |
| RGB-Blickwinkel | HFOV: 45°, VFOV: 64°, DFOV: 73° |
| RTK/PPK kompatibel | Ja |
| Betriebstemperatur | -10°C - 40°C |
| Formate | JPEG, <i>Digital Negative</i> (DNG)+JPEG |

verwendet, um die 3D-Punktwolke zu generieren. Die Punktwolke wird für die Rekonstruktion der 3D-Oberfläche der Untersuchungsgebiete benötigt und als Digitales Oberflächenmodell (DOM) bezeichnet.

4.1.2 Multispektral(MS)-Sensor

Zur Aufnahme multispektraler Daten wurde eine Kamera der Firma *Parrot* verwendet, die *Parrot Sequoia* +² (Abbildung 4.1c). Diese sehr leichte (72 g) Kamera verwendet vier einzelne Objektive für die spektralen Kanäle im grünen, roten und nahen Infrarot. Die vier Optiken verfügen alle über einen *Global Shutter* und haben eine Auflösung von 1,2 Megapixel. Außerdem verfügt die Sequoia über eine zusätzliche RGB-Kamera, die aber aufgrund ihrer geringen Auflösung und dem *Rolling Shutter* nicht verwendet wurde.

Statt eines blauen Kanals wird eine der vier Optiken für einen schmalbandigen Nahinfrarotkanal im Bereich des sogenannten *Red Edge* (RE) (deutsch: rote Kante/Flanke) benutzt. Der *Red Edge* ist der Übergangsbereich zwischen rotem Licht und nahem Infrarot von 670 nm bis etwa 760 nm [THENKABAIL et al. 2012]. Namensgebend ist der charakteristische starke Anstieg zu den längeren Wellenlängen im spektralen Signal von grüner Vegetation. Die vier Kanäle des MS-Sensors setzen sich somit zusammen aus einem grünen Kanal bei 550 nm (ab hier als G2 bezeichnet), einem roten Kanal bei 660 nm (R2) dem *Red Edge* bei 735 nm (RE) und einem nahinfraroten Kanal bei 790 nm (NIR). Der RE besitzt eine schmale Kanalbreite von 10 nm, die restlichen Kanäle sind etwa 40 nm breit.

Neben der Kamera selbst, nutzt die Sequoia einen zusätzlichen „Sonnenscheinsensor“ bzw. Irradianz-Sensor (35 g, Abbildung 4.1c). Dieser besitzt die gleichen vier Spektralkanäle wie die Hauptkamera, sitzt während des Fluges auf der Drohne hinaufschauend und misst für jede Einzelaufnahme die aktuelle Beleuchtungssituation. Vor den Optiken sitzt ein sogenannter Diffusor, damit die Strahlung nicht direkt, sondern gleichmäßig über die Optiken verteilt aufgenommen wird. In diesem Bauteil ist auch der GNSS-Empfänger installiert. In der Kamera und im Irradianz-Sensor sind jeweils auch eine *Inertial Measurement Unit* (IMU) und ein Magnetometer eingebaut.

Für die Vergleichbarkeit spektraler Messungen wird üblicherweise der Anteil der reflektierten Strahlung als Größe gemessen. Um diesen Anteil zu ermitteln, wird normalerweise eine Atmosphärenkorrektur durchgeführt, die für präzise Aussagen entweder zeitgleiche Feldspektrometernmessungen benötigt (*Ground Truth*) und /oder komplexe physikalisch basierte Korrektur-Modelle verwendet [SCHOWENGERDT 2006]. Für die MS-Daten des UAS ist das nicht notwendig, da für die Korrektur der Daten zum einen der Sonnenscheinsensor genutzt wird, zum anderen kommt eine Referenzplatte (Abbildung 4.1c) zum Einsatz, die unmittelbar vor dem Flug aufgenommen wird. Auf der Platte befindet sich eine standardisierte Graufäche, für die die exakten Reflexionswerte der vier Einzelkanäle bekannt sind. Im Zuge der Auswertung werden entsprechende Korrekturen vorgenommen um die physikalisch basierten Reflexionswerte zu ermitteln. Damit wird es einerseits möglich, spektrale

²<https://www.parrot.com/business-solutions-de/parrot-professional/parrot-sequoia#parrot-sequoia-details>

Tabelle 4.3: Technische Spezifikationen des Multispektralsensors Parrot Sequoia [SENSEFLY 2020].

| | |
|------------------------|----------------------------------------------------------------------------------------------------------|
| Sensor | Multispektralsensor und RGB-Kamera |
| GSD bei 75 m | ca. 7 cm |
| RGB-Auflösung | 16 MP 4.608 x 3.456 px (4:3) |
| RGB-Verschluss | Rollend, 6 Hz |
| Weißabgleich | Automatisch |
| ISO Bereich | Automatisch |
| RGB-Blickwinkel | HFOV: 64°, VFOV: 50°, DFOV: 74° |
| RTK/PPK kompatibel | Ja |
| Multispektralsensor | Vier-Band |
| Einzelbandauflösung | 1.2 MP 1.280 x 960 Pixel (4:3) |
| Multispektralbänder | Grün (550 nm ± 40 nm) Rot (660nm ± 40 nm) Red edge (735nm ± 10 nm) Nahinfrarot (790 nm ± 40 nm) |
| Einzelbandverschluss | Global |
| Einzelband-Blickwinkel | HFOV: 62°, VFOV: 49°, DFOV: 74° |
| Kalibrierung | Kalibriertes Reflexions-Panel (inbegriffen), Irradianz-Sensor |
| Kompatibel mit Formate | JPEG (RGB), TIFF (Multispektral) |

Produkte wie Spektralindizes (siehe Abschnitt 5.1.4) zu berechnen und andererseits aufgenommene Daten verschiedener Zeitpunkte spektral miteinander zu vergleichen. Strahlungswetterlage oder gleichmäßig bedeckter Himmel sind ideale Voraussetzungen für eine derartige MS-Befliegung. Bei schnell wechselnder Bewölkung hingegen können im Bild Schatten auftreten, die vom Irradianz-Sensor nicht erfasst werden. Diesen wichtigen Vorteilen gegenüber dem nicht korrigierbaren RGB-Sensor steht auch ein Nachteil entgegen. Aufgrund der geringen Auflösung der vier multispektralen Sensoren, der kurzen Brennweite und der beschränkten Bildfolgezeit ist die räumliche Auflösung des MS-Sensors bei vergleichbarer Flughöhe um den Faktor 3 größer als die der RGB-Kamera.

4.1.3 Thermal(TH)-Sensor

Der dritte verfügbare Sensor des eBee ist eine Thermalkamera (Abbildung 4.1d), SenseFly thermoMAP, mit einer Auflösung von 640 x 512 Pixeln (Tabelle 4.4). Die Kamera besitzt einen *Rolling Shutter* und nimmt während des Fluges ein Video auf. Beim späteren photogrammetrischen Prozess (Abschnitt 5.1) werden dann je nach benötigter Geländeabdeckung und Überlappung der Bilder nur einzelne *Frames* in regelmäßigen, kurzen Abständen herausgezogen. Aufgrund der geringen Auflösung des Sensors ist die Bodenauflösung um den Faktor 6 größer als die des RGB-Sensors bei gleicher Flughöhe. Die Kamera kalibriert sich zu Beginn des Fluges, sodass absolute Werte der Strahlungstemperatur in °C im Endprodukt zur Verfügung stehen.

Tabelle 4.4: Technische Spezifikationen des Thermalsensors SenseFly thermoMAP [SENSEFLY 2020].

| | |
|------------------------|-----------------------------------------|
| Sensor | Infrarot-Wärmebild (FLIR TAU II) |
| GSD bei 75 m | 14 cm/pixel |
| Temperatur-Bereich | -40 °C – 160 °C |
| Thermale Auflösung | 0.1 °C |
| Temperatur-Kalibration | Automatisch im Flug |
| Wärmebild-Objektiv | F/1.25, 13 mm (35 mm äquivalent: 40 mm) |
| Wärmebild-Auflösung | 640 x 512 px (5:4) |
| Wärmebild-Verschluss | Rollend, 30 Hz |
| IMU / DIFG | Synchronisierte IMU |
| Thermal-Blickwinkel | HFOV: 45 °, VFOV: 37 °, DFOV: 56 ° |
| Gewicht | 134 g |
| Formate | TIFF, MP4 |

Die thermale Auflösung beträgt 0.1 °C.

4.2 Aufnahme der UAS-Bilddaten

Für alle Aufnahmen galten bestimmt Rahmenbedingungen. Da jeder der drei Sensoren einzeln geflogen werden musste, wurde die Einsatzzeit so gewählt, dass die Einstrahlungsbedingungen nicht zu stark variieren und die Bilddaten zusammen verwendet werden können. Aus diesem Grund wurden jeder der drei Flüge pro Standort auf gleicher Flughöhe (auf Kosten gleicher räumlicher Auflösung) und ohne größere Pause nacheinander durchgeführt.

Bei Wind sollte ein Starrflügler idealerweise orthogonal zum Wind ausgerichtete Flugstreifen abfliegen um gleichbleibende Fluggeschwindigkeiten in Hin- und Rückflugrichtung zu gewährleisten. Dies lässt sich in der Realität nicht für jede Befliegung einhalten. Daher wurde als Längs- und Querüberlappung, abweichend von den Anforderungen an eine photogrammetrische Postprozessierung (80/60 %, GRENZDÖRFFER [2016]) aus Sicherheitsgründen bei allen Flügen jeweils 80 % gewählt. Der Wind führte bei den alternierend abgeflogenen Flugstreifen zu unterschiedlichen Fluggeschwindigkeiten, so dass nur bei Gegenwind die vorab gewählte Längsüberlappung realisiert werden konnte. Bei Rückenwind hingegen war die Längsüberlappung geringer und die Bildrate der Sensoren zu gering, was durch die zusätzliche Querüberlappung bei der Auswertung kompensiert wird.

Die Tabelle 4.5 fasst standortspezifische Rahmendaten, wie die Anzahl der Einzelaufnahmen pro Bildflug und die Flughöhe zusammen. Die sechs Flüge am 05.09.2017 fanden größtenteils unter sehr stabilen sonnigen Bedingungen statt, erst später während der letzten Flüge bildeten sich Schleierwolken, die jedoch keinen großen Einfluss auf die Bildqualität haben. Dabei wurden die Flüge in PW am Vormittag durchgeführt und aufgrund der einstündigen Entfernung in CDCW entsprechend am frühen Nachmittag. An beiden Standorten war die Windgeschwindigkeit moderat zwischen 3,7 bis 4,5 m/s.

Tabelle 4.5: Alle Standorte, die befliegen wurden, Tag der Befliegung und Anzahl der Einzelbilder der drei verwendeten Sensoren.

| Projekt | Standort | Datum | Anzahl an Einzelbildern | | | Höhe in m | Zeit Min. |
|-----------|----------|------------|-------------------------|----------------|---------|--------------|--------------|
| | | | RGB | MS (pro Kanal) | Thermal | | |
| WETSCAPES | PW | 05.09.2017 | 151 | 696 (174) | 335 | 85 | 15–25 |
| | CDCW | 05.09.2017 | 178 | 908 (227) | 783 | 85 | 20–30 |
| | PaW | 01.11.2018 | 635 | 3880 (970) | 1031 | 100 | 45–50 |
| TIBASS | HOL | 10.08.2017 | 395 | 1400 (350) | 2911 | 85 | 25–35 |
| | BAL | 11.08.2017 | 306 | 990 (198) | 1817 | 85 | 25–35 |

Aufgrund der späten Befliegung von PaW Anfang November 2017 und der damit verbundenen früh untergehenden (16:37 Uhr), niedrig stehenden (Höchststand: 21,3° um 11:54 Uhr) Sonne, wurde die Geländekampagne mit vergleichsweise langen Befliegungen schon früh begonnen. Aufgrund der niedrigen Temperaturen in dieser Jahreszeit musste jeder Flug für einen Akkuwechsel unterbrochen werden, sodass die drei Flüge insgesamt von 10:30 Uhr bis 13:30 durchgeführt wurden. Die Windgeschwindigkeiten waren auch hier moderat zwischen 4 und 5 m/s.

Die Flüge von HOL am 10.08.2017 und BAL am 11.08.2017 fanden größtenteils unter idealen Bedingungen statt. Die Windgeschwindigkeiten lagen bei nur 2 bis 4 m/s und der Wind kam aus nördlicher Richtung. In HOL zogen zwar bei heiterem Wetter verschiedene Wolkenfelder durch, jedoch konnte größtenteils offene Fenster für die einzelnen Bildflüge genutzt werden. In BAL hingegen war der Himmel gleichmäßig bewölkt, was die ideale Ausgangssituation für schattenfreie Bildmosaike darstellt.

4.3 Vegetationskartierungen auf den Niedermooren und Probenahme in den Marschgebieten

4.3.1 Vegetationsaufnahmen für Tribsees (PW) und Karrenforf (CDCW)

Die Vegetationskartierung für beide Moorstandorte wurde im Oktober 2017 von CARL BARNICK und MORITZ KAISER von der Universität Greifswald durchgeführt (Abbildung 4.2). Dabei lag der Fokus auf dominanten Pflanzenbeständen.

Im Feld wurde eine Kombination aus den schon zu dieser Zeit prozessierten UAS-Daten und einem mobilen RTK-GNSS-Empfänger, einem *Leica Viva GS10* mit SAPOS³ für die Echtzeitkorrektur, genutzt [LAIV-MV 2020]. Der Empfänger nutzt *Global Positioning System* (GPS)- und *Globalnaja Nawigazionnaja Sputnikowaja Sistema* (GLONASS)-Satelliten. Insgesamt wurden circa 30 Arten pro Standort identifiziert und in ein Geo-Informationssystem (GIS) übertragen.

³Genauer wurden der SAPOS-HEPS des Landesamt für innere Verwaltung - Amt für Geoinformation, Vermessungs- und Katasterwesen des Landes Mecklenburg-Vorpommerns genutzt. HEPS steht für *Hochpräziser Echtzeit-Positionierungs-Service* und bietet eine Echtzeit-Positionierung mit einer Lagegenauigkeit von 1 bis 2 cm und einer Höhengenaugigkeit von 2 bis 3 cm.

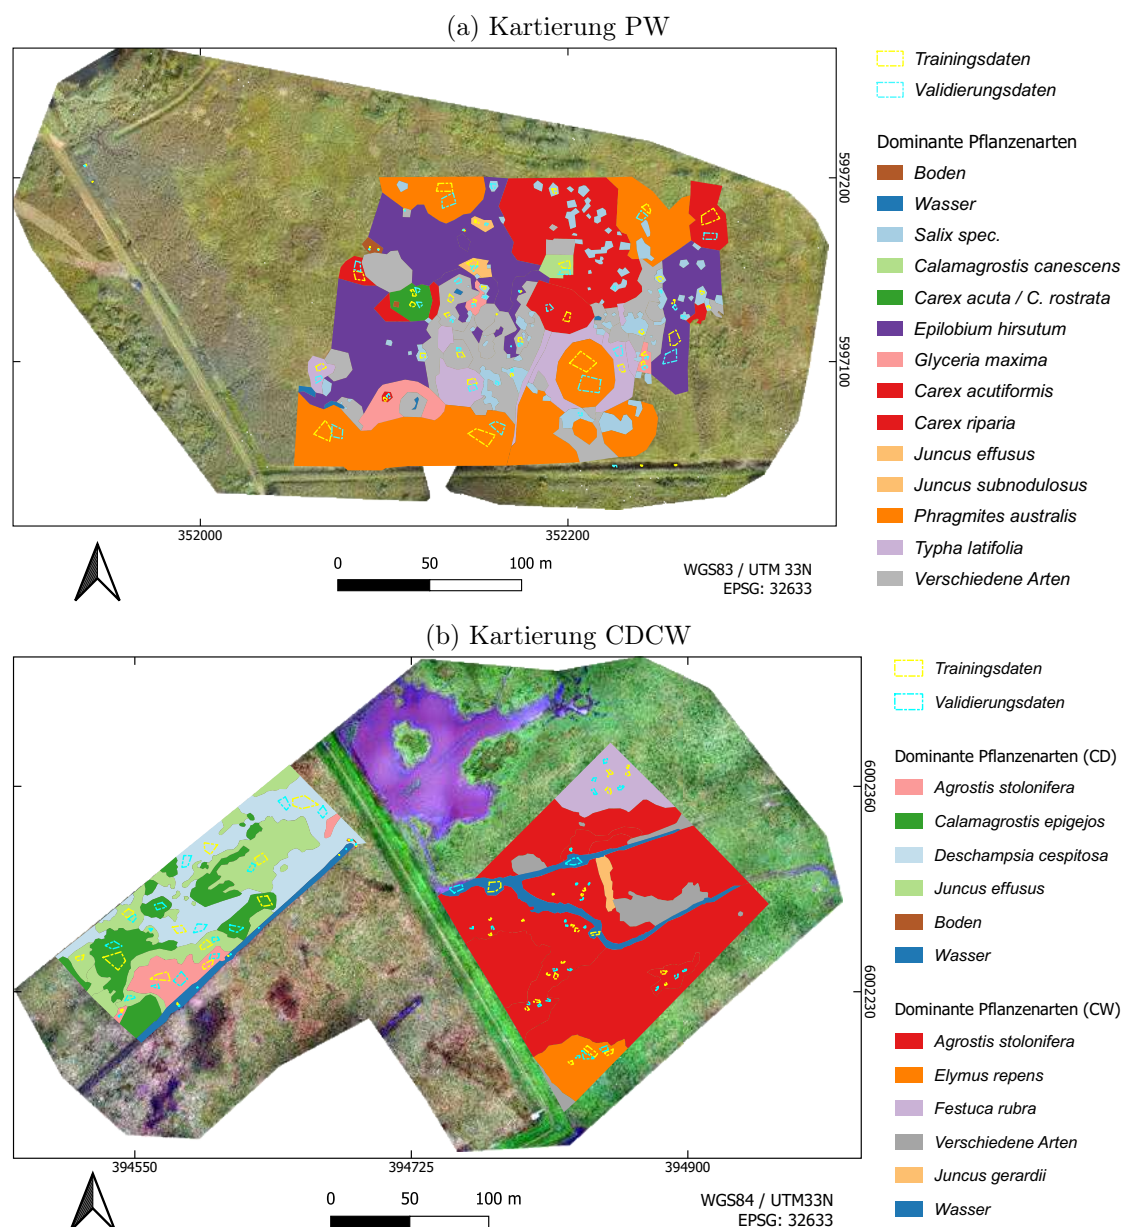


Abbildung 4.2: Kartierte Flächen der dominanten Arten für PW und CDCW (Kartierer: CARL BARNICK und MORITZ KAISER, Universität Greifswald). In gestrichelten Polygonen sind die extrahierten Trainings- und Validierungsdaten dargestellt.

Die kartierten Flächen sind in Abbildung 4.2 als zusammenhängende Polygone zu erkennen. Während der Kartierung wurden im Gelände die Flächen definiert und alle darin befindlichen Pflanzenarten aufgenommen. Im Anschluss erfolgte eine Einschätzung zur Dominanz. Somit sind im GIS ein Attribut zu finden, in dem die dominante Art bestimmt ist und ein zweites Attribut, in dem alle sekundären Arten eingetragen sind.

Für die großen westlichen violetten Polygone in PW (Abbildung 4.2a) wurde beispielsweise die Klasse *Epilobium hirsutum* als dominant zugeordnet. Diese Zone ist

Tabelle 4.6: Finale Klassen für die Vegetationsverteilung der dominanten Arten für beide Standorte PW und CDCW. Die deutschen Namen der Pflanzen sind im Anhang A.1 in Tabelle A.1 zu finden.

| Nr. | PW | | CDCW | |
|-----|---------------|-----------------------------------------------------|---------------|-------------------------------|
| | Klasse | Botanischer Name | Klasse | Botanischer Name |
| 1 | Boden | (offener Boden / Torf) | Boden | (offener Boden / Torf) |
| 2 | Wasser | (offene Wasserfläche) | Wasser | (offene Wasserfläche) |
| 3 | Salix | <i>Salix spec.</i> | Deschampsia | <i>Deschampsia cespitosa</i> |
| 4 | Calamagrostis | <i>Calamagrostis canesens</i> | Agrostis I | <i>Agrostis stolonifera</i> |
| 5 | Carex I | <i>Carex acutiformis</i> <i>Carex riparia</i> | Calamagrostis | <i>Calamagrostis epigejos</i> |
| 6 | Epilobium | <i>Epilobium hirsutum</i> | Juncus I | <i>Juncus effusus</i> |
| 7 | Glyceria | <i>Glyceria maxima</i> | Agrostis II | <i>Agrostis stolonifera</i> |
| 8 | Carex II | <i>Carex rostrata</i> <i>Carex acuta</i> | Juncus II | <i>Juncus gerardii</i> |
| 9 | Juncus | <i>Juncus effusus</i> <i>Juncus subnodulosus</i> | Elymus | <i>Elymus repens</i> |
| 10 | Phragmites | <i>Phragmites australis</i> | Festuca | <i>Festuca rubra</i> |
| 11 | Typha | <i>Typha latifolia</i> | | |

jedoch durch einige Arten mit ähnlicher Dominanz bestimmt und somit auch nicht geeignet zur Wahl von Trainingsgebieten, die einen möglichst reinen Bestand der dominanten Arten aufweisen sollte. Die Wahl der finalen Trainingsgebiete für die Arten erfolgte daher auf der Basis der Kartierung und in Zusammenarbeit mit den Kartierern. So konnten bspw. auch für *Epilobium hirsutum* im Osten der Fläche einige verhältnismäßig reinen Bestände gefunden werden. In Fällen, in denen mehrere dominante Arten stark vergesellschaftet auftreten, bspw. *Carex acutiformis* und *Carex rostrata*, wurden die entstprechenden Arten in eine Klasse zusammengefasst.

Kleinere Patches und einzelstehende Pflanzen wurden nicht weiter berücksichtigt und größeren dominanten Arten untergeordnet, mit denen sie vergesellschaftet sind. Beispielsweise tritt *Festuca rubra* dominant auf und ist vergesellschaftet mit anderen Pflanzenarten wie *Lolium perenne*, *Holcus lanatus* oder *Trifolium repens*.

Die wissenschaftlichen Taxonnamen (botanische Namen) werden nach der Konvention ICBN (Internationaler Code der Botanischen Nomenklatur) stets kursiv geschrieben [GREUTER und HIEPKO 1995]. Um sie von der fernerkundlichen Klasse, welche eine Pflanzengesellschaft repräsentiert, zu unterscheiden, werden die Klassen in dieser Arbeit verkürzt und nicht kursiv geschrieben. Die oben genannte Pflanzengesellschaft von *Festuca rubra* wurde dann beispielsweise als fernerkundliche Klasse Festuca definiert. Daher werden die finalen Klasse zwar nach einer dominanten Pflanzenart bezeichnet, repräsentieren aber Pflanzengesellschaften. Die finale Selektion der dominanten Arten bzw. die finalen Klassen für PW und CDCW sind in Tabelle 4.6 aufgeführt.

Neben den Nicht-Vegetationsklassen Boden (bzw. offener Torf) und Wasser (ohne Pflanzenbedeckung) wurden für PW neun und für CDCW acht Klassen dominanter Pflanzenarten gebildet. Meistens stehen die Klassen für eine dominante Art. In PW kommen jedoch einige dominante Arten stark miteinander vergesellschaftet vor und

werden damit als Klasse zusammen betrachtet. Das betrifft Carex I (*Carex acutiformis*, *Carex riparia*), Carex II (*Carex rostrata*, *Carex acuta*) und Juncus (*Juncus effusus*, *Juncus subnodulosus*)

In CDCW tauchen die Klassen Agrostis I und Agrostis II auf. Diese Differenzierung wurde gemacht, weil *Agrostis stolonifera* auf beiden Teilgebieten (eingedeicht und ausgedeicht) von CDCW vorkommt, aber sich, aufgrund unterschiedlicher Boden- und Wasserregime, unterschiedlich entwickelt hat und sich deswegen auch spektral unterscheidet (vgl. Abbildung 6.4, Seite 80). Die Klasse Juncus I steht für *Juncus effusus* und ist auf CDCW im eingedeichten Bereich dominant, Juncus II steht für *Juncus gerardii* im nassen ausgedeichten Bereich.

Nachdem die Klassen festgelegt waren, wurden die entsprechend sicheren Referenzflächen im GIS in zwei Datensätze aufgeteilt, die zum einen für das Trainieren des Klassifikationsalgorithmus notwendig ist. Zum anderen wurde ein zweiter Datensatz zur unabhängigen Validierung der Ergebnisse gebildet. Die Flächenanteile dieser beiden Datensätze liegt in etwa bei 50 zu 50 %. Allerdings mussten dahingehend bei einigen Klassen Kompromisse eingegangen werden, wenn diese sehr geringe Flächenanteile besaßen oder selten vorkamen, was beispielsweise bei Juncus in PW oder Festuca in CDCW der Fall war.

4.3.2 Vegetationsaufnahmen für das Hütelmoor (PaW)

Das System der Kartierung des Pflanzenbestandes unterschied sich von dem, welches in PW und CDCW durchgeführt wurde. Da PaW schon seit Beginn der Wiedervernässung, in den Jahren 2009/10, jedes Jahr auf die gleiche Weise kartiert wird (beschrieben in KOCH et al. [2017]), wurde auch für die Dürrestudie 2018 am 25.09.2018 gleichermaßen kartiert (Kartierer: DR. FRANZISKA KOEBSCH und BIRGIT SCHRÖDER, Universität Rostock).

Für die Kartierung werden immer die gleichen 65 Punkten angelaufen. Dort werden im Radius von 1 m die vorkommenden Pflanzenarten und deren flächenhafter Anteil bestimmt. Abbildung 4.3a zeigt die Ergebnisse der Kartierung für 2018. Dabei sind die dominanten Arten mit ihren Anteilen pro Punkt (Kreisdiagramm) farblich hervorgehoben. Als dominant galten Pflanzen die mehr als 30 mal in den Aufnahmepunkten vorkamen oder mehr als 5 % Flächenanteil in einem Aufnahmepunkt aufweisen.

Phragmites australis kommt in den Aufnahmepunkten am meisten vor. Offen anstehende Böden (bzw. Torf) war meist bedeckt von *Lemna minor*. Deswegen wurden beide zu einer Klasse zusammengefasst. *Schoenoplectus tabernaemontani* und *Bolboschoenus maritimus* konnten nicht mehr eindeutig in zwei distinkte Dominanzbestände eingeteilt werden. Außerdem wurden, wie bei KOCH et al. [ebd.], die *Carex spec.* und *Juncus effusus* in eine Klasse zusammengefasst. Ein Tabelle (A.2) aller, seit Wiedervernässungsbeginn, kartierten Arten und deren Vorkommen 2018 ist im Anhang A.2 angefügt. Die Klasse *Rest* fast alle nicht dominanten Arten zu einer Klasse zusammen, die im Weiteren keine Berücksichtigung mehr findet. Die finalen Klassen sind in Tabelle 4.7 aufgelistet.

Die Trainings- und Validierungsdaten wurden mit Hilfe der Kartierung und zusammen mit Expertenwissen der Kartierer digitalisiert und sind in Abbildung 4.3b dargestellt.

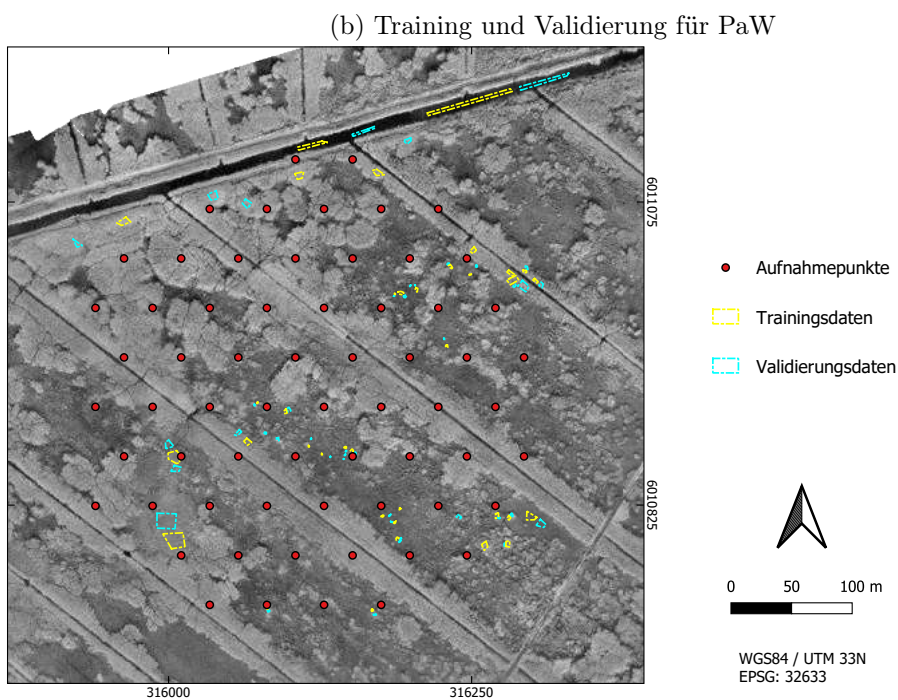
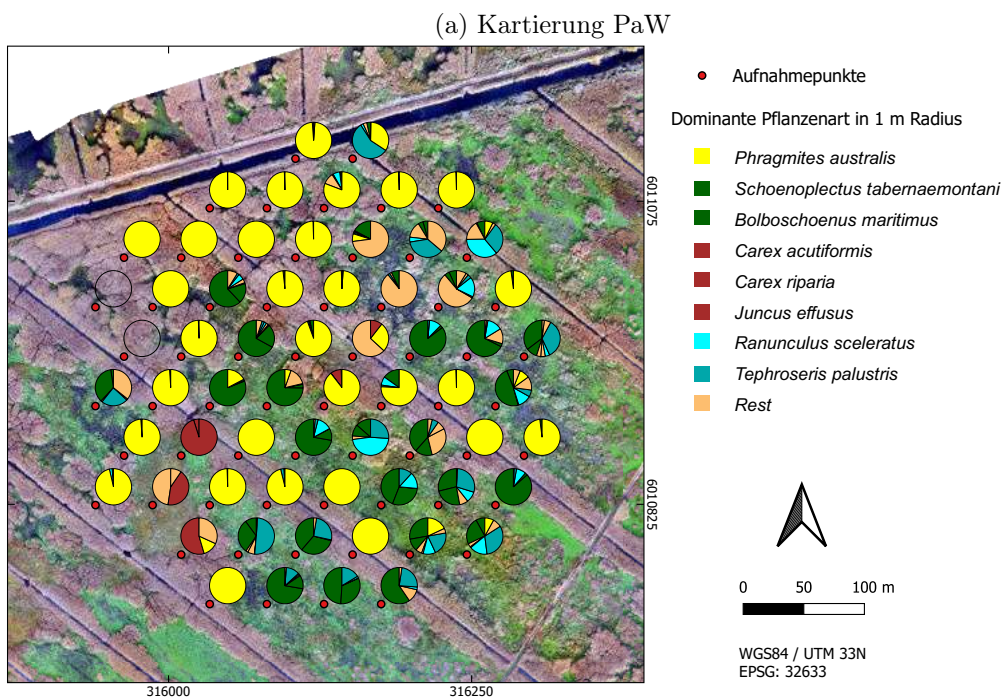


Abbildung 4.3: (a) Aufnahmepunkte, an denen der Pflanzenbestand und deren Flächenanteile in 1 m Radius aufgenommen wurden (Kartierer: DR. FRANZISKA KOEBSCH und BIRGIT SCHRÖDER, Universität Rostock). Gleichfarbige dominante Arten wurden nach KOCH et al. [2017] zusammengefasst oder waren nicht differenzierbar. Rest ist eine zusammengefasste Klasse von allen nicht dominant auftretenden Pflanzenarten. (b) Die Trainings- und Validierungsflächen, die aus (a) abgeleitet wurden.

Tabelle 4.7: Finale Klassen für die Vegetationsverteilung der dominanten Arten für den Standort PaW. Die deutschen Namen der Pflanzen sind im Anhang A.1 in Tabelle A.1 zu finden.

| Nr. | Klasse | Botanischer Name |
|-----|---------------|---------------------------------------------------------------------------|
| 1 | Boden/Lemna | (offener Boden / Torf) <i>Lemna minor</i> |
| 2 | Wasser | (offenes Wasser) |
| 3 | Phragmites | <i>Phragmites australis</i> |
| 4 | Schoeno/Bolbo | <i>Schoenoplectus tabernaemontani</i> <i>Bolboschoenus maritimus</i> |
| 5 | Carex | <i>Carex acutiformis</i> <i>Carex riparia</i> <i>Juncus effusus</i> |
| 6 | Tephroseris | <i>Tephroseris palustris</i> |
| 7 | Ranunculus | <i>Ranunculus sceleratus</i> |

4.3.3 Vegetationsaufnahmen für Balje (BAL) und Hollerwettern (HOL)

Der Fokus bei BAL und HOL lag auf der Ableitung von Pflanzenparametern. Im Unterschied zu den Niedermoorstandorten wurden daher hier keine Pflanzenarten flächig bestimmt, sondern an bestimmten Punkten im Gelände verschiedene Parameter gemessen (Abbildung 4.4).

Die Beprobung der Punkte in Balje fand am 09.08.2017 statt. Aufgrund des starken Windes konnte an diesem Tag nicht geflogen werden, weshalb die Befliegung erst zwei Tage später am 11.08.2017 erfolgte. Die Beprobung in Hollerwettern fand am 10.08.2017 statt, mit zeitgleicher Befliegung. Die zu beprobenden Punkte auf den Standorten wurden von der Bundesanstalt für Gewässerkunde (BfG) vorgegeben, da diese teilweise Dauerbeobachtungsstellen für das langfristige Monitoring der Marschländer der Tideelbe mit umfassten. Die randomisierte Auswahl an Punkten erfolgte mit der Funktion *optimDist* des Paketes *spsann* der Skriptsprache R, um das Probedesign optimal für räumliche Trends und Interpolationen der Stängeldichte der Pflanzen nutzen zu können [SAMUEL-ROSA et al. 2019]. Hierfür wurden verschiedene Kovariablen herangezogen:

- bereits bestehende Standorte (16 Standorte in Balje, 11 in Hollerwettern)
- Dominanzbestände, abgeleitet aus den Luftbildern 2016
- Geländehöhen aus dem Digitalen Geländemodell (DGM) 2010
- Distanz zur Marschkante, abgeleitet aus dem Luftbild 2016

Die letzten drei Kovariablen sind Faktoren, die die Stängeldichte häufig prägen ([MÖLLER 2006; SILINSKI et al. 2018]). Die Anzahl der Punkte in den drei Dominanzbeständen (*Schoenoplectus tabernaemontani*, *Bolboschoenus maritimus* und *Phragmites australis*) ist aufgrund ihrer unterschiedlichen Ausdehnung nicht gleichverteilt. Ziel war es räumliche Muster der erhobenen Parameter artenunabhängig abzubilden.

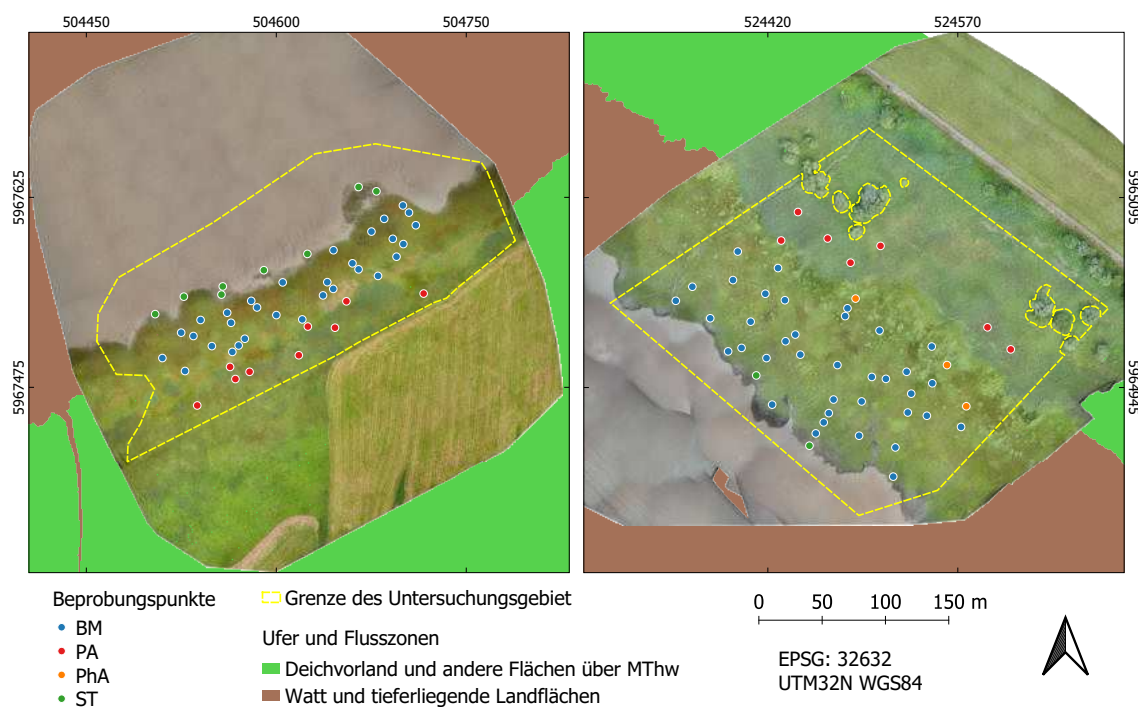


Abbildung 4.4: Beprobungspunkte auf den tibass-Standorten BAL und HOL (BM = *Bolboschoenus maritimus*, ST = *Schoenoplectus tabernaemontani*, PA = *Phragmites australis* und PhA = *Phalaris arundinacea*; Basisdaten Elbe-Strom vom WASSERSTRASSEN- UND SCHIFFFAHRTSVERWALTUNG DES BUNDES [2020]; RGB-Orthomosaik von UAS-Befliegung 09./10.08.2017).

Bei beiden Standorten wurden 50 Punkte beprobt (GNSS: DR. FERDINAND VETTERMANN, Probennahme und Pflanzenmessungen: EVA WITOROWSKI, DR. NILS KOLDRACK, Protokollant: FLORIAN BEYER, alle Universität Rostock), jedoch wurden bei BAL zwei Punkte und bei HOL ein Punkt entfernt. Der Grund dafür ist zum einen, dass bei einem Punkt die Vegetation nicht mehr vital war und am Boden lag. Zum anderen wurden Messfehler protokolliert, die statistisch zu starken Ausreißern geführt hätten. Als Ausreißer wurden hier Werte selektiert, die kleiner waren als die Differenz aus erstem Quartil und dem eineinhalbfachen Interquartilbereich (IQB) oder größer als die Summe des dritten Quartils und dem eineinhalbfachen IQB [FAHRMEIR et al. 2016]. Die Tabelle 4.8 listet die gemessenen Parameter mit kurzer Erklärung und Einheit auf. Zur Aufnahme der Parameter wurde ein standardisierter 40 x 40 cm großer Beprobungsrahmen verwendet, aus dem randomisiert auch Pflanzen entnommen wurden.

Zur Messung der genauen Probenpositionen und der Erfassung der Geländehöhen (NHN) wurde auch hier der RTK-GNSS-Empfänger *Leica Viva GS10* eingesetzt (siehe Abschnitt 4.3.1). Bei der Datenerfassung wurde darauf geachtet, dass die Spitze des Messstabs nicht oder nur sehr wenig in den Boden einsinkt.

Bei den Pflanzenmessungen wurden an allen Punkten die dominierenden Pflanzenarten identifiziert und mithilfe des Proberahmens die Parameter PA, PHG, PDMG, PARS und PARP erfasst. Bei PDMG wurden randomisiert an 10 Pflanzen bei etwa 3 cm über der Geländeoberkante die Stängeldicke mit einem Messschieber gemessen. Zur Schätzung von PHG wurde mit einem Zollstock die signifikante Pflanzenhöhe er-

Tabelle 4.8: Gemessene Pflanzenparameter, Abkürzungen und Einheiten des Projektes ti-bass.

| Abkürzung | Erklärung | Einheit |
|-----------|-------------------------------------------------------------|---------------------------|
| NHN | Normalhöhennull | m |
| PA | Anzahl der Stängel auf 40 x 40 cm | |
| PHG | Mittlere Pflanzenhöhe gemessen im Gelände | cm |
| PHL | Mittlere Pflanzenhöhe gemessen im Labor ¹ | cm |
| PDMG | Mittlerer Stängeldurchmesser gemessen im Gelände | mm |
| PDML | Mittlerer Stängeldurchmesser gemessen im Labor ¹ | mm |
| PFM | Mittlere Frischmasse pro Pflanze ¹ | g |
| FFM | Frischmasse auf 40x40 cm | g/0,16 m ² |
| PFM | Mittlere Trockenmasse pro Pflanze ¹ | g |
| FTM | Trockenmasse auf 40x40 cm | g/0,16 m ² |
| PWG | Wassergehalt pro Pflanze ¹ | % |
| PARP | PAR ² im Pflanzenbestand | μmol/s*m ² /mV |
| PARS | PAR ² über Pflanzenbestand | μmol/s*m ² /mV |
| PAR | Relative PAR ² im Bestand | % |

¹n = 10 pro Punkt ²Photosynthetisch aktive Strahlung

mittelt. Bei allen Geländemessungen wurde darauf geachtet, dass immer die gleiche Person die Parameter erhebt, um Schätzfehler zu minimieren.

Außerdem wurden jeweils 10 repräsentative Pflanzen aus dem Messrahmen entnommen, um im Labor die restlichen Parameter PHL, PDML, PFM und PTM zu messen. PFM wurde mit einer Laborwaage erfasst, bevor die Pflanzen 24 Stunden bei 105° C im Trockenschrank getrocknet wurden, um PTM zu ermitteln.

Außerdem wurden im Anschluss die Parameter FFM, FTM, PWG und PAR berechnet. Aus der Differenz von PTM und PFM wurde PWG in % ermittelt:

$$PWG (\%) = \frac{(PFM - PTM) * 100}{PFM} \quad (4.1)$$

Um die Frisch- und Trockenmasse für den gesamten Proberahmen und später auch für die UAS-Daten zu ermitteln, wurde FFM und FTM durch die Multiplikation von PA und PFM bzw. PTM errechnet.

Zur PAR-Messung wurde ein *LICOR 2500* verwendet. Für jeden Punkt erfolgten zwei Sammelmessungen. Fünf Messungen erfolgten über dem Bestand (PARS), um die solare Strahlungsstärke zu bestimmen und fünf Messungen im Bestand (PARP), d.h. ca. 3–5 cm über dem Boden. Aus den jeweiligen fünf Einzelmessungen wurde das arithmetische Mittel errechnet. Die Werte am Boden variieren je nach Dichte des Pflanzenbestandes stark und der eintreffenden Strahlung je nach Bewölkungssituation ebenfalls. Um den Anteil der durch die Pflanzen absorbierten Strahlung zu bestimmen (PAR), wurde der Quotient zwischen der solaren Strahlung und der Bestandsstrahlung in Bodennähe gebildet:

$$PAR(\%) = \frac{PARP * 100}{PARS} \quad (4.2)$$

5 Methoden

Im Kapitel Methoden wird zuerst der photogrammetrische Workflow vorgestellt mit dem aus den einzelnen Befliegungsdaten der verschiedenen Sensoren ein multisensoraler Datensatz erstellt wird (Sektion 5.1). Im Anschluss folgen die Erklärung des verwendeten Klassifikations- (Sektion 5.2) und des Regressionsverfahrens (Sektion 5.3).

5.1 Vorprozessierung

Nachdem alle UAS-Daten (Kapitel 4) aufgenommen wurden, müssen diese vorprozessiert werden. Ziel der Vorprozessierung ist es, die Einzelbildaufnahmen für jeden Flug zu Digitalen Orthophotos (-mosaiken) (DOPs) und gegebenenfalls einem DOM sowie Indizes zu berechnen und schließlich alle Datensätze zu einem multisensoralen Datensatz zusammenzuführen. Dafür durchlaufen die Daten die folgenden Schritte:

1. GNSS-Korrektur der Aufnahmepositionen der Einzelbilder
2. Generierung des DOP und DOM (Photogrammetrische Prozessierung)
3. Co-Registrierung der Bildmosaiken falls notwendig
4. Berechnung von Indizes
5. Anpassung (*Resampling*) der räumlichen Auflösung
6. Zuschneiden (*Subsetting*) der einzelnen Bildmosaiken auf das Untersuchungsgebiet
7. Stapelung (*Stacking*) der einzelnen Datensätze zu einem multisensoralen Datensatz

Alle Schritte sind in Abbildung 5.1 schematisch zusammengefasst.

5.1.1 Postprozessierung der GNSS-Daten in den UAS-Einzelbildaufnahmen

Der erste Schritt beinhaltet die Korrektur der GNSS-Koordinaten der Aufnahmepositionen für jedes Einzelbild je Sensortyp. Dafür wurden auf dem UAS und am Boden mit einer Basisstation GNSS-Rohdaten aufgenommen. Das UAS verfügt über einen geodätischen GNSS-Empfänger, der beide Trägerphasen für GPS und GLONASS unkorrigiert misst. Während des Fluges ist der PPK-Modus aktiviert, damit die GNSS-Rohdaten im Gerät mitgeschrieben werden. Die hochgenaue Bestimmung und Korrektur der Projektionszentren wird dann durch eine differentielle GNSS-Auswertemethode ermittelt. Diese liefert Koordinatendifferenzen (Basislinienvektoren dx , dy , dz), bezogen auf die Referenz-Station (Basis) zu den Aufnahmepositionen der Einzelbilder. Innerhalb der geloggtten und nun korrigierten Flugpositionen

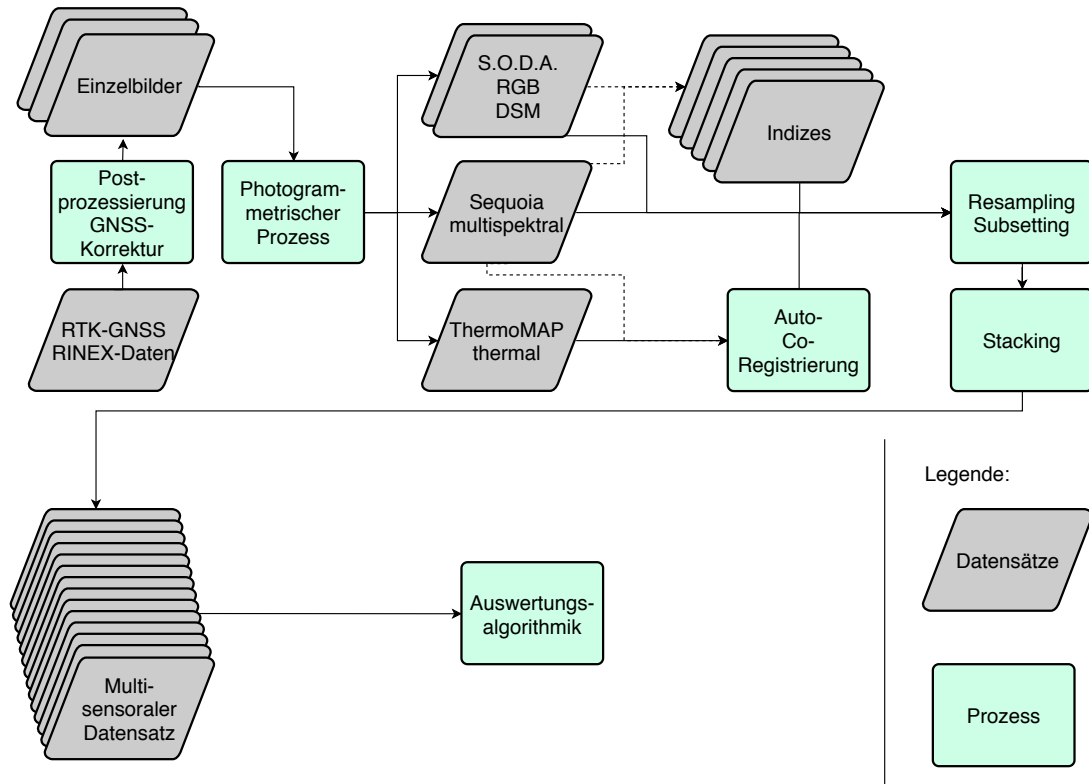


Abbildung 5.1: Arbeitsschritte für die Vorprozessierung der UAS-Daten zur Generierung des multisensoralen Datensatzes (DOM = Digitales Oberflächenmodell).

der Einzelbilder ist die innere Genauigkeit relativ zueinander hoch genau, unabhängig von der absoluten Genauigkeit der Basisstationskoordinate. Da die absolute Genauigkeit der Koordinate der Basisstation durch die RTK-Messung bekannt ist, können die verbesserten Bildkoordinaten auch in das Koordinatensystem referenziert werden. Damit sind alle Positionen der Einzelaufnahmen auch absolut hoch genau verortet. Das verwendete Gerät für die Basisstation war ein *JAVAD TRIUMPH-LS*, welches in der Lage ist, alle vier GNSS-Systeme (GPS, GLONASS, Europäisches globales Satellitennavigations- und Zeitgebungssystem (GALILEO), Chinesisches Satellitennavigationssystem (BEIDOU)) zu empfangen, wobei nur die GPS-/GLONASS-Messungen in der Postprozessierung genutzt werden können, da das GNSS des UAS nur diese beiden verarbeitet. Genauere Informationen und Grundlagen zum Thema GNSS und SAPOS-Korrekturdienst sind der Literatur zu entnehmen (bspw. MANSFELD und MAJOHR [2010] und SCHUETZE et al. [2015]).

Zur Korrektur der Koordinaten jeder Bildkoordinate wurde die Software *eMotion 3* der Firma *SenseFly* genutzt. Die Rohdaten der Basisstation mussten dafür zunächst in das *Receiver Independent Exchange Format* (RINEX)-Format umgewandelt werden, einem empfängerunabhängigen Datenspeicher- und Austauschformat für GNSS-Daten. Für die Umwandlung der Rohdaten wurde die Software *JAVAD JPS2RIN v.2.0.136* verwendet.

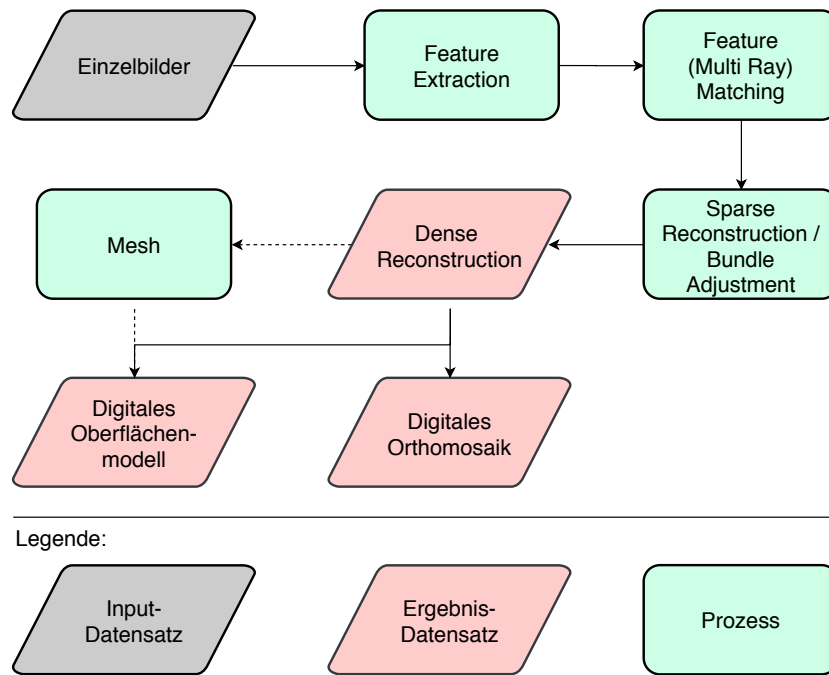


Abbildung 5.2: Vereinfachte Darstellung der einzelnen Phasen des photogrammetrischen Prozesses.

5.1.2 Generierung der Digitalen Orthophotos (-mosaike) und der Digitale Oberflächenmodell

Der photogrammetrische Prozess zur Generierung der DOPs ist in Abbildung 5.2 dargestellt. Außerdem sind im Anhang A.3 (Seite 199) Abbildungen zu den jeweiligen Schritten zu finden. Eine detaillierte Beschreibung der einzelnen Schritte, die im Folgenden nur grob skizziert werden, ist bspw. in LUHMANN [2018] zu finden.

Alle Sensordaten des UAV (RGB, MS und Thermal) wurden mit der Software *Pix4Dmapper* prozessiert. Zunächst werden die Bilder gemäß ihrer Projektion eingeladen. Im Projekt WETSCAPES war das UTM33N/ETRS89, in TIBASS UTM32/ETRS89. Aufgrund der korrigierten GNSS-Koordinaten ist die Position jeden Bildes präzise verortet und durch die IMU die Aufnahme-richtung grob bestimmt.

Der nächste Schritt wird als *Feature Extraction* oder Merkmalsextraktion bezeichnet und hat zur Aufgabe möglichst viele Merkmale im Bild zu finden (Abbildung A.1). Beispiele für oft verwendete Extraktionsalgorithmen sind hier der *Scale Invariant Feature Transform* (SIFT)- oder der *Speed-up Robust Features* (SURF)-Operator [ebd.].

Wurden genügend Merkmale in den Einzelaufnahmen gefunden, erfolgt im nächsten Schritt das *Feature Matching* bzw. die Merkmalszuordnung, indem korrespondierende Merkmale in allen Bildern gesucht und verknüpft werden. Abbildung A.2 zeigt ein Merkmal eines Busches, welches in zehn Aufnahmen des selben Fluges gefunden und verknüpft wurde.

Da die Positionen der Einzelaufnahmen bekannt sind und die einzelnen korrespondierenden Punkte (= Pixel) in den stark überlappenden Bildern aus verschiedenen Winkeln aufgenommen wurden, können gedachte Strahlen in den Raum projiziert

werden, bis sie sich an homologen Punkten schneiden. Dies ist quasi die Umkehrung des Aufnahmeprozesses und wird als *Multi-ray Image Matching* (MIM) bezeichnet (Abbildung A.3). Werden alle zuordenbaren Bildpunkte mittels MIM in den Raum projiziert, wird die sogenannte grobe Punktwolke (*Sparse Reconstruction*) abgeleitet (Abbildung A.4a).

Von der groben Punktwolke können alle korrespondierenden Punkte auf die Bilder zurückverfolgt werden. Im Rahmen der Aerotriangulation werden mit dem sogenannten Rückwärtsschnitt die äußere Orientierung der Kameras (Position und Ausrichtung im Raum) und die innere Orientierung (Bildhauptpunkt, Kammerkonstante, Radial- und Triangulationsverzeichnung) nochmals genauer korrigiert. In der Software sind zum einen durch sensorspezifische *Workflows* schon standardisierte Parameter für die Kameras vordefiniert. Zum anderen erfolgt während des Prozesses eine Nachschätzung der Parameter um die Abbildungsverzeichnung der verschiedenen Optiken der Sensoren zu minimieren. Wenn diese Korrektur durchgeführt wurde und die Bilder bzw. Kamerablickwinkel genau ausgerichtet sind, wird mittels Vorwärtsschnitt (*Dense Reconstruction*) eine dichte Punktwolke berechnet, sodass im Idealfall für jedes Pixel eine 3D-Position im Objektraum berechnet wird. Ergebnis des Vorwärtsschnittes ist die dichte Punktwolke (Abbildung A.4b). Diese dichte Punktwolke kann optional auch noch durch eine Dreiecksvermaschung (*Mesh*) zu einer Oberfläche verbunden werden, was aber eher zu dreidimensionalen Visualisierungszwecken genutzt wird.

Ausgehend von der dichten Punktwolke (oder dem *Mesh*) können die beiden Rasterdatensätze, zunächst das DOM (Abbildung A.5a) und dann das DOP (Abbildung A.5b), generiert werden. Das DOP ist ein mehrkanaliges orthorektifiziertes Raster, entsprechend der spektralen Auflösung des benutzten Sensors. Das heißt, für die Daten der RGB-Kamera sind das drei Graustufenbilder für die Farbkanäle Rot, Grün und Blau, für den Multispektralsensor vier Graustufenbilder aus den optischen Spektralbereichen Grün, Rot und zwei Infrarot-Kanälen (vgl. Kapitel 4).

Das DOM ist ein einkanaliges Graustufenraster, welches Informationen über die Höhe der jeweiligen Objekte im Bild zeigt. Wichtig ist hier, dass es kein DGM ist, welches die tatsächliche Topographie ohne Vegetation und Objekte (bspw. Gebäude) zeigt, sondern die Höhe einschließlich aller auf der Erdoberfläche stehenden Objekte. In sehr flachen Gebieten, wie den hier untersuchten Gebieten, kann man die DOM-Höhen somit als Vegetationshöhen interpretieren, weil die Pflanzenhöhen die Unterschiede im Mikrorelief deutlich übersteigen.

Aus den räumlich am höchsten aufgelösten RGB-Daten der S.O.D.A.-Kamera wurden die DOPs und das jeweilige DOM verwendet. Aus den Daten des multispektralen und des Thermalsensors wurde nur das DOP genutzt. Theoretisch wäre es auch möglich das DOM aus einem dieser beiden Sensoren zu generieren. Jedoch wird hier davon ausgegangen, dass eine höhere Auflösung ein besseres *Feature Extraction* und *Matching* gestattet und somit das DOM der RGB-Daten genauer ist und weniger Fehler besitzt.

5.1.3 Co-Registrierung der Bildmosaike

Nach der Generierung erfolgt eine Prüfung ob alle Datensätze hinreichend aufeinander co-registriert sind (Abbildung 5.1). Laut GRENZDÖRFFER [2016] sollten DOPs

an den Kontrollpunkten Genauigkeiten von ca. 1–3 cm aufweisen. War das nicht der Fall, wurden die betroffenen Bildmosaike händisch mit dem PlugIns *Georeferencer* der GIS-Software *QGIS* (Version 3.10.1-A Coruña) korrigiert. Ähnlich wie im photogrammetrischen Prozess wird eine Vielzahl an korrespondierenden Merkmalen (sogenannte *Tie Points*) in beiden Bildern gesucht (*Feature Extraction*) und zugeordnet (*Feature Matching*). Mithilfe eines Fehlerterms (*Root-Mean-Square Error* (RMSE)) können alle Merkmalspaare mit hoher Ungenauigkeit herausgefiltert und schließlich eine affine Transformation durchgeführt werden.

5.1.4 Indizes

Um den multisensoralen Datensatz um weitere Variablen zu erweitern, werden Indexbilder aus den RGB- und den MS-Daten berechnet. Unterschiedliche Oberflächen, Objekte, Vegetationsarten etc. haben unterschiedliche spektrale Charakteristika [SCHOWENGERDT 2006]. Pflanzenarten, Wassergehalte, Nährstoffversorgung und zahlreiche andere Faktoren haben einen Einfluss auf das Reflexionsverhalten von Vegetation im Wellenlängenbereich des sichtbaren und infraroten Lichtes (400–2500 nm) [JONES und VAUGHAN 2010]. Die Reflexion ist von bestimmten chemischen und morphologischen Eigenschaften der Pflanzen abhängig [XUE und SU 2017]. In der Vergangenheit wurden zahlreiche Vegetationsindizes entwickelt, um diese verschiedenen Eigenschaften aus den Reflexionsdaten abzuleiten.

Spektrale Indizes sind mathematische Kombinationen der Spektralkanäle, die hohe Korrelationen mit bspw. biophysikalischen Parametern von Vegetation aufweisen, wie bspw. Pflanzenwachstum und -vitalität, Wassergehalt, Pigmente, Zucker- oder Kohlenhydratgehalte, Proteingehalt und andere [JONES und VAUGHAN 2010; XUE und SU 2017]. Bekanntestes Beispiel ist der *Normalized Difference Vegetation Index* (NDVI), der gute Zusammenhänge mit der photosynthetischen Aktivität, Chlorophyll-Gehalt oder dem *Leaf Area Index* (LAI) zeigt [CARLSON und RIPLEY 1997; JONES und VAUGHAN 2010; THENKABAIL et al. 2012] und somit eine Aussage über den Vitalitätszustand der Vegetation erlaubt. Der NDVI wird berechnet aus der Reflexion (ρ) im roten Licht (*ROT*) und im nahen Infrarot (*NIR*):

$$NDVI = \frac{(\rho_{NIR} - \rho_{ROT})}{(\rho_{NIR} + \rho_{ROT})} \quad (5.1)$$

Für eine erste Version eines multisensoralen Datensatzes werden in der Arbeit neben dem NDVI weitere Spektralindizes mit Beteiligung an nahinfraroter Reflexion und ein Index auf Basis der RGB-Daten verwendet (Tabelle 5.1).

Im späteren Verlauf der Arbeit werden weitere Indizes auf ihren Informationsgewinn getestet. Diese Erweiterung umfasst nicht nur spektrale Indizes, sondern auch Texturindizes [HARALICK et al. 1973; HALL-BEYER 2017a] und Reliefindizes [WEISS 2001; WILSON et al. 2007; GDAL/OGR CONTRIBUTORS 2020]. Die Erweiterung wird im entsprechenden Ergebnisteil näher erläutert.

Tabelle 5.1: Übersicht der verwendeten spektralen Indizes im multisensoralen Datensatz (ρ_x = Reflexion im x ten Bereich des elektromagnetischen Spektrums, NIR = Nahes Infrarot, RE = Red Edge, GRN = Grünes Licht, BLA = Blaues Licht).

| Index | Datenbasis | Formel | Referenz |
|---------|--------------------|---------------------------------------------------------------|------------------------|
| NDVI | Multispektraldaten | $\frac{(\rho_{NIR} - \rho_{ROT})}{(\rho_{NIR} + \rho_{ROT})}$ | TUCKER [1979] |
| reNDVI1 | Multispektraldaten | $\frac{(\rho_{NIR} - \rho_{RE})}{(\rho_{NIR} + \rho_{RE})}$ | SCHUSTER et al. [2012] |
| reNDVI2 | Multispektraldaten | $\frac{(\rho_{RE} - \rho_{ROT})}{(\rho_{RE} + \rho_{ROT})}$ | SCHUSTER et al. [2012] |
| gNDVI | Multispektraldaten | $\frac{(\rho_{NIR} - \rho_{GRN})}{(\rho_{NIR} + \rho_{GRN})}$ | KROSS et al. [2015] |
| GrI | RGB-Daten | $\frac{\rho_{GRN}}{(\rho_{BLA} + \rho_{GRN} + \rho_{ROT})}$ | BROWN et al. [2017] |

5.1.5 Konvertierung, Zuschnitt und Stapelung der Datensätze — Resampling, Subsetting und Stacking

Nachdem alle notwendigen Daten vorbereitet waren, folgte deren Harmonisierung. Aus technischen Gründen besitzen die drei Sensoren unterschiedliche räumliche Auflösungen (GSD) bei gleicher Flughöhe. Beispielsweise haben die Datensätze bei einer Flughöhe von etwa 85 m folgende GSD:

- 2,5 cm RGB-Daten
- 8 cm MS-Daten
- 16 cm Thermaldaten

Da der Thermaldatensatz aufgrund der Sensoreigenschaften räumlich am größten aufgelöst ist, wurden alle Datensätze ausgehend von seiner GSD aufgerundet. Die Anpassung der räumlichen Auflösung (*Resampling*) erfolgte mit der *Nearest Neighbor*-Methode. Die Vorteile dieses Verfahrens sind zum einen die geringe erforderliche Rechenkapazität aufgrund des einfachen mathematischen Ansatzes und zum anderen ist das Verfahren bekannt dafür, dass die originalen Grauwerte (Reflexionswerte) unverändert bleiben [BABOO und DEVI 2010]. Letzteres ist bei anderen Verfahren, bspw. *Cubic Convolution*, die bessere geometrische Anpassungen gewährleisten, nicht der Fall [ebd.]. Die Kritik, dass bei *Nearest Neighbor* eine *blockige* Struktur entsteht, wurde in den benutzten Datensätzen nicht festgestellt und kann bei den hohen GSDs der UAS-Daten vernachlässigt werden.

Jede der eingesetzten Sensoren besitzt eine andere Schwadbreite bzw. *Field Of View* (FOV). Das heißt die abgedeckte Fläche bei gleicher Flughöhe ist unterschiedlich. Dies bedeutet auch die resultierenden DOPs und DOM sind unterschiedlich groß in der Flächenabdeckung. Daraus resultierend müssen alle Datensätze vor der Zusammenführung auf einen einheitlichen Bildausschnitt zugeschnitten werden (*Subsetting*).

Tabelle 5.2: Multisensoraler Datensatz, bestehend aus 14 Kanälen.

| Nr. | Kanal | Sensor |
|-----|-----------------------------------|-------------------|
| 1 | B1 (Blau) | RGB |
| 2 | G1 (Grün) | RGB |
| 3 | R1 (Rot) | RGB |
| 4 | G2 (Grün) | Multispektral |
| 5 | R2 (Rot) | Multispektral |
| 6 | RE (RedEdge) | Multispektral |
| 7 | NIR (Nahes Infrarot) | Multispektral |
| 8 | DOM (Digitales Oberflächenmodell) | aus RGB |
| 9 | TH | Thermal |
| 10 | GrI | aus RGB |
| 11 | NDVI | aus Multispektral |
| 12 | reNDVI1 | aus Multispektral |
| 13 | reNDVI2 | aus Multispektral |
| 14 | gNDVI | aus Multispektral |

Ist das *Subsetting* für alle Datensätze erfolgt kann im letzten Schritt der multisensorale Datensatz erstellt werden. Dabei werden die einzelnen Kanäle aller Datensätze gestapelt (*Stacking*). Tabelle 5.2 zeigt den finalen 14-kanaligen multisensoralen Datensatz bestehend aus den DOPs der RGB- (drei Kanäle), MS- (vier Kanäle) und Thermaldaten (ein Kanal), dem DOM (ein Kanal) der RGB-Daten sowie den fünf Vegetationsindizes.

5.2 Klassifikation zur Ableitung der Vegetationszusammensetzung

Zur Klassifikation des multisensoralen Datensatzes wurde ein Algorithmus des *Machine Learning* (ML) bzw. maschinellen Lernens und spezieller des überwachten Lernens (*Supervised Learning*) genutzt [RICHTER 2019]. Die Algorithmen des ML unterscheiden sich fundamental in der Herangehensweise von klassischen Klassifikationsverfahren. Frühere Klassifikatoren (bspw. Maximum Likelihood) nutzten statistische Parameter wie Mittelwertspektren und Kovarianzmatrizen oder auch Distanzmaße vorgegebener Klassen um einen gegebenen Ausgangsdatsatz zu clustern [SCHOWENGERDT 2006].

Allen ML-Algorithmen ist es gemein, dass mit Kalibrationsdaten ein Modell trainiert wird. Diese Trainingsdaten bestehen aus einer Teilmenge des zu klassifizierenden Gesamtdatensatzes, deren Variablen schon Zielklassen zugeordnet wurden. Der überwachte ML-Algorithmus lernt eigenständig Regeln auf Basis seiner mathematischen Grundstruktur zur Bewältigung des jeweiligen Problems und versucht sich möglichst genau darauf anzupassen. Daher muss der Trainingsdatensatz auch repräsentativ für den Gesamtdatensatz sein. Das trainierte Modell wird im Anschluss zur Klassifikation des gesamten Datensatzes verwendet, was als Vorhersage (*Prediction*) bezeichnet wird [RICHTER 2019]. Ein Vorteil solch angelernter Modelle ist es, dass

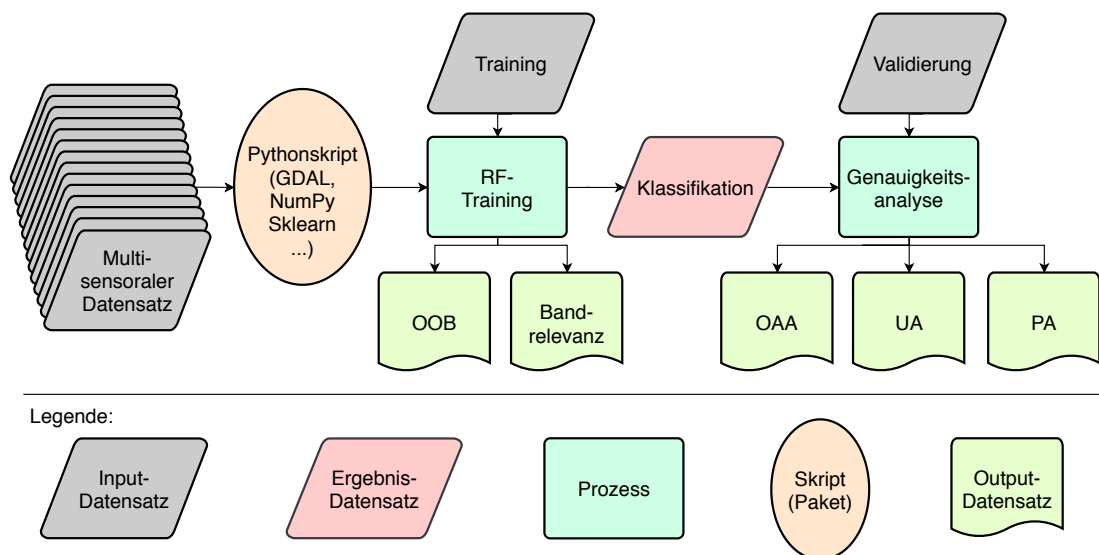


Abbildung 5.3: Arbeitsschema zur Klassifikation eines multisensoralen Datensatzes mithilfe des *Random Forest* (RF).

sie später auf neue Datensätze gleichen Aufbaus angewendet werden können. So wäre es bspw. möglich eine UAS-Befliegung im Folgejahr zum gleichen phänologischen Stadium durchzuführen und die schon trainierten Modelle darauf anzuwenden.

In dieser Arbeit wurde ein *Random Forest*-Klassifikator verwendet [BREIMAN 2001; ZHANG et al. 2017]. Der RF hat sich in bisherigen Studien [RODRIGUEZ-GALIANO et al. 2012; BEYER et al. 2015b; ABDI 2019] als sehr robuster Klassifizierungsalgorithmus herausgestellt. Er liefert konsistent präzise Ergebnisse und das Training benötigt, im Vergleich zu anderen oft genutzten lernenden Algorithmen wie *Support Vector Machines* (mit *Radial Base Function Kernel*), sehr wenig Zeit [BEYER et al. 2015b].

Die gesamte Prozesskette wurde mithilfe der Skriptsprache *Python 3* automatisiert. Dabei erfolgt nicht nur die Klassifikation, sondern auch die Validierung und die Ausgabe der Kanalrelevanz automatisiert. Der RF-Algorithmus selbst wurde mit dem Python-Paket *SciKit Learn* 0.22.1 verwendet [PEDREGOSA et al. 2011]. Der schematische Ablauf ist in Abbildung 5.3 dargestellt und wird im folgenden näher erläutert. Das entwickelte Pythonskript ist in verschiedenen Versionen frei verfügbar:

- Als Pythonskript bzw. *Jupyter Notebook* (siehe Anhang A.5, Seite 205):
<https://github.com/florianbeyer/RandomForest-Classification> oder
https://github.com/florianbeyer/PhD_Florian_Beyer
- Maptor 1.4b, ein plattformunabhängiges Programm (Windows, Linux, MacOS) mit Benutzeroberfläche siehe Anhang A.4

5.2.1 Klassifikationsalgorithmus — Random Forest

Wie der Name *Random* (deutsch: zufällig) und *Forest* (deutsch: Wald) schon andeutet, besteht der RF aus einer Vielzahl von Bäumen, die aus Objektivitätsgründen

randomisiert erstellt werden. Um die Funktionsweise eines RFs zu verstehen, ist es daher zunächst notwendig den einzelnen Baum zu erklären.

Entscheidungsbäume — Decision Trees

Die Bäume im RF werden als Entscheidungsbäume bzw. *Decision Trees* (DT) bezeichnet. Ein DT teilt die Trainingsdaten solange auf, bis alle vorkommenden Kombinationen aus Eingangsvariablen den Klassen zugeordnet werden. Abbildung 5.4a stellt beispielhaft einen DT dar. Basierend auf einer mathematischen Entscheidung an jedem sogenannten Knoten (Kreise in Abbildung 5.4a) wird der Datensatz aufgeteilt (*Splits*). Dieser Prozess generiert schließlich eine baumähnliche Struktur. Der erste Knoten wird Wurzelknoten (*Root Node*, schwarzer Kreis) genannt, die Endknoten sind die Blätter (*Leafs*, grüne Kreise) und stellen die finalen Klassen dar. Die inneren Knoten (zwischen Wurzelknoten und Blätter) werden vor der Aufteilung als Elternknoten bezeichnet. Die beiden Knoten, die nach der Aufteilung entstehen sind seine Kinderknoten. Der Pfad vom Wurzelknoten bis zum finalen Blatt stellt die Klassifikationsregeln dar.

Immer mehr Aufteilungen werden bei folgenden Knoten durchgeführt bis der DT die Variablenkombinationen der richtigen Zielklassen zuordnen kann. In der vorliegenden Arbeit besteht der Trainingsdatensatz aus Pixeln. Jedes Pixel hat multiple Eingangsvariablen gemäß seiner spektralen Auflösung, also die Reflexionswerte der einzelnen Sensoren und die Werte der generierten Produkte (bspw. DOM, Indizes).

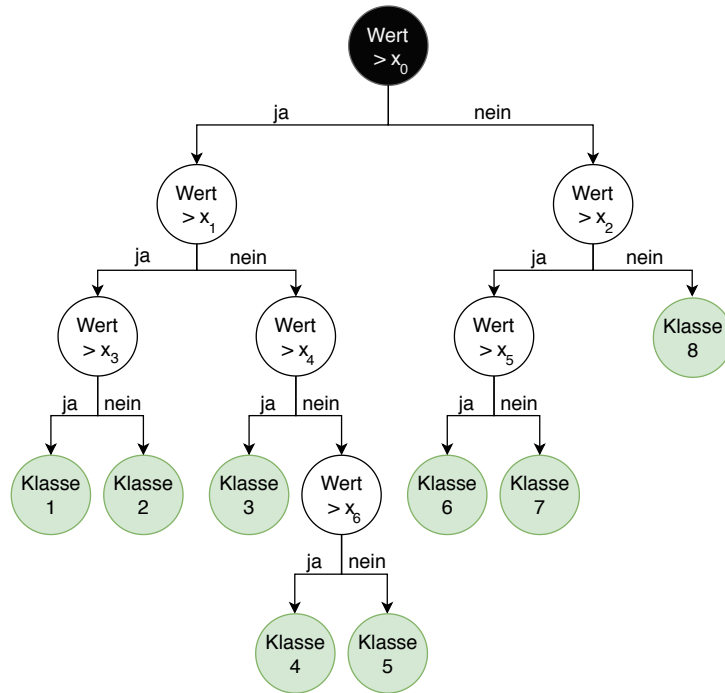
Wenn alle Klassifikationsregeln bekannt sind, könnte ein DT manuell zusammengestellt werden. Dies ist in der Realität jedoch selten der Fall. In den meisten Fällen, so auch in dieser Arbeit, sind die Eingangsvariablen (Trainingsdatensatz) und die Zielklassen (Vegetationsklassen) bekannt bzw. vordefiniert.

Um einen einzelnen Baum zu generieren und automatisiert die Klassifikationsregeln zu finden gibt es verschiedenen Ansätze. Der bekannteste ist der *Classification And Regression Trees* (CART)-Algorithmus [BREIMAN 1984], der auch Basis für das RF-Konzept ist. Der Algorithmus nimmt vordefinierte Trainingsdaten und versucht in einem rekursiven Ansatz mithilfe des Eingangsdatensatzes in mehreren Iterationen möglichst reine Unterklassen zu bilden. Auf dem Weg dahin werden alle Klassifikationsregeln an jedem Knoten generiert.

Entropie

Die automatische Aufteilung an jedem Elternknoten geschieht mithilfe der Entropie, also mit dem Maß der Unordnung. Am Elternknoten wird die Entropie berechnet und dann nochmals bei den beiden Kinderknoten. Wenn die Unordnung an den Kinderknoten gesunken ist, wird die Aufteilung angenommen und versucht weiter zu verfeinern. Man spricht hier auch von der Reinheit der Kinderknoten. Die Aufteilung im DT geschieht so lange, bis in den Blättern die Reinheit nicht mehr steigerbar ist. Der Aufbau des gesamten DT besteht daraus, die größte Steigerung der Reinheit an jedem *Split* zu finden.

(a) Schematische Darstellung eines Decision Tree



(b) Schematische Darstellung eines Random Forest

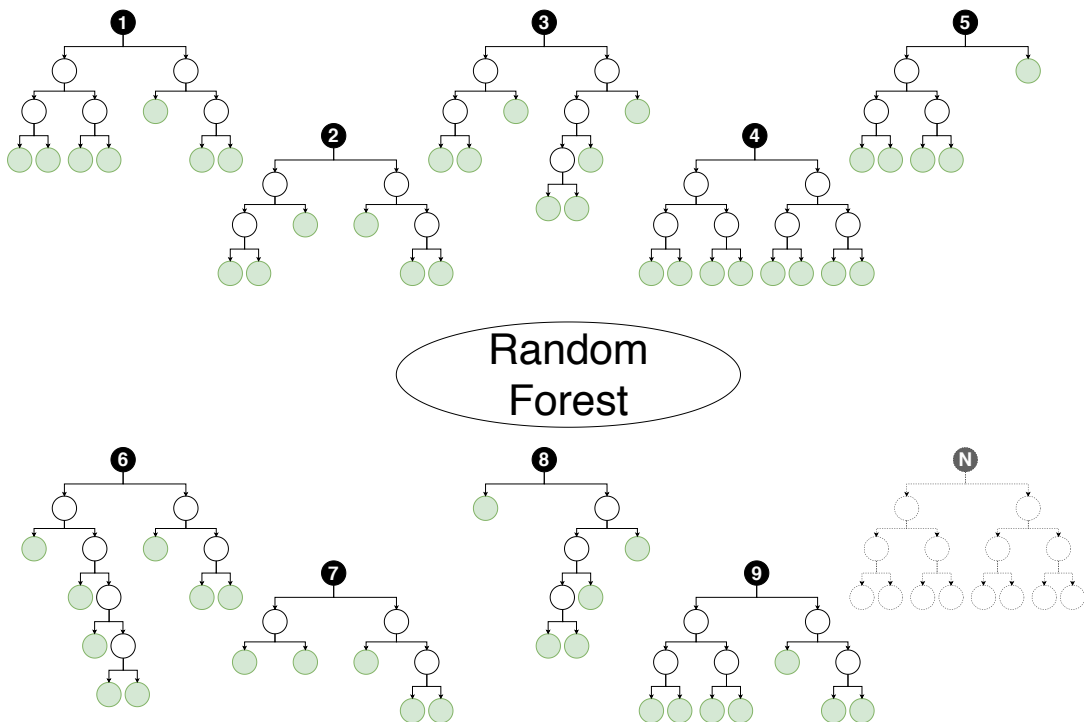


Abbildung 5.4: Schematische Darstellungen eines (a) *Decision Trees* (DT) und (b) eines *Random Forest* (RF). Der N-te DT steht für die Anzahl an Bäumen bzw. DTs im RF.

Gini Index

Um die Reinheit der Aufteilungen zu berechnen wurden verschiedene Metriken entwickelt. Für CART ist der Gini-Index (GI) von besonderer Bedeutung [PAL 2005; ARCHER und KIMES 2008; ZHANG et al. 2017]. Der GI basiert auf der *Gini Impurity* (Unreinheit) und ist definiert als:

$$Gini\ Impurity(p) = 1 - \sum_{i=1}^N p_i^2 \quad (5.2)$$

wobei p der gesamte Datensatz ist, N die Anzahl der Klassen und p_i die Frequenz der Klasse i im selben Datensatz.

Der GI ist definiert als die gewichtete Summe aller *Gini Impurities* von verschiedenen *Splits* nach der Aufteilung, in dem jeder Anteil nach dem Ratio der Größe jedes *Splits* gewichtet wurde, unter Berücksichtigung der Größe des Ausgangsdatensatzes:

$$Gini\ Index = \sum_{j=1}^K w_j Gini\ Impurity(j, \text{danach}) \quad (5.3)$$

$$w_j = \frac{\text{Daten im Kinderknoten } (j, \text{danach})}{\text{Daten im Elternknoten } (\text{zuvor})} \quad (5.4)$$

wobei K die Anzahl der aufgeteilten *Splits* und (j, danach) der *Split* j nach der Aufteilung ist. Für einen Datensatz mit zwei Klassen ist der Bereich für den GI zwischen 0 und 0,5: Die Daten des Kinderknotens gelten bei einem Wert 0 als komplett rein und bei 0,5 sind beide Klassen in den Subsets gleichmäßig verteilt. Daher werden die Daten des Kinderknotens mit dem geringsten GI genutzt für weitere Aufteilungen.

Bei kategorialen und rangskalierten Eingangsvariablen ist der Findungsprozess sehr schnell durchgeführt, bei numerischen Variablen, wie den Reflexionswerten im fernerkundlichen Datensatz ist der Berechnungsaufwand wesentlich höher. Um die *Splits* bzw. Aufteilungen mit der größten Steigerung der Reinheit zu finden, werden Mittelwerte zwischen allen vorkommenden Grauwert-Paaren in jedem Spektralband berechnet. Danach wird für jeden der Mittelwerte die Aufteilung durchgeführt und der GI berechnet. Es gewinnt derjenige *Split*, dessen Reinheitssteigerung am größten ist. Aus den neu entstandenen Kinderknoten wird dann geprüft ob weitere *Splits* notwendig sind oder ob sie zu finalen Blättern deklariert werden.

