

Journal of Applied Hydrography

HYDROGRAPHISCHE NACHRICHTEN

06/2026

HN 134

Hydrographie
im Kontext der
Nachhaltigkeit



Beiträge vom
38. Hydrographentag
und DVW-Seminar



Detektion von Hydrothermalfeldern in der Tiefsee

Ein Beitrag von TANJA DUFEK

Hydrothermalfelder | Exploration | marine Massivsulfidlagerstätten | Fächerecholotdaten | CNN U-Net
hydrothermal fields | exploration | seafloor massive sulphide deposits | MBES data | CNN U-Net

Autorin

Dr. Tanja Dufek arbeitet als Senior Geodata Advisor bei der Fugro Germany Marine GmbH in Bremen. Zuvor war sie wissenschaftliche Mitarbeiterin an der HafenCity Universität.

t.dufek@fugro.com

Hydrothermalfelder sind Gebiete, in denen hydrothermale Fluide austreten. Umgangssprachlich werden sie auch als »schwarze Raucher« bezeichnet (Abb. 1a); sie wurden erst vor weniger als 50 Jahren entdeckt (Corliss et al. 1979). Die austretenden Fluide können Temperaturen von über 400 °C erreichen und sind mit Edelmetallen angereichert. Beim Kontakt mit dem kalten Meerwasser fallen diese Metalle in Form von Sulfiden aus. Ein Teil der Partikel wird durch Strömungen abgetrieben, der Großteil lagert sich jedoch direkt an der Austrittsstelle, größtenteils unter dem Meeresboden, als Lagerstätte ab. An der Meeresbodenoberfläche sind sie als Sulfidhügel mit Durchmessern bis zu etwa 150 m erkennbar. Aufgrund ihrer chemischen Zusammensetzung gelten sie als potenzielle künftige Quelle metallischer Rohstoffe.

Seit 2015 hat die BGR (Bundesanstalt für Geowissenschaften und Rohstoffe) einen Lizenzvertrag mit der Internationalen Meeresbehörde zur Erkundung polymetallischer Massivsulfidlagerstätten, die durch hydrothermale Aktivität entstanden sind. Das Lizenzgebiet befindet sich im Indischen Ozean entlang des Zentral- sowie Südostindischen Rückens. Ziel der Erkundung ist es, Massivsulfidvorkommen zu identifizieren, zu kartieren und zu charakterisieren. Mindestens 50 % der Lizenzarbeiten sind zudem Umweltuntersuchungen gewidmet, die dem Schutz und Erhalt mariner Ökosysteme dienen (BGR 2026). Als Lizenznehmer wird die BGR darüber hinaus bei der Entwicklung zukünftiger Richtlinien und Standards konsultiert.

Typische Methoden zur Identifizierung neuer hydrothermaler Vorkommen basieren auf der Detektion chemischer Anomalien in der Wassersäule, die von austretenden hydrothermalen Fluiden herrühren. Mit Hilfe von Fächerecholotdaten werden potenzielle hydrothermale Gebiete kartiert und Austrittsstellen der Fluide lokalisiert, da hydrothermale Plumes in den Wassersäulendaten des Fächerecholots sichtbar sind (Abb. 1b). Zu diesem Zweck setzt die BGR die eigens entwickelte Echolot-Trägerplattform HOMESIDE (Abb. 1c) ein, die in etwa 100 m Höhe über dem Meeresboden hinter dem Schiff geschleppt wird.

Für die Exploration sind jedoch im Allgemeinen nicht die aktiven, sondern bereits erloschene hydrothermale Systeme von größerem Interesse. Diese sind in der Regel älter und konnten somit über längere Zeiträume Metallsulfide akkumulieren. Da sie jedoch keine aktiven Plumes mehr aufweisen, greifen klassische Erkundungsmethoden zu ihrer Entdeckung nicht. Im Rahmen der hier beschriebenen Dissertation wurde ein Workflow entwickelt, der es ermöglicht, Sulfidhügel sowohl aktiver als auch erloschener Hydrothermalquellen zu detektieren.

