

Kartierung von Seegras mit dem Fächerecholot in der Ostsee mit Hilfe von maschinellem Lernen

Ein Beitrag von CHRIS STRASSBURGER

Unterwasservegetation in den Küstenzonen führt bei hydrographischen Messungen häufig zu ungewünschten Störungen in Form von Fehlechos. Aus Sicht der Habitatforschung verbergen sich jedoch hinter den vermeintlichen Fehlechos wertvolle Informationen. Die akustische Fernerkundung in der Ostsee in Bezug auf die Habitatkartierung, insbesondere von Seegrasökosystemen, rückt in den letzten Jahren in den Forschungsvordergrund. Zudem gelten Seegrasvorkommen als stark gefährdet und es gibt kaum Basisdaten zur Verbreitung und räumlichen Struktur. Daher ist eine Kartierung der Lebensräume zu ihrem Schutz von großer Bedeutung. Ziel ist es, dem entgegenzuwirken und eine Methodik zu entwickeln, um Steine, Seegraswiesen sowie Sandflächen zu kartieren. Dies geschieht durch die Auswertung von Fächerecholotdaten, gezielte Punktwolkenanalyse, Merkmalsableitung und Klassifizierung durch künstliche Intelligenz.

Habitatkartierung | KI | Seegraswiese | SAV | Random Forest
habitat mapping | AI | seagrass meadow | SAV | Random Forest

Underwater vegetation in the coastal zones often leads to unwanted disturbances in the form of false echoes during hydrographic surveys. From the point of view of habitat research, however, the supposed false echoes conceal valuable information. Acoustic remote sensing in the Baltic Sea with regard to habitat mapping, especially of seagrass ecosystems, has moved into the research foreground in recent years. In addition, seagrass occurrences are considered highly endangered and there are hardly any baseline data on distribution and spatial structure. Therefore, habitat mapping is of great importance for their protection. The aim is to counteract this and to develop a methodology to map rocks, seagrass meadows as well as sandy areas. This is done by evaluating multibeam echo sounder data, targeted point cloud analysis, feature derivation and classification using artificial intelligence.

Autor

Chris Straßburger hat seine Bachelorarbeit an der Uni Kiel geschrieben. Inzwischen ist er im Masterstudium.

stu204376@mail.uni-kiel.de

Einleitung

Seegraswiesen zählen grundlegend zu den wertvollsten und produktivsten Ökosystemen der Erde (Costanza et al. 1997). Die Seegrasökosysteme weisen wesentliche Funktionen auf, welche die physikalische, chemische und biologische Umwelt in Küstengewässern beeinflussen, indem sie organischen Kohlenstoff produzieren sowie exportieren und den Kohlenstoffkreislauf in Küstengewässern regulieren (Lamb et al. 2017). Seegraswiesen binden mehr CO₂ als vergleichbar große Waldflächen, wodurch ihre Rolle als natürlicher Speicher zunehmend wichtiger wird. Gleichzeitig stellen sie Nahrungskreisläufe her, bieten anderen Organismen Schutz und Lebensräume, stabilisieren küstennahe Sedimente, beugen Küstenerosion vor und sind enorm wichtig für ein funktionierendes Ökosystem im Meer. Aktuell ist jedoch das Wissen über die räumliche Verbreitung sowie den gesundheitlichen Zustand der Habitate nicht umfassend erfasst.

Für die Region der westlichen Ostsee stehen kaum Basisdaten von *Zostera marina* (Gewöhnliches Seegras) zur Verfügung. Dies bedeutet, dass es keine Informationen über Prozesse, Auswirkungen von Küstenschutzmaßnahmen und Infrastruktur, Rückgangs- oder Wachstumsraten sowie eine vollständige Kartierung der Ökosysteme gibt. Um Auskunft darüber zu erhalten, wurde eine Forschungsausfahrt mit der Bezeichnung LIT/1907 im Rahmen des Forschungsprojektes »ECOMAP – Baltic Sea environmental assessments by innovative opto-acoustic remote sensing, mapping, and monitoring« vom 11. bis zum 14. Juni 2019 durchgeführt. Dabei wurde die westliche Ostsee mit dem Forschungsschiff *Littorina* von der Geltinger Bucht bis hin zur Kolberger Heide küstenparallel in einer durchschnittlichen Wassertiefe von fünf Metern mit einem modernen Fächerecholotssystem vermessen. Das Forschungsgebiet sowie die Vermessungsspurten und Testgebiete sind in [Abb. 1](#) dargestellt.

