

HYDROGRAPHISCHE NACHRICHTEN

Journal of Applied Hydrography

03/2024

HN 127

UN-Ozeandekade

40 Jahre DHyG



Nutzung künstlicher Intelligenz zur Aufspürung von Geisternetzen in Küstengewässern

Ein Beitrag von MIA SCHUMACHER, MARKUS GÖTZ, GABRIELE DEDERER und MAREEN LEE

Fischernetze, die frei im Gewässer »umhergeistern«, sind ein Problem für die Umwelt. Mit tiefgeschleppten Seitensichtsonargeräten werden die sogenannten Geisternetze gesucht. Auf den Bilddaten sind die Geisternetze jedoch kaum zu erkennen, dargestellt werden lediglich dünne Linien, die die Lage der Bleileinen wiedergeben, mit denen die Fischernetze beschwert werden; die eigentlich Netzstruktur bleibt unsichtbar. Bisher haben Menschen die Bilddaten ausgewertet. Viel schneller geht es mit einem automatisierten Ansatz aus der Computer Vision, bei dem mittels computergestützter Datenanalyse Geisternetze in den Bilddaten identifiziert werden können.

Geisternetze | Mikroplastik | Computer Vision | R-CNN | Trainingsdatensatz
ghost nets | microplastics | Computer Vision | R-CNN | training data set

Fishing nets that 'ghost' freely in the water are a problem for the environment. The so-called ghost nets are searched for using deep-towed side-scan sonar devices. However, the ghost nets are barely recognisable on the image data; only thin lines are shown that reflect the position of the lead lines with which the fishing nets are weighted; the actual net structure remains invisible. Until now, people have analysed the image data. An automated approach from Computer Vision is much faster, using computer-aided data analysis to identify ghost nets in the image data.

Autoren

Mia Schumacher arbeitet beim Geomar Helmholtz Zentrum für Meeresforschung in Kiel. Dr. Markus Götz arbeitet beim Karlsruher Institut für Technologie (KIT). Dr. Gabriele Dederer und Mareen Lee arbeiten beim World Wildlife Fund (WWF).

mschumacher@geomar.de

1 Hintergrund

Geisternetze sind ein immer größer werdendes Problem, das die Gewässer unseres Planeten belastet. Als solche werden abhanden gekommene Fischernetze, meistens Schlepp- oder Stellnetze aus Kunststoff, bezeichnet, die frei im Wasser »umhergeistern«. Netze, die in der Wassersäule driften oder auf den Boden abgesunken sind, »fischen« dabei unkontrolliert weiter, sodass sich viele Meerestiere darin verfangen und verenden. Durch permanenten Abrieb an festen Strukturen werden Geisternetze außerdem zu Kleinstpartikeln zermahlen und tragen so wesentlich zur Erhöhung des Mikroplastikanteils in Gewässern bei. Obwohl schwierig zu quantifizieren, haben Studien für den Nordostatlantik und die Nordsee ergeben, dass verloren gegangenes Fischereigerät einen Anteil von bis zu 30 % des gesamten Meeresmülls ausmacht (Pham et al. 2014). Zudem wird geschätzt, dass ca. 2 % des weltweit eingesetzten Fischereigeräts verloren geht (Richardson et al. 2022). Regionale Studien zeigen sogar deutlich höhere (bis zu 20 %) Verlustquoten (Macfayden et al. 2009).

Mehrere Organisationen und Projekte wie z. B. Coastal Action (Collaborative Remediation of Abandoned, Lost or Otherwise Discarded Fishing Gear in Southwest Nova Scotia, 2023–2024)

oder WWF (World Wildlife Fund) nehmen sich seit Jahren dieses Problems an und suchen in groß angelegter Feldarbeit mit Hilfe von Sonar nach Geisternetzen (Fulton 2023, WWF 2024). Mit tiefgeschleppten Seitensichtsonargeräten kann der Meeresboden effizient in sehr hoher Auflösung erfasst werden. In den erzeugten Bilddaten sind Netze als dünne Linien erkennbar, die sich um andere Strukturen gewickelt haben oder sich als lange schlangenähnliche Gebilde über den Boden ziehen (Abb. 1). Genau genommen handelt es sich bei dem, was auf dem Sonarbild akustisch sichtbar gemacht wird, um Bleileinen, die zum Beschweren an Fischernetzen befestigt sind. Der Kunststoffanteil der Netze bleibt mit dieser Methode unsichtbar. Bisher erfolgte die Auswertung manuell, das heißt, die Sonardaten werden von einer Person gesichtet und auf Linienstrukturen hin untersucht. Sobald Funde auf den Daten als potenzielle Geisternetze identifiziert werden, werden zur Verifizierung Tauchende eingesetzt. Bei richtig-positivem (RP) Ergebnis wird das Netz geborgen.

