

Klassifikation von Vegetationstypen auf Moorstandorten unter Verwendung von multisensoralen Drohrendaten

FLORIAN BEYER¹ & GÖRRES GRENZDÖRFFER¹

Zusammenfassung: UAS liefern sehr hochaufgelöste multisensorale Daten, mit deren Hilfe und unter Verwendung moderner Klassifikatoren eine präzise Vegetationsklassifikation eines Moores möglich wird. Der im Rahmen einer UAS-Befliegung aufgenommene multisensorale Datensatz (14 Bänder), einer ca. 8 ha großen Moorfläche, besteht aus RGB-Daten, multispektralen Informationen, Thermaldaten, einem digitalen Oberflächenmodell (DOM) und mehreren Vegetationsindizes. Die Klassifikation mit einem Random Forest Ansatz lieferte bei 11 Klassen eine Gesamtgenauigkeit von ca. 89 %. Die vier relevantesten Variablen für die Klassifikation waren das DOM, die Thermaldaten, der normalisierte Vegetationsindex aus Rot und Red-Edge und der NDVI. Somit ermöglichen UAS auf der Skalenebene zwischen Blatt- und Bestandsebene neue erklärende Daten, die herkömmlichen Satelliten- und Flugzeug-basierten Untersuchungen überlegen sind.

1 Einleitung

Seit Jahrzehnten wird intensiv an der Auswertung von fernerkundlichen Satelliten- und Flugzeug-Daten geforscht. Als Referenzmessungen werden oft punkthafte Messungen am Boden als Kalibration und Validierung der jeweiligen Methode genutzt (WU & LI 2009; MARCEAU & HAY 1999). Dabei entsteht das Problem eines Skalensprungs von einem sehr großen Maßstab auf eine sehr kleine Maßstabsebene, von einer punkthafte Messung auf eine Fläche, also ein Pixel eines Rasterdatensatzes. Man muss in seinen modellhaften Annahmen also davon ausgehen, dass die punkthafte Messung im Gelände die Fläche des Pixels einwandfrei repräsentiert. Dabei entstehen Unsicherheiten und Fehler, die nicht größer werden dürfen, als die eigentliche Zielgröße (SIEGMANN et al. 2015).

Seit einigen Jahren werden Drohnen, unmanned aerial systems (UAS), vermehrt in der fernerkundlichen Forschung eingesetzt. Diese Systeme können als entscheidende Technologie betrachtet werden, um die Skalenübergänge besser zu verstehen und etablierte Ansätze der Satelliten- und Flugzeug-basierten Fernerkundung zu überprüfen.

In der vorliegenden Studie werden verschiedene Arten an Sensoren auf ihre Synergie getestet. Dafür wurden Drohnenbefliegungen mit einer hochaufgelösten RGB-Kamera, mit einem Multispektral-Sensor und einer Thermal-Kamera durchgeführt.

Das Untersuchungsgebiet ist ein wiedervernässtes Durchströmungsmoor zwischen Rostock und Greifswald in Mecklenburg-Vorpommern. Die Moorfläche bei Triebsees befindet sich seit Mitte der 1990er Jahre unter Restaurierungsmaßnahmen und weist mittlerweile eine hohe Biodiversität auf.

¹ Universität Rostock, Agrar- und Umweltwissenschaftliche Fakultät, Professur für Geodäsie und Geoinformatik, Justus-von-Liebig-Weg 6, D-18059 Rostock, E-Mail: [florian.beyer, goerres.grenzdoeffler]@uni-rostock.de

Ziel der Studie war es zum einen die diverse Moorvegetation möglichst genau zu klassifizieren. Dafür wurde ein multisensoraler Datensatz aus den genannten Sensoren sowie daraus generierten Produkten erstellt und mit einem modernen Algorithmus des maschinellen Lernens (BISHOP 2006) klassifiziert und unabhängig validiert.

Zum anderen sollten die einzelnen Bänder des multisensoralen Datensatzes auf ihren Einfluss auf das Klassifikationsergebnis überprüft werden. Dabei wird untersucht inwiefern die klassischen Fernerkundungsinformationen (Spektralkanäle) aus dem optischen Bereich (400 – 2'500 nm) den gleichen Stellenwert bei einer Klassifikation von Vegetation zeigen oder ob auf dieser Maßstabsebene eventuell weitere bzw. andere Einflussgrößen eine wesentliche Rolle spielen.