Die Grundlage der Arbeit beruht auf den Forschungen von Held und Schneider von Deimling (2019). Dabei wurde eine Methodik entwickelt, die auf den räumlichen Eigenschaften der Nachbarschaften jedes Punktes in der Punktwolke und deren abgeleiteten Merkmalen basiert und durch maschinelles Lernen Seegras und andere Objekte vom Meeresboden trennen kann (Held und Schneider von Deimling 2019).

Dabei gilt es, dieses Verfahren mit den Fächerecholotdaten der Geltinger Bucht zu erweitern und zu erproben, um eine großflächige Kartierung im Gebiet zu ermöglichen.

Ziel ist, mit Hilfe von maschinellem Lernen eine großräumige Klassifizierung zwischen Seegras, Steinen und dem Meeresboden aus rohen Fächerecholotdaten zu erreichen.

Fächerecholote

Fächerecholote (MBES) wurden in den 1960er-Jahren entwickelt, um genaue und effiziente Tiefensondierungen durchzuführen, welche zur Interpretation des Meeresbodens genutzt werden können (Glenn 1970). Besonders in den letzten zwei Jahrzehnten wurden große Fortschritte in der Signalverarbeitung, der Bodenerkennung sowie bei der Positionierung und Bewegungserfassung erungen, sodass heute hochgenaue und hochauflösende Tiefenmessungen, insbesondere bei geringen Wassertiefen, möglich sind (Hughes Clarke 1996). Moderne Systeme führen durch die Cross-Array-Technologie und verbesserte Nahfeldfokussierung zu engerer Bündelung im Sonarfeld und somit zu einer extrem hohen Punktdichte, welche übergeordnete Informationen in Bezug auf ihre Gitterdaten enthalten, welche zunehmend zur Kartierung genutzt werden (Gumusay 2019). Somit bieten die Fächerecholote eine Fächerabdeckung von bis zu 160 Grad sowie integrierte hochauflösende Bathymetrie und Backscatter.

Heute sind MBES-Systeme leistungsstarke Geräte für die Klassifizierung des Meeresbodens und die Kartierung von Lebensräumen. Es besteht kein Zweifel, dass viele Arten von submariner aquatischer Vegetation (SAV) akustisch erfasst werden können.

Bei einer bathymetrischen Messung wird häufig die Krone der Seegraswiesen detektiert. Diese bildet im Vergleich zum Meeresboden deutliche Anomalien in ihrer Form aus, welche genutzt werden können, um Seegras zu kartieren und gleichzeitig Bewuchshöhen zu berechnen (Held und Schneider von Deimling 2019).

Methodik

MBES-Vermessung und Videovalidierung

Auf der Forschungsausfahrt LIT/1907 wurde das Fächerecholot Norbit iWBMS STX Multibeam Sys-