Neben dem enormen zeitlichen Aufwand ist die große Schwierigkeit dabei, falsch-positive (FP) Befunde zu identifizieren. Das sind Objekte, die eine ähnliche Form haben wie Netze, aber keine sind. Das können natürliche Strukturen wie Felsformati-

onen oder Sedimentwellen sein, aber auch künstliche wie Pipelines oder Kabel.

Die bisherigen Studien mit Sonargeräten haben gezeigt, dass das Vorgehen eine zuverlässige Entscheidungsgrundlage und ein großes Potenzial für die Suche und Bergung von Geisternetzen in der Ostsee liefert (Stolte et al. 2021). Berücksichtigt man die Größe von z. B. Schleppnetzen, ist deren Bergung auch im Hinblick auf den Eintrag von Mikroplastik in die Nahrungskette von signifikanter Bedeutung. Die Bergung von Großplastik trägt also wesentlich zur Verringerung von Mikroplastik bei.

Zieht man weitere Informationen wie Fanggebiete und -routen hinzu, lassen sich zudem Aussagen darüber treffen, wie groß das Problem wirklich ist. Eingangs erwähnte Schätzungen über die Menge des Mülleintrags durch verlorenes Fischereigerät können somit genauer quantifiziert werden. Aufgrund der Menge an Sonardaten, die über die Jahre gesammelt wurden, ist eine manuelle Auswertung ineffizient und aufgrund der Subjektivität bei der Auswertung durch einen menschlichen Operator auch häufig fehlerbehaftet. Wir machen uns daher die Methoden aus dem Bereich des maschinellen Lernens, konkret der Computer Vision, zunutze, um die Auswertung zu automatisieren – sprich, auf Sonardaten Geisternetze mittels computergestützter Datenanalyse zu identifizieren. Das erlaubt eine effizientere und objektivere Auswertung und der menschliche Fehler wird minimiert. Im folgenden Artikel geht es um den Aufbau und die Funktionsweise des Prototyps.

2 Die Methode

Neuronale Netzwerke

Als (künstliche) Neuronale Netzwerke ((K)NN) wird eine Graphenstruktur, bestehend aus Knoten und Kanten, bezeichnet, die dem biologischen Gehirn nachempfunden ist. Die Knoten, auch Neuronen genannt, sind im Fall des künstlichen NNs mathematische Funktionen, die eingehende Informationen verarbeiten und je nach Konfiguration über eine nicht-lineare Aktivierungsfunktion, gleich einem elektrischen Synapsenimpuls, weitergeben oder nicht. Ein solches Netzwerk ist durch Training mit annotierten Eingabedaten lern- und selbstoptimierungsfähig. Sie sind derzeit ein weitverbreitetes Werkzeug in der Computer Vision. Sofern richtig aufgebaut und gut trainiert, können sie in der automatisierten Bilderkennung Präzisionen erreichen, die dem Menschen ebenbürtig oder gar überlegen sind (z. B. Potrimba 2023).

Es gibt viele verschiedene NN-Architekturen, die alle aufzulisten an dieser Stelle den Rahmen sprengen würde. Die am häufigsten für die Bildanalyse verwendeten sind Convolutional Neural Networks (CNN). Diese zerlegen das Eingabebild in größer



Abb. 1: Korrekte vom CNN detektierte Geisternetzteile

werdende rezeptive Felder, z. B. Bildkacheln, um darin Muster zu erkennen und zu extrahieren. Im Prinzip ist ein CNN eine Abfolge von Bildfiltern, die erst einfache Konstrukte wie Kanten erkennen und diese dann zu komplexeren Strukturen und Merkmalen zusammenfügen. Für die Objekterkennung in Bildern existieren verschiedene Implementierungen von CNNs. Jedoch wird konzeptuell zwischen ein- und zweistufigen Ansätzen unterschieden: Zweistufige Detektoren, wie z. B. Regional Convolutional Neural Networks (R-CNN), schlagen zunächst Regions of Interest (ROIs) im Bild vor, um dann im zweiten Schritt in den ROIs Objekte zu identifizieren und genauer einzugrenzen. Bei einstufigen Detektoren (z. B. YOLO-X) erfolgt die Objekterkennung und Eingrenzung in einem Schritt auf dem gesamten Bild (Reswara 2023; Potrimba 2023).