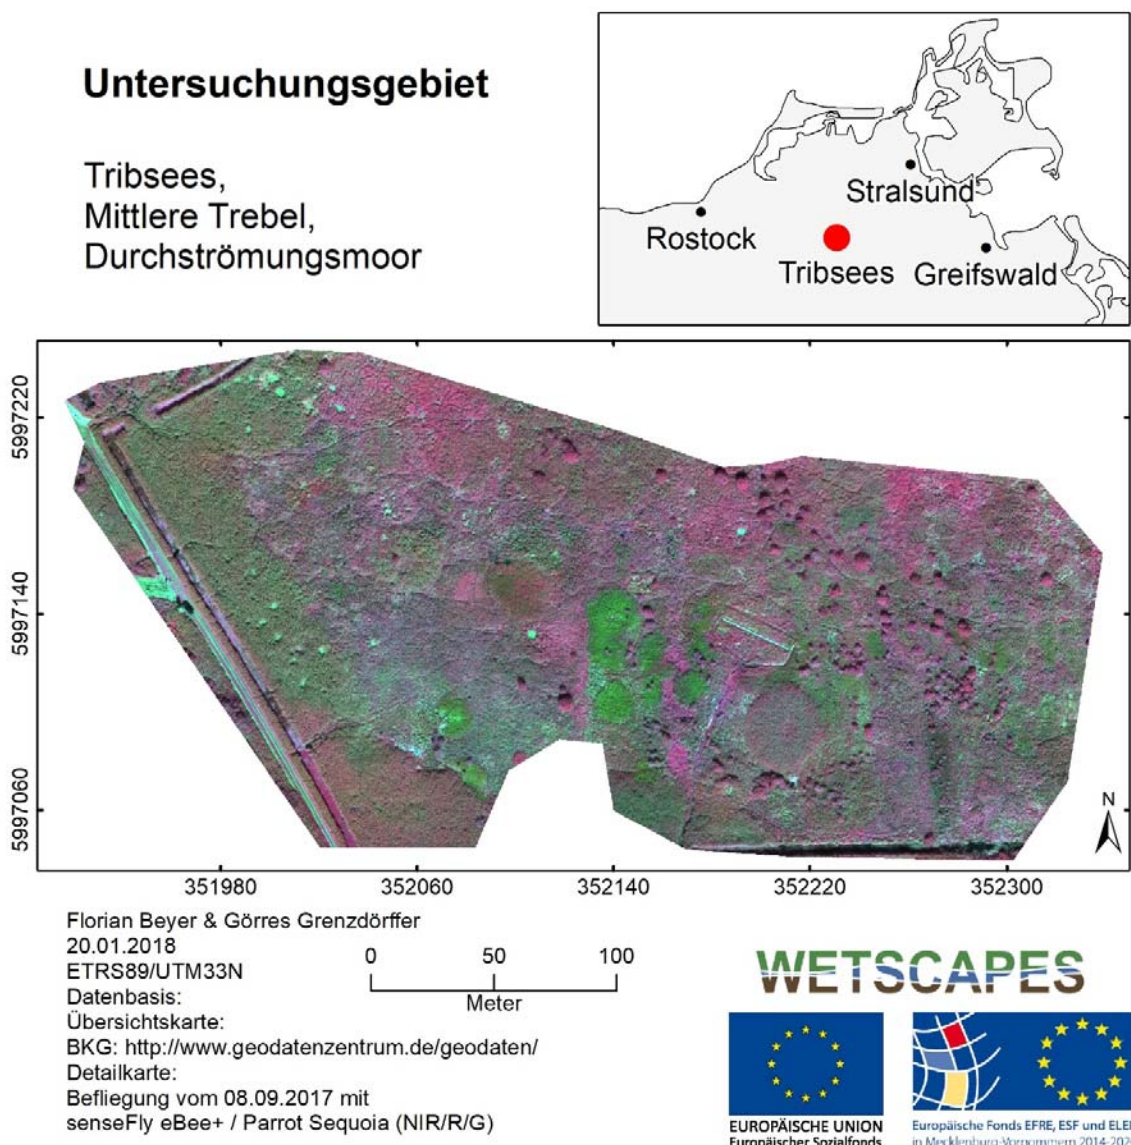


Abb. 1: Untersuchungsgebiet, wiedervernässtes Durchströmungsmoor bei Triebsees.

2 Untersuchungsgebiet

Das Untersuchungsgebiet (Abb. 1) stellt ein Flusstalmoor (WGS84: N 54°06', O 12°45') dar welches sich im Flusstal „Mittlere Trebel“ direkt bei Tribsees in Mecklenburg-Vorpommern (Deutschland) befindet. Die klimatischen Jahresmittel liegen bei 685 mm Niederschlag und 8 °C Temperatur. Das Untersuchungsgebiet ist somit in leicht kontinentales Klima mit maritimen Einflüssen einzuordnen. Die Fläche wurde zu Zeiten der Moormeliorationen in der DDR der 1960er & 70er Jahre tief entwässert (ZIEBARTH et al. 2009) um sie in eine agrarische Intensiv-Nutzung zu überführen. Mit Förderung aus EU-Mitteln wird versucht die Fläche wieder in seine ursprüngliche ökologische Funktion als hoch-biodiverses Durchströmungsmoor zurückzuführen. Diese Renaturierungsmaßnahmen laufen seit 1996. Abb. 1 zeigt die etwa 8 ha große Untersuchungsfläche.

Tab. 1: Übersicht über die kartierten Pflanzenarten und der verwendete Klassenname

No.	Klasse	botanischer Name (deutscher Name)	Pixelzahl Training	Pixelzahl Validierung
1	Salix	Salix spec. (Weide)	5280	3298
2	Boden		170	135
3	Calamagrostis	Calamagrostis canesens (Sumpfreitgras)	2962	2301
4	Carex I	Carex acutiformis, Carex riparia (Sumpf-Segge, Ufer-Segge)	16650	10360
5	Epilobium	Epilobium hirsutum (Zottiges Weidenröschen)	6194	6822
6	Glyceria	Glyceria maxima (Wasser-Schwaden)	1691	1552
7	Carex II	Carex rostrata, Carex acuta (Schnabel-Segge, Schlank-Segge)	4509	2662
8	Juncus	Juncus effesus, Juncus subnodulosus (Flutter-Binse, Stumpfbütige Binse)	2342	1319
9	Phragmites	Phragmites australis (Schilfrohr)	41504	33145
10	Typha	Typha latifolia (Breitblättriger Rohrkolben)	6218	6536
11	Wasser		375	352
Total			87895	68482

Eine Kartierung des Pflanzenbestandes fand am 24. Oktober 2017 statt. Die Zusammensetzung des Pflanzenbestandes ist in Tab. 1 zusammengefasst. Dabei ist zu beachten, dass es sich fernerkundungs-konform um Dominanzbestände handelt. Die kartierten Pflanzenarten wurden zu 11 verschiedenen Klassen zusammengefasst. Die verschiedenen Dominanzbestände bilden im Gelände eine charakteristische „Patch“-Struktur aus (Abb. 1). Die größten Flächenanteile nehmen

Phragmites- und Carex-Arten ein. Besonders die Klasse Carex II ist von ökologisch besonderem Interesse, weil die Art Carex rostrata unter die seltenen Seggenarten fällt. Epilobium hirsutum ist eher als Einzelpflanze über das ganze Gebiet verteilt und bildet nur vereinzelt größere Dominanzbestände aus.

