



Kontextsensitive Verhaltensprädiktion von Schiffen

Von der Fakultät für Informatik, Wirtschafts- und Rechtswissenschaften der
Carl von Ossietzky Universität Oldenburg zur Erlangung des Grades
und Titels eines

Doktors der Ingenieurwissenschaften (Dr.-Ing.)

angenommene Dissertation

von **Herrn Matthias Steidel**

Geboren am 23.09.1990 in Bad Mergentheim

Gutachter

Prof. Dr.-Ing. Axel Hahn

Prof. Dr.-Ing. Wolfram Wingerath

Tag der Disputation

03. April 2024

Danksagung

An dieser Stelle möchte ich mich zunächst bei meinem Doktorvater Axel Hahn bedanken. Meinen kurzfristigen Ausflug in die Industrie konnte ich glücklicherweise mit Axels Hilfe beenden und meine wissenschaftliche Karriere beginnen. Während meiner Promotion habe ich enorm von den konstruktiven und fachlichen Gesprächen gelernt. Hier möchte ich mich nochmal explizit für die direkte, unkomplizierte und immer auch schnelle Kommunikation bedanken – das sehe ich nicht als selbstverständlich an.

Bei Wolfram Wingerath möchte ich mich ebenfalls für die Betreuung und Begutachtung bedanken. Ich habe die Zusammenarbeit sehr genossen und bedanke mich, für den unkomplizierten Austausch mit Dir.

Weiterhin möchte ich mich bei Jorge Marx Gómez und Marco Grawunder für ihre Beiträge zur Disputation bedanken. Am Ende hat die Disputation sogar ein klein wenig Spaß gemacht.

Selbstverständlich geht hier auch ein großes Dankeschön an all meine Kollegen und Kolleginnen raus. Mit jedem Austausch beim Kaffee und jedem Gespräch über das noch so kleinste Detail ist diese Arbeit besser geworden. Danke, dass ihr euch Arbeits- und Freizeit genommen habt.

Die Grundlage für diese Promotion bildet mein Studium, was ich glücklicherweise sorgenfrei – abgesehen vom üblichen Prüfungsstress – durchführen konnte. Dafür möchte ich meinen Eltern, Marion und Jochen, aus tiefstem Herzen danken. Danke, dass ihr mich stets zu meinen eigenen Entscheidungen ermutigt habt und zu jederzeit da wart. Diese Promotion ist auch für euch!

Ich möchte meinem Bruder, Christoph, danken, für all die Stunden NBA2k auf der Xbox. Die gemeinsame Zeit an der Konsole habe ich gebraucht, um abzuschalten und nicht völlig verrückt zu werden.

Der größte Dank gebührt aber meiner Ehefrau Bärbel, die die Leidtragende der heißen Promotionsphase war und viele Abende und Nachmittage allein verbringen musste. Danke, dass ich immer auf Dich zählen konnte und Du mir den Rücken freigehalten hast. Das werde ich Dir nie vergessen!

Fehlen darf natürlich nicht mein Sohn Carl, der mir in jeder freien Minute gezeigt hat, wie unbeschwert und lustig das Leben sein kann. Danke Carl. Papa hat jetzt Zeit.

Matthias Steidel

Oldenburg, im April 2024

Für Bärbel

Carl & Fritz

Zusammenfassung

Schiffskollisionen sind selten, aber stets mit verheerenden Auswirkungen auf die Meeresumwelt, die Menschen an Bord und die Maschine verbunden. Zur Prävention solcher Unfälle ist die vorausschauende Kollisionsvermeidung eine elementare Aufgabe der Brückenbesatzung. Unterstützt wird sie hierbei durch Assistenzsysteme, die das zukünftige Verhalten der anderen Schiffe prädictieren und auf Basis dieser Prädiktion potenziell kritische Schiff-zu-Schiff-Begegnungen detektieren. Allerdings müssen die daraus resultierenden Alarme stets manuell von der Besatzung überprüft werden, weil bei der Verhaltensprädiktion ein linearer Bewegungsvektor genutzt wird. Jegliche verhaltensbeeinflussenden Faktoren, wie zum Beispiel das Seewetter oder der Verlauf von Wasserstraßen (hier: Kontext), werden nicht berücksichtigt. Die so entstehenden Fehlalarme müssen manuell identifiziert und korrigiert werden. Insbesondere in küstennahen Gewässern mit einer hohen Verkehrsdichte steigt die Arbeitsbelastung für die Besatzung, was wiederum den Raum für menschliche Fehler größer werden lässt. Als Resultat steigt das Kollisionsrisiko in diesen Gebieten an.

Diese Arbeit untersucht somit die Forschungsfrage, inwiefern zukünftiges Schiffsverhalten unter Berücksichtigung der kontextuellen Gegebenheiten in prädictiert werden kann.

Hierfür wird in der Arbeit unter Anwendung des ingenieurwissenschaftlichen Vorgehens eine Methode zur kontextsensitiven Verhaltensprädiktion entwickelt. Der Grundgedanke der Methode ist die Kombination von Bewegungsdaten mit Informationen über die aktuellen Gegebenheiten (Kontext) um das Schiff herum. Für die eigentliche Verhaltensprädiktion wird ein Long Short-Term Memory Neural Network (LSTM) genutzt, das basierend auf einer beobachteten Bewegungssequenz das zukünftige Verhalten in Abhängigkeit des Kontexts vorhersagt.