Verbesserung der Datenqualität

Grundlage bilden hochaufgelöste Fächerecholotdaten des HOMESIDE (Bathymetrie 2 m, Rückstreuungintensitäten 1 m). Das Untersuchungsgebiet umfasst eine Fläche von 782 km² und enthält sieben




Abb. 1: (a) Bild eines aktiven schwarzen Rauchers auf einem Sulfidhügel. (b) 3D-Visualisierung von HOMESIDE mit dargestellten Wassersäulendaten des Fächerecholots, in denen der Plume eines schwarzen Rauchers zu erkennen ist. (c) Tiefseeschlitten HOMESIDE

Hydrothermalfelder mit insgesamt 88 aktiven und erloschenen Vorkommen.

Ein zentraler Bestandteil des Workflows ist die Verbesserung der Datenqualität der zugrunde liegenden Fächerecholotdaten. Der Schwerpunkt lag dabei auf der Reduzierung von Artefakten, um die spätere automatisierte Datenauswertung zu erleichtern. Typische Artefakte resultieren unter anderem aus der im Verhältnis zur Datenauflösung geringen Navigationsgenauigkeit. In Wassertiefen von etwa 3000 m wurden mit der auf INS, USBL und weiteren Sensoren basierenden Navigation Genauigkeiten von einigen Metern erreicht. In Bereichen mit schlechterer Positionierungslösung, die von Sensorausfällen oder unzureichender USBL-Kalibrierung herrühren, wurde die Navigation nachträglich mit dem Open-Source-Tool MB-System verbessert. Dabei werden Positionen benachbarter Datensätze anhand bathymetrischer Strukturen im Überlappungsbereich relativ zueinander angepasst (Dufek et al. 2024).

Darüber hinaus wurde auch die Bearbeitung der Rückstreuintensitäten optimiert. Standardmäßige Korrekturen und Modelle sind meist für ebene Flachwasserdaten ausgelegt. Das Untersuchungsgebiet befindet sich jedoch im Bereich eines mitelozeanischen Rückens nahe einer Spreizungszone, das durch geringe Sedimentbedeckung und somit einem akustisch harten und stark reliefierten Meeresboden gekennzeichnet ist. Aufgrund dieser akustisch ungünstigen Bedingungen konnten einige Artefakte, insbesondere solche durch direkte Reflexion oder Schatteneffekte, nicht vollständig eliminiert werden.

Hügeldetektion unter Verwendung des CNN U-Net

Im nächsten Schritt erfolgt auf Grundlage der Bathymetrie sowie ihrer Ableitungen eine Segmentierung, die der »Hügeldetektion« dient. Hierfür wird das Convolutional Neural Network (CNN) U-Net eingesetzt (Ronneberger et al. 2015). Die detektierten Strukturen umfassen zunächst Hügel unterschiedlichster Entstehung, darunter sowohl vulkanische Pillow-Hügel als auch die für die Exploration relevanten Sulfidhügel.

In einem anschließenden Schritt wird die Anzahl der detektierten Strukturen reduziert. Hierzu werden die Ergebnisse des CNN mit Informationen aus der Bathymetrie und den Rückstreuintensitäten kombiniert. Ziel ist es, vulkanische Strukturen möglichst zuverlässig herauszufiltern und jene Bereiche hervorzuheben, die eine erhöhte Wahrscheinlichkeit für Sulfidvorkommen aufweisen. Diese können anschließend als potenzielle Zielgebiete für weiterführende Untersuchungen dienen.

Ähnlich Ansätze zur Detektion von Sulfidvorkommen unter Einsatz von CBBs sind bereits in der Literatur beschrieben, beispielsweise in Juliani