Random Forest aus Decision Trees (Entscheidungsbäume)

Ein einzelner DT neigt zur Überanpassung (*Overfitting*). Das bedeutet, dass der Klassifikator zwar sehr gut an den Trainingsdatensatz angepasst ist, jedoch Probleme bei der Übertragung auf den gesamten Datensatz geschehen können. Aufgrund dessen kann der RF als Weiterentwicklung von DTs bezeichnet werden, denn dieser generiert eine hohe Anzahl an unterschiedlichen DTs (Abbildung 5.4b). Diese wurden unterschiedlich trainiert und die Festlegung auf eine Klasse erfolgt durch eine Mehrheitsentscheidung (*Majority Voting*) der DTs [BREIMAN 2001]. Die Anzahl der DTs wird vom Nutzer vor dem Training festgelegt.

Bagging — Bootstrap Aggregating

Das Training unterschiedlicher DTs basiert auf dem sogenannten *Bagging*, was eine Wortschöpfung aus zwei Methoden darstellt, *Bootstrapping* und *Aggregation* [BREIMAN 1996]. Beim *Bootstrapping* werden neue Datensätze durch zufällige Stichproben aus dem originalen Trainingsdatensatz generiert, die am Ende die gleiche Größe wie der Originale besitzen. Es können also die gleichen Pixel mehrfach gezogen werden. Es ist gängige Praxis, dass bei jeder Iteration vom *Bootstrapping* Zweidrittel des originalen Datensatzes zufällig ausgewählt werden, aus dem dann der neue Datensatz generiert wird. Das restliche Drittel wird dann im weiteren Verlauf zur Überprüfung des Trainingserfolges genutzt (siehe Sektion 5.2.1). Jedoch ist nicht nur das Ziehen der Pixel randomisiert, sondern auch die Anzahl der Variablen (also der Spektralbänder). Aus jedem so generierten Datensatz mit unterschiedlichen Variablenzusammensetzungen wird ein dazugehöriger DT erzeugt. Die Anzahl der mit *Bootstrapping* erzeugten Datensätze entspricht also der Anzahl der Bäume die am Ende generiert werden [HASTIE et al. 2009]. So entstehen dekorrelierte Bäume, deren Ergebnisse im Anschluss wieder zusammengeführt werden (*Aggregation*), durch das *Majority Voting*.

Mehrheitsentscheidung — Majority Rule

Nachdem alle DTs erzeugt wurden, können alle unbekanntes Pixel vorhergesagt werden. Jeder Pixel durchläuft dann alle DTs. Entsprechend der gewählten Anzahl der Bäume erfolgt die finale Entscheidung über die Klasse durch die Mehrheitsentscheidung (*Majority Voting*). Dies ist auch der Grund, warum der RF zu den Ensemblemethoden gezählt wird, weil die finale Entscheidung auf einer größeren Menge von einzelnen Lernalgorithmen (DTs) basiert [ZHANG et al. 2017].

Messung des Vorhersagefehlers — Out-of-Bag-Error

Wie beim *Bagging* beschrieben, wird der Trainingsdatensatz ein Drittel zu zwei Drittel aufgeteilt, wobei zwei Drittel für das *Bootstrapping* verwendet werden. Das andere Drittel wird dann genutzt um den sogenannten *Out-of-Bag-Error* (OOB) zu berechnen [PAL 2005; ZHANG et al. 2017]. Die Pixel des gedrittelten Datensatzes werden durch die generierten Bäume geschickt, um deren Genauigkeit zu überprüfen. Der OOB ist somit ein Qualitätsmaß, welches Aussagen darüber erlaubt, wie gut das Modell die Klassen des Trainingsdatensatzes klassifizieren würde.

5.2.2 Unabhängige Validierung

Im vorherigen Abschnitt wurde gezeigt, dass der RF sich während des Trainings qualitativ selbst überprüft mit dem OOB. Dies gestattet jedoch keine Aussage darüber, wie präzise das trainierte Modell den gesamten Datensatz vorhersagt. Deswegen ist es gängige Praxis, eine zweiten, vom Training unabhängigen, Validierungsdatensatz zu erstellen und mit diesem eine Genauigkeitsanalyse (englisch: *accuracy assessment*) für die Klassifikation durchzuführen.

Tabelle 5.3: Beispiel einer Konfusionsmatrix zur Beurteilung der Klassifikationen der Einzelklassen durch die Produzentengenauigkeit (PA) und Benutzergenauigkeit (UA) sowie für die Gesamtgenauigkeit (rot, OAA). (N = Anzahl der Klassen)

| Klassen | | Referenz | | | | | Summe | UA (%) |
|----------------|----------|------------|------------|------------|-----|------------|-------------|-------------|
| | | Klasse 1 | Klasse 2 | Klasse 3 | ... | Klasse N | | |
| Klassifikation | Klasse 1 | 500 | 5 | 0 | ... | 10 | 515 | 97,1 |
| | Klasse 2 | 10 | 400 | 30 | ... | 20 | 460 | 87,0 |
| | Klasse 3 | 0 | 50 | 500 | ... | 0 | 550 | 90,9 |
| | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| | Klasse N | 0 | 0 | 10 | ... | 500 | 510 | 98,0 |
| Summe | | 510 | 455 | 540 | ... | 530 | 2035 | |
| PA | (%) | 98,0 | 87,9 | 92,6 | ... | 94,3 | | 92,9 |

Die Pixel der Validierungsdaten werden genutzt um verschiedene Qualitätsmaße zu berechnen. Das wichtigste Maß für die Qualität einer Klassifikation ist die Gesamtgenauigkeit, bzw. die *Overall Accuracy* (OAA). Des weiteren werden noch der kappa-Koeffizient, die Benutzergenauigkeit bzw. *User's Accuracy* (UA), und die Produzentengenauigkeit, die *Producer's Accuracy* (PA), berechnet [CONGALTON 1991].

Alle Maße lassen sich anhand der Konfusionsmatrix erklären [CONGALTON 1991; SCHOWENGERDT 2006]. Zur Veranschaulichung wurde eine einfache Matrix mit willkürlich gewählten Werten (Tabelle 5.3) generiert, anhand welcher die Qualitätsmaße erklärt werden. In der Konfusionsmatrix befinden sich die tatsächlich richtigen Klassen aus dem Validierungsdatensatz in den Spalten (Referenz). In den Zeilen wird die Vorhersage des Klassifikators abgetragen (Klassifikation). Das heißt, dass auf der Diagonalen die entscheidenden Werte stehen, denn diese entsprechen der Anzahl der Pixel, die vom Klassifikator richtig zugewiesen wurden. Die Gesamtgenauigkeit der Klassifikation über alle Klassen, also die OAA, wird daher errechnet aus der Summe der Matrixdiagonalen dividiert durch die Summe aller Werte in der Matrix (multipliziert mit 100 um eine prozentuale Angabe zu erhalten). In Tabelle 5.3 ist die OAA als rote Zahl dargestellt.

Der kappa-Koeffizient ist eine weitere Repräsentation der Gesamtgenauigkeit, jedoch dimensionslos zwischen 0 und 1, wobei 0 keine und 1 komplette Übereinstimmung der wahren und klassifizierten Pixel bedeutet. Der kappa wird wie folgt berechnet:

$$kappa = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n (G_i C_i)}{N^2 - \sum_{i=1}^n (G_i C_i)} \quad (5.5)$$

wobei i die Klassenanzahl, N die Anzahl der klassifizierten Pixel verglichen mit den wahren Pixeln, $m_{i,i}$ die Anzahl der Pixel, die zur wahren Klasse i und auch zur klassifizierten Klasse i gehören, C_i die Anzahl der vorhergesagten Pixel, die zur Klasse i gehören und G_i die Anzahl der wahren Pixel, die zur Klasse i gehören ist.

Die verbleibenden Qualitätsmaße sind dafür da, die Klassifikationsgenauigkeit der einzelnen Klassen zu bewerten. Die PA ist eine Genauigkeit aus Sicht des Erstellers bzw. Produzenten der Klassifikation. Sie setzt die richtig klassifizierten Pixel der jeweiligen Klasse in Beziehung zu der Anzahl der Pixel, die eigentlich in den Validierungsdaten für diese Klasse zur Verfügung stehen. Daher gibt die PA die

Wahrscheinlichkeit an, ob ein Pixel der Klasse richtig zugeordnet wurde. Sie ist für jede Klasse in der letzten Zeile der Tabelle 5.3 zu finden.

Die UA betrachtet die Einzelklassengenauigkeiten eher aus der Sicht des Nutzers der Klassifikation. Sie setzt die Zahl der richtig klassifizierten Werte in Beziehung zu allen Pixeln, die derjenigen Klasse zugeordnet wurden. Die UA kann daher als die Zuverlässigkeit des Klassifikators bezeichnet werden und drückt die Wahrscheinlichkeit aus, dass ein klassifizierter Pixel zu der ausgewiesenen Klasse gehört. Sie ist für jede Klasse in der letzten Spalte der Tabelle 5.3 ausgewiesen.

5.2.3 Kanalrelevanz

Permutationstests wurden durchgeführt, um die Relevanz jeder Ausgangsvariable zu berechnen. In diesem Fall sind die Ausgangsvariablen die Kanäle des multisensoralen Datensatzes.

Ein großer Vorteil des RF gegenüber anderen DT-Methoden ist es, dass während der Berechnung der Entropien an jedem Knoten diese Relevanzen in Form des GI (siehe Abschnitt 5.2.1) als *Nebenprodukt* entstehen [ZHANG et al. 2017]. Präziser ausgedrückt, steht in den Bäumen an jedem *Split* die Senkung der *Gini Impurity* (Gini-Unreinheit) vom Elternknoten zu den Kinderknoten und die dazugehörigen verwendeten Kanäle. Das arithmetische Mittel aller Senkungen der Unreinheit im Wald, wo der jeweils betrachtete Kanal verantwortlich ist für den *Split*, liefert den Gini-Index und somit die Kanalrelevanz für die Klassifikation [BREIMAN 2001; ARCHER und KIMES 2008].

Neben dem GI existieren noch andere Relevanzparameter (bspw. die Permutationsrelevanz [STROBL et al. 2007]), welche zwar meist andere Werte zeigen, jedoch keine Änderung der Rangordnung der Relevanz jeder Ausgangsvariable verursachen. Daher erfolgt die Angabe der Kanalrelevanz in dieser Arbeit ausschließlich durch den GI.

5.3 Regressionsverfahren zur Ableitung von Pflanzenparametern

5.3.1 Regressionsalgorithmus — Partial Least-Squares (PLSR)

Die PLSR wurde ursprünglich für ökonomische Untersuchungen von WOLD [1985] entwickelt, fand jedoch schnell Einzug in anderen Bereichen wie der chemischen, pharmazeutischen, Lebensmittel- und Kunststoffindustrie, um dort Qualitätsparameter aus spektrometrischen Messungen abzuleiten. Der Grundgedanke bei der Regression im Allgemeinen und bei der PLSR im Speziellen ist es, kosten-, zeit- oder personalintensive und komplexe Analysen zu ersetzen, durch günstige Verfahren bzw. einfache zu messende Variablen, die einen statistischen Zusammenhang zu den Zielparametern besitzen. So ist das Ziel in der vorliegenden Arbeit, einfache und nicht-destruktive spektrale Messungen mittels UAS-Befliegungen zu nutzen, um im

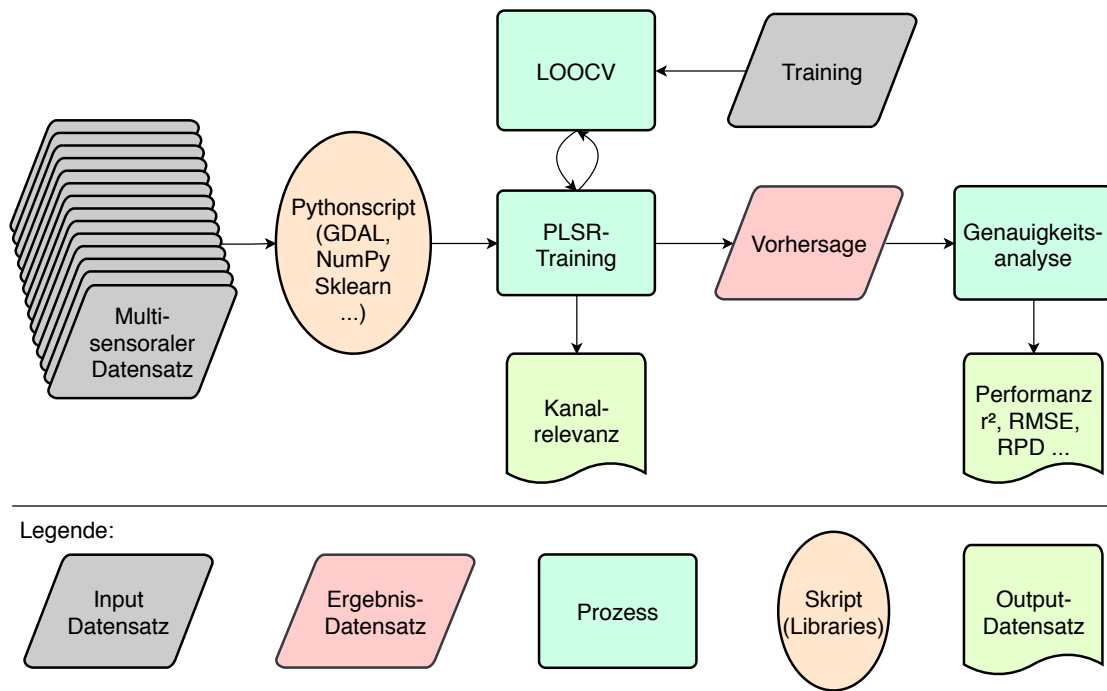


Abbildung 5.5: Arbeitsschema für die Verwendung des *Partial Least-Squares Regression* (PLSR)-Regressionsverfahren auf einem multisensoralen Datensatz.

Gelände gemessene Pflanzenparameter abzuleiten und auf die gesamte Fläche vorherzusagen. Dies spart wiederholte Geländemessungen, die kostenintensiv (Probenahme, Laboranalyse, ...) sind und einen Impact auf das zu schützende Ökosystem haben.

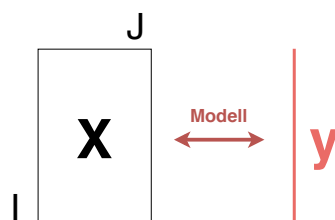
Die PLSR hat in den letzten Jahren sehr stark an Bedeutung gewonnen und hat sich im Vergleich zu anderen komplexen multivariaten Regressionsverfahren (wie der *Support Vector Regression* oder der *Gaussian Process Regression*) als sehr robust erwiesen. Dies konnten unter anderen SIEGMANN und JARMER [2015] für multi- und hyperspektrale Daten durch unabhängige Validierungsversuche nachweisen. Außerdem konnten sie nachweisen, dass die PLSR relativ robust gegenüber einer Überanpassung (*Over Fitting*) der Modelle agiert.

Wie beim RF wurde die gesamte Prozesskette mithilfe der Skriptsprache *Python 3* automatisiert. Dabei erfolgt nicht nur die Regression, sondern auch die Validierung und die Ausgabe der Kanalrelevanz automatisiert. Der PLSR-Algorithmus selbst wurde mit dem Python-Paket *SciKit Learn* 0.22.1 verwendet [PEDREGOSA et al. 2011]. Der schematische Ablauf ist in Abbildung 5.5 dargestellt und wird im Folgenden näher erläutert. Das entwickelte Pythonskript ist in verschiedenen Versionen frei verfügbar:

- Als Pythonskript bzw. *Jupyter Notebook* (siehe Anhang A.5, Seite 205): https://github.com/florianbeyer/PhD_Florian_Beyer
- Maptor 1.4b, ein plattformunabhängiges Programm (Windows, Linux, MacOS) mit Benutzeroberfläche siehe Anhang A.4

Funktionsweise der PLSR

Die PLSR versucht ein statistisches Modell zu finden, welches einen Zusammenhang herstellt zwischen Matrix X und dem Vektor y :



$$(5.6)$$

Dabei stellt X eine Selektion an I Trainingsdaten (Zeilen) dar, bestehend aus Pixeln bzw. Spektren aus dem multisensoralen Datensatz. Jede Zeile der Matrix ist ein Pixelspektrum, bestehend aus den Pixelwerten der J Kanäle, an dessen Punkt im Gelände der Messwert y , der Zielparameter, gemessen wurde. Das zu trainierende Modell soll die statistische Beziehung zwischen den Pixelspektren und den dazugehörigen Messwerten finden, um schließlich unbekannte Pixelwerte vorhersagen zu können.

Eigentlich wäre eine Multiple Lineare Regression (MLR) ein Weg um aus vielen Vorhersagevariablen (Werte der Kanäle) einen Zielparameter zu finden [NAES et al. 2010]. Jedoch müssen bei der MLR verschiedene Grundvoraussetzungen erfüllt werden, wie bspw. dass die Vorhersagevariablen (Kanäle) nicht stark untereinander korrelieren und dass die Anzahl an Messwerten des Zielparameters signifikant größer sein sollte als Vorhersagevariablen. Besonders in fernerkundlichen Untersuchungen kann die Zahl an Kanälen rasch die Zahl der im Gelände gemessenen Punkte übersteigen und die Reflexionswerte der Kanäle korrelieren untereinander oft sehr stark. Daher kann die MLR für fernerkundliche Analysen nur sehr eingeschränkt verwendet werden.

Um die genannten Hürden zu überwinden, wurden die Regression mittels Hauptkomponententransformation (*Principal Component Regression*, PCR) und die PLSR entwickelt. In diesen Regressionsmethoden werden die Modelle nicht direkt aus den Werten der X -Matrix trainiert, sondern aus einer reduzierten *Scores*(Punkte)-Matrix T der dazugehörigen *Loadings*(Ladungs)-Matrix P :

$$X = TP^T + E \quad (5.7)$$

E ist eine Matrix der Residuen der Matrix X . Bei der PCR werden die beiden Matrizen allein aus der X -Matrix so transformiert, dass die Varianz zwischen den sogenannten PCR-Komponenten möglichst groß und die Korrelation möglichst gering sind. Im Unterschied zu PCR, werden bei der PLSR die *Scores* und *Loadings* nicht nur so transformiert, dass deren Komponenten dekorreliert wurden und eine hohe Varianz aufweisen, sondern gleichzeitig eine möglichst hohe Kovarianz zum

Zielparameter y besitzen:

$$(5.8)$$

Diese Kovarianzen bzw. *Scores* werden als Vektoren in die T -Matrix geschrieben. Durch die Berücksichtigung des Zielparameters bei der Transformation der Matrix X , werden in den Spektren nicht die größten Varianzen (wie in der PCR) herausgefiltert, sondern die relevanten Unterschiede, die durch y verursacht werden. Die Bereiche, die in den Vorhersagevariablen gefunden werden, werden dann in der P -Matrix als *Loadings* beschrieben.

Latente Variablen bzw. PLSR-Komponenten

Der erste gefundene *Scores*- und *Loadings*-Vektor ist die erste PLSR-Komponente. Wenn diese erste Komponente die Varianz der Matrix X nicht hinreichend exakt und nicht die ganze Kovarianz des Vektors y beschreibt, wird diese von den Daten subtrahiert und eine weitere orthogonale PLSR-Komponente generiert. Dieser iterative Prozess wird solange wiederholt bis entweder der Kompromiss aus:

- TP^T beschreibt so viel Varianz in X wie möglich und
- T muss eine möglichst hohe Kovarianz zu y besitzen,

erfüllt sind oder die Anzahl J bzw. die Anzahl der Kanäle aus dem multisensoralen Datensatz erreicht wurde. Die PLSR-Komponenten werden auch als *Latente Variablen* bezeichnet, weil die Ableitung des Zielparameters aus transformierten Variablen geschieht.

Die Zahl der Komponenten entspricht meist nur einem Bruchteil der J Spalten in X , weil das Problem der Kollinearität bzw. die Korrelation der Kanäle durch die Transformation mit den ersten PLSR-Komponenten gelöst werden kann.

Innere Beziehung der PLSR

Nun fehlt noch der Schritt, in dem das eigentliche Regressionsmodell zwischen der PLSR-transformierten X -Matrix und dem Zielparameter bzw. Zielvektor y generiert wird. Dafür unterscheidet man die äußere und die innere Beziehung der PLSR. Während die äußere Beziehung den Zusammenhang zwischen der Matrix X und dem Zielvektor y beschreibt, versucht die innere Beziehung r (kleiner Vektor siehe Formel 5.8) die mathematischen Zusammenhänge zwischen T und y herzustellen. Dabei wird r auch als Regressionsvektor bezeichnet und ergibt sich aus:

$$Tr = y \quad (5.9)$$

$$r = (T^T T)^{-1} T^T y \quad (5.10)$$

Die Formel 5.10 wird als *Gewöhnliche Lösung der Kleinsten Quadrate* bezeichnet und ist gleichzeitig namensgebend für die PLSR. Die Werte des Vektors r werden als Regressionskoeffizienten bezeichnet und entsprechen der Anzahl der PLSR-Komponenten in T . Daraus ergibt sich, dass die Zielwerte von y durch:

$$\hat{y} = t_1 r_1 + \dots + t_n r_n = Tr \quad (5.11)$$

berechnet werden können, wobei n die Anzahl der PLSR-Komponenten darstellt. Das heißt, die Formel 5.9 ist das eigentliche Regressionsmodell, da aus dem Produkt von *Scores* und dem Regressionsvektor die Zielparameter vorhergesagt werden können.

Anstatt der Matrix T bestehend aus den *Scores* t_1 bis t_n (n = Anzahl der PLSR-Komponenten) kann auch die Matrix X mit den Originaldaten multipliziert mit den *Loadings* der Matrix P genutzt werden:

$$T = XP \quad (5.12)$$

$$y = Tr = XPr \quad (5.13)$$

Da also y vorhergesagt werden kann aus XPr , kann ein Regressionsvektor b aus Pr berechnet werden:

$$b = Pr \quad (5.14)$$

Mit b können nun aus neuen Vorhersagevariablen X_{neu} (neuen unbekanntem Pixel-spektren des multisensoralen Datensatzes) die Zielparameter vorhergesagt werden:

$$y_{unbekannt} = X_{neu} b \quad (5.15)$$

Qualitätsmaße der Regression

Für die Regression werden verschiedenen Qualitätsmaße berechnet, um die Güte der Modelle bewerten zu können. Das wichtigste Maß ist das Bestimmtheitsmaß r^2 , welches die tatsächlich im Gelände gemessenen Werte y den korrespondierenden vorhergesagten Werten \hat{y} aus dem trainierten Modell gegenüberstellt:

$$r^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5.16)$$

wobei \bar{y} der Mittelwert aller y -Werte ist. Der Bereich von r^2 geht von Null, das Modell kann den Zielparameter nicht erklären, bis Eins, das Modell erklärt den Zielparameter ohne jegliche Abweichung.

Desweiteren wurden noch der *Mean Squared Error* (MSE), der *Mean Absolute Error* (MAE) und der RMSE berechnet:

$$MSE = \frac{1}{m} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5.17)$$

$$MAE = \frac{1}{m} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5.18)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{m}} \quad (5.19)$$

wobei m die Anzahl der Punkte des im Gelände gemessenen Zielparameters y entspricht.

Ein weiterer Parameter ist der *Ratio Of Performance To Deviation* (RPD), welcher dimensionslos ist und den RMSE der Standardabweichung (STD_y) der im Gelände gemessenen Parameter gegenüberstellt:

$$RPD = \frac{STD_y}{RMSE} \quad (5.20)$$

Da der RPD nicht normalisiert und nach oben offen ist, hat er eher einen deskriptiven Charakter, vermittelt aber einen guten Eindruck über die Qualität der Vorhersage.

Kreuzvalidierung

In den vorhergehenden Abschnitten wurde beschrieben, dass je mehr latente Variablen bzw. Komponenten in der PLSR genutzt werden, desto mehr Varianz der Matrix X wird von der *Scores*-Matrix beschrieben. dies impliziert jedoch, dass erstens die Residuen E immer mehr sinken und in den Komponenten stecken und somit auch immer mehr unwichtige Information in den transformierten Matrizen steckt. Ziel der Transformation ist aber die Varianz der Daten in so wenig wie möglich Komponenten zu beschreiben und damit gleichzeitig kollineare Variablen zu verhindern. Somit muss ein Weg gefunden werden, systematisch zu entscheiden, wie viele Komponenten genutzt werden sollen, um die robustesten Regressionsmodelle zu selektieren.

Diese Selektion geschieht typischerweise mit der Kreuzvalidierung. Die Idee dahinter ist einen Teil der Trainingsdaten abzuspalten. Beispielsweise könnten die Trainingsdaten geviertelt werden. Dann werden 75 % der Daten genutzt um das Training des Regressionsmodells durchzuführen und die anderen 25 % werden genutzt um unabhängig die Qualität des Trainings zu prüfen. Dieser Prozess wird für alle vier Teile durchgeführt und die resultierenden Qualitätsmaße werden gemittelt. Im letzten Schritt wird diese Kreuzvalidierung iteriert beginnend mit der ersten Komponente, bis die mittleren Qualitätsmaße für alle Komponenten getestet wurden.

In der Fernerkundung allgemein ist es oft der Fall, dass die Zahl der Messpunkte im Gelände sehr begrenzt ist, aufgrund des hohen Aufwandes der Probenahme. Daher ist das Vierteln der Daten problematisch, da dies einen großen Einfluss auf die Repräsentativität des Trainings- und des Validierungsdatensatzes hat. Bei solch begrenzten Datensätzen wird stattdessen die sogenannte *Leave-One-Out Cross Validation* (LOOCV) genutzt. Statt der Teilung der Trainingsdaten in Training und Validierung wird immer nur ein Wert herausgenommen und dieser vorhergesagt. Dies wird je nach Anzahl komplett über alle Messwerte iteriert. Am Ende erhält man genauso viele korrespondierende vorhergesagte Werte wie Messwerte.

Nun können mithilfe der oben genannten Maße die Qualität des Trainings für jede Zahl der Komponenten errechnet werden. Als Qualitätsmaß wurde in dieser Arbeit der MSE genutzt, da dieser ein normalisierter und einfach zu berechnender Kontrollterm ist. Schließlich wird die Anzahl der Komponenten gewählt, mit der das

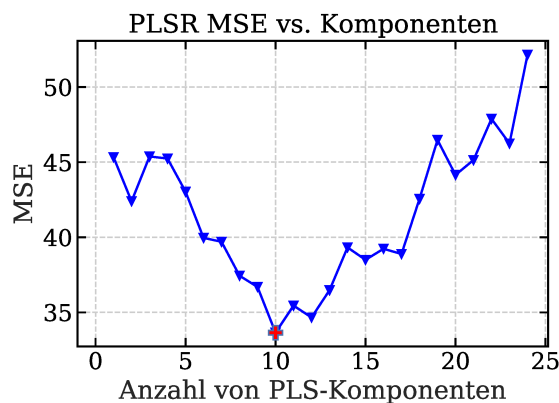


Abbildung 5.6: Beispiel eines Diagramms zur Selektion der finalen Anzahl an latenten Variablen bzw. PLSR-Komponenten, ermittelt aus der LOOCV und dem MSE. Das rote Kreuz markiert die selektierte Anzahl an Komponenten, die für das finale Training genutzt wurden.

Qualitätsmaß am niedrigsten ist (Abbildung 5.6). Mit dieser Anzahl der Komponenten wird dann das finale Regressionsmodell auf Basis der kompletten Matrix X trainiert.

Kanalrelevanz

Analog zum GI des RF wurde auch die Kanalrelevanz für das trainierte Regressionsmodell der PLSR berechnet. Die Relevanz VIP (*Average Variable Importance in the Projection*) wird berechnet für einen Kanal J der Matrix X [MUKHERJEE et al. 2015]:

$$VIP_J = \sqrt{\frac{z \sum_{k=1}^h (y^T t_k w_{Jk}^2)}{\sum_{k=1}^h (y^T t_k)}} \quad (5.21)$$

wobei h die Anzahl der Komponenten und z die Anzahl der Ausgangsvariablen ist. Das Ergebnis ist eine dimensionslose Zahl, die im Anschluss in Prozent umgerechnet wird.

6 Ergebnisse und Diskussion

Dieses Kapitel untergliedert sich in fünf Abschnitte. Zunächst werden die Ergebnisse der Vorprozessierung, im Wesentlichen die Ergebnisse der photogrammetrischen Prozessierung, vorgestellt.

Im zweiten Teil erfolgt die Vorstellung und Interpretation der klassifikativen Arbeiten auf den Moorstandorten. Dabei stehen zum einen die Klassifikationsergebnisse und deren Interpretation von ökologisch-angewandter Seite und zum anderen die Relevanzanalyse der Kanäle und Sensoren des multisensoralen Datensatzes aus methodisch-fernerkundlicher Sicht im Fokus.

Im dritten Abschnitt wird der multisensorale Datensatz nochmals um eine Vielzahl an weiteren verschiedenen Arten von fernerkundlichen Indizes erweitert und eine Selektion der sinnvollsten vorgenommen. Diese Erweiterung wird am Beispiel von PaW simuliert, auf deren Informationsgewinn getestet und mit den beiden anderen Standorten PW und CDCW verglichen.

Im vierten Abschnitt werden die Ergebnisse der Regressionsarbeiten der Marschen vorgestellt. Auch hier erfolgen die Interpretationen und Diskussionen zum einen aus ökologisch-angewandter Sicht für die Ergebnisse der Regression und zum anderen die Bewertung der Kanal- und Sensorrelevanz des multisensoralen Datensatzes aus methodischer Sicht.

Im abschließenden fünften Abschnitt werden alle Ergebnisse des erweiterten multisensoralen Datensatzes in einer synoptischen Betrachtung verglichen um eine finale Aussage über die Relevanz der Kanäle und Sensortypen zu treffen.

6.1 Ergebnisse der Vorprozessierung

Die aufgenommenen Einzelbilder der verschiedenen Sensoren wurden, gemäß Abschnitt 5.1, prozessiert. Dies beinhaltet zunächst die Korrektur der GNSS-Koordinaten jedes Einzelbildes der verschiedenen Sensoren.

Bis auf die thermalen Daten konnten alle Orthomosaike mit der notwendigen Präzision berechnet werden (Tabelle 6.1). Im Anhang A.6 (Seite 207) sind alle DOPs und DOMs abgebildet. Nach der Generierung erfolgte eine Prüfung ob alle Datensätze hinreichend aufeinander co-registriert waren. Durch das *Post Processing* der GNSS-Daten lagen die RGB- und die MS-Daten sehr genau aufeinander und erfüllten die Anforderungen für UAS-Befliegungen und DOPs laut GRENZDÖRFFER [2016] (ca. 1–3 cm an den Kontrollpunkten). Bei den multispektralen Aufnahmen sind die Abweichungen an den Passpunkten etwas größer, was sich durch die wesentlich geringere Bodenauflösung (ca. 8–12 cm) der zugrundeliegenden Bilder erklärt.

Die GNSS-Koordinaten der Thermaldaten konnten nicht korrigiert werden, weil die Prozessierungskette zur PPK-Korrektur dieses Datentyps von *SenseFly* nicht in

Tabelle 6.1: Überblick über verschiedene Parameter und Genauigkeiten für die einzelnen Orthomosaiken nach der photogrammetrischen Prozessierung (— = Daten standen nicht mehr zur Verfügung).

| Unter- suchungs- gebiet | Sensor | GSD cm | Fläche ha | Einzelbilder Anzahl | Mittlerer | Absolute Varianz d. | | |
|-------------------------------|--------|-----------|--------------|------------------------|-----------------|---------------------|-------|-------|
| | | | | | Projektions- | Geolokalisierung | | |
| | | | | | fehler Pixel | cm (RMSE) | | |
| x | y | z | | | | | | |
| PW | RGB | 1,5 | 8,6 | 142 | 0,2 | 1 | 1 | 6,7 |
| | DOM | | | | | | | |
| | MS | 7,9 | 13,6 | 174 | 0,3 | 1,4 | 1,3 | 1,9 |
| | TH | 15,1 | 12,3 | 332 | 0,5 | 646,9 | 141,0 | 140,0 |
| CDCW | RGB | 1,7 | 12,6 | 178 | 0,1 | 0,6 | 0,5 | 0,7 |
| | DOM | | | | | | | |
| | MS | 7,6 | 15,3 | 227 | 0,2 | 1,7 | 1,1 | 1,4 |
| | TH | 14,3 | 14,5 | 781 | 0,5 | 466,8 | 377,3 | 298 |
| PaW | RGB | 2,4 | 78,8 | 635 | 0,1 | 0,6 | 0,6 | 1 |
| | DOM | | | | | | | |
| | MS | 11,2 | 94,9 | 970 | 0,2 | 1,1 | 1,6 | 1,1 |
| | TH | 21,6 | 62,8 | 1031 | 0,6 | 491,9 | 552,5 | 236,6 |
| Bal | RGB | 1,5 | 13,2 | — | — | — | — | — |
| | DOM | | | | | | | |
| | MS | 7,5 | 11,3 | — | — | — | — | — |
| | TH | 17,1 | 9,8 | 269 | 0,6 | 274,6 | 468,6 | 137,4 |
| Hol | RGB | 1,5 | 15,2 | 298 | 0,2 | 1,1 | 0,9 | 1,2 |
| | DOM | | | | | | | |
| | MS | 7,7 | 19,6 | 305 | 0,3 | 1,6 | 1,3 | 1,9 |
| | TH | 17,3 | 17,3 | 776 | 0,5 | 485,7 | 336,1 | 149,8 |

die eMotion-Software implementiert wurde. Der Hersteller wollte diesen Software-Fehler seit Anfang 2018 beheben, was jedoch, Stand heute (22.10.2020), nicht geschehen ist. Ein Grund dafür ist, dass die Thermalbilder nur einzelne *Frames* aus einem Videosignal sind und somit keine Metadaten, bspw. zum Neigungswinkel des UAS während des Fluges, mitgeschrieben und den einzelnen Aufnahmen zugeordnet werden können. Somit mussten die DOPs im ersten Schritt mit der Lageungenauigkeit des unkorrigierten GNSS-Signals von etwa drei Metern erzeugt werden. Aufgrund der größeren Auflösung von etwa 14–22 cm, sind Zielmarken am Boden nicht erkennbar.

Da durch den photogrammetrischen Prozess (Abschnitt 5.1.2) die Genauigkeit der inneren Geometrie jedoch vergleichbar mit der der anderen Datensätze ist, wurden die Thermal Datensätze im Anschluss mithilfe des PlugIns *Georeferencer* der GIS-Software *QGIS* (Version 3.10.1-A Coruña) manuell georeferenziert. Dafür wurden die präzise co-registrierten RGB-Daten auf die Auflösung der Thermaldaten konvertiert (*Resampling* mittels *Nearest Neighbor*) um das Finden von korrespondierenden Punkten zu erleichtern. Die so erzielten Genauigkeiten sind in der Regel horizontal besser als 0,5 m, wie der visuelle Vergleich mit den RGB-Daten zeigt.

Die innere Genauigkeit der Bündelblockausgleichung (BBA) zeigt sehr hohe Ge-

naugigkeiten für alle berechneten Orthomosaik (Tabelle 6.1). Der Projektionsfehler wird gemittelt über das gesamte Orthomosaik in Pixel angegeben, da jeder Datensatz einen unterschiedlichen GSD besitzt. Im Mittel ergab sich ein Projektionsfehler von 0,26 Pixeln, bei einer STD von 0,14. Der Thermaldatensatz ist mit 0,5 Pixeln mittlerer innerer Genauigkeit am ungenauesten, was auf eine Kombination aus höchster GSD und schlechtestem Signal-/Rausch-Verhältnis zurückzuführen ist.

Der RMSE der Geolokalisierungsvarianz wird absolut in Zentimeter angegeben und liegt ohne den unkorrigierten Thermaldatensatz im Mittel bei 1,16 cm (STD = 0,4 cm). Die große Abweichung beim thermalen Datensatz wurde durch die manuelle Co-Registrierung korrigiert. Der Versatz zwischen RGB/MS-Daten belief sich nach der Korrektur auf wenige Zentimeter, was für die weitere Verarbeitung ausreicht, da die multisensoralen Datensätze auf eine gröbere räumliche Auflösung *resampled* werden. Auch GAUCI et al. [2018], die ebenfalls eine *eBee Plus* nutzen, zeigen, dass diese erreichten Genauigkeiten für eine weitere photogrammetrische Analyse von PPK-UAS-Daten ohne *Ground Control Points* (GCP) ausreichend sind.

Danach wurden die fünf Indizes (Abschnitt 5.1.4) berechnet. Der *Greenness Index* (GrI) [BROWN et al. 2017] wurde auf Basis der RGB-Daten berechnet, die vier Vegetationsindizes auf Basis der MS-Daten [SCHUSTER et al. 2012; KROSS et al. 2015].

Die Bildflüge erfolgten pro Standort immer bei einer konstanten Flughöhe, woraus sich unterschiedliche GSD pro Sensor ergeben. Daher erfolgte im nächsten Schritt das *Resampling* (Abschnitt 5.1.5) auf eine gleiche gröbere räumliche Auflösung. Da der Thermalsensor die niedrigste räumliche Auflösung besitzt, war dieser Ausgangspunkt für das *Resampling* (Tabelle 6.2). Ausgehend von dieser Auflösung und der fernerkundlichen Fragestellung wurde der GSD aller Datensätze aufgerundet. So wurde bspw. für den multisensoralen Datensatz von PW bei Auflösungen von 1,5/7,9/15,1 cm für RGB/MS/Thermal-Daten auf 20 cm aufgerundet. Diese Auflösung ist für die Klassifikation von dominanten Arten in einem wiedervernässten Moor ausreichend um dominante Pflanzengesellschaften zu klassifizieren. Gleichzeitig werden kleinteilige Mikro-Schattenflächen innerhalb des Pflanzenbestandes herausgemittelt.

Die Marschstandorte BAL und HOL wurden auf 40 cm *resampled*, weil dies der Flächengröße des Kartierrahmens entspricht und das die Ableitung von Parametern erleichtert, die darin erhoben wurden.

Tabelle 6.2: Übersicht über alle multisensoralen Datensätze.

| Standort | GSD | Fläche | Kanäle |
|----------|-------------------------|-------------------------|-----------------|
| | <i>Resampling</i> cm | <i>Subsetting</i> ha | <i>Stacking</i> |
| PW | 20 | 6,7 | 14 (32)* |
| CDCW | 20 | 10,3 | 14 (26)* |
| PaW | 25 | 54,6 | 14 (98, 27)* |
| BAL | 40 | 4,3 | (25)* |
| HOL | 40 | 6,3 | (26)* |

*Anzahl der Kanäle nach der Erweiterung des multisensoralen Datensatzes (siehe Abschnitt 6.2.3)

6.2 Maschinelles Lernen für die Klassifikation von Moorvegetation

Im Folgenden werden die Ergebnisse der multisensoralen Klassifikationen auf den Moorstandorten gezeigt und interpretiert.

6.2.1 Klassifikation der Vegetationsbestände in Tribsees (PW) und Karrendorf (CDCW) aus multisensoralen UAS-Daten

Nach der Vorprozessierung, also der Vorbereitung und Harmonisierung der unterschiedlichen Sensordaten, wurden die finalen multisensoralen Datensätze den Pythonskripten (Anhang A.5) übergeben um sie in Verbindung mit den Trainings- und Validierungsdaten zu klassifizieren. Zunächst wird die gesamte Prozessierungskette an den Standorten PW und CDCW durchgeführt und erörtert. PaW folgt im nächsten Kapitel mit erweiterter Prozessierungskette.

Parametertuning

Um das Trainingsergebnis von ML-Klassifikatoren zu verbessern, können meist bestimmte Eingangsparameter verändert werden. Diese Anpassung wird als *Parametertuning* bezeichnet. Beim RF gibt es neben sekundären Parametern (bspw. Tiefe der Entscheidungsebenen) einen wesentlichen Hauptparameter, die Anzahl der Bäume. Dieser Hauptparameter wurde einmalig iterativ getestet. Dafür wurde das Skript in den Schritten 10, 50, 100, 500, 1.000, 5.000, 10.000 und 50.000 Bäumen komplett mit Training, Vorhersage und Validierung ausgeführt und dabei die Rechenzeit mit-erfasst (Computer: DELL OptiPlex 5050 SFF VP7RF | Intel Core i5-7500 CPU @ 3.40 GHz 3.41 GHz | 64 GB DDR4 SDRAM (2400MHz)).

Genutzt wurde PW als kleinster Datensatz hinsichtlich des Datenvolumens. Die Ergebnisse dieses iterativen Prozesses sind in Abbildung 6.1 zusammengefasst. Der OOB, also die Genauigkeit des trainierten Modells getestet an den Trainingsdaten, ist nach wenigen Bäumen (ca. 50) schon nahe bei 100 %. Das heißt, nur wenige Bäume werden benötigt, um die Trainingsspektren den richtigen Klassen zuzuordnen. Wenn diese Modelle dann durch unabhängige Validierungsdaten überprüft werden, ergeben sich ähnliche Ergebnisse, jedoch im Bereich um circa zehn Prozent niedriger und die Gesamtgenauigkeit der Klassifikation (OAA) steigt langsamer an. Ein Peak ist bei 500 Bäumen erreicht und ein Plateau stellt sich ein. Dagegen steigt die Prozessierungszeit exponentiell an, was bei den verwendeten Eingangsdaten mit niedrigem Datenvolumen jedoch erst ab einer Zahl von 1.000 Bäumen im Minutenbereich liegt.

Mit einem Sicherheitspuffer hinsichtlich der Klassifikationsgenauigkeit und die Prozessierungszeit berücksichtigend wurden in der Arbeit 500 Bäume verwendet. Diese Größe des RF wird auch wiederholt in der Literatur im Rahmen von Fernerkundungsarbeiten verwendet [CORCORAN et al. 2015; FRANKLIN et al. 2015; MEYER et al. 2017].

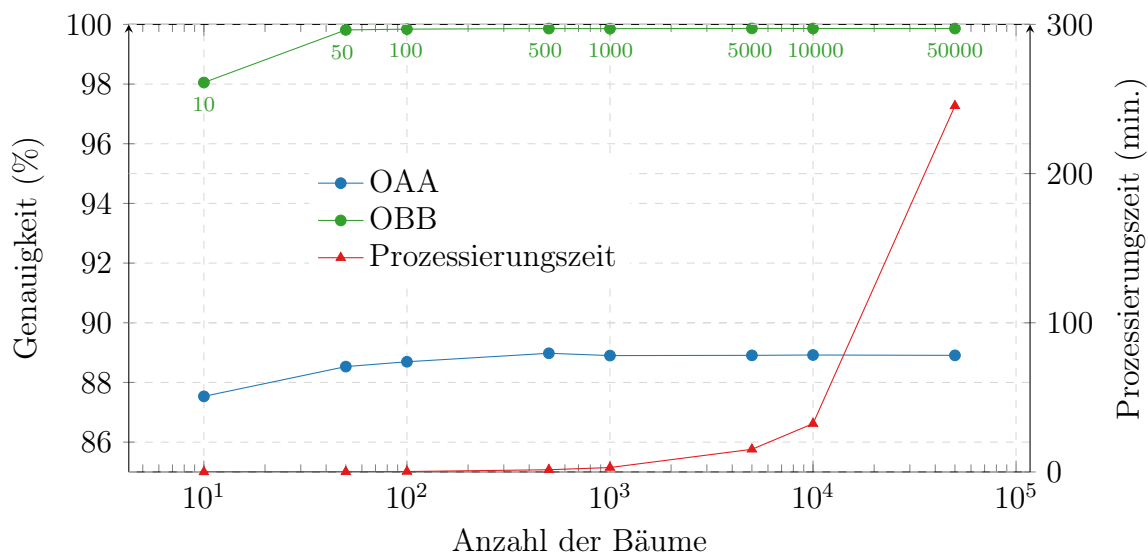


Abbildung 6.1: Vergleich verschiedener Baumzahlen im *Random Forest* anhand des Untersuchungsgebietes PW (OBB = *Out-of-Bag-Error*, OAA = *Overall Accuracy*, rot = Baumanzahl).

Training

Die Anzahl der, für das Training, verwendeten Pixel für die beiden Standorte sind in Tabelle 6.3 aufgeführt. Insgesamt wurden für die elf Klassen von PW 14.997 Pixel und für CDCW 16.270 Pixel für zehn Klassen verwendet. Die Größe der Trainingsflächen in Quadratmetern sind für beide Standorte vergleichbar. Im Mittel sind die Klassen $54,5 \text{ m}^2$ (STD = $79,5 \text{ m}^2$) für PW und für CDCW $65,1 \text{ m}^2$ (STD = $50,6 \text{ m}^2$) groß. Auffällig ist die hohe STD der Flächengrößen. Dies ist begründet durch die unterschiedlich starken Vorkommen der dominanten Pflanzenarten, sowie der wenigen Stellen, wo offener Boden (Torf) ansteht. Jedoch reichen auch die wenigen Trainingspixel aus, wie am Beispiel der Bodenklasse (PW 48 Pixel, CDCW 33 Pixel) gezeigt werden kann. Eine Anzahl von 33 Pixeln multipliziert mit 14 Kanälen ergibt eine Anzahl von 462 erklärenden unabhängigen Variablen, um den Boden von Vegetation zu trennen.

Methodisch werden solche Klassengrößenunterschiede während des Trainingsprozesses vom RF berücksichtigt. Dieser Schritt geschieht beim *bagging*, wo beim *boosting* immer eine gleichgewichtete Anzahl der berücksichtigten Klassen zusammengestellt wird (Kapitel 5.2.1).

Die Abbildung 6.2 zeigt gemittelte Spektren jeder Klasse der Trainingsdaten für PW (6.2a) und CDCW (6.2b). Die Anzahl der gemittelten Spektren pro Klasse entspricht der Anzahl der Pixel in Tabelle 6.3. Da diese Spektren aus verschiedenen Sensortypen zusammengesetzt und dadurch unterschiedlich skaliert sind, wurden zur Veranschaulichung die Werte des RGB-Sensors, des DOM und des Thermal-Sensors zwischen Null und Eins normiert. Damit verlaufen alle im multisensoralen Datensatz vorkommenden Werte in diesem Intervall. Für die Klassifikationen wurden die Originalwerte benutzt. Im Anhang A.7 sind die Originalwerte und die normierten Werte der Mittelwertspektren für PW (Tabelle A.5 und A.6) und CDCW (Tabelle A.7 und A.8) zusätzlich tabellarisch aufgeführt. Die Annahme könnte nun sein,

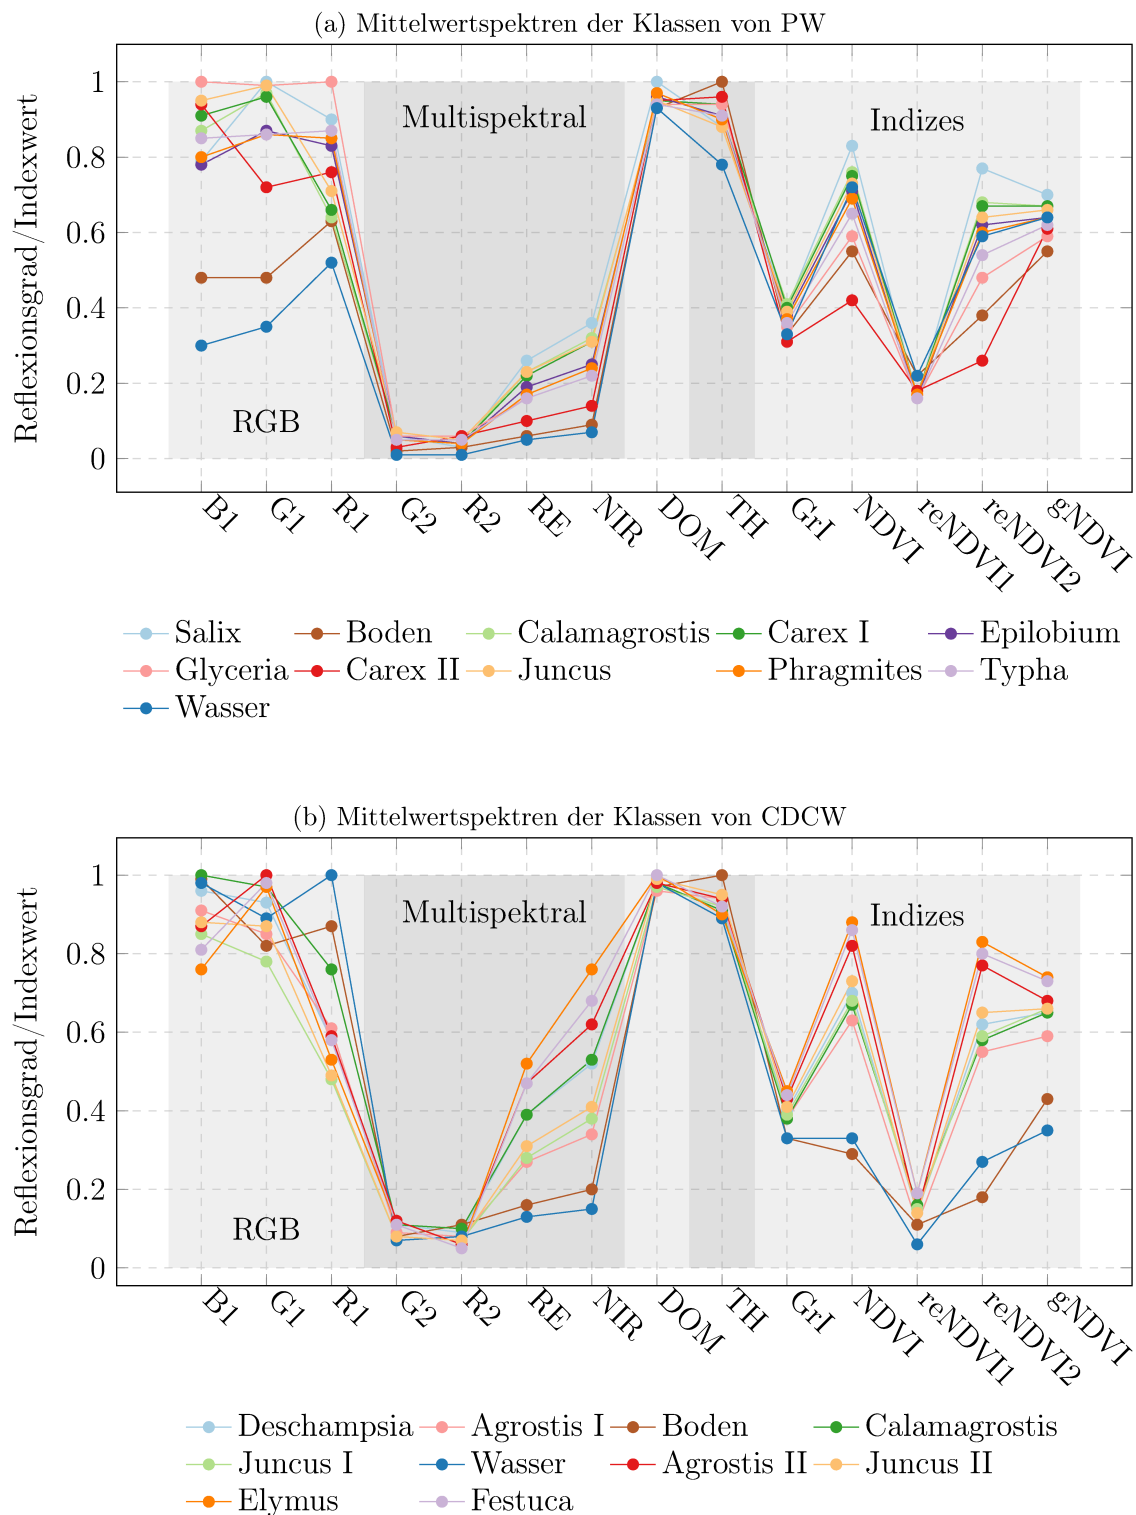


Abbildung 6.2: Multisensorale Mittelwertspektren der Klassen von PW (6.2a) und CD-CW (6.2b). Zur besseren Veranschaulichung wurden die Wertebereiche des RGB-Sensors, des DOM, der Thermal-Daten und des GI zwischen 0 und 1 normiert. Die originalen und normierten Werte sind den Tabellen im Anhang A.7 zu entnehmen. Die Auswahl der Farben für die Klassen wurde nach HARROWER und BREWER [2003] getroffen.

Tabelle 6.3: Gesamtzahl der Trainingspixel und deren Fläche (in m^2) für jede Klasse der beiden Testgebiete PW und CDCW.

| PW | | | CDCW | | |
|---------------|--------|------------------|---------------|--------|------------------|
| Klasse | Pixel | Fläche (m^2) | Klasse | Pixel | Fläche (m^2) |
| Salix | 980 | 39,2 | Deschampsia | 3.909 | 156,4 |
| Boden | 48 | 1,9 | Agrostis I | 1.770 | 70,8 |
| Calamagrostis | 501 | 20,0 | Boden | 33 | 1,3 |
| Carex I | 2.829 | 113,2 | Calamagrostis | 3.282 | 131,3 |
| Epilobium | 1.051 | 42,0 | Juncus I | 2.559 | 102,4 |
| Glyceria | 320 | 12,8 | Wasser | 1.449 | 58,0 |
| Carex II | 801 | 32,0 | Agrostis II | 1.016 | 40,6 |
| Juncus | 411 | 16,4 | Juncus II | 376 | 15,0 |
| Phragmites | 6.895 | 275,8 | Elymus | 1.151 | 46,0 |
| Typha | 1.073 | 42,9 | Festuca | 725 | 29,0 |
| Wasser | 88 | 3,5 | | | |
| | 14.997 | 599,9 | Summe | 16.270 | 9376,5 |

dass die Spektrenverläufe mit der höchsten Variabilität die wichtigsten Variablen bzw. Kanäle sein werden, um die Klassen zu unterscheiden. Auffällig ist, dass die Verläufe im RGB-Bereich (hellgrau) und die Werte des reNDVI2 sehr verschieden sind. Dagegen scheinen der multispektrale Bereich (grau) und die Werte des DOM oder des reNDVI1 wenig zu streuen.

Der OOB-Fehler gibt Auskunft über die Robustheit bzw. Qualität des Trainings. Der OOB lag bei beiden Standorten sehr hoch, PW = 94,6 % und CDCW = 94,4 %. Somit wird der Trainingsdatensatz mit fast 95 % Genauigkeit vom RF-Modell klassifiziert.

Vorhersage / Klassifikation

Die trainierten Modelle wurden nun genutzt um die gesamten multisensoralen Datensätze vorherzusagen (Abbildung 6.3). Die Patch-Struktur der Vegetation in PW ist in der Klassifikation sehr gut erkennbar (Abbildung 6.3a). Diese Struktur ist eine typische Charakteristik, verursacht durch *quasi*-natürliche Sukzession in wiedervernässten Durchströmungsmooren. So bilden sich auf der Fläche *Sukzessionskeime* von deren Zentren sich die Vegetation langsam ausbreitet. Besonders gut lässt sich das an den runden Patches der Klassen Phragmites (dunkelorange) und Carex II (dunkelrot) erkennen. Laut TIMMERMANN et al. [2006] bilden sich diese horizontalen Vegetationsstrukturen frühestens nach drei bis vier Jahren nach der Wiedervernäsung. Die Ergebnisse von PW, wiedervernässt seit den späten 1990ern, bestätigen das.

Phragmites australis-Gürtel dominieren entlang der ehemaligen Drainagen und wachsen von da aus in die Fläche hinein. *Phragmites australis* ist bekannt für seine sehr distinkten Dominanzbestände, was auch von TIMMERMANN et al. [ebd.] im Pennetal (Nordost-Deutschland) und im Hanság-Niedermoor (Neusiedler See,

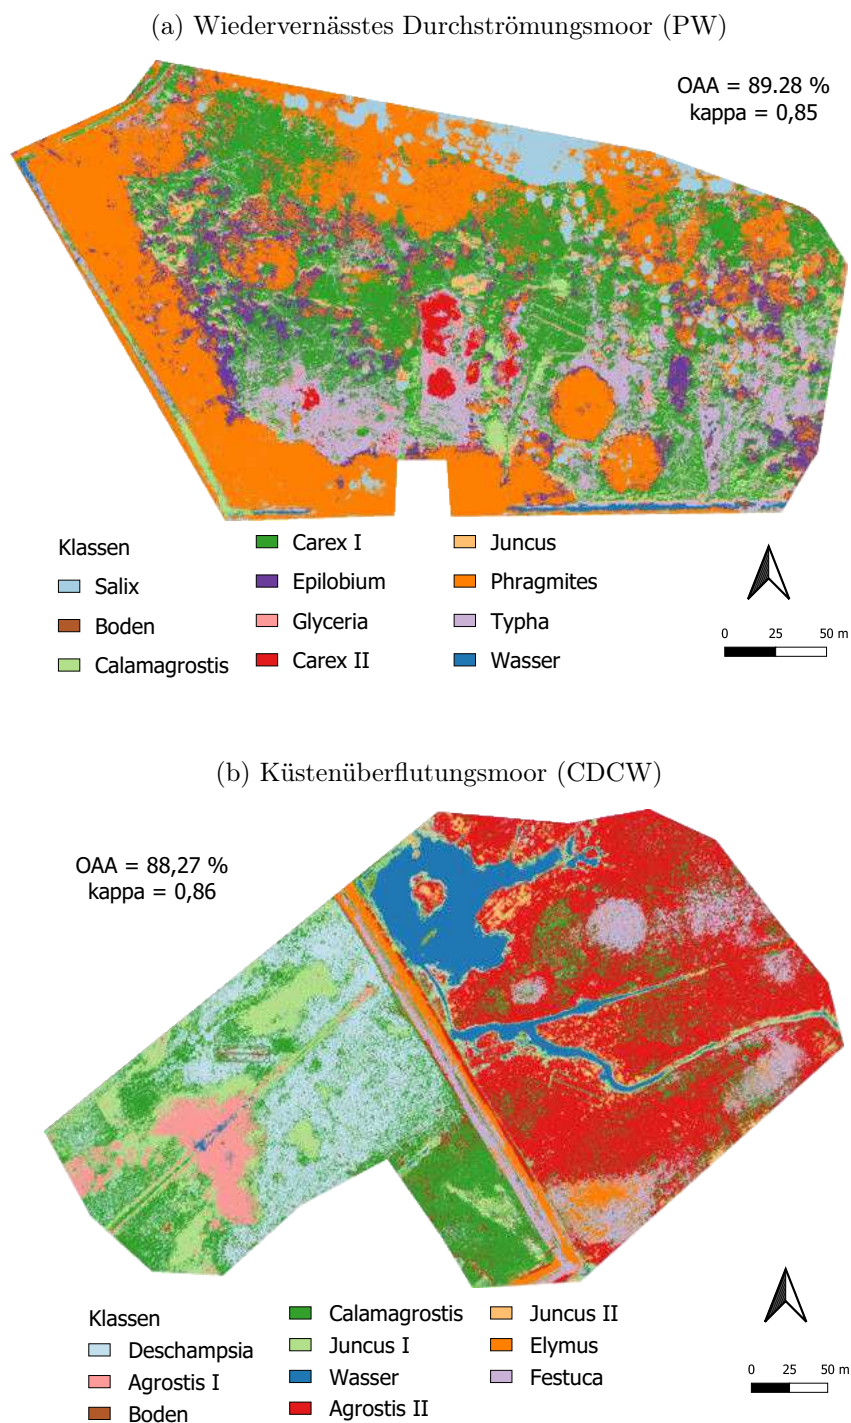


Abbildung 6.3: Ergebnisse der RF-Klassifikation für PW und CDCW. Gesamtgenauigkeit der Klassifikationen von PW OAA = 89,3 % und CDCW OAA = 88,3 %. Die Auswahl der Farben für die Klassen wurde nach HARROWER und BREWER [2003] getroffen.

Nordwest-Ungarn) beobachtet wurde. Diese ausgeprägten dominanten Bestände erlauben kaum eine Entwicklung anderer Arten. Im südlichen Teil der Fläche hat sich ein *Typha latifolia*-Gürtel (hellviolett) vom früheren Entwässerungskanal und den *Phragmites australis*-Beständen in Ost-West-Richtung entwickelt. *Typha latifolia* tritt vergesellschaftet mit *Sparganium erectum*, *Glyceria maxima* und *Phalaris arundinacea* auf. Im Norden befinden sich, eingerahmt von *Phragmites australis*-Beständen, große Gebiete mit verschiedenen Seggenarten (*Carex spec.*). Die Klasse Carex I (dunkelgrün) wird dominiert von *Carex acutiformis* und *Carex riparia*. Die Klasse Carex II besteht größtenteils aus *Carex acuta* und *Carex rostrata*. Die genannten Arten bilden die Haupttorfbildner am Standort PW [IGAMBERDIEV et al. 2013]. Außerdem treten noch weitere Arten auf, wozu *Epilobium hirsutum*, *Glyceria maxima*, *Juncus effusus* und *Juncus subnodulosus* zählen.

Im westlichen zentralen Bereich in PW waren die Bestände sehr heterogen, die patch-artige Struktur nicht gegeben und es war schwierig, eine klare Dominanz einer Art festzustellen. Dies wurde im Gelände beobachtet und auch in der Klassifikation ist dieser Sachverhalt erkennbar. Daher wurde in diesem Bereich darauf verzichtet Trainingsdaten zu selektieren. Da die dort vorkommenden dominanten Arten jedoch in anderen Zonen des Untersuchungsgebietes patch-artig vorhanden waren und damit die spektrale Referenz dort selektiert werden konnte, wird der Vorteil von Fernerkundungsdaten in einem so heterogenen Gebiet deutlich. So kann der Klassifikator diese sehr heterogene Fläche pixelweise sehr gut abbilden.

Die Dichotomie des Testgebietes CDCW ist auch in der Klassifikation anhand der Verteilung der dominanten Arten gut erkennbar (Abbildung 6.3b). Auch hier bilden sich Patch-Strukturen, jedoch nicht so deutlich wie in PW. Der drainierte Teil (CD) im Südwesten ist klar separiert durch die Linienstruktur des Deiches vom nordwestlichen wiedervernässten Teil (CW) der periodisch von der Ostsee überflutet wird. CD wird größtenteils von *Deschampsia cespitosa* (hellblau), *Juncus effusus* (hellgrün) und *Calamagrostis epigejos* (dunkelgrün) dominiert. Im Zentrum ist eine kleine Depression (feuchteres Regime) sichtbar, wo sich *Agrostis stolonifera* (hellrot) dominierend entwickelt hat.

Der periodisch überflutete Teil (CW) besitzt zwei markante offene Wasserflächen (dunkelblau). Ansonsten wird die Fläche größtenteils von *Agrostis stolonifera* (dunkelrot) und *Calamagrostis epigejos* (dunkelgrün) dominiert. Beide Arten kommen auch dominant im entwässerten Teil vor, jedoch sind die spektralen Charakteristika innerhalb von *Agrostis stolonifera* sehr unterschiedlich je nachdem ob sie in CD oder CW wachsen (Abbildung 6.4). Interessanterweise tritt *Agrostis stolonifera* in CD nur in den tieferen Teilen des Standortes (in der Depression) dominant auf. Die Wachstumsunterschiede von *Agrostis stolonifera* lassen sich durch die unterschiedlichen Feuchtigkeitsregime (zwischen CD und CW) im Boden und die daraus resultierenden unterschiedlichen phänologischen Verläufe erklären. *Agrostis* I, im trockeneren eingedeichten Bereich (CD), zeigt im multispektralen Bereich (grau) deutlich niedrigere Vitalitätszeichen. Die Reflexion im nahen Infrarot ist deutlich herabgesetzt und im roten Spektralbereich höher, was auch an niedrigeren Indexwerten der multispektralen Indizes zu sehen ist (*Agrostis* I NDVI = 0,63; *Agrostis* II NDVI = 0,82). In CW sind weiterhin kleinere Flächen bewachsen mit *Festuca rubra* (hellviolett) und *Elymus repens* (dunkelorange). Das *Festuca rubra* sich derart patch-artig auf der Fläche dominant gegen *Agrostis stolonifera* durchsetzt könnte ein Hinweis darauf

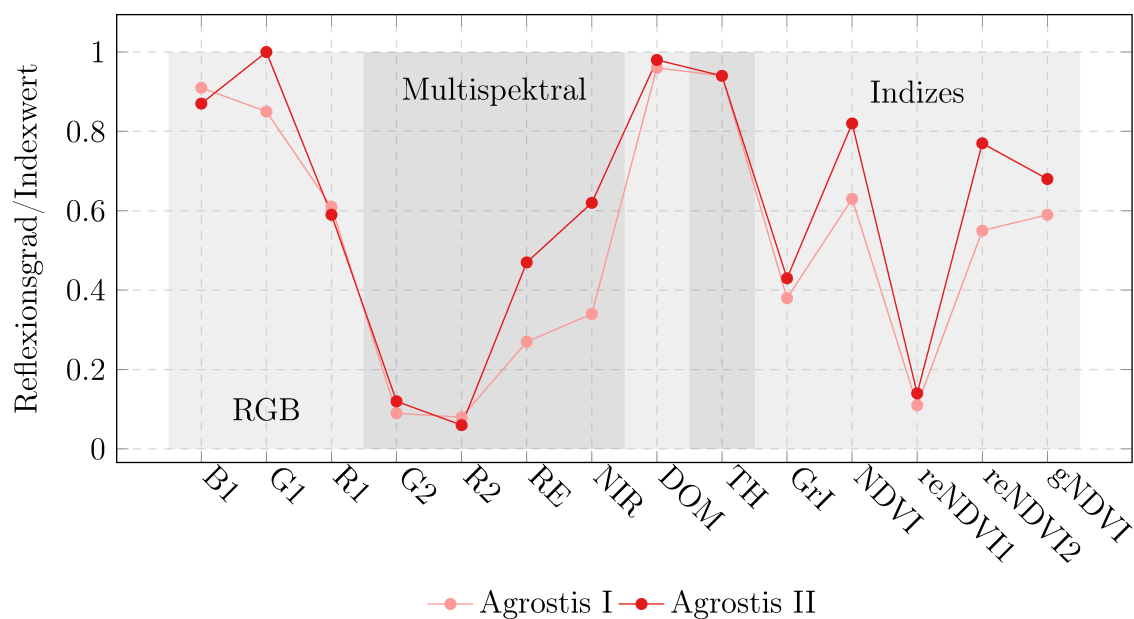


Abbildung 6.4: Spektrale Unterschiede von *Agrostis stolonifera* je nach Standort CD (Agrostis I) oder CW (Agrostis II).

sein, dass hier das Gelände etwas höher ist und somit sich das Feuchtigkeitsregime ändert. *Juncus gerardii* (hellorange) bildet kleine horstartige Bestände und siedelt sich in unmittelbarer Nähe zu den Wasserflächen an. Daher scheint der Prozess der Wiedervernässung und die dadurch entstehenden offenen Wasserflächen ein geeignetes Feuchtigkeitsregime zu etablieren, damit sich *Juncus gerardii* entwickeln kann.

Validierung

Die unabhängigen Validierungsdatensätze, die nicht am Training des RF beteiligt waren, wurden genutzt um die Klassifikationen unabhängig zu validieren und um die Konfusionsmatrizen zu erstellen (Tabelle 6.4).

Die Konfusionsmatrizen wurden genutzt, um die unterschiedlichen Genauigkeitsmaße zu berechnen. Die Zahl der Validierungspixel entsprach in etwa der Zahl der Trainingspixel (11.750 Pixel in PW und 12.741 für CDCW). Die OAA der RF-Klassifikationen erreichten für beide Standorte fast 90 %. Für die elf Klassen von PW ergaben sich eine OAA = 89,3 % ($\kappa = 0,85$) und für die zehn Klassen von CDCW eine OAA = 88,3 % ($\kappa = 0,86$).

Diese Ergebnisse sind als sehr genau einzustufen, weil eine hohe Anzahl an Klassen bestehend aus grüner Vegetation meist sehr schwer zu trennen sind. Andere Arbeiten zeigten oft, dass das Reflexionsverhalten zwischen verschiedenen Pflanzenarten oft weniger Unterschiede zeigt als innerhalb einer Spezies in unterschiedlichen Vitalitätszuständen [FRICK et al. 2011; BEYER et al. 2015a]. Daher kann für diese Ergebnisse geschlussfolgert werden, dass der Einsatz von verschiedenen Sensorarten, bzw. verschiedenen Datentypen die Separierung von spektral sehr ähnlicher Vegetation entscheidend verbessert [BEYER et al. 2015b].

Ein differenzierteres Bild ergibt sich bei der Betrachtung der Genauigkeiten der einzelnen Klassen (Abbildung 6.5). Die einzelnen Klassengenauigkeiten von PW

Tabelle 6.4: Konfusionsmatrizen der unabhängigen Validierung der RF-Klassifikationen von PW (a) und CDCW (b). Zeilen entsprechen den klassifizierten Pixel und die Spalten den Klassen des Validierungsdatensatzes (Referenz-Pixel).

| (a) PW | | | | | | | | | | | | | (b) CDCW | | | | | | | | | | | | | | |
|---------|------------|-----------|------------|--------------|------------|------------|------------|------------|--------------|------------|-----------|---------------|-------------|---------|--------------|--------------|-----------|--------------|--------------|--------------|------------|------------|------------|------|---------------|--------|--|
| Klassen | Sal | Bod | Cal | CarI | Epi | Gly | CarII | Jun | Phr | Typ | Was | Summe | UA (%) | Klassen | Des | AgrI | Bod | Cal | JunI | Was | AgrII | JunII | Ely | Fes | Summe | UA (%) | |
| Sal | 476 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 144 | 0 | 0 | 620 | 76,8 | Des | 2.334 | 0 | 0 | 589 | 158 | 0 | 0 | 1 | 0 | 0 | 3.082 | 75,7 | |
| Bod | 0 | 36 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 38 | 94,7 | AgrI | 5 | 1.790 | 0 | 2 | 38 | 0 | 0 | 0 | 0 | 0 | 1.835 | 97,5 | |
| Cal | 0 | 0 | 272 | 109 | 0 | 0 | 0 | 10 | 0 | 9 | 0 | 400 | 68,0 | Bod | 0 | 2 | 32 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 34 | 94,1 | |
| CarI | 0 | 0 | 0 | 1.642 | 5 | 0 | 0 | 104 | 0 | 32 | 0 | 1.794 | 91,5 | Cal | 343 | 0 | 0 | 1.601 | 37 | 0 | 0 | 0 | 0 | 0 | 1.981 | 80,8 | |
| Epi | 0 | 0 | 0 | 71 | 877 | 0 | 0 | 8 | 196 | 13 | 0 | 1.165 | 75,3 | JunI | 14 | 9 | 0 | 115 | 1.371 | 0 | 0 | 0 | 0 | 0 | 1.509 | 90,9 | |
| Gly | 0 | 0 | 1 | 21 | 0 | 164 | 0 | 0 | 0 | 114 | 0 | 300 | 54,7 | Was | 0 | 5 | 0 | 0 | 0 | 1.530 | 0 | 0 | 0 | 0 | 1.535 | 99,7 | |
| CarII | 0 | 0 | 0 | 0 | 0 | 0 | 497 | 0 | 0 | 0 | 0 | 497 | 100,0 | AgrII | 0 | 0 | 0 | 0 | 0 | 0 | 840 | 1 | 0 | 0 | 841 | 99,9 | |
| Jun | 0 | 0 | 0 | 87 | 4 | 0 | 0 | 114 | 0 | 27 | 0 | 255 | 44,7 | JunII | 2 | 0 | 0 | 3 | 0 | 0 | 21 | 252 | 0 | 0 | 278 | 90,6 | |
| Phr | 23 | 0 | 0 | 0 | 107 | 0 | 0 | 0 | 5.347 | 0 | 0 | 5.477 | 97,6 | Ely | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 57 | 980 | 94,0 | | |
| Typ | 0 | 0 | 15 | 81 | 6 | 30 | 3 | 4 | 0 | 992 | 0 | 1.131 | 87,7 | Fes | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 83 | 576 | 666 | 86,5 | | |
| Was | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 73 | 73 | 100,0 | Summe | 2.698 | 1.806 | 32 | 2.312 | 1.607 | 1.530 | 863 | 256 | 1.004 | 633 | 12.741 | | |
| Summe | 499 | 36 | 322 | 2.011 | 999 | 194 | 500 | 240 | 5.687 | 1.187 | 75 | 11.750 | 89,3 | PA (%) | 86,5 | 99,1 | 100,0 | 69,2 | 85,3 | 100,0 | 97,3 | 98,4 | 91,7 | 91,0 | | | |
| PA (%) | 95,4 | 100,0 | 84,5 | 81,7 | 87,8 | 84,5 | 99,4 | 47,5 | 94,0 | 83,6 | 97,3 | | | | | | | | | | | | | | | | |

sind generell sehr hoch (Abbildung 6.5a). Zunächst wird die Benutzergenauigkeit (UA) betrachtet. Sie zeigt wie viele Pixel pro, in der Validierung, verwendete Pixel der Klasse tatsächlich richtig zugeordnet wurden (Tabelle 6.4a). Die beiden Nicht-Vegetationsklassen Wasser und Boden konnten mit 95 % und 100% besonders gut klassifiziert werden, weil diese Oberflächentypen, verglichen mit denen der grünen Vegetation, ein anderes Reflexionsverhalten zeigen. Abbildung 6.2a (Seite 76)




Abbildung 6.5: Benutzer- und Produzentengenauigkeit aller Klassen der Standorte PW und CDCW.

zeigt die deutlichen Unterschiede zwischen den Vegetationsklassen und den Nicht-Vegetationsklassen Wasser (dunkelblau) und Boden (braun). Letztere zeichnen sich durch die niedrigste Reflexion im multispektralen Bereich (grau) aus. Darüber hinaus zeigten auch die Vegetationsgesellschaften, die am meisten auf der Fläche vorkommen, die höchsten Genauigkeiten. Dazu zählen die Seggen der Klassen Carex I und Carex II, sowie Phragmites und Typha¹. Diese Klassen erreichten Genauigkeiten zwischen 87 % und 100 %. Insbesondere die Klassen Carex II (*Carex rostrata* und *Carex acuta*) und Phragmites wurde sehr präzise klassifiziert. Für die genannten Klassen wurde kaum ein Validierungspixel falsch klassifiziert. Bei Carex I (UA = 91,5 % von 1.794 Pixeln) kam es vor allem zu Verwechslungen mit der Klasse Juncus

¹Nicht kursiv geschriebene Namen sind die fernerkundlichen Klassen, die aus mehreren kursiv geschriebenen dominanten Pflanzenarten bestehen können, wie Carex I bestehend aus *Carex acutiformis* und *Carex riparia* (Siehe auch Abschnitt 4.3).

(104 Pixel). Bei der Klasse *Typha* wurden wenige Pixel (139 von 1.131) mehreren verschiedenen Klassen zugewiesen. Dazu zählen *Carex* I, *Glyceria*, *Epilobium*, *Calamagrostis*, *Carex* II und *Juncus*. Jedoch ist das Gewicht dieser 139 Fehlzuordnungen sehr klein im Vergleich zu den 1.131 *Typha*-Pixeln (Tabelle 6.4a).

Außerdem muss bei solchen Fehlklassifizierungen berücksichtigt werden, dass jede Klasse als Pflanzengesellschaft bestehend aus dominanten und sporadisch vorkommenden Arten betrachtet werden muss. So können Arten auch vergesellschaftet in der Klasse *Typha* wachsen, die der Klassifikator zwar richtig erkennt, jedoch das Polygon des Validierungsdatensatzes nicht berücksichtigt. Beispielsweise kommen *Carex*-Arten in geringer Deckung auch vergesellschaftet mit *Typha latifolia*-Beständen vor. Ein zweiter Grund für solche Fehlklassifizierungen ist dem Sachverhalt geschuldet, dass die Validierungs-Polygone scharfe Grenzen ziehen, jedoch die Übergänge zwischen den Patches in der Realität und in den UAS-Aufnahmen diffus bzw. fließend sind. Bei drei Klassen wurden niedrigere Genauigkeiten erzielt. Dazu zählen *Calamagrostis* (68 %), *Glyceria* (54,7 %) und *Juncus* (44,7 %), wobei besonders *Juncus* die niedrigste Klassifikationsgenauigkeit erreichte. Auf PW kommen dominant zwei *Juncus*-Arten vor, *Juncus effusus* und *Juncus subnodulosus*, die in der Klasse *Juncus* (hellorange) zusammengefasst wurden. Jedoch sind die dominanten Bestände sehr klein parzelliert und heterogen verteilt. Sie bilden keine großen zusammenhängenden Bestände aus, wie *Phragmites* oder *Carex* I. Dies bestätigt auch die Ergebnisse von IGAMBERDIEV et al. [2013] auf der gleichen Fläche. Hauptsächlich werden *Calamagrostis* und *Juncus* der Klasse *Carex* I falsch zugewiesen. Auch wenn die betrachteten Pflanzenarten ökologisch teils sehr verschieden sind, kann aus fernerkundlich-spektraler Sicht konstatiert werden, dass die Pflanzen der drei Klassen als gleich hoch wachsend und in ihrer Form bzw. Geometrie relativ ähnlich sind. So wachsen *Juncus effusus*, *Calamagrostis canescens* und *Carex acutiformis* in senkrechten, länglichen, schmalen Blättern bzw. Stängeln. Dem gegenüber besitzt *Epilobium hirsutum* beispielsweise breitere Blätter und deshalb kommt es daher nicht zu nennenswerten Verwechslungen außer zu *Phragmites australis*.

Mit der PA werden Aussagen dazu getroffen, wieviel Validierungspixel insgesamt der Klasse zugeordnet wurden und wie groß deren Anteil an der betrachtenden Klasse ist. Nur die Klasse *Juncus* (PA = 47,5 %) zeigt eine deutlich niedrigere PA. Das heißt, dass 240 Pixel insgesamt der Klasse zugeordnet wurden, jedoch nur 114 (47,5 %) tatsächlich *Juncus* waren. Die restlichen Klassen zeigten Produzentengenauigkeiten höher als 80 %, wobei die sechs Klassen *Salix*, *Boden*, *Epilobium*, *Carex* II, *Phragmites* und *Wasser* besonders hohe Genauigkeiten erreichten.

Auch in CDCW sind PA und UA generell sehr hoch (Abbildung 6.5b). Die zwei Nicht-Vegetationsklassen *Boden* und *Wasser* wurden, dank ihres sehr spezifischen Reflexionsverhaltens in beiden Genauigkeiten sehr präzise klassifiziert. Dieser Sachverhalt ist in Abbildung 6.2b (Seite 76) besonders gut im multispektralen Bereich (grau) und bei den multispektralen Indexwerten zu sehen. So weisen *Wasser* (dunkelblau) und *Boden* (braun) die niedrigsten Werte auf.

Auch *Agrostis* I (PA = 99,1 %, UA = 97,5%) und II (PA = 97,3 %, UA = 99,9 %) wurden mit fast 100 % vorhergesagt. Die Genauigkeiten von UA und PA sind auch bei den Klassen *Juncus* I, *Juncus* II, *Elymus* und *Festuca* über, in zwei Fällen nah bei, 90 %. Die Klasse *Deschampsia* zeigt eine zufriedenstellende PA =

Tabelle 6.5: Relevanz der Kanäle (Gini-Index GI) bei der RF-Klassifikation für beide Standorte PW und CDCW.

| Nr. | PW | | | CDCW | | |
|-------|---------|-----|--------|---------|-----|--------|
| | Kanal | Nr. | GI (%) | Kanal | Nr. | GI (%) |
| 1 | DOM | 8 | 38,38 | DOM | 8 | 20,64 |
| 2 | TH | 9 | 10,37 | NIR | 7 | 10,27 |
| 3 | reNDVI2 | 13 | 8,76 | TH | 9 | 9,29 |
| 4 | NDVI | 11 | 7,54 | RE | 6 | 8,21 |
| 5 | GrI | 10 | 7,42 | R1 | 3 | 6,82 |
| 6 | NIR | 7 | 5,43 | gNDVI | 14 | 6,57 |
| 7 | gNDVI | 14 | 3,88 | reNDVI2 | 13 | 6,13 |
| 8 | RE | 6 | 3,68 | NDVI | 11 | 6,07 |
| 9 | G2 | 4 | 3,06 | GrI | 10 | 5,70 |
| 10 | R2 | 5 | 2,63 | reNDVI1 | 12 | 5,70 |
| 11 | B1 | 1 | 2,59 | G2 | 4 | 5,46 |
| 12 | reNDVI1 | 12 | 2,21 | R2 | 5 | 3,65 |
| 13 | R1 | 3 | 2,19 | B1 | 1 | 3,06 |
| 14 | G1 | 2 | 1,85 | G1 | 2 | 2,42 |
| Summe | | | 100,00 | 100,00 | | |

86,5 %, was heißt, dass die meisten Validierungspixel dieser Klasse zugewiesen wurden. Jedoch bedeutet eine $UA = 75,7\%$, dass ein Viertel der Validierungspixel auch anderen Klassen zugewiesen wurde. Viele Validierungspixel von *Calamagrostis* (589) und *Juncus I* (158) gehören eigentlich zur Klasse *Deschampsia*. Dieser Sachverhalt kann dadurch erklärt werden, dass die Pflanzenarten dieser drei Klassen besonders im entwässerten Teil (CD) stark vergesellschaftet vorkommen. Aus diesem Grund erreichte die Klasse *Calamagrostis* auch die niedrigste PA von 69,2 %. Neben der problematischen Separierung der beiden Klassen *Deschampsia* und *Calamagrostis*, wurde auch ein Teil der Pixel von *Juncus I* mit diesen Arten verwechselt. *Festuca* und *Elymus* kommen größtenteils auf der wiedervernässten Seite (CW) vor und sind dort stark vergesellschaftet, was die gegenseitigen Fehlzuordnungen erklärt.

Kanalrelevanz

Die Bewertung der Kanalrelevanzen ist zentraler Gegenstand der Untersuchung. Zunächst wird die Wichtigkeit der einzelnen Kanäle des multisensoralen Datensatzes für die Klassifikation ermittelt. Welcher Kanal hat den höchsten Informationsgehalt zur Unterscheidung von Moorvegetation? Danach werden die Kanalrelevanzen im Sensorverband untersucht. Dafür wurde der GI (Gini Index in Kapitel 5.2.1) für jeden Kanal berechnet und eine prozentuale Relevanz ausgegeben.

Tabelle 6.5 fasst die Ergebnisse der Kanalrelevanzen zusammen. Für beide Standorte, PW und CDCW, war mit großem Abstand der wichtigste Kanal das DOM.

