

Evaluation unterschiedlicher Klassifikationsalgorithmen zur Falschalarmreduktion in der Aktiv-Sonarortung

Matthias Buß¹, Yannik Steiniger², Stephan Benen², Dietmar Stiller³,
Dieter Kraus⁴, Anton Kummert¹

¹ Bergische Universität Wuppertal, 42199 Wuppertal, E-Mail: {matthias.buss; kummert}@uni-wuppertal.de

² ATLAS ELEKTRONIK GmbH, 28309 Bremen, E-Mail: {yannik.steiniger; stephan.benen}@atlas-elektronik.com

³ Wehrtechnische Dienststelle für Schiffe und Marinewaffen, Maritime Technologie und Forschung (WTD71),
24340 Eckernförde, E-Mail: dietmarstiller@bundeswehr.org

⁴ City University of Applied Sciences, 28199 Bremen, E-Mail: dieter.kraus@hs-bremen.de

Einleitung

In den letzten Jahren sind die Anforderungen an aktive Sonarsysteme deutlich gestiegen. Während die Detektion in der Vergangenheit in der Regel durch einen Sonar-Bediener erfolgte, sollen die heutigen Systeme möglichst automatisiert Ziele detektieren und im Falle einer Bedrohung einen Alarm ausgeben. Für ein vollautomatisches System sind eine geringe Falschalarmrate und gleichzeitig eine hohe Detektionswahrscheinlichkeit von essentieller Bedeutung. In der klassischen Aktivsonar-Signalverarbeitung hängen die Detektionswahrscheinlichkeit sowie die Falschalarmrate insbesondere von der Höhe des Signal-zu-Rauschverhältnisses (SNR) und der Schwelle des darauf basierenden Detektors ab. Es ist jedoch bekannt, dass die Echos weit mehr Informationen enthalten, welche sich in Form von Merkmalen extrahieren lassen. Mithilfe dieser Merkmale und der Verwendung von maschinellen Lernalgorithmen / Klassifikatoren lassen sich die Detektionen unterschiedlichen Klassen (z.B. Zielkontakt oder Falschalarm) zuordnen. Eine Reduktion der Falschalarmrate auf diese Weise wurde z.B. in [1–5] untersucht.

In dieser Arbeit wird die Leistungsfähigkeit unterschiedlicher Klassifikationsalgorithmen zur Falschalarmreduktion am Beispiel der aktiven Taucherdetektion vergleichend analysiert. Betrachtet werden ein Abstandsklassifikator (K -Nearest-Neighbor), ein kernelbasiertes Verfahren (Support Vector Machine), ein Boosting-Algorithmus (AdaBoost) sowie Neuronale Netze. Die Performance der einzelnen Klassifikatoren wird anhand von Receiver-Operating-Characteristic (ROC) Kurven bewertet und gegenübergestellt. Zur Verifikation der Robustheit werden die trainierten Klassifikatoren auf Daten aus unterschiedlichen Versuchsreihen angewendet. Hierbei liegt der Fokus insbesondere auf der Übertragbarkeit zwischen Datensätzen, die zu unterschiedlichen Zeiten und in unterschiedlichen Umgebungen aufgezeichnet wurden.

Daten

Da die nachfolgend angewendeten Klassifikatoren alle aus dem Bereich des überwachten Lernens stammen, ist es notwendig, die Kontakte in Klassen einzuordnen. Dies bedeutet, dass die durch den Taucher hervorgerufenen Kontakte identifiziert werden müssen. Eine manuelle Zuordnung der Daten würde einen enorm großen Zeitaufwand

erfordern. Aus diesem Grund wird in dieser Arbeit eine Methode verwendet, mit der die Kontaktzuordnung automatisch erfolgt. Liegt ein Track für einen Taucher vor, so wird dieser für die Kontaktzuordnung als „Ground-Truth“ verwendet und alle Kontakte, auf denen der Track basiert, werden der Klasse „Taucherkontakt“ zugeordnet. Alle übrigen Kontakte werden der Klasse „Falschalarm“ zugeordnet. Ein Beispiel für die Ergebnisse der automatischen Zuordnung ist in Abbildung 1 dargestellt. In der linken Teilabbildung sind die Tracking-Ergebnisse eines Versuches dargestellt, in denen Track 38 den zum Taucher zugehörigen Track zeigt. In der rechten Teilabbildung sind die zum Track 38 zugehörigen „Taucherkontakte“ als Punkte dargestellt.