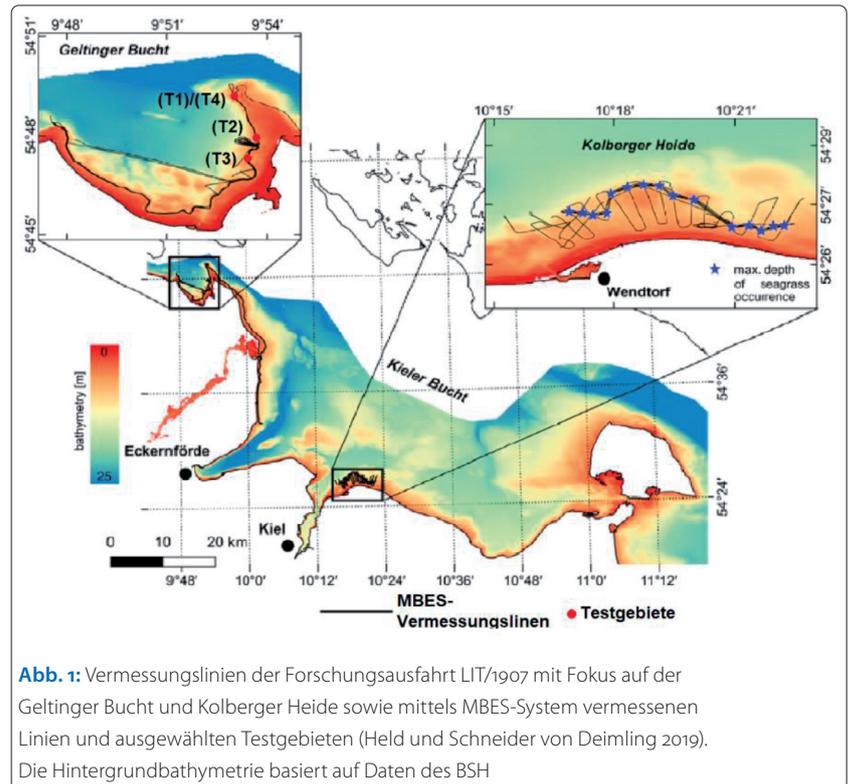


Abb. 1: Vermessungslinien der Forschungsausfahrt LIT/1907 mit Fokus auf der Geltinger Bucht und Kolberger Heide sowie mittels MBES-System vermessenen Linien und ausgewählten Testgebieten (Held und Schneider von Deimling 2019). Die Hintergrundbathymetrie basiert auf Daten des BSH

tem mit 400 kHz, 150° Öffnungswinkel des Fächers, einer räumlichen Auflösung im Dezimeterbereich und zentimetergenauer Echtzeitkorrektur (Real Time Kinematic, RTK) verwendet (Held und Schneider von Deimling 2019).

Für die Validierung werden ausschließlich Videoaufnahmen genutzt, da optische Fernerkundungen aufgrund einer durchschnittlichen Wassertiefe von ca. 5 m im optisch trüben Wasser der Ostsee an ihre Grenzen stoßen (Schneider von Deimling und Feldens 2021). Das im Fokus stehende Gebiet der Geltinger Bucht wurde im Auftrag des LLUR (Landesamt für Landwirtschaft, Umwelt und ländliche Räume) durch Videoaufnahmen untersucht. Das entstandene Material wird zur optisch-akustischen Validierung der Fächerecholotdaten genutzt.

Datenbearbeitungen und Merkmalsberechnung

Die üblichen MBES-Nachbearbeitungsschritte wie Patch-Test-Kalibrierung, Raytracing, Schallgeschwindigkeitskorrektur, Gezeitenreduktion und die Entfernung von Ausreißern aus den Rohdaten wurden mit dem Programm Qimera der Firma Quality Positioning Services (QPS) durchgeführt. Die bereinigte, nicht gerasterte dreidimensionale (3D) Punktwolke (PCL) wird anschließend als xyz-ASCII in kartesischen Koordinaten (UTM Zone 32N) mit einem Höhenbezug auf das deutsche Höhenhauptnetz (DHHN) exportiert.

Es werden zylindrische Nachbarschaften mit einem Radius von 0,3 m für alle Punkte in den Punktwolken berechnet und zur Merkmalsberechnung

durch ein C++-Programm, welches von Held und Schneider von Deimling (2019) entwickelt wurde, weiterverarbeitet. Somit werden die vertikale Verschiebung, drei lokale Merkmale (Linearität, Planarität, Sphärizität) und andere Maße wie Omnivarianz, Anisotropie, Eigenentropie, Änderung der Krümmung, Distanz sowie Winkel zur Ebene berechnet. Insgesamt werden neun Merkmale generiert, welche als Eingabe für die Klassifizierung durch das maschinelle Lernen auf der Grundlage des Random Forest (RF) fungieren.