Die Methode wird mit historischen Bewegungsdaten in der Jade, Weser und Elbe evaluiert. Als Referenzwert dient das Vorgehen zur linearen Verhaltensprädiktion. Insgesamt zeigt die Evaluation, dass die kontextsensitive Verhaltensprädiktion geringere Prädiktionsfehler produziert. Die abschließende Diskussion über den Abdeckungsgrad der Anforderungen hebt den wissenschaftlichen Beitrag der kontextsensitiven Verhaltensprädiktion hervor.

Abstract

Ship collisions are rare but always associated with devastating consequences for the marine environment, the people on board and the machinery. To prevent such accidents, predictive collision avoidance is a fundamental task of the bridge crew. Assistance systems that predict the future behavior of other ships and detect critical ship-to-ship encounters provide support in this task. However, the resulting alarms must always be checked manually by the crew because a linear movement vector is applied for behavior prediction. Any factors influencing behavior, such as the weather at sea or the course of waterways (context of behavior), are not taken into account. The resulting false alarms must be identified and corrected manually by the bridge crew. Particularly in coastal waters with a high traffic density, the workload for the crew increases, which in turn increases the margin for human error. As a result, the risk of collision increases in these areas.

This thesis thus examines the research question of the extent to which future ship behavior can be predicted taking into account the contextual conditions.

For this purpose, a method for context-sensitive behavior prediction is developed using the engineering approach.

This thesis thus examines the research question of how future ship behavior can be predicted by taking contextual conditions into account.

For this purpose, a method for context-sensitive behavior prediction is developed by applying the scientific engineering approach. The basic idea of the method is the combination of movement data with information about the current conditions (context) around the ship. For the behavior prediction itself, a Long Short-Term Memory Neural Network (LSTM) is used, which predicts future behavior depending on a given movement sequence and context.

The method is evaluated with historical movement data in the Jade, Weser and Elbe rivers. The procedure for linear behavior prediction is used as a reference value. Overall, the evaluation shows that context-sensitive behavior prediction produces lower prediction errors. The final discussion on the coverage degree of the requirements emphasizes the scientific contribution of context-sensitive behavior prediction.

Inhaltsverzeichnis

ABBILDUNGSVERZEICHNIS	VII	
ABKÜRZUNGSVERZEICHNIS	XI	
1	EINLEITUNG	1
1.1	PROBLEMSTELLUNG	2
1.2	ZIELSTELLUNG	6
1.3	ANFORDERUNGEN	8
1.4	AUFBAU DER ARBEIT	13
2	GRUNDLAGEN	15
2.1	AUTOMATIC IDENTIFICATION SYSTEM	15
2.1.1	<i>Aufbau und Funktionsweise</i>	16
2.1.2	<i>AIS-Nachrichtentypen</i>	17
2.1.3	<i>Mehrwert und Einschränkungen von AIS</i>	20
2.2	METEOROLOGISCHE UND OZEANOGRAPHISCHE GRUNDLAGEN.....	22
2.3	SEEKARTEN UND SEEZEICHEN	27
2.4	KNOWLEDGE DISCOVERY IN DATABASES	30
3	STAND DER WISSENSCHAFT UND TECHNIK	51
3.1	VERHALTENSPRÄDIKTION IM AUTOMOTIVE-BEREICH.....	51
3.1.1	<i>Physikalische Bewegungsmodelle</i>	52
3.1.2	<i>Manöverbasierte Bewegungsmodelle</i>	53
3.1.3	<i>Interaktionsbasierte Bewegungsmodelle</i>	54
3.2	VERHALTENSPRÄDIKTION IN DER LUFTFAHRT	54
3.2.1	<i>Zustandsraumbeschreibung</i>	56
3.2.2	<i>Kinematische Modelle</i>	58
3.2.3	<i>Machine Learning</i>	58
3.3	ANALYSE MARITIMER VERKEHRSDATEN	60
3.3.1	<i>IWRAP</i>	61
3.3.2	<i>Anomaliedetektion im Schiffsverhalten</i>	62
3.3.3	<i>Verhaltensprädiktion von Schiffen</i>	65
3.4	ZUSAMMENFASSUNG UND BEWERTUNG.....	73
4	KONTEXTSENSITIVE VERHALTENSPRÄDIKTION VON SCHIFFEN	78
4.1	FALLSTUDIE: GRAPH-BASIERTE VERKEHRSMUSTEREXTRAKTION UND MODELLIERUNG IN DER DEUTSCHEN BUCHT UND OSTSEE	80
4.2	IDENTIFIZIERUNG VON KONTEXTSENSITIVEN INFORMATIONEN	85
4.2.1	<i>Informationen aus Seekarten</i>	86
4.2.2	<i>Meteorologische und ozeanographische Informationen</i>	88