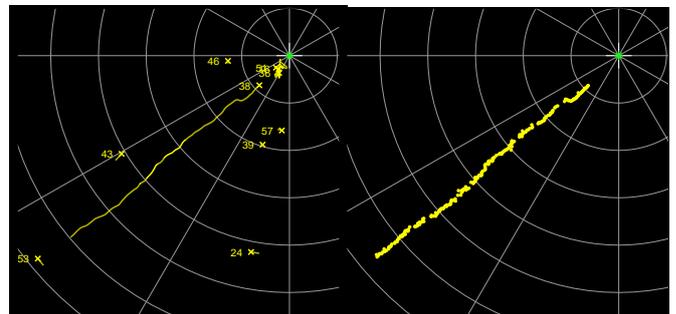


Abbildung 1: Beispiel für die Kontaktzuordnung. Links die Tracking-Ergebnisse mit Track des Tauchers (38) und rechts die zum Track 38 zugehörigen Kontakte.

In dieser Arbeit werden vier Datensätze betrachtet, von denen jeweils zwei in unterschiedlichen Häfen (nachfolgend mit H_1 und H_2 bezeichnet) aufgezeichnet wurden. Mit der zuvor beschriebenen Methode ergeben sich für die Datensätze die in Tabelle 1 aufgeführten Kontakte.

Tabelle 1: Anzahl der Kontakte in den Datensätzen.

Datensatzbez.	Taucherkontakte	Falschalarme
$Run_1 H_1$	240	28896
$Run_2 H_1$	328	52282
$Run_3 H_2$	139	78477
$Run_4 H_2$	199	79946

Für die Erstellung aller Datensätze wurde die gleiche Si-

Nachbarn des K -NN Klassifikators auf 1000 erhöht. In der linken Teilabbildung aus Abbildung 3 ist die Performance der Klassifikatoren, welche mit dem Datensatz Run_2H_1 getestet wurden, zu erkennen. Im Vergleich zu den ROC-Kurven aus der linken Teilabbildung aus Abbildung 2 ist die Performance des FNNs und des K -NN Klassifikators geringfügig und die des AdaBoost deutlich schlechter geworden. Die Performance des SVM Klassifikators ist nahezu gleich geblieben. Allgemein war in dieser Auswertung eine schlechtere Performance zu erwarten, da die Datensätze Run_1H_1 und Run_2H_1 sehr ähnlich sind und die Klassifikatoren in der vorherigen Analyse alleine mit dem Datensatz Run_1H_1 trainiert wurden. In der rechten Teilabbildung sind die ROC-Kurven der mit Datensatz Run_3H_2 getesteten Klassifikatoren dargestellt. Im Vergleich zu den ROC-Kurven aus der rechten Teilabbildung aus Abbildung 2 sollte eine bessere Performance erkennbar sein, da die Datensätze Run_3H_2 und Run_4H_2 am gleichen Tag im gleichen Hafen aufgezeichnet wurden und einer der Datensätze diesmal Teil des Trainingsdatensatzes war. Eine Steigerung der Performance ist für das FNN und den AdaBoost Klassifikator zu erkennen. Die ROC-Kurven des K -NN- und des SVM Klassifikators zeigen jedoch, dass im Vergleich zu den vorherigen Ergebnissen, die Performance geringfügig schlechter ist. Dies ist womöglich durch eine Varianz in den Merkmalswerten aus unterschiedlichen Datensätzen zu begründen. Wie zuvor erwähnt, könnte die Falschalarmrate in Datensatz Run_3H_2 allein durch Erhöhung der Detektionsschwelle um 65% reduziert werden. Dies könnte dazu führen, dass sich die extrahierten Merkmalswerte, wie z.B. die Ausdehnung, deutlich von denen der Datensätze aus Hafen H_1 unterscheiden. Da der AdaBoost-Klassifikator automatisch eine Merkmalsselektion durchführt und das FNN durch eine stärkere Gewichtung „besser“ geeigneter Merkmale etwas vergleichbares durchführt, könnte die Varianz der Merkmalswerte hierbei weniger stark ins Gewicht fallen.