Maschinelles Lernen auf Grundlage des Random Forest

Für die überwachte Klassifizierung wird ein maschinelles Random-Forest-Lernverfahren verwendet, um zwischen Seegras, Steinen und dem Meeresboden zu unterscheiden. Dabei wird mit der Open-Source-Bibliothek mlpack gearbeitet. Der RF fungiert als Ensemble-Klassifizierer, wodurch mehrere Entscheidungsbäume auf Grundlage der Untermengen der Eingabewerte erstellt werden (Breiman 2001). Als Ergebnis wird die Klasse ausgegeben, die durch die meisten Entscheidungsbäume vorhergesagt wird.

Die Berechnungen auf ungerasterte PCLs benötigen einen extrem leistungsstarken Computer, weswegen das gesamte Forschungsgebiet in vier

kleine Teilgebiete mit unterschiedlichen Habitaten unterteilt wurde. Die geografische Lage der Testgebiete (T1 bis T4) ist in [Abb. 1](#) dargestellt. Mittlerweile konnte das Verfahren erfolgreich in der Cloud (1&1 Ubuntu Server) angewendet werden.

Für die Erstellung und Testung eines maschinellen Klassifikationsmodells werden Trainings- sowie Testdatensätze benötigt. Dafür werden die Testgebiete manuell – durch die zugrunde liegende opto-akustische Validierung – im Programm Qimera klassifiziert. Dies wird als fundamental wichtiger Schritt angesehen, denn je exakter die manuelle Klassifizierung ist, umso genauer werden die Trainingsdaten für die künstliche Intelligenz und desto exakter die Ergebnisse. Aus diesem Grund werden Unterscheidungsmerkmale von Seegras- und Steindetektionen durch Videoanalysen untersucht und diese Grundlage sowie weitere Videos zur manuellen Kartierung genutzt. In [Abb. 2](#), werden die Charakteristiken grafisch dargestellt.

Der fertig klassifizierte Datensatz wird nach dem Zufallsprinzip in jeweils einen Testpunkt- (30 %) und Trainingspunkt datensatz (70 %) gespalten. Der Trainingsdatensatz wird zum Trainieren des RF-Modells genutzt und anschließend durch die Testpunkte überprüft. Das maschinelle Random-Forest-Lernverfahren wird zuerst in einem Mischhabitat (T1) getestet. Im zweiten Testgebiet, einer Seegraswiese, wird der RF mit den Trainingsdaten aus dem ersten Gebiet (T1) verknüpft, und anschließend wird überprüft ob Seegräser als Steine fehlerhaft kartiert werden. Das gewonnene Modell wird mit den Trainingsdaten aus einem Steinfeld (T3) kombiniert und auf Steine untersucht. Im letzten Schritt wird das Modell an einem unbekanntem Mischhabitat (T4) getestet.

Ergebnisse

Berechnete Merkmale der Punktwolken

Alle neun berechneten Merkmale aus dem ersten Testgebiet (T1) zeigen deutliche Reaktionen auf Seegras-, Stein- und Sandflächen. Zur visuellen Veranschaulichung sind in [Abb. 3](#) die drei lokalen Merkmale Linearität (a), Planarität (b), Sphärizität (c) und andere Maße wie Omnivarianz (d), Anisotropie (e) und Änderung der Krümmung (f) dargestellt. Die bathymetrische Karte, Unterwasserfotos und eine manuell klassifizierte Karte sind zum Vergleich in [Abb. 4](#) abgebildet.