Unabhängig von der Wahl der Architektur ist es gängige Praxis, vortrainierte Modelle zu nutzen. Diese Modelle wurden an einem großen, standardisierten und vielfältigen Datensatz trainiert, um Merkmale sämtlicher verschiedener Objekte zu differenzieren. Das vortrainierte Modell bzw. die dort erlernten Merkmale dienen dann als Ausgangspunkt und können im weiteren Training auf den eigenen Datensatz spezialisiert werden. Ein solcher Standardbilddatensatz umfasst meistens mehrere Tausend Bilder und wurde sorgfältig annotiert und kuratiert (z. B. Solawetz 2020).

Faster R-CNN

Für den Prototyp zur Erkennung von Geisternetzen auf Sonarbildern nutzten wir die von Facebook AI Research (FAIR) zur Verfügung gestellte und auf

PyTorch basierende KI-Plattform Detectron2 (Wu et al. 2019). Alle Modelle in Detectron2 wurden auf dem MS-COCO-Datensatz vortrainiert. Dieser umfasst mehr als 200 000 annotierte Bilder zur Objekterkennung und -segmentierung (Lin et al. 2014). Für unsere Fragestellung nutzen wir ein Faster-R-CNN-Modell. In diesem zweistufigen Ansatz werden zunächst potenzielle ROIs mittels eines Region Proposal Networks (RPN) vorgeschlagen. Diese Regionen werden dann im zweiten Schritt an ein CNN übergeben, um signifikante Merkmale aus den ROIs zu extrahieren (feature maps). Abschließend entscheidet ein Klassifizieralgorithmus auf dieser komprimierten Darstellung, in welche Kategorie das Objekt passt (Ren 2017).

Faster R-CNN gelten (je nach Literatur, die Aussage ist etwas umstritten) aufgrund ihres zweistufigen Ansatzes als genauer bei der Detektion kleiner Objekte (z. B. Khan 2021; Carranza-Garcia 2021). Da wir es bei Geisternetzen mit dünnen Linien zu tun haben, die unterschiedlichste Formen annehmen können, schien dieses Modell besonders geeignet. Eine im Rahmen des Projekts durchgeführte Algorithmenstudie hat diese Eignung empirisch bestätigt.

Im folgenden Text wird der Begriff »detektiert« oder »automatisch detektiert« verwendet, wenn von automatischer Objekterkennung mittels Computer Vision die Rede ist. Umgekehrt ist von manueller Verifizierung oder nur Verifizierung die Rede, wenn es um in den Daten manuell gefundene und per Tauchgang verifizierte Netze geht.

Der Trainingsdatensatz

Ein hochqualitativer und gut annotierter Trainingsdatensatz ist die wichtigste Grundlage für eine verlässliche Vorhersageleistung von datengetriebenen CNNs. Ein solcher Datensatz deckt theoretisch im besten Fall das ganze Spektrum möglicher Bildvariationen ab. In diesem Fall heißt das, dass sämtliche Gewässerböden, die hier den Bildhintergrund ausmachen, darin vorkommen: Homogene Untergründe, wie Schlamm und Sand, sowie inhomogene, wie Steine, Felsen oder Riffe. Aufgrund ihrer Beschaffenheit können Geisternetze bzw. die in den Daten sichtbaren Bleileinen verschiedene Formen annehmen – sie können, ähnlich wie ein Seil, als lange Linien erscheinen oder auch auf einem Haufen liegen. Der Trainingsdatensatz sollte sämtliche Erscheinungsformen der Netze auf allen unterschiedlichen Untergründen abbilden können und am besten von allen Möglichkeiten eine ähnliche Anzahl an Bildern beinhalten.