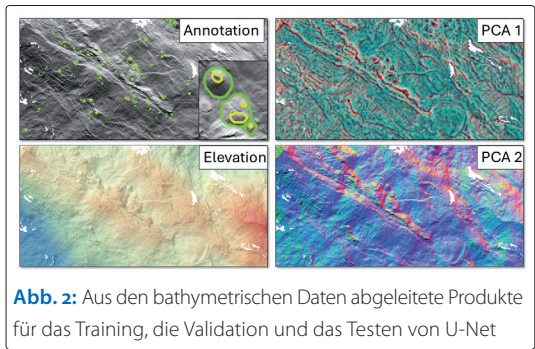


Abb. 2: Aus den bathymetrischen Daten abgeleitete Produkte für das Training, die Validation und das Testen von U-Net

und Juliani (2021) sowie in Heroon et al. (2023). Der hier vorgestellte Ansatz unterscheidet sich jedoch in wesentlichen Punkten. Zum einen basiert er auf einem deutlich umfangreicheren Trainingsdatensatz: Mit einer Fläche von 782 km² und 239 bekannten Sulfidhügeln ist dieser wesentlich größer als in vergleichbaren Studien, die Datensätze von weniger als 50 km² und maximal 15 Sulfidhügeln verwenden. Es ist daher davon auszugehen, dass die auf der größeren Datengrundlage trainierten Modelle eine höhere Robustheit aufweisen. Zum anderen werden im Anschluss an die CNN-basierte Segmentierung zunächst unter anderem die Rückstreuintensitäten zur weiteren Differenzierung der detektierten Hügel herangezogen.

Als Eingabedaten für das CNN wurden aus den bathymetrischen Daten verschiedene Ableitungen hergeleitet, darunter beispielsweise Hangneigung, Rauigkeit und Schummerung. Diese Ableitungen wurden in zwei Gruppen unterteilt, für die jeweils eine Hauptkomponentenanalyse (principle component analysis, PCA) durchgeführt wurde, um drei unkorrelierte Hauptkomponenten zu erhalten. Aus diesen Komponenten wurde jeweils ein RGB-Bild generiert. Für das Training des Modells wurden die Hügel zusätzlich manuell annotiert. Dabei wurden zwei Klassen unterschieden: Basis und Spitze. Die verschiedenen Datenprodukte sind in Abb. 2 dargestellt. Die Hügeldetektion wurde nicht nur mit dem eigenen trainierten Modell durchgeführt, sondern auch mit einem bereits vortrainierten Modell, um die Übertragbarkeit zu untersuchen (Abb. 3).




Abb. 3: Übersicht über die untersuchten Ansätze zur Hügeldetektion mit eigenem Modell sowie bereits trainiertem Modell

Training	Class	Ground Truth	Mounds				Sulphide Mounds		
			Predicted Correctly	Recall/Precision	DC	DC (pixel)	Ground Truth	Pred. Corr.	Pred. Add.
With	1	1,650	944 (57%)	0.57 / 0.41	0.48	0.49	44	22 (50%)	1
	2	1,447	1,305 (90%)	0.90 / 0.46	0.58	0.55	27	17 (63%)	0
Without	1	1,650	1,315 (80%)	0.80 / 0.09	0.16	0.06	44	31 (70%)	12
	2	1,447	1,393 (96%)	0.96 / 0.09	0.16	0.13	27	24 (89%)	8

Abb. 4: Ergebnis der Hügeldetektion. Links unten: Geländemodell mit annotierten Hügeln (grün und rosa) dargestellt. Hydrothermale Bereiche sind mit einer weißen Linie markiert. Rechts unten: Ergebnis des CNN für denselben Datenausschnitt

Abb. 4 zeigt exemplarisch die Ergebnisse für eine der vier untersuchten Regionen, in der 1650 Hügelspitzen und 1447 Hügelbasen annotiert wurden. In der linken Darstellung ist das Geländemodell mit den annotierten Hügeln (grün und rosa) zu sehen. Hydrothermale Bereiche sind durch weiße Linien markiert. Die rechte Abbildung zeigt das Ergebnis des CNN für denselben Datenausschnitt, wobei sowohl das vortrainierte Modell (»without training«) als auch das eigens trainierte Modell (»with training«) verwendet wurden. Bereiche mit hoher Wahrscheinlichkeit für das Vorliegen eines Hügels sind rot hervorgehoben.