Die Kartierung wurde als Grundlage verwendet um einen Trainings- sowie einen Validierungsdatensatz zu erstellen. Die Anzahl der jeweiligen Pixel pro Klasse sind in Tab. 1 aufgelistet. Dabei fällt auf, dass manche Klassen unterrepräsentiert sind. Flächen an Wasser und offenem Boden sind im Gebiet sehr begrenzt. Aber auch Pflanzenarten wie Glyceria maxima, die Juncus-Arten oder Calamagrostis canesens gehören zu den Klassen, die auf der Untersuchungsfläche relativ wenig vorkommen.

3 Methoden

3.1 UAS-Bilddaten und Vorprozessierung

Die UAS-Daten wurden mit einer eBee+ der Firma senseFly aufgenommen (ab hier „eBee“). Diese Drohne ist ein Flächenflügler, der etwa 1‘100 g wiegt und mit verschiedenen bildgebenden Sensoren bestückt werden kann. Das RTK-GNSS-Modul ermöglicht zudem eine passpunktlose Aerotriangulation, was insbesondere in schwer zugänglichen Bereichen, wie Mooren von sehr großem Vorteil ist. Der Workflow einer photogrammetrischen eBee-Mission ist weitestgehend automatisiert worden. Aufbauend auf der Flugplanung, einschließlich der Areale für Start und Landung, wird die Drohne im Gelände mit dem Feldrechner verbunden und losgeworfen. Der Bildflug und die Landung erfolgen automatisch. Die Befliegungen fanden am 08. September 2017 statt. Das ca. 8 ha große Untersuchungsgebiet wurde mit jedem Sensor unmittelbar nacheinander dreimal befliegen. Die Flugzeit betrug jeweils ca. 15 Minuten pro Flug. Zunächst erfolgte der Bildflug mit einer hochauflösten RGB-Kamera (senseFly S.O.D.A.). Dies ist eine 20 Megapixel-Kamera mit Global Shutter.

Tabelle 2: Spektrale Kanäle der Parrot Sequoia-Sensors

Band	Zentrums-Wellenlänge	Bandbreite
	in Nanometer	
Grün	550	40
Rot	660	40
Red-Edge	735	10
NIR	790	40

Im Anschluss erfolgte der Flug mit einer multispektralen Kamera, der Parrot Sequoia. Diese Kamera besitzt vier einzelne Optiken für die spektralen Bereiche des grünen, roten und zwei Kanäle im infraroten Licht. Einer der Infrarotkanäle ist sensitiv im sogenannten Red Edge, einem Bereich im Übergang vom roten zum infraroten Bereich, der besonders für Vegetationsuntersuchungen von großem Wert ist (MUTANGA & SKIDMORE 2007). Der zweite Kanal liegt klassisch im nahen Infrarot um beispielsweise den NDVI zu berechnen. Jeder der vier Sensoren besitzt

eine Auflösung von 1.2 Megapixel und einen Global Shutter. Die spektralen Kenndaten des Sensors sind in Tabelle 2 aufgelistet.

Eine weitere Besonderheit des Sequoia-Sensors ist ein Sonnenschein-Sensor, der während des Fluges für jede Bildaufnahme auch Einstrahlungsinformationen (Irradiance) in die Bild-Metadaten (EXIF tags) schreibt. So kann während der Vorprozessierung der Daten jedes Bild einer Beleuchtungskorrektur unterzogen und unter Einbeziehung einer kalibrierten Grau-Referenz-Platte echte Reflexionswerte errechnet werden. Im dritten Flug wurde die Thermalkamera (senseFly ThermoMAP, FLIR Tau2) verwendet. Dieser Sensor besitzt eine Auflösung von 0.3 Megapixel (640×512 Pix.). Der Sensor ist in einem Bereich zwischen 7'000 und 14'000 nm sensitiv, mit einem Maximum bei 9'000 bis 11'000 nm. Seine thermale Auflösung liegt laut Hersteller bei 0.1 °C. Die Kalibration der Temperatur erfolgt automatisch während des Fluges in Form einer Schwarzkalibrierung. Tab. 3 fasst die Kenndaten der drei Befliegungen zusammen.

Tab. 3: Überblick über die UAS-Flüge

Datentyp	Sensor	Anzahl Bilder	Fläche	GSD	Projektions-Fehler
RGB	S.O.D.A	151	8.56 ha	1.54 cm	0.163 Pixel
Multispektral	Sequoia	174	13.57 ha	7.93 cm	0.261 Pixel
Thermal	ThermoMap	1526	12.32 ha	15.14 cm	0.536 Pixel

Während der Befliegung wurden mit einer GNSS-Basisstation RINEX-Daten aufgenommen, die im Postprocessing zur hochgenauen Bestimmung der Projektionszentren genutzt werden. Das Postprocessing der GNSS-Messungen funktionierte mit den RGB- und den Multispektraldaten ohne Fehler. Die Thermaldaten konnten wegen eines Fehlers in der Software auf diese Weise nicht korrigiert werden und die Orthophotos mussten mit Hilfe der AutoSync Workstation in Erdas Imagine 2014 zu den Multispektral-Daten auto-koregistriert werden.