Die Abbildungen 6.6a und 6.7a zeigen das DOM mit den ellipsoidischen Höhen. Genauer zeigt das DOM die Summe der ellipsoidischen Höhe und der Höhe des Pflanzenbestandes. Beide Standorte zeigen kaum Reliefunterschiede, was bedeutet, dass

die ellipsoidische Höhe im gesamten Gebiet nahezu identisch ist. Die Untersuchungsgebiete können vielmehr als flache Ebenen mit wenigen Mikrorelief-Unterschieden bezeichnet werden. Diese Reliefunterschiede werden deutlich durch die unterschiedlichen Höhen der Pflanzenbestände überdeckt. Daher kann das DOM als Modell für unterschiedliche Höhen der Pflanzenbestände interpretiert werden. Die Pflanzhöhen tragen bei der Klassifikation also zu 2/5 in PW und 1/4 in CDCW zur Unterscheidung der Klassen bei. Bei der Betrachtung der Höhenunterschiede aller Vegetationseinheiten von CDCW zu PW, können zwei wesentliche Sachverhalte konstatiert werden:

1. Die Vegetation ist in CDCW generell niedriger und es gibt im betrachteten Bereich keine Bestände von *Phragmites australis* oder *Typha latifolia*.
2. Die Höhendifferenzen zwischen den dominanten Pflanzen ist in CDCW niedriger als in PW.

Diese Punkte führen dazu, dass der Einfluss bzw. die Relevanz des DOM in PW höher ist, als in CDCW.

Für PW wurden exemplarisch zwei Profilschnitte (Abbildungen 6.6b und 6.6c) durch das DOM gelegt, um den Unterschied der Pflanzhöhen zu verdeutlichen. In den Höhenprofilen 1 und 2 zeigen die Bereiche A, C und E den deutlichen Höhenunterschied zwischen *Phragmites australis* zu den anderen torfbildenden Pflanzen. Die Zwischenbereiche im Höhenprofil 1 zwischen A und B, B und C₁, nach D, sowie im Höhenprofil 2 zwischen C und G zeigen, dass die Klassen *Carex* I, *Carex* II, *Calamagrostis* und auch *Typha* keine signifikanten Höhenunterschiede im DOM aufweisen. Die Bereiche B, D, F und G sind besonders hoch, da sie von der Baumart *Salix spec.* bewachsen sind.

Die Dichotomie von CDCW spiegelt sich besonders gut in den Höhenunterschieden wider. Auch hier wurden zwei Höhenprofile durch das DOM gelegt (Abbildungen 6.7b und 6.7c). Abgesehen vom Deich (Bereich B in Abbildung 6.7b) sind die Höhenunterschiede innerhalb der Pflanzenbestände im Vergleich zu PW geringer. Der Bereich im Deichhinterland (CD, mittlere DOM-Höhe = 37,54 m) ist im Mittel 60 cm höher als der *nasse* Bereich im Vorland (CW, mittlere DOM-Höhe = 36,94 m). Der Bereich A im Höhenprofil 1 (Abbildung 6.7b) zeigt eine Mikrorelief-Senke, die gleichzeitig das dominante Auftreten von *Agrostis stolonifera* verursacht. Demgegenüber stehen die Bereiche C und D auf CW (Abbildungen 6.7b und 6.7c), wo kleinere Mikrorelief-Erhebungen der Grund sind, das sich *Festuca rubra* dominant ausbildet, welches sonst auf der Fläche stark vergesellschaftet mit *Agrostis stolonifera* der Klasse *Agrostis* II untergeordnet wird. Die beiden lokalen Minima E und F in Höhenprofil 2 (Abbildung 6.7c) sind Abflussrinnen, die sich bei periodischen Überschwemmungen nach Sturmfluten durch abfließendes Wasser gebildet haben.

An zweiter Stelle der Kanalrelevanzen stehen die Thermaldaten in PW. Auch in CDCW scheinen diese Daten mit einem GI von 9,3 % (drittichtigster Kanal) ein hohes Gewicht zu haben. Vergleiche vom DOM und der thermalen Daten zeigen besonders für PW, dass höhere und flächenmäßig größere Bestände (bspw. *Phragmites australis*) niedrigere Temperaturen aufweisen, was eventuell mit dem kühlenden Charakter durch Evaporationskälte begründet werden kann. Diese Beobachtung hat aber keine generelle Gültigkeit, weil die Regression der beiden Datensätze ($r^2 = 0,18$, $p = 0,000$) keinen signifikanten Zusammenhang zeigt.

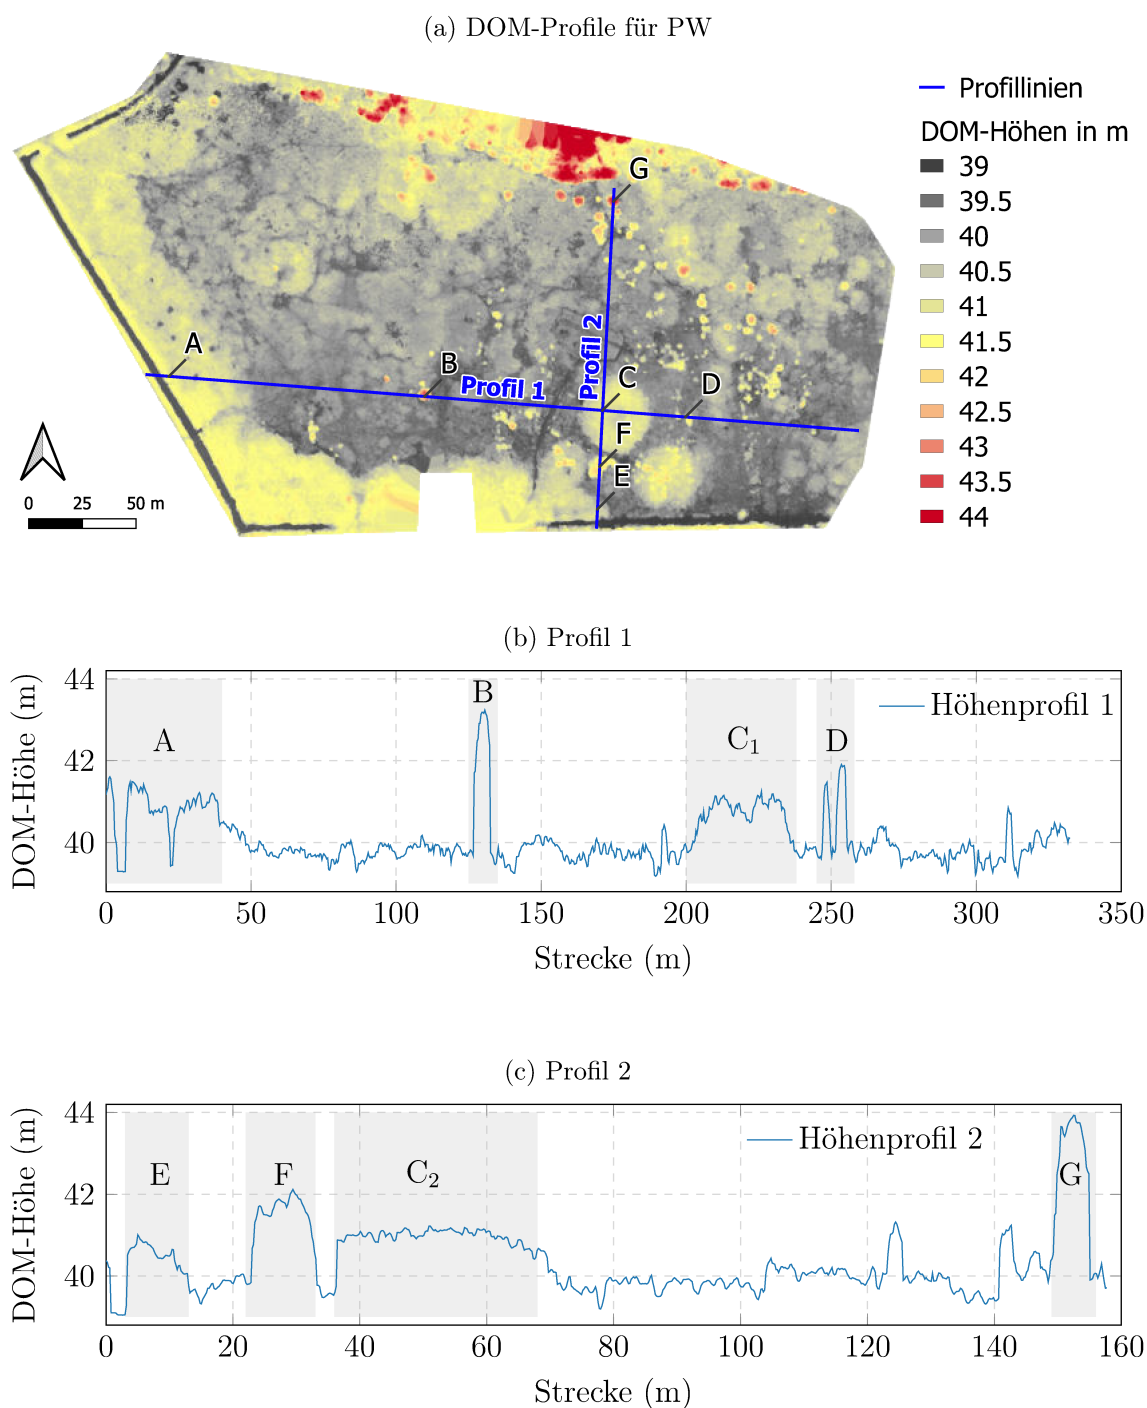


Abbildung 6.6: Exemplarische Höhenprofile durch das DOM von PW.

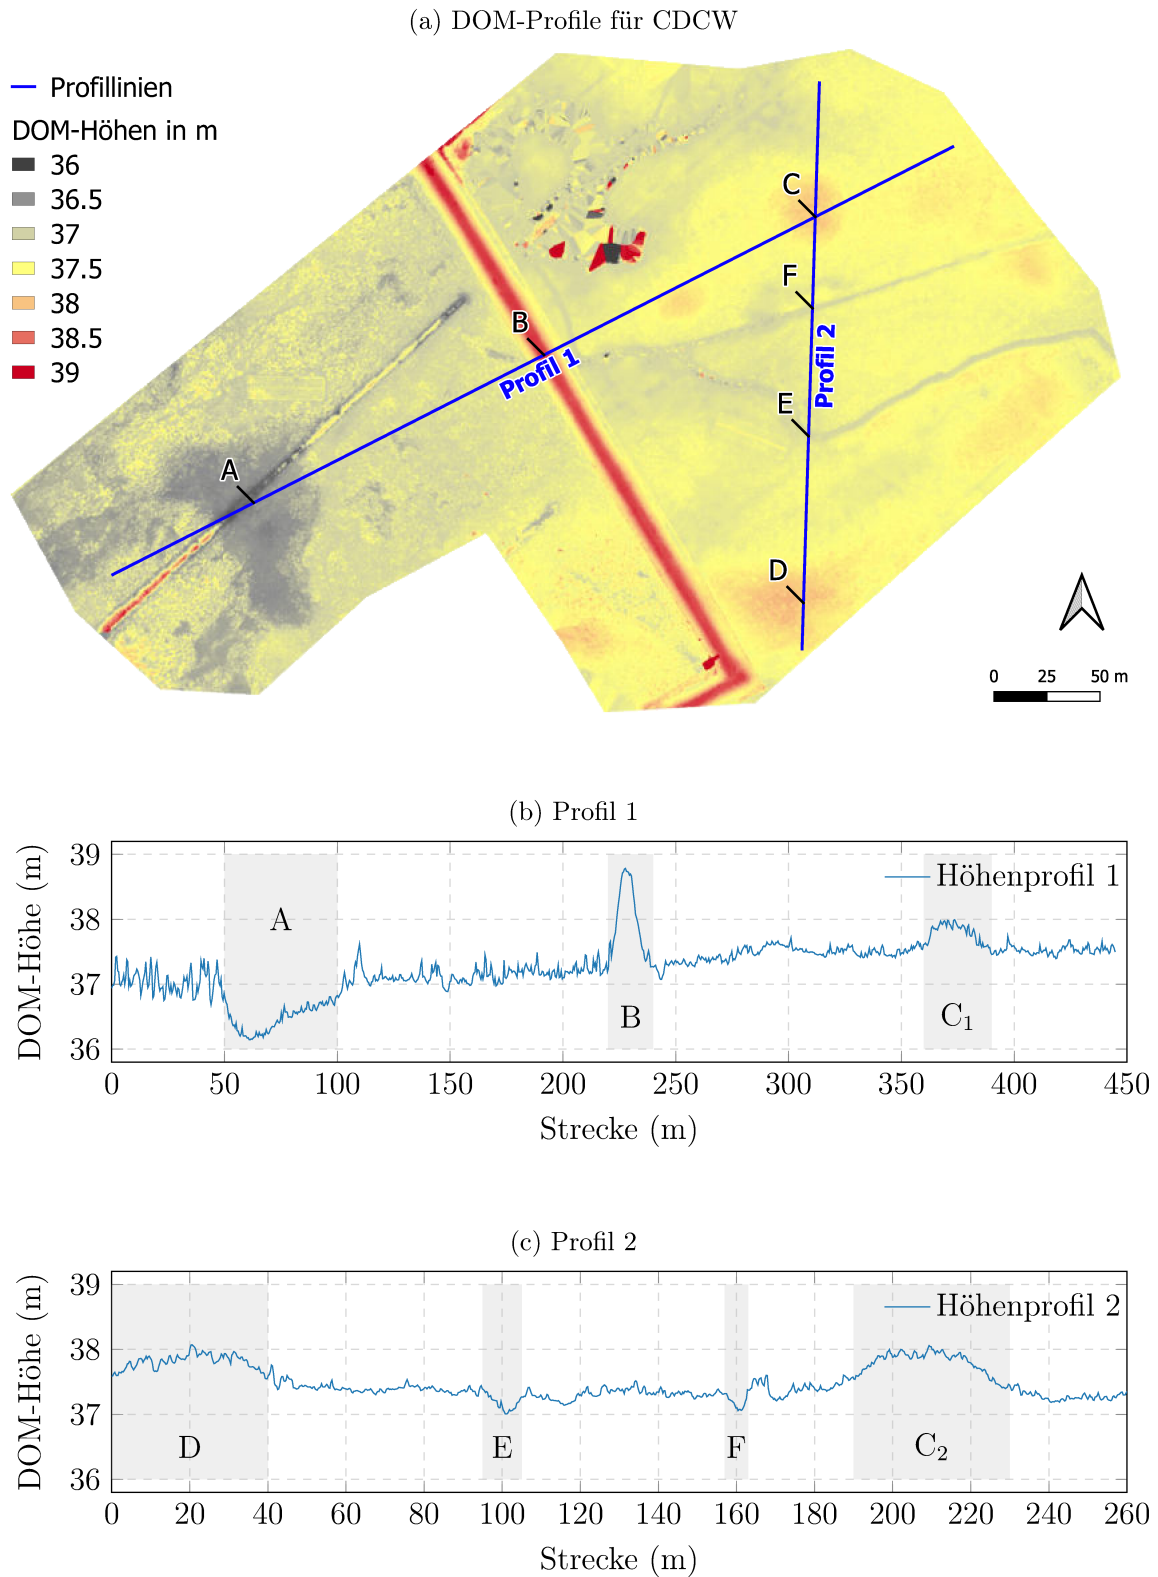


Abbildung 6.7: Exemplarische Höhenprofile durch das DOM von CDCW.

Neben der hohen Relevanz des DOM und der Thermaldaten ist der Tabelle 6.5 auch zu entnehmen, dass alle Informationen aus den infraroten Kanälen bzw. daraus abgeleitete Indizes wichtig sind bei der Unterscheidung verschiedener Vegetationsarten. Bei PW sind fünf, bei CDCW alle sechs Infrarotkanäle/-indizes unter den wichtigsten 10 der 14 Kanäle. Die Erkenntnis, dass der infrarote Spektralbereich (700 - 1.000 nm) besonders wichtig für Vegetationsanalysen ist, zeigen zahlreiche Studien in der Fernerkundung [KNIPLING 1970; CECCATO et al. 2001; XIE et al. 2008; JACQUEMOUD et al. 2009]. Strukturelle Merkmale der grünen Vegetation, insbesondere von Blättern, sind wichtig für den typischen Reflexionsverlauf in diesem Spektralbereich [JONES und VAUGHAN 2010; THENKABAIL et al. 2012]. Somit kann geschlussfolgert werden, dass die Infrarotkanäle und deren Indizes eine hohe Relevanz bei der Differenzierung von Pflanzengesellschaften aufweisen. Der Infrarotindex reNDVI1, berechnet aus den Kanälen Nahes Infrarot (NIR) und RE, ist bei beiden der Kanal mit dem geringsten Informationsgehalt. Im elektromagnetischen Spektrum liegen diese Kanäle sehr dicht beieinander und können pflanzenphysiologisch dem gleichen Wirkungsbereich zugeordnet werden. Daher tritt eine hohe Korrelation der beiden Kanäle von $r = 0,97$ ($p = 0,000$ für PW) auf und die Berechnung des Index scheint daher keinen großen Gewinn für die Klassifikation zu haben.

Außerdem zeigt sich, dass der Klassifikator bei beiden Standorten die wenigsten Informationen aus den Kanälen des RGB-Sensors zieht. Dies ist zum einen interessant, weil in den Mittelwertspektren der Trainingsdaten (Abbildung 6.2, Seite 76) diese Kanäle eine besondere Variabilität zeigten. Zum anderen ist es wenig überraschend, weil diese Daten als unprozessierte Roh-Daten einfließen und keine belastbaren, physikalisch basierten Reflexionswerte wie die Multispektraldaten sind. Die Multispektraldaten des Sequoia-Sensors haben dafür einen bestimmten Aufnahme- und Vorprozessierungsschritt durchlaufen (vgl. Kapitel 4.1, Multispektraldaten), der bei den RGB-Daten fehlt.

Der Echtfarb-Index GrI, generiert aus den RGB-Rohdaten, zeigt hingegen moderate Relevanz für PW und bei CDCW zumindest mehr Relevanz als Grün und Blau. Dieser Index kommt in ökologischen Modellierungen als standardisiertes Maß für RGB-Daten oft zur Anwendung [AHRENDTS et al. 2009; WESTERGAARD-NIELSEN et al. 2013].

Abhängigkeit der Kanalrelevanzen von der Anzahl an Bäumen im Random Forest

Auch hier wurde ein Test durchgeführt, inwiefern die Kanalrelevanz abhängig von der Anzahl der Bäume im RF ist. Dafür wurden wieder die verschiedenen Baumanzahlen (vgl. oben Parametertuning) und der Datensatz von PW verwendet. Abbildung 6.8 zeigt, dass die acht Iterationen mit 10–50.000 Bäumen keine signifikanten Unterschiede in der Ordnung der Kanalrelevanz zeigt. Egal welche Anzahl an Bäumen verwendet wird, die Ordnung der Kanäle bleibt stabil. Da intern die Entscheidung, welche Variablen der RF zur Unterscheidung der Klassen verwendet, mithilfe der Entropie erfolgt, zeigt sich, dass die Klassen beim *Bagging* so gezogen werden, dass die Ordnung gleich bleibt. Dies ist auch ein Hinweis darauf, dass die Menge an Trainingsdaten ausreicht, um die Klassen im Klassifikator zu repräsentieren.




Abbildung 6.8: Kanalrelevanz in Abhängigkeit zur Anzahl der verwendeten Bäume im RF, durchgeführt mit dem multisensoralen Datensatz von PW.

Aus der Relevanz der Einzelkanäle kann geschlussfolgert werden, dass die wichtigsten Variablen zur Unterscheidung von Vegetation auf Niedermooren die Pflanzenhöhe aus dem DOM und die Infrarotreflexion aus den Multispektraldaten ist. Jedoch werden diese Kanäle nicht durch einzelne Befliegungen aufgenommen, sondern im Verbund mit anderen des jeweiligen Sensors. Daher muss die Kanalrelevanz auch sensorweise untersucht werden. Eine Überprüfung der kumulativen Kanalrelevanzen nach Sensor zeigt ein anderes Bild (Tabelle 6.6). Für die kumulative Betrachtung wurden die Kanäle wie folgt zusammengerechnet:

$$MS = G2 + R2 + RE + NIR + NDVI + reNDVI1 + reNDVI2 + gNDVI$$

$$RGB = B1 + G1 + R1 + GrI$$

$$TH = Thermal$$

$$DOM = DOM$$

Das DOM wurde dabei unabhängig der RGB-Daten betrachtet, weil dieses Produkt theoretisch auch aus den Multispektral- oder auch den Thermaldaten berechnet werden könnte. Bei beiden Standorten zeigt sich jetzt, dass die Daten des Multispektral-

Tabelle 6.6: Sensorweise kumulierte Relevanzen der Kanäle mit Hilfe des Gini-Index (GI) für PW und CDCW.

| No. | PW | | CDCW | |
|-------|--------|--------|--------|--------|
| | Sensor | GI (%) | Sensor | GI (%) |
| 1 | DOM | 38,38 | MS | 52,06 |
| 2 | MS | 37,21 | DOM | 20,64 |
| 3 | TH | 14,05 | RGB | 18,00 |
| 4 | RGB | 10,37 | TH | 9,29 |
| Summe | | 100,00 | 100,00 | |

sensors sehr hohe Relevanz haben. Besonders bei CDCW, wo die Unterschiede der Pflanzenhöhen nicht so groß sind, ist der Multispektralsensor mit 52,1 % gegenüber 20,6 % des DOM der mit Abstand wichtigste Datensatz. Das DOM ist weiterhin sehr wichtig in PW und kann als gleichrangig zu den Multispektraldaten gezählt werden.

Werden lediglich die einzelnen Datensätze pro Sensor klassifiziert, sinken die Genauigkeiten der Klassifikation deutlich. Für PW bspw. ergeben die OAA-Werte des vierkanaligen Multispektral-Datensatzes 56,4 % ($\kappa = 0,35$) und die des DOM 64,4 % ($\kappa = 0,5$). Die alleinige Kombination von multispektralen Daten und DOM erreicht eine OAA von 86,1 % ($\kappa = 0,81$), was nochmals zeigt, dass Thermal- und RGB-Daten kaum zur Klassifikation beitragen.

Bei CDCW fallen die Klassifikationen etwas anders aus, was an den schon diskutierten Pflanzenhöhenunterschieden liegt. Die Klassifikationsergebnisse der Einzeldatensätze ergibt für die Multispektraldaten allein eine OAA = 78,1 % ($\kappa = 0,72$). Das einzelne DOM erreicht lediglich 44,4 % ($\kappa = 0,35$). Dies bedeutet, dass die spektrale Reflexionsinformation an Wichtigkeit gewinnt, wenn die Pflanzenbestände homogener werden. Und dies nicht nur hinsichtlich ihrer Höhenverteilung, sondern auch ihrer Dispersion über die Fläche. Benutzt man eine Kombination aus multispektralen Daten und dem DOM erhält man in CDCW eine OAA von 79,6 % ($\kappa = 0,76$). Auch die RGB- und Thermal-Daten werden vom Klassifikator in CDCW mehr verwendet und bringen immerhin eine Verbesserung um etwa neun Prozent, wobei die RGB-Daten um Faktor zwei wichtiger sind als die Thermaldaten, was die Wichtigkeit der spektralen Reflexion unterstreicht.

6.2.2 Klassifikation der Vegetationsbestände im Hütelmoor (PaW) zur Untersuchung der Dürre 2018 aus multisensoralen UAS-Daten

Im Folgenden wird die Prozessierungskette nochmals auf den Moorstandort PaW angewendet. Das soll weniger das Klassifikationsverfahren erneut testen als vielmehr die gefundenen Erkenntnisse bestätigen. Danach wird im nächsten Abschnitt für PaW eine Vielzahl weiterer Indizes berechnet, um deren Relevanz zu testen und tiefergehend die einzelnen Spektralbereiche bzw. Sensortypen zu untersuchen.

Außerdem wurde der Standort 2018 von einer starken Dürreperiode erfasst, welche einen abrupten und starken Wandel in der Verteilung der dominanten Vegetation verursachte. Um diesen Wandel in Relation zum Zustand vor der Dürre zu setzen, wird das Ergebnis mit Klassifikationen von KOCH et al. [2017] verglichen.

PaW wurde zunächst in der gleichen Weise wie die Standorte PW und CDCW bearbeitet. Das heißt, der multitemporale Datensatz, bestehend aus 14 Kanälen, wurde trainiert, das trainierte Klassifikationsmodell und die Kanalrelevanzen wurden ausgewertet, der gesamte Datensatz vorhergesagt und unabhängig validiert.

Training

Zunächst wurde das Training auf dem 14-kanaligen multisensoralen Datensatz durchgeführt. Das Training umfasste insgesamt 14.667 Pixel (Tabelle 6.7). Dies erscheint

Tabelle 6.7: Gesamtzahl der Trainingspixel und deren Fläche (in m²) für jede Klasse von PaW.

| Klasse | Pixel | Fläche in (m ²) |
|-------------|--------|-----------------------------|
| Phragmites | 3.558 | 222,38 |
| Schoe/Bolbo | 1.105 | 69,06 |
| Carex | 4.119 | 257,44 |
| Tephroseris | 411 | 25,69 |
| Boden/Lemna | 298 | 18,63 |
| Wasser | 4.231 | 264,44 |
| Ranunculus | 945 | 59,06 |
| Summe | 14.667 | 916,69 |

zunächst weniger als bei PW und CDCW, aber hier muss der größere GSD von 25 cm gegenüber 20 cm bei CDCW und PW berücksichtigt werden. Da die beflogene Fläche von PaW deutlich größer war (multispektral ca. 95 ha) als die der beiden Standorte PW (multispektral ca. 13,5 ha) und CDCW (multispektral ca. 15,2 ha), wurde eine Flughöhe von etwa 100 m geflogen, was einen größeren GSD zur Folge hatte. Die Trainingsflächen in absoluten Quadratmeterzahlen sind auch hier vergleichbar mit denen der beiden anderen Standorte.

Das trainierte Modell ergab auch bei PaW eine Genauigkeit von nahezu 100 % (OOB = 99,51 %), was bedeutet, dass die Pixel des Trainingsdatensatzes vom trainierten Modell vollständig richtig zugeordnet werden.

Klassifikation und Analyse der Dürreauswirkungen

Das Klassifikationsergebnis wird in Abbildung 6.9 gezeigt. Die Farben der Klassen wurden hier der Veröffentlichung von KOCH et al. [ebd.] angepasst, damit die Vegetationszusammensetzung besser mit der von 2014 verglichen werden kann. Die dominante Klasse ist *Phragmites australis* (gelb). Wie in PW bildet sich dieser Pflanzenbestand entlang der ehemaligen Entwässerungsgräben, die in der Klassifikation als linienhafte (blaue) Strukturen zu sehen sind. Zwischen diesen Beständen haben sich etwas entfernt vom offenen Wasserkörper die restlichen Arten entwickelt. *Bolboschoenus maritimus* und *Schoenoplectus tabernaemontani* kommen zusammengefasst als Klasse Bolbo/Schoeno sehr dispers verteilt auf dieser Fläche vor. Die Klasse Carex bildet eher zusammenhängende kleinere Bestände. Der Anteil der Klasse Boden ist marginal. Große Flächen werden dominant von *Tephroseris palustris* und *Ranunculus sceleratus* bewachsen.

Letztgenannte Klassen sind von besonderer Bedeutung für die Analyse der dürrebedingten Standortveränderungen. Ein direkter Vergleich der beiden Jahre 2014 und 2018 wird in Abbildung 6.10 dargestellt. Die Klassifikationskarte des Standortes PaW für das Referenzjahr 2014 von KOCH et al. [ebd.] wird in Abbildung 6.10a gezeigt, die Ergebnisse der Klassifikation des Dürrejahres 2018 in Abbildung 6.10b. Zur besseren Visualisierung und der richtigen prozentualen Flächenanteile wurde die Karte 2018 auf die Ausdehnung des Untersuchungsgebietes aus KOCH et al. [ebd.] zugeschnitten. Auffällig ist, dass vor der Dürre 2018 der Anteil offener




Abbildung 6.9: Klassifikationsergebnis für PaW. (Die Klassenfarben sind optimiert für die digitale Betrachtung am Bildschirm und können gedruckt eventuell nicht hinreichend differenziert werden. Die Graphik ist im Digitalverzeichnis unter *Arbeit/Abbildungen/06_Ergebnisse/PaW_rfclass_map.pdf* zu finden.)

Wasserflächen bedeutend höher war (2014: 20,5 %, 2018: 2,4 %). Dieser Anteil ist 2014–2017 etwas gestiegen, jedoch stagnierten die Flächenanteile in diesen Jahren bis auf *Schoenoplectus tabernaemontani* und *Bolboschoenus maritimus* [BEYER et al. 2020].

In Abschnitt 3.1.2 wurden die klimatisch extremen Bedingungen (Abbildung 3.8, Seite 27) während der Sommerdürre 2018 vorgestellt und mit den Jahren 1999–2017 bzw. 2010–2017 verglichen. Ab dem Zeitpunkt als das Wasser unter Geländeoberkante fiel (Abbildung 3.8d), waren die etablierten Vegetationseinheiten (wie *Phragmites australis*, *Schoenoplectus tabernaemontani*, *Bolboschoenus maritimus* und *Carex acutiformis*) in einer fortgeschrittenen Phase der Phänologie. Demgegenüber wurden die nun neuen Flächen offenen Bodens von zwei neuen Arten (*Tephroseris palustris* und *Ranunculus sceleratus*) invasiv erobert, die vorher von Wasser und *Lemna minor* bedeckt waren (Abbildung 6.10). Die Besiedlung dieser neuen offenen Flächen kann daher als zweite verzögerte Vegetationsphase im Dürrejahr 2018 bezeichnet werden, die äußerst schnell und großflächig vonstattenging [ebd.].

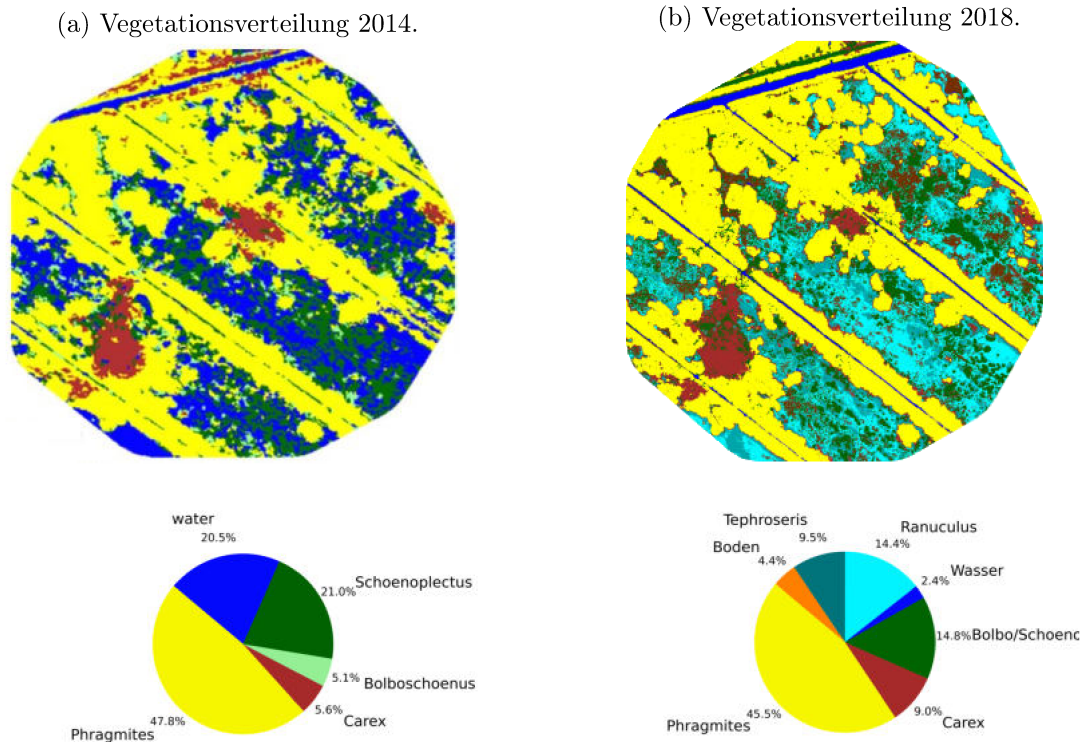


Abbildung 6.10: Zusammensetzung der dominanten Vegetationsarten 2014 (6.10a) aus KOCH et al. [2017] und nach der Dürre 2018 (6.10b).

Validierung

Die unabhängige Validierung der Klassifikation ergab eine sehr hohe Genauigkeit von OAA = 95.7 % ($\kappa = 0.94$). Auch die Einzelgenauigkeiten der Klassen sind bis auf eine Ausnahme sehr hoch oder betragen 100 % (Abbildung 6.11). Die Klasse Bolbo/Schoeno erreicht eine nur mittlere PA von 57,7 % (Tabelle 6.8). Dies bedeutet, dass zwar 98,9 % (UA) der Bolbo/Schoeno-Pixel aus dem Validierungsdatensatz richtig, jedoch eine fast ebenso hohe Anzahl an Pixel anderer Klassen zu Bolbo/Schoeno zugeordnet wurden. In diesem Falle wurden 444 Pixel der Klasse Carex fälschlicherweise der Klasse Bolbo/Schoeno zugewiesen. Das kann verschiedene Ursachen haben. Zum einen können Arten der Klasse Carex vergesellschaftet mit *Schoenoplectus tabernaemontani* und *Bolboschoenus maritimus* vorkommen. Zum anderen wurde der Flug in einem phänologischen Stadium (1. November 2018) durchgeführt, in der zwar *Tephroseris palustris* und *Ranunculus sceleratus* noch vital, jedoch die anderen Arten schon in einer seneszenten Phase waren. Das heißt, dass die Arten der Klasse Carex und Bolbo/Schoeno aufgrund ihrer niedrigen Vitalität spektral sehr ähnlich aussahen.

Kanalrelevanz

Der wichtigste Kanal zur Unterscheidung der dominanten Pflanzengesellschaften ist wieder das DOM (Tabelle 6.9a) mit einer Relevanz von anteilig mehr als einem Viertel (GI = 27,9 %). Bezüglich der Pflanzenhöhendifferenzen ist PaW mit PW




Abbildung 6.11: Benutzer- und Produzentengenauigkeiten aller Klassen der Klassifikation von PaW.

Tabelle 6.8: Konfusionsmatrix der Klassifikation des 14-kanaligen multisensoralen Datensatzes von PaW.

| Klassen | Phr | ScBo | Car | Tep | Bod | Was | Ran | Summe | UA (%) |
|---------|--------------|------------|--------------|------------|------------|--------------|------------|---------------|-------------|
| Phr | 3.277 | 4 | 13 | 0 | 0 | 0 | 0 | 3.294 | 99,5 |
| ScBo | 0 | 622 | 7 | 0 | 0 | 0 | 0 | 629 | 98,9 |
| Car | 0 | 444 | 3.676 | 25 | 0 | 0 | 0 | 4.145 | 88,7 |
| Tep | 0 | 0 | 0 | 350 | 0 | 0 | 0 | 350 | 100,0 |
| Bod | 0 | 1 | 0 | 0 | 118 | 0 | 0 | 119 | 99,2 |
| Was | 0 | 0 | 0 | 0 | 0 | 2.449 | 0 | 2.449 | 100,0 |
| Ran | 0 | 7 | 1 | 6 | 0 | 0 | 708 | 722 | 98,1 |
| Summe | 3.277 | 1.078 | 3697 | 381 | 118 | 2.449 | 708 | 11.708 | |
| PA (%) | 100,0 | 57,7 | 99,4 | 91,9 | 100,0 | 100,0 | 100,0 | | 95,7 |

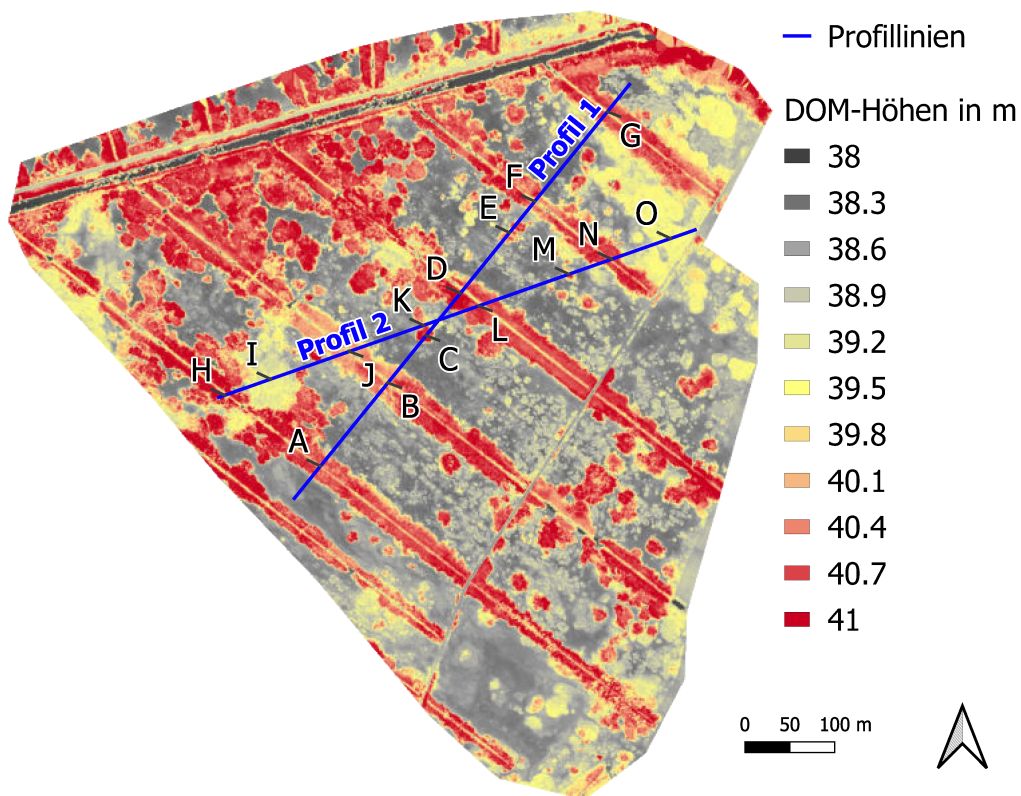
Tabelle 6.9: Relevanz der Kanäle (Gini-Index GI) der RF-Klassifikation für den Standort PaW und sensorweise kumulierte Relevanzen der Kanäle.

| (a) Kanalweise Relevanzen | | | | (b) Sensorweise Relevanzen. | | |
|---------------------------|---------------|-----|-----------|-----------------------------|--------|--------|
| Nr. | Kanal Name | Nr. | GI (%) | Nr. | Sensor | GI (%) |
| 1 | DOM | 8 | 27,79 | 1 | MS | 43,39 |
| 2 | TH | 9 | 11,55 | 2 | DOM | 27,79 |
| 3 | R2 | 5 | 8,78 | 3 | RGB | 17,26 |
| 4 | GrI | 10 | 7,15 | 4 | TH | 11,55 |
| 5 | G2 | 4 | 6,55 | Summe | | 100,00 |
| 6 | R1 | 1 | 5,73 | | | |
| 7 | gNDVI | 14 | 5,43 | | | |
| 8 | reNDVI2 | 13 | 5,42 | | | |
| 9 | RE | 6 | 5,34 | | | |
| 10 | NIR | 7 | 4,86 | | | |
| 11 | NDVI | 11 | 4,50 | | | |
| 12 | G1 | 2 | 3,04 | | | |
| 13 | reNDVI1 | 12 | 2,53 | | | |
| 14 | B1 | 3 | 1,34 | | | |
| Summe | | | 100,00 | | | |


vergleichbar. Auch hier haben sich mit *Phragmites australis* sehr viel höhere Pflanzenbestände gegenüber den anderen Arten ausgebildet (Abbildung 6.12). *Phragmites australis*-Bestände sind in den beiden Höhenprofilen (Abbildungen 6.12b und 6.12c) als lokale Maxima A–H, J–N markiert. Innerhalb dieser Bereiche sind lokale Minima zu erkennen (außer C, E, K, M), welche die ehemaligen, jetzt noch immer mit Wasser bestandenen Entwässerungsgräben darstellen. Die Bereiche C, E, K und M sind kleinere *Phragmites australis*-Zonen zwischen den Drainagegräben. Die nächstniedrigere Klasse ist *Carex*, welche gelb dargestellt wird (Bereiche I und O in Höhenprofil 2, Abbildung 6.12c). Außerdem ist in hellen Gelbtönen Bolbo/Schoeno dargestellt und in verschiedenen Grautönen die niedrigsten Zonen *Tephroseris*, *Ranunculus*, Boden und Wasser.

Auch der thermale Datensatz besitzt in der Einzelkanalbetrachtung eine große Relevanz mit 11,5 % auf dem zweiten Platz (Tabelle 6.9a). Ein diametraler Unterschied zu den Kanalrelevanzen von PW und CDCW sind jedoch die folgenden Ränge. In der Klassifikation PaW scheint der sichtbare Bereich des elektromagnetischen Spektrums, hier vor allem Grün und Rot, eine wichtigere Rolle zu spielen, als die Kanäle und Indizes des infraroten Bereiches. So belegen der grüne und der rote Kanal des Sequoia-Sensors Rang drei und fünf, der GrI Rang vier und der rote Kanal des RGB-Sensors den sechsten Rang. Da abgesehen von *Tephroseris palustris* und *Ranunculus sceleratus* alle Pflanzen schon in einer seneszenten Phase waren, ist die Vitalität der Pflanzen sehr niedrig und dementsprechend ist das Reflexionssignal im infraroten Bereich niedrig und gleichartig. Daher sind die unterschiedlichen Verfärbungen in der Absterbephase der Pflanzen von größerer Bedeutung. Diese Verfärbung äußert sich vor allem in der Abnahme der Grünreflexion und in der Zunahme in der Rotreflexion durch die Abnahme der photosynthetischen Aktivität [JONES und VAUGHAN

(a) DOM-Profile für PaW



(b) Profil 1



(c) Profil 2




Abbildung 6.12: Exemplarische Höhenprofile durch das DOM von PaW.

2010; THENKABAIL et al. 2012]. Die Relevanz der infraroten Kanäle waren trotzdem gegeben, bspw. für die Unterscheidung der photosynthetisch aktiven Arten *Ranunculus sceleratus* und *Tephrosieris palustris* sowie zur Unterscheidung dieser Arten von den seneszenten Pflanzenbeständen.

Bei den sensorweise kumulierten Relevanzen dominiert jedoch klar der multispektrale Sensor mit 43,3 % gegenüber dem DOM (Tabelle 6.9b). Wobei die beiden Farbkanäle des Multispektralsensors zu zwei Dritteln zu den 43,3 % beitragen. Aufgrund der hohen Ränge des GrI und des roten Kanals ist der RGB-Datensatz höher als der Thermaldatensatz eingestuft.

Bei der Klassifikation des reinen multispektralen Datensatzes wird eine relativ hohe Genauigkeit von OAA = 84,4 % ($\kappa = 0,78$) erreicht. Das DOM alleine erreicht eine Genauigkeit von OAA = 80,1 % ($\kappa = 0,73$). Dies sind für sich gesehen sehr gute Ergebnisse, wenn berücksichtigt wird, dass die Klassen aus grüner Vegetation verschiedener Arten bestehen [THENKABAIL et al. 2012]. Zusammengenommen erreichen die beiden Datentypen (multispektral + DOM) mit OAA = 94,4 % ($\kappa = 0,92$) annähernd das Ergebnis des 14-kanaligen multisensoralen Datensatzes (OAA = 95,6 %).

6.2.3 Erweiterung des multisensoralen Datensatzes

Nachdem nun gezeigt wurde, dass eine Fusion mehrerer Sensor- und Datentypen einen großen Mehrwert bei der Analyse von Vegetationsbeständen hat, wurden im nächsten Schritt weitere Indizes aus den Rohdaten² abgeleitet und zu einem *erweiterten* multisensoralen Datensatz zusammengefasst. Dieser erweiterte Datensatz wurde ebenfalls der gesamten Prozesskette unterzogen. In dieser Zusatzstudie sollte es weniger um die Verbesserung der Klassifikation gehen sondern vielmehr darum, den Informationsgehalt von anderen Indizes und Indextypen zu prüfen und weitere Hinweise zu bekommen, welche Datentypen geeignet sind um Vegetationsgesellschaften zu analysieren.

Dafür wurde eine Vielzahl weiterer Indizes berechnet, wobei diese sich in vier größere Klassen einteilen lassen. Zwei Klassen sind 74 spektrale Indizes generiert aus den Farb- bzw. Reflexionswerten der RGB- (sechs Indizes) und der Multispektraldaten (68 Indizes), eine Klasse aus neun Texturindizes aus den RGB-Daten und die vierte Klasse sind acht Terrain- bzw. Reliefindizes aus dem DOM. Letztere sind im engeren Sinne keine eigentliche Abbildung des Reliefs, da das DOM die Höhenunterschiede der Geländeoberkante einschließlich aller Objekte wie Vegetation und anthropogene Bauwerke abbildet. Diese Indizes werden trotz allem genutzt, weil sie Informationen über die Höhenunterschiede der Pflanzengesellschaften abbilden.

Insgesamt wurden 91 Indizes getestet und berechnet. Bis auf die Reliefindizes wurden alle Indizes in einem Python-Skript realisiert, welches ebenfalls auf *GitHub* (Anhang A.5) als *Python 3*-Skript abrufbar ist. Eine Übersicht aller Kanäle des erweiterten multisensoralen Datensatzes und der verwendeten Indizes ist in Tabelle 6.10 zu finden. Insgesamt hatte der erweiterte Datensatz eine Anzahl von 98 Kanä-

²Hier sind die RGB-, Multispektral- und Thermaldaten gemeint, die die Ausgangsdaten zur Indexberechnung sind und die im engeren Sinne aufgrund ihrer Vorprozessierung keine Rohdaten mehr sind.

6.2. KLASSIFIKATION VON MOORVEGETATION

Tabelle 6.10: Erweiterter multisensoraler Datensatz bestehend aus 98 Kanälen. In der jeweils letzten Spalte stehen entweder der Sensortyp (Sen.) oder aus welchen Sensordaten der jeweilige Kanal berechnet wurde (-> Gen. = Generiert aus).

| No. | Kanal | Typ | Sen. -> Gen. | No. | Kanal | Typ | Sen. -> Gen. |
|-----|-------------|----------------|-----------------|-----|-------------|---------------|-----------------|
| 1 | R1 | Rot | RGB | 50 | mtvi2 | Spektralindex | -> MS |
| 2 | G1 | Grün | RGB | 51 | myvi | Spektralindex | -> MS |
| 3 | B1 | Blau | RGB | 52 | ndrdi | Spektralindex | -> MS |
| 4 | G2 | Grün | MS | 53 | ndre | Spektralindex | -> MS |
| 5 | R2 | Rot | MS | 54 | ndvi | Spektralindex | -> MS |
| 6 | RE | RedEdge | MS | 55 | nli | Spektralindex | -> MS |
| 7 | NIR | Nahes Infrarot | MS | 56 | normg | Spektralindex | -> MS |
| 8 | DOM | DOM | -> RGB | 57 | normnir | Spektralindex | -> MS |
| 9 | TH | Thermal | Thermal | 58 | normr | Spektralindex | -> MS |
| 10 | ari | Spektralindex | -> MS | 59 | osavi1 | Spektralindex | -> MS |
| 11 | arvi2 | Spektralindex | -> MS | 60 | osavi2 | Spektralindex | -> MS |
| 12 | atsavi | Spektralindex | -> MS | 61 | pvr | Spektralindex | -> MS |
| 13 | avi | Spektralindex | -> MS | 62 | rdvi | Spektralindex | -> MS |
| 14 | bri | Spektralindex | -> MS | 63 | rededge2 | Spektralindex | -> MS |
| 15 | ccci | Spektralindex | -> MS | 64 | savi | Spektralindex | -> MS |
| 16 | chlgreen | Spektralindex | -> MS | 65 | sbl | Spektralindex | -> MS |
| 17 | chlrededge | Spektralindex | -> MS | 66 | spvi | Spektralindex | -> MS |
| 18 | cigreen | Spektralindex | -> MS | 67 | tcari | Spektralindex | -> MS |
| 19 | cirededge | Spektralindex | -> MS | 68 | tcari2 | Spektralindex | -> MS |
| 20 | ctvi | Spektralindex | -> MS | 69 | tcari_osavi | Spektralindex | -> MS |
| 21 | cvi | Spektralindex | -> MS | 70 | tci | Spektralindex | -> MS |
| 22 | datt1 | Spektralindex | -> MS | 71 | tc_gvimss | Spektralindex | -> MS |
| 23 | datt4 | Spektralindex | -> MS | 72 | tc_nsimss | Spektralindex | -> MS |
| 24 | ddn | Spektralindex | -> MS | 73 | tc_sbimss | Spektralindex | -> MS |
| 25 | diff1 | Spektralindex | -> MS | 74 | tc_yvimss | Spektralindex | -> MS |
| 26 | diff2 | Spektralindex | -> MS | 75 | tvi | Spektralindex | -> MS |
| 27 | dvimss | Spektralindex | -> MS | 76 | varirededge | Spektralindex | -> MS |
| 28 | evi2 | Spektralindex | -> MS | 77 | wdrvi | Spektralindex | -> MS |
| 29 | evi22 | Spektralindex | -> MS | 78 | exg | Spektralindex | -> RGB |
| 30 | fe3 | Spektralindex | -> MS | 79 | gcc | Spektralindex | -> RGB |
| 31 | gemi | Spektralindex | -> MS | 80 | gli | Spektralindex | -> RGB |
| 32 | gndvi | Spektralindex | -> MS | 81 | ngrdi | Spektralindex | -> RGB |
| 33 | gosavi | Spektralindex | -> MS | 82 | tgi | Spektralindex | -> RGB |
| 34 | grndvi | Spektralindex | -> MS | 83 | vari | Spektralindex | -> RGB |
| 35 | lai | Spektralindex | -> MS | 84 | asm | Texturindex | -> RGB |
| 36 | lci | Spektralindex | -> MS | 85 | cont | Texturindex | -> RGB |
| 37 | logr | Spektralindex | -> MS | 86 | diss | Texturindex | -> RGB |
| 38 | maccioni | Spektralindex | -> MS | 87 | ene | Texturindex | -> RGB |
| 39 | mari | Spektralindex | -> MS | 88 | ent | Texturindex | -> RGB |
| 40 | mcari | Spektralindex | -> MS | 89 | homo | Texturindex | -> RGB |
| 41 | mcari1 | Spektralindex | -> MS | 90 | ma | Texturindex | -> RGB |
| 42 | mcari2 | Spektralindex | -> MS | 91 | mean | Texturindex | -> RGB |
| 43 | mcari_mtvi2 | Spektralindex | -> MS | 92 | std | Texturindex | -> RGB |
| 44 | mcari_osavi | Spektralindex | -> MS | 93 | aspect | Reliefindex | -> DOM |
| 45 | mgvi | Spektralindex | -> MS | 94 | hillshade | Reliefindex | -> DOM |
| 46 | mnsi | Spektralindex | -> MS | 95 | roughness | Reliefindex | -> DOM |
| 47 | msavi | Spektralindex | -> MS | 96 | slope | Reliefindex | -> DOM |
| 48 | msbi | Spektralindex | -> MS | 97 | tpi | Reliefindex | -> DOM |
| 49 | msr670 | Spektralindex | -> MS | 98 | tri | Reliefindex | -> DOM |

len.

Alle Spektralindizes wurden in der Index-Datenbank IDB (<https://www.index-database.de>) recherchiert, wo zu jedem Index auch Sekundärliteratur zu finden ist [HENRICH et al. 2009, 2012]. Die Abkürzungen der Indizes wurde dabei der IDB entnommen und können dort recherchiert werden.

Die Texturindizes nach [HARALICK et al. 1973] werden basierend auf der Grauwertmatrix *Gray Level Co-occurrence Matrix* (GLCM) bzw. Co-occurrence-Matrix berechnet. Diese statistische Methode höherer Ordnung wird genutzt, um eine In-

Tabelle 6.11: Genutzte Texturindizes berechnet aus der GLCM.

| Deutsch | Englisch | Abkürzung |
|----------------------|------------------------------|-----------|
| Zweites Winkelmoment | <i>Angular Second Moment</i> | asm |
| Kontrast | <i>Contrast</i> | cont |
| Heterogenität | <i>Dissimilarity</i> | diss |
| Energie | <i>Energy</i> | ene |
| Entropie | <i>Entropy</i> | ent |
| Homogenität | <i>Homogeneity</i> | homo |
| Maximum | <i>Maximum</i> | max |
| Mittelwert | <i>Mean</i> | mean |
| Standardabweichung | <i>Standard deviation</i> | std |

formation über die Rauigkeit und den Kontrast der Textur in den Bilddaten zu erhalten. Die GLCM beschreibt die Häufigkeit des gemeinsamen Vorkommens gleicher Grauwerte. Für die Berechnung der GLCM wurde aus den RGB-Daten ein panchromatisches Bild (*PAN*) nach ALRUBAIEA und HAMEED [2018] berechnet,

$$PAN = 0.3 * R1 + 0.59 * G1 + 0.11 * B1 \quad (6.1)$$

wobei *R1*, *G1* und *B1* den drei Kanälen des RGB-Datensatzes entsprechen. Aus der GLCM wurden bestimmte Parameter nach HARALICK et al. [1973], HALL-BEYER [2017a] und HALL-BEYER [2017b] berechnet, die in Tabelle 6.11 aufgelistet sind. Die Größe des genutzten *Kernels* wurde auf 11 Pixel festgelegt, also einem *Sliding Window* von 2,75 m mal 2,75 m.

Die Reliefindizes wurden mithilfe des offenen Softwarepaketes GDAL [GDAL/OGR CONTRIBUTORS 2020] berechnet. Als Grundlage diente das DOM. Berechnet wurden die Indizes (Tabelle 6.10) Exposition (*aspect*), Schummerung (*hillshade*), Rauigkeit (*roughness*), Hangneigung (*slope*), der *Topographic Position Index* (*tpi*, WEISS [2001]) und der *Terrain Ruggedness Index* (*tri*, WILSON et al. [2007]).

Ergebnisse des erweiterten multisensoralen Datensatzes

Das Training des 98-kanaligen Datensatzes ergab ein OOB von 99,74 %. Die unabhängig validierte Gesamtgenauigkeit beträgt $OAA = 98,5 \%$ ($\kappa = 0.98$). Die Erweiterung des multisensoralen Datensatzes ergab daher eine Verbesserung des ohnehin schon hohen Ergebnisses um fast drei Prozent. Tabelle 6.12 zeigt die Genauigkeiten der einzelnen Klassen. Prinzipiell sind die Genauigkeitsmaße UA und PA bei allen Klassen sehr nah bei 100 %, bis auf eine Ausnahme. Die Klasse Schoeno/Bolbo zeigte bei dem Klassifikationsergebnis des einfachen multisensoralen Datensatzes eine PA von 57,7 % (Tabelle 6.8), was bedeutet, dass fast doppelt so viele Pixel vom Validierungsdatensatz falsch zugeordnet wurden. Diese Falschzuordnungen kamen hauptsächlich durch die Fehlklassifikation von Pixeln der Klasse Carex. Nach Ergänzung des multisensoralen Datensatzes mit weiteren Indizes stieg die PA dieser Klasse um 26 % auf 87,7 % (Tabelle 6.12). Nun wurden nur noch 114 statt vorher 444 Pixel fälschlicherweise der Klasse Carex zugeordnet. Dies bedeutet, dass in den neu hinzugekommenen Indizes weitere Klassifikationsinformation stecken, die diese Fehlklassifikationen dezimiert

Tabelle 6.12: Konfusionsmatrix der Klassifikation des erweiterten 98-kanaligen multisensoralen Datensatzes von PaW.

| | Phr | ScBo | Car | Tep | Bod | Was | Ran | Summe | UA (%) |
|--------|--------------|------------|--------------|------------|------------|--------------|------------|---------------|-------------|
| Phr | 3.284 | 1 | 9 | 0 | 0 | 0 | 0 | 3.294 | 99,7 |
| ScBo | 0 | 613 | 11 | 0 | 0 | 0 | 5 | 629 | 97,5 |
| Car | 0 | 114 | 4.027 | 0 | 0 | 0 | 4 | 4.145 | 97,2 |
| Tep | 0 | 0 | 0 | 350 | 0 | 0 | 0 | 350 | 100,0 |
| Bod | 0 | 0 | 1 | 0 | 118 | 0 | 0 | 119 | 99,2 |
| Was | 0 | 0 | 0 | 0 | 0 | 2.449 | 0 | 2.449 | 100,0 |
| Ran | 0 | 4 | 7 | 19 | 0 | 0 | 692 | 722 | 95,8 |
| Summe | 3.284 | 732 | 4.055 | 369 | 118 | 2.449 | 701 | 11.708 | |
| PA (%) | 100,0 | 83,7 | 99,3 | 94,9 | 100,0 | 100,0 | 98,7 | | 98,5 |

Um den Beitrag der einzelnen neuen Kanäle zu beurteilen wurde auch hier der GI berechnet (Tabelle 6.13). Das DOM bleibt weiterhin die wichtigste Variable zur Unterscheidung der gewählten Klassen, um den Faktor 2 höher als der nächste Rang. Der zweite Rang wird wieder belegt von den Thermaldaten. Die folgenden Reihungen unterscheiden sich jedoch von den bisherigen Ergebnissen. Auf den ersten 13 Plätzen befinden sich nun mehrere Texturindizes, die aus den RGB-Daten generiert wurden. Vor allem Kontrast (cont) und der Mittelwert (mean) der Textur bzw. Rauigkeit auf den Rängen drei und vier hatten einen hohen Informationsgehalt zur Unterscheidung der Arten. Dass diese beiden Indizes eine besondere Stellung bei der Analyse der Textur besitzen, wird auch durch die Literatur bestätigt [HOSSAIN et al. 2010; HALL-BEYER 2017b]. Verschiedene Pflanzengesellschaften haben also unterschiedliche Grauwertmuster in den Fernerkundungsdaten. Der Texturindex Kontrast hebt hervor, wenn benachbarte Pixel hohe Kontrastunterschiede zeigen. Ist eine Klasse bzw. Pflanzengesellschaft sehr kleinteilig und heterogen, so spiegelt sich das auch in diesem Index wieder. Der Texturindex mean ist nicht einfach nur der Mittelwert des *Sliding Window* der Originalgrauwerte. Der Mittelwert basiert auf der GLCM und der Pixelwert wird nicht nach der Häufigkeit seines Auftretens an sich gewichtet, sondern nach der Häufigkeit seines Auftretens in Kombination mit einem bestimmten Nachbarpixelwert. Außerdem folgen andere Texturindizes wie Energie (ene; Rang acht), Homogenität (homo; Rang zehn), zweites Winkelmoment (asm; Rang elf) und Heterogenität (diss; Rang 13).

Wie schon bei den Relevanzen des einfachen multisensoralen Datensatzes in Tabelle 6.9 war der sichtbare Bereich des elektromagnetischen Spektrums sehr wichtig zur Unterscheidung der verschiedenen seneszenten Pflanzengesellschaften. Dies wird beim erweiterten Datensatz nochmals unterstrichen, indem drei RGB-Indizes die Ränge fünf bis sieben belegen. Der *Triangular Greenness Index* (tgi) ist definiert durch das Flächendreieck welches bei grüner Vegetation durch die Reflexionswerte im blauen, grünen und roten Kanal aufgezo-gen wird [MCKINNON 2017],

$$tgi = G1 - 0,39 * R1 - 0,61 * B1 \quad (6.2)$$

wobei $G1$, $R1$ und $B1$ den Kanälen des RGB-Sensors entsprechen. Der tgi wurde entwickelt um Chlorophyll-Gehalte und indirekt auch Stickstoffgehalte abzuleiten

Tabelle 6.14: Kumulierte GIs nach Sensor und Datentyp der Kanäle.

| (a) Kumulierte Relevanzen | | | | (b) Sensorweise Relevanzen. | | |
|---------------------------|--------|-----------------|--------|-----------------------------|--------|--------|
| Nr. | Sensor | Datentyp | GI (%) | Nr. | Sensor | GI (%) |
| 1 | MS | Spektralindizes | 39,82 | 1 | MS | 46,49 |
| 2 | RGB | Texturindizes | 21,09 | 2 | RGB | 37,65 |
| 3 | RGB | Spektralindizes | 13,58 | 3 | DOM | 11,13 |
| 4 | DOM | Originalkanal | 10,71 | 4 | TH | 4,73 |
| 5 | MS | Originalkanäle | 6,67 | Summe | | 100,00 |
| 6 | TH | Originalkanal | 4,73 | | | |
| 7 | RGB | Originalkanäle | 2,98 | | | |
| 8 | DOM | Reliefindizes | 0,42 | | | |
| Summe | | | 100,00 | | | |

[HUNT et al. 2013]. Der *Visible Atmospherically Resistant Index* (*vari*) wurde von GITELSON et al. [2002] entwickelt,

$$vari = (G1 - R1)/(G1 + R1 - B1) \quad (6.3)$$

wobei $G1$, $R1$ und $B1$ den Kanälen des RGB-Sensors entsprechen. Der Index soll sensitiv auf Vegetation reagieren und hoch korrelieren mit dem Blattflächenindex (LAI) [MCKINNON 2017]. Außerdem ist noch der *Normalized Green Red Difference Index* (*ngrdi*) zu nennen, der von TUCKER [1979] erstmalig verwendet wurde,

$$ngrdi = (G1 - R1)/(G1 + R1) \quad (6.4)$$

wobei $G1$ und $R1$ den Kanälen des RGB-Sensors entsprechen. TUCKER [ebd.] stellt heraus, dass sämtliche Indizes mit Beteiligung der infraroten Spektralbereiche besonders sensitiv auf photosynthetisch aktive Vegetation reagieren und dass Bereiche des sichtbaren Spektrums, insbesondere mit Beteiligung des grünen Lichtes, genutzt werden können um bereits abgestorbene Vegetation zu untersuchen. Daher sind in Tabelle 6.13 neben den gerade genannten Kanälen auch die Farbkanäle $G2$ (Rang 16) und $R2$ (Rang 9) des MS-Datensatzes und der Rotkanal ($R1$, Rang 12) des RGB-Sensors sehr relevant.

Die restlichen Ränge werden beinahe ausschließlich von den MS-Spektralindizes eingenommen. Die Relevanzen spielen sich im Bereich von 2,2 % (*msbi*) bis 0,1 % ab. Die Reliefindizes nehmen beinahe ausschließlich die letzten Ränge ein, was zeigt, dass die aus dem DOM generierten Parameter keine Relevanz für die Unterscheidung von Pflanzengesellschaften spielt. Ein GI von quasi 0 % des *tpi* ist ein Hinweis darauf, dass er in kaum einem der 500 trainierten Bäume genutzt wird.

In Tabelle 6.14a wurden alle Kanäle nach Sensorart und Indextyp kumuliert. Aufgrund der Vielzahl an Multispektralindizes, zeigen die kumulierten Werte die höchste Relevanz mit 39,8 %. Danach folgen die RGB-Daten mit den Indizes die auch einzeln hohe Relevanzen gezeigt haben. Die Tabelle zeigt außerdem, dass die abgeleiteten Indizes höhere GIs erreichen als die Originalkanäle, aus denen sie abgeleitet wurden. So sind die Originaldaten bis auf die Reliefindizes hinter den Indizes.

Tabelle 6.14b fasst die GIs komplett sensorweise zusammen. Aufgrund der Hinzunahme weiterer Indizes ist das DOM zwar immer noch die wichtigste Einzelvariable, jedoch steigt die Relevanz der anderen Datensätze, insbesondere der RGB-Daten, durch die Textur- und Spektralindizes. Somit wird das DOM auf den dritten Rang verdrängt.

Vorselektion wichtiger Indexcluster zur Erstellung eines selektierten erweiterten multisensoralen Datensatzes

Bei den Relevanzen des 98-kanaligen Datensatzes weisen sehr viele Indizes gleiche Werte bzw. erst in Nachkommastellen Unterschiede auf (Tabelle 6.13). Besonders ersichtlich ist das bei der Vielzahl an Multispektralindizes. Um diese Redundanz zu vermeiden werden im nächsten Schritt alle verwendeten Indizes miteinander korreliert. Hoch korrelative Indizes können dabei zusammengefasst werden.

Die Abbildung 6.13 zeigt die Korrelationsmatrix aller verwendeten Indizes. Da die hohe Anzahl an Indizes und Korrelationskoeffizienten den verfügbaren Platz der A4-Seite übersteigt, kann die Graphik im Digitalverzeichnis unter *Arbeit/Abbildungen/06_Ergebnisse/PaW_CorrMatrix.pdf* oder online unter [Zenodo](#)³ in voller Auflösung betrachtet werden. Der Korrelationskoeffizient wird in einem Intervall von -1 bis +1 angegeben, wobei -1 (blau) einen negativen, 0 (weiß) keinen und +1 (rot) einen positiven Zusammenhang der betrachteten Indizes angibt. Die Farben der Korrelationsmatrix deuten mit ihren dunklen Blau- und Rot-Tönen darauf hin, dass es statistisch sehr hohe Zusammenhänge zwischen den Indizes gibt. Das heißt, bei allen Indizes, die eine hohe Korrelation zueinander zeigen, kann jeweils ein Index stellvertretend für das gesamte hochkorrelative Indexcluster selektiert werden.

Eine hierarchische Clusteranalyse [EVERITT et al. 2011] wurde verwendet, um alle hochkorrelierten Indizes zusammenzufassen. Dafür wurde das Standardverfahren *Unweighted Pair Group Method With Arithmetic Mean* (UPGMA) genutzt [ebd.]. Die Abbildung 6.14 zeigt die geclusterten Indizes⁴. Benachbarte Indizes haben eine höhere Korrelation, als weiter entfernte. Entlang der Matrixdiagonalen können mehrere große Cluster identifiziert werden. Die Diagonale ist immer Eins, da hier die Indizes mit sich selbst korreliert wurden. Mithilfe der berechneten dimensionslosen (Cluster-)Distanzmatrix wurden Indizes selektiert, die stellvertretend für ein Cluster an Indizes stehen. In der Abbildung sind fünf größere rote Quadrate entlang der Diagonalen identifizierbar. Das größte kann als NDVI-Cluster bezeichnet werden, weil die meisten MS-Indizes mit diesem Index hoch korrelieren. Für die dimensionslose Distanz wurde ein Schwellwert von 1,5 gewählt, um eine sinnvolle Anzahl an Clustern zu bilden, möglichst viele Indizes zu verwerfen und eine kleine Anzahl von repräsentativen Clusterindizes zu selektieren. Das Dendrogramm in Abbildung 6.15 zeigt die identifizierten Cluster, deren Distanzen und den Schwellwert (schwarze gestrichelte Linie). Mit dem Schwellwert konnten 18 Cluster gefunden werden, die in Tabelle 6.15 zusammengefasst werden. Jeweils ein Index wurde dann aus der Gruppe gewählt, der als namensgebender Index für die Gesamtgruppe fungiert. Bei-

³Digitalverzeichnis: *Arbeit/Abbildungen/06_Ergebnisse/PaW_CorrMatrix.pdf* oder URL: <https://zenodo.org/record/4267243>

⁴Datenverzeichnis: *Arbeit/Abbildungen/06_Ergebnisse/PaW_Cluster.pdf* oder URL: <https://zenodo.org/record/4267517> zu finden.



Abbildung 6.13: Korrelationsmatrix aller berechneten Indizes für PaW. Da die hohe Anzahl an Indizes und Korrelationskoeffizienten den verfügbaren Platz der A4-Seite übersteigt, kann die Graphik im Digitalverzeichnis oder online bei [Zenodo](#)⁵ abgerufen werden.

spielsweise steht der ndvi stellvertretend für 43 Spektralindizes, die sehr hoch mit diesem Index korrelieren.

Mit den selektierten Indizes wurde nun ein neuer multisensoraler Datensatz generiert (Tabelle 6.16a) und klassifiziert. Das Ergebnis ergab einen OOB von 99,8 %, eine OAA von 97,8 % ($\kappa = 0,97$). Der vorselektierte 27-kanalige Datensatz kommt also qualitativ an den 98-kanaligen Datensatz (OAA = 98,5 %) nah heran.

Auch die Kanalrelevanzen zeigen hier wieder vergleichbare Ergebnisse. Das DOM bleibt mit Faktor 2 der wichtigste Parameter zur Unterscheidung der Vegetationsgesellschaften. Diesmal sind ein Textur- und ein Spektralindex wichtiger als der Thermal датensatz in der Einzelkanalbetrachtung. Außerdem wird bestätigt, dass die zwei selektierten Reliefindizes weiterhin kaum gewinnbringende Informationen zur Klassifikation liefern. Tabelle 6.17 zeigt die sensorweise kumulierten Relevanzen.

⁵Digitalverzeichnis: *Arbeit/Abbildungen/06_Ergebnisse/PaW_CorrMatrix.pdf* oder URL: <https://zenodo.org/record/4267243>




Abbildung 6.14: Cluster-Matrix der Korrelationsmatrix aller berechneten Indizes (Volle Auflösung *Dissertation/Arbeit/Abbildungen/...pdf* und Zenodo⁶)

Die Relevanz der multispektralen Indizes hat, aufgrund der Selektion der wesentlichen Indizes, um 10 % abgenommen. Trotzdem sind sie in der Summe noch immer die wichtigsten Variablen und kumuliert mit den multispektralen Kanälen wichtigster Sensor. Beim selektierten Datensatz zeigt sich jedoch nochmal deutlicher, dass die Textur in den Daten eine wichtige Rolle spielt und dass die spektralen Indizes und Reflexionskanäle des RGB-Sensors in den Hintergrund rücken. Weiterhin ist das DOM als Einzelvariable bzw. -kanal von sehr hoher Bedeutung.

⁶Datenverzeichnis: *Arbeit/Abbildungen/06_Ergebnisse/PaW_Cluster.pdf* oder URL: <https://zenodo.org/record/4267517>




Abbildung 6.15: Dendrogramm der Cluster-Matrix aller berechneten Indizes. Die gestrichelte schwarze Linie markiert den Schwellwert 1,5.

Tabelle 6.15: Selektierte Indizes aus den hochkorrelativen Index-Clustern für PaW.

| Nr. | Index | Cluster |
|-----|------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1 | osavi2 | osavi2 |
| 2 | ndre | tcari2, cirededge, reledge2, ndre, rdvi |
| 3 | msbi | msbi, tc_sbimss |
| 4 | ndvi | mcari1, evi2, mtvi2, savi, msavi, evi22, lai, mgvi, tc_gvimss, gemi, diff2, spvi, mcari2, sbl, nli, atsavi, osavi1, mnsi, tc_nsimss, gosavi, diff1, avi, dvimss, gndvi, cigreen, mari, tci, logr, msr670, wdrvi, grndvi, normnir, varirededge, ctvi, tvi, ndvi, arvi2, mcari, mcari_mtvi2, pvr, tgi, gli, gcc |
| 5 | vari | exg, vari, ngrdi |
| 6 | bri | bri |
| 7 | chlrededge | chlrededge |
| 8 | ddn | ddn, datt4, tc_yvimss |
| 9 | ndrdi | normg, chlgreen, ndrdi |
| 10 | tcari | normr, ari, fe3, tcari, tcari_osavi |
| 11 | cvi | cvi |
| 12 | ccci | ccci, maccioni, datt1, lci |
| 13 | tpi | mcari_osavi, tpi |
| 14 | slope | slope, roughness, tri |
| 15 | cont | cont, diss, ent, aspect, hillshade |
| 16 | mean | mean, std |
| 17 | myvi | myvi |
| 18 | ene | homo, asm, ene, ma |

Tabelle 6.16: Kanalzusammensetzung des selektierten multisensoralen Datensatzes und dessen Kanalrelevanzen für die RF-Klassifikation sortiert nach dem GI.

| (a) Kanalzusammensetzung. | | | | (b) Kanalrelevanzen. | | |
|---------------------------|------------|----------------|---------------|----------------------|---------------|--------|
| Nr. | Kanal | Typ | Generiert aus | Nr. | Kanal | GI (%) |
| 1 | R1 | Rot | | 1 | 8 DOM | 19,15 |
| 2 | G1 | Grün | | 2 | 25 mean | 8,19 |
| 3 | B1 | Blau | | 3 | 14 vari | 7,98 |
| 4 | G2 | Grün | | 4 | 9 TH | 7,41 |
| 5 | R2 | Rot | | 5 | 24 cont | 6,45 |
| 6 | RE | Red Edge | | 6 | 18 ndrdi | 5,32 |
| 7 | NIR | Nahes Infrarot | | 7 | 5 R2 | 4,77 |
| 8 | DOM | DOM | RGB | 8 | 27 ene | 4,60 |
| 9 | TH | Thermal | | 9 | 15 bri | 4,16 |
| 10 | osavi2 | Spektralindex | MS | 10 | 4 G2 | 3,74 |
| 11 | ndre | Spektralindex | MS | 11 | 13 ndvi | 3,57 |
| 12 | msbi | Spektralindex | MS | 12 | 12 msbi | 3,08 |
| 13 | ndvi | Spektralindex | MS | 13 | 1 R1 | 3,00 |
| 14 | vari | Spektralindex | RGB | 14 | 19 tcari | 2,85 |
| 15 | bri | Spektralindex | MS | 15 | 20 cvi | 2,57 |
| 16 | chlrededge | Spektralindex | MS | 16 | 7 NIR | 2,52 |
| 17 | ddn | Spektralindex | MS | 17 | 17 ddn | 2,26 |
| 18 | ndrdi | Spektralindex | MS | 18 | 6 RE | 2,17 |
| 19 | tcari | Spektralindex | MS | 19 | 21 ccci | 1,85 |
| 20 | cvi | Spektralindex | MS | 20 | 26 myvi | 1,08 |
| 21 | ccci | Spektralindex | MS | 21 | 10 osavi2 | 0,98 |
| 22 | tpi | Reliefindex | DOM | 22 | 11 ndre | 0,71 |
| 23 | slope | Reliefindex | DOM | 23 | 2 G1 | 0,69 |
| 24 | cont | Texturindex | RGB | 24 | 16 chlrededge | 0,43 |
| 25 | mean | Texturindex | RGB | 25 | 3 B1 | 0,22 |
| 26 | myvi | Spektralindex | MS | 26 | 23 slope | 0,13 |
| 27 | ene | Texturindex | RGB | 27 | 22 tpi | 0,11 |
| | | | | Summe | | 100,00 |

Tabelle 6.17: Kumulierte Relevanzen (GIs) nach Kanal- und Sensortyp.

| (a) Kanaltypweise kumul. Relevanzen | | | | (b) Sensorweise kumul. Relevanzen. | | |
|-------------------------------------|--------|-----------------|--------|------------------------------------|--------|--------|
| Nr. | Sensor | Typ | GI (%) | Nr. | Sensor | GI (%) |
| 1 | MS | Spektralindizes | 28,86 | 1 | MS | 42,06 |
| 2 | RGB | Texturindizes | 19,24 | 2 | RGB | 31,14 |
| 3 | DOM | Originalkanal | 19,15 | 3 | DOM | 19,40 |
| 4 | MS | Originalkanäle | 13,20 | 4 | TH | 7,41 |
| 5 | RGB | Spektralindizes | 7,98 | Summe | | 100,00 |
| 6 | TH | Originalkanal | 7,41 | | | |
| 7 | RGB | Originalkanäle | 3,91 | | | |
| 8 | DOM | Reliefindizes | 0,25 | | | |
| Summe | | | 100,00 | | | |

Erweiterter Datensatz für Tribsees (PW) und Karrendorf (CDCW)

Die gleiche Clusterung und Selektion wurde auch für PW und CDCW vorgenommen, um die Ergebnisse mit denen von PaW zu vergleichen. Alle Tabellen und Abbildungen sind im Anhang A.9 (Seite 219) angefügt⁷.

Das Selektionsverfahren ergab eine Kanalzusammensetzung von 32 Kanälen für PW und 26 Kanälen für CDCW (Tabelle A.12). Klassifikativ konnte für PW nochmals eine deutliche Verbesserung erzielt werden von mehr als fünf Prozent auf eine OAA von 94,4 % ($\kappa = 0,92$). Bei CDCW konnte allerdings keine Verbesserung, sondern sogar eine leichte Senkung der Klassifikationsgenauigkeit festgestellt werden, allerdings um nur 1 % auf eine OAA von 87,5 % ($\kappa = 0,85$).

Die Kanalrelevanzen zeigen wieder deutlich, wie wichtig das DOM ist (Tabellen A.13 für PW und A.14 für CDCW). Außerdem sind die Texturindizes (ene, std, cont) wichtiger als spektrale Informationen, was auch bei PaW mit den Indizes mean, cont und ene der Fall war. Anders als bei PaW, konnte für beide Standorte die Wichtigkeit der RGB-Daten nicht bestätigt werden. Bei PW und CDCW sind eindeutig die Infrarotkanäle (NIR, RE) bzw. deren Spektralindizes (ndvi, ndrdi, mcari_mtvi2) wichtiger. Wie schon vorher festgestellt, sind auch die Thermaldaten stets unter den wichtigsten Einzelkanalrelevanzen zu finden.

Die kumulierten Relevanzen nach Sensortyp (Tabellen A.15a und A.16a) zeigen die enorme Wichtigkeit der multispektralen und der Texturindizes. Sie schieben sich gemeinsam betrachtet vor die Relevanz des DOM.

In den kumulierten Relevanzen nach Sensortyp (Tabellen A.15b und A.16b) ergibt sich wie bei PaW, dass die MS-Daten die wichtigsten Informationen zur Unterscheidung von Vegetation sind, gefolgt von den RGB-Daten. Bei den RGB-Daten haben die originalen Farbkanäle jedoch kaum einen Anteil am Training des Klassifikators. Die Hauptinformationen tragen hier die Textur und zu einem kleineren Anteil die Spektralindizes bei.

⁷Alle Korrelations- und deren Clustermatrizen sind im Digitalverzeichnis und online in voller Auflösung zu finden. Der Tabelle A.10 (Seite 219) sind die Speicherorte zu entnehmen.

6.3 Maschinelles Lernen zur flächenhaften Ableitung von Pflanzenparametern

Im folgenden Abschnitt werden die Ergebnisse der Regression auf den Marschlandstandorten vorgestellt.

Zunächst erfolgt eine statistische Voranalyse der Messwerte, die im Gelände gemessen wurden. Daraufhin werden die finale Zusammenstellung der multisensoralen Drohnendaten vorgestellt. Hier kam das gleiche Verfahren zur Erstellung eines erweiterten multisensoralen Datensatzes zur Anwendung wie im vorherigen Abschnitt 6.2.3 beschrieben. Die Regressionsergebnisse werden in den folgenden Abschnitten vorgestellt und interpretiert. Dies umfasst die Ergebnisse der PLSR und die Relevanz der Kanäle und Sensoren. Im letzten Abschnitt werden weitere Parameter abgeleitet, die lineare statistische Beziehungen zu den PLSR-Parametern aufweisen.

6.3.1 Statistische Voruntersuchungen zu den Geländemessungen

Im diesem Abschnitt werden die im Gelände und im Labor gemessenen und berechneten Pflanzenparameter statistisch untersucht, um zum einen einen Eindruck von den Standorten selbst zu bekommen und zum anderen einen Vergleich zwischen BAL und HOL zu ziehen. Außerdem sind die statistischen Voruntersuchungen notwendig, um die Zusammenhänge zwischen den Parametern zu identifizieren, die im späteren Verlauf noch benötigt werden.

In den Boxplots der folgenden Abbildungen 6.16–6.20 werden die Verteilungen der Parameter für den jeweiligen Standort dargestellt und die beiden Standorte vergleichend gegenübergestellt. Die Boxplots für BAL sind hellblau und für HOL hellgrün. Die überlagernden Punkte (Schwarzdiagramme) sind die tatsächlichen Messwerte, die Farben der Punkte stehen für die jeweilige Pflanzenart (blau = *Bolboschoenus maritimus*, grün = *Schoenoplectus tabernaemontani*, rot = *Phragmites australis*, orange = *Phalaris arundinacea*), die am jeweiligen Punkt dominant auftrat. Außerdem sind alle wesentlichen statistischen Kennziffern, wie MW, STD, Minimum, erstes bis drittes Quartil und Maximum jedes Parameters in den Tabellen A.17 (BAL) und A.18 (HOL) im Anhang A.10 (Seite 229) zu finden.

Die Geländehöhe (Abbildung 6.16) zeigt generell einen Offset der beiden Standorte. Mit großem Überschneidungsbereich der Spannweite liegt HOL etwas niedriger als BAL, obwohl der Standort etwas weiter im Landesinneren liegt. Dies kann unterschiedliche Gründe haben. BAL liegt nordexponiert an der Ästuaröffnung, was bedeutet, dass der Wellenschlag durch die Gezeiten hier stärker wirkt als in HOL. Dadurch wird mehr Material auf die Fläche transportiert und der Wellenschlag treibt die Marschkante in Richtung des Landes. Außerdem ist zu beobachten, dass die Marschkante sich näher an den Meeresspiegel ausbreitet, je flacher der Uferverlauf ist. Im Wattbereich von HOL ist strömungsbedingt viel Material angelandet. Verglichen mit BAL ist der Uferverlauf dadurch flacher und die Strömung ruhiger in HOL. Somit breitet sich die Marsch weiter in Richtung Meeresspiegelniveau aus.

Die Anzahl der Pflanzen (Abbildung 6.17) im Kartierrahmen war sehr unterschiedlich. Dadurch ist kein klares Muster zu erkennen, was darauf hinweisen könnte, dass




Abbildung 6.16: Mit RTK-GNSS eingemessene Normalhöhen für BAL und HOL (BM = *Bolboschoenus maritimus*, ST = *Schoenoplectus tabernaemontani*, PA = *Phragmites australis*, PhA = *Phalaris arundinacea*).