4.3	EXTRAKTION KONTEXTSENSITIVE BEWEGUNGSMUSTER	91
4.3.1	<i>Vorstudie der gitterbasierten Verkehrsmustermodellierung und Prädiktion</i>	92
4.3.2	<i>Verhaltensmodellierung durch Übergangspunkte</i>	100
4.3.3	<i>Kombination historischer Wetter- und Schiffsbewegungsdaten</i>	102
4.3.4	<i>Long Short-Term Memory Netze zur Prädiktion</i>	105
4.4	ANWENDUNGSBEZOGENES MESSEN DER PRÄDIKTIONSGÜTE	107
4.4.1	<i>Methoden zur Bestimmung des Kollisionsrisikos.....</i>	109
4.4.2	<i>Zusammenfassung</i>	112
5	UMSETZUNG ALS KDD-PROZESS	114
5.1	SELECTION	115
5.2	PREPROCESSING.....	118
5.3	TRANSFORMATION	119
5.4	DATA MINING.....	120
6	EVALUATION IN DER JADE, WESER UND ELBE	123
6.1	VORGEHEN ZUR EVALUATION.....	123
6.2	DATENBASIS	126
6.3	ERGEBNISSE	130
6.4	ZUSAMMENFASSUNG UND ABDECKUNG DER ANFORDERUNGEN	146
7	FAZIT	151
7.1	WISSENSCHAFTLICHER BEITRAG	152
7.2	ANWENDUNGSMÖGLICHKEITEN UND GRENZEN DER LÖSUNG	153
7.3	AUSBLICK	155
	LITERATURVERZEICHNIS	157
ANHANG	172	

Abbildungsverzeichnis

Abbildung 1: Weltweite Verkehrsdichte des Schiffsverkehrs (vgl. (MarineTraffic 2020))	1
Abbildung 2: Das Zielsystem der Arbeit, bestehend aus Teilzielen und Anforderungen.	8
Abbildung 3: Der Aufbau der Arbeit, der sich aus dem ingenieurwissenschaftlichen Vorgehen ergibt.	13
Abbildung 4: Komponenten einer AIS-Einheit auf einem Schiff (vgl. (International Maritime Organization 1974)).	16
Abbildung 5: Unterschiedliche AIS-Nachrichtenarten samt Inhalt (International Maritime Organization 1974).	18
Abbildung 6: Nutzer und Informationsgehalt des AIS Gesamtsystems nach (International Maritime Organization 1974).	19
Abbildung 7: Die Ordinalbewegung einer Welle (Angelehnt an (Berking und Brauner 2010)).	25
Abbildung 8: Der Zusammenhang der Windrichtung, Oberflächenströmung und der Ekman-Spirale (Angelehnt an (Berking und Brauner 2010)).	26
Abbildung 9: Das Wirken der Kräfte, die für die Entstehung der Gezeiten verantwortlich sind (Angelehnt an (Berking und Brauner 2010)).	27
Abbildung 10: Die Seetonnen des Lateralsystems A der IALA (Angelehnt an (International Association of Lighthouse Authorities 2018)).	29
Abbildung 11: Der KDD Prozess nach (Fayyad, Piatetsky-Shapiro und Smyth 1996).	31
Abbildung 12: Links: Der kontinuierliche Verlauf einer Zeitreihe. Rechts: Die einzelnen Messwerte der linken Zeitreihe (Dreiecke) und der sich daraus ergebene Verlauf der Zeitreihe.	33
Abbildung 13: Angabe der Position P in einem geografischen Koordinatensystem, definiert durch geografische Länge (λ) und Breite (φ) nach (Brinkhoff 2013).	34
Abbildung 14: Schematische Darstellung eines künstlichen neuronalen Netzes nach (Shalev-Shwartz und Ben-David 2014).	40
Abbildung 15: Exemplarische Darstellung eines KNN, wenn es zum Lernen einer zeitlichen Sequenz genutzt werden soll.	41
Abbildung 16: RNN erweitern den Ansatz von KNN um eine Gedächtnisfunktion, mit deren Hilfe der Zellzustand h_n im Rahmen des Lernprozesses an die nachfolgenden Zellen weitergegeben werden kann.	41
Abbildung 17: Grundstruktur der Neuronen in LSTM-Netzen, die das Konzept der Gated Cells umsetzen und dafür standardmäßige KNN-Operationen verwenden.	43
Abbildung 18: Für jede der vier Operationen <i>Forget</i> , <i>Store</i> , <i>Update</i> und <i>Output</i> sind unterschiedliche Funktionen der der Gated Cells verantwortlich.	44
Abbildung 19: Unterschiedliche Verfahren zur Unterteilung der Gesamtdatenmenge in Trainings- und Testdaten (orange gefärbt).	45
Abbildung 20: Grid und Random Search zur Hyperparameteroptimierung.	47