Im Anschluss der Befliegung wurden mit der Software Pix4D die Daten photogrammetrisch prozessiert und Orthomosaik der drei Datensätze berechnet. Außerdem wurde aus den RGB-Daten ein digitales Oberflächenmodell und Graustufenbilder des Greennees Index sowie vier Vegetationsindizes aus den Multispektraldaten berechnet (Tab. 4). Das DOM stellt im nahezu ebenen Moor gleichzeitig ein digitales Objekthöhenmodell dar und gibt somit Auskunft über die Wuchshöhe der zu untersuchenden Pflanzengesellschaften.

Tab. 4: Übersicht über die verwendeten Vegetationsindizes

Index	Akronym	Formel	Referenz
Greennees	GI	$(G)/(R+G+B)$	BROWN et al. 2017
Normalized Difference Vegetation Index	NDVI	$(NIR-RED)/(NIR+RED)$	KROSS et al. 2015
Red Edge NDVI	reNDVI	$(NIR-RE)/(NIR+RE)$	KROSS et al. 2015
Red Edge / Red VI	reNDVI2	$(RE-RED)/(RE+RED)$	SCHUSTER et al. 2012
Green NDVI	gNDVI	$(NIR-GREEN)/(NIR+GREEN)$	KROSS et al. 2015

Wie Tab. 3 zu entnehmen ist, haben die Bilddatensätze unterschiedliche räumliche Auflösungen. Für die Auswertung wurden alle Datensätze auf eine einheitliche Auflösung von GSD = 20 cm umgerechnet (Resampling: Nearest Neighbor).

Nachdem alle Datensätze angepasst waren, wurde ein repräsentativer Ausschnitt des Untersuchungsgebiets ausgesucht und alle Daten an diesen angepasst. Danach erfolgte die Aneinanderreihung aller zur Verfügung stehenden Datensätze (Stacking). In Tab. 5 ist die neue Zusammensetzung des 14-kanaligen multisensoralen Datensatzes aufgelistet.

Tab. 5: Neue Kanalzusammensetzung des multisensoralen Datensatzes

No.	Band	Sensor	No.	Band	Sensor
1	B ₁	S.O.D.A.	8	DOM	generiert aus S.O.D.A.
2	G ₁	S.O.D.A.	9	Thermal	ThermoMAP
3	R ₁	S.O.D.A.	10	GI	generiert aus S.O.D.A.
4	G ₂	Sequoia	11	NDVI	generiert aus Sequoia
5	B ₂	Sequoia	12	reNDVI	generiert aus Sequoia
6	RE	Sequoia	13	reNDVI2	generiert aus Sequoia
7	NIR	Sequoia	14	gNDVI	generiert aus Sequoia

3.2 Klassifikation und Genauigkeitsbewertung

Die Klassifikation des multisensoralen Datensatzes wurde in Python 2.7.13 durchgeführt. Das Skript dafür steht auf github unter <https://github.com/florianbeyer/RandomForest-Classification> zur Verfügung. Der verwendete Algorithmus ist der Random Forest Classifier (RF, BREIMAN 2001) in einer Python-Bibliothek namens SciKit-learn 0.18.1 (PEDREGOSA 2011). Für den RF wurden 500 Bäume aufgebaut, um das Klassifikationsergebnis möglichst sicher zu bestimmen. Die Robustheit und Genauigkeit des RF gegenüber etablierter Klassifikatoren wie der Support Vector Machine oder dem Maximum Likelihood wurde unter anderem von BEYER et al. (2015) belegt.

Ein weiterer wesentlicher Punkt, warum die Wahl auf diesen Klassifikator fiel ist, dass man sich aus dem trainierten Modell die Relevanz (band importance) der eingeflossenen erklärenden Variablen (die einzelnen Bänder des multisensoralen Datensatzes) ausgeben lassen kann (BEHNA-MIAN et al. 2017; YU et al 2017), was in der vorliegenden Studie als wesentliche Information galt. So kann analysiert werden, inwiefern Bänder wie der thermale Datensatz oder das DOM aus der Photogrammetrie einen Beitrag zum Klassifikationsergebnis leisten und wie wichtig sie gegenüber den klassischen Wellenlängen der optischen Fernerkundung sind.

Des Weiteren wird gezeigt, inwiefern der trainierte Algorithmus den Trainingsdatensatz vorher-sagt. Da dies jedoch keine Aussagen zur Genauigkeit auf der Fläche zulässt, wurde mit einem unabhängigen Datensatz validiert. Die Gesamtgenauigkeit (OA), der Kappa-Koeffizient (κ), sowie die Einzelklassengenauigkeiten werden mithilfe der Benutzer- (UA) und der Produzentengenauigkeit (PA) verglichen. Abb. 2 fasst den beschriebenen Workflow nochmal zusammen.