Für die hier verwendeten Trainingsdaten wurden vom WWF per Tauchgang verifizierte Netzfunde auf vorhandenen Sonardaten lokalisiert. Die Daten wurden an entsprechender Stelle extrahiert und in Bilder umgewandelt, um dann darauf vorhandene Geisternetze zu labeln. Dafür wurde RectLabel

(Kawamura 2017) genutzt, eine Software zum Annotieren von Objekten auf Bildern. Ein Teil der verifizierten Daten wurde für die spätere Evaluierung des NNs zurückgehalten. Aufgrund des enormen Aufwands, verifizierte Daten zu erhalten, ist der zur Verfügung stehende Datensatz klein und kann damit nicht alle möglichen Eventualitäten abdecken. Die oben beschriebenen Qualitätsstandards für einen optimalen Trainingsdatensatz können deshalb nur beschränkt erreicht werden. Derzeit (Stand Januar 2024) umfasst der Datensatz 201 Bilder mit insgesamt 330 Netzinstanzen.

Validierung

Diese Datensätze wurden im Verhältnis 80 : 10 : 10 aufgeteilt in Trainings-, Validierungs- und Testdaten. Mit den Validierungsdaten wurde die Modellleistung während des Trainings getrackt und analysiert. Der Testdatensatz wurde für eine spätere, vom Trainingsvorgang unabhängige Validierung zurückgehalten (»ungesehener« Datensatz).

Als Zielgröße zur Evaluierung wurde die Average Precision (AP) gewählt, eine häufig verwendete Metrik in der Computer Vision zur Bestimmung der Modellgüte. AP berücksichtigt sowohl die Vorhersagegenauigkeit (precision) eines Modells – also wie viele aus der Gesamtzahl detektierter Objekte tatsächlich RPs sind – als auch deren Vollständigkeit (recall) – das heißt, wie viele aus der Gesamtzahl tatsächlich vorhandener Objekte überhaupt detektiert wurden. Je nach Konfidenzlevel, mit dem ein Modell Objekte identifiziert, sinkt die precision und der recall steigt, oder anders formuliert: die Trefferquote (RP) sinkt und die Zahl der falschen Erkennungen (FPs) steigt. Die AP ist das Integral der precision-recall-Kurve und gibt Auskunft über die durchschnittliche Genauigkeit am entsprechenden Konfidenzlevel. Je höher die AP, desto fähiger ist ein Modell, Objekte korrekt zu finden und dabei die FP-Rate möglichst gering zu halten (Solawetz 2020).

Um sich aber nicht nur auf statistische Metriken zu verlassen, wurden einige der vorläufigen Modelle auf den zurückgehaltenen Testdaten evaluiert, um zu untersuchen, wie gut Geisternetze auf bisher ungesehenen Daten detektiert werden können. Dabei wurden RPs gezählt, also wie viele der automatisch detektierten Netze auch wirklich mit verifizierten Netzfunden übereinstimmen, wie viele davon FPs sind, also vom Algorithmus als Netz detektiert, aber nicht als solches verifiziert, und schlussendlich, wie viele Netze gar nicht automatisch detektiert, wohl aber manuell verifiziert wurden.

Trainingsparameter

Ein vorläufiges Modell wurde mit dem oben beschriebenen Ansatz trainiert. Folgende Hyperparameter wurden dabei gewählt (Tabelle 1):

Model Checkpoint	faster_rcnn_X_101_32x8d_FPN_3x
Epochen	10 000
Batchgröße	2
Anzahl Bilder Training/ Validierung/Test	161/20/20
Lernrate	0,00025

Tabelle 1: Hyperparameter des vorläufigen Modells

Bei der Wahl der Hyperparameter, das sind die nicht gelernten Parameter des Modells, haben wir uns zunächst an Literaturwerten orientiert, die sich, bei ähnlichen Bedingungen (kleiner Trainingsdatensatz, kleine Objekte, die unterschiedlich aussehen können) schon bewährt haben, z. B. der Segmentierung von Polymeren (Khan 2021). Während der Testläufe haben wir die Parameter zunächst manuell angepasst und das daraus resultierende Modell hinsichtlich seiner Vorhersageleistung evaluiert. Die so gefundenen Hyperparameter mit dem höchsten AP auf den Testdaten sind in [Tabelle 1](#) gelistet.