Abbildung 21: Das Ergebnis nach der Anwendung des DBSCAN und k-Means Algorithmus auf das gleiche Datenset.	49
Abbildung 22: Allgemeines Vorgehen zur Trajektorienprädiktion in der Luftfahrt, adaptiert von (FAA/EUROCONTROL 2010).	55
Abbildung 23: Schematische Darstellung des generellen Vorgehens zur Verhaltensprädiktion in der Literatur.	74
Abbildung 24: Ein Eigenschiff (hellblau) und Fremdschiff (dunkelblau) begegnen sich in einer Wasserstraße. Der relative Bewegungsvektor des Fremdschiffes zeigt dabei eine potenzielle Kollisionsgefahr mit dem Eigenschiff an.	79
Abbildung 25: Die Extraktion des Graphen besteht aus der Extraktion von Manöverpunkten, ihrer Konsolidierung und einer abschließenden Berechnung der Kanten des Graphen.	81
Abbildung 26: Der mittels CUSUM und einem genetischen Algorithmus extrahierte Graph aus der Fallstudie (Dominik Filipiak et al. 2021).	83
Abbildung 27: Auf (b) ist die konzeptionelle Idee für das eigene Vorgehen für einen Ansatz zur kontextsensitiven Verhaltensprädiktion von Schiffen zu sehen. Dieses Vorgehen orientiert sich an dem in der Literatur etablierten Vorgehensmodell (a) zur Prädiktion Schiffsverhalten.	84
Abbildung 28: Die vier Phasen der Reiseplanung aus den "Guidelines for Voyage Planning" der IMO (International Maritime Organization 1999) und den Informationen, die während der jeweiligen Phasen genutzt werden müssen.	85
Abbildung 29: Ausschnitt der Deutschen Bucht mit zwei Ausschnitte, die jeweils beschränkte und unbeschränkte Seegebiete zeigen. ((«Navionics ChartView» 2020))	87
Abbildung 30: Der Wind drückt das Schiff in die entgegengesetzte Richtung (a). Der Seegang ist dabei für Bewegungen der Schiffe in unterschiedlichen Dimensionen verantwortlich (b). .	89
Abbildung 31: (a) Die geografischen Positionen der lateralen Tonnen (eingekreist in orange) dienen als Grundlage zur Modellierung des Seegebiets als Gitter (b).	91
Abbildung 32: Ein Ausschnitt der in die Gitterstruktur unterteilte Wasserstraße der Elbe.	93
Abbildung 33: Die für die Machbarkeitsstudie verwendete Datenbasis, bestehend aus AIS-Nachrichten. Bei den AIS-Nachrichten werden Schiffe unterschieden, die in Richtung See fahren (lila) und die von der See kommend sind (blau).	93
Abbildung 34: COG, SOG und d_{star} als Parameter, aus denen sich Schiffsverhalten in einer jeden Zellen zusammensetzt.	95
Abbildung 35: Das Verhalten wird prädiziert, indem die Erwartungswerte für die Parameter COG, SOG und d_{star} sequenziell aneinandergereiht werden.	96
Abbildung 36: Vier Beispiele, bei denen große Abweichungen zwischen den direktionalen Korridoren benachbarter Zellen zu erkennen sind.	98
Abbildung 37: Vergleich einer prädizierten und tatsächlichen Schiffsbahn mit dem oben beschriebenen Prädiktionsvorgehen (Steidel, Mentjes und Hahn 2020).	98

Abbildung 38: Ein Übergangspunkt TP_n ist der geografische Schnittpunkt einer Schiffsbahn mit der vertikalen Zellengrenze.....	101
Abbildung 39: Die schiffsspezifischen Parameter am Übergangspunkt TP_n	102
Abbildung 40: Historische Daten zur signifikanten Wellenhöhe in der Deutschen Bucht, basierend auf einem numerischen Wellenmodell.....	103
Abbildung 41: Kombination von historischen AIS, Wind- und Wellendaten über die zeitlichen und räumlichen Eigenschaften der jeweiligen Datensätze.....	104
Abbildung 42: Exemplarische Abbildung der sequenziellen Prädiktion von Übergangspunkten unter Berücksichtigung von drei vorherigen Übergangspunkten.....	105
Abbildung 43: Das Konzept der Schiffsdomäne nach Fujii und Tanaka (Fujii und Tanaka 1971). Links ist die Schiffsdomäne für offene See zu dargestellt, auf der rechten Seite für Wasserstraßen und Kanäle.....	110
Abbildung 44: Runde und COLREG-konforme Schiffsdomänen. (a) diskontinuierliches Modell von (Goodwin 1975) und (b) kontinuierliches Modell von (Davis, Dove und Stockel 1980; 1982).	111
Abbildung 45: (a) zeigt die hexagonale Schiffsdomäne nach Smierzchalski (Smierzchalski und Michalewicz 2000). (b) illustriert die polygonale Schiffsdomäne nach Pietrzykowski (Pietrzykowski 2001).	111
Abbildung 46: Konzept zur Berechnung der Prädiktionsgüte im Kontext der Kollisionsvermeidung.....	112
Abbildung 47: Die einzelnen Analyseschritte zur Evaluation der Prädiktionsmethode. Die Schritte sind entsprechend dem KDD-Prozess von (Fayyad, Piatetsky-Shapiro und Smyth 1996).	115
Abbildung 48: Übersicht über verwendeten Mareografen.	117
Abbildung 49: Aktivitätsdiagramm zur Transformation aller genutzten Daten.....	119
Abbildung 50: Vorgehen zur Berechnung des wahrscheinlichsten beziehungsweise unwahrscheinlichsten Verhaltens zur Anomaliedetektion.	122
Abbildung 51: Das Evaluationsvorgehen in der Arbeit.....	124
Abbildung 52: Verteilung der Schiffsklassen innerhalb des Datensatzes.	126
Abbildung 53: Die Datengrundlage der Evaluation nach der Vorverarbeitung in der Jade. Weser und Elbe.....	127
Abbildung 54: Die Verteilung der Windgeschwindigkeit (links, in Knoten) und signifikanten Wellenhöhe (rechts, in Meter) in den jeweiligen Seegebieten.	128
Abbildung 55: Historische Schiffsbahnen durch das Elbefahrwasser, die als Sequenz von Übergangspunkten modelliert sind.....	129
Abbildung 56: Lernrate von Modell 1.	129
Abbildung 57: Lernrate von Modell 2.	130
Abbildung 58: RMSE der linearen Prädiktion, LSTM-Modell 1 und 2.	131