Aus der Tabelle in Abb. 4 geht hervor, dass die Erkennungsraten hoch sind: Für Hügelspitzen liegen sie bei 60 % bzw. 80 % und für Hügelbasen bei 90 % bzw. 96 % (»predicted correctly«). Zudem konnten zwischen 50 % und 89 % der im Untersuchungsgebiet vorhandenen Sulfidhügel identifiziert werden. Auf den ersten Blick schienen die Ergebnisse des vortrainierten Modells besser zu sein. Dies ist jedoch darauf zurückzuführen, dass dieses Modell Hügel tendenziell als größere Strukturen detektiert und somit auch Bereiche einbe-

Data set	No Target Reduction (Class 1)	Mean Slope & Texture	+ Clustering Class 1 (1 or 2)	+ Clustering Class 2 (3)
A	Mounds:	2,305	927 (40%)	361 (16%)
	Sulph. Md.:	22	21 (95%)	16 (72%)
B	Mounds:	1,459	596 (41%)	280 (19%)
	Sulph. Md.:	6	4 (67%)	1 (17%)
C	Mounds:	845	494 (58%)	212 (25%)
	Sulph. Md.:	9	8 (89%)	4 (44%)
D	Mounds:	1,832	753 (41%)	451 (25%)
	Sulph. Md.:	45	25 (56%)	19 (42%)
Sum	Mounds:	6,441	2,770 (43%)	1,204 (20%)
	Sulph. Md.:	82	58 (71%)	40 (49%)

Abb. 5: Ergebnisse der Reduzierung der Ergebnisse der Hügeldetektion

zieht, die über die ursprünglichen Annotationen hinausgehen.

Aus diesem Grund ist es bei der Bewertung der Modelle entscheidend, nicht ausschließlich den Recall zu betrachten, sondern auch die Precision zu berücksichtigen. Letztere liefert Aussagen über den Anteil der »false positives«, also darüber, wie häufig das Modell Bereiche fälschlicherweise als Hügel identifiziert. Idealerweise sollte dieser Wert möglichst hoch sein. Im vorliegenden Fall ist die Precision des vortrainierten Modells jedoch deutlich geringer als die des eigens trainierten Modells.

Identifizierung von Sulfidhügeln

Im folgenden Schritt erfolgt die Unterscheidung zwischen Sulfidhügeln und Hügeln vulkanischen Ursprungs. Junge Sulfidhügel weisen in der Regel steilere und unregelmäßigere Flanken auf, zudem ist ihre Spitze häufig kegelförmig ausgeprägt. Vulkanische Hügel hingegen besitzen eine eher abgeflachte und stärker gewölbte Spitze.

In der Literatur werden zur Differenzierung dieser Strukturen sowohl morphologische Merkmale als auch zusätzliche Datensätze, beispielsweise aus magnetischen Messungen, herangezogen. Im vorliegenden Ansatz wurden neben den Ergebnissen des CNN insbesondere die Rückstreuintensitäten sowie daraus abgeleitete Parameter genutzt. Dabei kamen vor allem Texturmerkmale zum Einsatz, die mit Hilfe der Grey-Level Co-occurrence Matrix (GLCM) bestimmt wurden, wie beispielsweise eine hohe Entropie (das heißt hohe Zufälligkeit) und eine geringe Homogenität. Ergänzend wurden die Hangneigung berücksichtigt und Clustering-Verfahren angewendet.

Die Tabelle in Abb. 5 fasst die Ergebnisse für alle vier untersuchten Regionen zusammen. In den Zeilen sind die Gesamtzahl der detektierten Hügel sowie der Sulfidhügel aufgeführt, während die Spalten die jeweils angewandten Unterscheidungsmethoden darstellen. Es zeigt sich, dass durch die angewendeten Verfahren die Anzahl vulkanischer Hügel stärker reduziert werden kann als die der Sulfidhügel. Dennoch ist eine vollständige Trennung der Sulfidhügel von den übrigen Strukturen auf Basis der verfügbaren Daten nicht möglich.

Insgesamt erlaubt der Ansatz jedoch eine räumliche Eingrenzung von Bereichen mit erhöhter Wahrscheinlichkeit für das Auftreten von Sulfidhügeln. Dadurch können potenzielle Explorationsziele gezielter identifiziert und weiterführende Untersuchungen effizienter geplant werden.

