

Vergleich von Methoden zur Echtzeit-Hinderniserkennung in Forward-Looking Sonardaten für die Kollisionsvermeidung

Marie-Luise Korn
Bachelorarbeit • Studiengang Applied Computer Science • Fachbereich Informatik und Medien • 06.10.2025

Aufgabenstellung

Kameras können aufgrund schlechter Sichtverhältnisse unter Wasser nur eingeschränkt zur Hinderniserkennung eingesetzt werden. Die Bachelorarbeit erkundet daher die Verwendung eines Forward-Looking-Sonars auf dem „Sonobot-5“ der Firma EvoLogics. Es werden zwei klassische, ein probabilistischer und ein Deep Learning-basierter Ansatz verglichen. Ziel ist es, eine echtzeitfähige Hinderniserkennung zu ermöglichen, die zur Kollisionsvermeidung verwendet werden kann.

Forward-Looking Sonar (FLS)

Ein FLS ist ein aktives Sonar, das Schallimpulse in mehreren Strahlen kegelförmig nach vorne aussendet. Die Schallwellen breiten sich durch das Wasser aus und werden von Objekten und Strukturen reflektiert. Die reflektierten Echos werden durch Hydrophone empfangen. Es entsteht eine zweidimensionale Abbildung der Umgebung geordnet nach Strahlenwinkel und Entfernung.




Abb. 1: Visualisierung des Scanvorgangs und der Bildausgabe eines FLS

Ausgewählte Ansätze

BG-Detektor (Galceran et al. 2012)

Das Verfahren nutzt lokales adaptives Thresholding auf einem Ausschnitt des Sonarbilds. Mithilfe von Integralbildern werden Hintergrund- und Echomaske berechnet und verglichen. Übersteigt die Abweichung einen Schwellwert, wird das Pixel als Hindernis markiert.

PEAK-Detektor (dos Santos et al., 2017)

Der Algorithmus sucht entlang der Sonarstrahlen nach lokalen Intensitätsspitzen, die auf Hindernisse hinweisen. Mithilfe einer Region-Growing-Methode werden zusammenhängende Bereiche gebildet und Rauscheinflüsse kompensiert.

OGM-Detektor (Jin et al., 2024)

Die Sonarrohdaten werden in eine zellenbasierte Occupancy Grid Map (OGM) übertragen und mit einem CFAR-Algorithmus gefiltert. Mithilfe Bayes'scher Inferenz wird die Belegungswahrscheinlichkeit jeder Zelle ständig aktualisiert. Übersteigt die Wahrscheinlichkeit einen Schwellwert, gilt das Hindernis als erkannt.

NN-Detektor (Cao et al., 2023)

Ein YOLOv3-basiertes neuronales Netz erkennt potenzielle Hindernisregionen in Sonarbildern. Anschließend wird eine adaptive Schwellwertsegmentierung angewendet, um die genauen Konturen der Hindernisse zu erhalten.

Vorgehensweise

Zur Vorbereitung der Arbeit wurden am Werbellinsee mithilfe des Sonobot-5 der Firma EvoLogics FLS-Daten verschiedener Objekte aufgenommen. Auf Basis dieser Datensätze wurden die Ansätze implementiert, parametrisiert und getestet. Sowohl die Datenerfassung als auch die Implementierung wurden in ROS2 unter Verwendung von C++ realisiert. Anschließend wurden alle Verfahren in einem Praxistest am Werbellinsee hinsichtlich ihrer Erkennungsleistung und Stabilität evaluiert.

Evaluationsmetriken

TP: korrekt erkannt; **FP:** fälschlich erkannt; **FN:** übersehen
Precision: Anteil korrekter Detektionen an allen Detektionen
Recall: Anteil erkannter Hindernisse an allen Hindernissen
F1-Score: harmonisches Mittel aus Precision & Recall
IoU: Überlappung von Detektion und tatsächlichem Hindernis
Erkennungsquote: Anteil der Frames, in denen dasselbe sichtbare Hindernis innerhalb einer Sequenz erkannt wurde

Ergebnisse

Die Auswertung zeigt, dass der OGM-Detektor mit der höchsten Erkennungsquote (81 %) und dem besten F1-Wert (0,80) die zuverlässigste Hinderniserkennung bietet, während seine geringe IoU auf eine grobe Lokalisierung hinweist. Der PEAK-Detektor erreicht ähnlich gute Ergebnisse bei Recall und Precision, ist jedoch empfindlicher gegenüber Umgebungsbedingungen. BG und NN zeigen dagegen Schwächen in Stabilität und Genauigkeit, wobei NN trotz hoher IoU- und Precision-Werte unter inkonsistenter Erkennung leidet.

Detektor	instanzbasiert, ohne IoU-Schwellwert						IoU	Laufzeit in ms	Erkennungs- quote
	TP	FP	FN	Recall	Precision	F1			
BG	56	12	33	0,62	0,82	0,70	0,39	7,93	64,89%
PEAK	61	11	22	0,73	0,84	0,78	0,31	8,52	80,70%
OGM	73	15	18	0,80	0,82	0,80	0,07	0,92	81,00%
NN	66	16	38	0,63	0,80	0,71	0,50	20,45	53,10%

Abb. 2: Evaluation der Detektoren im Praxistest

Fazit

In dieser Arbeit wurden erfolgreich vier Methoden zur Hinderniserkennung in FLS-Daten implementiert. Der probabilistische Ansatz ist aufgrund der geringen Laufzeit, hohen Erkennungsquote und Stabilität am besten für die Echtzeit-Hinderniserkennung geeignet. Das Deep Learning-basierte Verfahren zeigte eine hohe Genauigkeit bei der Konturerkennung von Objekten und könnte somit potenziell eher für Klassifikationsaufgaben geeignet sein.

Quellen

Cao, X., Ren, L. & Sun, C. (2023): Research on Obstacle Detection and Avoidance of Autonomous Underwater Vehicle Based on Forward-Looking Sonar. *IEEE Transactions on Neural Networks and Learning Systems*, vol. 34, no. 11.

Dos Santos, M., Ribeiro, P. O., Núñez, P., Drews-Jr, P. & Botelho, S. (2017): Object Classification in Semi Structured Enviroment Using Forward-Looking Sonar. In *Sensors*, 17(10), 2235.

Galceran, E., Djapic, V., Carreras, M. & Williams, D. P. (2012). A real-time underwater object detection algorithm for multi-beam forward looking sonar. *IFAC Proceedings Volumes*, 45 (5).

Jin, H.-S., Kang, H., Kim, M.-G., Lee, M.-J. & Li, J.-H. (2024). OGM-based real-time obstacle detection and avoidance using a multi-beam forward looking sonar. *Journal of Ocean Engineering and Technology*, 38 (4).