Abbildung 59: Prädizierte (blau) und tatsächliche (orange) Übergangspunkte in einem Abschnitt des Weserfahrwassers.	132
Abbildung 60: Prädizierte (blau) und tatsächliche (orange) Übergangspunkte in einem Kurvenabschnitt des Elbefahrwassers.....	133
Abbildung 61: Prädizierte (blau) und tatsächliche (orange) Übergangspunkte in einer Gerade des Elbefahrwassers.	133
Abbildung 62: Prozentuale Überschneidung der Schiffsdomänen (SD %) der linearen Prädiktion, des LSTM-Modells ohne (Modell 1) und mit Seewetter (Modell 2).	134
Abbildung 63: Der Fehler (RMSE) der Kursprädiktion (COG, in Grad) für die lineare Prädiktion, LSTM-Modell 1 und LSTM-Modell 2.	135
Abbildung 64: Der Fehler (RMSE) der Geschwindigkeitsprädiktion (SOG, in Knoten) für die lineare Prädiktion, des LSTM-Modells ohne (Modell 1) und mit Seewetter (Modell 2).....	136
Abbildung 65: Der TP-Fehler (RMSE, in Meter) für die spezifischen Schiffsklassen in den drei Seegebieten.	137
Abbildung 66: Der COG-Fehler (RMSE, in °) für die spezifischen Schiffsklassen in den drei Seegebieten.	140
Abbildung 67: Der SOG-Fehler (RMSE, in Knoten) für die spezifischen Schiffsklassen in den drei Seegebieten.	141
Abbildung 68: Die prozentuale Überschneidung der Schiffsdomänen je Schiffsklasse und Seegebiet.....	142
Abbildung 69: Detektierten Anomalien für <i>dstar</i> (oben) und für den Kurs (unten).	144
Abbildung 70: Beispiel einer Kurs-Anomalie, die der fachkundigen Person vorgelegt wird.	145
Abbildung 71: Verteilung der Schiffslängen der Cargo-Schiffe im Datensatz.....	172
Abbildung 72: Verteilung der Schiffslängen der Cargo-Schiffe im Datensatz.....	172
Abbildung 73:Prädiktionsfehler in Meter der linearen Prädiktion, des LSTM-Modells 1 und 2. .	173
Abbildung 74: Prädiktionsfehler für den Kurs der linearen Prädiktion, des LSTM-Modells 1 und 2.	173
Abbildung 75: Prädiktionsfehler für die Geschwindigkeit der linearen Prädiktion, des LSTM-Modells 1 und 2.....	174

Abkürzungsverzeichnis

A

AIS	Automatic Identification System
ARPA	Automated Radar Plotting Aid

C

CDS	Climate Data Storage
CMEMS	Copernicus Marine Environment Monitoring Service
COG	Course Over Ground
COLREGS	International Regulations for Preventing Collisions at Sea
CPA	Closest Point of Approach
CRISP-DM	Cross Industry Standard Process for Data Mining
CUSUM	Cumulated Sum

D

DBSCAN	Density-Based Spatial Clustering of Applications with Noise
--------	---

E

ECDIS	Electronic Chart Display and Information System
ECMWF	European Centre for Medium-Range Weather Forecasts

G

GRIB	General Regularly-distributed Information in Binary form
------	--

I

IALA	International Association of Lighthouse Authorities
IHO	International Hydrographic Organization
IMO	International Maritime Organization
IWRAP	IALA Waterway Risk Assessment Program

K

KDD	Knowledge Discovery in Databases
KDE	Kernel Density Estimation
KNN	Künstliches neuronales Netz

L

LSTM	Long Short-Term Memory Neural Network
------	---------------------------------------

M

MMSI	Maritime Mobile Service Identity
MSE	Mean Squared Error

R

RMSE Root Mean Squared Error

RNN Rekurrente Neuronale Netze

S

SOG Speed over Ground

SOLAS International Convention for Safety of Life at Sea

T

TCPA Time to Closest Point of Approach

TP Transition Point

V

VTSS Vessel Traffic Service

W

WAM Waves for the Atlantic and Mediterranean

1 Einleitung

Im Vergleich zum Warentransport mit dem Flugzeug, Zug oder LKW können Containerschiffe mehr Waren pro Fahrt transportieren, was diese Transportart vergleichsweise günstig macht. Aus diesem Grund findet rund 90% des weltweiten Güterverkehrs auf dem Seeweg statt (International Chamber of Shipping 2018). 2017 lief mit der „OOCL Hong Kong“ die nächste Generation an Containerschiffen vom Stapel. Die „OOCL Hong Kong“ kann bis zu 21.413 TEU (Twenty-foot Equivalent Unit) Container pro Fahrt transportieren (OOCL 2017). Seit ihrem Stapellauf gehört die „OOCL Hong Kong“ zu den 50.732 Handelsschiffen, die im Jahr 2017 rund 10,7 Milliarden Tonnen auf dem Seeweg transportiert haben. Bis zum Jahr 2023 wird eine weitere jährliche Steigerung der Transportmenge von rund 3,8% prognostiziert (United Nations 2018).