Um den Datensatz künstlich zu erweitern und Überanpassung zu vermeiden, wurden Bildaugmentierungen angewendet. Das bedeutet, dass Eigenschaften eines jeden Eingangsbildes absichtlich mit einer bestimmten Wahrscheinlichkeit abgeändert werden. So entstehen aus einem Bild mehrere pseudo-verschiedene Bilder, die einem NN dabei helfen, die zu erkennenden Muster besser zu differenzieren. Für unseren Ansatz verwendeten wir zufällig gewählte Anpassungen für Bildhelligkeit, Kontrast, Rotation sowie horizontale und vertikale Spiegelungen in den folgenden Wertebereichen ([Tabelle 2](#)):

Parameter Augmentation	Unterer – oberer Schwellwert
Helligkeit	0,4 bis 1,3
Kontrast	0,5 bis 4,0
Rotation	0 bis 359°
Spiegeln vertikal und horizontal	90 % Wahrscheinlichkeit

Tabelle 2: Datenaugmentation

Die Schwellwerte für Helligkeit und Kontrast lassen sich wie folgt interpretieren: Ein Faktor von 0,0 ergibt ein komplett schwarzes (Helligkeit) bzw. graues (Kontrast) Bild, 1,0 erhält die Werte des Originals, und Faktoren > 1 erhöhen Helligkeit/Kontrast um den entsprechenden Faktor. Die Schwellwerte wurden empirisch ermittelt.

3 Vorläufige Ergebnisse

Die hier präsentierte Arbeit ist noch nicht abgeschlossen, sondern wird fortlaufend weiterverfolgt und angepasst. Daher sind die Ergebnisse vorläufig und stellen lediglich einen aktuellen Schnappschuss des derzeitigen Standes dar.

Je nach Modell wurden mehr, weniger oder andere Objekte detektiert. Die Ergebnisse der Evaluierung auf dem Testdatensatz sind beispielhaft die eines Modells, welches ohne Augmentierung trainiert wurde; sie sind in [Tabelle 3](#) gelistet.

Average Precision	36 %
Verifiziert durch Taucher und automatisch detektiert	89 % (von neun verifizierten wurden acht vom Modell gefunden)
Nicht automatisch gefunden, aber verifiziert durch Taucher	1
FP-Rate (FP/Gesamtfunde)	69 % (von 42 automatisch gefundenen sind 29 FP)

Tabelle 3: Vorhersage auf ungesehenen Daten des CNNs

Beispiele für die Evaluierung der Testdaten sind in [Abb. 1](#), [Abb. 2](#) und [Abb. 3](#) dargestellt. Wir haben jeweils die CNN-Detektionen eines Datensatzes mit den manuell markierten Funden desselben Datensatzes visuell verglichen, um zu prüfen, wie gut das Modell in der Vorhersage ist.

Auf [Abb. 1](#) ist ein auf dem Meeresboden langgestrecktes Netz zu sehen, welches korrekt von dem CNN erkannt wurde. Die Zahlen am Rand der Bounding-Boxen geben das Konfidenzniveau an, mit dem das Objekt erkannt wurde. Auffällig ist hier, was auch auf anderen Bildern häufig der Fall war, dass das Modell dasselbe Netz dreimal an unterschiedlichen Stellen erkannt hat. Dort, wo die Netzstruktur blasser ist, wird bei den Bounding-Boxen mit höherem Konfidenzniveau ein Schnitt gemacht. Die Bounding-Box mit geringerer Konfidenz erkennt die komplette Netzstruktur.

[Abb. 2](#) zeigt Sedimentwellen, die fälschlicher-

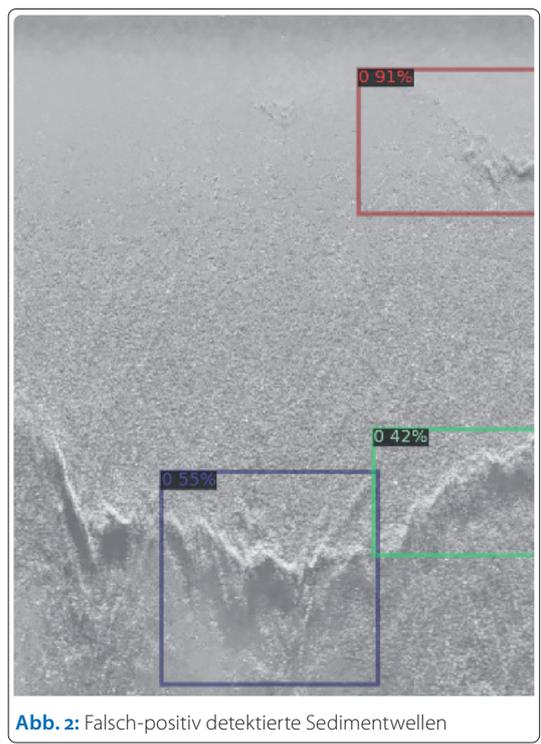


Abb. 2: Falsch-positiv detektierte Sedimentwellen



Abb. 3: Nicht vom CNN detektiertes, aber manuell verifiziertes Geisternetz (dünne Linie von links unten nach rechts in die Mitte)

weise als RPs detektiert wurden, während man auf [Abb. 3](#) ein langgestrecktes Netz auf inhomogenem Hintergrund sehen kann, welches nicht detektiert wurde.