Abbildung 6.17: Anzahl der Pflanzen im definierten Kartierrahmen von 40 x 40 cm für BAL und HOL.

die Geländehöhe, der Abstand zur Marschkante oder die Pflanzenart keinen Einfluss auf die Anzahl der Stängel pro definierte Fläche haben. Die statistische Spannweite ist in BAL größer. In BAL gibt es Bereiche, in denen *Bolboschoenus maritimus* und *Phragmites australis* sehr viel dichter stehen, als in HOL. In HOL sind die Pflanzen homogener verteilt. Außerdem ist zu erkennen, dass es keine klare Differenzierbarkeit zwischen den Hauptpflanzenarten gibt. Sie sind sehr dispers über den Wertebereich verteilt.

In Abbildung 6.18 werden die Pflanzenhöhen, gemessen im Gelände und im Labor, gegenübergestellt. Generell ist festzustellen, dass die Spannweite der Höhenverteilung in BAL größer ist, jedoch die Pflanzen in HOL mehrheitlich höher sind. Besonders in der Verteilung der Höhen, gemessen im Gelände, sind die artenabhängige *stockwerkartige* Höhenverteilung nach Arten, von *Schoenoplectus tabernaemontani*




Abbildung 6.18: Im Gelände (links) und Labor (rechts) gemessene Pflanzenhöhen für BAL und HOL.

über *Bolboschoenus maritimus* nach *Phragmites australis*, sehr gut erkennbar. Dies gilt jedoch nicht für die Labormessungen von HOL. Hier sind die Pflanzenhöhen nicht klar differenzierbar. Im Mittel scheinen die Labormessungen niedriger zu sein, obwohl die Pflanzen während der Messung auf ihre volle Länge gezogen wurden. Für die Laboruntersuchungen wurden an jedem Standort zehn Pflanzen geerntet. Durch die randomisierte Wahl sind wahrscheinlich auch Pflanzen entnommen wurden, die nicht repräsentativ für die Bestandshöhe waren und somit den Durchschnitt mindern.

Bei den Durchmessern der Stängel (Abbildung 6.19) fällt zunächst auf, dass die Stängel in HOL systematisch dicker sind als in BAL. Die Stängel von *Phragmites australis* sind in der Regel dünner (größtenteils erster und zweiter Quartilbereich) als die von *Bolboschoenus maritimus* und *Schoenoplectus tabernaemontani* (größtenteils dritter und vierter Quartilbereich). Die Verteilung der Geländewerte bei BAL




Abbildung 6.19: Im Gelände und Labor gemessene Stängeldurchmesser für BAL und HOL.




Abbildung 6.20: Photosynthetisch aktive Strahlung (PAR) für BAL und HOL.

zeigen, dass bei der ersten Geländekampagne auf Ganzzahlen gerundet wurde, in HOL wurden die Einzelmessungen dann aber gemittelt.

Die berechneten PAR-Werte (Abbildung 6.20) zeigen abgesehen vom Median keine großen Unterschiede. Der Bestand von *Bolboschoenus maritimus* und *Phragmites australis* absorbiert bei beiden Arten vergleichbar viel Strahlung. Die PAR-Werte von *Phragmites australis* sind dabei jedoch überwiegend unter dem Median. Da die Bestandsdichte von *Schoenoplectus tabernaemontani* an der Marschkante nur sehr gering ist und diese Pflanze kein dichtes oder ausladendes Blätterwerk entwickelt sind auch die PAR-Werte entsprechend hoch. Viel einkommende Strahlung erreicht komplett den Boden. Besonders kurzgewachsen und spärlich war *Schoenoplectus tabernaemontani* in BAL verteilt (vgl. Abbildungen 3.11b und 3.12a), was sich in den Werten widerspiegelt.

In der Abbildung 6.21a ist die ermittelte Frisch- und Trockenmasse pro Pflanze (oben), sowie die errechnete Frisch- und Trockenmasse pro 40 x 40 cm des Kartierrahmens (unten) dargestellt. Außerdem wurde aus den Pflanzenmassewerten der Wassergehalt berechnet (Abbildung 6.21b). Zunächst ist erkennbar, dass die Frischmasse der Vegetation in BAL niedriger ist, als in HOL. Dieser Unterschied ist nach der Trocknung nicht mehr erkennbar, weil die Trockenmassen vergleichbar sind. Die Wassergehalte, wie auch in der Abbildung 6.21b erkennbar, sind in HOL also höher. Besonders in BAL ist gut zu erkennen, dass die Werte von der Pflanzenart abhängig sind. *Phragmites australis* hat beispielsweise die höchsten Frisch- und Trockenmassegewichte, jedoch die niedrigsten Wassergehalte. *Schoenoplectus tabernaemontani* hat dagegen die niedrigsten Gewichte aber die höchsten Wassergehalte. Der Wassergehalt in den Pflanzen steigt demnach vom Marsch-Hinterland zur Marschkante an.

Als nächstes wurden die einzelnen Parameter gegeneinander auf statistische Zusammenhänge untersucht. Dafür wurden die Werte nach *Pearson* korreliert [FAHRMEIR et al. 2016]. Die Korrelationsmatrizen sind in Abbildung A.17 im Anhang A.10 (Seite 229) dargestellt. Aus den Korrelationsmatrizen wurden mithilfe der hierarchischen Clusteranalyse UPGMA [EVERITT et al. 2011] die Parameter nach der Stärke

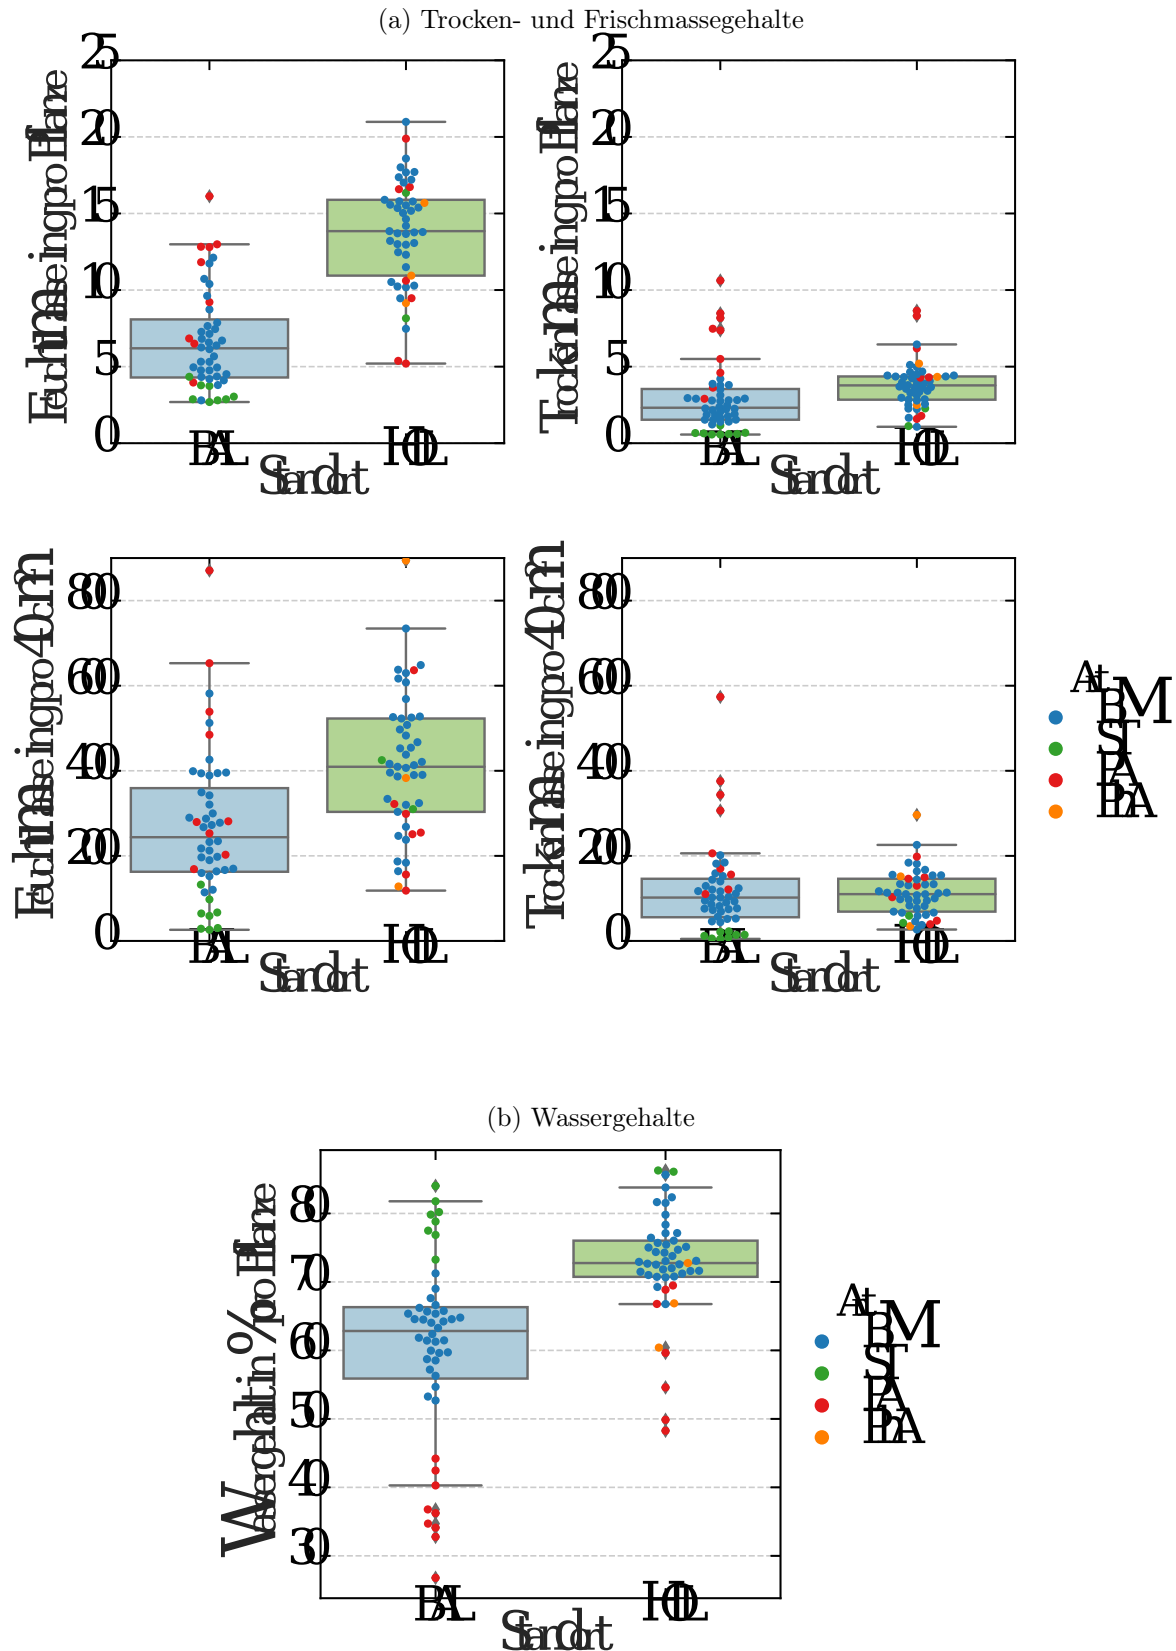


Abbildung 6.21: Frisch- und Trockenmasse pro Pflanze (oben) und hochgerechnet auf die 40 x 40 cm des Kartierrahmens (Mitte) und Wassergehalt in % (unten).

ihres Zusammenhangs geclustert (Abbildung 6.22). Der Wertebereich des Korrelationskoeffizienten reicht von 1 (rot, starker positiver Zusammenhang) über 0 (weiß, kein Zusammenhang) bis hin zu -1 (blau, negativer Zusammenhang).

Hochkorrelative Cluster sind in den Matrizen nur bedingt zu finden. Hohe Korrelationen waren zu erwarten bei der Beziehung zwischen Frisch- und Trockenmasse (BAL: 0,91; HOL 0,69) sowie Trockenmasse und Wassergehalt (BAL: -0,78 ; HOL: -0,74) und zwischen den Messungen der Pflanzenhöhe im Gelände und Labor (BAL: 0,92; HOL: 0,86, Abbildungen 6.23).

Die Regression zwischen PHL und PHG bei BAL zeigt nochmals die drei Wachstumsstockwerke der dominanten Pflanzenarten (Abbildung 6.23a). Der Zusammenhang zwischen der Gelände- und der Labormessung konnte für HOL in der Regression nicht bestätigt werden. Die hohe Streuung der Werte ist deutlich zu erkennen. Beispielsweise sind in den Labormessungen sehr niedrige Messwerte für *Phragmites australis* zu sehen ($PHL < 100$ cm), die jedoch realistischere Messungen im Gelände zeigen ($PHG > 200$ cm). Das ist ein weiterer Hinweis darauf, dass bei der randomisierten Entnahme von 10 Pflanzen aus dem Kartierahmen zu kurze Pflanzen entnommen wurden, die die tatsächliche Bestandshöhe nicht richtig abbilden.

Neben den zu erwartenden Korrelationen wurden noch weitere Zusammenhänge zwischen den Parametern gefunden. Beispielsweise scheint die Geländehöhe (NHN) ein Parameter zu sein, der in der Entwicklung der Marschpflanzen eine wichtige Rolle spielt. Besonders auf dem vergleichsweise steileren Uferanstieg bei BAL sind Beziehungen zwischen NHN und den Parametern PHL/PHG (0,85/0,82), PDML (-0,71) und PWG (-0,91) sowie moderate Zusammenhänge zu PTM (0,69) zu finden.

Für HOL wurden hohe bis moderate Zusammenhänge von NHN zu PHG (0,83), PWG (-0,85), PDML (-0,71) und PAR (-0,66) gefunden.

Des weiteren korreliert PWG in BAL mit den Pflanzenhöhen ($PHL = -0,89$; $PHG = -0,88$) und den Trockenmassen ($PTM = -0,78$; $FTM = -0,71$).

In HOL korreliert PWG mit Pflanzenhöhen ($PHL = -0,72$; $PHG = -0,86$) und der Trockenmasse pro Pflanze ($PTM = -0,74$).

Die photosynthetisch aktive Strahlung korrelierte mit den Pflanzenhöhen im Gelände auf beiden Standorten moderat negativ (BAL: $PHG = -0,69$; $PHL = -0,68$; HOL: $PHG = -0,64$).

6.3.2 Partial Least-Squares Regression zur Ableitung von Pflanzenparametern aus multisensoralen UAS-Daten

Im folgenden Abschnitt werden zunächst die multisensoralen Datensätze vorgestellt, die für BAL und HOL erstellt wurden. Danach werden die Ergebnisse der PLSR ausgewertet und für hochkorrelative Parameter Karten erstellt. Daraufhin erfolgt die Beurteilung der Relevanz der Kanäle und Sensoren für die selektierten Parameter.

Zusammensetzung der multisensoralen Datensätze

Für BAL und HOL wurde das gleiche Selektionsverfahren genutzt wie für PaW (Abschnitt 6.2.3) um einen erweiterten multisensoralen Datensatz zu generieren, indem hochkorrelative Indexcluster durch einen einzigen prominenten Vertreter ersetzt

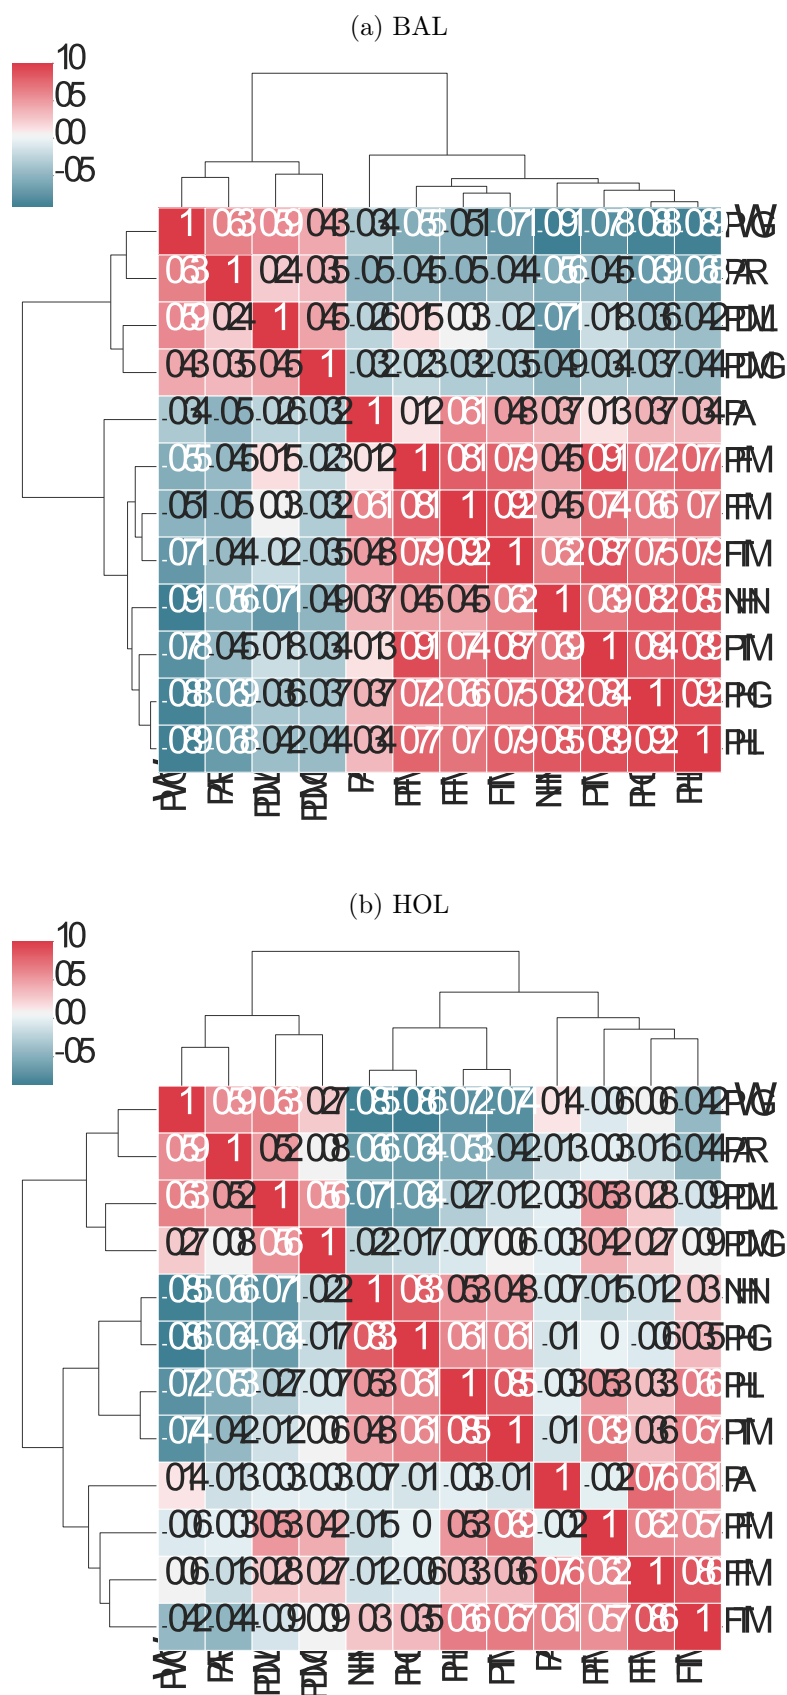


Abbildung 6.22: Geclusterte Korrelationsmatrix und Dendrogramme der gemessenen und berechneten Parameter aus Gelände und Labor für BAL (6.22a) und HOL (6.22b; Abkürzungen siehe Tabelle 4.8, Seite 50).

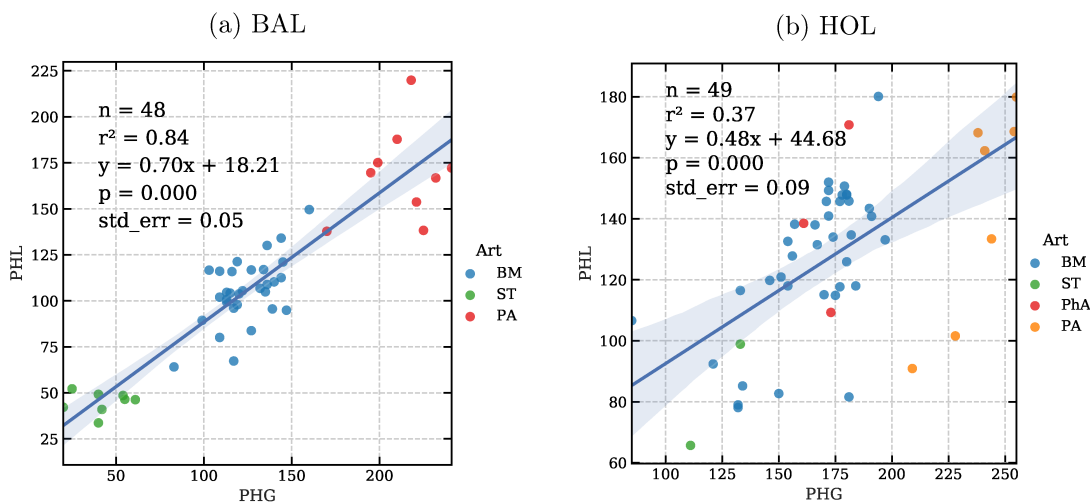


Abbildung 6.23: Gegenüberstellung der Messungen der Pflanzenhöhen im Gelände und im Labor für BAL und HOL. Die Messwerte sind weiterhin nach dominanter Pflanzenart unterschieden (BM = *Bolboschoenus maritimus*, ST = *Schoenoplectus tabernaemontani*, PA = *Phragmites australis*, PhA = *Phalaris arundinacea*)

wurden. Die Korrelations- und Clustermatrizen sind für BAL und HOL im Anhang A.11 (Seite 233) zu finden⁷. Erneut wurde für die dimensionslose Distanz des Clusterverfahrens UPGMA der Schwellwert von 1,5 gewählt, um Cluster zu bilden und einen repräsentativen Vertreter zu selektieren. Die Dendrogramme in Abbildung A.23 (Seite 237) zeigen die Ergebnisse der Clusterung.

Die selektierten Indizes für beide Standorte sind in Tabelle 6.18 aufgeführt. Damit wurden neben den Hauptdatensätzen RGB-, MS-, Thermaldaten und dem DOM 16 weitere Indizes für BAL (insgesamt 25 Kanäle) und 17 weitere Indizes für HOL (insgesamt 26 Kanäle) selektiert. Die finale Zusammensetzung der erweiterten multisensoralen Datensätze sind in Tabelle A.20 (Seite 238) aufgelistet.

Ergebnisse der PLSR

Die PLSR-Regressionsmodelle wurden nun genutzt um die erweiterten multisensoralen Datensätze der beiden Standorte für die jeweiligen Parameter vorherzusagen. Die Ergebnisse der trainierten und kreuzvalidierten Modelle sind in den Tabellen 6.19a für BAL und 6.19b für HOL zusammengefasst. Dabei sind Parameter hervorgehoben, bei denen das Regressionsmodell mehr als 50 % (höhere Bestimmtheitsmaße (r^2) als 0,5) der Varianz erklärt. Diese Parameter sind für beide Standorte:

BAL NHN, PHG, PHL, PWG, PAR

HOL NHN, PHG, PWG, PAR.

Die folgenden Karten (Abbildungen 6.24 bis 6.34) zeigen die vorhergesagten Parameter, sowie die Selektion der in der PLSR genutzten Komponenten und die Ergebnisse der Kreuzvalidierung der Modelle.

⁷In Tabelle A.19 (Anhang A.11) sind auch die Links zu den digitalen Online-Graphiken aufgeführt.

Tabelle 6.18: Selektierte Indizes aus den hochkorrelativen Index-Clustern.

| BAL | | | HOL | | |
|-----|-----------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|-----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nr. | Index | Cluster | Nr. | Index | Cluster |
| 1 | std | std | 1 | std | std |
| 2 | myvi | myvi | 2 | ccci | ccci |
| 3 | ene | ma, homo, asm, ene | 3 | datt1 | maccioni, datt1, lci |
| 4 | ndrdi | chlrededge, normr, normg, chlgreen, ndrdi, ddn, datt4, ari, fe3, | 4 | ene | asm, ma, homo, ene |
| 5 | ccci | ccci, maccioni, datt1, lci | 5 | tcari | tcari, tcari_osavi, ddn, myvi |
| 6 | tc_yvimss | tc_yvimss | 6 | ndrdi | ari, datt4, fe3, chlrededge, normr, normg, chlgreen, ndrdi, |
| 7 | tcari | tcari, tcari_osavi | 7 | cont | cont, diss, ent |
| 8 | vari | mcari_osavi, msbi, tc_sbimss, vari, mcari, ngrdi, | 8 | msbi | tcari2, msbi, tc_sbimss |
| 9 | ndvi | gndvi, grndvi, normnir, ctvi, tvi, ndvi, arvi2, atsavi, varirededge, cirededge, rededge2, ndre, rdvi, osavi2, cigreen, mari, exg, gli, gcc, pvr, tgi, avi, dvimss, mgvi, mcari1, tc_gvimss, diff1, diff2, spvi, mnsi, tc_nsimss, msr670, nli, logr, osavi1, gosavi, wdrvi, tci, sbl, mcari2, evi2, evi22, lai, mtvi2, savi, gemi, msavi | 9 | ndvi | cigreen, mari, osavi2, cirededge, rededge2, ndre, rdvi, gndvi, grndvi, normnir, varirededge, ctvi, tvi, ndvi, arvi2, tci, atsavi, nli, osavi1, logr, msr670, wdrvi, mcari_osavi, mnsi, tc_nsimss, mcari, avi, dvimss, diff1, diff2, spvi, tc_gvimss, mcari1, mgvi, gosavi, savi, sbl, gemi, evi2, evi22, lai, mcari2, msavi, mtvi2, pvr, mcari_mtvi2 |
| 10 | cont | cont, diss, ent | 10 | cvi | cvi |
| 11 | cvi | cvi, tcari2 | 11 | vari | vari, ngrdi, tgi, exg, gli, gcc |
| 12 | mean | mean | 12 | bri | bri, tc_yvimss |
| 13 | hillshade | hillshade | 13 | mean | mean |
| 14 | slope | mcari_mtvi2, slope, roughness, tri | 14 | hillshade | hillshade |
| 15 | bri | bri | 15 | slope | tri, roughness, slope |
| 16 | tpi | aspect, tpi | 16 | aspect | aspect |
| | | | 17 | tpi | tpi |

Tabelle 6.19: Ergebnisse der kreuzvalidierten PLSR-Modelle für BAL und HOL. Markiert sind die kreuzvalidierten Bestimmtheitsmaße (r_{CV}^2 , die über 0,5 erreichten (r_T^2 = Bestimmtheitsmaß des Trainings, n = Anzahl der verfügbaren Messwerte, Komp. = PLSR-Komponenten, die Qualitätsmaße sind in Abschnitt 5.3.1 beschrieben).

(a) BAL

| Parameter | n | Komp. | r_T^2 | r_{CV}^2 | MSE_T | MSE_{CV} | MAE | RMSE | RPD |
|-----------|----|-------|---------|-------------|-----------|------------|--------|--------|------|
| NHN | 48 | 12 | 0,96 | 0,90 | 0,01 | 0,02 | 0,54 | 0,14 | 3,24 |
| PA | 48 | 3 | 0,48 | 0,18 | 120,30 | 191,30 | 14,78 | 13,83 | 1,11 |
| PHG | 48 | 1 | 0,83 | 0,80 | 483,83 | 557,68 | 56,08 | 23,62 | 2,26 |
| PHL | 48 | 14 | 0,92 | 0,77 | 125,20 | 384,83 | 44,72 | 19,62 | 2,09 |
| PDMG | 48 | 1 | 0,20 | 0,08 | 2,09 | 2,42 | 1,40 | 1,55 | 1,04 |
| PDML | 48 | 1 | 0,36 | 0,25 | 1,07 | 1,25 | 1,18 | 1,12 | 1,16 |
| PFM | 48 | 1 | 0,38 | 0,28 | 6,61 | 7,64 | 3,09 | 2,76 | 1,18 |
| PTM | 48 | 2 | 0,611 | 0,49 | 1,91 | 2,51 | 2,09 | 1,58 | 1,40 |
| FFM | 48 | 1 | 0,43 | 0,33 | 16.662,08 | 19.433,14 | 158,35 | 139,40 | 1,22 |
| FTM | 48 | 1 | 0,54 | 0,45 | 4.994,70 | 5.977,40 | 94,75 | 77,31 | 1,34 |
| PWG | 48 | 10 | 0,94 | 0,83 | 10,92 | 31,45 | 14,95 | 5,61 | 2,43 |
| PAR | 46 | 16 | 0,97 | 0,93 | 15,25 | 52,96 | 22,38 | 7,28 | 3,75 |

(b) HOL

| Parameter | n | Komp. | r_T^2 | r_{CV}^2 | MSE_T | MSE_{CV} | MAE | RMSE | RPD |
|-----------|----|-------|---------|-------------|-----------|------------|--------|--------|------|
| NHN | 49 | 14 | 0,97 | 0,89 | 0,01 | 0,02 | 0,47 | 0,14 | 3,00 |
| PA | 49 | 1 | 0,07 | -0,39 | 80,18 | 119,91 | 7,98 | 10,95 | 0,86 |
| PHG | 49 | 6 | 0,90 | 0,73 | 116,11 | 324,63 | 37,85 | 18,02 | 1,95 |
| PHL | 49 | 1 | 0,40 | 0,25 | 452,50 | 569,60 | 25,96 | 23,87 | 1,16 |
| PDMG | 49 | 1 | 0,33 | -0,08 | 1,88 | 3,01 | 1,50 | 1,73 | 0,97 |
| PDML | 49 | 1 | 0,57 | 0,37 | 1,52 | 2,25 | 1,86 | 1,50 | 1,27 |
| PFM | 49 | 2 | 0,20 | -0,12 | 9,86 | 13,76 | 3,07 | 3,71 | 0,96 |
| PTM | 49 | 1 | 0,36 | 0,21 | 1,46 | 1,79 | 1,32 | 1,34 | 1,14 |
| FFM | 49 | 1 | 0,14 | -0,16 | 23.091,56 | 31.129,25 | 140,62 | 176,43 | 0,94 |
| FTM | 49 | 1 | 0,24 | 0,07 | 2.147,75 | 2.623,77 | 46,42 | 51,22 | 1,05 |
| PWG | 49 | 21 | 0,91 | 0,77 | 5,80 | 14,41 | 8,21 | 3,80 | 2,09 |
| PAR | 49 | 25 | 0,80 | 0,57 | 39,77 | 86,47 | 13,44 | 9,30 | 1,54 |

Bei beiden Standorten liefert die PLSR eine hohe Genauigkeit der Ableitung der Geländehöhe in m ü. NHN (Abbildung 6.24 und 6.25). Die Referenzmessungen stammen an den jeweiligen Punkten vom RTK-GNSS. Anhand des Farbverlaufes vom Watt zur Marsch ist der kontinuierliche Gradient des steigenden Geländes sehr gut erkennbar. Die bläulichen Farben repräsentieren den Bereich, in dem *Schoenoplectus tabernaemontani* aufwächst. Dies ist die Marschkante, der tiefste Marschbereich. Darauf folgt ein diffuser Übergang grüner bis orangefarbener Töne, die dominiert werden von *Bolboschoenus maritimus*. Die Mittlere Tidehochwasser (MThw)-Linie verläuft in etwa in der Zone, wo die dunklen bis schwarzen Flächen beginnen, was gleichzeitig den Übergang von *Bolboschoenus maritimus* zu *Phragmites australis* re-

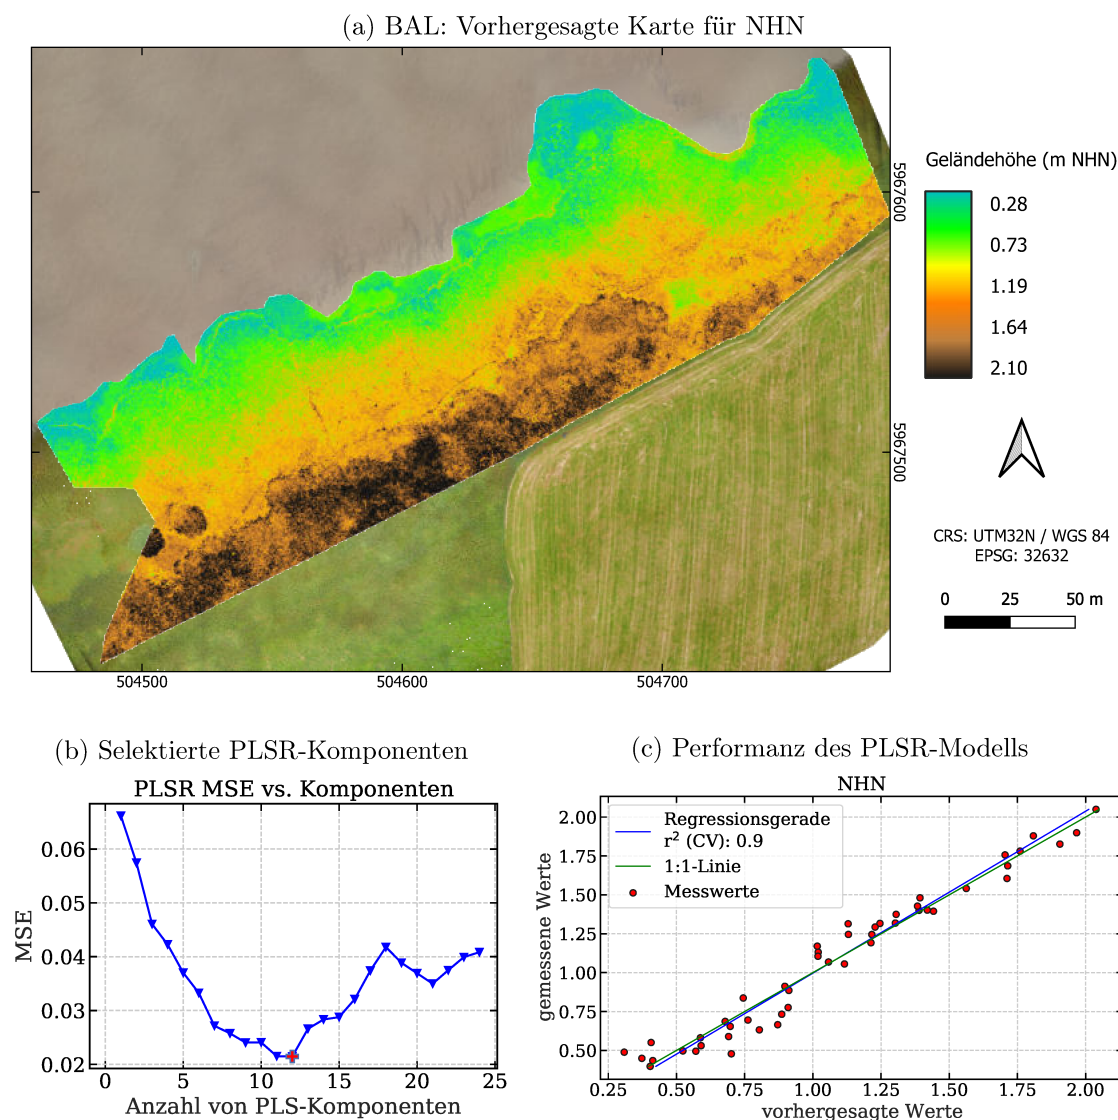


Abbildung 6.24: Ergebnisse der PLSR für den Parameter Geländehöhe (NHN) des Standortes BAL. (a) Vorhergesagte Karte der Geländehöhe in m ü. NHN. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

präsentiert. Oft bildet sich an dieser Linie ein Geländesprung. Das Ergebnis zeigt, dass durch die Kombination aus der Geometrie (DOM, Textur) und spektraler Information (Pflanzenart und -eigenschaften) die Geländehöhe und somit ein DGM für die jeweiligen Untersuchungsgebiete abgeleitet werden kann.

Die Anzahl der PLSR-Komponenten wird in Abhängigkeit zum MSE der Kreuzvalidierung bestimmt. Im Komponentendiagramm markiert das rote Kreuz die selektierten Komponenten. In Abbildung 6.24b wird beispielsweise Komponente zwölf mit dem geringsten MSE selektiert. Das bedeutet, dass das Training für NHN in BAL mit zwölf PLSR-Komponenten ein kreuzvalidiertes r^2 von 0,90 ergab.

Das Performanz-Diagramm (bspw. in Abbildung 6.24c) stellt die gemessenen Wer-

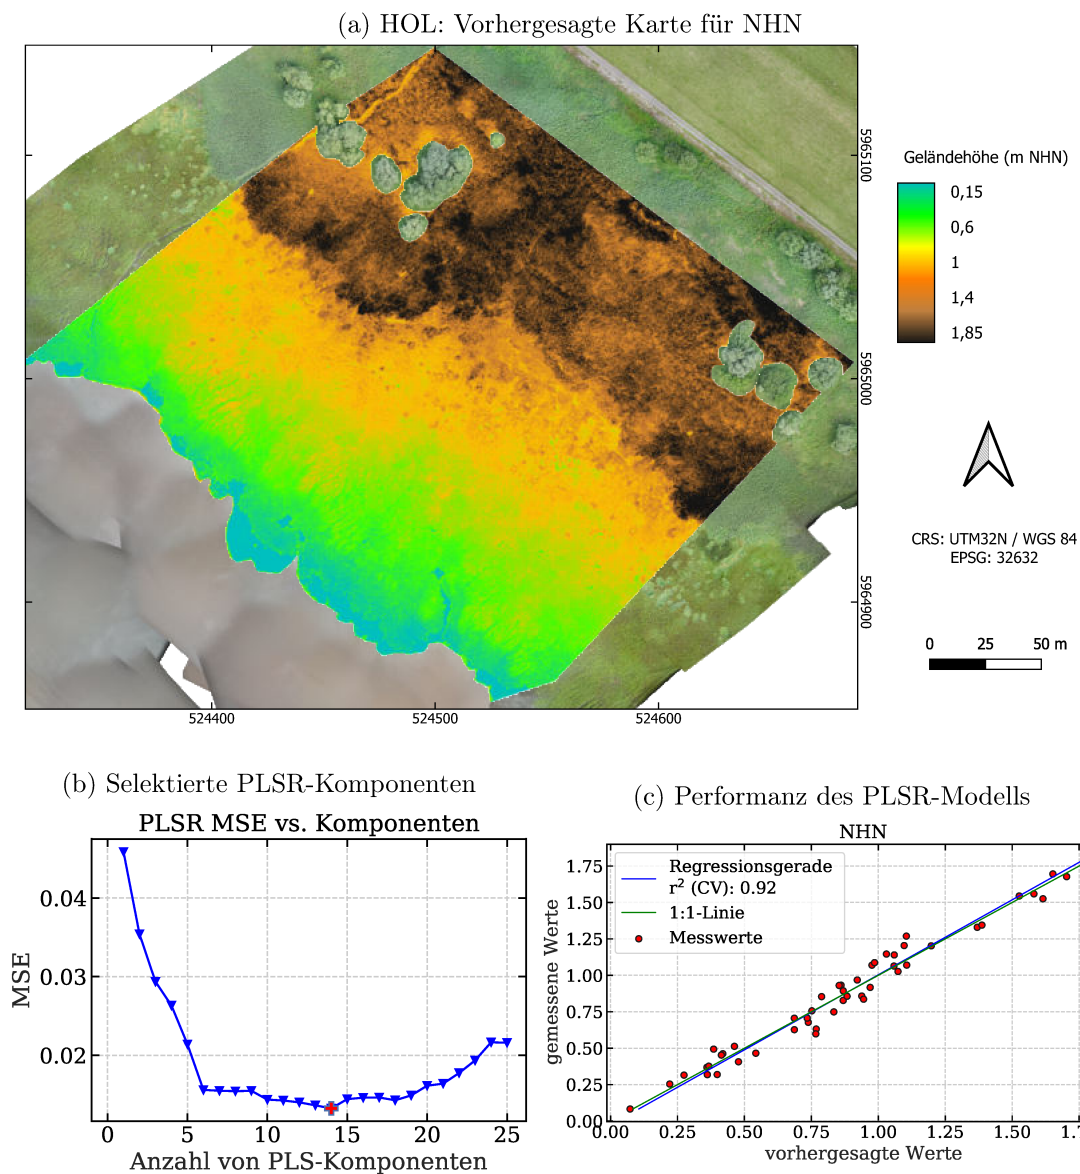


Abbildung 6.25: Ergebnisse der PLSR für den Parameter Geländehöhe (NHN) des Standortes HOL. (a) Vorhergesagte Karte der Geländehöhe in m ü. NHN. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

te vom Gelände den in der Kreuzvalidierung vorhergesagten Werten für die gleichen Punkte gegenüber. Aufgrund des sehr ähnlichen Verlaufes der 1:1-Linie und der Regressionsgerade kann gefolgert werden, dass das Modell die Werte aus der Realität gut abbildet. Selbst bei niedrigen bzw. hohen Werten kommt es kaum zu Unter- bzw. Überschätzungen der Geländehöhen. Der RPD für BAL ist mit 3,24 sehr hoch (Tabelle 6.19a), was bedeutet, dass der Fehler der vorhergesagten Werte um einen mehr als dreifachen Faktor weniger streuen, als die Standardabweichung der gemessenen Geländehöhen. In HOL wurden 14 PLSR-Komponenten genutzt (Abbildung 6.25b). Der Verlauf des MSE zeigt jedoch, dass der Fehler schon ab Komponente Sechs auf

einem konstant niedrigen Niveau gewesen ist. Daher wäre auch eine Nutzung von nur sechs Komponenten möglich gewesen. Das Performanz-Diagramm (Abbildung 6.25c) zeigt, dass die tatsächlich gemessenen Werte in der Kreuzvalidierung sehr präzise vorhergesagt wurden. Im gesamten Wertebereich kommt es kaum zu Über- oder Unterschätzungen, was auch durch ein sehr hohes r^2 von 0,89 und einen RPD von 3,00 bestätigt wird.

Wie schon in den Kapiteln zum Stand der Wissenschaft (Abschnitt 2.2) und in den ökologischen Grundlagen (Abschnitt 3.2) beschrieben, ist die Geländehöhe ein wichtiger genetischer Parameter und wesentlicher Treiber für die Entwicklung der Vegetation im Marschland. Sie entscheidet über die Höhe, Stärke und Dauer der tideinduzierten Überschwemmungen. HLADIK und ALBER [2012] beschreiben die Relevanz der Geländehöhe für das Küstenmanagement, insbesondere für Überschwemmungen/Hochwasser, Gefährdungsbewertung für die Küsten und für die Modellierung des Meeresspiegelanstieges. Die Häufigkeit und Dauer von tidebedingten Überschwemmungen hat Einfluss auf Muster und Struktur der Vegetation in Marschen: Höhenunterschiede von weniger als 10 cm können die Verteilung und Produktivität der Pflanzen beeinflussen [ebd.]. Die Autoren zeigen in ihrer Arbeit, dass luftgestützte LIDAR-Befliegungen, welche großflächig die genauesten Höhenmodelle liefern, in Marschen nur unzureichende Ergebnisse zeigen und diskutieren, dass andere Wege gefunden werden müssen, um die Geländehöhe im Bestand ableiten zu können.

Die Abbildungen 6.26, 6.27 und 6.28 zeigen die abgeleiteten Pflanzenhöhen. Die Farbgebung zeigt den kontinuierlichen Anstieg der Pflanzenhöhe von der Marschkante landeinwärts. Dabei sind die Höhenverläufe zwischen den drei Hauptarten sprunghaft und zeigen klare Grenzen. Blaue Bereiche markieren die Zone des Wattes und *Schoenoplectus tabernaemontani*, blau-grün-gelbe Bereiche *Bolboschoenus maritimus* und orange bis rote Bereiche *Phragmites australis*. Innerhalb der dominanten Pflanzenart sind die Verläufe eher fließend. Dies wird besonders im blau-grün-gelben Farbverlauf in der Zone von *Bolboschoenus maritimus* in HOL sichtbar.

Die beiden Pflanzenhöhen von BAL gemessen im Labor (Abbildung 6.26) und im Gelände (Abbildung 6.27) zeigen prinzipiell ähnliche Muster und Spannweiten (Tabelle 6.20). Die Verteilung der gemessenen Werte (Abbildung 6.18, Seite 111) sind vergleichbar mit den vorhergesagten mittleren Werten (Mittelwert, Median, Quartile). Jedoch scheint die PLSR bei der Modellierung von extremen Pixelwerten Probleme zu bekommen, so ist ein Maximum von über drei Metern in den Labormessungen genauso unrealistisch wie ein negativer Wert für das Minimum der Pflanzenhöhen vorhergesagt aus den Geländehöhen. Diese Extremwerte können jedoch als statistische Ausreißer vernachlässigt werden. Im gesamten Untersuchungsgebiet kommen Laborhöhen von über 2,50 m in nur 40 (0,02 %) von 178.939 Pixeln, negative Werte bei den Geländehöhen kommen in nur 97 Pixel (0,05 %) vor. Allen Vorhersagen ist gemein, dass es bei höheren Werten zu leichten Überschätzungen und bei niedrigen Werten zu Unterschätzungen kommt. Dies wird in den Performanzdiagrammen (Abbildungen 6.26c, 6.27c, 6.28c) sichtbar, weil die Regressionsgerade von der 1:1-Linie entsprechend abweichen. Besonders ausgeprägt ist dieser Sachverhalt bei der Modellierung der Pflanzenhöhen aus dem Gelände für BAL (Abbildung 6.27c). Die Punktwolke zeigt gemäß der drei Hauptvegetationsarten drei Cluster, wobei die Anzahl der Messungen für die hohen (*Phragmites australis*) bzw. die niedrigen Werte (*Schoenoplectus tabernaemontani*) weniger sind als das Hauptcluster im Zentrum

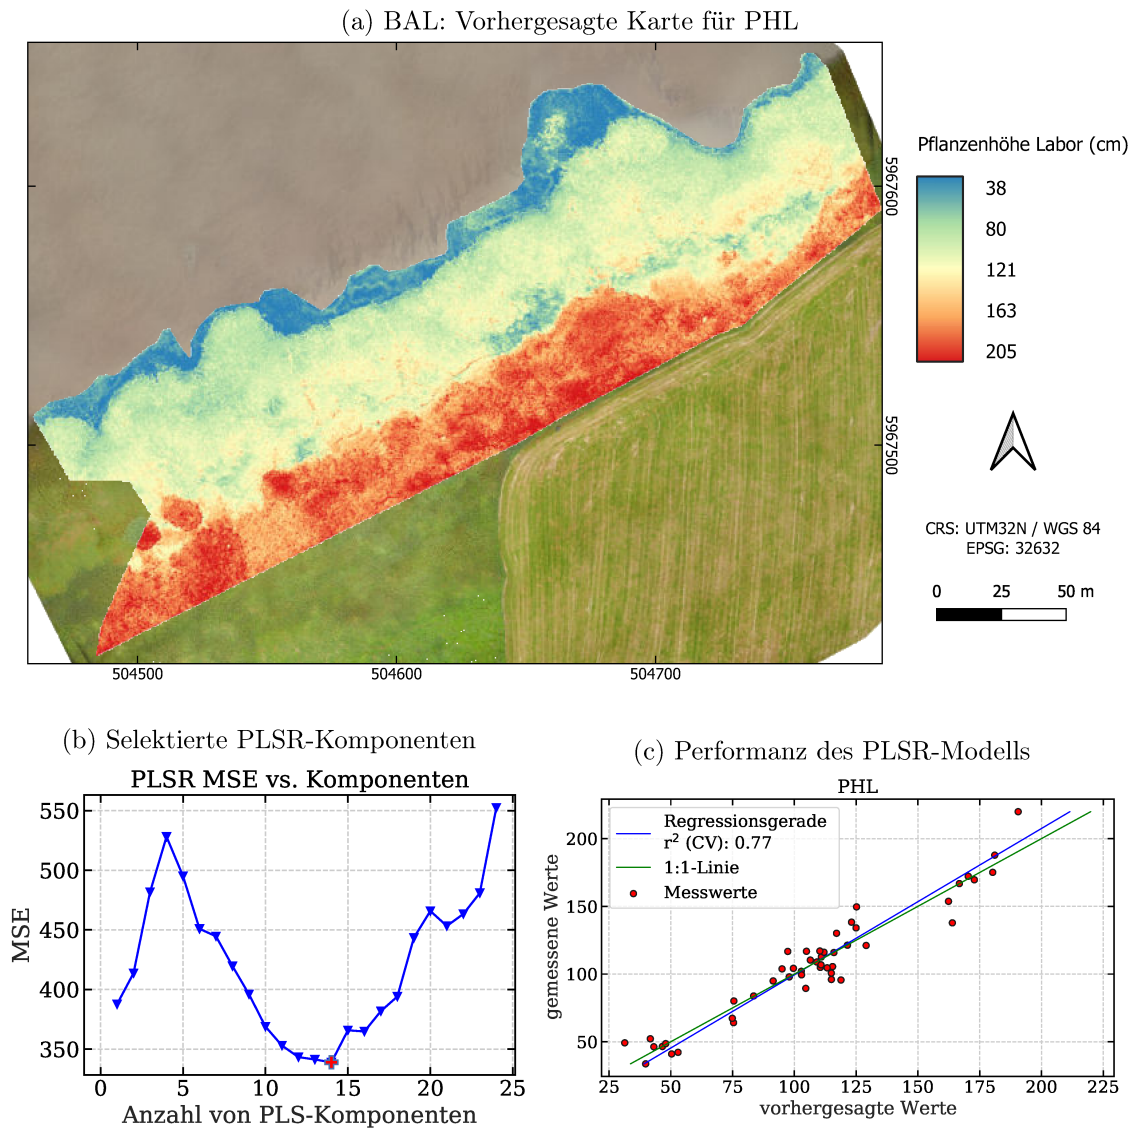


Abbildung 6.26: Ergebnisse der PLSR für den Parameter Pflanzenhöhe gemessen im Labor des Standortes BAL. (a) Vorhergesagte Karte der Pflanzenhöhen in cm. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

(*Bolboschoenus maritimus*).

Da die PLSR-Modelle für BAL und HOL jeweils robuste Ergebnisse für die Geländehöhen (PLSR-NHN) und für die Pflanzenhöhen (PLSR-PHG) zeigten, können hier Differenzkarten der Pflanzenhöhen eine Güte der Modelle zeigen. Dafür wird zunächst die Differenz aus dem DOM (Geländehöhe und Pflanzenbestandshöhen) und der PLSR-NHN-Karten (Geländehöhe) berechnet, um die tatsächlichen Pflanzenhöhen zu erhalten. Im Anschluss werden die erhaltenen Pflanzenhöhen von den Pflanzenhöhen aus der PLSR-PHG abgezogen. Im besten Fall sollten die Pixelwerte der Differenzkarte bei null liegen. Abbildung 6.29 zeigt das Resultat dieser Differenzbildung. In BAL und in HOL sind große Flächen erkennbar, bei der die Differenzbil-

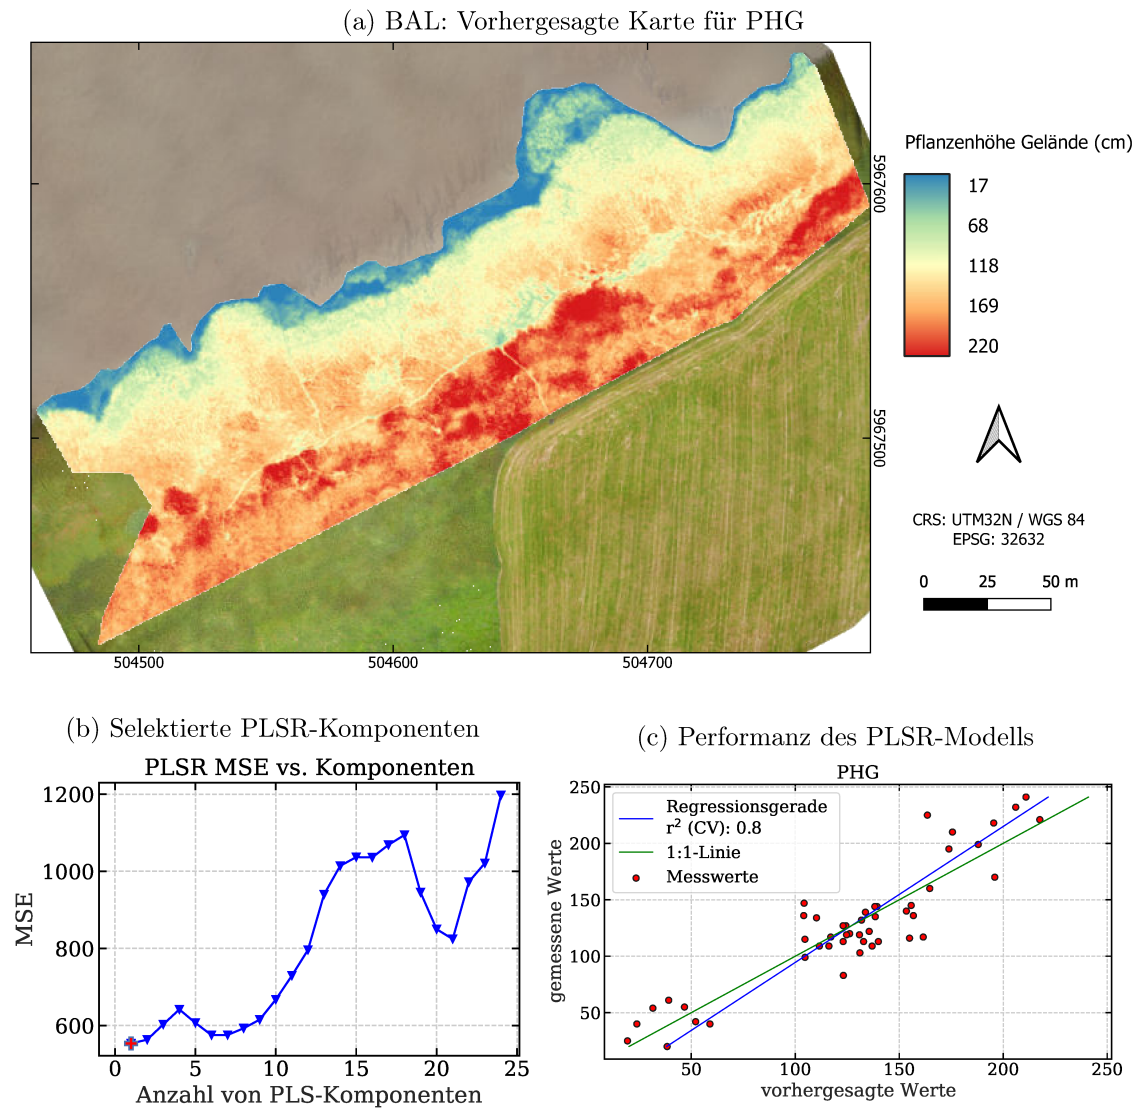


Abbildung 6.27: Ergebnisse der PLSR für den Parameter Pflanzenhöhe gemessen im Gelände des Standortes BAL. (a) Vorhergesagte Karte der Pflanzenhöhen in cm. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

dung tatsächlich grüne Pixelwerte nah bei null Zentimeter Höhendifferenz ergaben. Dies ist ein Hinweis darauf, dass die Ergebnisse beider PLSR-Modellierungen zur Geländehöhe und Pflanzenhöhe gut funktioniert haben. Trotzdem sind auch rote Zonen zu sehen, die auf größere Unterschiede hinweisen. Bei beiden Standorten sind das die Übergangsbereiche von einer Dominanzzone zur nächsten. Dies wird deutlich beim Übergang von *Bolboschoenus maritimus* zu *Phragmites australis* in HOL (Abbildung 6.29b) wo sich eine schwache rote Zone ausbildet. Das kann außerdem eine Hinweis darauf sein, dass in dieser Übergangszone, wo die Bestandshöhe von *Phragmites australis* erst allmählich ansteigt, statistisch nicht hinreichend beprobt wurde. In BAL (Abbildung 6.29a) ist diese Zone auch zu sehen. Jedoch ist in BAL in

Tabelle 6.20: Deskriptive Statistik der vorhergesagten Pflanzenhöhen gemessen im Labor und im Gelände für das gesamte Untersuchungsgebiet in BAL.

| Pflanzenhöhe | Labor (cm) | Gelände (cm) |
|--------------------|------------|--------------|
| Pixelanzahl | 178.939 | 178.939 |
| Minimum | 5,53 | -11,32 |
| 1. Quartil | 92,818 | 113,26 |
| Mittelwert | 121,89 | 137,58 |
| Median | 113,61 | 143,32 |
| Standardabweichung | 45,12 | 49,09 |
| 3. Quartil | 162,94 | 171,53 |
| Maximum | 306,96 | 260,83 |
| Spannweite | 301,43 | 272,15 |

dieser Zone noch ein weiterer Sachverhalt zu berücksichtigen. In der Übergangszone zwischen *Bolboschoenus maritimus* und *Phragmites australis* kommt es zur Lagerbildung, also zu Zonen, wo vorrangig *Bolboschoenus maritimus* patch-artig niedergedrückt ist. Dies konnte durch mangelnde Beprobung von den statistischen Modellen nicht berücksichtigt werden und deswegen sind die Fehler hier entsprechend groß.

Des weiteren ist in BAL der Übergang zwischen *Schoenoplectus tabernaemontani* und *Bolboschoenus maritimus* mit hohen Differenzen verbunden, was ebenfalls darauf schließen lässt, dass diese sehr schmale Übergangszone durch die Feldbeprobung nicht abgedeckt wurde. In HOL ist die gesamte *Schoenoplectus tabernaemontani*-Zone mit hohen Differenzen verbunden, was jedoch eher auf die Wattflächen zwischen dem sehr lichten Bestand zurückzuführen ist, als auf die Modellierung der Pflanzen selbst. Innerhalb dieses roten Bereiches gibt es grüne Bereiche, die auf die tatsächlichen Bestände der Pflanze hinweisen. Die freien Wattflächen werden allgemein schlecht modelliert, weil diese in der Feldbeprobung nicht berücksichtigt wurden und somit auch nicht in der Modellierung.

Ein statistischer Zusammenhang zwischen der Frisch- bzw. Trockenmasse der Pflanzen zum Reflexionsspektrum des multisensoralen Datensatzes konnte nicht gefunden werden. So zeigen die r^2 -Werte der kreuzvalidierten PLSR-Modelle für die Parameter PFM, PTM, FFM sowie FTM keine eindeutigen Muster, sondern sehr heterogene Ergebnisse zwischen -0,16 bis 0,49 (Tabelle 6.19). Um diese Parameter zukünftig besser zu modellieren, sollte das Probedesign verändert werden. Eine randomisierte Entnahme von 10 Pflanzen aus dem Kartierrahmen (40 cm x 40 cm) scheint nicht ausreichend zu sein, um statistisch valide Ergebnisse zu erzielen. Stattdessen sollte der Kartierrahmen zukünftig komplett abgeerntet werden.

Der Wassergehalt der Pflanzen scheint jedoch in diesem hydrologischen Ökosystem ein fernerkundbarer Parameter zu sein, der aus der Differenz der Frisch- und Trockenmasse errechnet wird. So erreichte das kreuzvalidierte PLSR-Modell einen r^2 von 0,83 für BAL und 0,77 für HOL (Tabelle 6.19). Die Abbildungen 6.30 und 6.31 zeigen die Ergebnisse der Vorhersage des Wassergehaltes der Pflanzen. Der Farbverlauf zeigt bei beiden Standorten, dass der Wassergehalt in den Pflanzen vom Hinterland Richtung Watt steigt. Auch hier sind wieder die drei Zonen mit den drei Hauptvegetationsarten erkennbar. *Schoenoplectus tabernaemontani* (dunkelblaue Zone) weist dabei die höchsten Wassergehalte auf, danach kommt *Bolboschoenus maritimus*

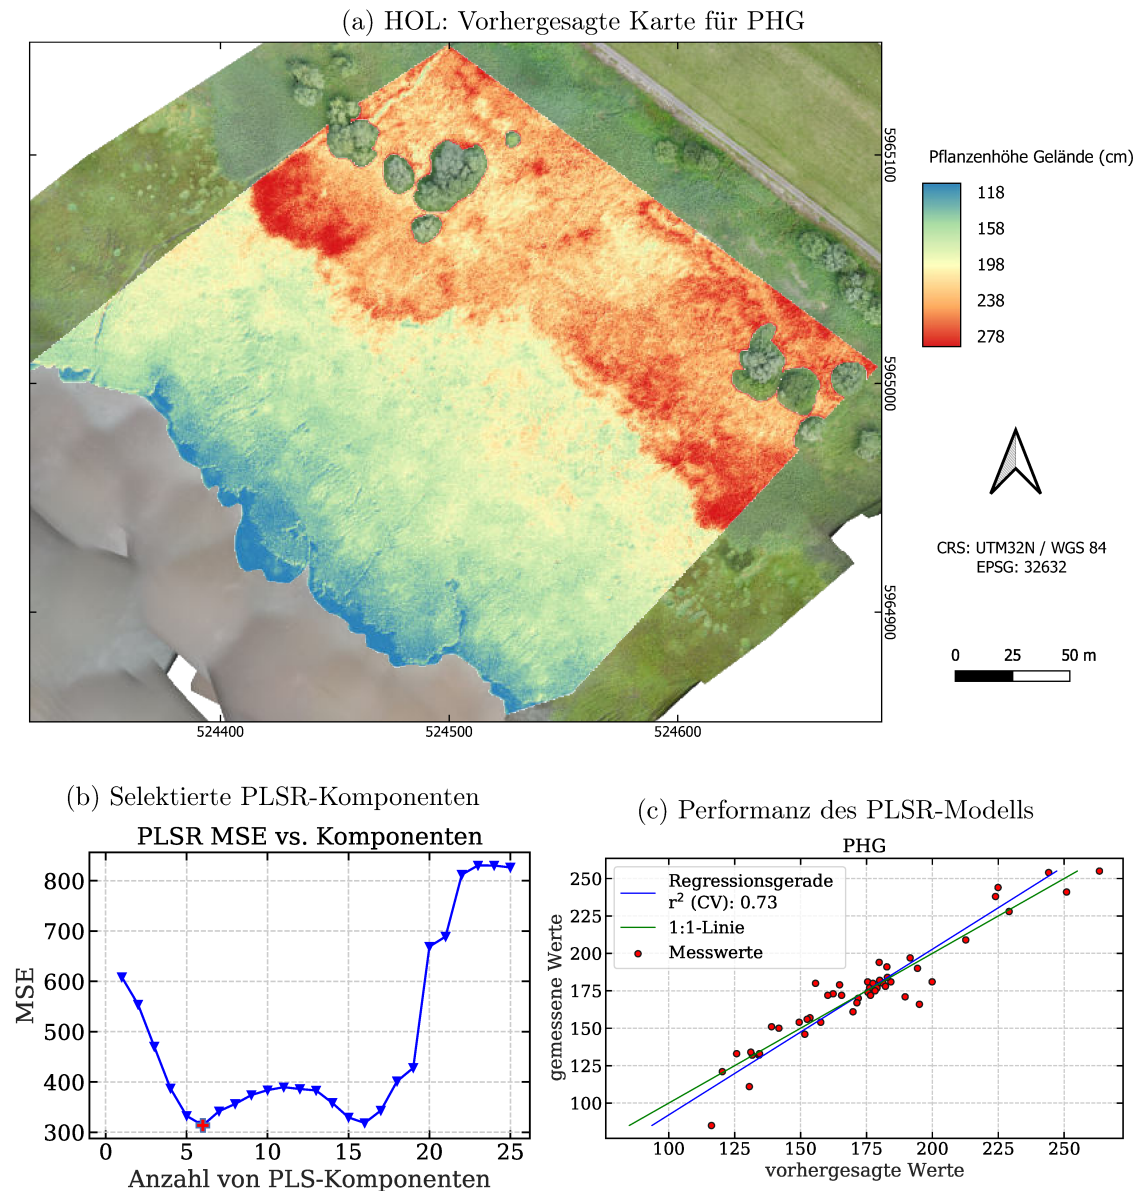


Abbildung 6.28: Ergebnisse der PLSR für den Parameter Pflanzenhöhe gemessen im Gelände des Standortes HOL. (a) Vorhergesagte Karte der Pflanzenhöhen in cm. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

(hellblau grünlich), dann *Phragmites australis* (gelb-grünlich/gelb). Wie schon in den Messwerten ersichtlich war (Abbildung 6.21b) gibt es einen systematischen Unterschied im Wassergehalt zwischen den Standorten BAL und HOL. Der Wassergehalt in den Pflanzen ist in HOL systematisch höher als in BAL. Dies wird auch in den modellierten Daten ersichtlich. Für Tabelle 6.21 und Abbildung 6.32 wurden aus den drei Hauptvegetationszonen beider Standorte jeweils randomisiert Pixel für den Wassergehalt ausgewählt und statistisch aufbereitet. Anhand der Boxplots ist gut zu erkennen, dass die drei Hauptvegetationsarten anhand der Wassergehalte

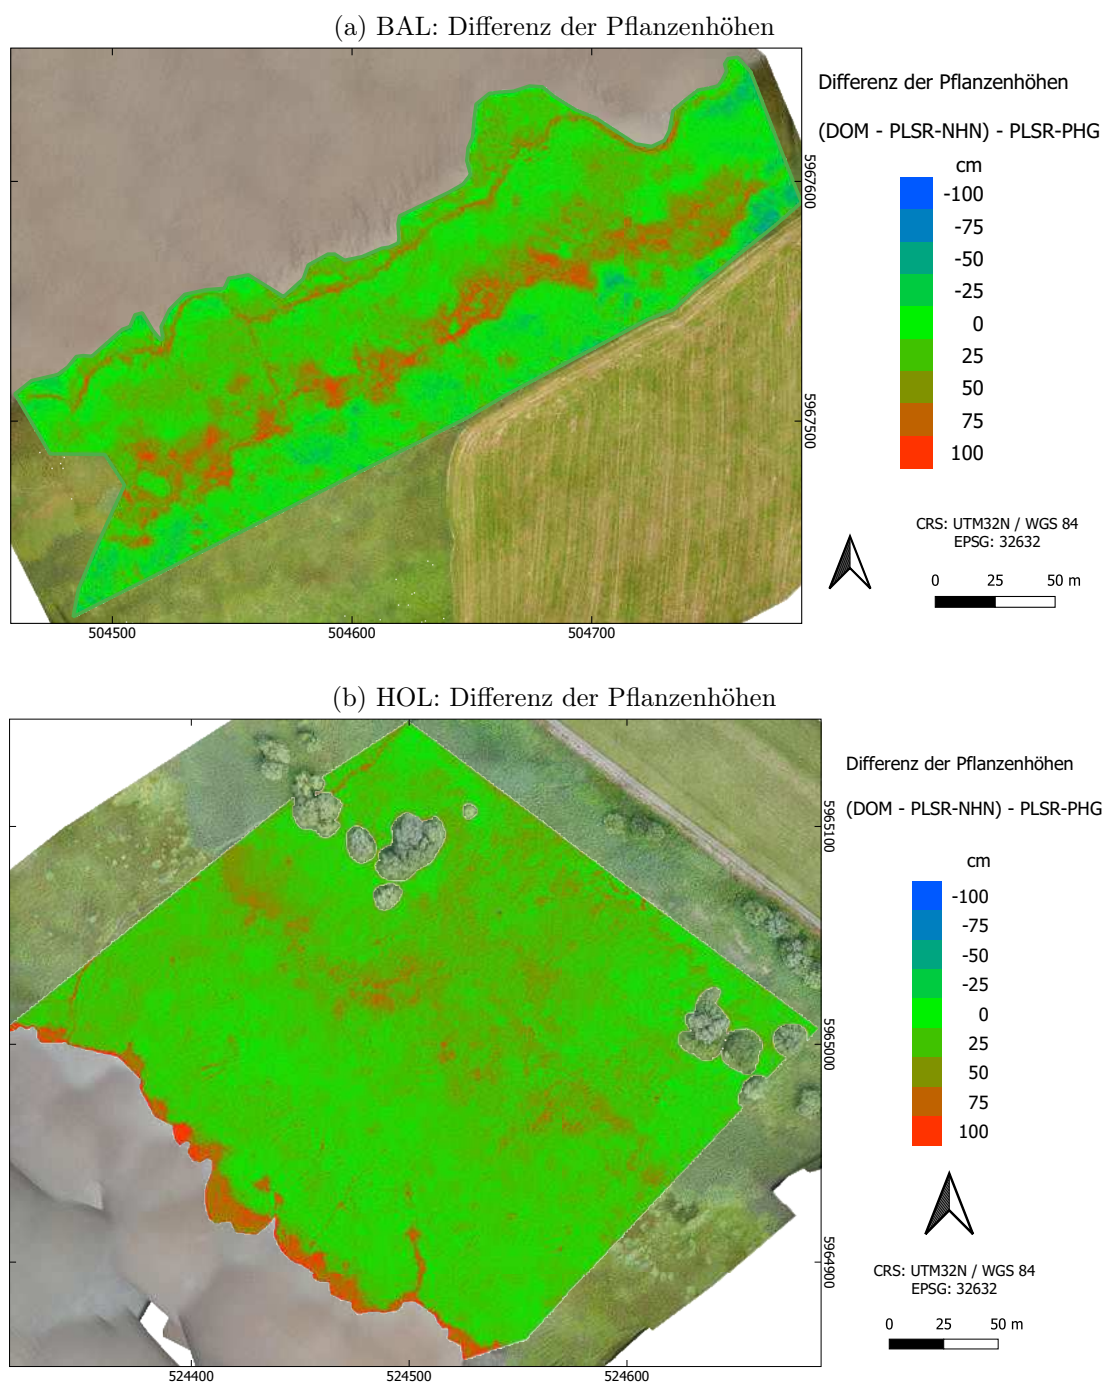


Abbildung 6.29: Differenzkarten zwischen den Pflanzenhöhen, die sich aus der Differenz des DOM und der Geländehöhe (PLSR-NHN) ergaben, und der Pflanzenhöhenkarte (PLSR-PHG). Grüne Werte sind niedrige, blaue sind hohe negative und rote sind hohe positive Differenzen.

sehr gut unterscheidbar sind. Für die Werte von *Schoenoplectus tabernaemontani* in HOL wurden durch die PLSR am oberen Ende der Verteilung Werte über 100 % modelliert, was physikalisch nicht möglich ist. Dies ist ein Hinweis darauf, dass aufgrund der geringen Zahl an Beprobungspunkten in dieser Zone nicht der gesamte Wertebereich abgedeckt wurde. Dies gilt auch für einige Maximalwerte in der Zone

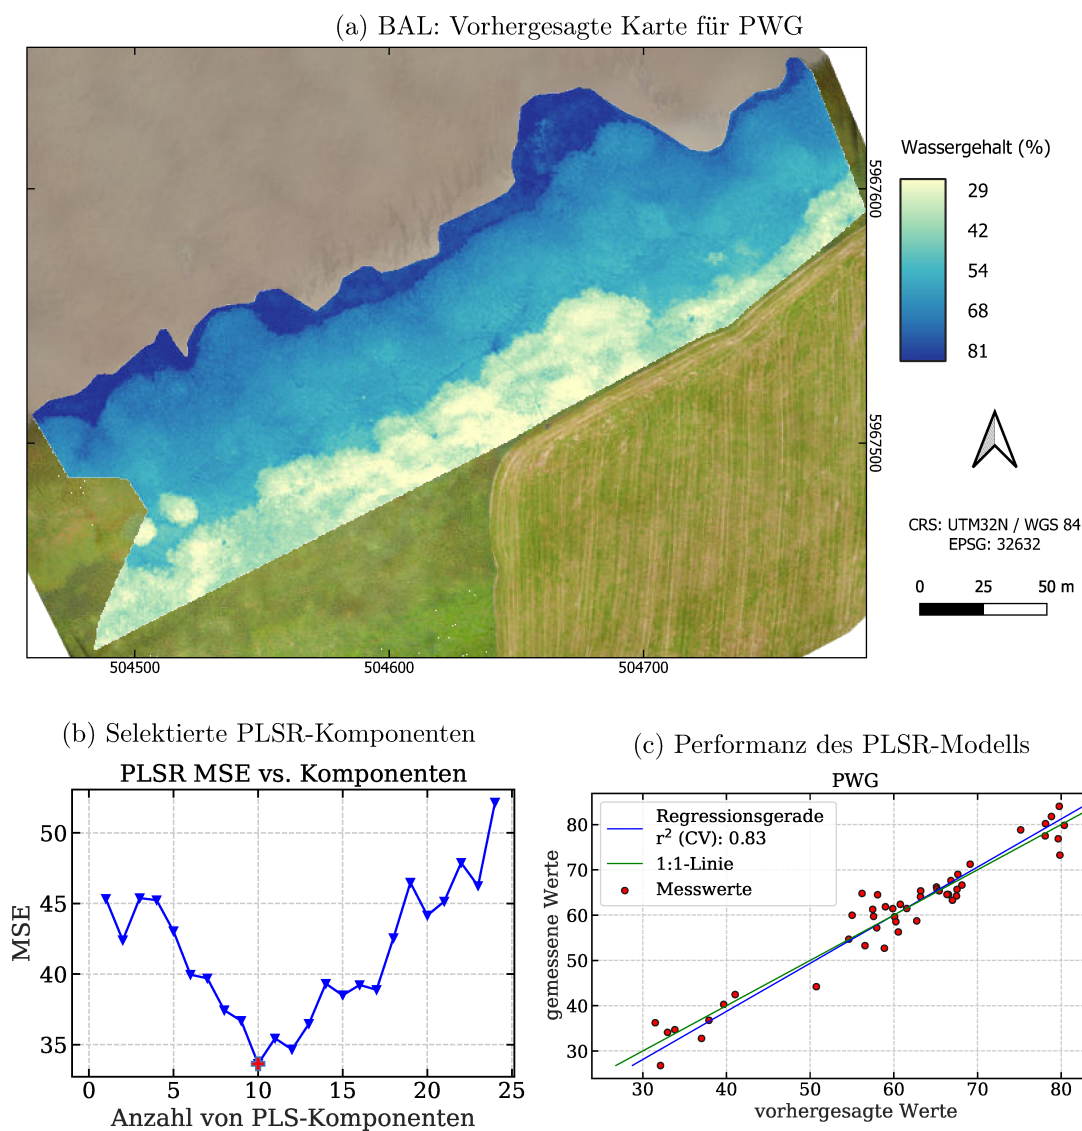


Abbildung 6.30: Ergebnisse der PLSR für den Parameter Wassergehalt der Pflanzen des Standortes BAL. (a) Vorhergesagte Karte des Wassergehalts der Pflanzen in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

von *Phragmites australis*.

Der letzte Parameter, der sehr hohe bis moderate kreuzvalidierte r^2 -Werte von 0,93 (BAL) und 0,57 (HOL) erreichte, ist die photosynthetisch aktive Strahlung (PAR). Die Abbildungen 6.33 (BAL) und 6.34 (HOL) zeigen jedoch, dass die PAR-Werte innerhalb der Pflanzenbestände zu einem Großteil nicht gut differenzierbar sind. Der lichte Bestand am wattnahen *Schoenoplectus tabernaemontani*-Gürtel ist gut erkennbar, jedoch scheinen dann die Bestände von *Bolboschoenus maritimus* und *Phragmites australis* so dicht zu sein, dass die PAR-Werte schnell aufsättigen. Dieser Sachverhalt wird bestätigt durch die Performanzdiagramme (Abbildungen 6.30c und 6.31c). Die hohen Regressionswerte kommen nur zustande durch die hohen

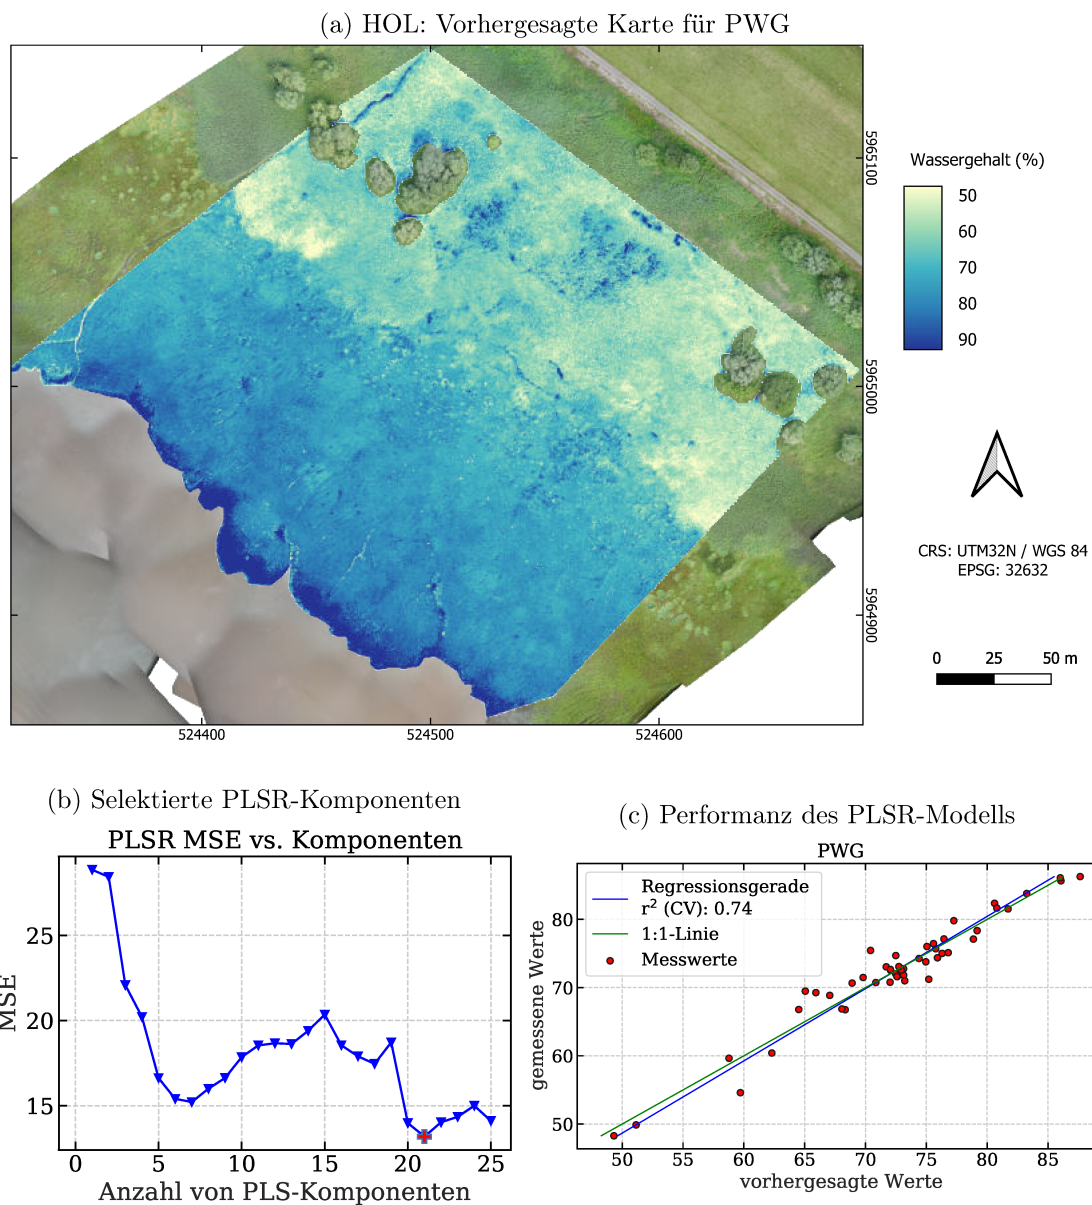


Abbildung 6.31: Ergebnisse der PLSR für den Parameter Wassergehalt der Pflanzen des Standortes HOL. (a) Vorhergesagte Karte des Wassergehalts der Pflanzen in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

PAR-Werte aus dem *Schoenoplectus tabernaemontani*-Bestand. Die restlichen Werte bilden eine dispers streuende Punktwolke nahe am Koordinatenursprung respektive im unteren Bereich der PAR-Werte.




Abbildung 6.32: Vergleich der Wassergehalte der drei Zonen der dominanten Pflanzenarten (ST = *Schoenoplectus tabernaemontani*, BM = *Bolboschoenus maritimus*, PA = *Phragmites australis*) pro Standort. Die Selektion der Pixel erfolgte randomisiert innerhalb der jeweiligen Zone und stellt somit nicht die Gesamtanzahl dar.