Ein weiterer Anstieg des Warenumschsags wird mit einem Anstieg der Verkehrsdichte einhergehen. Abbildung 1 zeigt die weltweite Verkehrsdichte der Schifffahrt. Rote Bereiche weisen auf eine besonders hohe Verkehrsdichte hin: je dunkler das rot, desto höher die Verkehrsdichte.




Abbildung 1: Weltweite Verkehrsdichte des Schiffsverkehrs (vgl. (MarineTraffic 2020))

Besonders stark ist das nördliche Europa frequentiert, was auf die drei großen Containerhäfen Rotterdam, Antwerpen und Hamburg zurückzuführen ist. Die meisten Schiffe, die einen dieser Häfen ansteuern, müssen hierfür den Ärmelkanal passieren. Das Verkehrsaufkommen beläuft sich hier auf 400 Schiffe pro Tag (Maritime & Coastguard Agency 2018).

1.1 Problemstellung

Der weitere Anstieg des Schiffsverkehrs wird in Gebieten mit einer hohen Verkehrsdichte mit einem Anstieg des Kollisionsrisikos einhergehen. Um dennoch eine hohe Verkehrssicherheit auf See gewährleisten zu können, existieren entsprechende Regelwerke. Insbesondere die „International Convention for Safety of Life at Sea, 1974“ (SOLAS) (International Maritime Organization 1974) und die „International Regulations for Preventing Collisions at Sea 1972“ (COLREGs) (International Maritime Organization 1972) sind in diesem Kontext hervorzuheben. In den SOLAS werden unter anderem Anforderungen an die Konstruktion von Schiffen, Equipment zur Lebensrettung, Kommunikationstechnologien und Ausrüstung von Schiffen beschrieben (International Maritime Organization 1974). Darüber hinaus existiert mit den COLREGs ein Regelwerk, das Navigations- und Verhaltensregeln an Bord von Schiffen beschreibt, um Kollisionen frühzeitig zu erkennen und zu vermeiden (International Maritime Organization 1972).

Aufgrund der domänenspezifischen Gegebenheiten, wie die besonders hohe Trägheit von Schiffen und der damit einhergehenden eingeschränkten Manövrierfähigkeit (Fossen 2011), muss die Kollisionsvermeidung proaktiv erfolgen (Berking und Brauner 2010). Proaktivität in der Kollisionsvermeidung wird auch in den COLREGs beschrieben: Regel 5 definiert, dass die Besatzung sich stets mit allen verfügbaren Mitteln einen Überblick über die Lage verschaffen soll, um potenzielle Kollisionsrisiken so früh wie möglich erkennen zu können (International Maritime Organization 1972). Ein Kollisionsrisiko besteht dann, wenn sich zwei Schiffe auf direktem Kollisionskurs oder einem Kurs befinden, der zu einem unsicheren Passierabstand führt (Berking und Brauner 2010). Um ein solches Risiko zu beurteilen, ist es in der Schiffsführung allgemeine Praxis, zukünftiges Verhalten von Schiffen zu prädictieren (Berking und Brauner 2010).

Zu diesem Zweck existieren auf Schiffsbrücken Assistenzsysteme, die das nautische Personal bei der Vorhersage von Schiffsverhalten unterstützen sollen. Reglementiert ist dies unter anderem in den COLREGs: Regel 7 definiert, dass Schiffe eine geeignete Radaranlage mit sich führen und nutzen müssen (International Maritime Organization 1972). Mittels solch einer Radaranlage hat das nautische Personal unterschiedliche Möglichkeiten das Kollisionsrisiko mit Schiffen in ihrer Umgebung zu beurteilen. Eine einfache Option ist die Berechnung und fortlaufende Prüfung der stehenden Peilung. Hierfür wird vom nautischen Personal in einem Radargerät eine elektronische Kurslinie vom Eigenschiff zu den jeweiligen Fremdschiffen gezeichnet. Wenn sich anschließend das jeweilige Fremdschiff entlang der elektronischen Kurslinie auf das Eigenschiff zu bewegt, dann befindet sich das Schiff auf direktem Kollisionskurs (Berking und Brauner 2010).

Die zweite Möglichkeit ist die Anzeige und Interpretation sogenannter Trails. Ein Trail ist eine Nachleuchtschleppe, die das vergangene Verhalten eines sich bewegenden Objekts auf dem Radar

darstellt. Mittels dieser Trails kann das nautische Personal die zukünftige Fahrtrichtung abschätzen und mit der des eigenen Schiffs vergleichen. Auch hier muss das Radarbild manuell ausgewertet und beobachtet werden. Die Verwendung von Trails hat den Vorteil, dass sich das nautische Personal schnell einen Überblick über das Seegebiet verschaffen können. Allerdings erlaubt die Interpretation der Trails nur eine qualitative Bewertung des Kollisionsrisikos, da die Passierabstände und -zeiten nicht angezeigt werden können (Berking und Brauner 2010).