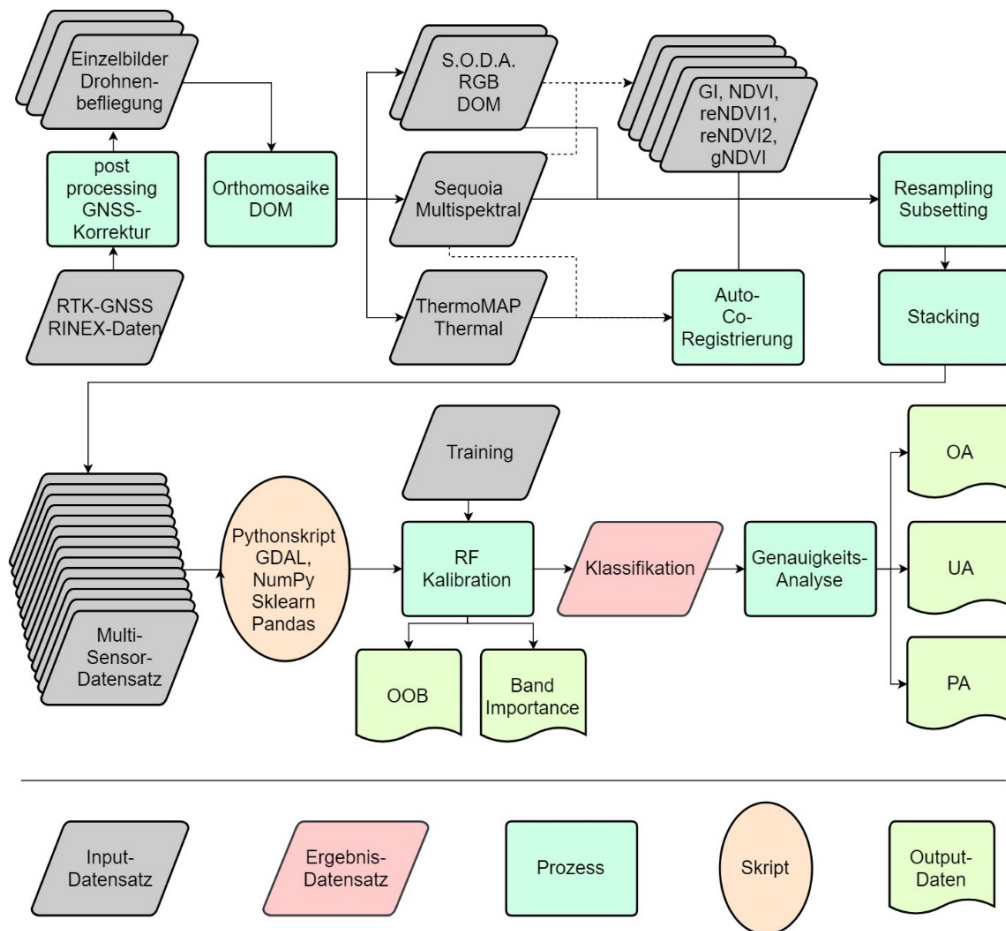


Abb. 2: Workflow der multisensoralen UAS-Datenanalyse

4 Ergebnisse & Interpretation

Nach erfolgreicher Datenvor- und Aufbereitung wurde mit Hilfe des Trainingsdatensatzes der 11 Klassen der RF trainiert. Mit dem trainierten Modell wurde zunächst der Trainingsdatensatz vorhergesagt, um die Kalibrationsgenauigkeit zu überprüfen. Der Tab. 6 kann man entnehmen, dass der Algorithmus zu 100 % (OOB = 99.85 %) an den Trainingsdatensatz angepasst wurde und jedes Pixel zur richtigen Klasse zu geordnet wurde.

Mit diesem Ergebnis wurde das RF-Modell auf das gesamte Untersuchungsgebiet angewendet. Das Ergebnis ist in Abb. 3 dargestellt und die Flächenanteile pro Klasse in Tab. 7. *Phragmites australis* ist mit 33 % entlang der Entwässerungsgräben im Süden und Westen flächenmäßig die dominante Klasse im Untersuchungsgebiet. Darauf folgen *Carex acutiformis* und *riparia* (*Carex* I: 24.85 %) innerhalb der Fläche. Diese *Carex*-Arten sind fast überall zu finden. Die selteneren *Carex rostrata* und *acuta* (*Carex* II) sind nur „patch“-artig auf einer kleinen Fläche im Zentrum des Untersuchungsgebietes zu finden (1.26 %).

Tab. 6: Fehlermatrix des vorhergesagten Trainingsdatensatzes

Vorhersage-Genauigkeit	Salix	Boden	Calamagrostis	Carex I	Epilobium	Glyceria	Carex II	Juncus	Phragmites	Typhia	Wasser	Total
Salix	5280	0	0	0	0	0	0	0	0	0	0	5280
Soil	0	170	0	0	0	0	0	0	0	0	0	170
Calamagrostis	0	0	2962	0	0	0	0	0	0	0	0	2962
Carex I	0	0	0	16650	0	0	0	0	0	0	0	16650
Epilobium	0	0	0	0	6194	0	0	0	0	0	0	6194
Glyceria	0	0	0	0	0	1691	0	0	0	0	0	1691
Carex II	0	0	0	0	0	0	4509	0	0	0	0	4509
Juncus	0	0	0	0	0	0	0	2342	0	0	0	2342
Phragmites	0	0	0	0	0	0	0	0	41504	0	0	41504
Typhia	0	0	0	0	0	0	0	0	0	6218	0	6218
Water	0	0	0	0	0	0	0	0	0	0	375	375
Total	5280	170	2962	16650	6194	1691	4509	2342	41504	6218	375	87895

Typha latifolia und *Epilobium hirsutum* haben beide einen Flächenanteil von etwa 14 %. Dabei kann grob eine Zonierung erkannt werden, wo im Norden eher *Epilobium* und südlich eher *Typha* zu finden ist. Dies kann mit der Nähe zum Entwässerungsgraben erklärt werden. BARRAQUETA et al. (1999) bestätigen, dass *Epilobium*- und verschiedenen *Carex*-Sorten bei Wassertiefen bis maximal 20 cm auftreten und sich *Typha* eher in tieferem Wasser (20 – 50 cm) entwickelt.