Die Linearität ist für die Erkennung von aufgereihten Punkten von Bedeutung und somit ein gutes Merkmal zur Erkennung von Seegras und Steinen. Die flachen sandigen Regionen mit hoher Ebenheit können durch die Planarität erkannt werden. Ebenso werden Punkte in der Punktwolke mit einer hohen Krümmung durch das Merkmal Sphärizität erfasst (Lin et al. 2014). Insgesamt

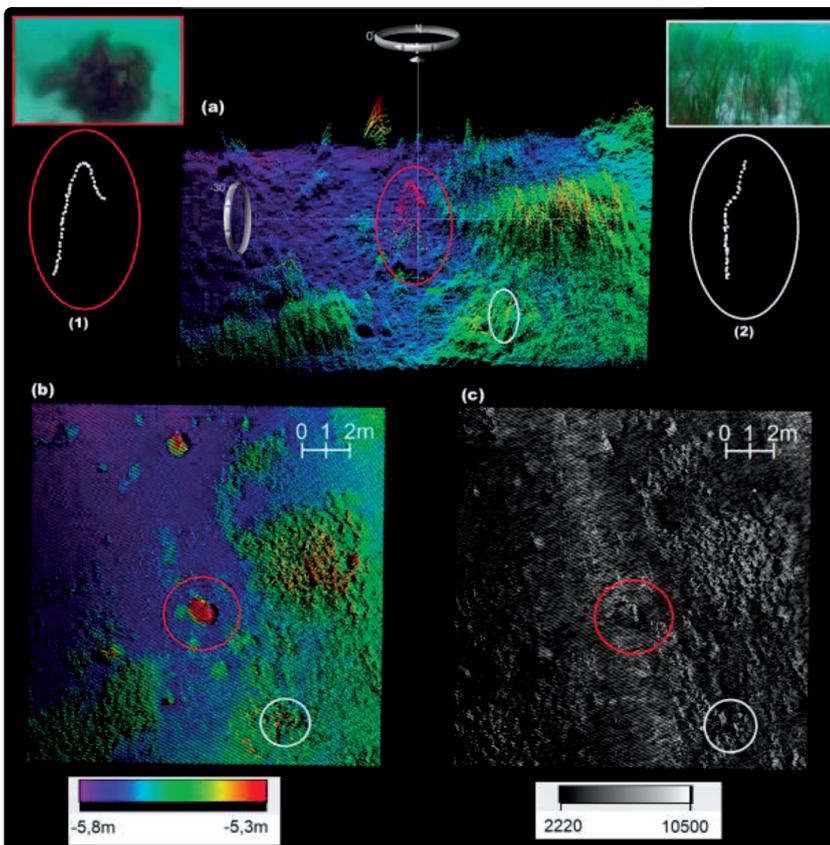


Abb. 2: Darstellung der untersuchten Punktwolke mit einem um -30° geneigten Blick Richtung Norden (a), einer Draufsicht der Bathymetrie (b) und der Rückstreuintensität (c) sowie ein skizziertes Rückstreusignal eines Steines (1) und von einem Seegrasblatt (2)

zeigen alle Merkmale deutliche Reaktionen gegenüber den drei Klassen. Dies stellt eine gute Basis dar, um mit der maschinellen Klassifizierung fortzufahren.

Klassifizierung durch den Random Forest

Das erste Testgebiet (T1) zeigt ein klassisches Mischhabitat mit Seegraswiesen, Steinen und Sandflächen in der Geltinger Bucht auf. Der Random Forest (RF) erzielt eine Klassifizierungsgenauigkeit von 82,1 %. In der Abb. 4 erkennt man eine bathymetrische Karte mit Unterwasserfotos (1) sowie den manuell (2) und den durch den RF klassifizierten Bereich (3) als optischen Vergleich.

Als erstes Ergebnis zeigen die RF-klassifizierten Seegraswiesen eine sehr lückenhafte Bedeckung auf und sehr kleine bis mittelgroße Steine werden als Seegras identifiziert. Dabei wird deutlich, dass Steine, die eine Größe kleiner als 18 cm besitzen, fehldetektiert werden. Durch ein Kronendach-Höhenmodell (CHM) können Bewuchshöhen bis maximal 43 cm festgestellt werden. Im zweiten Testgebiet hingegen bis zu 52 cm. Der RF erreicht im Testgebiet (T2) eine Klassifizierung mit einer Genauigkeit von 89,5 %. Deutlich festzustellen sind klare Abgrenzungen zwischen Seegraswiesen und Sandflächen. Die bewachsenen Abschnitte sind wesentlich dichter klassifiziert. Zudem werden nur sehr wenige Steine fehldetektiert, was als deutlicher Erfolg gilt.