Zum jetzigen Zeitpunkt ist jedoch die Kollisionsvermeidung unter Verwendung von Vektoren die standardisierte Methode in der Berufsschiffahrt. Hierfür existieren auf Brücken Assistenzsysteme, die Radarziele automatisiert verfolgen (Target Tracking). In Kapitel 5 der SOLAS wird beschrieben, dass alle Schiffe mit einer Bruttoreaumzahl (BRZ) ab 10.000 verpflichtend über ein Radargerät mit automatisierten Plot- und Trackingfunktionen verfügen müssen (International Maritime Organization 1974). Für diesen Zweck ist das heutige Standardgerät auf Schiffen mit einer entsprechenden BRZ das „Automated Radar Plotting Aid“ (ARPA). Das ARPA berechnet für das Eigenschiff und alle Fremdschiffe in der Umgebung Vektoren, die auf der aktuellen Geschwindigkeit und dem Kurs der jeweiligen Schiffe basieren. Dies geschieht unter der Prämisse, dass Kurs und Geschwindigkeit konstant bleiben. Sobald ein Fremdschiff mehrfach im Radar geplottet wurde, kann der Kurs und die Geschwindigkeit errechnet werden, die zur Kalkulation der Vektoren genutzt werden. Der letzte Vektor wird auf dem ARPA dargestellt und ist wie folgt zu interpretieren: die Richtung des Vektors bildet den Kurs ab, die Länge des Vektors die Geschwindigkeit. Die Vektorspitze repräsentiert die Position des jeweiligen Schiffes zu einer definierten Zeit t ab. Neben einer qualitativen Gefahrenabschätzung erlaubt diese Methode auch eine quantitative Beurteilung. Hierfür errechnet das ARPA weitere Werte und zeigt sie an. Neben der aktuellen Peilung und dem Abstand zum Fremdschiff wird der Punkt der nächsten Annäherung (CPA, Closest Point of Approach) und die Zeit, die bis zum Erreichen des CPA benötigt wird (TCPA, Time to CPA), errechnet. Bei der Unterschreitung eines durch das nautische Personal individuell definierten Schwellenwertes des TCPA löst das ARPA einen Alarm aus und weist das nautische Personal auf eine potentiell gefährliche Situation hin (Berking und Brauner 2010).

Die Fremdschiffe in der Umgebung des Eigenschiffs werden vom ARPA zwar automatisiert akquiriert und als Track verfolgt (Berking und Brauner 2010), allerdings muss der errechnete CPA vom nautischen Personal jeweils auf Plausibilität geprüft werden. Der Grund dafür liegt in der oben beschriebenen Berechnungsweise der Vektoren durch das ARPA, die auf der Annahme basiert, dass Kurse und Geschwindigkeiten konstant bleiben. Diese grundlegende Annahme ist wegen navigatorischen, bathymetrischen und meteorologischen Gegebenheiten nichtzutreffend. Wenn ein Schiff beispielsweise einer Wasserstraße folgt und diese eine Kurve macht, wird auch das Schiff aller Wahrscheinlichkeit nach dem Kurvenverlauf folgen. Gleiches gilt, wenn ein Schiff auf ein

tiefgangbeschränktes Gebiet zusteuert. Es ist wahrscheinlicher, dass das Schiff seinen Kurs ändert, als dass es in dieses Gebiet hineinfährt. Hinzu kommen Fälle, in denen typisches Schiffsverhalten in einem Seegebiet darauf hinweisen, dass ein Schiff in naher Zukunft sein Kurs ändern wird. Die aktuelle Vorhersage des Verhaltens mittels der Vektorrechnung in einem ARPA kann solche Gegebenheiten nicht berücksichtigen. Folglich muss das Ergebnis des ARPAs vom nautischen Personal manuell korrigiert werden.

Bei einer hohen Arbeitsbelastung und in Stresssituationen können hierbei Fehler unterlaufen. Aktuelle Unfalluntersuchungen zeigen, dass menschliches Versagen in rund 75% aller maritimen Unfälle die Ursache war (Allianz Global Corporate and Specialty 2018). Insbesondere in küstennahen Gewässern, die hoch frequentierte Seegebiete sind, ist eine statistische Häufung von Kollisionen zu beobachten (Wróbel, Montewka und Kujala 2017). In der maritimen Domäne ist menschliches Versagen am häufigsten auf Müdigkeit, zu hohe Arbeitsbelastung, fehlerhafte Entscheidungen, Stress und beim Situationsbewusstsein zurückzuführen (Chauvin 2011; Chauvin et al. 2013; Hetherington, Flin und Mearns 2006).

Situationsbewusstsein ist in der Literatur unter dem englischen Begriff *Situation Awareness* (SA) bekannt und wurde maßgeblich von Mica Endsley geprägt. Die proaktive Kollisionsvermeidung ist eine Ausgestaltung des SA-Begriffs, den Endsley (Endsley 1988) als

„[...] the perception of the elements in the environment within a volume of space and time, the comprehension of their meaning, and the projection of their status in near future.“
(Endsley 1988)

beschreibt. Der Definition entsprechend kann die SA als dreistufiger Prozess aufgefasst werden, der sich in der eben beschriebenen maritimen Kollisionsvermeidung wiederfindet: Zu Beginn müssen die Elemente in der Umgebung wahrgenommen werden. Auf einer Schiffsbrücke können andere Schiffe entweder durch das Hinausschauen und durch die Verwendung des Radars beziehungsweise ARPAs wahrgenommen werden. Weitere Informationen über die Umgebung wird der Seekarte entnommen.

Nach der Definition von Endsley (Endsley 1988) muss in einem nachfolgenden Schritt das Wahrgenommene verarbeitet und verstanden werden, um damit ein Lagebild der aktuellen Situation bilden zu können. Auf einer Schiffsbrücke geschieht das durch die Besatzung, die die Informationen verarbeitet und daraufhin weiß, wo in seiner Umgebung andere Schiffe unterwegs sind.