Offener Boden und Wasser sind die Klassen, die am wenigsten vorkommen. Jedoch muss Wasser als fehlklassifizierte Klasse interpretiert werden. Der Entwässerungsgraben im Westen des Gebietes wurde größtenteils als *Typha* identifiziert. Hier bedeckt *Typha* die Wasseroberfläche nahezu komplett und hat das dominierende Signal, was eine Klassifizierung der Wasserwege unmöglich macht. Westlich des Grabens verläuft ein Wirtschaftsweg, der irrtümlich als *Glyceria* identifiziert wurde. Die Gräser auf dem Wirtschaftsweg wurden in der Klassifikation nicht berücksichtigt und sind *Glyceria maxima* (Wasser-Schwaden) spektral ähnlicher als die restlichen Klassen.

Um die Gefahr einer Überanpassung (Overfitting) des Modells zu überprüfen, wurde der Validierungsdatensatz für eine unabhängige Überprüfung verwendet. Diese Validierung ergab, dass 60'917 der 68'482 Validierungs-Pixel den richtigen Klassen zugeordnet worden. Dies entspricht einer Gesamtgenauigkeit von $OA = 88.95\%$ und einem Kappakoeffizienten von $kappa = 0.8457$. Dies ist unter der gegebenen Anzahl an Klassen (11) und der Klassifikation zu einem einzigen Aufnahmezeitpunkt ein sehr gutes Ergebnis.

Klassifikationsergebnis

Random Forest

Tribsees,
Mittlere Trebel,
Durchströmungsmoor

WETSCAPES




Abb. 3: Klassifikationsergebnis

Tab. 7: Flächenanteile der Klassen im Untersuchungsgebiet

No.	Klasse	Pixel	Prozent	No.	Klasse	Pixel	Prozent
1	Salix	271033	2.72	7	Carex II	125943	1.26
2	Boden	16193	0.16	8	Juncus	345577	3.47
3	Calamagrostis	305766	3.07	9	Phragmites	3295576	33.09
4	Carex I	2474499	24.85	10	Typha	1392772	13.99
5	Epilobium	1419847	14.26	11	Wasser	47049	0.47
6	Glyceria	264333	2.65	Total		9958588	100.00

In Tab. 8 sind die Fehlermatrizen in prozentualen Angaben dargestellt. Falsch klassifizierte Pixel sind in Gelb dargestellt und als Commission-Fehler in der letzten Spalte gezeigt. Das sind Pixel, die irrtümlich einer falschen Klasse zugewiesen wurden. Alle von ihrer Klasse nicht erkannte Pixel sind in der blauen Fläche gekennzeichnet und als Omission-Fehler in der letzten Zeile aufgelistet. Zusätzlich sollen PA und UA nochmal pro Klasse interpretiert werden. Dafür sind in Abb. 4 diese Einzelklassengenauigkeiten direkt gegenübergestellt und die Werte in Tab. 8 ablesbar. Die PA beschreibt wie viele Pixel einer Klasse X tatsächlich richtig klassiert wurden. Die

UA nimmt die Summe aller als Klasse X identifizierten Pixel und setzt diese in Beziehung zu dem Anteil der davon tatsächlich der Klasse X angehört.

Tab. 8: Fehlermatrix der unabhängigen Validierung
(UA = Benutzergenauigkeit, PA = Produzentengenauigkeit)

Klassen in Prozent	Salix	Boden	Calamagrostis	Carex I	Epilobium	Glyceria	Carex II	Juncus	Phragmites	Typha	Wasser	Total	UA	Commission Er.
Unclassified	0	0	0	0	0	0	0	0.2	0	0	0	0		
Salix	79.1	0	0	0	0	0	0	0	0.3	0	0	4.0	95.7	4.3
Boden	0	94.8	0	0	0	0	0	0	0	0	0	0.2	100	0
Calamagrostis	0	0	63.3	1.4	0	0	0	7.4	0	0.8	0	2.6	83.1	16.9
Carex I	0	0	32.86	93	5.8	6.4	0	27.6	0	7.6	0	17.1	82.0	18.0
Epilobium	0	0	0	0.09	80.9	0	0	0.6	4.8	1.1	0	10.5	76.8	23.2
Glyceria	0	0	0	0	0	60.2	0	0	0	3.1	0	1.7	82.4	17.6
Carex II	0	0	0	0	0	0	100	0	0	0.5	0	3.9	98.7	1.3
Juncus	0	0	0.6	4.8	0	0.4	0	39.1	0	0.3	0	1.5	48.7	51.3
Phragmites	20.9	0	0	0	12.4	0	0	0	94.9	0	0	48.2	95.3	4.7
Typha	0	0	3.3	0.7	0.8	32.9	0	25.0	0	86.5	0	9.8	84.5	15.5
Wasser	0	5.2	0	0	0	0	0	0	0	0	100	0.5	98.0	1.9
Total	100	100	100	100	100	100	100	100	100	100	100	100		
PA	79.1	94.8	63.3	93	80.9	60.2	100	39.1	94.9	86.5	100			
Omission Er.	20.9	5.2	36.7	7	19.0	39.7	0	60.9	5.1	13.5	0			

Der Anteil an richtig klassifizierten Pixel ist bei den meisten Klassen sehr hoch (Abb. 4). Dazu gehören die Klassen Boden, Carex I, Carex II, Phragmites, Typha und Wasser mit einer PA und UA über 80 %. Auch Salix ergab gute Ergebnisse, denn die PA liegt bei fast 80 % und der richtige Anteil an allen der Klasse Salix zugeordneten Pixel beträgt 95.7 %. Über 80 % der Pixel von Epilobium wurden richtig zugeordnet, jedoch wurden auch knapp 19 % aus anderen Klassen dieser Klasse zugeordnet. Die sehr kleine Klasse Glyceria kommt immerhin noch auf 60 % richtig klassifizierte Pixel und weist eine hohe UA von über 80 % auf. Die Klasse Juncus ist die problematischste Klasse. Nur 40 % konnten der Klasse Juncus richtig zugeordnet werden und auch nur knapp 50% der als Juncus klassifizierten Pixel sind tatsächlich Juncus.