Tabelle 6.21: Vergleich der Wassergehalte der drei Zonen der dominanten Pflanzenarten (ST = *Schoenoplectus tabernaemontani*, BM = *Bolboschoenus maritimus*, PA = *Phragmites australis*). Die Selektion der Pixel erfolgte randomisiert innerhalb der jeweiligen Zone und stellt somit nicht die Gesamtanzahl dar.

| | BAL | | | HOL | | |
|--------------------|------|------|------|-------|------|-------|
| | ST | BM | PA | ST | BM | PA |
| Pixelanzahl | | 6965 | | | 6965 | |
| Minimum | 65.4 | 49.5 | 26.3 | 43.5 | 37.2 | 1.7 |
| 1. Quartil | 76.3 | 58.9 | 34.9 | 85.8 | 70.8 | 58.2 |
| Mittelwert | 78.0 | 61.4 | 39.5 | 93.0 | 72.6 | 60.9 |
| Standardabweichung | 2.6 | 3.4 | 6.3 | 12.2 | 3.1 | 5.4 |
| Median | 78.3 | 61.6 | 38.7 | 92.9 | 72.5 | 61.7 |
| 3. Quartil | 79.8 | 64.2 | 42.7 | 100.5 | 74.4 | 64.1 |
| Maximum | 87.6 | 75.3 | 58.4 | 145.0 | 94.0 | 103.2 |

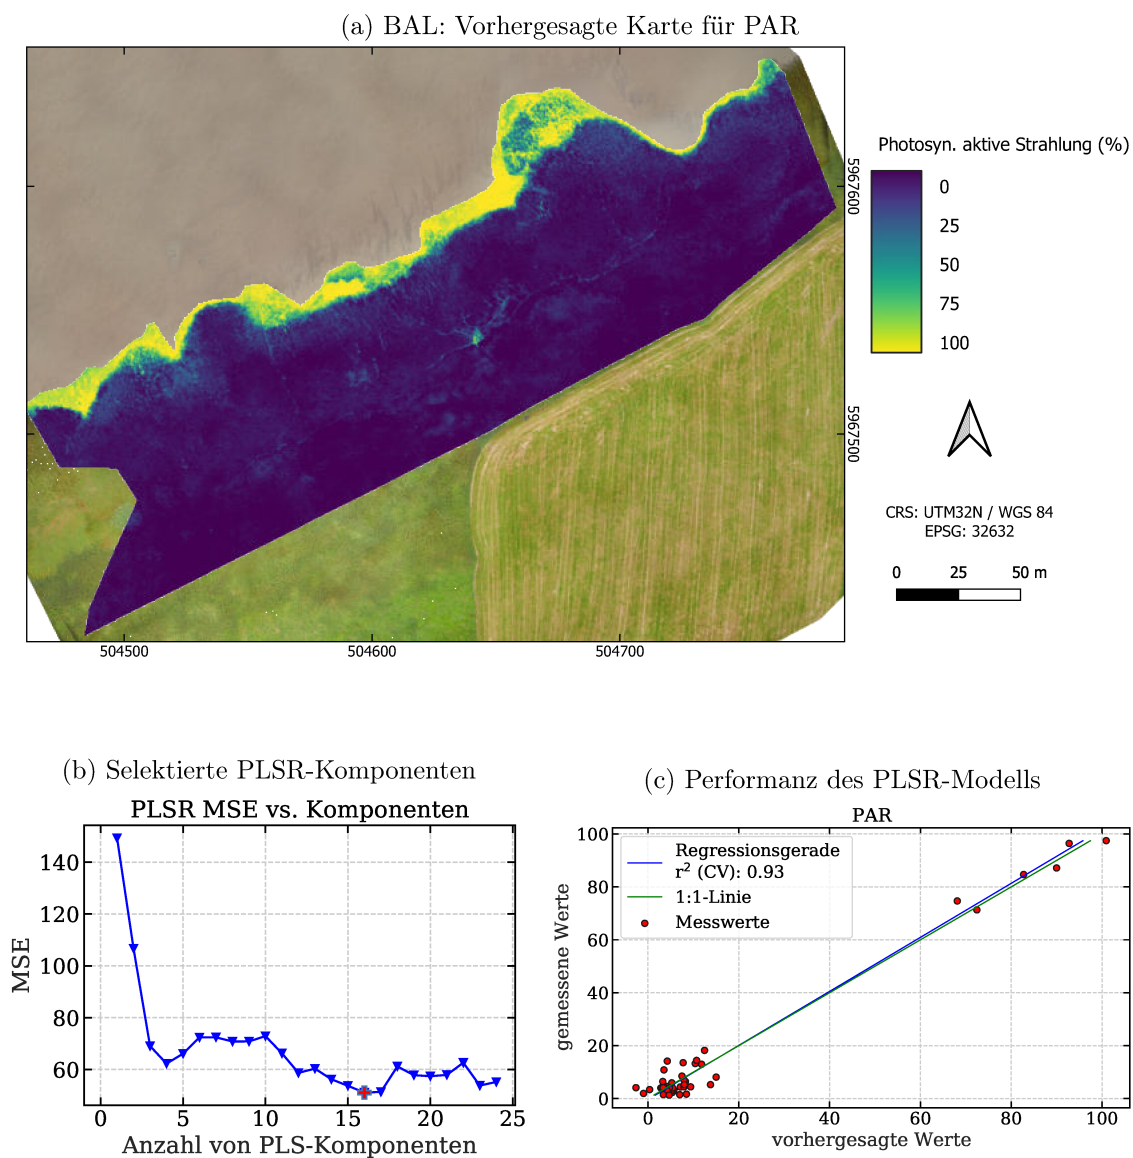


Abbildung 6.33: Ergebnisse der PLSR für den Parameter photosynthetisch aktive Strahlung des Standortes BAL. (a) Vorhergesagte Karte der photosynthetisch aktiven Strahlung in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

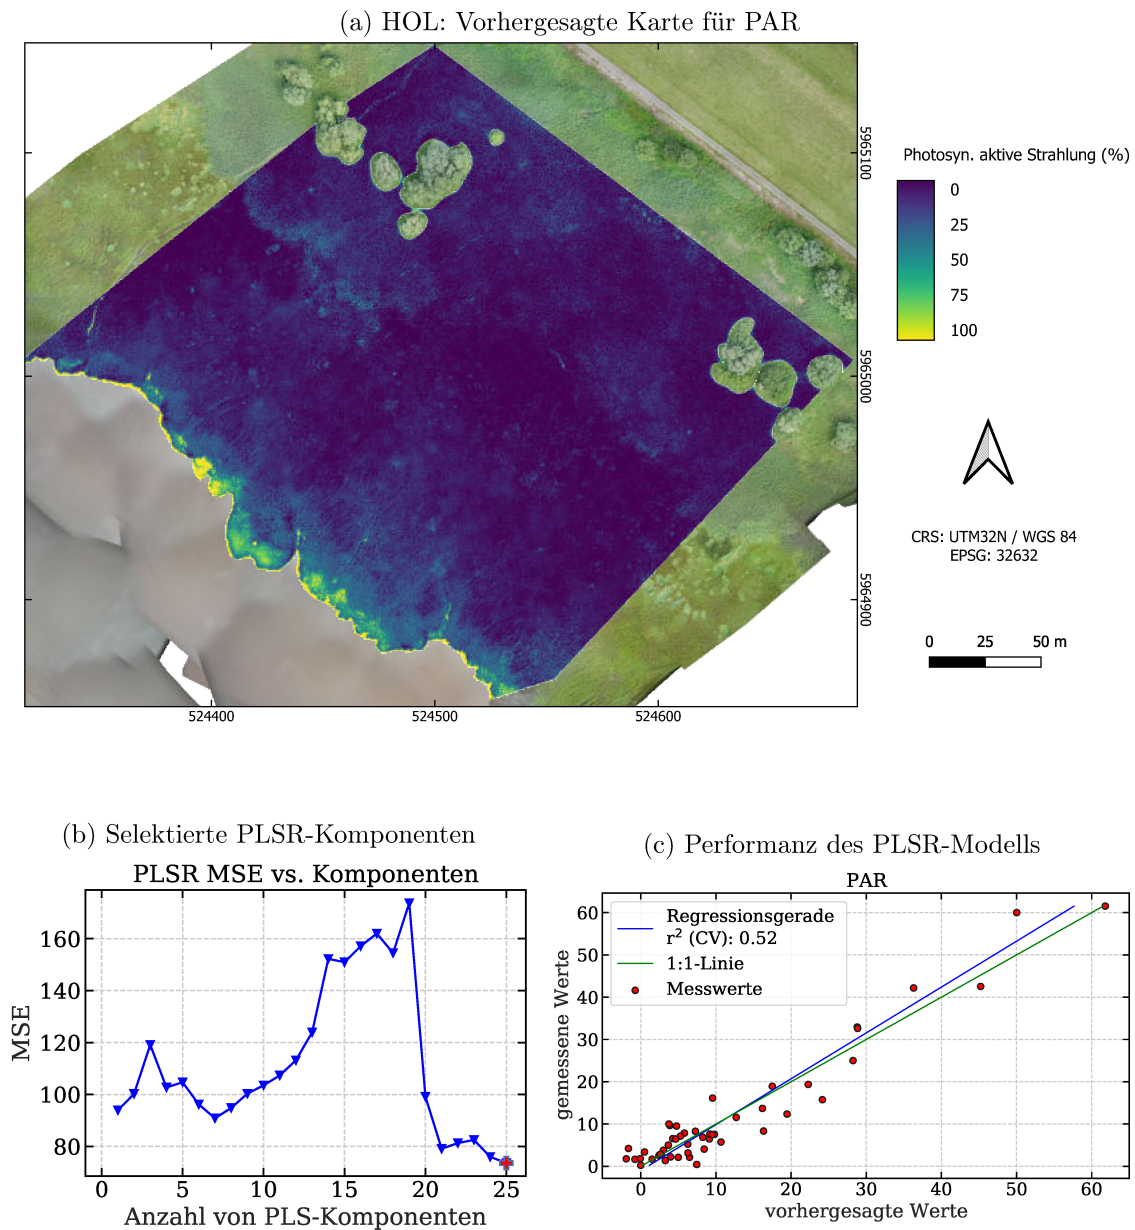


Abbildung 6.34: Ergebnisse der PLSR für den Parameter photosynthetisch aktive Strahlung des Standortes HOL. (a) Vorhergesagte Karte der photosynthetisch aktiven Strahlung in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells.

Relevanzen der Kanäle

Im Folgenden werden die Kanalrelevanzen zusammengetragen. Dafür wurde im Pythonskript eine Funktion geschrieben, die für jeden Kanal die Relevanz *VIP* ausgibt und die Werte im Anschluss in prozentuale Angaben umrechnet. Für jeden Parameter bzw. für jedes PLSR-Modell wurde so der Einfluss jedes einzelnen Kanals und danach die sensorweise kumulierten Relevanzen berechnet. Bei der folgenden Betrachtung werden nur die selektierten Parameter berücksichtigt, die schon im vorherigen Abschnitt als Karte dargestellt wurden und in der PLSR ein höheres r^2 als 0,5 aufwiesen.

Die Abbildung 6.35 zeigt alle prozentualen Relevanzen der Parameter NHN, PHL, PHG, PWG und PAR für BAL sowie NHN, PHG, PWG und PAR für HOL. Im Anhang A.11 (Seite 233) sind die Werte der Einzelkanäle absteigend sortiert nach Relevanz nochmals tabellarisch zusammengefasst für BAL in Tabelle A.21 und für HOL in Tabelle A.22. Die sortierten Einzelkanal-Relevanzen zeigen in BAL (Abbildung 6.35a) für die Parameter NHN, PHL, PHG und PWG klare und vergleichbare Muster. Die grau hinterlegten Bereiche sind die Kanäle mit den höchsten Relevanzen. Der Parameter PAR, der schon in den vorherigen Betrachtungen niedrige statistische Robustheit aufwies, zeigt auch hier differente Ergebnisse.

Wie im Klassifikationsteil, ist das DOM bzw. die Oberflächenstruktur bei allen Parametern (außer bei PAR) die wesentliche Variable zur Generierung eines statistischen Modells. Das heißt, dass die unterschiedlichen Vegetationshöhen, trotz des leicht aber kontinuierlich ansteigenden Geländes der wichtigste Treiber beim Training des Algorithmus ist. Dicht gefolgt wird das DOM meist von Infrarotinformation, entweder von den reinen Spektralkanälen NIR und RE oder von Spektralkanälen, wo dieser Bereich mit einfließt, wie der *ndrdi*, *tc_yvimss* oder *ccci*. Die beiden Indizes *ndrdi* und *ccci* sind normalisierte Differenzen aus den Kanälen des Infrarotbereiches und dem sichtbaren Bereich. Der Index *tc_yvimss* ist ein Index aus der *Tasseled Cap Transformation*, einer Methode die alle Kanäle einbezieht und nach bestimmten Regeln transformiert [JONES und VAUGHAN 2010]. Der *tc_yvimss* ist hier der sogenannte *Yellowness Index*. Zwei weitere Indizes die bei jeder Regression obere Ränge belegen sind aus den RGB-Daten berechnet worden, der Texturindex *Energy* (*ene*) und der Spektralindex *vari*.

Die restlichen Texturindizes zeigen systematisch niedrigere Relevanzen, besonders *Contrast* (*cont*). Auch die originalen RGB-Kanäle befinden sich stets im unteren Drittel. Außerdem sind die Reliefindizes, vergleichbar zum Klassifikationsteil, eher moderat bis wenig wichtig.

Vergleichbare Ergebnisse wurden auch für HOL erzielt (Abbildung 6.35b und Tabelle A.22 im Anhang A.11). Bei HOL ist die Relevanz des DOM im Vergleich zu BAL noch deutlicher. Die Ergebnisse für PAR weichen auch hier wieder erheblich ab von den Parametern NHN, PHG und PWG und werden aufgrund der statistisch schwachen Ergebnisse nicht weiter betrachtet. Nach dem DOM folgen größtenteils die MS-Kanäle RE und NIR oder die daraus generierten spektralen Indizes *datt1*, *msbi* und *ndrdi*. In diesem Bereich ist auch wieder der RGB-Index *vari* sowie die Texturindizes *Energy* (*ene*) und *mean* angesiedelt. Außerdem sind, wie für BAL, die Reliefindizes und die reinen RGB-Kanäle von untergeordneter Bedeutung für die

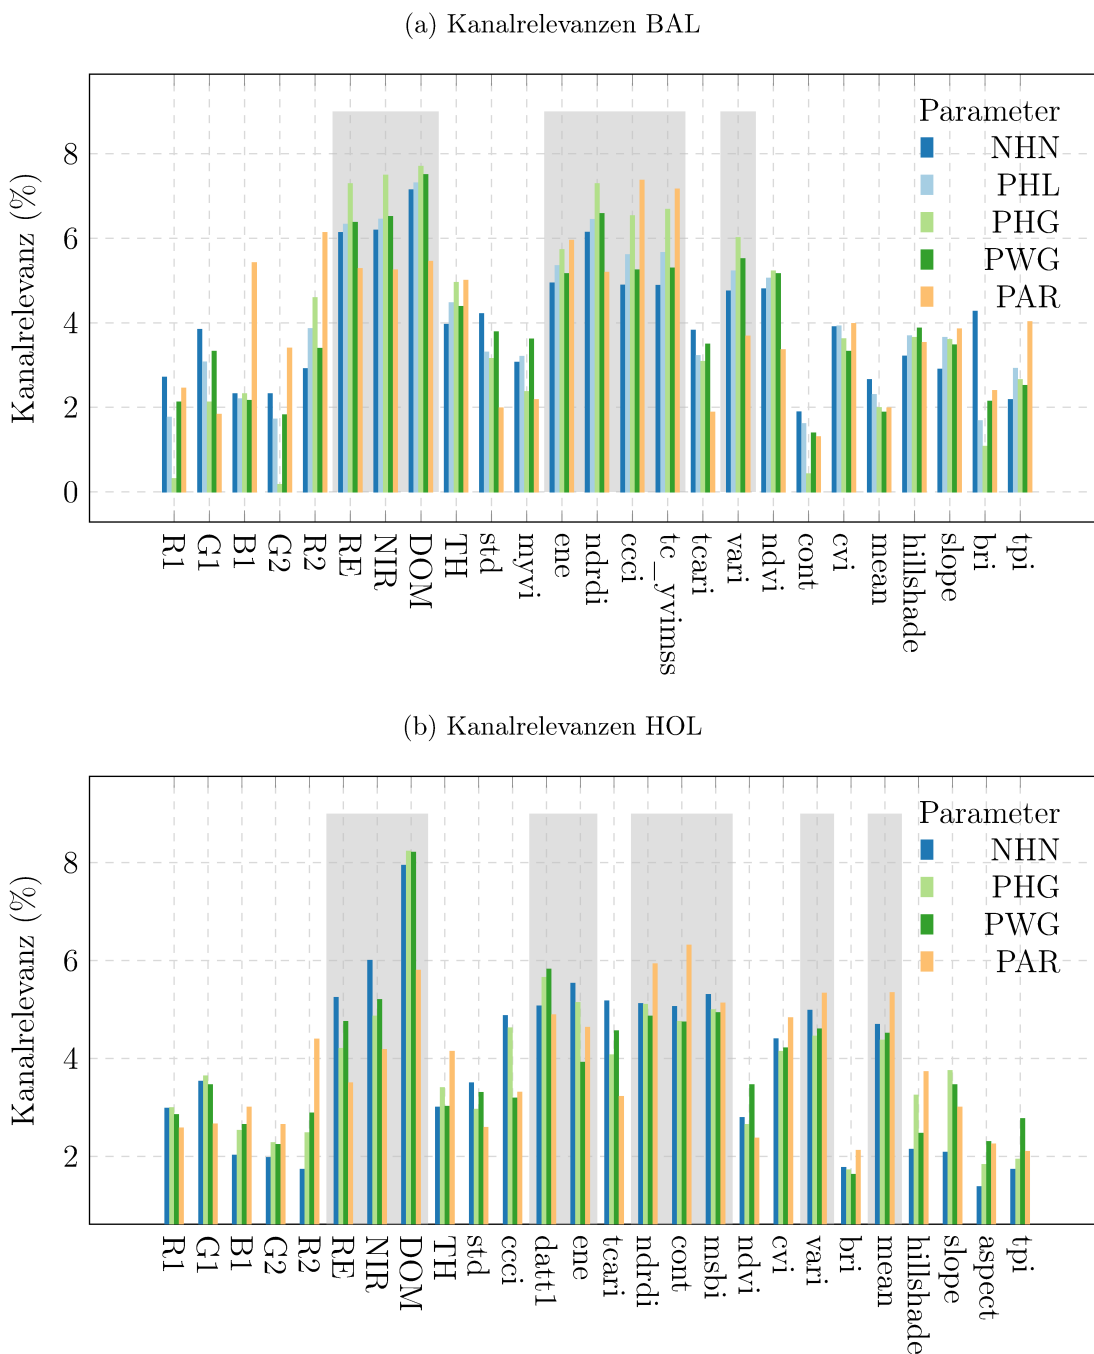


Abbildung 6.35: Relevanz der einzelnen Kanäle der erweiterten multisensoralen Datensätze für (a) BAL und (b) HOL und die jeweilig selektierten Parameter. Die grau hinterlegten Bereiche heben die wichtigsten Kanäle hervor.

Generierung der Regressionsmodelle. Im Unterschied zu BAL ist der Texturindex *cont* (*Contrast*) auch im oberen Drittel der Relevanzen zu finden.

Die Abbildung 6.36 zeigt die kumulierten Relevanzen nach dem Kanaltyp und dem jeweiligen Sensor für jede der Parameter für beide Standorte. Die Relevanz der einzelnen Kanal- bzw. Datentypen verhält sich größtenteils, bis auf eine Ausnahme gleich. Kumuliert sind die Texturindizes bei HOL wichtiger als die multispektralen Originalkanäle: Beide Datentypen scheinen aber grundsätzlich wichtig zu sein.




Abbildung 6.36: Kumulierte Relevanzen nach Kanaltyp für (a) BAL und (b) HOL (Orig = Originalkanäle, Spek = Spektralindex, Tex = Texturindex, Rel = Reliefindex).

Ansonsten sind die kumulierten multispektralen Indizes die wichtigsten Informationsquellen um die PLSR für die gewählten Parameter zu verwenden. Außerdem ist auffällig, dass der originale DOM-Kanal im Vergleich zu den kumulierten Kanälen unwichtiger wird und jetzt sogar die Reliefindizes wichtiger sind. Es muss jedoch berücksichtigt werden, dass der einzelne Kanal in dieser Betrachtung konkurriert mit einer kumulierten Vielzahl von anderen Kanälen und für sich allein gesehen weiterhin beachtlichen Informationsgehalt aufweist.

Die sensorweise kumulierten Werte (Tabelle A.25, Seite 242) zeigen ein eindeutiges Ergebnis. Der MS-Sensor liefert mit rund 50 % die wichtigsten Informationen für die Regressionen, gefolgt vom RGB-Sensor, DOM und den Thermaldaten. Da das DOM theoretisch aus allen der drei Sensoren berechnet werden könnte, wird dies auch hier gesondert aufgeführt.

6.3.3 Ableitung weiterer Karten mittels linearer Regression aus den PLSR-Karten

Auf Basis der statistischen Voruntersuchungen (Abschnitt 6.3.1) und der Ergebnisse der PLSR (Abschnitt 6.3.2) kann nun geprüft werden, ob weitere Parameter abgeleitet werden können

Beispielsweise hat die statistische Voruntersuchung ergeben, dass in BAL die Korrelation von NHN mit den Parametern PHL ($r = 0,85$), PHG ($r = 0,82$), PTM ($r = 0,69$), FTM ($r = 0,62$), PWG ($r = -0,91$) und PDML ($r = -0,71$) moderate bis hohe Zusammenhänge aufweisen (Abbildung 6.22a, 115). Auch in HOL zeigte NHN moderate bis hohe Korrelationen (Abbildung 6.22b, Seite 115) mit den Parametern PHG ($r = 0,83$), PWG ($r = -0,85$), PDML ($r = -0,71$) und PAR ($r = -0,66$). Die Abbildungen 6.37 (BAL) und 6.38 (HOL) zeigen die lineare Regression dieser Parameter. Da die PLSR-Modelle statistisch robuste Vorhersagen der Geländehöhe (NHN) erlauben, kann diese Vorhersage genutzt werden um die genannten Parameter flächenhaft abzuleiten. Die Bestimmtheitsmaße (r^2) der NHN-Regressionen zeigen für BAL moderate Zusammenhänge zwischen den Pflanzenhöhen (Abbildungen 6.37a und 6.37b) und einen hohen Zusammenhang zum Wassergehalt (Abbildung 6.37e) der Pflanzen. Da diese schon mithilfe der PLSR selbst abgeleitet werden konnten, wird auf deren Übertragung mittels linearer Regression verzichtet.

Der Zusammenhang zwischen NHN und dem Stängeldurchmesser (PDML, Abbildung 6.37f) sowie der Trockenmassen pro Pflanze (PTM, Abbildung 6.37c) sinkt auf ein Niveau, in der die Regressionsgerade nur noch die Hälfte der Varianz oder weniger erklärt. Da die Regressionen trotzdem hoch signifikant sind ($p = 0,000$), kann trotzdem der erklärte Anteil von NHN auf diese Parameter abgeleitet werden.

In HOL zeigt sich das gleiche Muster (Abbildung 6.38). Die schon in über die PLSR abgeleiteten Karten für PHG und PWG zeigen auch hohe lineare Zusammenhänge zu NHN. Das ermittelte Bestimmtheitsmaß (r^2) für die Stängeldurchmesser (PDML) ist mit 0,5 vergleichbar mit dem Ergebnis von BAL. Die schwache Repräsentation der PAR-Werte durch eine lineare Regression für den Parameter PAR zeigt die Abbildung 6.38d. Hier lässt sich eher eine exponentielle Funktion durch die Punktwolke legen, was bedeutet, dass PAR im lichten, niedrigliegenden Bestand von *Schoenoplectus tabernaemontani* zunächst hohe Werte hat, jedoch dann sehr rasch aufsättigt in dichteren, höherliegenden Beständen. Im gesättigten Bereich ist dann keine Differenzierung mehr möglich.

Neben NHN korrelieren auch Parameter mit PWG, was auch mittels der PLSR sehr robust abgeleitet werden konnte. In BAL sind das die Pflanzenhöhen (PHL: $r = -0,89$, PHG: $r = -0,88$) und die Trockenmassen (PTM: $r = -0,78$, FTM: $r = -0,71$). Die Regression der Pflanzenhöhen (Abbildung 6.39a und 6.39b) unterstreichen nochmals die Unterschiede zwischen den drei dominanten Hauptvegetations-

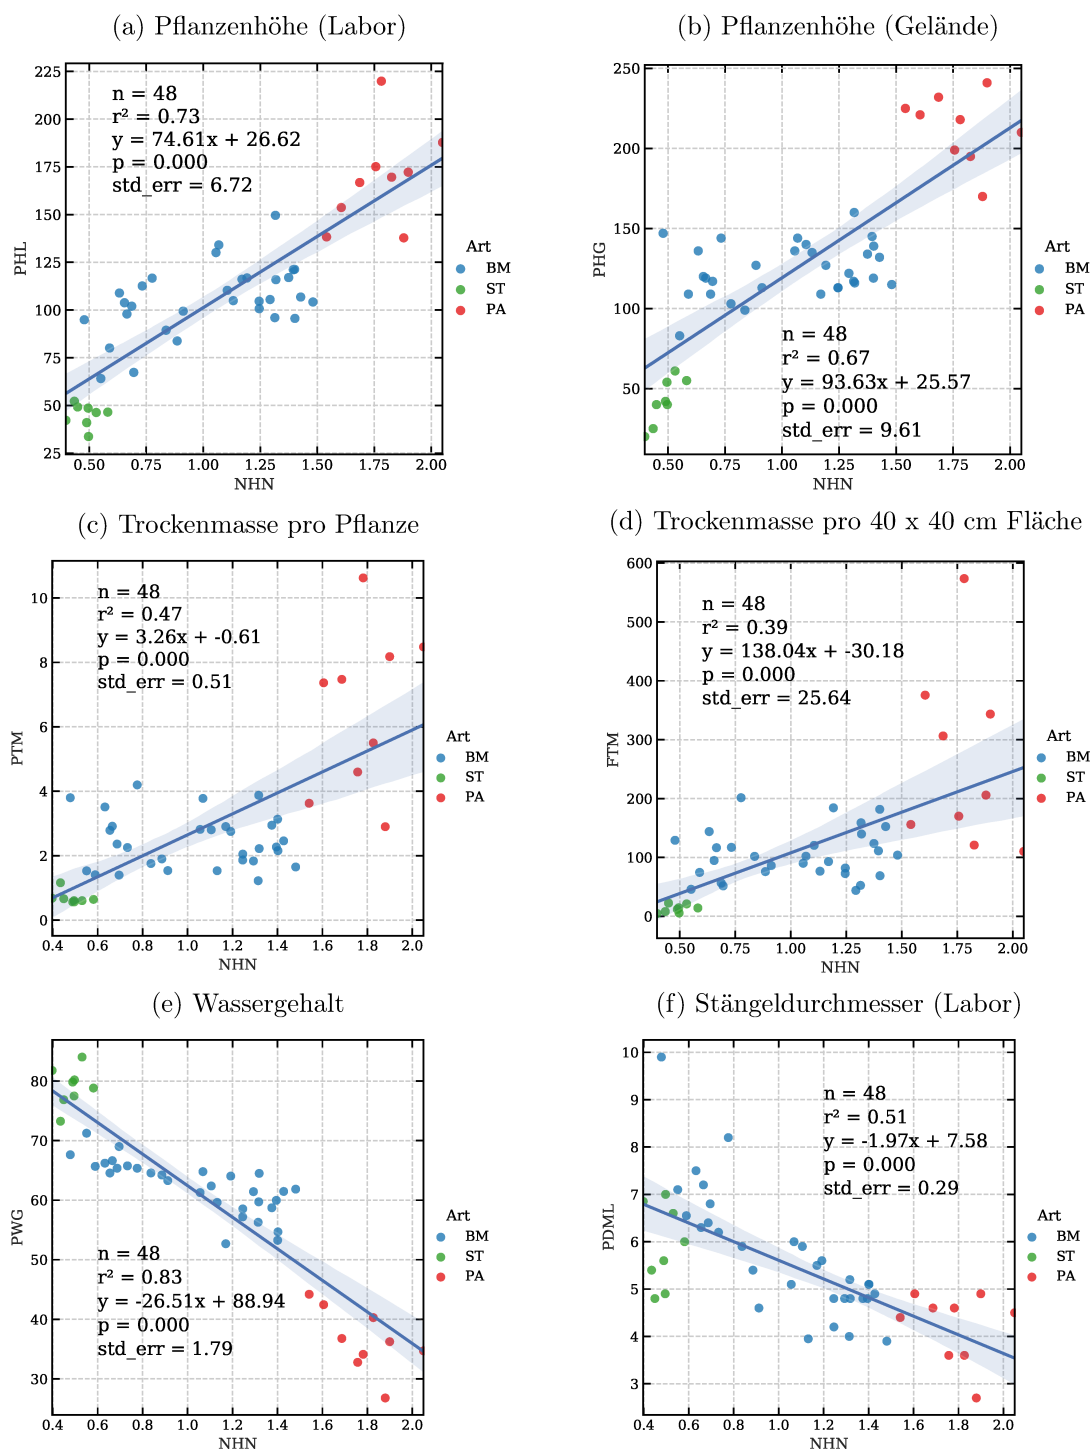


Abbildung 6.37: Regressions zwischen NHN und ausgewählten Parametern für BAL.

typen. Die hohen *Phragmites australis*-Bestände sind trockener als *Bolboschoenus maritimus* und *Schoenoplectus tabernaemontani*. Dasselbe Bild ergibt sich bei der Regression von PWG mit der Trockenmasse PTM und FTM, wo höhere Pflanzen ein höheres Trockenmassegewicht aufweisen (Abbildung 6.39c und 6.39d).

In HOL korreliert PWG mit Pflanzenhöhen (PHL: $r = -0,72$, PHG: $r = -0,86$) und der Trockenmasse pro Pflanze (PTM: $r = -0,74$). Die Regressions in Abbildung 6.40

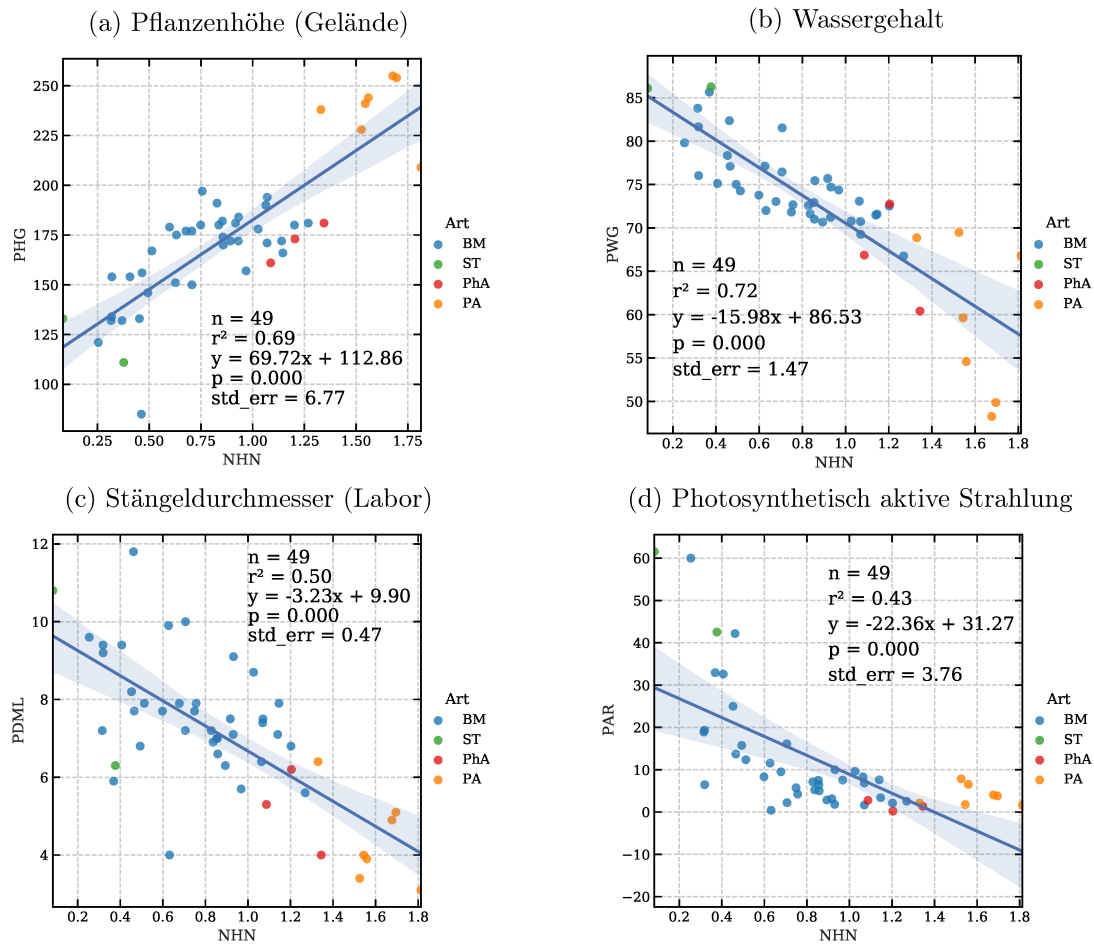


Abbildung 6.38: Regressionen zwischen NHN und ausgewählten Parametern für HOL.

zeigen erhöhte Streuung und Unsicherheiten in den hohen Messwerten von PHG, PHL und PTM. Daraus sollte jedoch nicht geschlossen werden, dass diese hohen Werte statistische Ausreißer sind. Für diese Pflanzenbestände, vor allem *Phragmites australis*, existieren im Vergleich zu *Bolboschoenus maritimus* zu wenige Messpunkte um das Modell robuster zu generieren.

Die Pflanzenhöhen zeigten moderate bis hohe statistische Beziehungen zu Pflanzenmassen (Abbildung 6.22, Seite 115), besonders bei BAL. Die Pflanzenhöhe korrelierten mit den Frischmassen PFM (PHL: $r = 0,77$, PHG: $r = 0,72$) und FFM (PHL: $r = 0,7$, PHG: $r = 0,66$). Die Regression (Abbildung 6.41) zwischen den Pflanzenhöhen und der Frischmasse zeigt, dass besonders die hohen Werte des *Phragmites australis*-Bestandes stark streuen. Die Regressionsmodelle sind alle hochsignifikant und erklären in etwa die Hälfte der Varianz. Das robusteste Modell ist dabei die Regression zwischen PHL und PFM (Abbildung 6.41b), mit einem r^2 von 0,6.

Die Trockenmassen PTM (PHL: $r = 0,89$, PHG: $r = 0,84$) und FTM (PHL: $r = 0,79$, PHG: $r = 0,75$) weisen höhere statistische Zusammenhänge mit den Pflanzenhöhen auf als die Frischmassen. Die Regressionen (Abbildung 6.42) zeigen ähnliche Muster mit hoher Streuung in den hohen Werten wie bei den Frischmassen, jedoch streuen sie im Mittel 10 bis 20 % weniger. Das robusteste Modell ist auch hier die Regression zwischen PHL und PTM (Abbildung 6.42c), mit einem r^2 von 0,79.

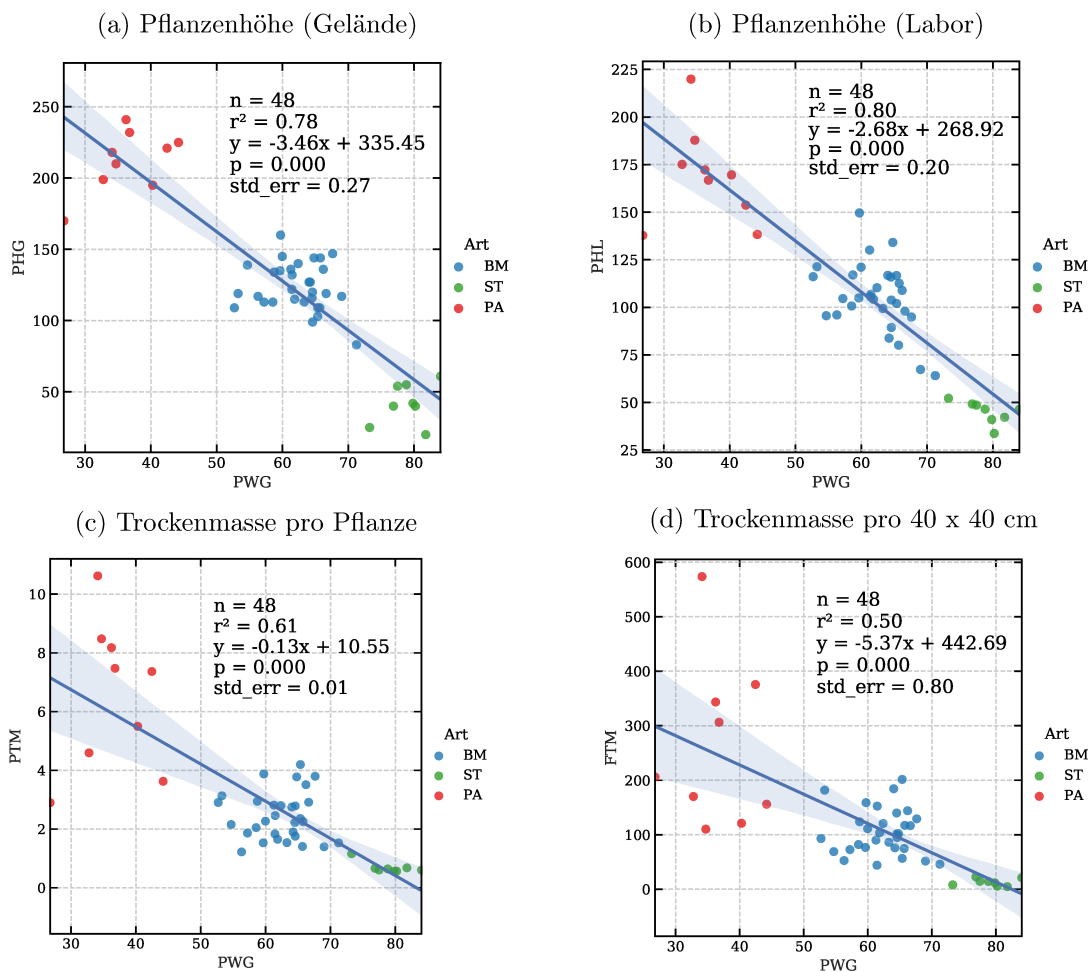


Abbildung 6.39: Regressionen zwischen PWG und anderen Parametern in BAL

Es wurden auch weitere Korrelationen zwischen den Parametern gefunden, deren lineare Regressionen als Abbildungen im Anhang A.10 (Seite 229) zu finden sind. Die photosynthetisch aktive Strahlung korrelierte mit den Pflanzenhöhen im Gelände auf beiden Standorten moderat negativ (BAL: PHG = -0,69; PHL = -0,68; HOL: PHG = -0,64, Abbildung A.18). Auch die Beziehung zwischen PAR und Pflanzenhöhe ist nicht linear, sondern exponentiell. Dies bedeutet, dass die Strahlung, die bis zum Boden gelangt exponentiell mit steigender Pflanzenhöhe, bzw. hier eher Bestandsdichte, abnimmt. In den Punktwolken von BAL (Abbildung A.18a und A.18b) ist deutlich zu erkennen, dass große pflanzenartenabhängige Messlücken bestehen zwischen dem dichten Bestand von *Bolboschoenus maritimus* und dem sehr lichten Bestand von *Schoenoplectus tabernaemontani*. In HOL (Abbildung A.18c) ist der Übergang dieser beiden Bestände nicht so deutlich. Außerdem zeigt der Bereich mit hohen PAR-Werten, dass es nicht nur lichte Bestände von *Schoenoplectus tabernaemontani*, sondern auch von *Bolboschoenus maritimus* gibt.

Aus den gezeigten Regressionen werden im folgenden Schritt die robustesten Modelle selektiert um die jeweiligen Parameter auf die Fläche zu übertragen. Nach Sichtung der Ergebnisse der linearen Regressionen können für BAL fünf weitere Parameter, für HOL zwei weitere Parameter abgeleitet werden. Welche Parameter

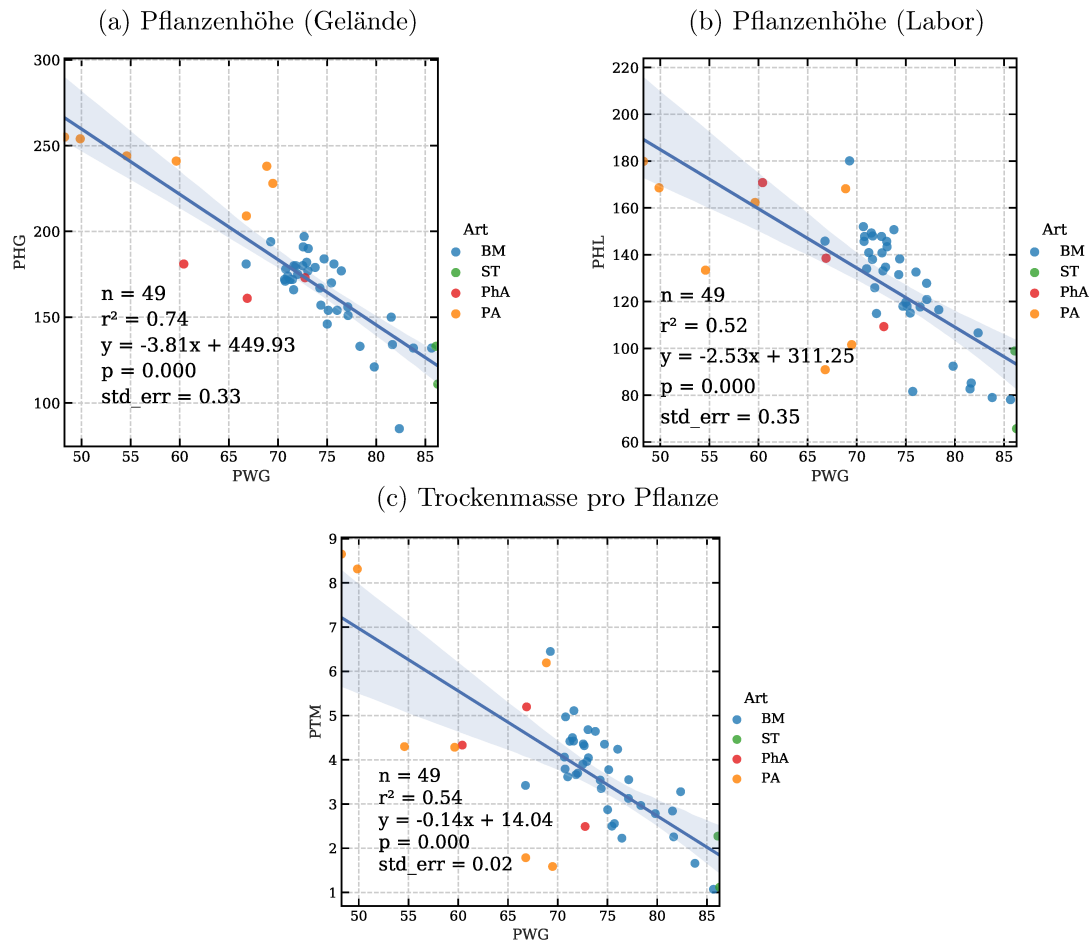


Abbildung 6.40: Regressionen zwischen PWG und anderen Parametern in HOL

das sind und aus welchen PLSR-Karten diese generiert werden, wird in Tabelle 6.22 zusammengefasst. Für das Projekt TIBASS ist unter anderen der Parameter Stängeldurchmesser ein zentraler Faktor, um die Wellenreduktion durch Pflanzen zu modellieren. Der durchschnittliche Stängeldurchmesser für die drei Hauptpflan-

Tabelle 6.22: Selektierte Parameter die mithilfe der Regressionsgerade (Abb. = Abbildung)) auf die jeweilige PLSR-Karte übertragen werden.

| | ableitbarer Parameter | | lin. Regression | | Abb. | aus PLSR |
|-----|-----------------------|-----------------------------|-----------------|---------------------|-------|----------|
| | Code | Parameter | r ² | Gleichung | | |
| BAL | PDML | Stängeldurchmesser (Labor) | 0,51 | y = -1,97x + 7,58 | 6.37f | NHN |
| | PTM | Trockenmasse pro Pflanze | 0,79 | y = 0,05x - 2,24 | 6.42d | PHL |
| | PTM | Trockenmasse pro Pflanze | 0,61 | y = -0,13x + 10,55 | 6.39c | PWG |
| | FTM | Trockenmasse pro 40 x 40 cm | 0,63 | y = 2,02x - 97,48 | 6.42b | PHL |
| | FTM | Trockenmasse pro 40 x 40 cm | 0,50 | y = -5,37x + 442,69 | 6.39d | PWG |
| | PFM | Frischmasse pro Pflanze | 0,60 | y = 0,06x + 0,09 | 6.41d | PHL |
| | FFM | Trockenmasse pro 40 x 40 cm | 0,49 | y = 2,91x - 42,28 | 6.41b | PHL |
| HOL | PDML | Stängeldurchmesser (Labor) | 0,50 | y = -3,23x + 9,90 | 6.38c | NHN |
| | PTM | Trockenmasse pro Pflanze | 0,54 | y = -0,14x + 14,04 | 6.40c | PWG |

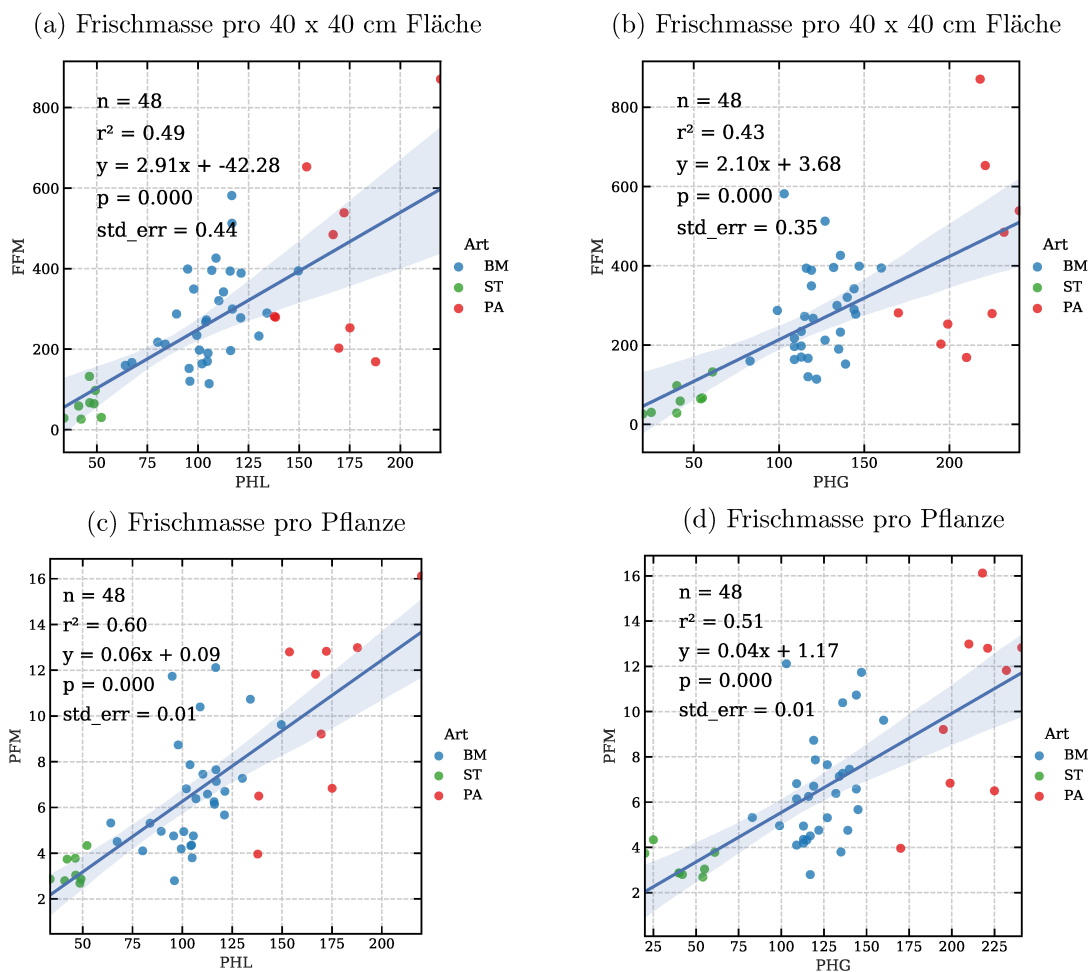


Abbildung 6.41: Regressionen zwischen Pflanzenhöhen und Frischmassen für BAL.

zonen wurde mithilfe des linearen Zusammenhangs zur Geländehöhe für beide Standorte abgeleitet (Abbildung 6.44).

Die Ergebnisse der Vorhersagekarten entsprechen den im Gelände beobachteten und in der Literatur diskutierten Sachverhalten, dass die Stängeldicke mit abnehmendem Abstand zum Wasser zunimmt, was als Anpassung an Wellenschlag interpretiert wird [ENGELS 2010; TEMMERMAN et al. 2013; HEUNER 2016; SILINSKI et al. 2018]. Die jeweiligen Performanzdiagramme stellen die beobachteten bzw. im Gelände gemessenen Werte den final modellierten Werten gegenüber. Da die Ergebnisse der linearen Zusammenhänge zwischen PDML und NHN (BAL und HOL Abbildung 6.37f und 6.38c) jeweils nur ein r^2 von 0,5 erreichten und auch die PLSR ebenfalls statistische Unsicherheiten aufwiesen, sind Anteile der erklärten Varianz für die Vorhersage entsprechend niedrig. Jedoch sind die Regressionen hoch signifikant. Das heißt, dass der erklärte Anteil statistisch abgesichert ist. Bei beiden Standorten werden die hohen Werte überschätzt und die niedrigen unterschätzt.

Ähnliche Ergebnisse mit teilweise höheren Bestimmtheitsmaßen ergeben sich auch für die anderen Parameter. Eine weitere maßgebliche Rolle bei der Modellierung der Wellenreduktion natürlicher Ökosysteme spielt die Biomasse. Dabei sollte die Kombination aus der Frisch- und Trockenmasse und der Anzahl der Stängel auf

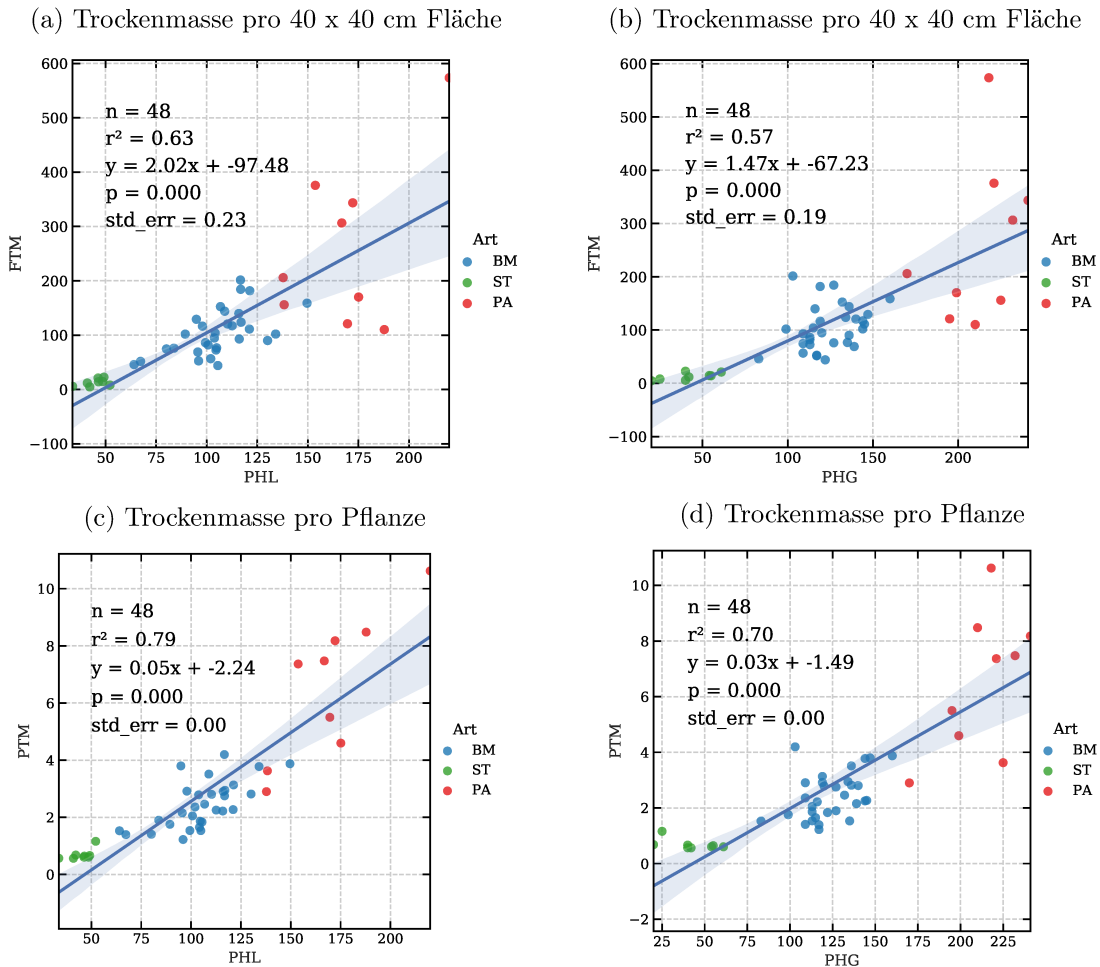


Abbildung 6.42: Regressionen zwischen Pflanzenhöhen und Trockenmassen für BAL.

40 x 40 cm Fläche eine Biomasserhebung und Vorhersage für die gesamte Befliegungsfläche ermöglichen. Da jedoch die Stängelanzahl keine statistisch sicheren Zusammenhänge zu irgendeinem der anderen gemessenen Parameter zeigte, ist auch die Hochrechnung auf die Fläche nur sehr begrenzt möglich. Die durchschnittliche Trockenmasse der Pflanzen an jedem Punkt hatte jedoch einen moderaten Zusammenhang zum Wassergehalt und zur Pflanzenhöhe. Daher wurde zunächst der Wassergehalt der Pflanzen, der für beide Standorte als PLSR-Karte vorlag, genutzt um die Trockenmasse pro Pflanze herzuleiten (Abbildung 6.45). Die Ergebnisse spiegeln die im Gelände gewonnenen Erkenntnisse wider, dass mit steigendem Abstand zum Wasser der Wassergehalt sinkt und die Trockenmasse steigt. Auch hier kommt es wiederum zur Überschätzung von hohen und zur Unterschätzung von niedrigen Werten.

Für BAL konnte auch die Pflanzenhöhe (gemessen im Labor) genutzt werden um die mittlere Trockenmasse pro Pflanze abzuleiten (Abbildung 6.46). Jedoch gibt es *Bolboschoenus maritimus*-Zonen an der Grenze zu *Phragmites australis*, wo sich die Pflanzen gelegt haben. Da diese sich auch auf die Vorhersagekarte der Pflanzenhöhe auswirken, repräsentieren diese Zonen falsche Werte. Daher ist die Vorhersage der Trockenmasse aus dem Wassergehalt der Pflanzen als statistisch robuster einzuschät-

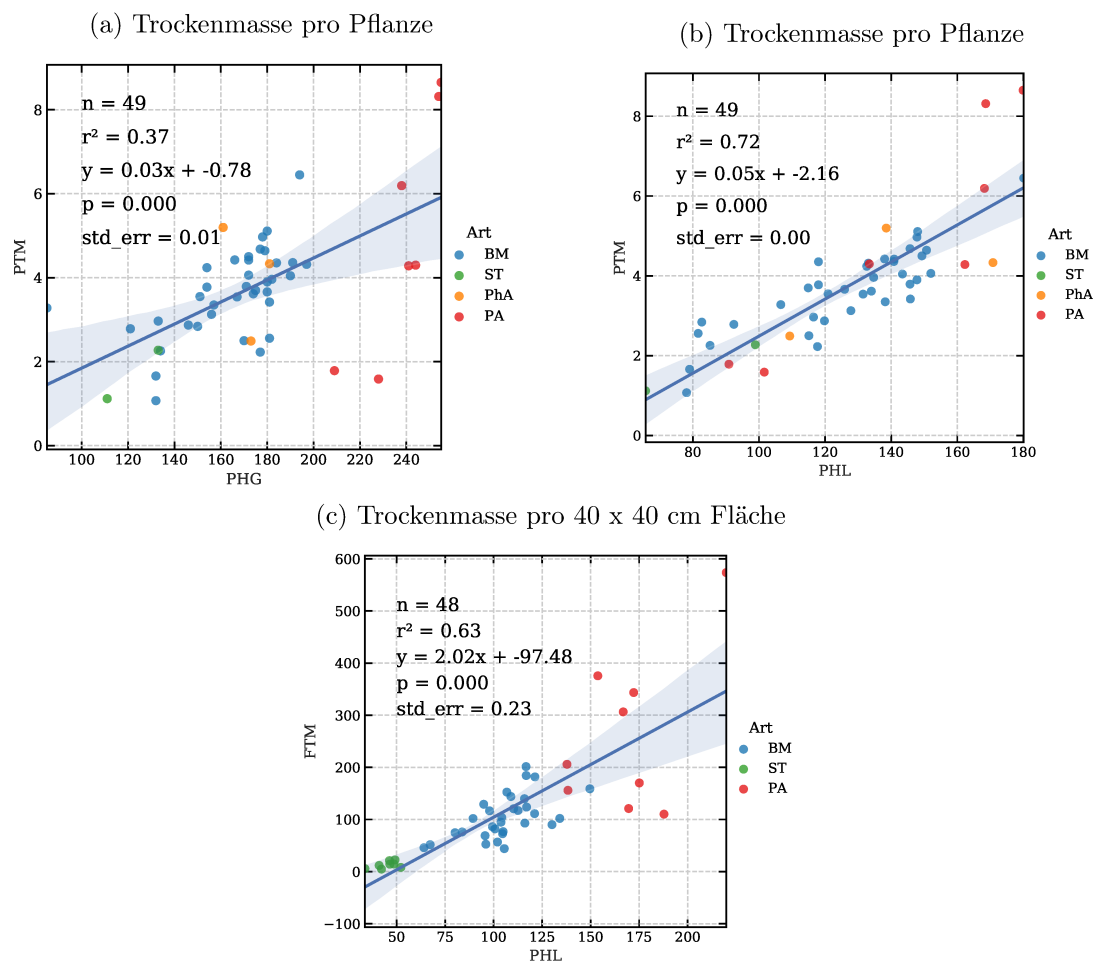


Abbildung 6.43: Regressionen zwischen Pflanzenhöhen und Pflanzenmassen für HOL.

zen. Die Abbildungen 6.47 und 6.48 zeigen weitere Biomassearten für BAL, deren statistische Sicherheiten vergleichbar sind mit den schon vorgestellten Ergebnissen.

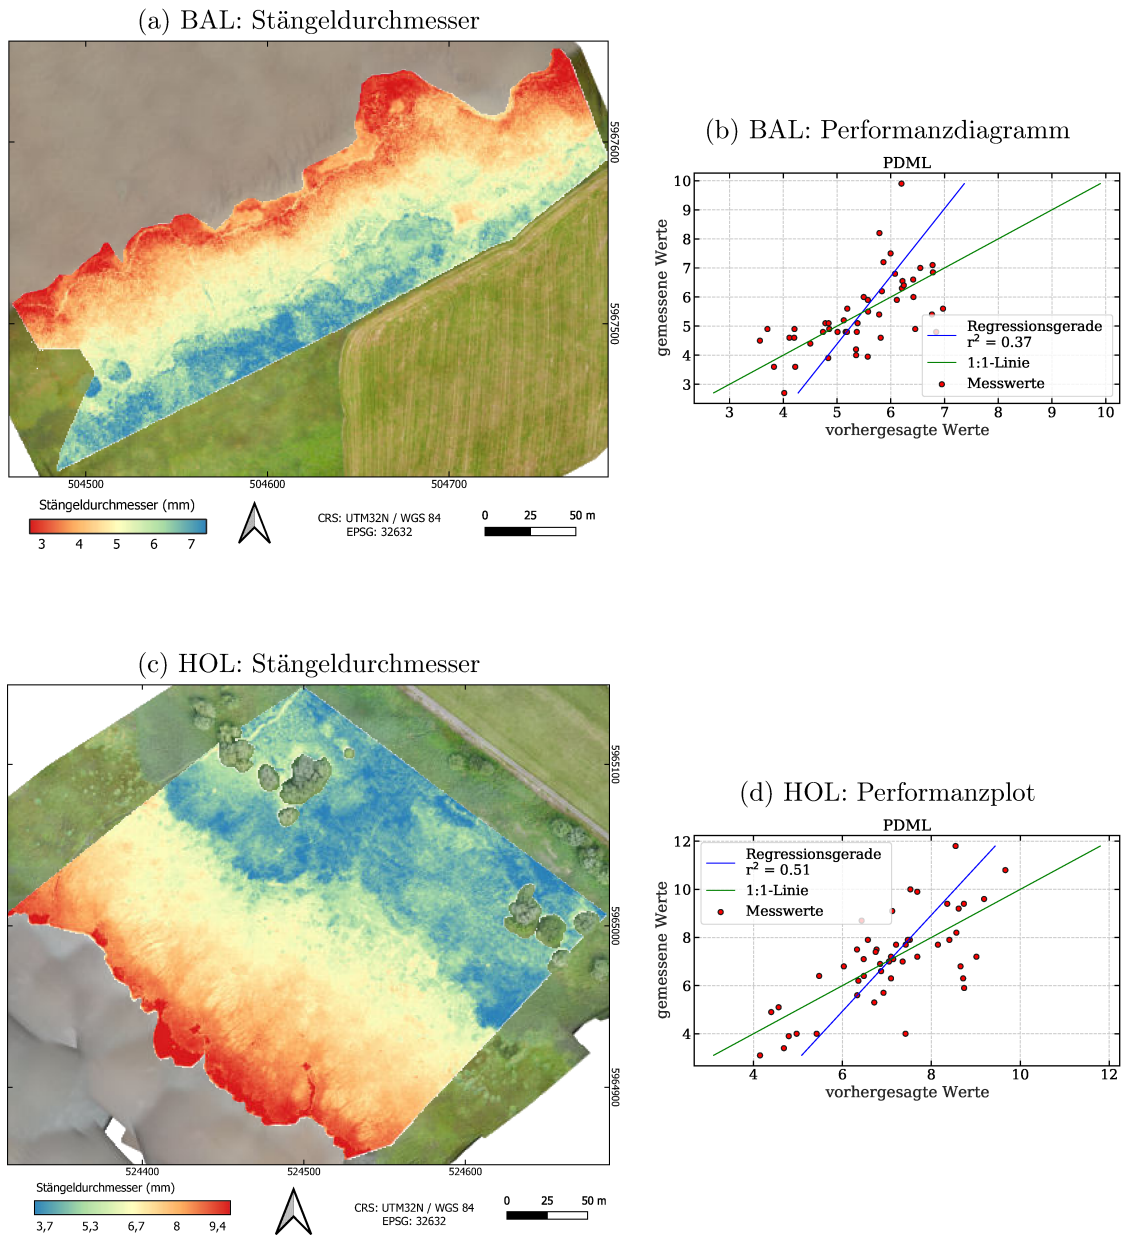


Abbildung 6.44: Ergebnisse der linearen Regression für den Parameter Stängeldurchmesser in mm für BAL und HOL abgeleitet aus der Geländehöhe (PLSR-NHN). (a) und (c) sind die vorhergesagten Karten, (b) und (d) die Performanzdiagramme der jeweiligen Modelle für BAL und HOL.

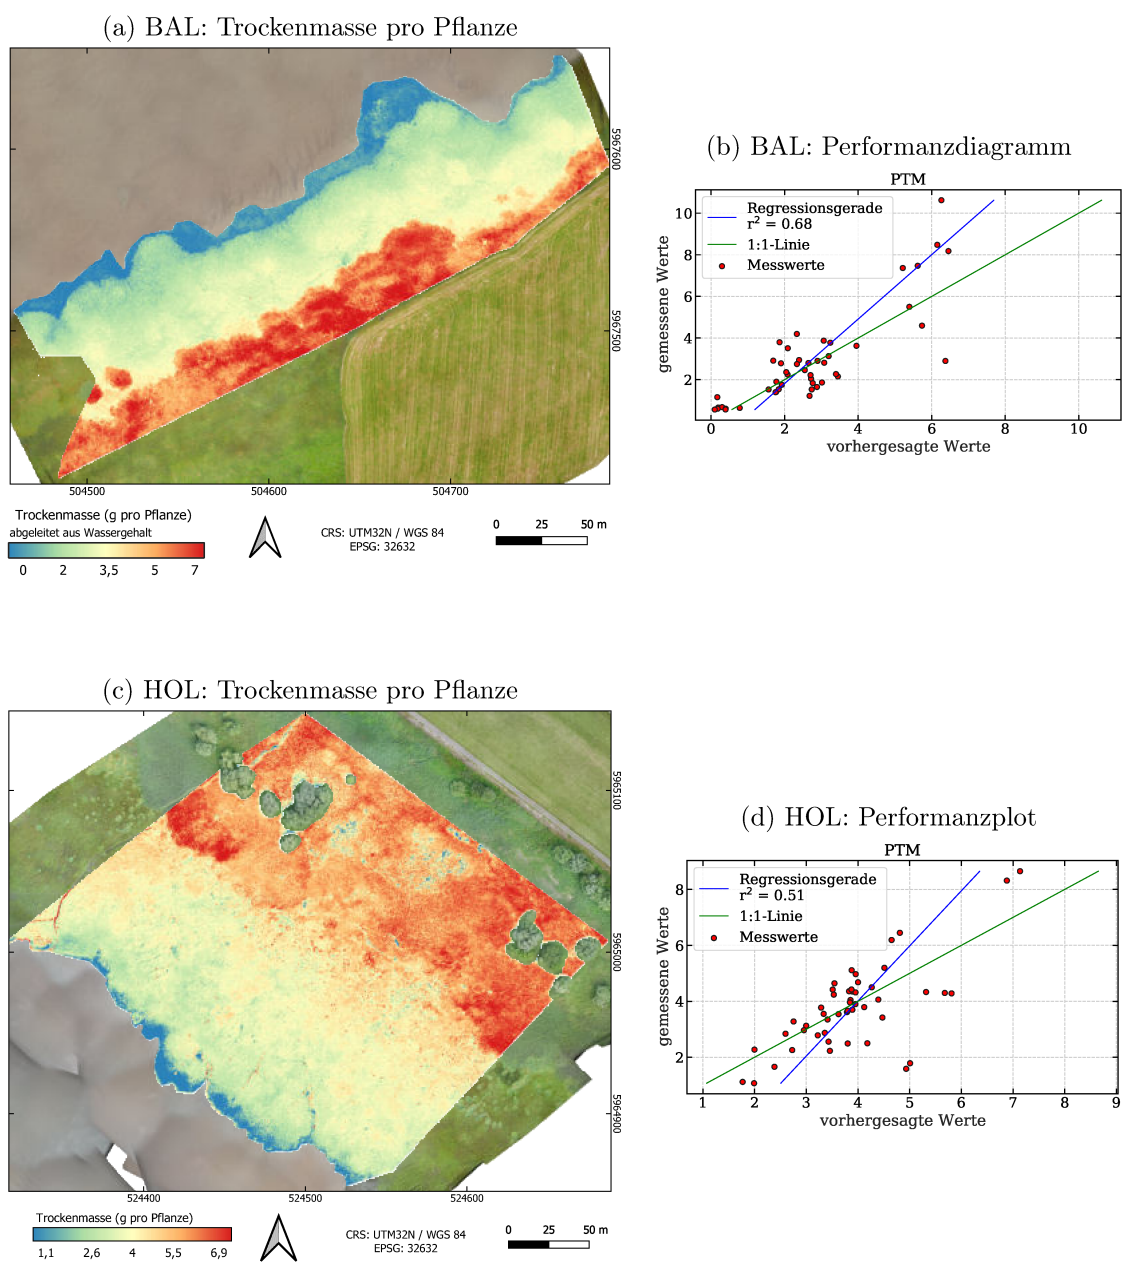


Abbildung 6.45: Ergebnisse der linearen Regression für den Parameter Trockenmasse in g pro Pflanze für BAL und HOL abgeleitet aus dem Wassergehalt (PLSR-PWG). (a) und (c) sind die vorhergesagten Karten, (b) und (d) die Performanzdiagramme der jeweiligen Modelle für BAL und HOL.

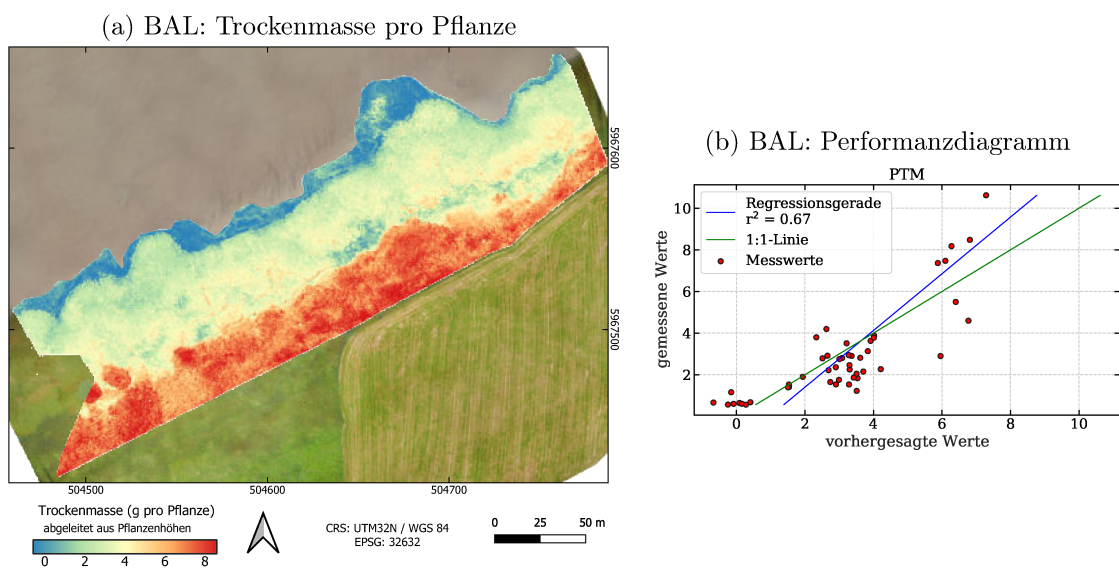


Abbildung 6.46: Ergebnisse der linearen Regression für den Parameter Trockenmasse in g pro Pflanze für BAL und HOL abgeleitet aus der Pflanzenhöhe (PLSR-PHL). (a) ist die vorhergesagte Karte und (b) die Performanz des Modells.

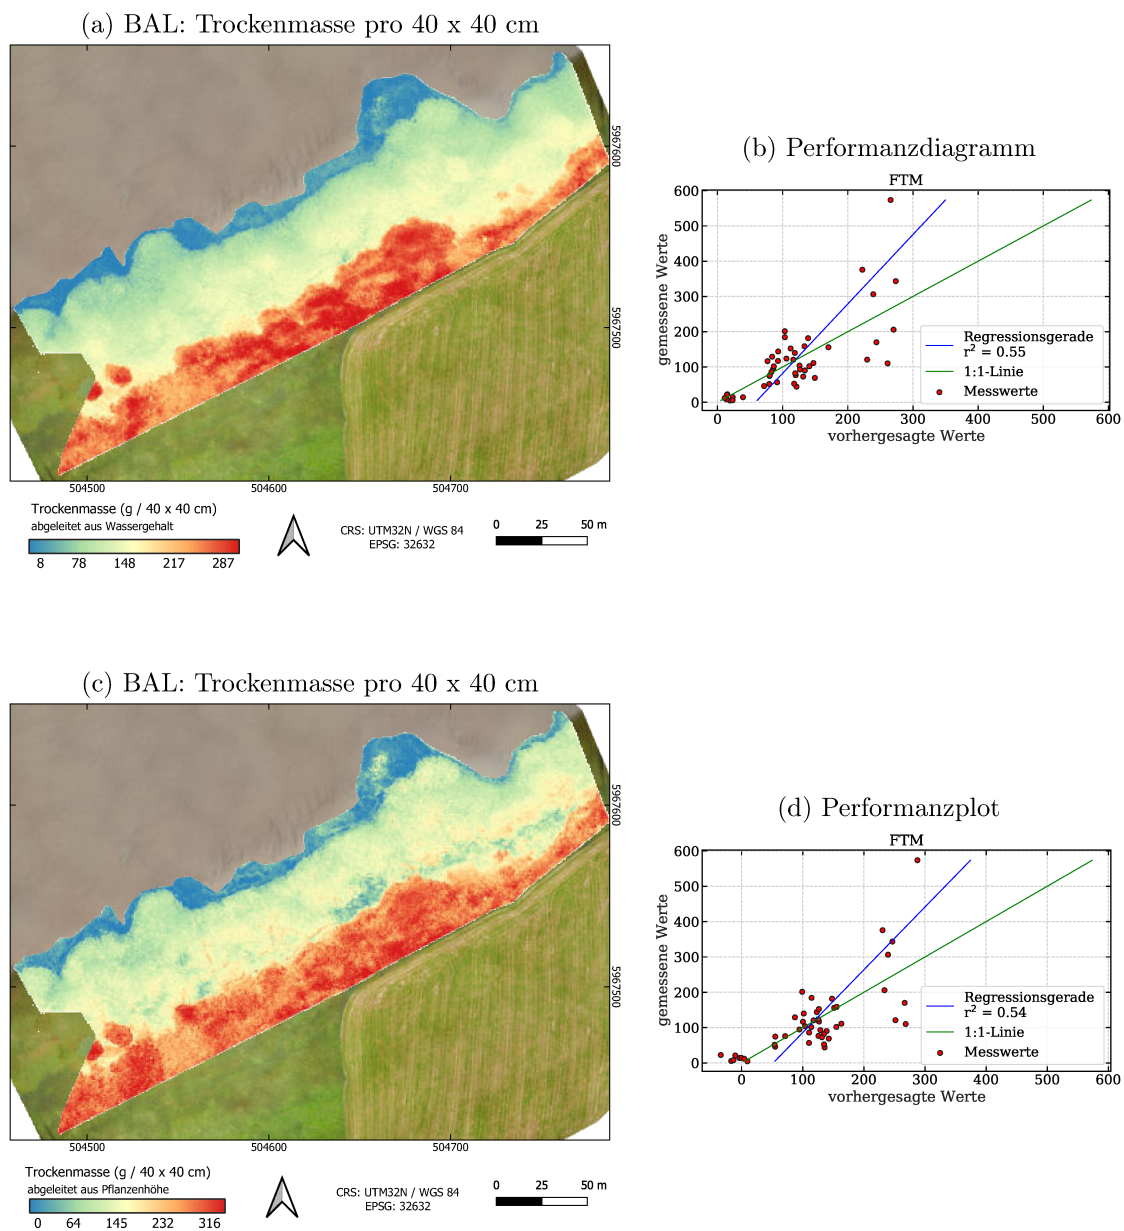


Abbildung 6.47: Ergebnisse der linearen Regression für den Parameter Trockenmasse in g pro 40 x 40 cm für BAL abgeleitet (a) aus dem Wassergehalt (PLSR-PWG) und (c) aus den Pflanzenhöhen (PLSR-PHL). (b) und (d) sind die Performanzdiagramme der Modelle.

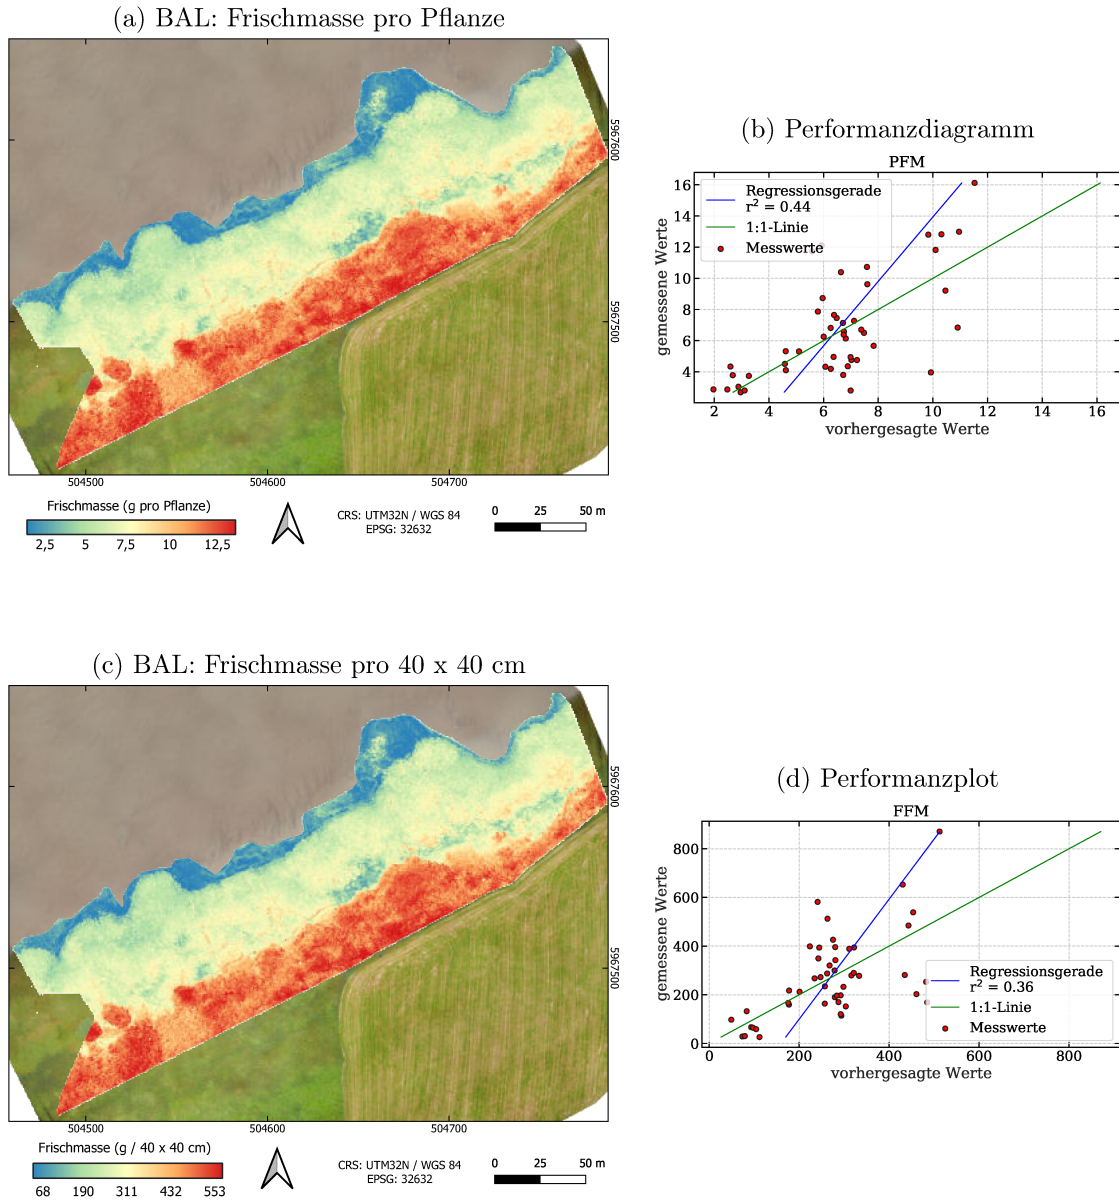


Abbildung 6.48: Ergebnisse der linearen Regression für die Parameter Frischmasse (a) in g pro Pflanze und (c) in g pro 40 x 40 cm für BAL abgeleitet aus der Pflanzenhöhe (PLSR-PHL). (b) und (d) sind die Performanzdiagramme der Modelle.

6.4 Synoptische Auswertung der Kanalrelevanzen

Im Abschnitt 6.2 wurden die Kanalrelevanzen für die Klassifikations- und im Abschnitt 6.3 für die Regressionsergebnisse gezeigt. In diesem Abschnitt werden diese Ergebnisse nochmals gemeinsam gegenübergestellt um eine generelle Ableitung der Relevanz der Kanäle und der Sensoren des erweiterten multisensoralen Ansatzes zu evaluieren. Tabelle 6.23 trägt alle Werte für die Kanalrelevanzen für zehn Untersuchungen (drei Klassifikationen und sieben Regressionen) zusammen. Dabei wurden die PLSR-Ergebnisse für die photosynthetisch aktive Strahlung (PAR) für BAL und HOL aufgrund ihrer statistischen Unsicherheit verworfen. Wenn kein Wert in der Tabelle zu finden ist, wurde der jeweilige Index bzw. das dafür stellvertretende Indexcluster durch das Clusterverfahren nicht selektiert. Tabelle 6.24 ist eine statistische Zusammenfassung der Tabelle 6.23. Sie ist nach dem Mittelwert sortiert.

In dieser zusammenfassenden Betrachtung zeigt sich die Dominanz des DOM für die Relevanz bei den verwendeten Klassifikations- und Regressionsverfahren. Bei den aufsummierten prozentualen Relevanzen ist das DOM um den Faktor 1,8 wichtiger als der zweitwichtigste Kanal. BENDIG et al. [2015] bestätigen in einem landwirtschaftlichen und ZHANG et al. [2015] im urbanen Kontext den hohen Informationsgehalt vom DOM.

An zweiter Position der relevantesten Kanäle folgt der Texturparameter *ene* (*Energy*). Dieser steht bei allen Untersuchungen stellvertretend für ein Cluster bestehend aus den Texturindizes *asm* (*Angular Second Moment*), *ene* (*Energy*), *homo* (*homogeneity*) und *ma* (*Maximum*). Somit stehen an den beiden wichtigsten Stellen zwei Variablen, welche die Geometrie der Vegetationsbestände beschreiben.

Auf den Rängen drei bis neun folgen spektrale Kanäle. Zunächst ist der Index *ndrdi* der drittwichtigste Kanal überhaupt und der wichtigste Spektralindex. Berechnet wird er aus der normalisierten Differenz zwischen der Reflexion des grünen Lichtes (G2 des MS-Sensors) und dem Übergangsbereich zwischen rotem und infraroten Bereich (dem *Red Edge*, RE des MS-Sensors):

$$ndrdi = \frac{(\rho_{RE} - \rho_{G2})}{(\rho_{RE} + \rho_{G2})} \quad (6.5)$$

Dass der Bereich des infraroten Lichtes des elektromagnetischen Spektrums besonders wichtig für die vorliegenden Vegetationsuntersuchungen war, wird auch daran sichtbar, dass die beiden reinen Reflexionskanäle des MS-Sensors RE und NIR an vierter und fünfter Stelle der Relevanz der Kanäle stehen. Auch BEIJMA et al. [2014] bestätigen diesen Sachverhalt bei der Klassifikation von Vegetation in Feuchtgebieten. In ihrer Untersuchung testeten sie zwar die Relevanz von SAR-Daten, die aufgrund ihrer texturalen Information ein hohes Potential haben sollten, kommen aber zu dem Schluss, dass das DOM und multispektrale Indizes den größten Einfluss auf die Klassifikation haben.