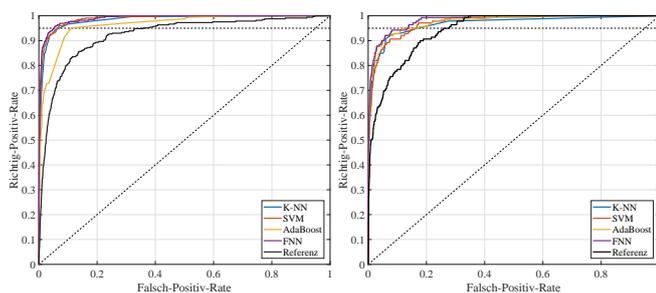


Abbildung 3: Performance der mit Run_1H_1 & Run_4H_2 trainierten Klassifikatoren, links für Run_2H_1 und rechts für Run_3H_2 .

Zusammenfassung und Ausblick

Abschließend lässt sich sagen, dass die in dieser Arbeit vorgestellte Methode eine effektive Maßnahme zur Reduktion der Falschalarme in der Aktiv-Sonarortung darstellt. Die Extraktion verschiedener Kontaktmerkmale sowie die Verwendung maschineller Lernalgorithmen zeigen, dass im Vergleich zur Standard-

Aktivsignalverarbeitung eine deutliche Performancesteigerung erzielt werden kann. Alle vorgestellten Klassifikationsalgorithmen sind für die hier betrachtete Anwendung geeignet. Die Performance aller Klassifikatoren ist ähnlich, allerdings ist hervorzuheben, dass mit dem FNN insgesamt die besten Ergebnisse erzielt wurden.

In Folgearbeiten sollte eine Merkmalsinvarianz gegenüber SNR-Variationen sowie der damit verbundenen Detektionsschwelle sichergestellt werden. Da alle Klassifikatoren sich als geeignet erwiesen haben, ist weiterhin zu untersuchen, ob durch eine Kombination mehrerer Klassifikatoren die Falschalarmrate weiter reduziert werden kann. Darüber hinaus ist die Nutzung von Deep Learning Ansätzen, die keine manuelle Extraktion von Merkmalen erfordern, für die hier betrachtete Anwendung zu prüfen.

Literatur

- [1] Juan, Y. et al.: Adaptive Multi-Feature Fusion for underwater diver classification. Acoustics in Underwater Geosciences Symposium (2013).
- [2] Hjelmervik, K. et al.: A hybrid recorded-synthetic sonar data set for validation of ASW classification algorithms. OCEANS 2015.
- [3] Berg, H. et al.: A comparison of different machine learning algorithms for automatic classification of sonar targets. OCEANS 2016.
- [4] Buß, M. et al.: Echoklassifizierung für Aktivsonare. DAGA 2017, 1406 - 1409.
- [5] Buß, M. et al.: Feature Selection and Classification for False Alarm Reduction on Active Diver Detection Sonar Data. Underwater acoustics conference & exhibition (UACE) 2017, 569 - 576.
- [6] Fix, E., Hodges, J.: Discriminatory Analysis - Non-parametric Discrimination: Consistency Properties. USAF School of Aviation Medicine 4 (1951).
- [7] Boser, B. et al.: A Training Algorithm for Optimal Margin Classifiers. Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory (1992), 144-152.
- [8] Zhu, J.-q., Cai, C.-h.: Real-time face detection using Gentle AdaBoost algorithm and nesting cascade structure. Intelligent Signal Processing and Communications Systems (ISPACS) 2012, 33-37.
- [9] Viola, P., Jones, M.: Rapid object detection using a boosted cascade of simple features. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR) 2001, I-511-I-518.
- [10] Cybenko, G.: Approximation by Superpositions of a Sigmoidal Function. Mathematics of Control, Signals, and Systems 2 (1989), 303-314.