Im dritten Testgebiet (T3) erstreckt sich ein Steinfeld, wobei schätzungsweise 95 % der Steine mit Algenbewuchs durch Videoanalysen erkannt werden. Auf Basis der geringen Datengrundlage wird die Unterscheidung zwischen bewachsenen und unbewachsenen Steinen nicht weiter untersucht, jedoch wird ein Ansatz mit Hilfe von Rückstreuintensitäten gefunden, um auch zwischen diesen Klassen unterscheiden zu können.

Dieses Gebiet wird genutzt, um eine Untersuchung von kleinen sowie mittelgroßen Steinen durchzuführen. Das Modell erzielt eine Genauig-

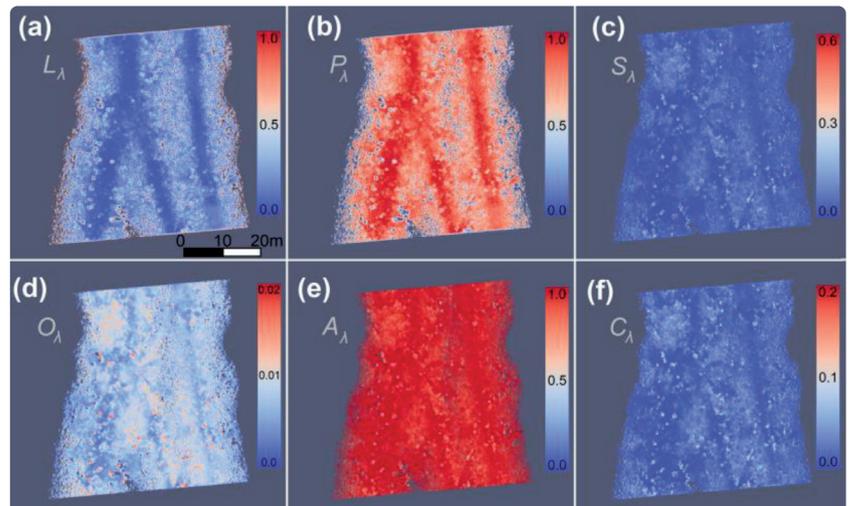


Abb. 3: Grafische Darstellung der berechneten Merkmale der Linearität (a), Planarität (b), Sphärität (c), Omnivarianz (d), Anisotropie (e) und Änderung der Krümmung (f) im ersten Testgebiet (T1), welches durch drei MBES-Spuren vermessen wurde

keit von 65 %, wobei 35 % der Steine als Seegras fehldetektiert sind. Letztendlich bedeutet dies, dass Steine anhand eines punktwolkenbasierten Ansatzes nur klassifiziert werden, wenn sie eine bestimmte Größe und Charakteristik besitzen. Sehr kleine bis mittelgroße Steine mit einem maximalen Durchmesser von 15 cm, werden durch den RF als Seegras klassifiziert.

Im letzten Schritt wird das gewonnene RF-Modell aus den Testgebieten (T1), (T2) und (T3) an einem neuen unbekanntem Mischhabitat (T4) getestet. Im vierten Testgebiet (T4) können Seegraswiesen, welche von flachen sandigen Bereichen eingegrenzt sind, in denen unterschiedlich große Steine vorkommen, erkannt werden. Die Seegrasdächer können mit einer maximalen Bewuchshöhe von 55 cm ermittelt werden. In der Abb. 5 erkennt man eine bathymetrische Karte des Testgebietes (T4) mit Unterwasserfotos (1) sowie den manuell (2) und den durch den RF klassifizierten Bereich (3) als optischen Vergleich.