Ein weiterer wichtiger Index ist der *tc_yvimss*, generiert aus der *Tasseled Cap Transformation*, an siebenter Stelle, der alle Kanäle des MS-Sensors berücksichtigt und wie folgt transformiert:

$$tc_yvimss = -0,899\rho_{G2} + 0,428\rho_{R2} + 0,076\rho_{RE} - 0,041\rho_{NIR} \quad (6.6)$$

Tabelle 6.23: Kanalrelevanzen (%) zusammengefasst und alphabetisch sortiert nach Kanalname.

| Kanal | Klassifikation | | | Regression | | | BAL | | | |
|-------------|----------------|-------|-------|------------|------|------|------|------|------|------|
| | PW | CDCW | PaW | HOL NHN | PHG | PWG | NHN | PHL | PHG | PWG |
| ari | 3.63 | | | | | | | | | |
| aspect | | | | 1.38 | 1.83 | 2.30 | | | | |
| B1 | 0.43 | 2.50 | 0.22 | 2.02 | 2.53 | 2.65 | 2.32 | 2.20 | 2.32 | 2.16 |
| bri | 0.87 | | 4.16 | 1.77 | 1.72 | 1.63 | 4.27 | 1.68 | 1.07 | 2.14 |
| ccci | 1.28 | 1.44 | 1.85 | 4.87 | 4.62 | 3.19 | 4.89 | 5.61 | 6.53 | 5.25 |
| chlgreen | 1.10 | 1.80 | 0.43 | | | | | | | |
| chlrededge | 0.41 | | | | | | | | | |
| cont | 8.72 | 5.28 | 6.45 | 5.06 | 4.75 | 4.74 | 1.89 | 1.61 | 0.42 | 1.39 |
| cvi | 1.99 | | 2.57 | 4.40 | 4.14 | 4.21 | 3.90 | 3.92 | 3.62 | 3.32 |
| datt1 | | 1.40 | | 5.07 | 5.65 | 5.82 | | | | |
| ddn | | | 2.26 | | | | | | | |
| DOM | 26.69 | 15.06 | 19.15 | 7.94 | 8.23 | 8.21 | 7.14 | 7.31 | 7.70 | 7.50 |
| ene | 10.32 | 9.82 | 4.60 | 5.53 | 5.14 | 3.92 | 4.94 | 5.35 | 5.73 | 5.16 |
| exg | 0.42 | | | | | | | | | |
| G1 | 0.37 | 0.62 | 0.69 | 3.53 | 3.64 | 3.46 | 3.84 | 3.07 | 2.12 | 3.32 |
| G2 | 0.67 | 4.03 | 3.74 | 1.97 | 2.28 | 2.24 | 2.32 | 1.72 | 0.17 | 1.82 |
| gndvi | 1.17 | | | | | | | | | |
| hillshade | | 0.46 | | 2.14 | 3.25 | 2.47 | 3.21 | 3.69 | 3.65 | 3.87 |
| lai | 3.32 | | | | | | | | | |
| mcari_mtvi2 | 4.79 | | | | | | | | | |
| mcari_osavi | | 3.62 | | | | | | | | |
| mean | | | 8.19 | 4.69 | 4.37 | 4.51 | 2.65 | 2.30 | 1.99 | 1.88 |
| msbi | 0.85 | | 3.08 | 5.30 | 4.99 | 4.93 | | | | |
| myvi | 0.93 | 3.82 | 1.08 | | | | 3.06 | 3.20 | 2.37 | 3.61 |
| ndrdi | | 4.56 | 5.32 | 5.12 | 5.10 | 4.86 | 6.14 | 6.44 | 7.29 | 6.58 |
| ndre | 0.43 | 1.99 | 0.71 | | | | | | | |
| ndvi | 3.64 | 3.94 | 3.57 | 2.79 | 2.65 | 3.46 | 4.80 | 5.05 | 5.22 | 5.16 |
| NIR | 1.43 | 7.76 | 2.52 | 6.00 | 4.86 | 5.20 | 6.19 | 6.45 | 7.49 | 6.51 |
| osavi | | | 0.98 | | | | | | | |
| osavi2 | 0.71 | | | | | | | | | |
| R1 | 0.45 | 0.42 | 3.00 | 2.98 | 2.99 | 2.85 | 2.71 | 1.76 | 0.31 | 2.12 |
| R2 | 0.88 | 1.58 | 4.77 | 1.73 | 2.48 | 2.88 | 2.91 | 3.86 | 4.59 | 3.39 |
| RE | 1.19 | 6.78 | 2.17 | 5.24 | 4.20 | 4.75 | 6.13 | 6.33 | 7.29 | 6.37 |
| slope | 0.98 | 2.05 | 0.13 | 2.08 | 3.75 | 3.46 | 2.90 | 3.65 | 3.60 | 3.47 |
| std | 9.22 | 6.48 | | 3.50 | 2.96 | 3.30 | 4.21 | 3.30 | 3.15 | 3.78 |
| tc_yvimss | 2.62 | 2.72 | | | | | 4.88 | 5.66 | 6.68 | 5.29 |
| tcari | 2.79 | 2.69 | 2.85 | 5.17 | 4.07 | 4.56 | 3.82 | 3.22 | 3.08 | 3.49 |
| TH | 4.63 | 6.41 | 7.41 | 3.00 | 3.40 | 3.02 | 3.96 | 4.47 | 4.95 | 4.38 |
| tpi | 0.50 | 0.66 | 0.11 | 1.73 | 1.94 | 2.77 | 2.18 | 2.92 | 2.65 | 2.51 |
| vari | 2.58 | 2.12 | 7.98 | 4.98 | 4.45 | 4.60 | 4.75 | 5.22 | 6.01 | 5.51 |
| Summe | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 |

Tabelle 6.24: Statistische Zusammenfassung der Kanalrelevanzen (%) sortiert nach dem Mittelwert.

| Nr. | Kanal | Anzahl | Summe | Min | MW | STD | Median | Max |
|-----|-------------|--------|--------|------|-------|------|--------|-------|
| 1 | DOM | 10 | 124.92 | 7.14 | 11.49 | 6.69 | 8.07 | 26.69 |
| 2 | ene | 10 | 70.50 | 3.92 | 6.05 | 2.18 | 5.25 | 10.32 |
| 3 | ndrdi | 9 | 60.41 | 4.56 | 5.71 | 0.93 | 5.32 | 7.29 |
| 4 | NIR | 10 | 64.42 | 1.43 | 5.44 | 2.04 | 6.10 | 7.76 |
| 5 | RE | 10 | 60.45 | 1.19 | 5.05 | 2.02 | 5.68 | 7.29 |
| 6 | vari | 10 | 58.22 | 2.12 | 4.82 | 1.65 | 4.87 | 7.98 |
| 7 | tc_yvimss | 6 | 33.86 | 2.62 | 4.64 | 1.64 | 5.09 | 6.68 |
| 8 | TH | 10 | 55.62 | 3.00 | 4.56 | 1.42 | 4.42 | 7.41 |
| 9 | datt1 | 4 | 21.95 | 1.40 | 4.49 | 2.09 | 5.36 | 5.82 |
| 10 | std | 9 | 48.90 | 2.96 | 4.43 | 2.09 | 3.50 | 9.22 |
| 11 | cont | 10 | 50.30 | 0.42 | 4.03 | 2.62 | 4.74 | 8.72 |
| 12 | ndvi | 10 | 50.28 | 2.65 | 4.03 | 0.97 | 3.79 | 5.22 |
| 13 | ccci | 10 | 49.53 | 1.28 | 3.95 | 1.88 | 4.75 | 6.53 |
| 14 | msbi | 5 | 24.15 | 0.85 | 3.83 | 1.88 | 4.93 | 5.30 |
| 15 | mean | 8 | 38.59 | 1.88 | 3.82 | 2.12 | 3.51 | 8.19 |
| 16 | tcari | 10 | 45.75 | 2.69 | 3.58 | 0.83 | 3.36 | 5.17 |
| 17 | cvi | 9 | 41.08 | 1.99 | 3.56 | 0.81 | 3.90 | 4.40 |
| 18 | R2 | 10 | 39.06 | 0.88 | 2.91 | 1.29 | 2.89 | 4.77 |
| 19 | hillshade | 8 | 30.74 | 0.46 | 2.84 | 1.14 | 3.23 | 3.87 |
| 20 | slope | 10 | 36.08 | 0.13 | 2.61 | 1.26 | 3.18 | 3.75 |
| 21 | myvi | 7 | 25.08 | 0.93 | 2.58 | 1.17 | 3.06 | 3.82 |
| 22 | G1 | 10 | 34.66 | 0.37 | 2.47 | 1.40 | 3.20 | 3.84 |
| 23 | bri | 9 | 28.32 | 0.87 | 2.15 | 1.23 | 1.72 | 4.27 |
| 24 | G2 | 10 | 30.96 | 0.17 | 2.10 | 1.18 | 2.11 | 4.03 |
| 25 | R1 | 10 | 29.59 | 0.31 | 1.96 | 1.15 | 2.42 | 3.00 |
| 26 | B1 | 10 | 29.36 | 0.22 | 1.94 | 0.87 | 2.26 | 2.65 |
| 27 | aspect | 3 | 8.50 | 1.38 | 1.83 | 0.46 | 1.83 | 2.30 |
| 28 | tpi | 10 | 27.98 | 0.11 | 1.80 | 1.02 | 2.06 | 2.92 |
| 29 | chlgreen | 3 | 6.33 | 0.43 | 1.11 | 0.69 | 1.10 | 1.80 |
| 30 | ndre | 3 | 6.12 | 0.43 | 1.04 | 0.83 | 0.71 | 1.99 |
| 31 | ari | 1 | 4.63 | | | | | |
| 32 | chlrededge | 1 | 1.41 | | | | | |
| 33 | ddn | 1 | 3.26 | | | | | |
| 34 | exg | 1 | 1.42 | | | | | |
| 35 | gndvi | 1 | 2.17 | | | | | |
| 36 | lai | 1 | 4.32 | | | | | |
| 37 | mcari_mtvi2 | 1 | 5.79 | | | | | |
| 38 | mcari_osavi | 1 | 4.62 | | | | | |
| 39 | osavi | 1 | 1.98 | | | | | |
| 40 | osavi2 | 1 | 1.71 | | | | | |

Der Index wurde eher alleinstehend selektiert oder hatte eine sehr heterogene Zusammensetzung von wenigen anderen Indizes, die wahrscheinlich eher zufällig hoch korrelierten.

Die Spektralindex *vari* ist ein Spektralindex, der aus dem RGB-Daten berechnet wurde:

$$vari = \frac{(\rho_{G1} - \rho_{R1})}{(\rho_{G1} + \rho_{R1} - \rho_{B1})} \quad (6.7)$$

Dieser Index ist in der finalen Auswertung sechstwichtigster Kanal und wurde bei allen Untersuchungen selektiert. Er steht stellvertretend für eher diverse Cluster, wobei neben anderen vor allem der *ngrdi* und der *exg* in diesen Clustern zu finden sind, die ebenfalls aus den RGB-Daten berechnet werden:

$$ngrdi = \frac{(\rho_{G1} - \rho_{R1})}{(\rho_{G1} + \rho_{R1})} \quad (6.8)$$

$$exg = 2\rho_{G1} - (\rho_{R1} + \rho_{B1}) \quad (6.9)$$

Auch die reinen Thermaldaten sind unter den wichtigsten zehn Kanälen auf Platz acht. Dieser Datentyp reiht sich in die gleiche mittlere Relevanz ein wie etwa der *vari* und *tc_yvimss*.

Nach den zehn wichtigsten Kanälen reihen sich zunächst noch zwei weitere Texturindizes (*std*, *cont*) ein. Erst auf Rang zwölf folgt der Spektralindex *ndvi*, der in der fernerkundlichen Fachliteratur der am meisten verwendete Index für Vegetationsanalysen ist. Die weit verbreitete Nutzung dieses Indexes wird unterstrichen durch die Größe des Clusters, dass er bei allen Analysen vertritt. Die Indizes in diesem Cluster können als *Derivate* bezeichnet werden, die jedoch prinzipiell die gleiche Aussagekraft haben. In der vorliegenden Arbeit war das *ndvi*-Cluster bei allen Untersuchungen, außer bei PW, stets das Größte (PW: 11 Indizes, CDCW: 39 Indizes, PaW: 43 Indizes, BAL: 47 Indizes, HOL: 46 Indizes).

7 Zusammenfassung und Ausblick

Die vorliegende Arbeit zeigt den Mehrwert von multisensoralen UAS-Daten gegenüber herkömmlichen Interpolations- und klassischen Fernerkundungsmethoden, um ökologische, flächenhafte Themenkomplexe in Feuchtgebiete klassifikativ und regressiv zu untersuchen. Die zu Beginn aufgeworfenen Fragen wurden untersucht und deren Ergebnisse sollen hier in den folgenden Abschnitten zusammengefasst werden:

1. **Welches Potential hat die Fusion verschiedener Sensoren zu einem multisensoralen UAS-Datensatz für das Monitoring in schützenswerten Feuchtgebieten ...**
 - a) ... bei der Klassifikation von feingliedrigen komplexen Strukturen von Pflanzengesellschaften in Niedermooren?
 - b) ... bei der Regression bzw. Ableitung von Parametern für die Beurteilung der Widerstandsfähigkeit von Pflanzen in tide-beeinflussten Marschländern gegenüber Wellenschlag und Sturmfluten?
2. **Welche Daten bzw. Eingangsvariablen sind die relevantesten für die Beantwortung der vorgestellten Themenkomplexe ...**
 - a) ... hinsichtlich der drei eingesetzten Sensortypen?
 - b) ... hinsichtlich abgeleiteter Produkte aus den Originaldatensätzen der drei Sensoren?
3. **Reichen die Daten eines Sensors aus oder werden erst durch die Fusion verschiedener Datentypen sinnvolle und zufriedenstellende Ergebnisse erreicht?**

7.1 Potential multisensoraler UAS-Daten für das Monitoring in Feuchtgebieten

7.1.1 Klassifikation von Mooren

Der erste Hauptteil der Arbeit befasste sich mit der Klassifikation von Vegetationsbeständen auf wiedervernässten Niedermooren. Dafür wurde ein einfacher multisensoraler Datensatz klassifiziert. Hochauflösende RGB-Daten wurden mit multispektralen und thermalen Daten kombiniert. Darüber hinaus wurden fünf spektrale Indizes sowie das DOM als Indikator für die Pflanzenhöhe genutzt. Zur Klassifizierung des multisensoralen Stacks und zur Analyse der Bedeutung der verschiedenen Variablen wurde ein *Random Forest*-Klassifikator (RF) aus dem maschinellen Lernen eingesetzt. Der RF hat sich als robuster Klassifikator von hochkomplexen Daten erwiesen.

In der Arbeit wurde zunächst der Vegetationsbestand eines wiedervernässten Moores (PW) klassifiziert. Die patch-artige Struktur des Bestandes wurde in der Klassifikation sehr präzise abgebildet. Auch die heterogenen Zonen, in denen nur schwer eine Pflanzenart als dominant festgelegt werden konnte, spiegelte die pixelweise Klassifikation realistisch wider. Für die elf Klassen von PW, darunter allein neun Vegetationsklassen, wurde eine Gesamtgenauigkeit der RF-Klassifikation von beinahe 90 % (OAA = 89,3 %) erreicht. Verglichen mit bisherigen Ergebnissen aus der Literatur und unter Berücksichtigung der Anzahl der Arten, ist diese Qualität des Ergebnisses für eine monotemporale Klassifikation als besonders hochwertig zu erachten. Auch die Einzelklassengenauigkeiten erreichten größtenteils sehr hohe Präzision. Bei zwei Klassen (*Juncus* und *Glyceria*) waren die Einzelgenauigkeiten auf einem eher niedrigen Niveau, was bei deren Anteil an der Gesamtfläche jedoch größtenteils vernachlässigbar ist.

Parallel dazu wurde ein Standort untersucht, an dem eine wiedervernässte Fläche unmittelbar angrenzt an eine noch in Nutzung befindliche entwässerte Fläche. Das Küstenüberflutungsmoor CDCW hat einen eingedeichten und einen ausgedeichten Bereich, welche zusammen in einer Klassifikation behandelt wurden. Die Dichotomie des Standortes kam in der Klassifikation sehr deutlich heraus. Auf diesem Weg ließen sich die Unterschiede schnell und gut erfassen. Die trockenere Seite (CD) war dominiert von *Deschampsia cespitosa*, *Calamagrostis epigejos* und *Juncus effusus*, die episodische überflutete Fläche von *Agrostis stolonifera*, *Festuca rubra* und *Elymus repens*. Wobei *Agrostis stolonifera* auch auf der trockenen Seite auftrat, aber dominant nur in einer feuchteren Senke. *Festuca rubra* und *Elymus repens* schien mikrorelief-bedingt auf höheren und somit etwas trockeneren Bereichen im nassen Bereich dominant aufzutreten. Die Klassifikationsgenauigkeit war auch auf CDCW bei fast 90 % (OAA = 88,3 %). Die Genauigkeiten in der Einzelklassenbetrachtung waren durchgehend hoch. Die beiden Klassifikationen und deren Ergebnisse, sowie Implikationen für die Zukunft wurden veröffentlicht in BEYER et al. [2019b].

Als drittes wurde die Artenzusammensetzung eines Küstenversumpfungsmoores (PaW) klassifiziert. Dieser Standort war stark von der Sommerdürre 2018 betroffen. Daher wurde ein Pre- und Post-Dürrevergleich durchgeführt, um festzustellen, welchen Einfluss dieses Extremereignis auf die Zusammensetzung des Pflanzenbestandes hatte. Als Pre-Dürre-Klassifikation wurde eine Arbeit von KOCH et al. [2017] herangezogen, indem der seit Wiedervernässung quasi-stabile Zustand der Niedermoorfläche untersucht wurde. Die Fläche war ganzjährig überschwemmt mit einem großen Anteil offener Wasserflächen und die Zusammensetzung der Vegetation war stabil dominiert von *Phragmites australis*, *Bolboschoenus maritimus* und *Schoenoplectus tabernaemontani*, sowie sekundär von *Carex acutiformis*, *Carex riparia* und *Juncus effusus*. Die Dürre, beginnend im Frühling 2018, hatte erstmals seit Wiedervernässung zur Folge, dass der Wasserspiegel unter die Geländeoberkante sank. Die Post-Dürre-Klassifikation zeigte, dass die nun trockengefallenen, nicht von Vegetation bewachsenen Flächen komplett von zwei neuen Arten erobert wurden, *Tephroseria palustris* und *Ranunculus sceleratus*. Beide Arten traten vor der Dürre nicht dominant auf. Die Implikationen und eine interpretative Verknüpfung dieses Sachverhaltes mit Treibhausgasemissionen sind veröffentlicht als *Preprint* in BEYER et al. [2020] und befinden sich derzeit in der finalen Bearbeitung zur Veröffentlichung (Stand: 09.11.2020). Die RF-Klassifikation erreichte mit 95,7 % eine sehr präzise

Gesamtgenauigkeit und auch die Einzelqualität der sieben Klassen war, bis auf die Produzentengenauigkeit der Mischklasse Schoeno/Bolbo, bei allen nahezu 100 %.

In einer Zusatzstudie sollte der einfache multisensorale Datensatz um zusätzliche Indizes und Indextypen erweitert werden, um das gesamte fernerkundliche Repertoire auszuschöpfen und somit neue bzw. andere Informationsquellen zu untersuchen. Dafür wurden am Beispiel von PaW 91 weitere Indizes bestehend aus spektralen, Textur- und Reliefindizes berechnet. Da eine sehr große Anzahl dieser Indizes jedoch untereinander hoch-korrelative Zusammenhänge zeigten, wurde eine Variablenselektion auf Basis eines hierarchischen Clusterverfahrens durchgeführt. Das Ergebnis war ein erweiterter multisensoraler Datensatz, der spektrale und geometrische Information miteinander verbindet. Die Klassifikationen wurden dadurch für PaW auf 97,8 % und PW auf 94,4 % verbessert. CDCW blieb die Klassifikationsgenauigkeit auf dem gleichen Niveau, verschlechterte sich jedoch um 0,7 %.

Für den klassifikativen Teil wurde hier anhand von drei Szenarien und Anwendungsbeispielen gezeigt, dass multisensorale UAS-Daten ein großes Potential haben, die Zusammensetzung dominanter Pflanzengesellschaften auf wiedervernässten Niedermooren zu erfassen. Da der Erfolg der Wiedervernässung und die Entwicklung dieses neuen Ökosystems ein langwieriger Prozess ist, der im besten Fall durch ein regelmäßiges Monitoring untersucht werden sollte, sind diese Untersuchungen nur der erste Schritt. Jedoch ist dieser Schritt ein nicht-invasiver, zeitlich wiederholbarer, objektiver und flächenhafter Ansatz, der das sensible und klimarelevante Ökosystem schützt. Die Fernerkundung erhebt nicht den Anspruch, die regelmäßigen Feldbegehungen zu ersetzen. Ein regelmäßiges Neukalibrieren der Trainings- und Validierungsdaten ist wichtig, um eine hohe Qualität der Kartierung zu gewährleisten. Jedoch kann zum einen die Frequenz von invasiven Feldbegehungen gesenkt werden. Zum anderen ist diese Art der Kartierung präziser als der Status quo, wo bspw. für eine amtliche Biotopkartierung gelernte Kartierer aus menschlicher Blickhöhe große Flächen abschätzen oder zeitintensive, punkthafte, botanische Pflanzenzählungen auf große Flächen interpoliert werden müssen.

7.1.2 Regression in Marschen

Der zweite Hauptteil der Arbeit befasste sich mit der Ableitung von Pflanzenparametern aus dem multisensoralen UAS-Datensatzes für zwei Marschland-Ökosysteme im Brackwasserbereich der Tideelbe. Dafür wurde direkt der erweiterte multisensorale Datensatz für beide Standorte (BAL und HOL) so generiert, wie im vorhergehenden Abschnitt beschrieben. Zur Findung eines statistischen Zusammenhangs zwischen den im Gelände und im Labor gemessenen punkthaften Parametern und den fernerkundlichen multiplen Pixelwerten des multisensoralen Datensatzes wurde ein Verfahren aus dem Bereich der ML genutzt, die *Partial Least-Squares Regression* (PLSR). Sie gilt für im Bereich der regressiven Analysen von Fernerkundungsdaten als besonders robust.

Für die beiden Untersuchungsgebiete wurden an jeweils 50 Standorten die Parameter Geländehöhe, Anzahl der Pflanzen auf 0,16 m², mittlere Pflanzenhöhe, mittlerer Stängeldurchmesser, sowie die photosynthetisch aktive Strahlung im Gelände gemessen. Des Weiteren wurden zehn repräsentative Pflanzen randomisiert aus dem

Messrahmen entnommen und im Labor nochmals die mittlere Pflanzhöhe und die mittleren Stängeldurchmesser vermessen und gewogen um die Frisch- und Trockenmasse, sowie den Wassergehalt zu ermitteln. Im Anschluss wurden mittels der PLSR die statistischen Zusammenhänge dieser Parameter zum multisensoralen Datensatz ermittelt. Bei beiden Standorten wurde die gleiche Beziehung identifiziert. Es können mit dieser Herangehensweise statistisch robuste Aussagen über die Geländehöhe, der Pflanzhöhen und den Wassergehalt der Pflanzen des Ökosystem Marsch getroffen werden. Dies ist insofern eine wichtige Erkenntnis, weil in der aktuellen Fachliteratur besonders die Geländehöhe als wesentlicher Treiber des Pflanzenwachstums diskutiert wird und ein wichtiger Indikator für die Dauer und Intensität der tide- und schiffsverkehrsbedingten Wellen ist. Komplementär geben Pflanzhöhe und Wassergehalt Aufschluss über den ökologischen Zustand des Ökosystems. Ein weiterer Parameter, die photosynthetisch aktive Strahlung, wurde zwar auch als statistisch gutes Modell ausgegeben, lieferte aber aufgrund der schnellen Aufsättigung wenig nutzbare Information.

Auf Basis der gefundenen PLSR-Modelle wurden weitere Parameter abgeleitet. In einer statistischen Voruntersuchung wurde dafür ermittelt, welchen linearen Zusammenhang die gemessenen Parameter untereinander haben, um im nächsten Schritt die gefundenen linearen Modelle auf die PLSR-Karten zu übertragen. Hier gab es zwischen beiden Standorten größere Unterschiede. Für BAL konnten fünf Parameter (Stängeldurchmesser aus der Geländehöhe, Trockenmasse pro Pflanze und pro $0,16 \text{ m}^2$ aus Pflanzhöhe oder Wassergehalte und Frischmasse pro Pflanze und pro $0,16 \text{ m}^2$ aus Pflanzhöhe) und für HOL zwei Parameter (Stängeldurchmesser aus der Geländehöhe, Trockenmasse pro Pflanze aus Pflanzhöhe) abgeleitet werden. Allgemein lässt sich festhalten, dass auf beiden Standorten die mittleren Stängeldurchmesser und die mittlere Trockenmasse pro Pflanze abgeleitet werden konnten, dass jedoch die Aussagekraft der Modelle nur moderat ist, durch den indirekten Weg der Ableitung. Die vorgestellten linearen Modelle erklärten zwar nur die Hälfte der erklärten Varianz (r^2 : 0,37–0,68), waren aber alle statistisch hoch signifikant. Nichtsdestotrotz sind die beiden Parameter Stängeldurchmesser und Trockenmasse essentiell, für die Beurteilung des Ökosystems Marsch. Die Stängel der Pflanzen sind an der Marschkante dick und elastisch und werden Richtung Hinterland dünn und plastisch. Diese Muster der Stängeldurchmesser waren in den abgeleiteten Karten sehr gut zu erkennen. Marschland wird wissenschaftlich als eine der Schlüssellösungen natur-basierter Maßnahmen gegen den Klimawandel, Wetterveränderungen und dem steigenden Meeresspiegel diskutiert. Die Trockenmasse des Pflanzenbestandes gestattet eine Aussage über die Dichte des Bestandes und deren Wirkung gegen Wellen und Sturmfluten. Das macht diesen Parameter neben den Stängeldurchmesser und der Geländehöhe zu zentralen Faktoren, um diese Ökosysteme zu untersuchen und den multisensoralen Ansatz zu einer gewinnbringenden Bewertungsmethode für Marschland als natürlichen Küstenschutz.

Natürlich lassen sich diese Regressionsmodelle (vor allem zur Geländehöhe) nicht auf andere Standorte übertragen und müssten für jeden Standort neu modelliert bzw. trainiert werden. Im Vergleich zum Status quo, entsteht jedoch ein eindeutiger Mehrwert für die Nutzung multisensoraler UAS-Daten. Beispielsweise finden jedes Jahr zeit-, personal-, kosten- und flächenintensive Messkampagnen statt um die Tideelbe zu monitoren und deren Entwicklung zu bewerten. Diese Feldbegehun-

gen haben stets einen invasiven Impact auf das Ökosystem. Anstelle dieser Praxis, könnten mit der vorgestellten Methodik an mehreren repräsentativen Dauerbeobachtungsflächen mit trainierten PLSR-Modellen an festen phänologischen Zeitpunkten jedes Jahr nicht-invasive Befliegungen durchgeführt werden um den aktuellen ökologischen Zustand zu erfassen und auszuwerten. Bezugnehmend auf die erste Forschungsfrage, kann konstatiert werden, dass in der Analyse von multisensoralen UAS-Daten ein großes Potential liegt, Feuchtgebiete flächenhaft zu bewerten und deren Entwicklung zeitlich zu überwachen. Vor allem verglichen mit dem Status quo entstehen hier Chancen, den Monitoringprozess arbeits-, zeit- und kostentechnisch zu optimieren.

7.2 Kanal- und Sensorrelevanz der multisensoralen UAS-Daten für das Monitoring in Feuchtgebieten

Neben den ökologisch-anwendungsorientierten Ergebnissen, die im vorherigen Abschnitt zusammengefasst wurden, hatte diese Arbeit noch den zweiten fernerkundlich-methodischen Fokus. Im klassischen Feld der satellitengestützten Fernerkundung in Feuchtgebieten lag bisher der Fokus (siehe Abschnitt 2) hauptsächlich in der Nutzung des optischen Bereiches (sichtbares Licht und kurzwelliges Infrarot). Die Nutzung geometrischer bzw. struktureller und textueller Datentypen sind im Vergleich dazu eher marginal. Sie beschränken sich auf Tests mit SAR-Daten und Texturindizes abgeleitet aus optischen Daten. UAS-Daten bieten hier, neben ihrer sehr hohen räumlichen Auflösung, einen echten Mehrwert, weil sie aufgrund des photogrammetrischen Prozesses neben den klassischen Produkten des optischen Spektrums auch das DOM liefern. Dies war der Ausgangspunkt für die Idee der vorliegenden Arbeit, den tatsächlichen Mehrwert dieses Produktes zu beziffern.

Parallel zu den eigentlichen Ergebnissen, haben die beiden verwendeten Algorithmen (RF und PLSR) den Vorteil, dass sie die Relevanz der Eingangsvariablen, bzw. die Kanäle des multisensoralen Datensatzes, mathematisch bewerten. Beim RF geschieht dies über die Berechnung der Entropie mithilfe des Gini-Index, bei der PLSR wird die *VIP (Average Variable Importance in the Projection)* mithilfe der *Loadings* und *Scores* berechnet. Somit kann in beiden Algorithmen das Differenzierungspotential eines jeden Kanals im multisensoralen Datensatz berechnet werden.

Alle Klassifikationen und Regressionen wurden dieser Relevanzberechnung unterzogen. Die Ergebnisse lieferten ein eindeutiges Ergebnis. Schon bei den ersten drei Klassifikationen mit dem zunächst einfachen multisensoralen Datensatz war eine klare Dominanz des DOM zu erkennen. So hatte in PW das DOM eine Relevanz von fast 40 % zur Unterscheidung der elf Klassen (davon neun Klassen grüne Vegetation). Alle anderen Kanäle waren weit abgeschlagen mit unter 10 %. In PaW sank die Relevanz des DOM zwar um 10 %, war im Vergleich zum nächsten Kanal (Thermalkanal) trotzdem noch um den Faktor drei wichtiger. In CDCW sank der GI nochmals auf 20 % und den Faktor zwei zum zweitwichtigsten Kanal. Die naheliegendste Erklärung dafür ist die Verteilung der verschiedenen Pflanzhöhen innerhalb der Gebiete. So ist die höchste Differenz innerhalb der Arten auf PW zu

finden, wo niedrige *Carex spec.* zusammen auftraten mit höheren *Phragmites australis*-Beständen und noch höheren *Salix Spec.* (Weiden). Auf PaW waren ebenso *Carex spec.* und *Phragmites australis* an beiden Enden des Höhenspektrums zu finden, jedoch keine Baumbestände. Die niedrigsten Höhenunterschiede innerhalb der vorkommenden Pflanzenarten waren auf CDCW zu finden.

Des Weiteren war der Thermalkanal in der Rangordnung der Kanalrelevanzen stets wichtig. So nahm er bei PW und PaW den Platz direkt hinter dem DOM ein, bei CDCW den Dritten. Visuell ist festzustellen, dass höhere Bestände kälter sind als Niedrige. Somit könnte die Interpretation die gleiche sein wie beim DOM, dass diese Daten die Höhenschichtung der Vegetation abbilden. Ein mathematischer Beweis konnte jedoch diesen Sachverhalt nicht bestätigen. Trotzdem ist davon auszugehen, dass dieser Zusammenhang ansatzweise vorhanden ist und der niedrigere Informationsgehalt eher durch die niedrige Qualität der Thermaldaten selbst zu erklären ist. Der langwellige infrarote Bereich ist geprägt von niedriger Energie und die Herausforderung für die Sensoren ist noch größer (als im optischen Bereich), das eigentliche Signal vom Rauschen zu trennen [MEMIS 2007]. Daher ist anzunehmen, dass es einen Zusammenhang zwischen Pflanzenhöhe und Oberflächentemperatur von Pflanzenbeständen gibt, der jedoch gedämpft wird, vom niedrigen Signal-Rausch-Verhältnis der Thermalkamera.

Nach dem DOM und den Thermaldaten kommen die klassischen Fernerkundungskanäle, die in der Literatur schon breit diskutiert wurden und die auch in der vorliegenden Arbeit zeigten, dass der spektrale Bereich des Nahen Infrarots unverzichtbar ist für Vegetationsanalysen. So zeigten die Ergebnisse, dass die Infrarotkanäle und Indizes, die aus diesem Bereich berechnet werden, die höchsten Relevanzen besitzen. Die Informationen aus dem sichtbaren Bereich waren die Kanäle mit den niedrigsten Relevanzen. Dies änderte sich jedoch ein wenig, wenn der Pflanzenbestand sich schon in einer seneszenten Phase befand, was für große Teile in PaW galt. Aufgrund fehlender photosynthetischer Aktivität war hier zu erkennen, dass daraufhin Farbunterschiede im sichtbaren Bereich an Relevanz gewinnen.

Die Einzelkanalbetrachtung ist zwar wichtig, um die einzelnen Datentypen und Spektralbereich zu untersuchen, jedoch werden diese Kanäle nicht von einzelnen Sensoren, bzw. Kamerasystemen aufgenommen. Daher wurden die Einzelkanalrelevanzen auch sensorweise kumuliert, um einen Überblick zu erhalten, welcher Sensor den höchsten Informationsgehalt besitzt. Da das DOM theoretisch aus allen drei Sensoren generiert werden könnte, wurde es weiterhin als Einzelkanal behandelt. Bei PW war das DOM weiterhin der wichtigste Datentyp, dicht gefolgt von den Multispektraldaten, die sich aus den reinen Kanälen und vier Spektralindizes zusammensetzen. Bei CDCW und PaW änderte sich die Reihenfolge. An diesen Standorten stieg die Relevanz des Multispektralsensors deutlich über die des DOM um den Faktor 1,5 bis 2. Die Relevanz des RGB-Sensors und der Thermalkamera sanken deutlich.

Diese ersten Erkenntnisse sollten durch die Erweiterung des multisensoralen Datensatzes ausgebaut werden, indem weitere 74 Spektral-, neun Textur- und acht Reliefindizes in die Analysen einfließen. Durch eine dekorrelative Clusteranalyse wurde dieser Datensatz jedoch noch ausgedünnt, sodass die finalen erweiterten Datensätze aus 25 bis 32 Kanälen bestanden. Ab hier wurden auch die Marschlandregressionen mit der PLSR und der damit zusammenhängenden *VIP*-Kanalrelevanzen berechnet.

Die erste zentrale Erkenntnis dieser Erweiterung war, dass das DOM weiterhin wichtigster Kanal bleibt. Nicht nur in den Klassifikationen mit dem RF, sondern auch mit einer mathematisch diametral anderen Methode, der PLSR. Bei den Klassifikationen sind die DOMs weiterhin mindestens um den Faktor 2 wichtiger als folgende Kanäle. Bei den Regressionen war der Unterschied zu den Folgerängen kleiner.

Neben dieser Bestätigung zeigte die Erweiterung des multisensoralen Datensatzes noch weitere neue Erkenntnisse. Bei den Klassifikationen schoben sich interessanterweise die Textur-Indizes als weitere geometrische Informationsquelle zwischen das DOM und die Thermaldaten, die auch bei den Regressionen eine wichtige Rolle spielten. Die hohe Auflösung der UAS-Daten gestattet also, Pflanzenbestände auch nach ihrer Oberflächenrauigkeit zu beurteilen. Bei allen Untersuchungen hatten die Reliefindizes einen nur sehr schwachen bis keinen Informationsgehalt. Des Weiteren wurden Infrarotindizes als wichtiger identifiziert als der wissenschaftshistorisch am meisten genutzte und älteste Vegetationindex, dem NDVI. Dazu zählt beispielsweise ein Index, der grünes Licht und den *Red Edge* in Beziehung setzt (*ndrdi*). Außerdem wurde ein Index der *Tasseled Cap Transformation* als wichtiger identifiziert, der alle Kanäle des multispektralen Sensors berücksichtigt.

7.3 Synergieeffekte durch Sensorfusion, zentrale Erkenntnisse der Arbeit und Ausblicke

Die letzten Abschnitte zusammenfassend, kann konstatiert werden, dass multisensorale UAS-Daten in der Fernerkundung eine neue Maßstabebene erschließen. Diese Ebene repräsentiert die Transitionszone zwischen der einzelnen Pflanze zur Bestandesebene. Sie schließt die Lücke zwischen der Feldbegehung und der Satellitenebene, zwischen Ökologie und Fernerkundung. KNOTH et al. [2013] haben Folgendes schon früh erkannt, was nicht nur für Moore und Marschen, sondern für alle schwer begeharen oder sensiblen Ökosysteme gilt:

By addressing the limitations of conventional remote sensing approaches, UAV platforms may bridge the gap between the need for an accurate means of monitoring species composition changes and vegetation structure in restored peatlands, and the considerable effort required for field surveys.

(UAS-Daten können die Grenzen herkömmlicher Fernerkundungsansätze überwinden und so die Lücke zwischen dem Bedarf an präzisen Verfahren zum Monitoring von Veränderungen der Artenzusammensetzung und der Vegetationsstruktur in wiedervernässten Mooren und dem beträchtlichen Aufwand für Feldkampagnen schließen.)

Der photogrammetrische Prozess schafft dabei einen tatsächlichen Mehrwert, weil so ein neuer Typ von Datensatz die Analyse komplettiert. Für die Beantwortung ökologischer, vegetationsorientierter Fragestellungen spielt die geometrische bzw. strukturelle Information eine zentrale Rolle, was in der vorliegenden Arbeit anhand des

DOM und der Textur des Pflanzenbestandes gezeigt wurde. Der hohe Informationsgehalt dieser Geometrie kann jedoch erst im Zusammenspiel mit Infrarot-Daten des Multispektralsensors gewinnbringend eingesetzt werden. Daher ist auch die Fusion dieser Datentypen eine der wesentlichen Erkenntnisse dieser Arbeit.

Die Arbeit zeigt einen Weg, wie ein zukünftiges Monitoring sensibler, klimarelevanter Ökosysteme nicht-invasiv, objektiv, automatisierbar, sowie zeit- und kostenoptimiert durchgeführt werden kann.

Dabei können zukünftig noch eine Vielzahl weiterer Potentialtests und Forschungsfragen beantwortet werden. Dazu zählen weitere Eingangsvariablen, die noch getestet werden könnten, wie beispielsweise der *Topographic Wetness Index* [SØRENSEN et al. 2006] oder Transformationsansätze wie der *Principal Component Analysis* [ESTORNELL et al. 2013]. Des Weiteren wurde ein sehr entscheidender Faktor bzw. Parameter in der vorliegenden Arbeit nicht berücksichtigt, die Zeit. Multitemporale Analysen verbessern Ergebnisse durch die Berücksichtigung unterschiedlicher phänologischer Verläufe der unterschiedlichen Pflanzenarten auf den Flächen, was in einer Nebenstudie von BEYER et al. [2019a] gezeigt werden konnte. Dabei verbessert die Phänologie nicht nur die Ergebnisse, sondern eröffnet auch weitere neue interessante Fragestellungen, wie die Suche nach dem besten Zeitpunkt einer fernerkundlichen Befliegung.

Weiterhin kommen ständig neue Sensoren und Sensorideen auf den Markt, die neue Möglichkeiten eröffnen. So entwickelt die amerikanische Firma *Headwall* derzeit eine Multisensordrohne, die einen hyperspektralen Zeilenscanner mit einem LIDAR-Sensor kombiniert, um erstens spektrale und geometrische Informationen zu verknüpfen und zum zweiten die komplexe Vorprozessierung von hyperspektralen Daten mithilfe des Laserscanners zu erleichtern [HEADWALL 2020]. Die deutsche Firma *Quantum-Systems* hat einen großen Starrflügler (Trinity F90+) entwickelt, der ein duales multispektrales Kamerasystem der Firma *Micasense* tragen kann, welches in der Lage ist die Kanaleigenschaften des VNIR-Bereiches von Sentinel-2 oder Landsat-8 zu simulieren [MICASENSE 2020; QUANTUM-SYSTEMS 2020]. Werden auf der Maßstabsebene des UAS ökologische Monitoringverfahren entwickelt, entstehen hier Möglichkeiten die gefundenen Erkenntnisse auf die entsprechende Satellitenebene hoch zu skalieren. Mit einer standardisierten und abstrahierenden Herangehensweise könnten so Ergebnisse von einem Untersuchungsgebiet mit all seinen geografischen Eigenschaften auf andere Ökosysteme gleicher Eigenschaften übertragen werden.

Literatur

- ABDI, A. M. (2019). “Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data”. In: *GIScience & Remote Sensing*, S. 1–20. ISSN: 1548-1603. DOI: 10.1080/15481603.2019.1650447.
- ABEL, S., A. BARTHELMES, G. GAUDIG, H. JOOSTEN, A. NORDT und J. PETERS (2019). *Klimaschutz auf Moorböden. Lösungsansätze und Best-Practice-Beispiele*. Techn. Ber. Greifswald: Greifswald Moor Centrum.
- ADAM, E., O. MUTANGA und D. RUGEGE (2010). “Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review”. In: *Wetlands Ecology and Management* 18.3, S. 281–296. ISSN: 0923-4861. DOI: 10.1007/s11273-009-9169-z.
- ADOLPH, W., H. FARKE, S. LEHNER und M. EHLERS (2018). “Remote Sensing Intertidal Flats with TerraSAR-X. A SAR Perspective of the Structural Elements of a Tidal Basin for Monitoring the Wadden Sea”. In: *Remote Sensing* 10.7, S. 1085. ISSN: 2072-4292. DOI: 10.3390/rs10071085.
- AHRENDTS, H., S. ETZOLD, W. KUTSCH, R. STOECKLI, R. BRUEGGER, F. JEANNERET, H. WANNER, N. BUCHMANN und W. EUGSTER (2009). “Tree phenology and carbon dioxide fluxes: use of digital photography for process-based interpretation at the ecosystem scale”. In: *Climate Research* 39, S. 261–274. ISSN: 0936-577X. DOI: 10.3354/cr00811.
- AKUMU, C. E. und J. W. MCLAUGHLIN (2014). “Modeling peatland carbon stock in a delineated portion of the Nayshkootayaow river watershed in Far North, Ontario using an integrated GIS and remote sensing approach”. In: *Catena* 121, S. 297–306. ISSN: 03418162. DOI: 10.1016/j.catena.2014.05.025.
- ALLER, R. C., C. HEILBRUN, C. PANZECA, Z. ZHU und F. BALTZER (2004). “Coupling between sedimentary dynamics, early diagenetic processes, and biogeochemical cycling in the Amazon–Guianas mobile mud belt: coastal French Guiana”. In: *Marine Geology* 208.2-4, S. 331–360. ISSN: 00253227. DOI: 10.1016/j.margeo.2004.04.027.
- ALRUBAIEA, S. A. H. und A. H. HAMEED (2018). “Dynamic Weights Equations for Converting Grayscale Image to RGB Image”. In: *Journal of University of Babylon for Pure and Applied Sciences* 26.8, S. 122–129. URL: <https://journalofbabylon.com/index.php/JUBPAS/article/view/1677/1332>.
- AMANI, M., B. SALEHI, S. MAHDAVI und B. BRISCO (2018). “Spectral analysis of wetlands using multi-source optical satellite imagery”. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 144, S. 119–136. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2018.07.005.
- ARCHER, K. J. und R. V. KIMES (2008). “Empirical characterization of random forest variable importance measures”. In: *Computational Statistics & Data Analysis* 52.4, S. 2249–2260. ISSN: 01679473. DOI: 10.1016/j.csda.2007.08.015.

- ARROYO-MORA, J., M. KALACSKA, R. SOFFER, G. IFIMOV, G. LEBLANC, E. SCHAAF und O. LUCANUS (2018). "Evaluation of phenospectral dynamics with Sentinel-2A using a bottom-up approach in a northern ombrotrophic peatland". In: *Remote Sensing of Environment* 216, S. 544–560. ISSN: 00344257. DOI: 10.1016/j.rse.2018.07.021.
- BABOO, S. S. und M. R. DEVI (2010). "An Analysis of Different Resampling Methods in Coimbatore, District". In: *Global Journal of Computer Science and Technology* 10.15, S. 61–66. URL: https://globaljournals.org/GJCST_Volume10/10-An-Analysis-of-Different-Resampling-Methods-in-Coimbatore-District.pdf.
- BECKER, B. L., D. P. LUSCH und J. QI (2007). "A classification-based assessment of the optimal spectral and spatial resolutions for Great Lakes coastal wetland imagery". In: *Remote Sensing of Environment* 108.1, S. 111–120. ISSN: 00344257. DOI: 10.1016/j.rse.2006.11.005.
- BEHRE, K. E., H. KLIEWE und K. SCHWARZER (2002). "Die Küsten Deutschlands". In: *Physische Geographie Deutschlands*. Hrsg. von H. LIEDTKE und J. MARCINEK. 3. Gotha und Stuttgart: Klett-Perthes. Kap. 7, S. 323–384. ISBN: 978-3623008608.
- BEIJMA, S. van, A. COMBER und A. LAMB (2014). "Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data". In: *Remote Sensing of Environment* 149, S. 118–129. ISSN: 00344257. DOI: 10.1016/j.rse.2014.04.010.
- BENDIG, J., K. YU, H. AASEN, A. BOLTEN, S. BENNERTZ, J. BROSCHEIT, M. L. GNYP und G. BARETH (2015). "Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley". In: *International Journal of Applied Earth Observation and Geoinformation* 39, S. 79–87. ISSN: 03032434. DOI: 10.1016/j.jag.2015.02.012.
- BERHANE, T. M., C. R. LANE, Q. WU, O. A. ANENKHONOV, V. V. CHEPINOVA, B. C. AUTREY und H. LIU (2018). "Comparing pixel- and object-based approaches in effectively classifying wetland-dominated landscapes". In: *Remote Sensing* 10.1, S. 46. ISSN: 20724292. DOI: 10.3390/rs10010046.
- BERLANGA-ROBLES, C. A. und A. RUIZ-LUNA (2002). "Land Use Mapping and Change Detection in the Coastal Zone of Northwest Mexico Using Remote Sensing Techniques". In: *Journal of Coastal Research* 18.3, S. 514–522. URL: <https://www.jstor.org/stable/4299098?seq=1>.
- BEYER, F., A. STEIGER und G. GRENZDÖRFFER (2019a). "Multitemporale Auswertung von Moor-Vegetationsgesellschaften unter Verwendung von multisensoralen UAS-Daten". In: *gis.Science* 4, S. 119–132.
- BEYER, F., F. JANSEN, G. JURASINSKI, M. KOCH, B. SCHRÖDER und F. KOEBSCH (2020). "Drought years in peatland rewetting: Rapid vegetation succession can maintain the net CO₂ sink function". In: *Biogeosciences Preprint*. DOI: 10.5194/bg-2020-215.
- BEYER, F., T. JARMER und B. SIEGMANN (2015a). "Identification of Agricultural Crop Types in Northern Israel using Multitemporal RapidEye Data". In: *Photogrammetrie - Fernerkundung - Geoinformation* 2015.1, S. 21–32. DOI: 10.1127/pfg/2015/0249.
- BEYER, F., T. JARMER, B. SIEGMANN und P. FISCHER (2015b). "Improved crop classification using multitemporal RapidEye data". In: *2015 8th International*

- Workshop on the Analysis of Multitemporal Remote Sensing Images (Multi-Temp)*. IEEE Xplore. DOI: 10.1109/multi-temp.2015.7245780.
- BEYER, F., G. JURASINSKI, J. COUWENBERG und G. GRENZDÖRFFER (2019b). “Multisensor data to derive peatland vegetation communities using a fixed-wing unmanned aerial vehicle”. In: *International Journal of Remote Sensing* 00.00, S. 1–23. ISSN: 0143-1161. DOI: 10.1080/01431161.2019.1580825.
- BFG (2018). *Die Ufer der Tideelbe im Wechselspiel von Mensch und Umwelt. Vegetation, Boden und deren Ökosystemleistungen*. Techn. Ber. DOI: 10.5675/BfG{_}Tideelbe{_}ElbService{_}tibass.
- BONN, A., T. ALLOTT, M. EVANS, H. JOOSTEN und R. STONEMAN, Hrsg. (2016). *Peatland Restoration and Ecosystem Services*. Cambridge: Cambridge University Press. ISBN: 9781139177788. DOI: 10.1017/CB09781139177788.
- BOSSIO, D. A., S. C. COOK-PATTON, P. W. ELLIS, J. FARGIONE, J. SANDERMAN, P. SMITH, S. WOOD, R. J. ZOMER, M. von UNGER, I. M. EMMER und B. W. GRISCOM (2020). “The role of soil carbon in natural climate solutions”. In: *Nature Sustainability* 3.5, S. 391–398. ISSN: 2398-9629. DOI: 10.1038/s41893-020-0491-z.
- BOUMA, T. J., M. B. DE VRIES, E. LOW, G. PERALTA, I. C. TÁNCZOS, J. van de KOPPEL und P. M. J. HERMAN (2005). “TRADE-OFFS RELATED TO ECOSYSTEM ENGINEERING: A CASE STUDY ON STIFFNESS OF EMERGING MACROPHYTES”. In: *Ecology* 86.8, S. 2187–2199. ISSN: 0012-9658. DOI: 10.1890/04-1588.
- BREIMAN, L. (1984). *Classification and Regression Trees (Wadsworth Statistics/Probability)*. Chapman und Hall/CRC. ISBN: 978-0412048418.
- BREIMAN, L. (1996). “Bagging Predictors”. In: *Machine Learning* 24.2, S. 123–140. DOI: 10.1023/A:1018054314350.
- BREIMAN, L. (2001). “Random Forests”. In: *Machine Learning* 45.1, S. 5–32. ISSN: 1573-0565. DOI: 10.1023/A:1010933404324.
- BROUSSARD, W. P., J. M. VISSER und R. P. BROOKS (2020). “Quantifying Vegetation and Landscape Metrics with Hyperspatial Unmanned Aircraft System Imagery in a Coastal Oligohaline Marsh”. In: *Estuaries and Coasts*. ISSN: 1559-2723. DOI: 10.1007/s12237-020-00828-8.
- BROWN, L. A., J. DASH, B. O. OGUTU und A. D. RICHARDSON (2017). “On the relationship between continuous measures of canopy greenness derived using near-surface remote sensing and satellite-derived vegetation products”. In: *Agricultural and Forest Meteorology* 247.August, S. 280–292. ISSN: 01681923. DOI: 10.1016/j.agrformet.2017.08.012.
- BUBIER, J. L., T. R. MOORE, L. BELLISARIO, N. T. COMER und P. M. CRILL (1995). “Ecological controls on methane emissions from a Northern Peatland Complex in the zone of discontinuous permafrost, Manitoba, Canada”. In: *Global Biogeochemical Cycles* 9.4, S. 455–470. ISSN: 08866236. DOI: 10.1029/95GB02379.
- BUBIER, J. L., B. N. ROCK und P. M. CRILL (1997). “Spectral reflectance measurements of boreal wetland and forest mosses”. In: *Journal of Geophysical Research: Atmospheres* 102.D24, S. 29483–29494. ISSN: 01480227. DOI: 10.1029/97JD02316.
- BUDD, J. T. C. und E. J. MILTON (1982). “Remote sensing of salt marsh vegetation in the first four proposed Thematic Mapper bands”. In: *International*

- Journal of Remote Sensing* 3.2, S. 147–161. ISSN: 0143-1161. DOI: 10.1080/01431168208948388.
- BUNDESAMT FÜR KARTOGRAPHIE UND GEODÄSIE (2020). *Digitales Landschaftsmodell 1:250 000 (Ebenen) (DLM250)*. URL: <https://gdz.bkg.bund.de/index.php/default/digitales-landschaftsmodell-1-250-000-ebenen-dlm250-ebenen.html>.
- BUTCHART, S. H. M., M. WALPOLE, B. COLLEN, A. van STRIEN, J. P. W. SCHARLEMANN, R. E. A. ALMOND, J. E. M. BAILLIE, B. BOMHARD, C. BROWN, J. BRUNO, K. E. CARPENTER, G. M. CARR, J. CHANSON, A. M. CHENERY, J. CSIRKE, N. C. DAVIDSON, F. DENTENER, M. FOSTER, A. GALLI, J. N. GALLOWAY, P. GENOVESI, R. D. GREGORY, M. HOCKINGS, V. KAPOS, J.-F. LAMARQUE, F. LEVERINGTON, J. LOH, M. A. MCGEOCH, L. MCRAE, A. MINASYAN, M. H. MORCILLO, T. E. E. OLDFIELD, D. PAULY, S. QUADER, C. REVENGA, J. R. SAUER, B. SKOLNIK, D. SPEAR, D. STANWELL-SMITH, S. N. STUART, A. SYMES, M. TIERNEY, T. D. TYRRELL, J.-C. VIE und R. WATSON (2010). “Global Biodiversity: Indicators of Recent Declines”. In: *Science* 328.5982, S. 1164–1168. ISSN: 0036-8075. DOI: 10.1126/science.1187512.
- BYRNE, K. A., B. CHOJNICKI, T. R. CHRISTENSEN, M. DROSLER, S. FROLKING, A. LINDROTH, J. MAILHAMMER, N. MALMER, P. SELIN, J. TURUNEN, R. VALENTINI und L. ZETTERBERG (2004). *EU peatlands: Current carbon stocks and trace gas fluxes*. Techn. Ber. Geosphere-Biosphere Centre, University of Lund, S. 1–58. URL: https://scholars.unh.edu/earthsci_facpub/490/.
- CAO, R., Y. CHEN, X. WU, Q. ZHOU und S. SUN (2018). “The effect of drainage on CO₂, CH₄ and N₂O emissions in the Zoige peatland: a 40-month in situ study”. In: *Mires and Peat* 21.2018/10, S. 1–15. DOI: 10.19189/MaP.2017.OMB.292.
- CARLSON, T. N. und D. A. RIPLEY (1997). “On the relation between NDVI, fractional vegetation cover, and leaf area index”. In: *Remote Sensing of Environment* 62.3, S. 241–252. ISSN: 00344257. DOI: 10.1016/S0034-4257(97)00104-1.
- CARUS, J. und B. SCHRÖDER (2014). *Analyse abiotischer und biotischer Treiber der Röhrchentwicklung im tidebeeinflussten Bereich der Elbe - Entwicklung und Parametrisierung eines mechanistischen Wachstumsmodells*. Techn. Ber. Koblenz: Bundesanstalt für Gewässerkunde, S. 107. DOI: 10.5675/Kliwas{_}26{_}2014{_}Roehrichtwachstum.
- CARUS, J., M. HEUNER, M. PAUL und B. SCHRÖDER (2017a). “Plant distribution and stand characteristics in brackish marshes: Unravelling the roles of abiotic factors and interspecific competition”. In: *Estuarine, Coastal and Shelf Science* 196, S. 237–247. ISSN: 02727714. DOI: 10.1016/j.ecss.2017.06.038.
- CARUS, J., M. HEUNER, M. PAUL und B. SCHRÖDER (2017b). “Which factors and processes drive the spatio-temporal dynamics of brackish marshes?—Insights from development and parameterisation of a mechanistic vegetation model”. In: *Ecological Modelling* 363, S. 122–136. ISSN: 03043800. DOI: 10.1016/j.ecolmodel.2017.08.023.
- CECCATO, P., S. FLASSE, S. TARANTOLA, S. JACQUEMOUD und J.-M. GRÉGOIRE (2001). “Detecting vegetation leaf water content using reflectance in the optical domain”. In: *Remote Sensing of Environment* 77.1, S. 22–33. ISSN: 00344257. DOI: 10.1016/S0034-4257(01)00191-2.

- CHIABRANDO, F., F. D'ANDRIA, G. SAMMARTANO und A. SPANÒ (2018). "UAV photogrammetry for archaeological site survey. 3D models at the Hierapolis in Phrygia (Turkey)". In: *Virtual Archaeology Review* 9.18, S. 28. ISSN: 1989-9947. DOI: 10.4995/var.2018.5958.
- CIGNETTI, M., D. GODONE, A. WRZESNIAK und D. GIORDAN (2019). "Structure from Motion Multisource Application for Landslide Characterization and Monitoring: The Champlas du Col Case Study, Sestriere, North-Western Italy". In: *Sensors* 19.10, S. 2364. ISSN: 1424-8220. DOI: 10.3390/s19102364.
- CLIFTON, B. C., W. G. HOOD und S. R. HINTON (2018). "Floristic Development in Three Oligohaline Tidal Wetlands after Dike Removal". In: September, S. 238–251.
- CLUTTERBUCK, B., G. CHICO, J. LABADZ und N. MIDGLEY (2018). "The potential of geospatial technology for monitoring peatland environments". In: *Inventory, value and restoration of peatlands and mires: recent contributions*. Hrsg. von J. M. FERNÁNDEZ-GARCÍA und F. J. PÉREZ. Provincial Council of Bizkaia, S. 167–181. URL: <http://irep.ntu.ac.uk/id/eprint/32921/>.
- COLOMINA, I. und P. MOLINA (2014). "Unmanned aerial systems for photogrammetry and remote sensing: A review". In: *ISPRS Journal of Photogrammetry and Remote Sensing* 92, S. 79–97. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2014.02.013.
- CONGALTON, R. G. (1991). "A review of assessing the accuracy of classifications of remotely sensed data". In: *Remote Sensing of Environment* 37.1, S. 35–46. ISSN: 00344257. DOI: 10.1016/0034-4257(91)90048-B.
- CONNOLLY, J. und N. M. HOLDEN (2017). "Detecting peatland drains with Object Based Image Analysis and Geospatial imagery". In: *Carbon Balance and Management* 12.1. ISSN: 17500680. DOI: 10.1186/s13021-017-0075-z.
- CORCORAN, J., J. KNIGHT, K. PELLETIER, L. RAMPI und Y. WANG (2015). "The effects of point or polygon based training data on randomForest classification accuracy of wetlands". In: *Remote Sensing* 7.4, S. 4002–4025. ISSN: 20724292. DOI: 10.3390/rs70404002.
- COUWENBERG, J., A. THIELE, F. TANNEBERGER, J. AUGUSTIN, S. BÄRISCH, D. DUBOVİK, N. LIASHCHYNSKAYA, D. MICHAELIS, M. MINKE, A. SKURATOVICH und H. JOOSTEN (2011). "Assessing greenhouse gas emissions from peatlands using vegetation as a proxy". In: *Hydrobiologia* 674.1, S. 67–89. ISSN: 1573-5117. DOI: 10.1007/s10750-011-0729-x.
- CRAFT, C., J. CLOUGH, J. EHMAN, S. JOYE, R. PARK, S. PENNINGS, H. GUO und M. MACHMULLER (2009). "Forecasting the effects of accelerated sea-level rise on tidal marsh ecosystem services". In: *Frontiers in Ecology and the Environment* 7.2, S. 73–78. ISSN: 1540-9295. DOI: 10.1890/070219.
- DABROWSKA-ZIELINSKA, K., M. BUDZYNSKA, M. TOMASZEWSKA, M. BARTOLD, M. GATKOWSKA, I. MALEK, K. TURLEJ und M. NAPIORKOWSKA (2014). "Monitoring Wetlands Ecosystems Using ALOS PALSAR (L-Band, HV) Supplemented by Optical Data: A Case Study of Biebrza Wetlands in Northeast Poland". In: *Remote Sensing* 6.2, S. 1605–1633. ISSN: 2072-4292. DOI: 10.3390/rs6021605.
- DAI, W., H. LI, X. CHEN, F. XU, Z. ZHOU und C. ZHANG (2020). "Saltmarsh Expansion in Response to Morphodynamic Evolution: Field Observations in the

- Jiangsu Coast using UAV”. In: *Journal of Coastal Research* 95.sp1, S. 433. ISSN: 0749-0208. DOI: 10.2112/SI95-084.1.
- DALE, P. E. R., K. HULSMAN und A. L. CHANDICA (1986). “Classification of reflectance on colour infrared aerial photographs and sub-tropical salt-marsh vegetation types”. In: *International Journal of Remote Sensing* 7.12, S. 1783–1788. ISSN: 0143-1161. DOI: 10.1080/01431168608948968.
- DALL’ASTA, E., G. FORLANI, R. RONCELLA, M. SANTISE, F. DIOTRI und U. MORRA DI CELLA (2017). “Unmanned Aerial Systems and DSM matching for rock glacier monitoring”. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 127, S. 102–114. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2016.10.003.
- DAVIDSON, N. C. (2014). “How much wetland has the world lost? Long-term and recent trends in global wetland area”. In: *Marine and Freshwater Research* 65.10, S. 934. ISSN: 1323-1650. DOI: 10.1071/MF14173.
- DAVIDSON, N. C. und C. M. FINLAYSON (2007). “Earth Observation for wetland inventory, assessment and monitoring”. In: *Aquatic Conservation: Marine and Freshwater Ecosystems* 17.3, S. 219–228. ISSN: 10527613. DOI: 10.1002/aqc.846.
- DISE, N. B. (2009). “Peatland Response to Global Change”. In: *Science* 326.5954, S. 810–811. ISSN: 0036-8075. DOI: 10.1126/science.1174268.
- DOUGHTY, C. und K. CAVANAUGH (2019). “Mapping Coastal Wetland Biomass from High Resolution Unmanned Aerial Vehicle (UAV) Imagery”. In: *Remote Sensing* 11.5, S. 540. ISSN: 2072-4292. DOI: 10.3390/rs11050540.
- DRONOVA, I. (2015). *Object-based image analysis in wetland research: A review*. DOI: 10.3390/rs70506380.
- DUDGEON, D., A. H. ARTHINGTON, M. O. GESSNER, Z.-I. KAWABATA, D. J. KNOWLER, C. LÉVÊQUE, R. J. NAIMAN, A.-H. PRIEUR-RICHARD, D. SOTO, M. L. J. STIASSNY und C. A. SULLIVAN (2006). “Freshwater biodiversity: importance, threats, status and conservation challenges”. In: *Biological Reviews* 81.02, S. 163. ISSN: 1464-7931. DOI: 10.1017/S1464793105006950.
- EDGAR, G. J., N. S. BARRETT, D. J. GRADDON und P. R. LAST (2000). “The conservation significance of estuaries: a classification of Tasmanian estuaries using ecological, physical and demographic attributes as a case study”. In: *Biological Conservation* 92.3, S. 383–397. ISSN: 00063207. DOI: 10.1016/S0006-3207(99)00111-1.
- ENGELS, J. G. (2010). “Drivers of marsh plant zonation and diversity patterns along estuarine stress gradients”. Diss. Universität Hamburg. URL: <https://ediss.sub.uni-hamburg.de/volltexte/2010/4695/>.
- ERWIN, K. L. (2009). “Wetlands and global climate change: the role of wetland restoration in a changing world”. In: *Wetlands Ecology and Management* 17.1, S. 71–84. ISSN: 0923-4861. DOI: 10.1007/s11273-008-9119-1.
- ESPRIELLA, M. C., V. LECOURS, P. C. FREDERICK, E. V. CAMP und B. WILKINSON (2020). “Quantifying Intertidal Habitat Relative Coverage in a Florida Estuary Using UAS Imagery and GEOBIA”. In: *Remote Sensing* 12.4, S. 677. ISSN: 2072-4292. DOI: 10.3390/rs12040677.
- ESTORNELL, J., J. M. MARTÍ-GAVLIÀ, M. T. SEBASTIÀ und J. MENGUAL (2013). “Principal component analysis applied to remote sensing”. In: *Modelling in Science Education and Learning* 6, S. 83. ISSN: 1988-3145. DOI: 10.4995/mse1.2013.1905.

- EVERITT, B. S., S. LANDAU, M. LEESE und D. STAHL (2011). *Cluster Analysis*. Bd. 5. Wiley. ISBN: 9780470749913. URL: <https://www.oreilly.com/library/view/cluster-analysis-5th/9780470978443/>.
- FAHRMEIR, L., C. HEUMANN, R. KÜNSTLER, I. PIGEOT und G. TUTZ (2016). *Statistik*. Springer-Lehrbuch. Berlin, Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-50371-3. DOI: 10.1007/978-3-662-50372-0.
- FARRIS, A. S., Z. DEFNE und N. K. GANJU (2019). “Identifying Salt Marsh Shorelines from Remotely Sensed Elevation Data and Imagery”. In: *Remote Sensing* 11.15, S. 1795. ISSN: 2072-4292. DOI: 10.3390/rs11151795.
- FENNER, N. und C. FREEMAN (2011). “Drought-induced carbon loss in peatlands”. In: *Nature Geoscience* 4.12, S. 895–900. ISSN: 1752-0894. DOI: 10.1038/ngeo1323.
- FERNÁNDEZ-GUISURAGA, J., E. SANZ-ABLANEDO, S. SUÁREZ-SEOANE und L. CALVO (2018). “Using Unmanned Aerial Vehicles in Postfire Vegetation Survey Campaigns through Large and Heterogeneous Areas: Opportunities and Challenges”. In: *Sensors* 18.2, S. 586. ISSN: 1424-8220. DOI: 10.3390/s18020586.
- FRANKLIN, S. E., O. S. AHMED, M. A. WULDER, J. C. WHITE, T. HERMOSILLA und N. C. COOPS (2015). “Large Area Mapping of Annual Land Cover Dynamics Using Multitemporal Change Detection and Classification of Landsat Time Series Data”. In: *Canadian Journal of Remote Sensing* 41.4, S. 293–314. ISSN: 17127971. DOI: 10.1080/07038992.2015.1089401.
- FREEMAN, C., N. OSTLE, N. FENNER und H. KANG (2004). “A regulatory role for phenol oxidase during decomposition in peatlands”. In: *Soil Biology and Biochemistry* 36.10, S. 1663–1667. ISSN: 00380717. DOI: 10.1016/j.soilbio.2004.07.012.
- FRICK, A., P. STEFFENHAGEN, S. ZERBE, T. TIMMERMANN und K. SCHULZ (2011). “Monitoring of the Vegetation Composition in Rewetted Peatland with Iterative Decision Tree Classification of Satellite Imagery”. In: *Photogrammetrie - Fernerkundung - Geoinformation* 2011.3, S. 109–122. ISSN: 14328364. DOI: q.
- FROLKING, S. und N. T. ROULET (2007). “Holocene radiative forcing impact of northern peatland carbon accumulation and methane emissions”. In: *Global Change Biology* 13.5, S. 1079–1088. ISSN: 1354-1013. DOI: 10.1111/j.1365-2486.2007.01339.x.
- GAUCI, A. A., C. J. BRODBECK, A. M. PONCET und T. KNAPPENBERGER (2018). “Assessing the Geospatial Accuracy of Aerial Imagery Collected with Various UAS Platforms”. In: *Transactions of the ASABE* 61.6, S. 1823–1829. ISSN: 2151-0040. DOI: 10.13031/trans.12852.
- GDAL/OGR CONTRIBUTORS (2020). *{GDAL/OGR} Geospatial Data Abstraction software Library*. URL: <https://gdal.org>.
- GELBRECHT, J. und D. ZAK (2004). “Stoffumsetzungsprozesse in Niedermooren und ihr Einfluss auf angrenzende Oberflächengewässer”. In: *Wasserwirtschaft* 5, S. 15–18.
- GITELSON, A. A., Y. J. KAUFMAN, R. STARK und D. RUNDQUIST (2002). “Novel algorithms for remote estimation of vegetation fraction”. In: *Remote Sensing of Environment* 80.1, S. 76–87. ISSN: 00344257. DOI: 10.1016/S0034-4257(01)00289-9.
- GMC (2019). *Moorbodenschutz als naturbasierte Lösung im Klimaschutzprogramm 2030 - schnelle Einstellung von Moor-Entwässerung für wirkungsvollen Klima-*

- schutz nötig!* Techn. Ber. Greifswald: Greifswald Moor Centrum. URL: https://www.greifswaldmoor.de/files/dokumente/Infopapiere_Briefings/2019-09-Faktenpapier_MoorklimaschutzDE_4S.pdf.
- GRENZDÖRFFER, G. (2016). “Pflichtenheft zur Ausschreibung von UAS-Dienstleistungen”. In: *Dreiländertagung der DGPF, der OVG und der SGPF*. Bd. 25. Bern: Publikationen der DGPF, S. 12. URL: https://www.dgpf.de/src/tagung/jt2016/proceedings/papers/01_DLT2016_Grenzdoerffer.pdf.
- GREUTER, W. und P. HIEPKO (1995). “Internationaler Code der Botanischen Nomenklatur”. In: *Englera* 15, S. i. ISSN: 01704818. DOI: 10.2307/3776775.
- GRISCOM, B. W., J. ADAMS, P. W. ELLIS, R. A. HOUGHTON, G. LOMAX, D. A. MITEVA, W. H. SCHLESINGER, D. SHOCH, J. V. SIIKAMÄKI, P. SMITH, P. WOODBURY, C. ZGANJAR, A. BLACKMAN, J. CAMPARI, R. T. CONANT, C. DELGADO, P. ELIAS, T. GOPALAKRISHNA, M. R. HAMSIK, M. HERRERO, J. KIESECKER, E. LANDIS, L. LAESTADIUS, S. M. LEAVITT, S. MINNEMEYER, S. POLASKY, P. POTAPOV, F. E. PUTZ, J. SANDERMAN, M. SILVIUS, E. WOLLENBERG und J. FARGIONE (2017). “Natural climate solutions”. In: *Proceedings of the National Academy of Sciences* 114.44, S. 11645–11650. ISSN: 0027-8424. DOI: 10.1073/pnas.1710465114.
- GUO, M., J. LI, C. SHENG, J. XU und L. WU (2017). “A review of wetland remote sensing”. In: *Sensors (Switzerland)* 17.4, S. 1–36. ISSN: 14248220. DOI: 10.3390/s17040777.
- HALL-BEYER, M. (2017a). *GLCM Texture: A Tutorial*. Techn. Ber. Calgary: University of Calgary. URL: https://prism.ucalgary.ca/bitstream/handle/1880/51900/texture%20tutorial%20v%203_0%20180206.pdf?sequence=11&isAllowed=y.
- HALL-BEYER, M. (2017b). “Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales”. In: *International Journal of Remote Sensing* 38.5, S. 1312–1338. ISSN: 0143-1161. DOI: 10.1080/01431161.2016.1278314.
- HARALICK, R. M., K. SHANMUGAM und I. DINSTEN (1973). “Textural Features for Image Classification”. In: *IEEE Transactions on Systems, Man, and Cybernetics* SMC-3.6, S. 610–621. ISSN: 0018-9472. DOI: 10.1109/TSMC.1973.4309314.
- HARROWER, M. und C. A. BREWER (2003). “ColorBrewer.org: An Online Tool for Selecting Colour Schemes for Maps”. In: *The Cartographic Journal* 40.1, S. 27–37. ISSN: 0008-7041. DOI: 10.1179/000870403235002042.
- HASTIE, T., R. TIBSHIRANI und J. FRIEDMAN (2009). *The Elements of Statistical Learning*. Springer Series in Statistics. New York, NY: Springer New York. ISBN: 978-0-387-84857-0. DOI: 10.1007/978-0-387-84858-7.
- HEADWALL (2020). *Hyperspectral Sensor Drone Integration*. URL: <https://www.headwallphotonics.com/uav-integration>.
- HENDERSON, F. M. und A. J. LEWIS (2008). “Radar detection of wetland ecosystems: a review”. In: *International Journal of Remote Sensing* 29.20, S. 5809–5835. ISSN: 0143-1161. DOI: 10.1080/01431160801958405.
- HENRICH, V., A. JUNG, C. GÖTZE, C. SANDOW, D. THÜRKOW und C. GLÄSSER (2009). “Development of an online indices database: Motivation, concept and implementation”. In: *6th EARSeL Imaging Spectroscopy SIG Workshop Innovative Tool for Scientific and Commercial Environment Applications*. URL: <http://>

- //earsel6th.tau.ac.il/~earsel6/CD/PDF/earsel-PROCEEDINGS/3064%20Henrich.pdf.
- HENRICH, V., G. KRAUSS, C. GÖTZE und C. SANDOW (2012). “IDB - www.\-index\data\-base.\-de, Entwicklung einer Datenbank für Fernerkundungsindizes”. In: *AK Fernerkundung*. URL: <https://www.indexdatabase.de/info/credits.php>.
- HEUNER, M. (2016). “Key ecosystem engineers in estuarine vegetation”. Diss. Technische Universität Dresden. DOI: 10.14279/depositonce-5564.
- HEUNER, M., B. SCHRÖDER, U. SCHRÖDER und B. KLEINSCHMIT (2018). “Contrasting elevational responses of regularly flooded marsh plants in navigable estuaries”. In: *Ecohydrology and Hydrobiology*, S. 1–17. ISSN: 20803397. DOI: 10.1016/j.ecohyd.2018.06.002.
- HEUNER, M., A. SILINSKI, J. SCHOELYNCK, T. J. BOUMA, S. PUIJALON, P. TROCH, E. FUCHS, B. SCHRÖDER, U. SCHRÖDER, P. MEIRE und S. TEMMERMAN (2015). “Ecosystem Engineering by Plants on Wave-Exposed Intertidal Flats Is Governed by Relationships between Effect and Response Traits”. In: *PLOS ONE* 10.9. Hrsg. von V. MAGAR, e0138086. ISSN: 1932-6203. DOI: 10.1371/journal.pone.0138086.
- HIRSCHELMANN, S., F. TANNEBERGER, W. S., F. REICHELT, M. HOHLBEIN, J. COUWENBERG, S. BUSSE, C. SCHRÖDER und A. NORDT (2020). *Moore in Mecklenburg-Vorpommern im Kontext nationaler und internationaler Klimaschutzziele - Zustand und Entwicklungspotenzial, Faktensammlung*. Techn. Ber. Greifswald: Greifswald Moor Centrum, S. 25.
- HLADIK, C. und M. ALBER (2012). “Accuracy assessment and correction of a LIDAR-derived salt marsh digital elevation model”. In: *Remote Sensing of Environment* 121, S. 224–235. ISSN: 00344257. DOI: 10.1016/j.rse.2012.01.018.
- HOBBIE, S. E. (1996). “Temperature and Plant Species Control Over Litter Decomposition in Alaskan Tundra”. In: *Ecological Monographs* 66.4, S. 503–522. ISSN: 00129615. DOI: 10.2307/2963492.
- AD-HOC-AG BODEN (2015). *Bodenkundliche Kartieranleitung*. 5th. Stuttgart: E. Schweizerbart’sche Verlagsbuchhandlung. ISBN: 978-3-510-95920-4.
- HOLZ, R., C. HERRMANN und G. MÜLLER-MOTZFELD (1996). “Vom Polder zum Ausdeichungsgebiet: Das Projekt Karrendorfer Wiesen und die Zukunft der Küstenüberflutungsgebiete in Mecklenburg-Vorpommern”. In: *Natur und Naturschutz in Mecklenburg-Vorpommern*. Band XXXII. Greifswald: I.L.N. Greifswald, S. 3–27. URL: http://www.iln-greifswald.de/natur_und_naturschutz.html.
- HOOVER, M. und A. W. WHELCHER (2015). “Tidal Marsh Classification Approaches and Future Marsh Migration Mapping Methods for Long Island Sound, Connecticut, and New York”. In: *Remote Sensing of Wetlands - Applications and Advances*. Hrsg. von R. W. TINER, M. W. LANG und V. KLEMAS. Boca: CRC Press, Taylor & Francis Group. Kap. 13, S. 265–282. ISBN: 978-1-4822-3738-2.
- HOSSAIN, K., R. PAREKH, S. PARUYA, S. KAR und S. ROY (2010). “Extending GLCM to include Color Information for Texture Recognition”. In: S. 583–588. DOI: 10.1063/1.3516370.
- HUMPENÖDER, F., K. KARSTENS, H. LOTZE-CAMPEN, J. LEIFELD, L. MENICETTI, A. BARTHELMES und A. POPP (2020). “Peatland protection and restoration

- are key for climate change mitigation”. In: *Environmental Research Letters* 15.10, S. 104093. ISSN: 1748-9326. DOI: 10.1088/1748-9326/abae2a.
- HUNT, E. R., P. C. DORAISWAMY, J. E. MCMURTREY, C. S. T. DAUGHTRY, E. M. PERRY und B. AKHMEDOV (2013). “A visible band index for remote sensing leaf chlorophyll content at the canopy scale”. In: *International Journal of Applied Earth Observation and Geoinformation* 21, S. 103–112. ISSN: 0303-2434. DOI: <https://doi.org/10.1016/j.jag.2012.07.020>.
- IGAMBERDIEV, R., R. ZÖLITZ und M. WILMKING (2013). *Vorpommern Initiative Paludikultur - Modell zur Fernerkundung-gesteuerten Flächenkartierung*. Techn. Ber. University of Greifswald.
- JACQUEMOUD, S., W. VERHOEF, F. BARET, C. BACOUR, P. J. ZARCO-TEJADA, G. P. ASNER, C. FRANÇOIS und S. L. USTIN (2009). “PROSPECT+SAIL models: A review of use for vegetation characterization”. In: *Remote Sensing of Environment* 113, S56–S66. ISSN: 00344257. DOI: 10.1016/j.rse.2008.01.026.
- JONES, H. G. und R. A. VAUGHAN (2010). *Remote Sensing of Vegetation: Principles, Techniques, and Applications*. Oxford University Press. ISBN: 9780199207794.
- JOOSTEN, H. (2009). “The Global Peatland CO₂ picture Peatland status and drainage related emissions in all countries of the world”. In: *Wetlands International*, S. 36. ISSN: 1064-8275. DOI: 10.1137/S1064827501399006.
- JOOSTEN, H., A. SIRIN, J. COUWENBERG, J. LAINE und P. SMITH (2016). “The role of peatlands in climate regulation”. In: *Peatland Restoration and Ecosystem Services*. Hrsg. von A. BONN, T. ALLOTT, M. EVANS, H. JOOSTEN und R. STONEMAN. Cambridge: Cambridge University Press, S. 63–76. DOI: 10.1017/CB09781139177788.005.
- JOOSTEN, H., M.-L. TAPIO-BISTRÖM und S. TOL, Hrsg. (2012). *Peatlands - guidance for climate change mitigation through conservation, rehabilitation and sustainable use*. 2. Aufl. Mitigation of Climate Change in Agriculture (MICCA) Programme series 5. Food und Agriculture Organization of the United Nations. ISBN: 978-92-5-107302-5. URL: <http://www.fao.org/docrep/015/an762e/an762e00.htm>.
- JORGENSON, M., G. FROST und D. DISSING (2018). “Drivers of Landscape Changes in Coastal Ecosystems on the Yukon-Kuskokwim Delta, Alaska”. In: *Remote Sensing* 10.8, S. 1280. ISSN: 2072-4292. DOI: 10.3390/rs10081280.
- JUNK, W. J., S. AN, C. M. FINLAYSON, B. GOPAL, J. KVĚT, S. A. MITCHELL, W. J. MITSCH und R. D. ROBERTS (2013). “Current state of knowledge regarding the world’s wetlands and their future under global climate change: a synthesis”. In: *Aquatic Sciences* 75.1, S. 151–167. ISSN: 1015-1621. DOI: 10.1007/s00027-012-0278-z.
- JURASINSKI, G., A. GÜNTHER, V. HUTH, J. COUWENBERG und S. GLATZEL (2016). “Treibhausgasemissionen”. In: *Paludikultur – Bewirtschaftung nasser Moore*. Stuttgart: Schweizerbart, S. 79–94.
- KALACSKA, M., G. CHMURA, O. LUCANUS, D. BÉRUBÉ und J. ARROYO-MORA (2017a). “Structure from motion will revolutionize analyses of tidal wetland landscapes”. In: *Remote Sensing of Environment* 199, S. 14–24. ISSN: 00344257. DOI: 10.1016/j.rse.2017.06.023.
- KALACSKA, M., O. LUCANUS, R. J. SOFFER, G. LEBLANC und J. P. ARROYO-MORA (2017b). “Spectro-spatial relationship between UAV derived high reso-

- lution DEM and SWIR hyperspectral data: application to an ombrotrophic peatland”. In: *Remote Sensing for Agriculture, Ecosystems, and Hydrology XIX*. Hrsg. von C. M. NEALE und A. MALTESE. SPIE, S. 25. ISBN: 9781510613065. DOI: 10.1117/12.2277874.
- KEDDY, P. A. (2010). *Wetland Ecology*. 2. Aufl. Cambridge: Cambridge University Press. ISBN: 9780511778179. DOI: 10.1017/CB09780511778179.
- KELCEY, J. und A. LUCIEER (2013). “An adaptive texture selection framework for ultra-high resolution UAV imagery”. In: *2013 IEEE International Geoscience and Remote Sensing Symposium - IGARSS*. IEEE, S. 3883–3886. ISBN: 978-1-4799-1114-1. DOI: 10.1109/IGARSS.2013.6723680.
- KHANNA, S., M. SANTOS, A. KOLTUNOV, K. SHAPIRO, M. LAY und S. USTIN (2017). “Marsh Loss Due to Cumulative Impacts of Hurricane Isaac and the Deepwater Horizon Oil Spill in Louisiana”. In: *Remote Sensing* 9.2, S. 169. ISSN: 2072-4292. DOI: 10.3390/rs9020169.
- KLEMAS, V. (2011). “Remote Sensing of Wetlands: Case Studies Comparing Practical Techniques”. In: *Journal of Coastal Research* 27.3, S. 418. ISSN: 0749-0208. DOI: 10.2112/JCOASTRES-D-10-00174.1.
- KLEMAS, V. (2013a). “Remote Sensing of Coastal Wetland Biomass: An Overview”. In: *Journal of Coastal Research* 290, S. 1016–1028. ISSN: 0749-0208. DOI: 10.2112/JCOASTRES-D-12-00237.1.
- KLEMAS, V. (2013b). “Using Remote Sensing to Select and Monitor Wetland Restoration Sites: An Overview”. In: *Journal of Coastal Research* 289, S. 958–970. ISSN: 0749-0208. DOI: 10.2112/JCOASTRES-D-12-00170.1.
- KNIPLING, E. B. (1970). “Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation”. In: *Remote Sensing of Environment* 1.3, S. 155–159. ISSN: 00344257. DOI: 10.1016/S0034-4257(70)80021-9.
- KNOTH, C., B. KLEIN, T. PRINZ und T. KLEINEBECKER (2013). “Unmanned aerial vehicles as innovative remote sensing platforms for high-resolution infrared imagery to support restoration monitoring in cut-over bogs”. In: *Applied Vegetation Science* 16.3, S. 509–517. ISSN: 1654-109X. DOI: 10.1111/avsc.12024.
- KOCH, M. und G. JURASINSKI (2015). “Four decades of vegetation development in a percolation mire complex following intensive drainage and abandonment”. In: *Plant Ecology & Diversity* 8.1, S. 49–60. ISSN: 1755-0874. DOI: 10.1080/17550874.2013.862752.
- KOCH, M., F. KOEBSCH, J. HAHN und G. JURASINSKI (2017). “From meadow to shallow lake: Monitoring secondary succession in a coastal fen after rewetting by flooding based on aerial imagery and plot data”. In: *Mires and Peat* 19.11, S. 1–17. ISSN: 1819754X. DOI: 10.19189/MaP.2015.OMB.188.
- KOEBSCH, F., S. GLATZEL, J. HOFMANN, I. FORBRICH und G. JURASINSKI (2013). “CO₂ exchange of a temperate fen during the conversion from moderately rewetting to flooding”. In: *Journal of Geophysical Research: Biogeosciences* 118.2, S. 940–950. ISSN: 21698953. DOI: 10.1002/jgrg.20069.
- KOSKINEN, M., T. SALLANTAUS und H. VASANDER (2011). “Post-restoration development of organic carbon and nutrient leaching from two ecohydrologically different peatland sites”. In: *Ecological Engineering* 37.7, S. 1008–1016. ISSN: 09258574. DOI: 10.1016/j.ecoleng.2010.06.036.