Abb. 4: Produzenten- (PA) und Benutzergenauigkeit (UA) pro Klasse

Die zentrale Frage in der vorliegenden Studie war, inwiefern zusätzliche Daten aus der Photogrammetrie, thermale Daten sowie Vegetationsindizes neben den etablierten spektralen Echtfarb-

und Infrarot-Kanälen einen Beitrag zur Klassifikation liefern können. Dafür wurde ein relativer Wert „Relevanz“ aus dem trainierten RF-Modell für jedes Band des multisensoralen Datensatzes extrahiert. Erstaunlicherweise sind die drei wichtigsten Bänder für den RF das DOM, die Thermaldaten und der reNDVI2, ein Vegetationsindex aus Rot und dem Red-Edge-Kanal (Tab. 9). Erst an vierter Stelle kommt der etablierte NDVI und der erste Farbkanal „NIR“ folgt auf Platz fünf. Dies ist daher erstaunlich, weil bisherige Forschungsarbeiten meistens die reinen Farbkanäle optischer Fernerkundungsdaten als wichtiger als daraus generierte Produkte identifizierten (u.a. LI et al. 2017; SCHUSTER et al 2012). Dies könnte ein Hinweis darauf sein, dass die neuen hochaufgelösten Skalen, die mit Fernerkundungs-Drohnen erreicht werden, im Gegensatz zu Flugzeug und Satelliten-Sensoren, neue Ergebnisse mit etablierten Methoden generieren können. Entgegen bisheriger Möglichkeiten lassen sich aus sich überlappenden Drohnen-Einzelbildaufnahmen immer Oberflächenmodelle generieren, die einen wesentlichen Informationsgehalt (Wuchshöhe) auf der Mikrorelief-Ebene zu haben scheinen. Außerdem bewegen sich die hochaufgelösten Daten im kontinuierlichen Übergangsbereich von der Bestandsebene zur Einzelpflanzenbetrachtung. Daher geben Vegetationsindizes eventuell neue Informationen preis, die auf größeren Daten vorher rausgemittelt wurden. Unerwartet war auch, dass die bei Tage aufgenommenen thermalen Daten bei Vegetationsanalysen einen so wichtigen Einfluss haben. Dies soll zukünftig bei weiteren Studien überprüft und vertieft untersucht werden.

Tab. 9: Relevanz der einzelnen Bänder als erklärende Variable in der Random Forest Klassifikation

No.	Band	Relevanz [%]	No.	Band	Relevanz [%]
1	DOM	39.84	8	gNDVI	3.53
2	Thermal	11.84	9	R ₂	3.20
3	reNDVI2	9.99	10	R ₁	2.57
4	NDVI	8.61	11	reNDVI	2.19
5	NIR	5.45	12	B ₁	2.03
6	RE	4.37	12	G ₁	1.48
7	G ₂	3.69	14	GI	1.21
Total					100.00

5 Zusammenfassung & Ausblick

Die vorliegende Studie untersucht zum einen die Genauigkeit der Klassifikation von Moorvegetation mithilfe verschiedener Sensoren eines UAS. Dabei kamen eine hochauflösende Echtfarbkamera, eine Multispektrale Frame-Kamera und eine Thermal-Kamera zur Anwendung. Zum anderen sollte die Studie zeigen, welcher dieser Datenarten sowie daraus generierte Produkte den größten Einfluss (Relevanz) auf die Klassifikationsgenauigkeit haben. Elf Klassen wurden mit dem Random Forest-Algorithmus klassifiziert.

Es wurde eine hohe Klassifikationsgenauigkeit von 88.95 % erreicht, welche durch eine unabhängige Validierung festgestellt wurde. Abgesehen von drei flächenmäßig kleinen Gruppen sind die Einzelbetrachtungen der Klassen mit über 80 % Genauigkeit sehr zufriedenstellend.

Die jedoch wichtigste Erkenntnis der Studie erbrachte die Analyse der Relevanz der berücksichtigten Variablen. Die vier wichtigsten Variablen für die Klassifikation waren nach Einfluss geordnet das Digitale Höhenmodell, die Thermaldaten, der normalisierte Vegetationsindex aus Rot

und Red-Edge und der NDVI. Erst an fünfter Stelle kommt der erste Farbkanal (NIR). Dies war so nicht zu erwarten und soll weiter untersucht werden. Auf der neuen Skalenebene, auf der UAS operieren, scheinen andere Parameter wichtig zu sein als bei herkömmlichen Satelliten- und Flugzeug-basierten Untersuchungen.

In Zukunft soll zum einen das Ergebnis auf anderen Moorstandorten verifiziert werden und zum anderen auch andere Aufnahmezeitpunkte während der phänologischen Entwicklung der Moorvegetation Aufschluss darüber geben wann welcher Vegetationstyp durch welche Datenart am besten beschrieben werden kann. Möglicherweise können so auch die schwachen Klassen besser identifiziert werden.

Außerdem war diese Analyse eine Vorstudie für tiefergehende Untersuchungen, welchen Beitrag UAS-Daten auf Moorstandorten bezüglich der Beschreibung des ökologischen Wertes wiedervernässter Moore leisten kann. So sollen beispielsweise die Vegetationsklassifikationen in Zukunft mit Treibhausgas-Emissionen verknüpft werden (COUWENBERG et al. 2011).