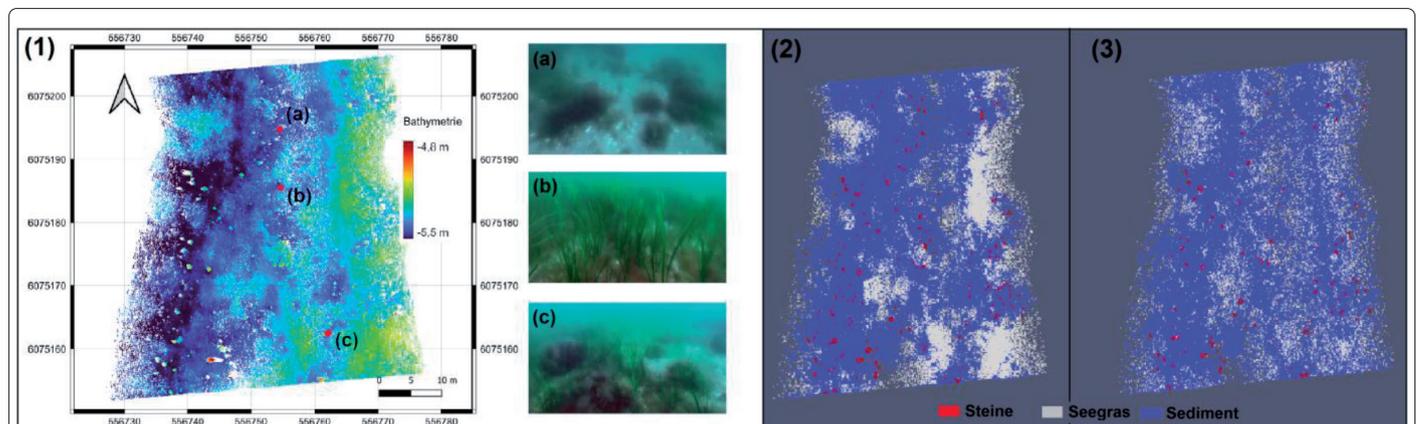


Abb. 4: Bathymetrische Karte des ersten Testgebietes (T1) mit Unterwasserfotos (1) sowie eine manuell erstellte (2) und eine durch den RF klassifizierte Karte (3) als Vergleich

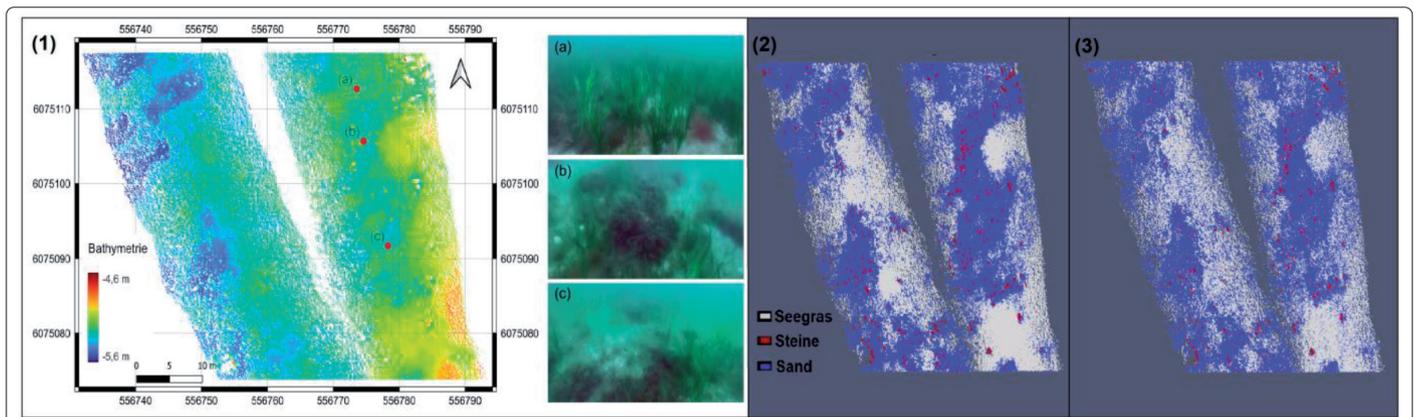


Abb. 5: Darstellung einer bathymetrischen Karte (1) des vierten Testgebietes (T4) mit Unterwasserfotos sowie eine manuell erstellte (2) und eine durch das Modell klassifizierte Karte (3) als Vergleich

Die Klassifizierungsgenauigkeit im vierten Testgebiet (T4) beträgt gegenüber der manuellen Karte 90,7 %, was ein sehr gutes Ergebnis ist, um Mischhabitate erfolgreich zu klassifizieren. Zudem werden alle Steine erkannt, welche eine Größe größer als 15 cm aufweisen. Da Steine in der Ostsee als schützenswertes Hartsubstrat gelten, ist eine verlässliche Detektion für Umweltbehörden von großer Bedeutung.