- KROSS, A., H. MCNAIRN, D. LAPEN, M. SUNOHARA und C. CHAMPAGNE (2015). "Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops". In: *International Journal of Applied Earth Observation and Geoinformation* 34, S. 235–248. ISSN: 0303-2434. DOI: <http://dx.doi.org/10.1016/j.jag.2014.08.002>.
- KUMAR, L. und P. SINHA (2014). "Mapping salt-marsh land-cover vegetation using high-spatial and hyperspectral satellite data to assist wetland inventory". In: *GIS-science & Remote Sensing* 51.5, S. 483–497. ISSN: 1548-1603. DOI: [10.1080/15481603.2014.947838](https://doi.org/10.1080/15481603.2014.947838).
- LAINE, A., L. MEHTÄTALO, A. TOLVANEN, S. FROLKING und E.-S. TUUTTILA (2019). "Impacts of drainage, restoration and warming on boreal wetland greenhouse gas fluxes". In: *Science of The Total Environment* 647, S. 169–181. ISSN: 00489697. DOI: [10.1016/j.scitotenv.2018.07.390](https://doi.org/10.1016/j.scitotenv.2018.07.390).
- LAIIV-MV (2020). *SAPOS des Landesamt für innere Verwaltung - Amt für Geoinformation, Vermessungs- und Katasterwesen des Landes Mecklenburg-Vorpommerns*. URL: <https://www.laiiv-mv.de/Geoinformation/Raumbezug/SAPOS/>.
- LEES, K. J., T. QUAIFFE, R. R. ARTZ, M. KHOMIK und J. M. CLARK (2018). "Potential for using remote sensing to estimate carbon fluxes across northern peatlands – A review". In: *Science of the Total Environment* 615, S. 857–874. ISSN: 18791026. DOI: [10.1016/j.scitotenv.2017.09.103](https://doi.org/10.1016/j.scitotenv.2017.09.103).
- LEHMANN, J., W. MÜNCHBERGER, C. KNOTH, C. BLODAU, F. NIEBERDING, T. PRINZ, V. PANCOTTO und T. KLEINEBECKER (2016). "High-Resolution Classification of South Patagonian Peat Bog Microforms Reveals Potential Gaps in Up-Scaled CH₄ Fluxes by use of Unmanned Aerial System (UAS) and CIR Imagery". In: *Remote Sensing* 8.3, S. 173. ISSN: 2072-4292. DOI: [10.3390/rs8030173](https://doi.org/10.3390/rs8030173).
- LEHOSMAA, K., J. JYVÄSJÄRVI, R. VIRTANEN, J. ILMONEN, J. SAASTAMOINEN und T. MUOTKA (2017). "Anthropogenic habitat disturbance induces a major biodiversity change in habitat specialist bryophytes of boreal springs". In: *Biological Conservation* 215, S. 169–178. ISSN: 00063207. DOI: [10.1016/j.biocon.2017.09.010](https://doi.org/10.1016/j.biocon.2017.09.010).
- LEIFELD, J. und L. MENICHETTI (2018). "The underappreciated potential of peatlands in global climate change mitigation strategies". In: *Nature Communications* 9.1, S. 1071. ISSN: 2041-1723. DOI: [10.1038/s41467-018-03406-6](https://doi.org/10.1038/s41467-018-03406-6).
- LEIFELD, J., M. MÜLLER und J. FUHRER (2011). "Peatland subsidence and carbon loss from drained temperate fens". In: *Soil Use and Management* 27.2, S. 170–176. ISSN: 02660032. DOI: [10.1111/j.1475-2743.2011.00327.x](https://doi.org/10.1111/j.1475-2743.2011.00327.x).
- LEIFELD, J., C. WÜST-GALLEY und S. PAGE (2019). "Intact and managed peatland soils as a source and sink of GHGs from 1850 to 2100". In: *Nature Climate Change* 9.12, S. 945–947. ISSN: 1758-678X. DOI: [10.1038/s41558-019-0615-5](https://doi.org/10.1038/s41558-019-0615-5).
- LEPAGE, B. A., Hrsg. (2011). *Wetlands*. Dordrecht: Springer Netherlands. ISBN: 978-94-007-0550-0. DOI: [10.1007/978-94-007-0551-7](https://doi.org/10.1007/978-94-007-0551-7).
- LIBRÁN-EMBED, F., F. KLAUS, T. TSCHARNTKE und I. GRASS (2020). "Unmanned aerial vehicles for biodiversity-friendly agricultural landscapes - A systematic review". In: *Science of The Total Environment* 732, S. 139204. ISSN: 00489697. DOI: [10.1016/j.scitotenv.2020.139204](https://doi.org/10.1016/j.scitotenv.2020.139204).

- LIN, N., K. EMANUEL, M. OPPENHEIMER und E. VANMARCKE (2012). "Physically based assessment of hurricane surge threat under climate change". In: *Nature Climate Change* 2.6, S. 462–467. ISSN: 1758-678X. DOI: 10.1038/nclimate1389.
- LM M-V (2009). *Konzept zum Schutz und zur Nutzung der Moore. Fortschreibung des Konzeptes zur Bestandssicherung und zur Entwicklung der Moore*. Techn. Ber. Schwerin: Ministerium für Landwirtschaft, Umwelt und Verbraucherschutz Mecklenburg-Vorpommern. URL: https://www.lung.mv-regierung.de/insite/cms/umwelt/natur/lebensraumschutz_portal/moorschutz.htm.
- LM M-V (2017). *Umsetzung von Paludikultur auf landwirtschaftlich genutzten Flächen in Mecklenburg-Vorpommern. Fachstrategie zur Umsetzung der nutzungsbezogenen Vorschläge des Moorschutzkonzeptes*. Techn. Ber. Schwerin: für Landwirtschaft, Umwelt und Verbraucherschutz Mecklenburg-Vorpommern.
- LOVITT, J., M. M. RAHMAN, S. SARASWATI, G. J. MCDERMID, M. STRACK und B. XU (2018). "UAV Remote Sensing Can Reveal the Effects of Low-Impact Seismic Lines on Surface Morphology, Hydrology, and Methane (CH₄) Release in a Boreal Treed Bog". In: *Journal of Geophysical Research: Biogeosciences* 123.3, S. 1117–1129. ISSN: 21698953. DOI: 10.1002/2017JG004232.
- LUHMANN, T. (2018). *Nahbereichs photogrammetrie*. 4. Edition. Berlin: Wichmann. ISBN: 978-3-87907-640-6.
- MALAK, D. A. und L. HILARIDES (2016). *SWOS - Satellite-based Wetland Observation Service - Guidelines for the delimitation of wetland ecosystems*. Techn. Ber. Málaga: European Topic Centre of University of Málaga, S. 1–23. URL: <https://www.swos-service.eu/publications/>.
- MANSFELD, E. und J. MAJOHR (2010). *Satellitenortung und Navigation Grundlagen, Wirkungsweise und Anwendung globaler Satellitennavigationssysteme*. Bd. 3. Wiesbaden: Vieweg+Teubner.
- MARCACCIO, J. V., C. E. MARKLE und P. CHOW-FRASER (2016). "Use of fixed-wing and multi-rotor unmanned aerial vehicles to map dynamic changes in a freshwater marsh". In: *Journal of Unmanned Vehicle Systems* 4.3, S. 193–202. ISSN: 2291-3467. DOI: 10.1139/jjuvs-2015-0016.
- MCKINNON, T. (2017). *Comparing RGB-Based Vegetation Indices With NDVI For Drone Based Agricultural Sensing*. Techn. Ber., S. 1–8. URL: <https://agribotix.com/wp-content/uploads/2017/05/Agribotix-VARI-TGI-Study.pdf>.
- MEDEIROS, S., S. HAGEN, J. WEISHAMPEL und J. ANGELO (2015). "Adjusting lidar-derived digital terrain models in coastal marshes based on estimated above-ground biomass density". In: *Remote Sensing* 7.4, S. 3507–3525. ISSN: 20724292. DOI: 10.3390/rs70403507.
- MEMIS, O. (2007). *Long-wave infrared detectors: Inspired by nature, IR detector targets long-wavelength applications*. URL: <https://www.laserfocusworld.com/detectors-imaging/article/16552888/longwave-infrared-detectors-inspired-by-nature-ir-detector-targets-longwavelength-applications>.
- METZING, D. und A. GERLACH (2001). "Climate change and coastal flora". In: *"Fingerprints" of Climate Change*. Hrsg. von G. WALTHER, C. BURGA und P. EDWARDS. Boston, MA: Springer US, S. 185–201. DOI: 10.1007/978-1-4419-8692-4_{_}12.
- MEYER, H., L. W. LEHNERT, Y. WANG, C. REUDENBACH, T. NAUSS und J. BENDIX (2017). "From local spectral measurements to maps of vegetation cover and

- biomass on the Qinghai-Tibet-Plateau: Do we need hyperspectral information?" In: *International Journal of Applied Earth Observation and Geoinformation* 55, S. 21–31. ISSN: 0303-2434. DOI: <http://dx.doi.org/10.1016/j.jag.2016.10.001>.
- MICASENSE (2020). *RedEdge MX - Dual Camera Imaging System*. URL: <https://micasense.com/dual-camera-system/>.
- MISHRA, D. R. und S. GHOSH (2015). "Using Moderate-Resolution Satellite Sensors for Monitoring the Biophysical Parameters and Phenology of Tidal Marshes". In: *Remote Sensing of Wetlands - Applications and Advances*. Hrsg. von R. W. TINER, M. W. LANG und V. KLEMAS. Boca: CRC Press, Taylor & Francis Group. Kap. 14, S. 283–314. ISBN: 978-1-4822-3738-2.
- MITSCHE, W. J. und J. G. GOSSELINK (2000). "The value of wetlands: importance of scale and landscape setting". In: *Ecological Economics* 35.1, S. 25–33. ISSN: 0921-8009. DOI: 10.1016/S0921-8009(00)00165-8.
- MOEN, A., J. HANS und F. TANNEBERGER (2017). *Mires and peatlands of Europe. Status, distribution and conservation*. Stuttgart, Germany: Schweizerbart Science Publishers. ISBN: 9783510653836. URL: http://www.schweizerbart.de/publications/detail/isbn/9783510653836/Joosten_Tanneberger_Moen_Mires_and_peat.
- MOHD NOOR, N., A. ABDULLAH und M. HASHIM (2018). "Remote sensing UAV/drones and its applications for urban areas: a review". In: *IOP Conference Series: Earth and Environmental Science* 169, S. 012003. ISSN: 1755-1315. DOI: 10.1088/1755-1315/169/1/012003.
- MÖLLER, I. (2006). "Quantifying saltmarsh vegetation and its effect on wave height dissipation: Results from a UK East coast saltmarsh". In: *Estuarine, Coastal and Shelf Science* 69.3-4, S. 337–351. ISSN: 02727714. DOI: 10.1016/j.ecss.2006.05.003.
- MÖLLER, I., T. SPENCER, J. FRENCH, D. LEGGETT und M. DIXON (1999). "Wave Transformation Over Salt Marshes: A Field and Numerical Modelling Study from North Norfolk, England". In: *Estuarine, Coastal and Shelf Science* 49.3, S. 411–426. ISSN: 02727714. DOI: 10.1006/ecss.1999.0509.
- MUKHERJEE, R., D. SENGUPTA und S. K. SIKDAR (2015). "Selection of Sustainable Processes Using Sustainability Footprint Method". In: *Computer Aided Chemical Engineering*. Elsevier. Bd. 36. Kap. 12, S. 311–329. DOI: 10.1016/B978-0-444-63472-6.00012-4.
- MURFIT, S. L., B. M. ALLAN, A. BELLGROVE, A. RATTRAY, M. A. YOUNG und D. IERODIACONOU (2017). "Applications of unmanned aerial vehicles in intertidal reef monitoring". In: *Scientific Reports* 7.1, S. 10259. ISSN: 2045-2322. DOI: 10.1038/s41598-017-10818-9.
- MUSSEAU, R., L. BOUTAULT und S. BESLIC (2018). "Rapid losses of intertidal salt marshes due to global change in the Gironde estuary (France) and conservation implications for marshland passerines". In: *Journal of Coastal Conservation* 22.2, S. 443–451. ISSN: 1400-0350. DOI: 10.1007/s11852-018-0592-2.
- NAES, T., P. B. BROCKHOFF und O. TOMIC (2010). "Multiple Regression, Principal Components Regression and Partial Least Squares Regression". In: *Statistics for Sensory and Consumer Science*. Chichester, UK: John Wiley & Sons, Ltd, S. 227–247. DOI: 10.1002/9780470669181.ch15.

- NICHOLLS, R., S. HANSON, C. HERWEIJER, N. PATMORE, S. HALLEGATTE, J. CORFEE-MORLOT, J. CHATEAU und R. MUIR-WOOD (2007). *Ranking of the world's cities most exposed to coastal flooding today and in the future*. Techn. Ber. OECD. URL: <https://climate-adapt.eea.europa.eu/metadata/publications/ranking-of-the-worlds-cities-to-coastal-flooding/11240357>.
- NOWAK, M. M., K. DZIÓB und P. BOGAWSKI (2019). "Unmanned Aerial Vehicles (UAVs) in environmental biology: a review". In: *European Journal of Ecology* 4.2, S. 56–74. ISSN: 1339-8474. DOI: 10.2478/eje-2018-0012.
- OTEMAN, B., E. MORRIS, G. PERALTA, T. BOUMA und D. van der WAL (2019). "Using Remote Sensing to Identify Drivers behind Spatial Patterns in the Biophysical Properties of a Saltmarsh Pioneer". In: *Remote Sensing* 11.5, S. 511. ISSN: 2072-4292. DOI: 10.3390/rs11050511.
- PAL, M. (2005). "Random forest classifier for remote sensing classification". In: *International Journal of Remote Sensing* 26.1, S. 217–222. ISSN: 0143-1161. DOI: 10.1080/01431160412331269698.
- PALACE, M., C. HERRICK, J. DELGRECO, D. FINNELL, A. GARNELLO, C. MCCALLEY, K. MCARTHUR, F. SULLIVAN und R. VARNER (2018). "Determining Subarctic Peatland Vegetation Using an Unmanned Aerial System (UAS)". In: *Remote Sensing* 10.9, S. 1498. ISSN: 2072-4292. DOI: 10.3390/rs10091498.
- PARRY, L. E., J. HOLDEN und P. J. CHAPMAN (2014). "Restoration of blanket peatlands". In: *Journal of Environmental Management* 133, S. 193–205. ISSN: 03014797. DOI: 10.1016/j.jenvman.2013.11.033.
- PEDREGOSA, F., G. VAROQUAUX, A. GRAMFORT, V. MICHEL, B. THIRION, O. GRISEL, M. BLONDEL, P. PRETTENHOFER, R. WEISS, V. DUBOURG, J. VANDERPLAS, A. PASSOS, D. COURNAPEAU, M. BRUCHER, M. PERROT und E. DUCHESNAY (2011). "Scikit-learn: Machine Learning in {P}ython". In: *Journal of Machine Learning Research* 12, S. 2825–2830. URL: https://scikit-learn.org/stable/user_guide.html.
- PENGR, B. W., C. A. JOHNSTON und T. R. LOVELAND (2007). "Mapping an invasive plant, *Phragmites australis*, in coastal wetlands using the EO-1 Hyperion hyperspectral sensor". In: *Remote Sensing of Environment* 108.1, S. 74–81. ISSN: 00344257. DOI: 10.1016/j.rse.2006.11.002.
- PEREIRA, H. M., P. W. LEADLEY, V. PROENÇA, R. ALKEMADE, J. P. W. SCHARLEMANN, J. F. FERNANDEZ-MANJARRÉS, M. B. ARAÚJO, P. BALVANERA, R. BIGGS, W. W. L. CHEUNG, L. CHINI, H. D. COOPER, E. L. GILMAN, S. GUÉNETTE, G. C. HURTT, H. P. HUNTINGTON, G. M. MACE, T. OBERDORFF, C. REVENGA, P. RODRIGUES, R. J. SHOLES, U. R. SUMAILA und M. WALPOLE (2010). "Scenarios for Global Biodiversity in the 21st Century". In: *Science* 330.6010, S. 1496–1501. ISSN: 0036-8075. DOI: 10.1126/science.1196624.
- PFADENHAUER, J. und A. GROOTJANS (1999). "Wetland restoration in Central Europe: aims and methods". In: *Applied Vegetation Science* 2.1, S. 95–106. ISSN: 14022001. DOI: 10.2307/1478886.
- PINTON, D., A. CANESTRELLI, B. WILKINSON, P. IFJU und A. ORTEGA (2020). "A new algorithm for estimating ground elevation and vegetation characteristics in coastal salt marshes from high-resolution UAV-based LiDAR point clouds". In: *Earth Surface Processes and Landforms* 45.14, S. 3687–3701. ISSN: 0197-9337. DOI: 10.1002/esp.4992.

- POULIOT, R., L. ROCHEFORT und E. KAROFELD (2011). “Initiation of microtopography in revegetated cutover peatlands”. In: *Applied Vegetation Science* 14.2, S. 158–171. ISSN: 14022001. DOI: 10.1111/j.1654-109X.2010.01118.x.
- QUANTUM-SYSTEMS (2020). *Trinity F90+*. URL: <https://www.quantum-systems.com/project/trinity-f90/>.
- RAFFAELLI, D. und S. HAWKINS (1996). *Intertidal Ecology*. Dordrecht: Springer Netherlands. ISBN: 978-0-412-29960-5. DOI: 10.1007/978-94-009-1489-6.
- RAHMAN, M. M., G. J. MCDERMID, M. STRACK und J. LOVITT (2017). “A new method to map groundwater table in peatlands using unmanned aerial vehicles”. In: *Remote Sensing* 9.10, S. 1–14. ISSN: 20724292. DOI: 10.3390/rs9101057.
- RAMSAR (1994). *Convention on Wetlands of International Importance especially as Waterfowl Habitat*. URL: https://www.ramsar.org/sites/default/files/documents/library/current_convention_text_e.pdf.
- RAMSAR (2019). *Contracting Parties to the Ramsar Convention*. URL: https://www.ramsar.org/sites/default/files/documents/library/annotated_contracting_parties_list_e.pdf.
- RICHTER, S. (2019). *Statistisches und maschinelles Lernen*. Berlin, Heidelberg: Springer Berlin Heidelberg, S. 163–220. ISBN: 978-3-662-59353-0. DOI: 10.1007/978-3-662-59354-7.
- RILO, A., P. FREIRE, M. GUERREIRO, A. B. FORTUNATO und R. TABORDA (2013). “Estuarine margins vulnerability to floods for different sea level rise and human occupation scenarios”. In: *Journal of Coastal Research* 65, S. 820–825. ISSN: 0749-0208. DOI: 10.2112/SI65-139.1.
- RODRIGUEZ-GALIANO, V., B. GHIMIRE, J. ROGAN, M. CHICA-OLMO und J. RIGOL-SANCHEZ (2012). “An assessment of the effectiveness of a random forest classifier for land-cover classification”. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 67, S. 93–104. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2011.11.002.
- RYU, J.-H., J.-K. CHOI und Y.-K. LEE (2014). “Potential of remote sensing in management of tidal flats: A case study of thematic mapping in the Korean tidal flats”. In: *Ocean & Coastal Management* 102, S. 458–470. ISSN: 09645691. DOI: 10.1016/j.ocecoaman.2014.03.003.
- SAMUEL-ROSA, A., L. CUNHA DOS ANJOS, G. de MATTOS VASQUES, G. HEUVELINK, E. PEBESMA, S. J., J. FRENCH, P. ROUDIER, D. BRUS und M. LARK (2019). *R-Package ‘spsann’. Optimization of Sample Configurations using Spatial Simulated Annealing*.
- SANDI, S. G., J. F. RODRIGUEZ, N. SAINTILAN, L. WEN, G. KUCZERA, G. RICCARDI und P. M. SACO (2020). “Resilience to drought of dryland wetlands threatened by climate change”. In: *Scientific Reports* 10.1, S. 13232. ISSN: 2045-2322. DOI: 10.1038/s41598-020-70087-x.
- SCHOLEFIELD, P., D. MORTON, G. MCSHANE, L. CARRASCO, M. G. WHITFIELD, C. ROWLAND, R. ROSE, C. WOOD, E. TEBBS, B. DODD und D. MONTEITH (2019). “Estimating habitat extent and carbon loss from an eroded northern blanket bog using UAV derived imagery and topography”. In: *Progress in Physical Geography: Earth and Environment* 43.2, S. 282–298. ISSN: 0309-1333. DOI: 10.1177/0309133319841300.
- SCHOUTENS, K., M. HEUNER, V. MINDEN, T. SCHULTE OSTERMANN, A. SILINSKI, J.-P. BELLARD und S. TEMMERMAN (2019). “How effective are tidal marshes as

- nature-based shoreline protection throughout seasons?” In: *Limnology and Oceanography* 64.4, S. 1750–1762. ISSN: 00243590. DOI: 10.1002/lno.11149.
- SCHOWENGERDT, R. (2006). *Remote Sensing*. Bd. 3. Academic Press, S. 560. ISBN: 9780123694072.
- SCHUETZE, B., A. ENGLER und H. WEBER (2015). *Lehrbuch Vermessung Fachwissen Band 2 - Grundlagen der Vermessung - verständlich - übersichtlich - handlungsorientiert*. Bd. 2. Dresden: SEW- Verlag. ISBN: 9783936203271. URL: <https://www.sew-verlag.de/c6/index.php/fach-und-sachb%C3%BCcher/lehrbuch-vermessung-fachwissen-detail.html>.
- SCHUSTER, C., M. FÖRSTER und B. KLEINSCHMIT (2012). “Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data”. In: *International Journal of Remote Sensing* 33.17, S. 5583–5599. DOI: 10.1080/01431161.2012.666812.
- SENSEFLY (2020). *eBee Plus*. URL: <https://www.sensefly.com/drone/abee-plus-survey-drone/>.
- SHENG, Y., L. C. SMITH, G. M. MACDONALD, K. V. KREMENETSKI, K. E. FREY, A. A. VELICHKO, M. LEE, D. W. BEILMAN und P. DUBININ (2004). “A high-resolution GIS-based inventory of the west Siberian peat carbon pool”. In: *Global Biogeochemical Cycles* 18.3, n/a–n/a. ISSN: 08866236. DOI: 10.1029/2003GB002190.
- SIEGMANN, B. und T. JARMER (2015). “Comparison of different regression models and validation techniques for the assessment of wheat leaf area index from hyperspectral data”. In: *International Journal of Remote Sensing* 36.18, S. 4519–4534. ISSN: 0143-1161. DOI: 10.1080/01431161.2015.1084438.
- SILINSKI, A. (2015). “Living on the edge. Bio-physical interactions in the pioneer zone of expanding tidal marshes”. Diss. University of Antwerp.
- SILINSKI, A., M. HEUNER, J. SCHOELYNCK, S. PUIJALON, U. SCHRÖDER, E. FUCHS, P. TROCH, T. J. BOUMA, P. MEIRE und S. TEMMERMAN (2015). “Effects of Wind Waves versus Ship Waves on Tidal Marsh Plants: A Flume Study on Different Life Stages of *Scirpus maritimus*”. In: *PLOS ONE* 10.3. Hrsg. von V. MAGAR, e0118687. ISSN: 1932-6203. DOI: 10.1371/journal.pone.0118687.
- SILINSKI, A., K. SCHOUTENS, S. PUIJALON, J. SCHOELYNCK, D. LUYCKX, P. TROCH, P. MEIRE und S. TEMMERMAN (2018). “Coping with waves: Plasticity in tidal marsh plants as self-adapting coastal ecosystem engineers”. In: *Limnology and Oceanography* 63.2, S. 799–815. ISSN: 00243590. DOI: 10.1002/lno.10671.
- SIMPSON, J., M. WOOSTER, T. SMITH, M. TRIVEDI, R. VERNIMMEN, R. DEDI, M. SHAKTI und Y. DINATA (2016). “Tropical Peatland Burn Depth and Combustion Heterogeneity Assessed Using UAV Photogrammetry and Airborne LiDAR”. In: *Remote Sensing* 8.12, S. 1000. ISSN: 2072-4292. DOI: 10.3390/rs8121000.
- SINHA, S., C. JEGANATHAN, L. K. SHARMA und M. S. NATHAWAT (2015). “A review of radar remote sensing for biomass estimation”. In: *International Journal of Environmental Science and Technology* 12.5, S. 1779–1792. ISSN: 1735-1472. DOI: 10.1007/s13762-015-0750-0.
- SONNENTAG, O., J. CHEN, D. ROBERTS, J. TALBOT, K. HALLIGAN und A. GOVIND (2007). “Mapping tree and shrub leaf area indices in an ombrotrophic peatland through multiple endmember spectral unmixing”. In: *Remote Sensing of Environment* 109.3, S. 342–360. ISSN: 00344257. DOI: 10.1016/j.rse.2007.01.010.

- SØRENSEN, R., U. ZINKO und J. SEIBERT (2006). “On the calculation of the topographic wetness index: evaluation of different methods based on field observations”. In: *Hydrology and Earth System Sciences* 10.1, S. 101–112. ISSN: 1607-7938. DOI: 10.5194/hess-10-101-2006.
- STEFFENHAGEN, P., D. ZAK, K. SCHULZ, T. TIMMERMANN und S. ZERBE (2012). “Biomass and nutrient stock of submersed and floating macrophytes in shallow lakes formed by rewetting of degraded fens”. In: *Hydrobiologia* 692.1, S. 99–109. ISSN: 0018-8158. DOI: 10.1007/s10750-011-0833-y.
- STROBL, C., A. L. BOULESTEIX, A. ZEILEIS und T. HOTHORN (2007). “Bias in random forest variable importance measures: Illustrations, sources and a solution”. In: *BMC Bioinformatics* 8. ISSN: 14712105. DOI: 10.1186/1471-2105-8-25.
- STROHMAYER, A. (2017). *NUnmanned Aerial Systems – Auslegung, Einsatzbereiche und operative Rahmenbedingungen* Title. Bd. 86. DVW-Schriftenreihe. Augsburg.
- SUCCOW, M. und H. JOOSTEN (2001). *Landschaftsoekologische Moorkunde*. 2. Auflage. Stuttgart: Schweizerbart Science Publishers. ISBN: 978-3510651986.
- SUN, C., S. FAGHERAZZI und Y. LIU (2018). “Classification mapping of salt marsh vegetation by flexible monthly NDVI time-series using Landsat imagery”. In: *Estuarine, Coastal and Shelf Science* 213, S. 61–80. ISSN: 02727714. DOI: 10.1016/j.ecss.2018.08.007.
- SUN, L. und Z. ZHU (2017). “Using structured decision making and remote sensing to help implement ecological restoration of degraded mud flat ecosystem”. In: *2017 6th International Conference on Agro-Geoinformatics*. IEEE, S. 1–5. ISBN: 978-1-5386-3884-2. DOI: 10.1109/Agro-Geoinformatics.2017.8047009.
- SYVITSKI, J. P. M., A. J. KETTNER, I. OVEREEM, E. W. H. HUTTON, M. T. HANNON, G. R. BRAKENRIDGE, J. DAY, C. VÖRÖSMARTY, Y. SAITO, L. GIOSAN und R. J. NICHOLLS (2009). “Sinking deltas due to human activities”. In: *Nature Geoscience* 2.10, S. 681–686. ISSN: 1752-0894. DOI: 10.1038/ngeo629.
- TANG, L. und G. SHAO (2015). “Drone remote sensing for forestry research and practices”. In: *Journal of Forestry Research* 26.4, S. 791–797. ISSN: 1007-662X. DOI: 10.1007/s11676-015-0088-y.
- TEMMERMAN, S., P. MEIRE, T. J. BOUMA, P. M. J. HERMAN, T. YSEBAERT und H. J. DE VRIEND (2013). “Ecosystem-based coastal defence in the face of global change”. In: *Nature* 504.7478, S. 79–83. ISSN: 0028-0836. DOI: 10.1038/nature12859.
- THENKABAIL, P. S., J. G. LYON und A. HUETE (2012). *Hyperspectral remote sensing of vegetation*. English. CRC Press. ISBN: 978-1-4398-4538-7,978-1-4398-4537-0,1439845387,1439845379.
- THOMAS, V., P. TREITZ, D. JELINSKI, J. MILLER, P. LAFLEUR und J. MCCAUGHEY (2003). “Image classification of a northern peatland complex using spectral and plant community data”. In: *Remote Sensing of Environment* 84.1, S. 83–99. ISSN: 00344257. DOI: 10.1016/S0034-4257(02)00099-8.
- TIEMEYER, B., E. ALBIAC BORRAZ, J. AUGUSTIN, M. BECHTOLD, S. BEETZ, C. BEYER, M. DRÖSLER, M. EBELI, T. EICKENSCHIEDT, S. FIEDLER, C. FÖRSTER, A. FREIBAUER, M. GIEBELS, S. GLATZEL, J. HEINICHEN, M. HOFFMANN, H. HÖPER, G. JURASINSKI, K. LEIBER-SAUHEITL, M. PEICHL-BRAK, N. ROSSKOPF, M. SOMMER und J. ZEITZ (2016). “High emissions of greenhouse gases

- from grasslands on peat and other organic soils”. In: *Global Change Biology* 22.12, S. 4134–4149. ISSN: 13541013. DOI: 10.1111/gcb.13303.
- TIMM, B. C. und K. MCGARIGAL (2012). “Fine-scale remotely-sensed cover mapping of coastal dune and salt marsh ecosystems at Cape Cod National Seashore using Random Forests”. In: *Remote Sensing of Environment* 127, S. 106–117. ISSN: 00344257. DOI: 10.1016/j.rse.2012.08.033.
- TIMMERMANN, T., H. JOOSTEN und M. SUCCOW (2009). “Restaurierung von Mooren”. In: *Renaturierung von Ökosystemen in Mitteleuropa*. Hrsg. von S. ZERBE und G. WIEGLEB. Heidelberg: Spektrum Akademischer Verlag. Kap. Restaurier, S. 55–93. ISBN: 978-3-8274-1901-9. DOI: 10.1007/978-3-8274-2161-6.
- TIMMERMANN, T., K. MARGÓCZI, G. TAKÁCS und K. VEGELIN (2006). “Restoration of peat-forming vegetation by rewetting species-poor fen grasslands”. In: *Applied Vegetation Science* 9.2, S. 241–250. ISSN: 14022001. DOI: 10.1111/j.1654-109X.2006.tb00673.x.
- TINER, R. W., M. W. LANG und V. V. KLEMAS (2015). *Remote Sensing of Wetlands: Applications and Advances*. CRC Press. ISBN: 978-1-4822-3738-2. URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4157423>.
- TORABI HAGHIGHI, A., M. W. MENBERU, H. DARABI, J. AKANEGBU und B. KLØVE (2018). “Use of remote sensing to analyse peatland changes after drainage for peat extraction”. In: *Land Degradation & Development* 29.10, S. 3479–3488. ISSN: 10853278. DOI: 10.1002/ldr.3122.
- TÖRÖK, Á., G. BÖGÖLY, Á. SOMOGYI und T. LOVAS (2020). “Application of UAV in Topographic Modelling and Structural Geological Mapping of Quarries and Their Surroundings—Delineation of Fault-Bordered Raw Material Reserves”. In: *Sensors* 20.2, S. 489. ISSN: 1424-8220. DOI: 10.3390/s20020489.
- TORRESAN, C., A. BERTON, F. CAROTENUTO, S. F. DI GENNARO, B. GIOLI, A. MATESE, F. MIGLIETTA, C. VAGNOLI, A. ZALDEI und L. WALLACE (2017). “Forestry applications of UAVs in Europe: a review”. In: *International Journal of Remote Sensing* 38.8-10, S. 2427–2447. ISSN: 0143-1161. DOI: 10.1080/01431161.2016.1252477.
- TOTH, C. und G. JÓZKÓW (2016). “Remote sensing platforms and sensors: A survey”. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 115, S. 22–36. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2015.10.004.
- TSOUROS, D. C., S. BIBI und P. G. SARIGIANNIDIS (2019). “A Review on UAV-Based Applications for Precision Agriculture”. In: *Information* 10.11, S. 349. ISSN: 2078-2489. DOI: 10.3390/info10110349.
- TUBIELLO, F., R. BIANCALANI, M. SALVATORE, S. ROSSI und G. CONCHEDDA (2016). “A Worldwide Assessment of Greenhouse Gas Emissions from Drained Organic Soils”. In: *Sustainability* 8.4, S. 371. ISSN: 2071-1050. DOI: 10.3390/su8040371.
- TUCKER, C. J. (1979). “Red and photographic infrared linear combinations for monitoring vegetation”. In: *Remote Sensing of Environment* 8.2, S. 127–150. ISSN: 00344257. DOI: 10.1016/0034-4257(79)90013-0.
- TURETSKY, M. R., B. BENSCOTER, S. PAGE, G. REIN, G. R. van der WERF und A. WATTS (2015). “Global vulnerability of peatlands to fire and carbon loss”. In: *Nature Geoscience* 8.1, S. 11–14. ISSN: 1752-0894. DOI: 10.1038/ngeo2325.

- TUUKKANEN, T., L. STENBERG, H. MARTTILA, L. FINÉR, S. PIIRAINEN, H. KOIVUSALO und B. KLØVE (2016). “Erosion mechanisms and sediment sources in a peatland forest after ditch cleaning”. In: *Earth Surface Processes and Landforms* 41.13, S. 1841–1853. ISSN: 01979337. DOI: 10.1002/esp.3951.
- VRIELING, A., A. K. SKIDMORE, T. WANG, M. MERONI, B. J. ENS, K. OOSTERBEEK, B. O’CONNOR, R. DARVISHZADEH, M. HEURICH, A. SHEPHERD und M. PAGANINI (2017). “Spatially detailed retrievals of spring phenology from single-season high-resolution image time series”. In: *International Journal of Applied Earth Observation and Geoinformation* 59, S. 19–30. ISSN: 0303-2434. DOI: <http://dx.doi.org/10.1016/j.jag.2017.02.021>.
- WAN, H., Q. WANG, D. JIANG, J. FU, Y. YANG und X. LIU (2014). “Monitoring the Invasion of *Spartina alterniflora* Using Very High Resolution Unmanned Aerial Vehicle Imagery in Beihai, Guangxi (China)”. In: *The Scientific World Journal* 2014, S. 1–7. ISSN: 2356-6140. DOI: 10.1155/2014/638296.
- WANG, C., M. MENENTI, M.-P. STOLL, E. BELLUCO und M. MARANI (2007). “Mapping mixed vegetation communities in salt marshes using airborne spectral data”. In: *Remote Sensing of Environment* 107.4, S. 559–570. ISSN: 00344257. DOI: 10.1016/j.rse.2006.10.007.
- WANG, W., X. YANG, G. LIU, H. ZHOU, W. MA, Y. YU und Z. LI (2016). “RANDOM FOREST CLASSIFICATION OF SEDIMENTS ON EXPOSED INTERTIDAL FLATS USING ALOS-2 QUAD-POLARIMETRIC SAR DATA”. In: *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLI-B8, S. 1191–1194. ISSN: 2194-9034. DOI: 10.5194/isprsarchives-XLI-B8-1191-2016.
- WASSERSTRASSEN- UND SCHIFFFAHRTSVERWALTUNG DES BUNDES (2020). *Download der Geodaten - Auswahl: Portal Tideelbe*. URL: https://www.kuestendaten.de/Tideelbe/DE/Service/Kartenthemen/Kartenthemen_node.html.
- WEISS, A. D. (2001). “Topographic Position and Landforms Analysis (poster)”. In: *ESRI International User Conference*. San Diego. URL: file:///E:/GoogleDrive/A000_LESEN/Wilson-MarGeo-2007.pdf.
- WESTERGAARD-NIELSEN, A., M. LUND, B. U. HANSEN und M. P. TAMSTORF (2013). “Camera derived vegetation greenness index as proxy for gross primary production in a low Arctic wetland area”. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 86, S. 89–99. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2013.09.006.
- WILSON, M. F. J., B. O’CONNELL, C. BROWN, J. C. GUINAN und A. J. GREHAN (2007). “Multiscale Terrain Analysis of Multibeam Bathymetry Data for Habitat Mapping on the Continental Slope”. In: *Marine Geodesy* 30.1-2, S. 3–35. ISSN: 0149-0419. DOI: 10.1080/01490410701295962.
- WOLD, H. (1985). “Partial Least Squares”. In: *Encyclopedia of the Statistical Sciences*. 6. Aufl. New York: John Wiley & Sons, Inc., S. 581–591.
- WONG, P., I. LOSADA, J.-P. GATTUSO, J. HINKEL, A. KHATTABI, K. MCINNES, Y. SAITO und A. SALLENGER (2014). “Coastal systems and low-lying areas”. In: *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Hrsg. von C. FIELD, V. BARROS, D. DÖKKEN, K. MACH, M. MASTRANDREA, T. BILIR, M. CHAT-

- TERJEE, K. EBI, Y. ESTRADA, R. GENOVA, B. GIRMA, E. KISSEL, A. LEVY, S. MACCRACKEN, P. MASTRANDREA und L. WHITE. Cambridge, United Kingdom und New York, NY, USA. Kap. 5, S. 361–409.
- WOODWARD, R. T. und Y.-S. WUI (2001). “The economic value of wetland services: a meta-analysis”. In: *Ecological Economics* 37.2, S. 257–270. ISSN: 09218009. DOI: 10.1016/S0921-8009(00)00276-7.
- XIE, Y., Z. SHA und M. YU (2008). “Remote sensing imagery in vegetation mapping: a review”. In: *Journal of Plant Ecology* 1.1, S. 9–23. ISSN: 1752-9921. DOI: 10.1093/jpe/rtm005.
- XUE, J. und B. SU (2017). “Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications”. In: *Journal of Sensors* 2017, S. 1–17. ISSN: 1687-725X. DOI: 10.1155/2017/1353691.
- YANG, S. L., B. W. SHI, T. J. BOUMA, T. YSEBAERT und X. X. LUO (2012). “Wave Attenuation at a Salt Marsh Margin: A Case Study of an Exposed Coast on the Yangtze Estuary”. In: *Estuaries and Coasts* 35.1, S. 169–182. ISSN: 1559-2723. DOI: 10.1007/s12237-011-9424-4.
- YAO, H., R. QIN und X. CHEN (2019). “Unmanned Aerial Vehicle for Remote Sensing Applications—A Review”. In: *Remote Sensing* 11.12, S. 1443. ISSN: 2072-4292. DOI: 10.3390/rs11121443.
- YU, Z., J. LOISEL, D. P. BROSSEAU, D. W. BEILMAN und S. J. HUNT (2010). “Global peatland dynamics since the Last Glacial Maximum”. In: *Geophysical Research Letters* 37.13, n/a–n/a. ISSN: 00948276. DOI: 10.1029/2010GL043584.
- ZEDLER, J. B. und S. KERCHER (2005). “WETLAND RESOURCES: Status, Trends, Ecosystem Services, and Restorability”. In: *Annual Review of Environment and Resources* 30.1, S. 39–74. ISSN: 1543-5938. DOI: 10.1146/annurev.energy.30.050504.144248.
- ZHANG, H., Q. LI, J. LIU, J. SHANG, X. DU, H. MCNAIRN, C. CHAMPAGNE, T. DONG und M. LIU (2017). “Image Classification Using RapidEye Data: Integration of Spectral and Textual Features in a Random Forest Classifier”. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10.12, S. 5334–5349. ISSN: 1939-1404. DOI: 10.1109/JSTARS.2017.2774807.
- ZHANG, Q., R. QIN, X. HUANG, Y. FANG und L. LIU (2015). “Classification of Ultra-High Resolution Orthophotos Combined with DSM Using a Dual Morphological Top Hat Profile”. In: *Remote Sensing* 7.12, S. 16422–16440. ISSN: 2072-4292. DOI: 10.3390/rs71215840.

Abbildungsverzeichnis

| | | |
|-----|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 1.1 | Auswirkungen und Effekte auf sensible Ökosysteme. Rasterproben- nahmen (obere Reihe, vorher, während der Probennahme und da- nach) in einem wiedervernässten Moor. Repräsentationsprobleme ei- ner Dauerbeobachtungsflächen (untere Reihe) in einem entwässerten Niedermoor, welches außerhalb der Untersuchungsfläche beweidet wird. | 5 |
| 3.1 | Treibhausgas-Emissionen (in Tonnen CO ₂ -Äquivalente) in MV pro Jahr (verändert nach HIRSCHMANN et al. [2020]) | 19 |
| 3.2 | Übersicht der drei Niedermoor-Standorte an denen klassifikative Ve- getationsarbeiten auf Basis von multisensoralen Drohnendaten durch- geführt wurden. PaW = Versumpfungsmoor Hüttelmoor, PW = Durch- strömungsmoor, CDCW = Küstenüberflutungsmoor. | 21 |
| 3.3 | Untersuchungsgebiet PW, ein wiedervernässtes Durchströmungsmoor bei Tribsees (MV). | 22 |
| 3.4 | Untersuchungsgebiet CDCW, ein Küstenüberflutungsmoor auf den Karrendorfer Wiesen (MV). Multispektrale UAS-Aufnahme vom 04.05.2018 (Color-Infrarot-Darstellung) | 23 |
| 3.5 | <i>Karrendorfer Wiesen</i> (a) landwirtschaftlich geprägt (Landsat 5-Aufnahme, 31.07.1986, Bandkombination 4 3 2) und (b) ausgedeicht bzw. wieder- vernässt (Landsat 8-Aufnahme, 02.06.2017, Bandkombination 5 4 3). Das gelbe Rechteck markiert die Lage des Untersuchungsgebietes. . . | 24 |
| 3.6 | Multispektrale UAS-Aufnahme vom 01.11.2018 vom Untersuchungs- gebiet Versumpfungsmoor Hüttelmoor. | 25 |
| 3.7 | <i>Hüttelmoor</i> (a) landwirtschaftlich geprägt (Landsat 5-Aufnahme, 21.06.1984, Bandkombination 4 3 2) und (b) wiedervernässt (Landsat 8-Aufnahme, 28.06.2018, Bandkombination 5 4 3). Das gelbe Rechteck markiert die Lage des Untersuchungsgebietes. | 25 |
| 3.8 | Tagesmitteltemperaturen (a), kumulierte Niederschläge (b), kumu- lierte Globalstrahlung (c) und Wasserstände über Geländeoberkante (d) im Jahresverlauf. Die schwarze Line repräsentiert die Messwerte 2018 und die graue Fläche repräsentiert den Wertebereich (Minimum- Maximum) der Referenzperiode 1999—2017 bzw. 2010—2017 für die Wasserstände. [BEYER et al. 2020]. | 27 |
| 3.9 | Schematische Darstellung der stratigraphischen Ausbildung der Ve- getationsgürtel der dominanten Pflanzen <i>Phragmites australis</i> (PA), <i>Bolboschoenus maritimus</i> (BM), <i>Schoenoplectus tabernaemontani</i> (ST). (PhA = <i>Phalaris arundinacea</i> , W = Watt) | 30 |

| | | |
|------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 3.10 | Untersuchungsstandorte des Projektes <i>tibass</i> Balje und Hollerwettern am tide-beeinflussten Elbe-Ästuar (Datengrundlage: Basisdaten Elbe-Strom vom WASSERSTRASSEN- UND SCHIFFFAHRTSVERWALTUNG DES BUNDES [2020]), Landesgrenzen und Siedlungsflächen DLM250 vom BUNDESAMT FÜR KARTOGRAPHIE UND GEODÄSIE [2020] | 32 |
| 3.11 | Fotos (GRENZDÖRFFER UND BEYER 2017) vom Untersuchungsgebiet Balje. Der Holzrahmen ist 40 x 40 cm und wurde genutzt um die Parameter an jedem Punkt zu erheben. | 34 |
| 3.12 | Fotos (GRENZDÖRFFER UND BEYER 2017) vom Untersuchungsgebiet Hollerwettern. Der Holzrahmen ist 40 x 40 cm und wurde genutzt um die Parameter an jedem Punkt zu erheben. | 35 |
| 4.1 | Das genutzte UAS war Starrflügler, eine SenseFly eBee Plus, mit den drei einbaubaren Sensoren SenseFly S.O.D.A. (RGB), Parrot Sequoia (Multispektralkamera) und SenseFly ThermoMap (Thermalkamera). Neben der Kamera (unten links) sind auf 4.1c auch noch der Irradianzsensor und die Referenzplatte für die radiometrische Korrektur der Multispektraldaten abgebildet. (Fotos: FLORIAN BEYER 2017/2020) | 38 |
| 4.2 | Kartierte Flächen der dominanten Arten für PW und CDCW (Kartierer: CARL BARNICK und MORITZ KAISER, Universität Greifswald). In gestrichelten Polygonen sind die extrahierten Trainings- und Validierungsdaten dargestellt. | 44 |
| 4.3 | (a) Aufnahmepunkte, an denen der Pflanzenbestand und deren Flächenanteile in 1 m Radius aufgenommen wurden (Kartierer: DR. FRANZISKA KOEBSCH und BIRGIT SCHRÖDER, Universität Rostock). Gleichfarbige dominante Arten wurden nach KOCH et al. [2017] zusammengefasst oder waren nicht differenzierbar. <i>Rest</i> ist eine zusammengefasste Klasse von allen nicht dominant auftretenden Pflanzenarten. (b) Die Trainings- und Validierungsflächen, die aus (a) abgeleitet wurden. | 47 |
| 4.4 | Beprobungspunkte auf den <i>tibass</i> -Standorten BAL und HOL (BM = <i>Bolboschoenus maritimus</i> , ST = <i>Schoenoplectus tabernaemontani</i> , PA = <i>Phragmites australis</i> und PaH = <i>Phalaris arundinacea</i> ; Basisdaten Elbe-Strom vom WASSERSTRASSEN- UND SCHIFFFAHRTSVERWALTUNG DES BUNDES [2020]; RGB-Orthomosaike von UAS-Befliegung 09./10.08.2017). | 49 |
| 5.1 | Arbeitsschritte für die Vorprozessierung der UAS-Daten zur Generierung des multisensoralen Datensatzes (DOM = Digitales Oberflächenmodell). | 52 |
| 5.2 | Vereinfachte Darstellung der einzelnen Phasen des photogrammetrischen Prozesses. | 53 |
| 5.3 | Arbeitsschema zur Klassifikation eines multisensoralen Datensatzes mithilfe des <i>Random Forest</i> (RF). | 58 |
| 5.4 | Schematische Darstellungen eines (a) <i>Decision Trees</i> (DT) und (b) eines <i>Random Forest</i> (RF). Der N-te DT steht für die Anzahl an Bäumen bzw. DTs im RF. | 60 |

| | | |
|------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 5.5 | Arbeitsschema für die Verwendung des PLSR-Regressionsverfahren auf einem multisensoralen Datensatz. | 65 |
| 5.6 | Beispiel eines Diagramms zur Selektion der finalen Anzahl an latenten Variablen bzw. PLSR-Komponenten, ermittelt aus der LOOCV und dem MSE. Das rote Kreuz markiert die selektierte Anzahl an Komponenten, die für das finale Training genutzt wurden. | 70 |
| 6.1 | Vergleich verschiedener Baumzahlen im <i>Random Forest</i> anhand des Untersuchungsgebietes PW (OOB = <i>Out-of-Bag-Error</i> , OAA = <i>Overall Accuracy</i> , rot = Baumanzahl). | 75 |
| 6.2 | Multisensorale Mittelwertspektren der Klassen von PW (6.2a) und CDCW (6.2b). | 76 |
| 6.3 | Ergebnisse der RF-Klassifikation für PW und CDCW. Gesamtgenauigkeit der Klassifikationen von PW OAA = 89,3 % und CDCW OAA = 88,3 %. Die Auswahl der Farben für die Klassen wurde nach HARROWER und BREWER [2003] getroffen. | 78 |
| 6.4 | Spektrale Unterschiede von <i>Agrostis stolonifera</i> je nach Standort CD (<i>Agrostis</i> I) oder CW (<i>Agrostis</i> II). | 80 |
| 6.5 | Benutzer- und Produzentengenauigkeit aller Klassen der Standorte PW und CDCW. | 82 |
| 6.6 | Exemplarische Höhenprofile durch das DOM von PW. | 86 |
| 6.7 | Exemplarische Höhenprofile durch das DOM von CDCW. | 87 |
| 6.8 | Kanalrelevanz in Abhängigkeit zur Anzahl der verwendeten Bäume im RF, durchgeführt mit dem multisensoralen Datensatz von PW. | 89 |
| 6.9 | Klassifikationsergebnis für PaW. (Die Klassenfarben sind optimiert für die digitale Betrachtung am Bildschirm und können gedruckt eventuell nicht hinreichend differenziert werden. Die Graphik ist im Digitalverzeichnis unter <i>Arbeit/Abbildungen/06_Ergebnisse/PaW_rfclass_map.pdf</i> zu finden.) | 92 |
| 6.10 | Zusammensetzung der dominanten Vegetationsarten 2014 (6.10a) aus KOCH et al. [2017] und nach der Dürre 2018 (6.10b). | 93 |
| 6.11 | Benutzer- und Produzentengenauigkeiten aller Klassen der Klassifikation von PaW. | 94 |
| 6.12 | Exemplarische Höhenprofile durch das DOM von PaW. | 96 |
| 6.13 | Korrelationsmatrix aller berechneten Indizes für PaW. Da die hohe Anzahl an Indizes und Korrelationskoeffizienten den verfügbaren Platz der A4-Seite übersteigt, kann die Graphik im Digitalverzeichnis oder online bei Zenodo ⁵ abgerufen werden. | 104 |
| 6.14 | Cluster-Matrix der Korrelationsmatrix aller berechneten Indizes (Vollständige Auflösung <i>Dissertation/Arbeit/Abbildungen/...pdf</i> und Zenodo ⁶) | 105 |
| 6.15 | Dendrogramm der Cluster-Matrix aller berechneten Indizes. Die gestrichelte schwarze Linie markiert den Schwellwert 1,5. | 106 |
| 6.16 | Mit RTK-GNSS eingemessene Normalhöhen für BAL und HOL (BM = <i>Bolboschoenus maritimus</i> , ST = <i>Schoenoplectus tabernaemontani</i> , PA = <i>Phragmites australis</i> , PhA = <i>Phalaris arundinacea</i>). | 110 |
| 6.17 | Anzahl der Pflanzen im definierten Kartierrahmen von 40 x 40 cm für BAL und HOL. | 110 |

| | | |
|------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 6.18 | Im Gelände (links) und Labor (rechts) gemessene Pflanzenhöhen für BAL und HOL. | 111 |
| 6.19 | Im Gelände und Labor gemessene Stängeldurchmesser für BAL und HOL. | 111 |
| 6.20 | Photosynthetisch aktive Strahlung (PAR) für BAL und HOL. | 112 |
| 6.21 | Frisch- und Trockenmasse pro Pflanze (oben) und hochgerechnet auf die 40 x 40 cm des Kartierrahmens (Mitte) und Wassergehalt in % (unten). | 113 |
| 6.22 | Geclusterte Korrelationsmatrix und Dendrogramme der gemessenen und berechneten Parameter aus Gelände und Labor für BAL (6.22a) und HOL (6.22b; Abkürzungen siehe Tabelle 4.8, Seite 50). | 115 |
| 6.23 | Gegenüberstellung der Messungen der Pflanzenhöhen im Gelände und im Labor für BAL und HOL. Die Messwerte sind weiterhin nach dominanter Pflanzenart unterschieden (BM = <i>Bolboschoenus maritimus</i> , ST = <i>Schoenoplectus tabernaemontani</i> , PA = <i>Phragmites australis</i> , PaH = <i>Phalaris arundinacea</i>) | 116 |
| 6.24 | Ergebnisse der PLSR für den Parameter Geländehöhe (NHN) des Standortes BAL. (a) Vorhergesagte Karte der Geländehöhe in m ü. NHN. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells. | 119 |
| 6.25 | Ergebnisse der PLSR für den Parameter Geländehöhe (NHN) des Standortes HOL. (a) Vorhergesagte Karte der Geländehöhe in m ü. NHN. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells. | 120 |
| 6.26 | Ergebnisse der PLSR für den Parameter Pflanzenhöhe gemessen im Labor des Standortes BAL. (a) Vorhergesagte Karte der Pflanzenhöhen in cm. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells. | 122 |
| 6.27 | Ergebnisse der PLSR für den Parameter Pflanzenhöhe gemessen im Gelände des Standortes BAL. (a) Vorhergesagte Karte der Pflanzenhöhen in cm. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells. | 123 |
| 6.28 | Ergebnisse der PLSR für den Parameter Pflanzenhöhe gemessen im Gelände des Standortes HOL. (a) Vorhergesagte Karte der Pflanzenhöhen in cm. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kreuzvalidierten PLSR-Modells. | 125 |

| | | |
|------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 6.29 | Differenzkarten zwischen den Pflanzenhöhen, die sich aus der Differenz des DOM und der Geländehöhe (PLSR-NHN) ergaben, und der Pflanzenhöhenkarte (PLSR-PHG). Grüne Werte sind niedrige, blaue sind hohe negative und rote sind hohe positive Differenzen. | 126 |
| 6.30 | Ergebnisse der PLSR für den Parameter Wassergehalt der Pflanzen des Standortes BAL. (a) Vorhergesagte Karte des Wassergehalts der Pflanzen in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kruzvalidierten PLSR-Modells. | 127 |
| 6.31 | Ergebnisse der PLSR für den Parameter Wassergehalt der Pflanzen des Standortes HOL. (a) Vorhergesagte Karte des Wassergehalts der Pflanzen in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kruzvalidierten PLSR-Modells. | 128 |
| 6.32 | Vergleich der Wassergehalte der drei Zonen der dominanten Pflanzenarten (ST = <i>Schoenoplectus tabernaemontani</i> , BM = <i>Bolboschoenus maritimus</i> , PA = <i>Phragmites australis</i>) pro Standort. Die Selektion der Pixel erfolgte randomisiert innerhalb der jeweiligen Zone und stellt somit nicht die Gesamtanzahl dar. | 129 |
| 6.33 | Ergebnisse der PLSR für den Parameter photosynthetisch aktive Strahlung des Standortes BAL. (a) Vorhergesagte Karte der photosynthetisch aktiven Strahlung in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kruzvalidierten PLSR-Modells. | 130 |
| 6.34 | Ergebnisse der PLSR für den Parameter photosynthetisch aktive Strahlung des Standortes HOL. (a) Vorhergesagte Karte der photosynthetisch aktiven Strahlung in %. (b) Anzahl der selektierten PLSR-Komponenten gemessen am mittleren quadrierten Fehler (MSE, das rote Kreuz markiert die selektierte Anzahl mit dem niedrigsten MSE). (c) Performanz des kruzvalidierten PLSR-Modells. | 131 |
| 6.35 | Relevanz der einzelnen Kanäle der erweiterten multisensoralen Datensätze für (a) BAL und (b) HOL und die jeweilig selektierten Parameter. Die grau hinterlegten Bereiche heben die wichtigsten Kanäle hervor. | 133 |
| 6.36 | Kumulierte Relevanzen nach Kanaltyp für (a) BAL und (b) HOL (Orig = Originalkanäle, Spek = Spektralindex, Tex = Texturindex, Rel = Reliefindex). | 134 |
| 6.37 | Regressionen zwischen NHN und ausgewählten Parametern für BAL. | 136 |
| 6.38 | Regressionen zwischen NHN und ausgewählten Parametern für HOL. | 137 |
| 6.39 | Regressionen zwischen PWG und anderen Parametern in BAL | 138 |
| 6.40 | Regressionen zwischen PWG und anderen Parametern in HOL | 139 |
| 6.41 | Regressionen zwischen Pflanzenhöhen und Frischmassen für BAL. . . | 140 |
| 6.42 | Regressionen zwischen Pflanzenhöhen und Trockenmassen für BAL. . | 141 |
| 6.43 | Regressionen zwischen Pflanzenhöhen und Pflanzenmassen für HOL. . | 142 |

| | | |
|------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 6.44 | Ergebnisse der linearen Regression für den Parameter Stängeldurchmesser in mm für BAL und HOL abgeleitet aus der Geländehöhe (PLSR-NHN). (a) und (c) sind die vorhergesagten Karten, (b) und (d) die Performanzdiagramme der jeweiligen Modelle für BAL und HOL. | 143 |
| 6.45 | Ergebnisse der linearen Regression für den Parameter Trockenmasse in g pro Pflanze für BAL und HOL abgeleitet aus dem Wassergehalt (PLSR-PWG). (a) und (c) sind die vorhergesagten Karten, (b) und (d) die Performanzdiagramme der jeweiligen Modelle für BAL und HOL. | 144 |
| 6.46 | Ergebnisse der linearen Regression für den Parameter Trockenmasse in g pro Pflanze für BAL und HOL abgeleitet aus der Pflanzenhöhe (PLSR-PHL). (a) ist die vorhergesagte Karte und (b) die Performanz des Modells. | 145 |
| 6.47 | Ergebnisse der linearen Regression für den Parameter Trockenmasse in g pro 40 x 40 cm für BAL abgeleitet (a) aus dem Wassergehalt (PLSR-PWG) und (c) aus den Pflanzenhöhen (PLSR-PHL). (b) und (d) sind die Performanzdiagramme der Modelle. | 146 |
| 6.48 | Ergebnisse der linearen Regression für die Parameter Frischmasse (a) in g pro Pflanze und (c) in g pro 40 x 40 cm für BAL abgeleitet aus der Pflanzenhöhe (PLSR-PHL). (b) und (d) sind die Performanzdiagramme der Modelle. | 147 |
| A.1 | Photogrammetrischer Prozess: <i>Feature Extraction</i> / Merkmalsextraktion. Beispiel für ein einzelnes Bild. Die orangefarbenen Kreuze stellen die gefundenen Merkmale (features) dar, die in einem Bild gefunden wurden. | 199 |
| A.2 | Photogrammetrischer Prozess: <i>Feature Matching</i> / Merkmalszuordnung. Das grüne Kreuz zeigt eines der extrahierten Merkmale in zehn verschiedenen Bildern nach der Merkmalszuordnung. | 200 |
| A.3 | Photogrammetrischer Prozess: <i>Multi Ray Matching</i> und <i>Sparse Reconstruction</i> / Erstellung der groben Punktwolke. Jedes Merkmal kann im Raum dargestellt werden und zu allen Bildern zurückverfolgt werden. Die Pyramiden zeigen die Position und Ausrichtung des UAS und die jeweilige Aufnahme. | 200 |
| A.4 | Photogrammetrischer Prozess: <i>Dense Reconstruction</i> / Erstellung der dichten Punktwolke. Die grobe Punktwolke (A.4a) kann mit den unverorteten Pixelwerten zur dichten Punktwolke (A.4b) mittels Vorwärtsschnitt berechnet werden. | 201 |
| A.5 | Photogrammetrischer Prozess: Endprodukte sind zum einen das Digitale Orthomosaik (A.5b) und das Digitale Oberflächenmodell (A.5a). | 202 |
| A.6 | Beispiel von Maptor (Version 1.4beta, 11.11.2020) für eine PLSR für kleine Probenahmenumfang unter Nutzung der <i>Leave-One-Out Cross Validation</i> (Links: Haupt- und Prozess-Fenster, Mitte: Auswahlfenster Regressionsverfahren und Regressionsfenster, Rechts: Ergebnisreport mit Validierungsergebnissen). | 203 |

| | | |
|------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| A.7 | Photogrammetrisch prozessierte Orthomosaike für PW (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen) | 207 |
| A.8 | Photogrammetrisch prozessierte Orthomosaike für CDCW (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen) | 208 |
| A.9 | Photogrammetrisch prozessierte Orthomosaike für PaW (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen) | 209 |
| A.10 | Photogrammetrisch prozessierte Orthomosaike für BAL (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen) | 210 |
| A.11 | Photogrammetrisch prozessierte Orthomosaike für HOL (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen) | 211 |
| A.12 | Korrelationsmatrix aller berechneten Indizes für PW. Link zur digitalen Graphik in Tabelle A.10. | 219 |
| A.13 | Korrelationsmatrix aller berechneten Indizes für CDCW. Link zur digitalen Graphik in Tabelle A.10. | 220 |
| A.14 | Cluster-Matrix der Korrelationsmatrix aller berechneten Indizes für PW. Link zur digitalen Graphik in Tabelle A.10. | 221 |
| A.15 | Cluster-Matrix der Korrelationsmatrix aller berechneten Indizes für CDCW. Link zur digitalen Graphik in Tabelle A.10. | 222 |
| A.16 | Dendrogramm der Cluster-Matrix aller berechneten Indizes für (a) PW und (b) CDCW. Die gestrichelte schwarze Linie markiert den Schwellwert. | 223 |
| A.17 | Korrelationsmatrix der gemessenen und berechneten Parameter aus Gelände und Labor für BAL (A.17a) und HOL (A.17b). | 230 |
| A.18 | Regressionen zwischen PAR und den Pflanzhöhen von BAL und HOL | 231 |
| A.19 | Korrelationsmatrix BAL. Link zur digitalen Graphik in Tabelle A.19. | 233 |
| A.20 | Clustermatrix BAL. Link zur digitalen Graphik in Tabelle A.19. | 234 |
| A.21 | Korrelationsmatrix HOL. Link zur digitalen Graphik in Tabelle A.19. | 235 |
| A.22 | Clustermatrix HOL. Link zur digitalen Graphik in Tabelle A.19. | 236 |
| A.23 | Dendrogramme mit Distanzschwellwert 1,5 zur Selektion von Index-Clustern für BAL und HOL. | 237 |

Tabellenverzeichnis

| | | |
|-----|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 4.1 | Technische Spezifikationen für das UAS SenseFly eBee Plus [SENSEFLY 2020]. | 39 |
| 4.2 | Technische Spezifikationen [SENSEFLY 2020] des RGB-Sensors SenseFly S.O.D.A. | 39 |
| 4.3 | Technische Spezifikationen des Multispektralsensors Parrot Sequoia [SENSEFLY 2020]. | 41 |
| 4.4 | Technische Spezifikationen des Thermalsensors SenseFly thermoMAP [SENSEFLY 2020]. | 42 |
| 4.5 | Alle Standorte, die befliegen wurden, Tag der Befliegung und Anzahl der Einzelbilder der drei verwendeten Sensoren. | 43 |
| 4.6 | Finale Klassen für die Vegetationsverteilung der dominanten Arten für beide Standorte PW und CDCW. Die deutschen Namen der Pflanzen sind im Anhang A.1 in Tabelle A.1 zu finden. | 45 |
| 4.7 | Finale Klassen für die Vegetationsverteilung der dominanten Arten für den Standort PaW. Die deutschen Namen der Pflanzen sind im Anhang A.1 in Tabelle A.1 zu finden. | 48 |
| 4.8 | Gemessene Pflanzenparameter, Abkürzungen und Einheiten des Projektes tibass. | 50 |
| 5.1 | Übersicht der verwendeten spektralen Indizes im multisensoralen Datensatz (ρ_x = Reflexion im x ten Bereich des elektromagnetischen Spektrums, NIR = Nahes Infrarot, RE = Red Edge, GRN = Grünes Licht, BLA = Blaues Licht). | 56 |
| 5.2 | Multisensoraler Datensatz, bestehend aus 14 Kanälen. | 57 |
| 5.3 | Beispiel einer Konfusionsmatrix zur Beurteilung der Klassifikationen der Einzelklassen durch die Produzentengenauigkeit (PA) und Benutzergenauigkeit (UA) sowie für die Gesamtgenauigkeit (rot, OAA). (N = Anzahl der Klassen) | 63 |
| 6.1 | Überblick über verschiedene Parameter und Genauigkeiten für die einzelnen Orthomosaike nach der photogrammetrischen Prozessierung (— = Daten standen nicht mehr zur Verfügung). | 72 |
| 6.2 | Übersicht über alle multisensoralen Datensätze. | 73 |
| 6.3 | Gesamtzahl der Trainingspixel und deren Fläche (in m^2) für jede Klasse der beiden Testgebiete PW und CDCW. | 77 |
| 6.4 | Konfusionsmatrizen der unabhängigen Validierung der RF-Klassifikationen von PW (a) und CDCW (b). Zeilen entsprechen den klassifizierten Pixel und die Spalten den Klassen des Validierungsdatensatzes (Referenz-Pixel). | 81 |

| | | |
|------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 6.5 | Relevanz der Kanäle (Gini-Index GI) bei der RF-Klassifikation für beide Standorte PW und CDCW. | 84 |
| 6.6 | Sensorweise kumulierte Relevanzen der Kanäle mit Hilfe des Gini-Index (GI) für PW und CDCW. | 89 |
| 6.7 | Gesamtzahl der Trainingspixel und deren Fläche (in m ²) für jede Klasse von PaW. | 91 |
| 6.8 | Konfusionsmatrix der Klassifikation des 14-kanaligen multisensoralen Datensatzes von PaW. | 94 |
| 6.9 | Relevanz der Kanäle (Gini-Index GI) der RF-Klassifikation für den Standort PaW und sensorweise kumulierte Relevanzen der Kanäle. . . | 95 |
| 6.10 | Erweiterter multisensoraler Datensatz bestehend aus 98 Kanälen. In der jeweils letzten Spalte stehen entweder der Sensortyp (Sen.) oder aus welchen Sensordaten der jeweilige Kanal berechnet wurde (-> Gen. = Generiert aus). | 98 |
| 6.11 | Genutzte Texturindizes berechnet aus der GLCM. | 99 |
| 6.12 | Konfusionsmatrix der Klassifikation des erweiterten 98-kanaligen multisensoralen Datensatzes von PaW. | 100 |
| 6.13 | Relevanz der 98 Kanäle für die Klassifikation des erweiterten multisensoralen Datensatzes. Alle Indizes werden unter github.com/florianbeyer/SpectralIndices beschrieben. | 101 |
| 6.14 | Kumulierte GIs nach Sensor und Datentyp der Kanäle. | 102 |
| 6.15 | Selektierte Indizes aus den hochkorrelativen Index-Clustern für PaW. | 106 |
| 6.16 | Kanalzusammensetzung des selektierten multisensoralen Datensatzes und dessen Kanalrelevanzen für die RF-Klassifikation sortiert nach dem GI. | 107 |
| 6.17 | Kumulierte Relevanzen (GIs) nach Kanal- und Sensortyp. | 108 |
| 6.18 | Selektierte Indizes aus den hochkorrelativen Index-Clustern. | 117 |
| 6.19 | Ergebnisse der kreuzvalidierten PLSR-Modelle für BAL und HOL. Markiert sind die kreuzvalidierten Bestimmtheitsmaße (r_{CV}^2 , die über 0,5 erreichten (r_T^2 = Bestimmtheitsmaß des Trainings, n = Anzahl der verfügbaren Messwerte, Komp. = PLSR-Komponenten, die Qualitätsmaße sind in Abschnitt 5.3.1 beschrieben). | 118 |
| 6.20 | Deskriptive Statistik der vorhergesagten Pflanzhöhen gemessen im Labor und im Gelände für das gesamte Untersuchungsgebiet in BAL. | 124 |
| 6.21 | Vergleich der Wassergehalte der drei Zonen der dominanten Pflanzenarten (ST = <i>Schoenoplectus tabernaemontani</i> , BM = <i>Bolboschoenus maritimus</i> , PA = <i>Phragmites australis</i>). Die Selektion der Pixel erfolge randomisiert innerhalb der jeweiligen Zone und stellt somit nicht die Gesamtanzahl dar. | 129 |
| 6.22 | Selektierte Parameter die mithilfe der Regressionsgerade (Abb. = Abbildung)) auf die jeweilige PLSR-Karte übertragen werden. | 139 |
| 6.23 | Kanalrelevanzen (%) zusammengefasst und alphabetisch sortiert nach Kanalname. | 149 |
| 6.24 | Statistische Zusammenfassung der Kanalrelevanzen (%) sortiert nach dem Mittelwert. | 150 |

A.1 Alle in der Arbeit verwendeten Pflanzenarten mit wissenschaftlichen und deutschen Namen. 195

A.2 Komplette Kartierungsliste aller Pflanzenarten, die in PaW seit der Wiedervernässung kartiert wurden und deren Vorkommen 2018. (N = Anzahl der Vorkommen auf den 65 Aufnahmepunkten) 197

A.3 Selektion von in der Arbeit verwendeten Skripten bzw. *Jupyter Notebooks*. 205

A.4 Übersicht über alle Pakete, die für die Skripte in Python verwendet wurden. 206

A.5 Originale multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von PW 213

A.6 Normierte multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von PW. Die rot hervorgehobenen Werte wurden zwischen 0 und 1 normiert. 214

A.7 Originale multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von CDCW 215

A.8 Normierte multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von CDCW. Die rot hervorgehobenen Werte wurden zwischen 0 und 1 normiert. 216

A.9 Nach GI absteigend sortierte Kanalrelevanzen für PaW, die im erweiterten 98-kanäligen multisensoralen Datensatz verwendet wurden. . . 217

A.10 Die Korrelations- und Clustermatrizen für PW und CDCW können in voller Auflösung im Internet auf Zenodo betrachtet werden. 219

A.11 Selektierte Indizes aus den hochkorrelativen Index-Clustern für PW und CDCW. 224

A.12 Kanalzusammensetzung von PW und CDCW nach Cluster- und Selektionsverfahren. 225

A.13 Kanalrelevanzen (%) von PW für den erweiterten multisensoralen Datensatz. 226

A.14 Kanalrelevanzen (%) von CDCW für den erweiterten multisensoralen Datensatz. 227

A.15 Kumulierte Relevanzen (GIs) nach Kanal- und Sensortyp für PW. . . 227

A.16 Kumulierte Relevanzen (GIs) nach Kanal- und Sensortyp für CDCW. 228

A.17 Deskriptive Statistik der gemessenen und berechneten Parameter am Standort Balje. 229

A.18 Deskriptive Statistik der gemessenen und berechneten Parameter am Standort Hollerwettern. 229

A.19 Die Korrelations- und Clustermatrizen für PW und CDCW können in voller Auflösung im Internet auf Zenodo betrachtet werden. 233

A.20 Zusammensetzung der Kanäle der erweiterten multisensoralen Datensätze für HOL und BAL. 238

A.21 Prozentuale Kanalrelevanzen (*VIP* in %) der PLSR-Modelle ausgewählter Parameter für BAL. 239

A.22 Prozentuale Kanalrelevanzen (*VIP* in %) der PLSR-Modelle ausgewählter Parameter für HOL. 240

A.23 Kumulierte Relevanzen (*VIP* in %) nach Kanaltyp für BAL. 241

A.24 Kumulierte Relevanzen (*VIP* in %) nach Kanaltyp für HOL. 242

A.25 Kumulierte Relevanzen (*VIP* in %) nach Sensortyp für BAL und HOL.242

A Anhang

A.1 Pflanzennamen

Tabelle A.1: Alle in der Arbeit verwendeten Pflanzenarten mit wissenschaftlichen und deutschen Namen.

| Wissenschaftlicher Name | Deutscher Name |
|---------------------------------------|---------------------------------------|
| <i>Agrostis stolonifera</i> | Weißes Straußgras |
| <i>Bolboschoenus maritimus</i> | Gewöhnliche Strandsimse |
| <i>Deschampsia cespitosa</i> | Rasen-Schmiele |
| <i>Calamagrostis canescens</i> | Sumpf-Reitgras |
| <i>Calamagrostis epigejos</i> | Land-Reitgras |
| <i>Carex acuta</i> | Schlank-Segge |
| <i>Carex acutiformis</i> | Sumpf-Segge |
| <i>Carex riparia</i> | Ufer-Segge |
| <i>Carex rostrata</i> | Schnabel-Segge |
| <i>Elymus repens</i> | Kriech-Quecke |
| <i>Epilobium hirsutum</i> | Zottiges Weidenröschen |
| <i>Festuca rubra</i> | Rot-Schwingel |
| <i>Glyceria maxima</i> | Wasser-Schwaden |
| <i>Holcus lanatus</i> | Wolliges Honiggras |
| <i>Juncus effusus</i> | Flutter-Binse oder Flutter-Simse |
| <i>Juncus gerardii</i> | Bodden-Binse |
| <i>Juncus subnodulosus</i> | Stumpfbblütige Binse |
| <i>Lemna minor</i> | Kleine Wasserlinse |
| <i>Lolium perenne</i> | Deutsches Weidelgras |
| <i>Phalaris arundinacea</i> | Rohrglanzgras |
| <i>Phragmites australis</i> | Schilfrohr |
| <i>Ranunculus sceleratus</i> | Gift-Hahnenfuß |
| <i>Schoenoplectus tabernaemontani</i> | Salz-Teichbinse oder Salz-Teichsimse |
| <i>Sparganium erectum</i> | Ästige Igelkolben |
| <i>Tephrosieris palustris</i> | Moor-Greiskraut oder Moor-Aschenkraut |
| <i>Trifolium repens</i> | Weißklee |
| <i>Typha latifolia</i> | Breitblättrige Rohrkolben |

A.2 Kartierungsdaten vom Hütelmoor (PaW)

Tabelle A.2: Komplette Kartierungsliste aller Pflanzenarten, die in PaW seit der Wiedervernässung kartiert wurden und deren Vorkommen 2018. (N = Anzahl der Vorkommen auf den 65 Aufnahmepunkten)

| Nr. | Botanischer Name | N | Flächenanteile in % | | | | kumulativ |
|-----|----------------------------------------|----|---------------------|------|------|-------|-----------|
| | | | Min | MW | STD | Max | |
| 1 | <i>Schoenoplectus tabernaemontanii</i> | 24 | 1,0 | 30,2 | 25,3 | 80,0 | 725,0 |
| 2 | <i>Bolboschoenus maritimus</i> | 43 | 0,1 | 6,5 | 7,2 | 25,0 | 279,1 |
| 3 | <i>Typha latifolia</i> | 3 | 10,0 | 16,7 | 7,6 | 25,0 | 50,0 |
| 4 | <i>Carex acutiformis</i> | 3 | 1,0 | 22,0 | 33,0 | 60,0 | 66,0 |
| 5 | <i>Carex riparia</i> | 3 | 0,5 | 35,2 | 54,5 | 98,0 | 105,5 |
| 6 | <i>Rumex maritimus</i> | 18 | 0,1 | 2,5 | 3,1 | 12,0 | 44,1 |
| 7 | <i>Chenopodium rubrum</i> | 14 | 0,1 | 1,6 | 1,7 | 5,0 | 21,8 |
| 8 | <i>Ranunculus sceleratus</i> | 33 | 0,1 | 5,4 | 8,7 | 45,0 | 178,8 |
| 9 | <i>Tephrosieris palustris</i> | 30 | 0,1 | 10,1 | 11,9 | 50,0 | 303,6 |
| 10 | <i>Barbarea vulgaris</i> | 18 | 0,5 | 1,9 | 1,6 | 5,0 | 33,5 |
| 11 | <i>Juncus articulatus</i> | 3 | 0,1 | 0,4 | 0,2 | 0,5 | 1,1 |
| 12 | <i>Nasturtium officinale</i> | 2 | 0,5 | 1,8 | 1,8 | 3,0 | 3,5 |
| 13 | <i>Rumex hydrolapathum</i> | 2 | 2,0 | 3,5 | 2,1 | 5,0 | 7,0 |
| 14 | <i>Agrostis stolonifera</i> | 6 | 0,5 | 22,8 | 25,8 | 60,0 | 136,5 |
| 15 | <i>Phragmites australis</i> | 40 | 1,5 | 71,4 | 36,3 | 100,0 | 2857,5 |
| 16 | <i>Iris pseudacorus</i> | 1 | 35,0 | 35,0 | 0,0 | 35,0 | 35,0 |
| 17 | <i>Solanum dulcamara</i> | 2 | 0,1 | 0,6 | 0,6 | 1,0 | 1,1 |
| 18 | <i>Juncus effusus</i> | 5 | 0,2 | 11,4 | 19,2 | 45,0 | 57,2 |
| 19 | <i>Lemna minor</i> | 9 | 0,5 | 20,3 | 29,3 | 85,0 | 183,0 |
| 20 | <i>Phalaris arundinacea</i> | 1 | 10,0 | 10,0 | 0,0 | 10,0 | 10,0 |
| 21 | <i>Galium palustre</i> | 1 | 0,1 | 0,1 | 0,0 | 0,1 | 0,1 |
| 22 | <i>Rumex crispus</i> | 3 | 0,5 | 0,8 | 0,3 | 1,0 | 2,5 |
| 23 | <i>Mentha aquatica</i> | 2 | 0,5 | 2,8 | 3,2 | 5,0 | 5,5 |
| 24 | <i>Eurhynchium swartzii</i> | 2 | 0,1 | 0,6 | 0,6 | 1,0 | 1,1 |
| 25 | <i>Urtica dioica</i> | 3 | 0,1 | 2,0 | 1,7 | 3,0 | 6,1 |
| 26 | <i>Ranunculus repens</i> | 1 | 3,0 | 3,0 | 0,0 | 3,0 | 3,0 |
| 27 | <i>Potentilla anserina</i> | 2 | 0,5 | 1,3 | 1,1 | 2,0 | 2,5 |
| 28 | <i>Lycopus europaeus</i> | 1 | 1,0 | 1,0 | 0,0 | 1,0 | 1,0 |
| 29 | <i>Lythrum salicaria</i> | 1 | 0,5 | 0,5 | 0,0 | 0,5 | 0,5 |
| 30 | <i>Calystegia sepium</i> | 1 | 0,5 | 0,5 | 0,0 | 0,5 | 0,5 |
| 31 | <i>Vicia spec,</i> | 2 | 0,1 | 0,6 | 0,6 | 1,0 | 1,1 |
| 32 | <i>Epilobium palustre</i> | 1 | 0,5 | 0,5 | 0,0 | 0,5 | 0,5 |
| 33 | <i>Cirsium vulgare</i> | 1 | 1,0 | 1,0 | 0,0 | 1,0 | 1,0 |
| 34 | <i>Cirsium arvense</i> | 1 | 3,0 | 3,0 | 0,0 | 3,0 | 3,0 |
| 35 | <i>Hydrocotyle vulgaris</i> | 2 | 0,5 | 0,8 | 0,4 | 1,0 | 1,5 |
| 36 | <i>Polygonum amphibium</i> | 0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 |
| 37 | <i>Eleocharis</i> | 0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 |
| 38 | <i>Atriplex glabrascula</i> | 0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 |
| 39 | <i>Bidens fondosa</i> | 0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 |
| 40 | <i>Gnaphalium uliginosum</i> | 1 | 0,1 | 0,1 | 0,0 | 0,1 | 0,1 |

A.3 Photogrammetrischer Prozess

(a) Einzelbild vor der Merkmalsextraktion



(b) Einzelbild mit extrahierten Merkmalen




Abbildung A.1: Photogrammetrischer Prozess: *Feature Extraction* / Merkmalsextraktion. Beispiel für ein einzelnes Bild. Die orangefarbenen Kreuze stellen die gefundenen Merkmale (features) dar, die in einem Bild gefunden wurden.




Abbildung A.2: Photogrammetrischer Prozess: *Feature Matching* / Merkmalszuordnung. Das grüne Kreuz zeigt eines der extrahierten Merkmale in zehn verschiedenen Bildern nach der Merkmalszuordnung.





Abbildung A.3: Photogrammetrischer Prozess: *Multi Ray Matching* und *Sparse Reconstruction* / Erstellung der groben Punktwolke. Jedes Merkmal kann im Raum dargestellt werden und zu allen Bildern zurückverfolgt werden. Die Pyramiden zeigen die Position und Ausrichtung des UAS und die jeweilige Aufnahme.

(a) Grobe Punktwolke



(b) Dichte Punktwolke





Abbildung A.4: Photogrammetrischer Prozess: *Dense Reconstruction* / Erstellung der dichten Punktwolke. Die grobe Punktwolke (A.4a) kann mit den unverorteten Pixelwerten zur dichten Punktwolke (A.4b) mittels Vorwärtsschnitt berechnet werden.

(a) Digitales Oberflächenmodell (DOM)



(b) Digitales Orthomosaik (DOP)




Abbildung A.5: Photogrammetrischer Prozess: Endprodukte sind zum einen das Digitale Orthomosaik (A.5b) und das Digitale Oberflächenmodell (A.5a).