6 Danksagung

Besonderer Dank gilt Moritz KAISER (Universität Greifswald) für die am 24. Oktober 2017 durchgeführte Pflanzenkartierung und der anschließenden GIS-Aufbereitung der Daten. Des Weiteren gilt unser Dank Frau Dipl.-Biol. Birgit SCHRÖDER für die hilfreichen Tipps und Ratschläge bezüglich botanischer Fragen. Die vorliegende Studie ist eingebettet in das Verbundprojekt WETSCAPES der Universitäten Rostock und Greifswald, ein Exzellenzforschungsprogramm finanziert durch das Ministerium für Bildung, Wissenschaft und Kultur Mecklenburg-Vorpommern und dem Europäischen Sozial Fond (ESF/14-BM-A55-0034/16).

7 Literatur

- BEHNAMIAN, A., MILLARD, K., BANKS, S.N., WHITE, L., RICHARDSON, M. & PASHER, J., 2017: A Systematic Approach for Variable Selection With Random Forests: Achieving Stable Variable Importance Values. *IEEE Geoscience and Remote Sensing Letters*, **14**(11), 1988-1992. DOI: 10.1109/LGRS.2017.2745049.
- BEYER, F., JARMER, T. & SIEGMANN, B., 2015: Identification of Agricultural Crop Types in Northern Israel using Multitemporal RapidEye Data. *PFG – Journal for Photogrammetry, Remote Sensing and Geoinformation*, **2015** (1), 21-32. DOI: 10.1127/pfg/2015/0249.
- BISHOP, C., 2006: *Pattern Recognition and Machine Learning*. Springer-Verlag New York.
- BREIMAN, L., 2001: Random Forests. *Machine Learning*, **45**(1), 5-32. DOI: 10.1023/A:1010933404324.
- BROWN, L.A., DASHA, J., OGUTUA, B.O. & RICHARDSON, A.D., 2017: On the relationship between continuous measures of canopy greenness derived using near-surface remote sensing and satellite-derived vegetation products. *Agricultural and Forest Meteorology*, **147**, 280-292. DOI: 10.1016/j.agrformet.2017.08.012.
- BARRAQUETA, P., HERAS, P. & INFANTE, M., 1999: *Saldropo: Vom Moor zum Feuchtgebiet. Bodenökologie interdisziplinär*, Koehler, H., Mathes, K., Breckling, B. (Hrsg.), Springer-Verlag Berlin Heidelberg GmbH, 189-198. DOI: 10.1007/978-3-642-58495-4.

- Couwenberg, J., Thiele, A., Tanneberger, F., Augustin, J., Bärtsch, S., Dubovik, D., Liashchynskaya, N., Michaelis, D., Minke, M., Skuratovich, A. & Joosten, H., 2011: Assessing greenhouse gas emissions from peatlands using vegetation as a proxy. *Hydrobiologia*, **674**, 67–89. DOI: 10.1007/s10750-011-0729-x.
- KROSS, A., MCNAIRN, H., LAPEN, D., SUNOHARA, M. & CHAMPAGNE, C., 2015: Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. *International Journal of Applied Earth Observation and Geoinformation*, **34**, 235–248. DOI: 10.1016/j.jag.2014.08.002.
- LI, X., CHEN, W., CHENG, X., LIAO, Y. & CHEN, G., 2017: Comparison and integration of feature reduction methods for land cover classification with RapidEye imagery. *Multimedia Tools and Applications*, **76**(21), 23041–23057. DOI: 10.1007/s11042-016-4311-4.
- MARCEAU, D.J. & HAY, G.J., 1999: Remote Sensing Contributions to the Scale Issue. *Canadian Journal of Remote Sensing*, **25**(4), 357–366. DOI: 10.1080/07038992.1999.10874735.
- Mutanga, O. & Skidmore, A.K., 2007: Red edge shift and biochemical content in grass canopies. *ISPRS Journal of Photogrammetry and Remote Sensing*, **62**(1), 34–42. DOI: 10.1016/j.isprsjprs.2007.02.001.
- PEDREGOSA, G., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, B., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M. & DUCHESNAY, E., 2011: Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, **12**, 2825–2830.
- SCHUSTER, C., FÖRSTER, M. & KLEINSCHMIT, B., 2012: Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. *International Journal of Remote Sensing*, **33**(17), 5583–5599. DOI: 10.1080/01431161.2012.666812.
- SIEGMANN, B., JARMER, T., BEYER, F. & EHLERS, M., 2015: The Potential of Pan-Sharpened EnMAP Data for the Assessment of Wheat LAI. *Remote Sensing*, **7**(10), 12737–12762. DOI: 10.3390/rs71012737.
- WU, H. & LI, Z.L., 2009: Scale Issues in Remote Sensing: A Review on Analysis, Processing and Modeling. *Sensors*, **9**(3), 1768–1793. DOI: 10.3390/s90301768.
- Yu, B., Chen, F. & Chen, H., 2017: NPP estimation using random forest and impact feature variable importance analysis. *Journal of Spatial Science*, 1–20. DOI: 10.1080/14498596.2017.1367331.
- ZIEBARTH, M., LENSCHOW, U. & PERMIEN, T., 2009: Konzept zum Schutz und zur Nutzung der Moore - Fortschreibung des Konzeptes zur Bestandssicherung und zur Entwicklung der Moore. Ministerium für Landwirtschaft, Umwelt und Verbraucherschutz Mecklenburg-Vorpommern.