Work in Progress

Es gibt eine Reihe von Stellschrauben, um die bisher entwickelten neuronalen Netzwerke weiter zu verbessern. Der größte Faktor ist aber der Trainingsdatensatz: je mehr gut annotierte Daten als Lerngrundlage dienen, desto präziser wird das Modell. Die Schwierigkeit bei unserer Fragestellung ist die knappe Datengrundlage. Benchmark-Modelle werden mit Tausenden bis Millionen von Bildern trainiert, um als verlässliche Vorhersagealgorithmen eingesetzt zu werden, und erreichen dabei je nach Art APs um 60 bis 80 % (Paperswithcode 2024). Uns stehen derzeit nur die oben genannten 200 Bilder zur Verfügung.

Eine weitere Herausforderung stellt die effektive Suche der Hyperparameter dar. Aufgrund der Vielzahl an Möglichkeiten kann dieser Prozess enorm zeit- und rechenintensiv sein. Wir integrieren gerade die Optimierungsbibliothek ›populate‹, die vom Helmholtz AI entwickelt wurde. Angelehnt an die biologische Evolution macht sich populate den Generationenmechanismus zunutze, bei dem nach dem Survival-of-the-Fittest-Prinzip nur die besten Leistungen von einer Generation in die nächste übertragen werden. Für die Bestimmung von Hyperparametern heißt das, dass verschiedene Konfigurationen an Hyperparametern parallel von einem Supercomputer getestet werden, aber nur diejenigen akzeptiert werden, die, gemessen an der AP, das beste Ergebnis liefern (Taubert et al. 2023). Dabei werden nicht stumpf alle möglichen Kombinationen ausprobiert, sondern nur diejenigen verfeinert, die vielversprechend sind. Erste

Experimente deuten darauf hin, dass die Hyperparameteroptimierung AP-Werte größer 43 % erzielen kann. Allerdings steht eine abschließende Güteevaluation dieser Modelle noch aus.

4 Diskussion

Auch wenn es auf den ersten Blick so scheint, als sei die Leistung der bisherigen Modelle gering (besonders bei Betrachtung der AP), ist die tatsächliche Vorhersage auf ungesehenen Testdaten vergleichsweise gut – vor allem unter Berücksichtigung des kleinen und nicht ausgewogenen Trainingsdatensatzes. Deutlich sichtbare Netze, das heißt Netze, die ausgestreckt auf homogenem Grund des Gewässerbodens liegen (also nicht im Sediment vergraben sind), werden in den meisten Fällen erkannt. Dabei ist die Rate der falsch-positiv detektierten Netze allerdings noch relativ hoch: Ähnliche Strukturen – wie z. B. Sedimentwellen, Kabel, Stahlseile etc. – werden oft ebenfalls als Netze detektiert. So lassen sich die niedrigen AP-Werte erklären – mit steigender FP-Rate sinkt die AP. Die deutlich höhere Anzahl falsch-positiver Funde des Modells, das mit Augmentation trainiert wurde, unterstreicht diese Aussage. Da wir aber darauf abzielen, möglichst viele Geisternetze zu finden, nehmen wir eine hohe Rate an falsch-positiven eher in Kauf, als potenzielle Treffer zu verpassen.

Die Vorhersageleistung und -qualität hängt zudem signifikant von der Datenqualität und der Bodenbeschaffenheit ab. Beispielsweise lässt starkes Rauschen in den Daten Kanten verschwimmen, was die Differenzierung zwischen Objekt und Hintergrund maßgeblich erschwert. Auf ungleichmäßigem Boden mit inhomogenen Strukturen, wie z. B. Steine, Felsen, Riffe etc., sind Geisternetze daher schwieriger zu detektieren. Dünne Linien in den Konturen verschwinden

dann häufig. Ein Trainingsdatensatz, der die beschriebenen Fälle mit einer gleichmäßig verteilten und genügend großen Anzahl an Daten abdeckt, würde hier helfen.