Ausblick

Zusammenfassend wird gezeigt, dass Punktwolken von Fächerecholoten mit Hilfe von künstlicher Intelligenz klassifiziert werden können. Dabei ist das entstandene Modell in der Lage, eine Kartierung zwischen Seegras, Steinen und dem Meeresboden mit einer Genauigkeit von 90,7 %

durchzuführen. Die entwickelte Methodik kann als ein automatisierter Filter für die Tiefenmessung betrachtet werden, wodurch automatisch die Daten auf Seegras- sowie Steinrückstreuungen gefiltert und somit klassifiziert werden.

Zukünftige Seevermessungen können somit zur großräumigen Kartierung von Seegras beitragen, um eine Datengrundlage zu erschaffen, wodurch ein gegenseitiger Nutzen zwischen Seevermessungs-, Seekartenhersteller-, Meeresboden- und Lebensraumkartierungs-Gemeinschaften entsteht. Hierbei können die MBES-Vermessungen und die entstandene Interaktion mit Seegras in Zukunft besser verstanden werden sowie Fragen über Vorkommen, Gesundheitszustand, Wachstums- und Rückgangsraten künftig beantwortet werden. //

Literatur

- Breiman, Leo (2001): Random Forests. Machine Learning, DOI: 10.1023/A:1010933404324
- Costanza, Robert; Ralph d'Arge; Rudolf de Groot et al. (1997): The value of the world's ecosystem services and natural capital. Nature, DOI: 10.1038/387253a0
- Glenn, Morris F. (1970): Introducing an operational multi-beam array sonar. International Hydrographic Review, No. 47, S. 35–39
- Gumusay, Mustafa Umit; Tolga Bakirman; Inci Tuney Kizilkaya; Nedim Onur Aykut (2019): A review of seagrass detection, mapping and monitoring applications using acoustic systems. European Journal of Remote Sensing, DOI: 10.1080/22797254.2018.1544838
- Held, Philipp; Jens Schneider von Deimling (2019): New Feature Classes for Acoustic Habitat Mapping – A Multibeam Echosounder Point Cloud Analysis for Mapping Submerged Aquatic Vegetation (SAV). Geosciences, DOI: 10.3390/geosciences9050235
- Hughes Clarke, John E.; Larry A. Mayer; David E. Wells (1996): Shallow-water imaging multibeam sonars: A new tool for investigating seafloor processes in the coastal zone and on the continental shelf. Marine Geophysical Researches, DOI: 10.1007/BF00313877
- Lamb, Joleah B.; Jeroen A.J.M. van De Water; David G. Bourne et al. (2017): Seagrass ecosystems reduce exposure to bacterial pathogens of humans, fishes, and invertebrates. Science, DOI: 10.1126/science.aah1956
- Lurton, Xavier (2002): An Introduction to Underwater Acoustics: Principles and Applications. Springer, ISBN: 978-3-662-49969-6
- Schneider von Deimling, Jens (2019): Cruise Report RV Littorina LIT/1907: Hydroacoustic assessment of the seagrass *Zostera marina* with modern multibeam echosounding in the Geltinger Bucht and the Kolberger Heide. BONUS ECOMAP, URL: <https://oceanrep.geomar.de/id/eprint/46977>
- Schneider von Deimling, Jens; Peter Feldens (2021): ECOMAP – Habitatkartierung mittels innovativer optischer und akustischer Fernerkundungs- und Auswerteverfahren. Hydrographische Nachrichten, DOI: 10.23784/HN120-02