A.4 Software Maptor

Die Prozessierung der Ergebnisse der vorliegenden Arbeit wurden größtenteils realisiert durch Python-Skripte. Die Skripte zur Klassifikation und Regression wurden durch QASIM MUHAMMAD USMANI (Universität Rostock) in eine lauffähiges Programm für *Microsoft Windows* überführt (*Linux* und *MacOS* in Planung). Das Programm hat den Namen *Maptor* und ist derzeit (11.11.2020) in der Betaversion 1.4 frei verfügbar unter dem Link:

<https://datenportal.wetscapes.de/dataset/maptor-0-0>

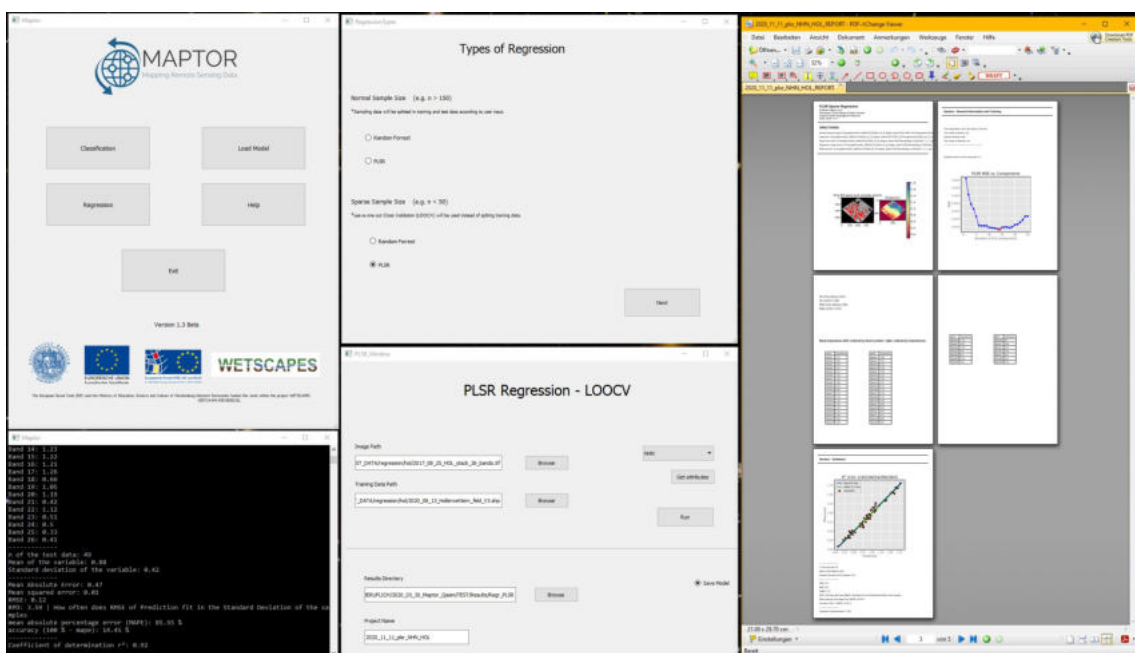


Abbildung A.6: Beispiel von Maptor (Version 1.4beta, 11.11.2020) für eine PLSR für kleine Probenahmenumfang unter Nutzung der *Leave-One-Out Cross Validation* (Links: Haupt- und Prozess-Fenster, Mitte: Auswahlfenster Regressionsverfahren und Regressionsfenster, Rechts: Ergebnisreport mit Validierungsergebnissen).

Für alle implementierten Verfahren werden nur der Fernerkundungsdatensatz im *Tagged Image File*(TIF)-Format sowie die Trainingsdaten (und Validierungsdaten) im Vektordatenformat *Shapefile* benötigt. Der Funktionsumfang der Software umfasst derzeit die Klassifikation mit RF, die Regression für großen Probenahmenumfang mit dem RF-Regressor und die Regression für kleinen Probenahmeumfang mit der PLSR. Für jede dieser Prozessierungen werden die Klassifikationskarten im TIF-Format, ein Report im PDF-Format, die trainierten Modelle und alle Graphiken aus dem Report extra in einer hohen Qualität abgespeichert (300x300 dpi).

A.5 Python

In der Arbeit wurden viele Aufgaben bei der Prozessierung der Daten mit der Skriptsprache *Python 3* durchgeführt. Vor allem betrifft das die Verfahren des maschinellen Lernens, der RF und die PLSR. Alle Skripte wurden in einem sogenannten *Repository* namens *PhD_Florian_Beyer* auf *Github* hochgeladen und stehen frei zur Verfügung. Die Adresse des *Repository* lautet:

https://github.com/florianbeyer/PhD_Florian_Beyer

Die Tabelle A.3 zeigt die dort verfügbaren Skripte bzw. *Jupyter Notebooks* und gibt eine kurze Erklärung, was dieses Skript tut. Die *Jupyter Notebooks* sind gleichzeitig Beispiele aus der Arbeit, die online bei *Github* geöffnet werden können und in denen die Ergebnisse direkt visualisiert werden.¹ Tabelle A.4 nennt die wichtigsten Pakete, die in den Skripten genutzt wurden, und ihre Funktionsweise.

Tabelle A.3: Selektion von in der Arbeit verwendeten Skripten bzw. *Jupyter Notebooks*.

| Skript | Beschreibung |
|-----------------------------|------------------------------------------------------------------|
| RF_classification.ipynb | Klassifikationsskript Beispiel: erweiterter Datensatz PaW |
| PLSR_regression_LOOCV.ipynb | Regressionsskript Beispiel: BAL |
| Indices.ipynb | Berechnung der Indizes und statistische Analyse Beispiel: BAL |
| Linear_Regression.ipynb | Lineare Regression auf Basis der PLSR Beispiel: BAL |
| Precipitation.ipynb | Visualisierung Niederschlag PaW |
| Radiation.ipynb | Visualisierung Globalstrahlung PaW |
| Temperature.ipynb | Visualisierung Temperatur PaW |
| Waterlevel.ipynb | Visualisierung Wasserstand PaW |

¹Falls die Fehlermeldung *Sorry, something went wrong. Reload?* beim Öffnen der Skripte erscheint, dann solange auf *Reload* klicken, bis das Skript erfolgreich lädt.

Tabelle A.4: Übersicht über alle Pakete, die für die Skripte in Python verwendet wurden.

| Paket | Funktion | Quelle |
|--------------|--------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------|
| GDAL/OGR | Lesen/Bearbeiten/Speichern von Raster- und Vektor-Geodatenformaten | https://gdal.org/ |
| Scikit-Learn | Maschinelles Lernen in Python | https://scikit-learn.org/stable/ |
| NumPy | Wissenschaftliches Rechnen mit großen Matrizen und Vektoren | http://www.numpy.org/ |
| Pandas | Analyse und Manipulation von großen Datenmengen | https://pandas.pydata.org/ |
| Geopandas | Analyse und Manipulation von großen Mengen an Geodaten | https://geopandas.org/ |
| Seaborn | Visualisierung von statistischen Ergebnissen | https://seaborn.pydata.org/ |
| Statsmodels | Berechnen statistischer Parameter | https://www.statsmodels.org |
| Scipy | Wissenschaftliches Rechnen und Berechnen statistischer Parameter | https://www.scipy.org/ |
| PyLab | Bestandteil von Scipy | https://scipy.github.io/old-wiki/pages/PyLab |
| Matplotlib | Visualisierung von Rasterdaten und Diagrammen | https://matplotlib.org/ |
| Joblib | Speichern von trainierten Modellen | https://joblib.readthedocs.io |

A.6 Orthomosaik

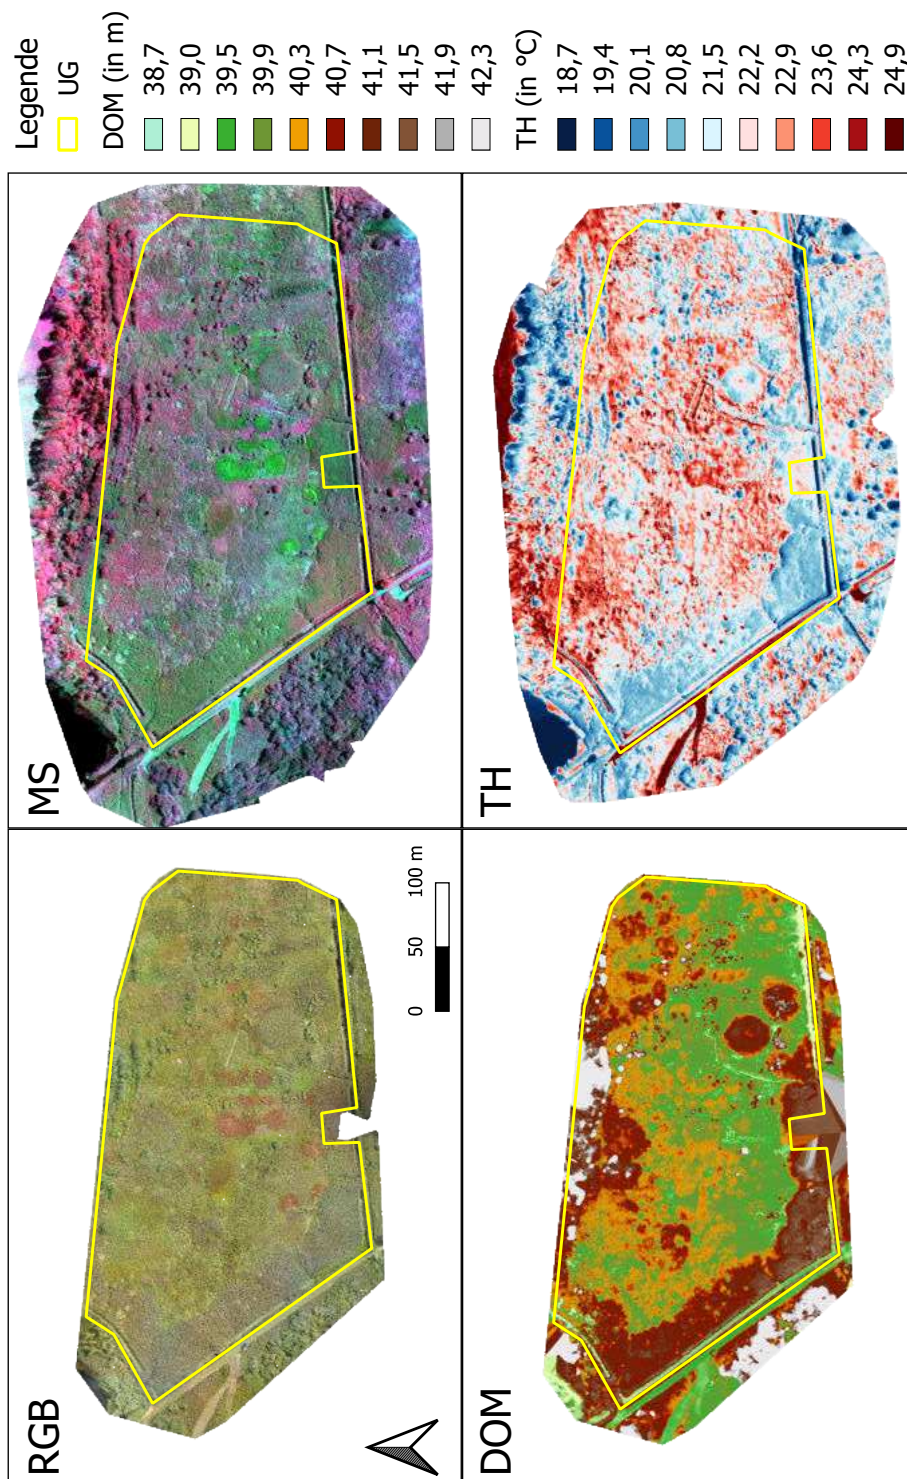


Abbildung A.7: Photogrammetrisch prozessierte Orthomosaik für PW (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen)




Abbildung A.8: Photogrammetrisch prozessierte Orthomosaik für CDCW (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen)




Abbildung A.9: Photogrammetrisch prozessierte Orthomosaik für PaW (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen)

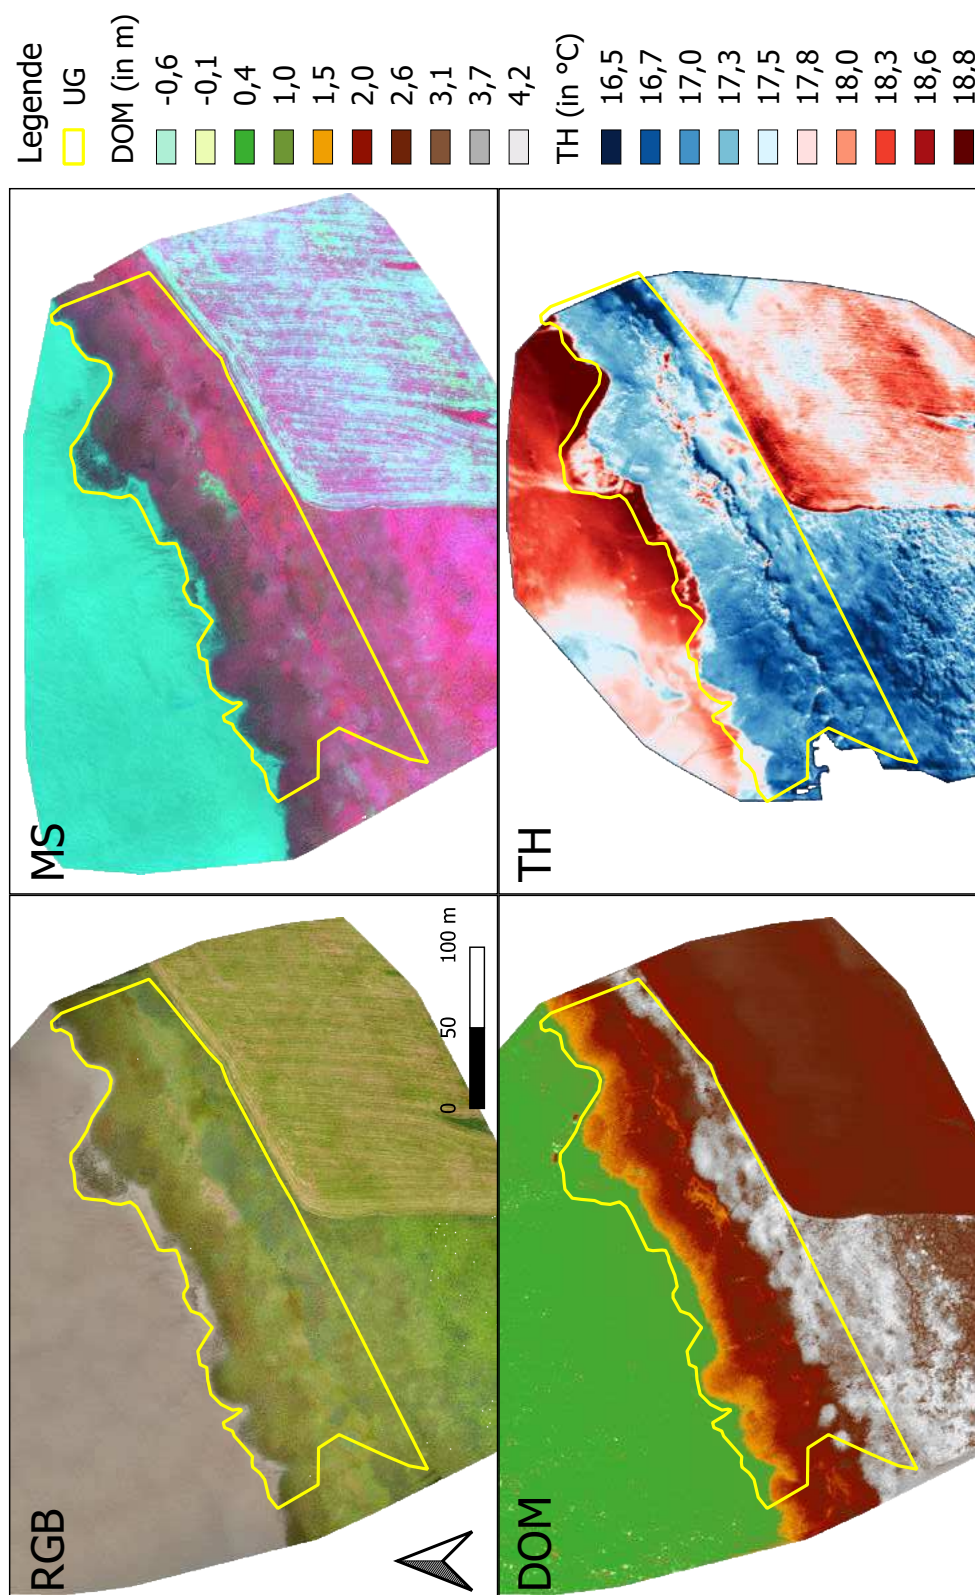


Abbildung A.10: Photogrammetrisch prozessierte Orthomosaike für BAL (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen)




Abbildung A.11: Photogrammetrisch prozessierte Orthomosaik für HOL (UG = Untersuchungsgebiet): RGB = Rot-Grün-Blau-Datensatz, MS = Multispektraldatensatz, DOM = Digitales Oberflächenmodell generiert aus den RGB-Daten (Elipsoidische Höhen: ETRS89), TH = thermale Daten (Oberflächentemperaturen)

A.7 Mittelwertspektren

Tabelle A.5: Originale multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von PW

| Kanal | Salix | Soil | Calamagrostis | CarexI | Epilobium | Glyceria | CarexII | Juncus | Phragmites | Typha | Water |
|---------|--------|-------|---------------|--------|-----------|----------|---------|--------|------------|--------|-------|
| B1 | 142,33 | 85,56 | 156,75 | 163,09 | 140,61 | 179,50 | 168,23 | 169,76 | 143,69 | 151,81 | 53,72 |
| G1 | 160,31 | 76,68 | 155,14 | 153,67 | 139,14 | 158,03 | 116,01 | 159,49 | 137,12 | 137,77 | 55,65 |
| R1 | 100,56 | 70,78 | 71,49 | 73,67 | 92,99 | 111,86 | 84,52 | 79,08 | 94,95 | 97,21 | 57,95 |
| G2 | 0,06 | 0,02 | 0,06 | 0,06 | 0,06 | 0,06 | 0,03 | 0,07 | 0,05 | 0,05 | 0,01 |
| R2 | 0,03 | 0,03 | 0,04 | 0,04 | 0,04 | 0,06 | 0,06 | 0,05 | 0,04 | 0,05 | 0,01 |
| RE | 0,26 | 0,06 | 0,23 | 0,22 | 0,19 | 0,16 | 0,10 | 0,23 | 0,17 | 0,16 | 0,05 |
| NIR | 0,36 | 0,09 | 0,32 | 0,31 | 0,25 | 0,22 | 0,14 | 0,31 | 0,24 | 0,22 | 0,07 |
| DOM | 42,20 | 39,39 | 39,63 | 39,92 | 40,41 | 39,58 | 39,93 | 39,94 | 41,08 | 39,72 | 39,04 |
| TH | 21,16 | 24,16 | 22,08 | 22,62 | 21,98 | 22,81 | 23,18 | 21,31 | 21,67 | 22,10 | 18,95 |
| GrI | 0,40 | 0,33 | 0,41 | 0,40 | 0,38 | 0,35 | 0,31 | 0,39 | 0,37 | 0,36 | 0,33 |
| NDVI | 0,83 | 0,55 | 0,76 | 0,75 | 0,71 | 0,59 | 0,42 | 0,73 | 0,69 | 0,65 | 0,72 |
| reNDVI1 | 0,16 | 0,22 | 0,17 | 0,17 | 0,16 | 0,16 | 0,18 | 0,17 | 0,17 | 0,16 | 0,22 |
| reNDVI2 | 0,77 | 0,38 | 0,68 | 0,67 | 0,62 | 0,48 | 0,26 | 0,64 | 0,60 | 0,54 | 0,59 |
| gNDVI | 0,70 | 0,55 | 0,67 | 0,67 | 0,64 | 0,59 | 0,61 | 0,66 | 0,64 | 0,62 | 0,64 |

Tabelle A.6: Normierte multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von PW. Die rot hervorgehobenen Werte wurden zwischen 0 und 1 normiert.

| Kanal | Salix | Soil | Calamagrostis | CarexI | Epilobium | Glyceria | CarexII | Juncus | Phragmites | Typha | Water |
|---------|-------|------|---------------|--------|-----------|----------|---------|--------|------------|-------|-------|
| B1 | 0,79 | 0,48 | 0,87 | 0,91 | 0,78 | 1,00 | 0,94 | 0,95 | 0,80 | 0,85 | 0,30 |
| G1 | 1,00 | 0,48 | 0,97 | 0,96 | 0,87 | 0,99 | 0,72 | 0,99 | 0,86 | 0,86 | 0,35 |
| R1 | 0,90 | 0,63 | 0,64 | 0,66 | 0,83 | 1,00 | 0,76 | 0,71 | 0,85 | 0,87 | 0,52 |
| G2 | 0,06 | 0,02 | 0,06 | 0,06 | 0,06 | 0,06 | 0,03 | 0,07 | 0,05 | 0,05 | 0,01 |
| R2 | 0,03 | 0,03 | 0,04 | 0,04 | 0,04 | 0,06 | 0,06 | 0,05 | 0,04 | 0,05 | 0,01 |
| RE | 0,26 | 0,06 | 0,23 | 0,22 | 0,19 | 0,16 | 0,10 | 0,23 | 0,17 | 0,16 | 0,05 |
| NIR | 0,36 | 0,09 | 0,32 | 0,31 | 0,25 | 0,22 | 0,14 | 0,31 | 0,24 | 0,22 | 0,07 |
| DOM | 1,00 | 0,93 | 0,94 | 0,95 | 0,96 | 0,94 | 0,95 | 0,95 | 0,97 | 0,94 | 0,93 |
| TH | 0,88 | 1,00 | 0,91 | 0,94 | 0,91 | 0,94 | 0,96 | 0,88 | 0,90 | 0,91 | 0,78 |
| GrI | 0,40 | 0,33 | 0,41 | 0,40 | 0,38 | 0,35 | 0,31 | 0,39 | 0,37 | 0,36 | 0,33 |
| NDVI | 0,83 | 0,55 | 0,76 | 0,75 | 0,71 | 0,59 | 0,42 | 0,73 | 0,69 | 0,65 | 0,72 |
| reNDVI1 | 0,16 | 0,22 | 0,17 | 0,17 | 0,16 | 0,16 | 0,18 | 0,17 | 0,17 | 0,16 | 0,22 |
| reNDVI2 | 0,77 | 0,38 | 0,68 | 0,67 | 0,62 | 0,48 | 0,26 | 0,64 | 0,60 | 0,54 | 0,59 |
| gNDVI | 0,70 | 0,55 | 0,67 | 0,67 | 0,64 | 0,59 | 0,61 | 0,66 | 0,64 | 0,62 | 0,64 |

Tabelle A.7: Originale multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von CDCW

| Kanal | Deschampsia | AgrostisI | Boden | Calamagrostis | JuncusI | Wasser | AgrostisII | JuncusII | Elymus | Festuca |
|---------|-------------|-----------|--------|---------------|---------|--------|------------|----------|--------|---------|
| B1 | 161,29 | 152,41 | 167,07 | 168,39 | 142,83 | 164,70 | 146,46 | 148,71 | 128,56 | 137,02 |
| G1 | 159,23 | 145,61 | 140,96 | 165,97 | 133,88 | 151,59 | 171,12 | 148,81 | 166,21 | 168,51 |
| R1 | 81,08 | 84,70 | 120,64 | 105,21 | 67,37 | 139,26 | 81,72 | 68,89 | 73,45 | 80,87 |
| G2 | 0,11 | 0,09 | 0,08 | 0,11 | 0,08 | 0,07 | 0,12 | 0,08 | 0,11 | 0,11 |
| R2 | 0,09 | 0,08 | 0,11 | 0,10 | 0,07 | 0,08 | 0,06 | 0,07 | 0,05 | 0,05 |
| RE | 0,39 | 0,27 | 0,16 | 0,39 | 0,28 | 0,13 | 0,47 | 0,31 | 0,52 | 0,47 |
| NIR | 0,52 | 0,34 | 0,20 | 0,53 | 0,38 | 0,15 | 0,62 | 0,41 | 0,76 | 0,68 |
| DOM | 37,10 | 36,53 | 36,65 | 37,20 | 36,92 | 37,04 | 37,29 | 37,32 | 37,88 | 37,86 |
| TH | 18,67 | 19,38 | 20,52 | 18,68 | 18,82 | 18,29 | 19,28 | 19,53 | 18,45 | 18,90 |
| Gri | 0,40 | 0,38 | 0,33 | 0,38 | 0,39 | 0,33 | 0,43 | 0,41 | 0,45 | 0,44 |
| NDVI | 0,70 | 0,63 | 0,29 | 0,67 | 0,68 | 0,33 | 0,82 | 0,73 | 0,88 | 0,86 |
| reNDVII | 0,14 | 0,11 | 0,11 | 0,16 | 0,15 | 0,06 | 0,14 | 0,14 | 0,19 | 0,19 |
| reNDVI2 | 0,62 | 0,55 | 0,18 | 0,58 | 0,59 | 0,27 | 0,77 | 0,65 | 0,83 | 0,80 |
| gNDVI | 0,65 | 0,59 | 0,43 | 0,65 | 0,66 | 0,35 | 0,68 | 0,66 | 0,74 | 0,73 |

Tabelle A.8: Normierte multisensorale Mittelwertspektren der Trainingsdaten für jede Klasse von CDCW. Die rot hervorgehobenen Werte wurden zwischen 0 und 1 normiert.

| Kanal | Deschampsia | AgrostisI | Boden | Calamagrostis | JuncusI | Wasser | AgrostisII | JuncusII | Elymus | Festuca |
|---------|-------------|-----------|-------|---------------|---------|--------|------------|----------|--------|---------|
| B1 | 0,96 | 0,91 | 0,99 | 1,00 | 0,85 | 0,98 | 0,87 | 0,88 | 0,76 | 0,81 |
| G1 | 0,93 | 0,85 | 0,82 | 0,97 | 0,78 | 0,89 | 1,00 | 0,87 | 0,97 | 0,98 |
| R1 | 0,58 | 0,61 | 0,87 | 0,76 | 0,48 | 1,00 | 0,59 | 0,49 | 0,53 | 0,58 |
| G2 | 0,11 | 0,09 | 0,08 | 0,11 | 0,08 | 0,07 | 0,12 | 0,08 | 0,11 | 0,11 |
| R2 | 0,09 | 0,08 | 0,11 | 0,10 | 0,07 | 0,08 | 0,06 | 0,07 | 0,05 | 0,05 |
| RE | 0,39 | 0,27 | 0,16 | 0,39 | 0,28 | 0,13 | 0,47 | 0,31 | 0,52 | 0,47 |
| NIR | 0,52 | 0,34 | 0,20 | 0,53 | 0,38 | 0,15 | 0,62 | 0,41 | 0,76 | 0,68 |
| DOM | 0,98 | 0,96 | 0,97 | 0,98 | 0,97 | 0,98 | 0,98 | 0,99 | 1,00 | 1,00 |
| TH | 0,91 | 0,94 | 1,00 | 0,91 | 0,92 | 0,89 | 0,94 | 0,95 | 0,90 | 0,92 |
| GfI | 0,40 | 0,38 | 0,33 | 0,38 | 0,39 | 0,33 | 0,43 | 0,41 | 0,45 | 0,44 |
| NDVI | 0,70 | 0,63 | 0,29 | 0,67 | 0,68 | 0,33 | 0,82 | 0,73 | 0,88 | 0,86 |
| reNDVI1 | 0,14 | 0,11 | 0,11 | 0,16 | 0,15 | 0,06 | 0,14 | 0,14 | 0,19 | 0,19 |
| reNDVI2 | 0,62 | 0,55 | 0,18 | 0,58 | 0,59 | 0,27 | 0,77 | 0,65 | 0,83 | 0,80 |
| gNDVI | 0,65 | 0,59 | 0,43 | 0,65 | 0,66 | 0,35 | 0,68 | 0,66 | 0,74 | 0,73 |

A.8 Indizes für die Klassifikation vom Hütelmoor (PaW)

Tabelle A.9: Nach GI absteigend sortierte Kanalrelevanzen für PaW, die im erweiterten 98-kanaligen multisensoralen Datensatz verwendet wurden.

| Nr. | Kanal | Gini (%) | Gini (kumul.) | Nr. | Kanal | Gini (%) | Gini (kumul.) |
|-----|-------------------------------|----------|---------------|-----|-------------------------------|----------|---------------|
| 8 | DSM | 0.06415 | 6.4 | 63 | savi | 0.00618 | 85.0 |
| 35 | grndvi | 0.03760 | 10.2 | 100 | band3_Energy | 0.00596 | 85.6 |
| 82 | normmir | 0.03268 | 13.4 | 85 | band1_Entropy | 0.00560 | 86.1 |
| 17 | arv12 | 0.02773 | 16.2 | 106 | band3_ClusterProminence | 0.00556 | 86.7 |
| 50 | msr670 | 0.02674 | 18.9 | 96 | band2_Inertia | 0.00551 | 87.2 |
| 74 | tvi | 0.02510 | 21.4 | 45 | mcari2 | 0.00539 | 87.8 |
| 38 | logr | 0.02499 | 23.9 | 87 | band1_InverseDifferenceMoment | 0.00522 | 88.3 |
| 76 | wdrvi | 0.02460 | 26.4 | 43 | mcari_osavi | 0.00522 | 88.8 |
| 52 | mvvi | 0.02302 | 28.7 | 93 | band2_Entropy | 0.00517 | 89.3 |
| 49 | msbi | 0.02271 | 30.9 | 54 | evi22 | 0.00498 | 89.8 |
| 40 | mar1 | 0.02140 | 33.1 | 95 | band2_InverseDifferenceMoment | 0.00492 | 90.3 |
| 30 | ddn | 0.02102 | 35.2 | 48 | msavi | 0.00486 | 90.8 |
| 5 | MS2 | 0.02093 | 37.3 | 80 | nli | 0.00485 | 91.3 |
| 79 | ndvi | 0.02086 | 39.4 | 102 | band3_Correlation | 0.00485 | 91.8 |
| 26 | ctvi | 0.01867 | 41.2 | 53 | cv12 | 0.00478 | 92.3 |
| 34 | gosavi | 0.01826 | 43.0 | 101 | band3_Entropy | 0.00477 | 92.7 |
| 67 | tc_nsimss | 0.01819 | 44.9 | 84 | band1_Energy | 0.00456 | 93.2 |
| 64 | sbj | 0.01775 | 46.6 | 66 | tc_gvimss | 0.00443 | 93.6 |
| 83 | normr | 0.01750 | 48.4 | 29 | datt4 | 0.00435 | 94.1 |
| 47 | msi | 0.01665 | 50.1 | 36 | lai | 0.00432 | 94.5 |
| 31 | difi1 | 0.01630 | 51.7 | 44 | mcari1 | 0.00432 | 94.9 |
| 68 | tc_sbimss | 0.01529 | 53.2 | 81 | normg | 0.00386 | 95.3 |
| 75 | varirededge | 0.01527 | 54.7 | 104 | band3_Inertia | 0.00370 | 95.7 |
| 70 | tcari | 0.01515 | 56.3 | 65 | spvi | 0.00367 | 96.0 |
| 7 | MS4 | 0.01454 | 57.7 | 11 | tgi | 0.00301 | 96.3 |
| 22 | chlgreen | 0.01404 | 59.1 | 98 | band2_ClusterProminence | 0.00291 | 96.6 |
| 60 | pvr | 0.01399 | 60.5 | 4 | MS1 | 0.00289 | 96.9 |
| 6 | MS3 | 0.01375 | 61.9 | 105 | band3_ClusterShade | 0.00275 | 97.2 |
| 55 | fe3 | 0.01319 | 63.2 | 90 | band1_ClusterProminence | 0.00268 | 97.5 |
| 33 | dvimss | 0.01283 | 64.5 | 32 | diff2 | 0.00257 | 97.7 |
| 24 | cgreen | 0.01272 | 65.8 | 14 | gcc | 0.00246 | 98.0 |
| 19 | avi | 0.01267 | 67.0 | 15 | gli | 0.00240 | 98.2 |
| 9 | th_index | 0.01096 | 68.1 | 89 | band1_ClusterShade | 0.00222 | 98.4 |
| 27 | cvi | 0.01083 | 69.2 | 59 | osavi2 | 0.00169 | 98.6 |
| 57 | grndvi | 0.00977 | 70.2 | 10 | ngrdi | 0.00160 | 98.8 |
| 71 | tcari_osavi | 0.00975 | 71.2 | 86 | band1_Correlation | 0.00145 | 98.9 |
| 77 | ndrdi | 0.00957 | 72.1 | 12 | vari_Correlation | 0.00144 | 99.1 |
| 107 | band3_HaralickCorrelation | 0.00896 | 73.0 | 69 | tc_yvimss | 0.00142 | 99.2 |
| 58 | osavi1 | 0.00885 | 73.9 | 94 | band2_Correlation | 0.00097 | 99.3 |
| 56 | gemi | 0.00879 | 74.8 | 97 | band2_ClusterShade | 0.00085 | 99.4 |
| 91 | band1_HaralickCorrelation | 0.00874 | 75.7 | 78 | ndre | 0.00070 | 99.4 |
| 103 | band3_InverseDifferenceMoment | 0.00838 | 76.5 | 25 | cirededge | 0.00062 | 99.5 |
| 73 | tci | 0.00816 | 77.3 | 23 | chlrededge | 0.00059 | 99.6 |
| 16 | ari | 0.00811 | 78.1 | 72 | tcari2 | 0.00058 | 99.6 |
| 18 | atsavi | 0.00773 | 78.9 | 21 | ccci | 0.00051 | 99.7 |
| 99 | band2_HaralickCorrelation | 0.00772 | 79.7 | 61 | rdrvi | 0.00051 | 99.7 |
| 51 | mtvi2 | 0.00727 | 80.4 | 37 | lci | 0.00051 | 99.8 |
| 20 | bri | 0.00686 | 81.1 | 62 | rededge2 | 0.00050 | 99.8 |
| 42 | mcari_mtv12 | 0.00682 | 81.8 | 28 | datt1 | 0.00046 | 99.9 |
| 88 | band1_Inertia | 0.00660 | 82.4 | 39 | maccioni | 0.00038 | 99.9 |
| 92 | band2_Energy | 0.00659 | 83.1 | 3 | RGB3 | 0.00035 | 100.0 |
| 41 | mcari | 0.00643 | 83.7 | 13 | exg | 0.00029 | 100.0 |
| 46 | mgvi | 0.00627 | 84.3 | 1 | RGB1 | 0.00011 | 100.0 |
| | | | | 2 | RGB2 | 0.00009 | 100.0 |

A.9 Erweiterter multisensoraler Datensatz für Tribsees (PW) und Karrendorf (CDCW)

Tabelle A.10: Die Korrelations- und Clustermatrizen für PW und CDCW können in voller Auflösung im Internet auf Zenodo betrachtet werden.

| Standort | Matrix | Abbildung | URL |
|----------|-------------|-----------|-------------------------------------------------------------------------------------------------------------------------|
| | | | <i>Digitalverzeichnis</i> <i>Arbeit/Abbildungen/99_Anhang/...</i> |
| PW | Korrelation | A.12 | https://zenodo.org/record/4267689 <i>PW_indizes_CorrMatrix.pdf</i> |
| | Cluster | A.14 | https://zenodo.org/record/4267694 <i>PW_Indizes_Cluster.pdf</i> |
| CDCW | Korrelation | A.13 | https://zenodo.org/record/4267681 <i>CDCW_indizes_CorrMatrix.pdf</i> |
| | Cluster | A.15 | https://zenodo.org/record/4267687 <i>CDCW_Indizes_Cluster.pdf</i> |




Abbildung A.12: Korrelationsmatrix aller berechneten Indizes für PW. Link zur digitalen Graphik in Tabelle A.10.



Abbildung A.13: Korrelationsmatrix aller berechneten Indizes für CDCW. Link zur digitalen Graphik in Tabelle A.10.




Abbildung A.14: Cluster-Matrix der Korrelationsmatrix aller berechneten Indizes für PW.
 Link zur digitalen Graphik in Tabelle A.10.




Abbildung A.15: Cluster-Matrix der Korrelationsmatrix aller berechneten Indizes für CD-CW. Link zur digitalen Graphik in Tabelle A.10.





Abbildung A.16: Dendrogramm der Cluster-Matrix aller berechneten Indizes für (a) PW und (b) CDCW. Die gestrichelte schwarze Linie markiert den Schwellwert.

Tabelle A.11: Selektierte Indizes aus den hochkorrelativen Index-Clustern für PW und CDCW.

| PW | | | CDCW | | |
|-----|-------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------|-------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Nr. | Index | Cluster | Nr. | Index | Cluster |
| 1 | mcari_mtvi2 | mcari_mtvi2 | 1 | ndre | tcari2, osavi2, cirededge, rededge2, ndre, rdvi |
| 2 | msbi | msbi, tc_sbimss | 2 | vari | exg, tgi, gli, gcc, vari, ngrdi, pvr, mcari, mcari_mtvi2 |
| 3 | lai | mtvi2, mcari1, evi2, savi, msavi, evi22, lai, mnsi, tc_nsimss, gosavi, mgvi, tc_gvimss, diff2, spvi, diff1, gemi, avi, dvimss, mcari, nli, mcari2, sbl, atsavi, osavi1 | 3 | ndvi | msbi, tc_sbimss, gndvi, cigreen, mari, tci, msr670, wdrvi, logr, varirededge, grndvi, normnir, ctvi, tvi, ndvi, arvi2, gosavi, gemi, atsavi, nli, mnsi, tc_nsimss, mcari1, mcari2, sbl, diff1, avi, dvimss, diff2, spvi, mgvi, tc_gvimss, osavi1, evi22, lai, msavi, mtvi2, evi2, savi |
| 4 | gndvi | mari, cigreen, gndvi | 4 | myvi | myvi |
| 5 | ndvi | tci, varirededge, grndvi, normnir, ctvi, tvi, ndvi, arvi2, logr, msr670, wdrvi | 5 | tcari | tcari |
| 6 | vari | tgi, pvr, gli, gcc, vari, ngrdi | 6 | tc_yvimss | tc_yvimss, fe3, ari, tcari_osavi |
| 7 | bri | bri | 7 | chlrededge | chlrededge |
| 8 | tc_yvimss | ddn, datt4, tc_yvimss | 8 | ndrdi | bri, ndrdi, chlgreen, normg, normr, datt4, ddn |
| 9 | ari | ari | 9 | ene | asm, ene, homo, ma |
| 10 | chlgreen | chlgreen, normg | 10 | std | std |
| 11 | tcari | fe3, ndrdi, normr, tcari, tcari_osavi | 11 | slope | slope, roughness, tri |
| 12 | osavi2 | osavi2, tcari2 | 12 | mcari_osavi | mcari_osavi |
| 13 | ndre | cirededge, rededge2, ndre, rdvi | 13 | tpi | aspect, tpi |
| 14 | cvi | cvi | 14 | cont | cont, diss, ent |
| 15 | ccci | ccci, maccioni, datt1, lci | 15 | hillshade | mean, hillshade |
| 16 | std | mean, std | 16 | datt1 | maccioni, datt1, lci |
| 17 | cont | hillshade, cont, diss, ent | 17 | ccci | ccci, cvi |
| 18 | chlrededge | chlrededge | | | |
| 19 | myvi | myvi | | | |
| 20 | ene | homo, ene, asm, ma | | | |
| 21 | exg | exg | | | |
| 22 | slope | slope, roughness, tri | | | |
| 23 | tpi | aspect, mcari_osavi, tpi | | | |

Tabelle A.12: Kanalzusammensetzung von PW und CDCW nach Cluster- und Selektionsverfahren.

| PW | | | | CDCW | | | |
|-----|-------------|----------------|-----|------|-------------|----------------|-----|
| Nr. | Kanal | Typ | aus | Nr. | Kanal | Typ | aus |
| 1 | R1 | Rot | | 1 | R1 | Rot | |
| 2 | G1 | Grün | | 2 | G1 | Grün | |
| 3 | B1 | Blau | | 3 | B1 | Blau | |
| 4 | G2 | Grün | | 4 | G2 | Grün | |
| 5 | R2 | Rot | | 5 | R2 | Rot | |
| 6 | RE | Red Edge | | 6 | RE | Red Edge | |
| 7 | NIR | Nahes Infrarot | | 7 | NIR | Nahes Infrarot | |
| 8 | DOM | DOM | RGB | 8 | DOM | DOM | RGB |
| 9 | TH | Thermal | | 9 | TH | Thermal | |
| 10 | ari | Spektralindex | MS | 10 | ccci | Spektralindex | MS |
| 11 | bri | Spektralindex | MS | 11 | chlrededge | Spektralindex | MS |
| 12 | ccci | Spektralindex | MS | 12 | datt1 | Spektralindex | MS |
| 13 | chlgreen | Spektralindex | MS | 13 | mcari_osavi | Spektralindex | MS |
| 14 | chlrededge | Spektralindex | MS | 14 | myvi | Spektralindex | MS |
| 15 | cvi | Spektralindex | MS | 15 | ndrdi | Spektralindex | MS |
| 16 | gndvi | Spektralindex | MS | 16 | ndre | Spektralindex | MS |
| 17 | lai | Spektralindex | MS | 17 | ndvi | Spektralindex | MS |
| 18 | mcari_mtvi2 | Spektralindex | MS | 18 | tc_yvimss | Spektralindex | MS |
| 19 | msbi | Spektralindex | MS | 19 | tcari | Spektralindex | MS |
| 20 | myvi | Spektralindex | MS | 20 | vari | Spektralindex | RGB |
| 21 | ndre | Spektralindex | MS | 21 | cont | Texturindex | RGB |
| 22 | ndvi | Spektralindex | MS | 22 | ene | Texturindex | RGB |
| 23 | osavi2 | Spektralindex | MS | 23 | std | Texturindex | RGB |
| 24 | tc_yvimss | Spektralindex | MS | 24 | hillshade | Reliefindex | DOM |
| 25 | tcari | Spektralindex | MS | 25 | slope | Reliefindex | DOM |
| 26 | exg | Spektralindex | MS | 26 | tpi | Reliefindex | DOM |
| 27 | vari | Spektralindex | RGB | | | | |
| 28 | cont | Texturindex | RGB | | | | |
| 29 | ene | Texturindex | RGB | | | | |
| 30 | std | Texturindex | RGB | | | | |
| 31 | slope | Reliefindex | DOM | | | | |
| 32 | tpi | Reliefindex | DOM | | | | |

Tabelle A.13: Kanalrelevanzen (%) von PW für den erweiterten multisensoralen Datensatz.

| PW | | | | | |
|-------|-------------|-------|-----|-------------|-------|
| Nr. | Kanal | % | Nr. | Kanal | % |
| 1 | R1 | 0,4 | 8 | DOM | 26,7 |
| 2 | G1 | 0,4 | 29 | ene | 10,3 |
| 3 | B1 | 0,4 | 30 | std | 9,2 |
| 4 | G2 | 0,7 | 28 | cont | 8,7 |
| 5 | R2 | 0,9 | 18 | mcari_mtvi2 | 4,8 |
| 6 | RE | 1,2 | 9 | TH | 4,6 |
| 7 | NIR | 1,4 | 22 | ndvi | 3,6 |
| 8 | DOM | 26,7 | 10 | ari | 3,6 |
| 9 | TH | 4,6 | 17 | lai | 3,3 |
| 10 | ari | 3,6 | 25 | tcari | 2,8 |
| 11 | bri | 0,9 | 24 | tc_yvimss | 2,6 |
| 12 | ccci | 1,3 | 27 | vari | 2,6 |
| 13 | chlgreen | 1,1 | 15 | cvi | 2,0 |
| 14 | chlrededge | 0,4 | 7 | NIR | 1,4 |
| 15 | cvi | 2,0 | 12 | ccci | 1,3 |
| 16 | gndvi | 1,2 | 6 | RE | 1,2 |
| 17 | lai | 3,3 | 16 | gndvi | 1,2 |
| 18 | mcari_mtvi2 | 4,8 | 13 | chlgreen | 1,1 |
| 19 | msbi | 0,9 | 31 | slope | 1,0 |
| 20 | myvi | 0,9 | 20 | myvi | 0,9 |
| 21 | ndre | 0,4 | 5 | R2 | 0,9 |
| 22 | ndvi | 3,6 | 11 | bri | 0,9 |
| 23 | osavi2 | 0,7 | 19 | msbi | 0,9 |
| 24 | tc_yvimss | 2,6 | 23 | osavi2 | 0,7 |
| 25 | tcari | 2,8 | 4 | G2 | 0,7 |
| 26 | exg | 0,4 | 32 | tpi | 0,5 |
| 27 | vari | 2,6 | 1 | R1 | 0,4 |
| 28 | cont | 8,7 | 3 | B1 | 0,4 |
| 29 | ene | 10,3 | 21 | ndre | 0,4 |
| 30 | std | 9,2 | 26 | exg | 0,4 |
| 31 | slope | 1,0 | 14 | chlrededge | 0,4 |
| 32 | tpi | 0,5 | 2 | G1 | 0,4 |
| Summe | | 100,0 | | | 100,0 |

Tabelle A.14: Kanalrelevanzen (%) von CDCW für den erweiterten multisensoralen Datensatz.

| CDCW | | | | | |
|-------|-------------|-------|-----|-------------|-------|
| Nr. | Kanal | % | Nr. | Kanal | % |
| 1 | R1 | 0,4 | 8 | DOM | 15,1 |
| 2 | G1 | 0,6 | 22 | ene | 9,8 |
| 3 | B1 | 2,5 | 7 | NIR | 7,8 |
| 4 | G2 | 4,0 | 6 | RE | 6,8 |
| 5 | R2 | 1,6 | 23 | std | 6,5 |
| 6 | RE | 6,8 | 9 | TH | 6,4 |
| 7 | NIR | 7,8 | 21 | cont | 5,3 |
| 8 | DOM | 15,1 | 15 | ndrdi | 4,6 |
| 9 | TH | 6,4 | 4 | G2 | 4,0 |
| 10 | ccci | 1,4 | 17 | ndvi | 3,9 |
| 11 | chlrededge | 1,8 | 14 | myvi | 3,8 |
| 12 | datt1 | 1,4 | 13 | mcari_osavi | 3,6 |
| 13 | mcari_osavi | 3,6 | 18 | tc_yvimss | 2,7 |
| 14 | myvi | 3,8 | 19 | tcari | 2,7 |
| 15 | ndrdi | 4,6 | 3 | B1 | 2,5 |
| 16 | ndre | 2,0 | 20 | vari | 2,1 |
| 17 | ndvi | 3,9 | 25 | slope | 2,1 |
| 18 | tc_yvimss | 2,7 | 16 | ndre | 2,0 |
| 19 | tcari | 2,7 | 11 | chlrededge | 1,8 |
| 20 | vari | 2,1 | 5 | R2 | 1,6 |
| 21 | cont | 5,3 | 10 | ccci | 1,4 |
| 22 | ene | 9,8 | 12 | datt1 | 1,4 |
| 23 | std | 6,5 | 26 | tpi | 0,7 |
| 24 | hillshade | 0,5 | 2 | G1 | 0,6 |
| 25 | slope | 2,1 | 24 | hillshade | 0,5 |
| 26 | tpi | 0,7 | 1 | R1 | 0,4 |
| Summe | | 100,0 | | | 100,0 |

Tabelle A.15: Kumulierte Relevanzen (GIs) nach Kanal- und Sensortyp für PW.

(a) Kanaltypweise kumul. Relevanzen

| Nr. | Sensor | Datentyp | GI (%) |
|-------|--------|-----------------|--------|
| 1 | MS | Spektralindizes | 30,51 |
| 2 | RGB | Texturindizes | 28,27 |
| 3 | DOM | Originalkanal | 26,69 |
| 4 | TH | Originalkanal | 4,63 |
| 5 | MS | Originalkanäle | 4,17 |
| 6 | RGB | Spektralindizes | 3,01 |
| 7 | DOM | Reliefindizes | 1,48 |
| 8 | RGB | Originalkanäle | 1,25 |
| Summe | | | 100,00 |

(b) Sensorweise kumul. Relevanzen.

| Nr. | Sensor | GI (%) |
|-------|--------|--------|
| 1 | MS | 34,68 |
| 2 | RGB | 32,53 |
| 3 | DOM | 28,16 |
| 4 | TH | 4,63 |
| Summe | | 100,00 |

Tabelle A.16: Kumulierte Relevanzen (GIs) nach Kanal- und Sensortyp für CDCW.

(a) Kanaltypweise kumul. Relevanzen

| Nr. | Sensor | Datentyp | GI (%) |
|-------|--------|-----------------|--------|
| 1 | MS | Spektralindizes | 27,98 |
| 2 | RGB | Texturindizes | 21,57 |
| 3 | MS | Originalkanäle | 20,15 |
| 4 | DOM | Originalkanal | 15,06 |
| 5 | TH | Originalkanal | 6,41 |
| 6 | RGB | Originalkanäle | 3,55 |
| 7 | DOM | Reliefindizes | 3,17 |
| 8 | RGB | Spektralindizes | 2,12 |
| Summe | | | 100,00 |

(b) Sensorweise kumul. Relevanzen.

| Nr. | Sensor | GI (%) |
|-------|--------|--------|
| 1 | MS | 48,13 |
| 2 | RGB | 27,20 |
| 3 | DOM | 18,22 |
| 4 | TH | 6,40 |
| Summe | | 100,00 |

A.10 Statistik der Pflanzenparameter für Balje (BAL) und Hollerwettern (HOL)

Tabelle A.17: Deskriptive Statistik der gemessenen und berechneten Parameter am Standort Balje.

| | n | MW | STD | MIN | 25% | 50% | 75% | MAX |
|------|----|---------|--------|--------|--------|---------|---------|---------|
| NHN | 48 | 1,08 | 0,47 | 0,40 | 0,65 | 1,12 | 1,40 | 2,05 |
| PA | 48 | 39,33 | 15,45 | 7,00 | 31,50 | 40,00 | 50,25 | 71,00 |
| PHG | 48 | 126,88 | 53,97 | 20,00 | 109,00 | 121,00 | 144,25 | 241,00 |
| PHL | 48 | 107,34 | 41,36 | 33,70 | 88,00 | 105,20 | 123,50 | 219,90 |
| PDML | 48 | 5,45 | 1,31 | 2,70 | 4,75 | 5,10 | 6,23 | 9,90 |
| PDMG | 48 | 4,20 | 1,64 | 0,30 | 3,00 | 4,00 | 5,00 | 8,00 |
| PFM | 48 | 6,72 | 3,30 | 2,69 | 4,29 | 6,20 | 8,08 | 16,12 |
| PTM | 48 | 2,91 | 2,24 | 0,57 | 1,53 | 2,32 | 3,54 | 10,62 |
| FFM | 48 | 270,09 | 172,39 | 26,16 | 162,61 | 243,80 | 359,18 | 870,70 |
| FTM | 48 | 119,17 | 105,04 | 4,77 | 55,65 | 101,93 | 146,12 | 573,64 |
| PWG | 48 | 60,26 | 13,79 | 26,79 | 55,89 | 62,83 | 66,32 | 84,03 |
| PARP | 46 | 177,39 | 325,81 | 17,00 | 36,00 | 51,50 | 95,00 | 1350,00 |
| PARS | 46 | 1110,87 | 350,50 | 470,00 | 802,50 | 1115,00 | 1392,50 | 1920,00 |
| PAR | 46 | 16,20 | 27,57 | 1,30 | 3,46 | 4,52 | 12,44 | 97,47 |

Tabelle A.18: Deskriptive Statistik der gemessenen und berechneten Parameter am Standort Hollerwettern.

| | n | MW | STD | MIN | 25% | 50% | 75% | MAX |
|------|----|--------|--------|--------|--------|--------|--------|--------|
| NHN | 49 | 0.88 | 0.42 | 0.08 | 0.51 | 0.86 | 1.14 | 1.81 |
| PA | 49 | 30.10 | 9.38 | 12.00 | 23.00 | 31.00 | 36.00 | 57.00 |
| PHG | 49 | 173.94 | 35.16 | 85.00 | 154.00 | 174.00 | 182.00 | 255.00 |
| PHL | 49 | 127.93 | 27.80 | 65.70 | 114.90 | 133.10 | 145.80 | 180.10 |
| PDML | 49 | 7.07 | 1.91 | 3.10 | 6.20 | 7.10 | 7.90 | 11.80 |
| PDMG | 49 | 6.78 | 1.69 | 3.00 | 5.67 | 7.00 | 7.67 | 11.33 |
| PFM | 49 | 13.72 | 3.54 | 5.20 | 10.94 | 13.85 | 15.89 | 20.98 |
| PTM | 49 | 3.79 | 1.52 | 1.07 | 2.84 | 3.78 | 4.36 | 8.65 |
| FFM | 49 | 412.64 | 165.83 | 118.29 | 303.36 | 409.40 | 522.84 | 894.22 |
| FTM | 49 | 112.51 | 53.73 | 26.80 | 68.86 | 109.99 | 146.17 | 296.23 |
| PWG | 49 | 72.53 | 7.93 | 48.27 | 70.74 | 72.76 | 76.03 | 86.28 |
| PAR | 49 | 11.68 | 14.33 | 0.23 | 2.84 | 6.86 | 12.35 | 61.54 |




Abbildung A.17: Korrelationsmatrix der gemessenen und berechneten Parameter aus Gelände und Labor für BAL (A.17a) und HOL (A.17b).

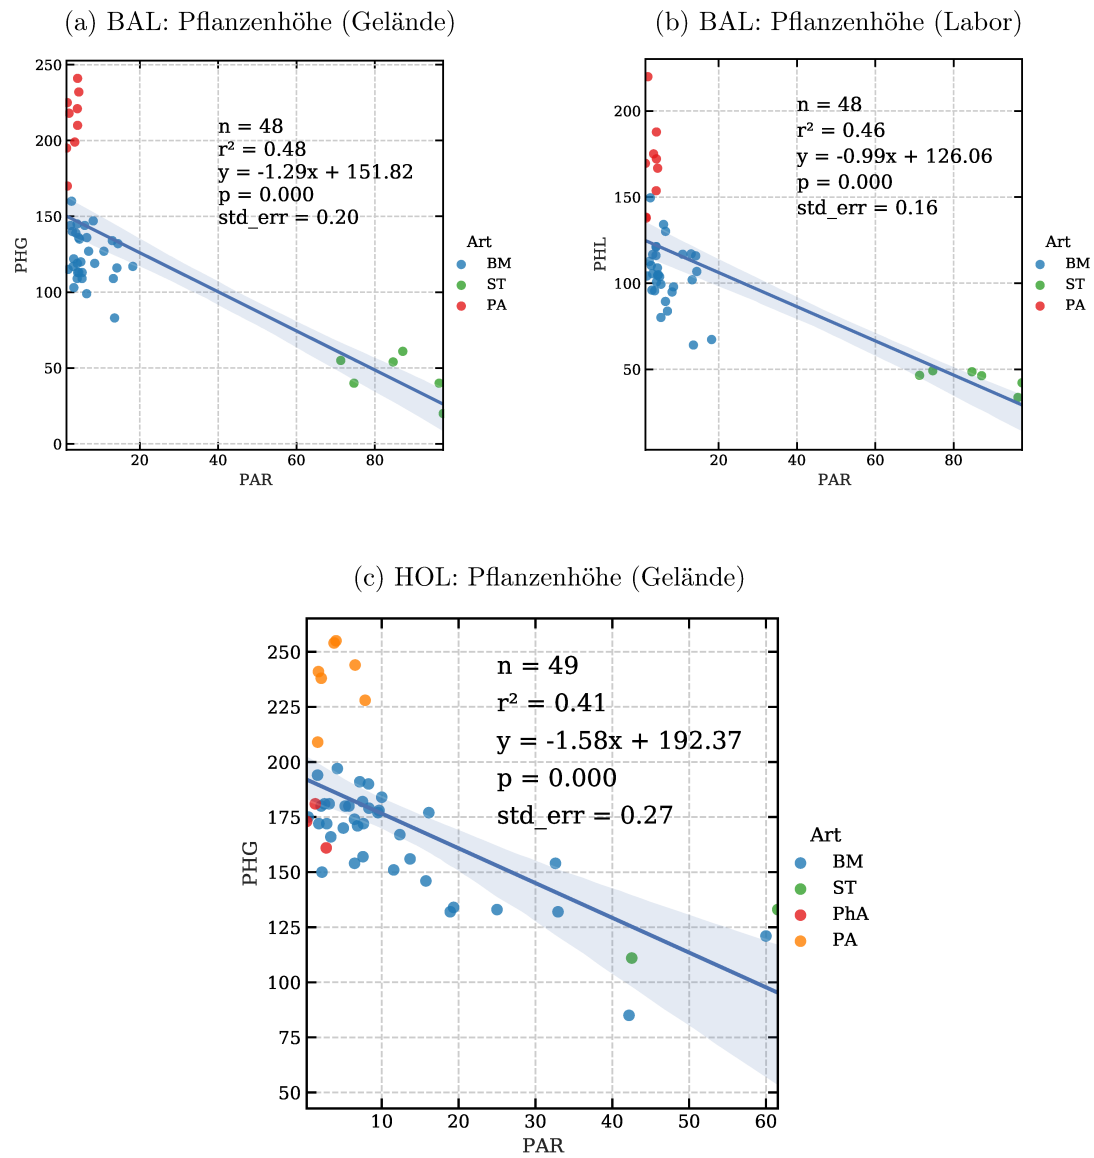


Abbildung A.18: Regressionen zwischen PAR und den Pflanzenhöhen von BAL und HOL

A.11 Erweiterter multisensoraler Datensatz für Balje (BAL) und Hollerwettern HOL

Tabelle A.19: Die Korrelations- und Clustermatrizen für PW und CDCW können in voller Auflösung im Internet auf Zenodo betrachtet werden.

| Standort | Matrix | Abbildung | URL <i>Digitalverzeichnis Arbeit/Abbildungen/99_Anhang/...</i> |
|----------|-------------|-----------|---------------------------------------------------------------------------------------------------------------------------------------------|
| BAL | Korrelation | A.19 | https://zenodo.org/record/4267707 BAL_indizes_CorrMatrix.pdf |
| | Cluster | A.20 | https://zenodo.org/record/4267709 BAL_Indizes_Cluster.pdf |
| HOL | Korrelation | A.21 | https://zenodo.org/record/4267713 HOL_indizes_CorrMatrix.pdf |
| | Cluster | A.22 | https://zenodo.org/record/4267722 HOL_Indizes_Cluster.pdf |




Abbildung A.19: Korrelationsmatrix BAL. Link zur digitalen Graphik in Tabelle A.19.




Abbildung A.20: Clustermatrix BAL. Link zur digitalen Graphik in Tabelle A.19.




Abbildung A.21: Korrelationsmatrix HOL. Link zur digitalen Graphik in Tabelle A.19.




Abbildung A.22: Clustermatrix HOL. Link zur digitalen Graphik in Tabelle A.19.




Abbildung A.23: Dendrogramme mit Distanzschwelle 1,5 zur Selektion von Index-Clustern für BAL und HOL.

Tabelle A.20: Zusammensetzung der Kanäle der erweiterten multisensoralen Datensätze für HOL und BAL.

| BAL | | | | HOL | | | |
|-----|-----------|----------------|---------------|-----|-----------|----------------|---------------|
| Nr. | Kanal | Typ | Generiert aus | Nr. | Kanal | Typ | Generiert aus |
| 1 | R1 | Rot | | 1 | R1 | Rot | |
| 2 | G1 | Grün | | 2 | G1 | Grün | |
| 3 | B1 | Blau | | 3 | B1 | Blau | |
| 4 | G2 | Grün | | 4 | G2 | Grün | |
| 5 | R2 | Rot | | 5 | R2 | Rot | |
| 6 | RE | Red Edge | | 6 | RE | Red Edge | |
| 7 | NIR | Nahes Infrarot | | 7 | NIR | Nahes Infrarot | |
| 8 | DOM | DOM | RGB | 8 | DOM | DOM | RGB |
| 9 | TH | Thermal | | 9 | TH | Thermal | |
| 10 | std | Texturindex | RGB | 10 | std | Texturindex | RGB |
| 11 | myvi | Spektralindex | MS | 11 | ccci | Spektralindex | MS |
| 12 | ene | Texturindex | RGB | 12 | datt1 | Spektralindex | MS |
| 13 | ndrdi | Spektralindex | MS | 13 | ene | Texturindex | RGB |
| 14 | ccci | Spektralindex | MS | 14 | tcari | Spektralindex | MS |
| 15 | tc_yvimss | Spektralindex | MS | 15 | ndrdi | Spektralindex | MS |
| 16 | tcari | Spektralindex | MS | 16 | cont | Texturindex | RGB |
| 17 | vari | Spektralindex | RGB | 17 | msbi | Spektralindex | MS |
| 18 | ndvi | Spektralindex | MS | 18 | ndvi | Spektralindex | MS |
| 19 | cont | Texturindex | RGB | 19 | cvi | Spektralindex | MS |
| 20 | cvi | Spektralindex | MS | 20 | vari | Spektralindex | RGB |
| 21 | mean | Texturindex | RGB | 21 | bri | Spektralindex | MS |
| 22 | hillshade | Reliefindex | DOM | 22 | mean | Texturindex | RGB |
| 23 | slope | Reliefindex | DOM | 23 | hillshade | Reliefindex | DOM |
| 24 | bri | Spektralindex | MS | 24 | slope | Reliefindex | DOM |
| 25 | tpi | Reliefindex | DOM | 25 | aspect | Reliefindex | DOM |
| | | | | 26 | tpi | Reliefindex | DOM |

Tabelle A.21: Prozentuale Kanalrelevanzen (*VIP* in %) der PLSR-Modelle ausgewählter Parameter für BAL.

| NHN | | | PHL | | | PHG | | |
|-------|-----------|----------------|-----|-----------|----------------|-----|-----------|----------------|
| Nr. | Kanal | <i>VIP</i> (%) | Nr. | Kanal | <i>VIP</i> (%) | Nr. | Kanal | <i>VIP</i> (%) |
| 8 | DOM | 7,1 | 8 | DOM | 7,3 | 8 | DOM | 7,7 |
| 7 | NIR | 6,2 | 7 | NIR | 6,5 | 7 | NIR | 7,5 |
| 13 | ndrdi | 6,1 | 13 | ndrdi | 6,4 | 6 | RE | 7,3 |
| 6 | RE | 6,1 | 6 | RE | 6,3 | 13 | ndrdi | 7,3 |
| 12 | ene | 4,9 | 15 | tc_yvimss | 5,7 | 15 | tc_yvimss | 6,7 |
| 14 | ccci | 4,9 | 14 | ccci | 5,6 | 14 | ccci | 6,5 |
| 15 | tc_yvimss | 4,9 | 12 | ene | 5,3 | 17 | vari | 6,0 |
| 18 | ndvi | 4,8 | 17 | vari | 5,2 | 12 | ene | 5,7 |
| 17 | vari | 4,8 | 18 | ndvi | 5,0 | 18 | ndvi | 5,2 |
| 24 | bri | 4,3 | 9 | TH | 4,5 | 9 | TH | 4,9 |
| 10 | std | 4,2 | 20 | cvi | 3,9 | 5 | R2 | 4,6 |
| 9 | TH | 4,0 | 5 | R2 | 3,9 | 22 | hillshade | 3,7 |
| 20 | cvi | 3,9 | 22 | hillshade | 3,7 | 20 | cvi | 3,6 |
| 2 | G1 | 3,8 | 23 | slope | 3,7 | 23 | slope | 3,6 |
| 16 | tcari | 3,8 | 10 | std | 3,3 | 10 | std | 3,1 |
| 22 | hillshade | 3,2 | 16 | tcari | 3,2 | 16 | tcari | 3,1 |
| 11 | myvi | 3,1 | 11 | myvi | 3,2 | 25 | tpi | 2,6 |
| 5 | R2 | 2,9 | 2 | G1 | 3,1 | 11 | myvi | 2,4 |
| 23 | slope | 2,9 | 25 | tpi | 2,9 | 3 | B1 | 2,3 |
| 1 | R1 | 2,7 | 21 | mean | 2,3 | 2 | G1 | 2,1 |
| 21 | mean | 2,7 | 3 | B1 | 2,2 | 21 | mean | 2,0 |
| 4 | G2 | 2,3 | 1 | R1 | 1,8 | 24 | bri | 1,1 |
| 3 | B1 | 2,3 | 4 | G2 | 1,7 | 19 | cont | 0,4 |
| 25 | tpi | 2,2 | 24 | bri | 1,7 | 1 | R1 | 0,3 |
| 19 | cont | 1,9 | 19 | cont | 1,6 | 4 | G2 | 0,2 |
| Summe | | 100,0 | | | 100,0 | | | 100,0 |

| PWG | | | PAR | | |
|-------|-----------|----------------|-----|-----------|----------------|
| Nr. | Kanal | <i>VIP</i> (%) | Nr. | Kanal | <i>VIP</i> (%) |
| 8 | DOM | 7,5 | 14 | ccci | 7,4 |
| 13 | ndrdi | 6,6 | 15 | tc_yvimss | 7,2 |
| 7 | NIR | 6,5 | 5 | R2 | 6,1 |
| 6 | RE | 6,4 | 12 | ene | 6,0 |
| 17 | vari | 5,5 | 8 | DOM | 5,5 |
| 15 | tc_yvimss | 5,3 | 3 | B1 | 5,4 |
| 14 | ccci | 5,3 | 6 | RE | 5,3 |
| 12 | ene | 5,2 | 7 | NIR | 5,2 |
| 18 | ndvi | 5,2 | 13 | ndrdi | 5,2 |
| 9 | TH | 4,4 | 9 | TH | 5,0 |
| 22 | hillshade | 3,9 | 25 | tpi | 4,0 |
| 10 | std | 3,8 | 20 | cvi | 4,0 |
| 11 | myvi | 3,6 | 23 | slope | 3,9 |
| 16 | tcari | 3,5 | 17 | vari | 3,7 |
| 23 | slope | 3,5 | 22 | hillshade | 3,5 |
| 5 | R2 | 3,4 | 4 | G2 | 3,4 |
| 2 | G1 | 3,3 | 18 | ndvi | 3,4 |
| 20 | cvi | 3,3 | 1 | R1 | 2,5 |
| 25 | tpi | 2,5 | 24 | bri | 2,4 |
| 3 | B1 | 2,2 | 11 | myvi | 2,2 |
| 24 | bri | 2,1 | 21 | mean | 2,0 |
| 1 | R1 | 2,1 | 10 | std | 2,0 |
| 21 | mean | 1,9 | 16 | tcari | 1,9 |
| 4 | G2 | 1,8 | 2 | G1 | 1,8 |
| 19 | cont | 1,4 | 19 | cont | 1,3 |
| Summe | | 100,0 | | | 100,0 |

Tabelle A.22: Prozentuale Kanalrelevanzen (*VIP* in %) der PLSR-Modelle ausgewählter Parameter für HOL.

| NHN | | | PHG | | |
|-------|-----------|----------------|-----|-----------|----------------|
| Nr. | Kanal | <i>VIP</i> (%) | Nr. | Kanal | <i>VIP</i> (%) |
| 8 | DOM | 7,9 | 8 | DOM | 8,2 |
| 7 | NIR | 6,0 | 12 | datt1 | 5,7 |
| 13 | ene | 5,5 | 13 | ene | 5,1 |
| 17 | msbi | 5,3 | 15 | ndrdi | 5,1 |
| 6 | RE | 5,2 | 17 | msbi | 5,0 |
| 14 | tcari | 5,2 | 7 | NIR | 4,9 |
| 15 | ndrdi | 5,1 | 16 | cont | 4,7 |
| 12 | datt1 | 5,1 | 11 | cci | 4,6 |
| 16 | cont | 5,1 | 20 | ngrdi | 4,5 |
| 20 | ngrdi | 5,0 | 22 | mean | 4,4 |
| 11 | cci | 4,9 | 6 | RE | 4,2 |
| 22 | mean | 4,7 | 19 | cvi | 4,1 |
| 19 | cvi | 4,4 | 14 | tcari | 4,1 |
| 2 | G1 | 3,5 | 24 | slope | 3,7 |
| 10 | std | 3,5 | 2 | G1 | 3,6 |
| 9 | TH | 3,0 | 9 | TH | 3,4 |
| 1 | R1 | 3,0 | 23 | hillshade | 3,3 |
| 18 | ndvi | 2,8 | 1 | R1 | 3,0 |
| 23 | hillshade | 2,1 | 10 | std | 3,0 |
| 24 | slope | 2,1 | 18 | ndvi | 2,7 |
| 3 | B1 | 2,0 | 3 | B1 | 2,5 |
| 4 | G2 | 2,0 | 5 | R2 | 2,5 |
| 21 | bri | 1,8 | 4 | G2 | 2,3 |
| 26 | tpi | 1,7 | 26 | tpi | 1,9 |
| 5 | R2 | 1,7 | 25 | aspect | 1,8 |
| 25 | aspect | 1,4 | 21 | bri | 1,7 |
| Summe | | 100,0 | | | 100,0 |

| PWG | | | PAR | | |
|-------|-----------|----------------|-----|-----------|----------------|
| Nr. | Kanal | <i>VIP</i> (%) | Nr. | Kanal | <i>VIP</i> (%) |
| 8 | DOM | 8,2 | 16 | cont | 6,3 |
| 12 | datt1 | 5,8 | 15 | ndrdi | 5,9 |
| 7 | NIR | 5,2 | 8 | DOM | 5,8 |
| 17 | msbi | 4,9 | 22 | mean | 5,3 |
| 15 | ndrdi | 4,9 | 20 | ngrdi | 5,3 |
| 6 | RE | 4,8 | 17 | msbi | 5,1 |
| 16 | cont | 4,7 | 12 | datt1 | 4,9 |
| 20 | ngrdi | 4,6 | 19 | cvi | 4,8 |
| 14 | tcari | 4,6 | 13 | ene | 4,6 |
| 22 | mean | 4,5 | 5 | R2 | 4,4 |
| 19 | cvi | 4,2 | 7 | NIR | 4,2 |
| 13 | ene | 3,9 | 9 | TH | 4,1 |
| 2 | G1 | 3,5 | 23 | hillshade | 3,7 |
| 18 | ndvi | 3,5 | 6 | RE | 3,5 |
| 24 | slope | 3,5 | 11 | cci | 3,3 |
| 10 | std | 3,3 | 14 | tcari | 3,2 |
| 11 | cci | 3,2 | 3 | B1 | 3,0 |
| 9 | TH | 3,0 | 24 | slope | 3,0 |
| 5 | R2 | 2,9 | 2 | G1 | 2,7 |
| 1 | R1 | 2,8 | 4 | G2 | 2,6 |
| 26 | tpi | 2,8 | 10 | std | 2,6 |
| 3 | B1 | 2,6 | 1 | R1 | 2,6 |
| 23 | hillshade | 2,5 | 18 | ndvi | 2,4 |
| 25 | aspect | 2,3 | 25 | aspect | 2,3 |
| 4 | G2 | 2,2 | 21 | bri | 2,1 |
| 21 | bri | 1,6 | 26 | tpi | 2,1 |
| Summe | | 100,0 | | | 100,0 |

Tabelle A.23: Kumulierte Relevanzen (*VIP* in %) nach Kanaltyp für BAL.

| (a) NHN | | | (b) PWG | | |
|---------|-----------------|----------------|---------|-----------------|----------------|
| Sensor | Datentyp | <i>VIP</i> (%) | Sensor | Datentyp | <i>VIP</i> (%) |
| MS | Spektralindizes | 35,76 | MS | Spektralindizes | 34,84 |
| MS | Originalkanäle | 17,55 | MS | Originalkanäle | 18,09 |
| RGB | Texturindizes | 13,7 | RGB | Texturindizes | 12,21 |
| RGB | Originalkanäle | 8,86 | DOM | Reliefindizes | 9,86 |
| DOM | Reliefindizes | 8,28 | RGB | Originalkanäle | 7,61 |
| DOM | Originalkanal | 7,14 | DOM | Originalkanal | 7,50 |
| RGB | Spektralindizes | 4,75 | RGB | Spektralindizes | 5,51 |
| TH | Originalkanal | 3,96 | TH | Originalkanal | 4,38 |
| Summe | | 100,00 | Summe | | 100,00 |

| (c) PHL | | | (d) PHG | | |
|---------|-----------------|----------------|---------|-----------------|----------------|
| Sensor | Datentyp | <i>VIP</i> (%) | Sensor | Datentyp | <i>VIP</i> (%) |
| MS | Spektralindizes | 34,78 | MS | Spektralindizes | 35,88 |
| MS | Originalkanäle | 18,37 | MS | Originalkanäle | 19,54 |
| RGB | Texturindizes | 12,55 | RGB | Texturindizes | 11,28 |
| DOM | Reliefindizes | 10,26 | DOM | Reliefindizes | 9,90 |
| DOM | Originalkanal | 7,31 | DOM | Originalkanal | 7,70 |
| RGB | Originalkanäle | 7,03 | RGB | Spektralindizes | 6,01 |
| RGB | Spektralindizes | 5,22 | TH | Originalkanal | 4,95 |
| TH | Originalkanal | 4,47 | RGB | Originalkanäle | 4,74 |
| Summe | | 100,00 | Summe | | 100,00 |

| (e) PAR | | |
|---------|-----------------|----------------|
| Sensor | Datentyp | <i>VIP</i> (%) |
| MS | Spektralindizes | 33,49 |
| MS | Originalkanäle | 20,06 |
| DOM | Reliefindizes | 11,41 |
| RGB | Texturindizes | 11,21 |
| RGB | Originalkanäle | 9,71 |
| DOM | Originalkanal | 5,45 |
| TH | Originalkanal | 5,00 |
| RGB | Spektralindizes | 3,68 |
| Summe | | 100,00 |

Tabelle A.24: Kumulierte Relevanzen (VIP in %) nach Kanaltyp für HOL.

| (a) NHN | | | (b) PWG | | |
|---------|-----------------|-----------|---------|-----------------|-----------|
| Sensor | Datentyp | VIP (%) | Sensor | Datentyp | VIP (%) |
| MS | Spektralindizes | 34,49 | MS | Spektralindizes | 32,67 |
| RGB | Texturindizes | 18,78 | RGB | Texturindizes | 16,47 |
| MS | Originalkanäle | 14,94 | MS | Originalkanäle | 15,07 |
| RGB | Originalkanäle | 8,53 | DOM | Reliefindizes | 11,00 |
| DOM | Originalkanal | 7,94 | RGB | Originalkanäle | 8,96 |
| DOM | Reliefindizes | 7,33 | DOM | Originalkanal | 8,21 |
| RGB | Spektralindizes | 4,98 | RGB | Spektralindizes | 4,60 |
| TH | Originalkanal | 3,00 | TH | Originalkanal | 3,02 |
| Summe | | 100,00 | Summe | | 100,00 |

| (c) PHL | | | (d) PAR | | |
|---------|-----------------|-----------|---------|-----------------|-----------|
| Sensor | Datentyp | VIP (%) | Sensor | Datentyp | VIP (%) |
| MS | Spektralindizes | 32,95 | MS | Spektralindizes | 31,80 |
| RGB | Texturindizes | 17,22 | RGB | Texturindizes | 18,88 |
| MS | Originalkanäle | 13,81 | MS | Originalkanäle | 14,72 |
| DOM | Reliefindizes | 10,77 | DOM | Reliefindizes | 11,09 |
| RGB | Originalkanäle | 9,17 | RGB | Originalkanäle | 8,24 |
| DOM | Originalkanal | 8,23 | DOM | Originalkanal | 5,80 |
| RGB | Spektralindizes | 4,45 | RGB | Spektralindizes | 5,33 |
| TH | Originalkanal | 3,40 | TH | Originalkanal | 4,14 |
| Summe | | 100,00 | Summe | | 100,00 |

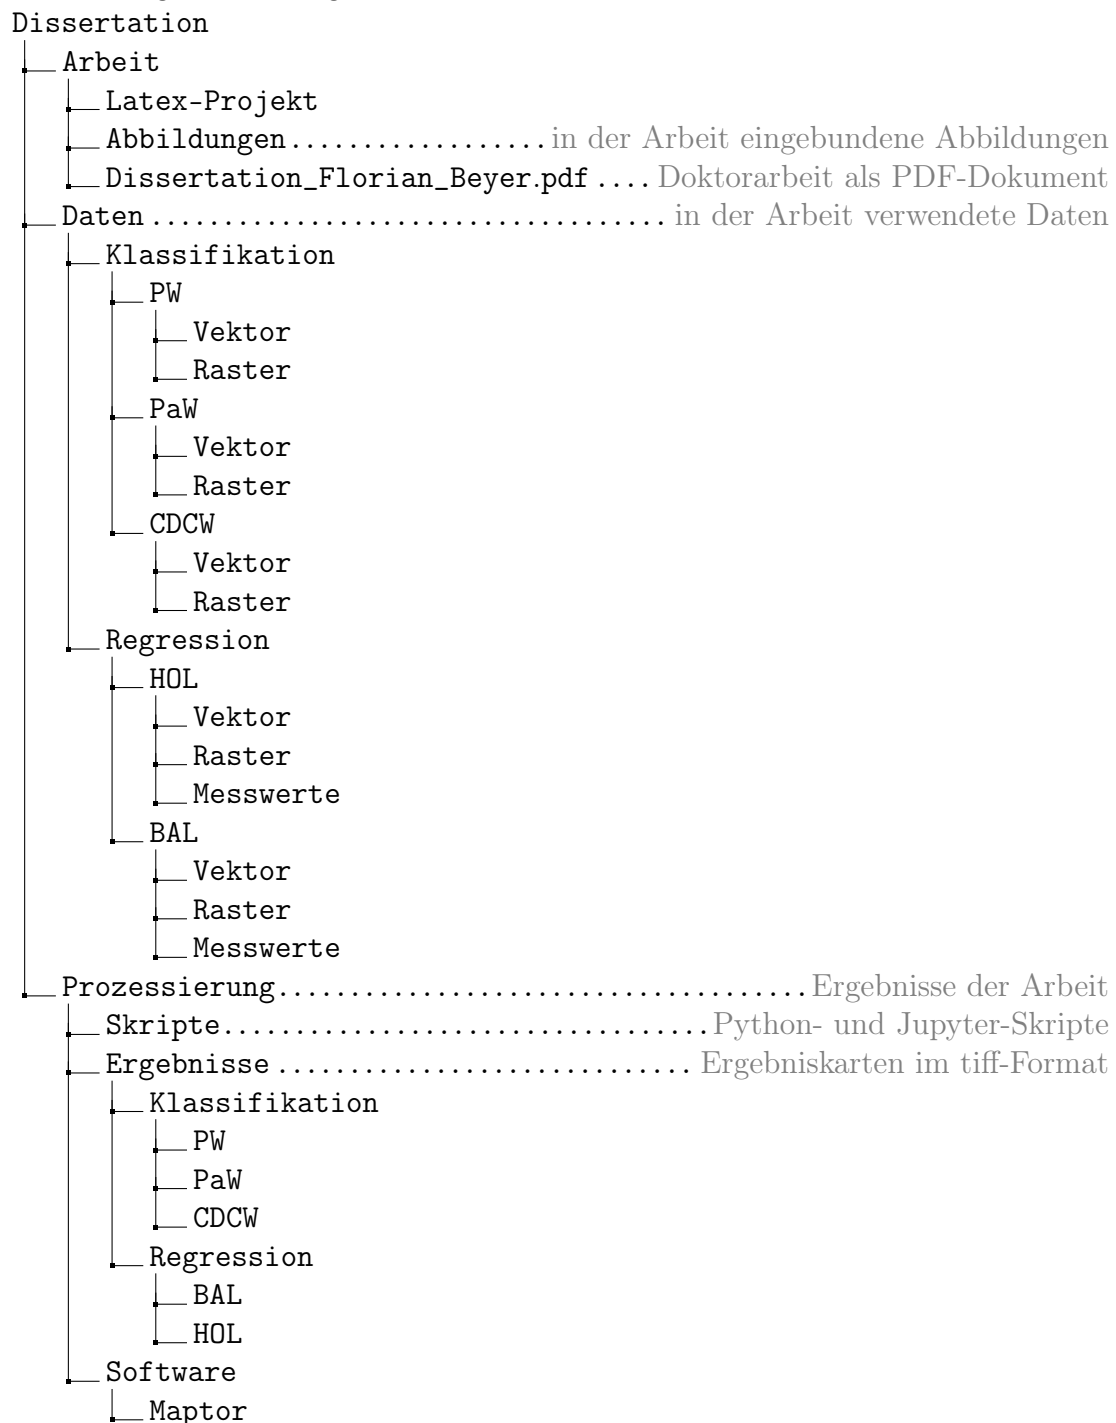
Tabelle A.25: Kumulierte Relevanzen (VIP in %) nach Sensortyp für BAL und HOL.

| (a) BAL | | | | | |
|---------|--------|--------|--------|--------|--------|
| Sensor | NHN | PHL | PHG | PWG | PAR |
| MS | 53,3 | 53,15 | 55,42 | 52,93 | 53,55 |
| RGB | 27,31 | 24,81 | 22,03 | 25,33 | 24,59 |
| DOM | 15,42 | 17,57 | 17,60 | 17,36 | 16,86 |
| TH | 3,96 | 4,47 | 4,95 | 4,38 | 5,00 |
| Summe | 100,00 | 100,00 | 100,00 | 100,00 | 100,00 |

| (b) HOL | | | | |
|---------|--------|--------|--------|--------|
| Sensor | NHN | PHG | PWG | PAR |
| MS | 49,43 | 46,76 | 47,75 | 46,52 |
| RGB | 32,29 | 30,84 | 30,03 | 32,45 |
| DOM | 15,27 | 19,00 | 19,21 | 16,89 |
| TH | 3,00 | 3,40 | 3,02 | 4,14 |
| Summe | 100,00 | 100,00 | 100,00 | 100,00 |

A.12 Struktur der digital verfügbaren Daten

Der Datenträger für die digitalen Daten befindet sich innen am hinteren Buchdeckel.



Förderung

Teile dieser Arbeit sind im Rahmen des Verbundprojektes WETSCAPES entstanden. Das Vorhaben wird im Rahmen des Exzellenzforschungsprogramms des Landes Mecklenburg-Vorpommern über einen Zeitraum von vier Jahren und drei Monaten aus dem Europäischen Sozialfonds gefördert.

Projekt: ESF/14-BM-A55-0032/16

Projektlaufzeit: 01.01.2017-31.03.2021



Europäische Fonds EFRE, ESF und ELER
in Mecklenburg-Vorpommern 2014-2020



EUROPÄISCHE UNION
Europäischer Sozialfonds

Eidesstattliche Erklärung

Hiermit erkläre ich durch eigenhändige Unterschrift, die vorliegende Dissertation selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel verwendet zu haben. Die aus den Quellen direkt oder indirekt übernommenen Gedanken sind als solche kenntlich gemacht. Die Dissertation ist in dieser Form noch keiner anderen Prüfungsbehörde vorgelegt worden.

Ort, Datum

Unterschrift des Doktoranden