Es gibt viele Diskussionen über die Leistung unterschiedlicher Algorithmen und Architekturen und was sich für welche Fragestellung am besten eignet. Je nach Bedarf ist es z. B. entscheidend, nur Treffer und keine falsch-positiven zu detektieren, in

anderen Beispielen, so wie in diesem, gilt es, möglichst alle richtig-positiven zu finden. Wenn die Optimierung der Hyperparameter abgeschlossen ist, lässt sich besser abschätzen, in welche Richtung die Modellentwicklung noch gehen könnte. Es ist angedacht, weitere und andere Architekturen zu testen, z. B. die aus der YOLO-Familie und zudem je nach Möglichkeit den Trainingsdatensatz stetig zu erweitern, um bessere Leistung zu erzielen. //

Literatur

- Carranza-García, Manuel; Jesus Torres-Mateo; Pedro Lara-Benítez; Jorge García-Gutiérrez (2021): On the Performance of One-Stage and Two-Stage Object Detectors in Autonomous Vehicles Using Camera Data. Remote Sensing, DOI: 10.3390/rs131010089
- Fulton, Leah; Jessie McIntyre; Katie Duncan et al. (2023): Evaluating the use of side scan sonar for improved detection and targeted retrieval of abandoned, lost, or otherwise discarded fishing gear. Continental Shelf Research, DOI: 10.1016/j.csr.2023.105077
- Kawamura, Ryo (2017): RectLabel. <https://rectlabel.com>
- Khan, Faraz (2021): Train a Custom Computer Vision Model using Detectron2. <https://blogs.nottingham.ac.uk/digitalresearch/2021/07/16/train-a-custom-computer-vision-model-using-detectron2/>
- Lin, Tsung-Yi; Michael Maire; Serge Belongie et al. (2014): Microsoft COCO: Common objects in context. Computer Vision and Pattern Recognition, DOI: 10.48550/arXiv:1405.0312
- Macfadyen, Graeme; Tim Huntington; Rod Cappell (2009): Abandoned, lost or otherwise discarded fishing gear. UNEP Regional Seas Reports and Studies, No. 185
- Paperswithcode (2024): Object Detection on COCO minival. <https://paperswithcode.com/dataset/coco>
- Pham, Christopher K.; Eva Ramirez-Llodra; Claudia H. S. Alt et al. (2014): Marine Litter Distribution and Density in European Seas, from the Shelves to Deep Basins. PLOS ONE. DOI: 10.1371/journal.pone.0095839
- Potrimba, Petru (2023): What is a Neural Network? A Deep Dive. Roboflow Blog, <https://blog.roboflow.com/what-is-a-neural-network/#key-takeaways-on-neuralnetworks>
- Ren, Shaoqing; Kaiming He; Ross Girshick; Jian Sun (2017): Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, DOI: 10.1109/TPAMI.2016.2577031
- Reswara, Evan; Sinung Suakanto; Seno Adi Putra (2023): Comparison of Object Detection Algorithm using YOLO vs Faster R-CNN: A Systematic Literature Review. Proceedings of the 2023 6th International Conference on Big Data Technologies (ICBDT '23), DOI: 10.1145/3627377.3627443
- Richardson, Kelsey; Britta Denise Hardesty; Joanna Vince; Chris Wilcox (2022): Global estimates of fishing gear lost to the ocean each year. Science Advances, DOI: 10.1126/sciadv.abq0135
- Solawetz, Jacob (2020): How to Train Detectron2 on Custom Object Detection Data. Roboflow Blog, <https://blog.roboflow.com/how-to-train-detectron2/>
- Stolte, Andrea; Gabriele Dederer; Jochen Lamp et al. (2022): The quest for ghost gear in the German Baltic Sea: A team effort between WWF, divers, fisherfolk, and public authorities. Frontiers in Marine Science, DOI: 10.3389/fmars.2022.981840
- Taubert, Oskar; Marie Weiel; Daniel Coquelin et al. (2023): Massively Parallel Genetic Optimization Through Asynchronous Propagation of Populations. In: High Performance Computing, DOI: 10.1007/978-3-031-32041-5_6
- Wu, Yuxin; Alexander Kirillov; Francisco Massa; Wan-Yen Lo; Ross Girshick (2019): Detectron2
- WWF (2024): Projektfortschritt Geisternetze. <https://www.wwf.de/themen-projekte/projektregionen/ostsee/geisternetze/projektfortschritt-geisternetze>