Schlussfolgerung

Die Arbeit zeigt, dass ein automatisierter Prozess zur Erkennung von Sulfidhügeln auf Basis hochaufgelöster Fächerecholotdaten grundsätzlich realisierbar ist. Die deutlichen Unterschiede zwischen

den Ergebnissen des eigens trainierten und des vortrainierten Modells verdeutlichen jedoch, wie herausfordernd es ist, allgemeingültige Modelle für diesen Anwendungsbereich zu entwickeln. Die Abweichungen lassen sich zum einen auf unterschiedliche Vorgehensweisen bei der Annotation zurückführen, zum anderen auf die erwartbaren Unterschiede in den morphologischen Eigenschaften der untersuchten Strukturen. Letztere ergeben sich insbesondere daraus, dass die Trainingsdaten des vortrainierten Modells aus dem Arktischen Ozean stammen und somit voraussichtlich nur eingeschränkt auf das hier untersuchte Gebiet übertragbar sind.

Die ausschließliche Nutzung der vorhandenen Rückstreuintensitäten zur Unterscheidung der Hügeltypen reicht derzeit nicht aus, um die Anzahl potenzieller Explorationsziele im gewünschten Maß zu reduzieren. Eine Verbesserung der Ergebnisse könnte durch eine Optimierung der Datenaufnahme und damit der Datenqualität sowie durch die Integration zusätzlicher Sensordaten oder geologischer Interpretationen erreicht werden.

Insgesamt konnte gezeigt werden, dass der vorgestellte Ansatz ein vielversprechendes Werkzeug zur räumlichen Eingrenzung potenziell interessanter Gebiete für weiterführende Explorationsarbeiten darstellt. //

Dieser Kurzbeitrag fasst einen Teil der Promotion zusammen, die unter der DOI 10.34712/142.80 auf repOS veröffentlicht wurde: <https://repos.hcu-hamburg.de>

Literatur |

BGR (2026): BGR Homepage. www.bgr.bund.de
 Corliss, John B.; Jack Dymond; Louis I. Gordon et al. (1979): Submarine thermal springs on the Galapagos Rift. *Science*, DOI: 10.1126/science.203.4385.1073
 Dufek, Tanja; Rald Freitag; Thomas Kuhn; Harald Sternberg (2024): Exploration of hydrothermal venting sites using deep-towed multibeam echo sounder data. *International Hydrographic Review*, DOI: 10.58440/ihr-30-1-c01
 Haroon, Amir; Hendrik Paasche; Sebastian Graber et al. (2023): Automated seafloor massive sulfide detection through integrated image segmentation and geophysical

data analysis: Revisiting the TAG hydrothermal field. *Geochemistry, Geophysics, Geosystems*, DOI: 10.1029/2023GC011250
 Juliani, Cyrill; Eric Juliani (2021): Deep learning of terrain morphology and pattern discovery via network-based representational similarity analysis for deep-sea mineral exploration. *Ore Geology Reviews*, DOI: 10.1016/j.oregeorev.2020.103936
 Ronneberger, Olaf; Philipp Fischer; Thomas Brox (2015): U-Net: Convolutional networks for biomedical image segmentation. DOI: 10.48550/arXiv.1505.04597

NEU

RIEGL VUX-820-G

Airborne LiDAR System für die topo-bathymetrische Vermessung



- ✓ kompakter, leistungsstarker LiDAR Scanner (> 2 Secchi Tiefen Wassereindringung)
- ✓ bestens geeignet für den Einsatz auf Drohnen (5.7 kg leicht)
- ✓ typische Flughöhe 75 m AWL / AGL (über Wasser / über Grund)
- ✓ RIEGL RiLOC-F^{inside} IMU/GNSS System und 5 MPx Kamera voll integriert
- ✓ RIEGL Software Lizenzen für die Erstellung georeferenzierter und brechungskorrigierter Punktwolken inkludiert
- ✓ **Vollintegriertes Gesamtsystem für schnelle, reibungslose Installation und effizienten, zuverlässigen Betrieb**



Weitere topo-bathymetrische Laserscanner und Systeme finden Sie auf www.riegl.com

Besuchen Sie uns

Hydrographentag
 23. - 25. Juni 2026
 Lübeck-Travemünde, Deutschland
RIEGL Messestand Nr. 5