Der letzte Schritt der SA beschreibt die Projektion des zukünftigen Status der wahrgenommenen Elemente (Endsley 1988). Diese Funktion übernimmt das ARPA, das für die wahrgenommenen Radartargets das zukünftige Verhalten prädiziert. Wie oben erwähnt, muss das nautische Personal diese Prädiktion auf Plausibilität überprüfen (Berking und Brauner 2010).

Das Problem der ungenügenden Verhaltensprädiktion gewinnt bei der Betrachtung der aktuellen Entwicklungen in der Schifffahrt weiter an Bedeutung. Forschung und Industrie investieren zurzeit viel Aufwand in die Entwicklung von hochautomatisierten Schiffen und intelligenten Assistenzsystemen, die das Betreiben solcher Schiffe ermöglichen soll. Das prominenteste Beispiel ist die „Yara Birkeland“, ein autonomes Schiff mit vollelektrischem Antrieb (Kongsberg 2017; Paris 2017). Beispielhaft für die Entwicklung eines intelligenten Assistenzsystems zur Kollisionsvermeidung ist das „Maritime Traffic Alert and Collision Avoidance System“ (MTCAS) zu nennen, welches mit Hilfe von Prädiktionstechniken das nautische Personal bei einer Wahrnehmung und Beurteilung von Schiffsbegegnungen ohne Missverständnisse unterstützt. Weiterhin ist das MTCAS bei der Auflösung kritischer Begegnungssituationen durch einen Mechanismus zur kooperativen Aushandlung evasiver Manöver behilflich. Das Aushandlungsergebnis wird dem nautischen Personal als Manöverempfehlung zur Verfügung gestellt (Steidel und Hahn 2019).

Ab einem gewissen Punkt in diesem Entwicklungsprozess wird sich auf See ein gemischtes Verkehrsaufkommen ergeben, bestehend aus traditionellen Schiffen ohne intelligente Assistenzsysteme und hochautomatisierten Schiffen. Die herkömmliche Verfahrensweise und existierende Assistenzsysteme zur Kollisionsvermeidung werden dann nicht mehr ausreichen, um die Sicherheit auf See gewährleisten zu können. Mögliche Fehler und Unzulänglichkeiten der bisherigen Systeme können auf hochautomatisierten Schiffen nicht mehr durch den Menschen und dessen Erfahrung ausgeglichen werden, was besonders kritisch ist im Rahmen der Kollisionsvermeidung.

Dem Gedanken folgend kommt man zu dem Schluss, dass die Entwicklung eines Vorgehens zur kontextsensitiven Verhaltensprädiktion von Schiffen notwendig ist, um den Betrieb hochautomatisierter Schiffe gewährleisten zu können. Gleichzeitig kann ein solcher Ansatz auf herkömmlichen Schiffsbrücken zur Unterstützung der Besatzung eingesetzt werden. Hierdurch wird das Problem adressiert, dass menschliches Versagen einer der Hauptgründe für maritime Unfälle ist (Allianz Global Corporate and Specialty 2018; Chauvin 2011; Chauvin et al. 2013; Hetherington, Flin und Mearns 2006).

Folglich ist es bei der Konzeption und Entwicklung einer kontextsensitiven Verhaltensprädiktion von Schiffen das Ziel, die Schwächen des existierenden Verfahrens zu adressieren.

Hieraus ergibt sich der Forschungsgegenstand dieser Arbeit. Es gilt zu untersuchen, wie zukünftiges Schiffsverhalten unter Berücksichtigung kontextueller Informationen vorhergesagt werden kann. Die grundlegende Idee ist, typische kontextsensitive Bewegungsmuster aus historischen Bewegungsdaten zur Verhaltensprädiktion von Schiffen zu verwenden. Hierfür muss ein Vorgehen konzipiert werden, um historische Schiffsbewegungsdaten mit entsprechenden Kontextinformationen zu kombinieren und zu analysieren. Folgende Forschungsfrage ergibt sich für diese Arbeit:

„Wie kann das wahrscheinlichste Schiffsverhalten unter Berücksichtigung von kontextbezogenen Informationen und Wissen über typisches Schiffsverhalten vorhergesagt werden?“

Aus der Forschungsfrage können folgende Teilfragen abgeleitet werden:

1. Wie müssen historische Bewegungsdaten mit Kontextinformationen verknüpft werden, damit das wahrscheinlichste Verhalten prädiziert werden kann?
2. Wie sind kontextsensitive Verhaltensmuster zu repräsentieren, um sie zur Verhaltensprädiktion von Schiffen verwenden zu können?

1.2 Zielstellung

Die oben beschriebene Problemstellung resultiert in folgendem Ziel für diese Arbeit:

„Entwicklung und Evaluation einer Methode, mit der das wahrscheinlichste Schiffsverhalten unter Berücksichtigung kontextueller Informationen vorhergesagt werden kann.“

Aus diesem Ziel können vier Teilziele abgeleitet werden:

TZ.1 Identifizierung von kontextuellen Informationen, die das Schiffsverhalten beeinflussen.

Wie eingangs beschrieben ist die Prämisse, dass Schiffe sich konstant linear bewegen werden, nicht korrekt. Kontextuelle Informationen, wie zum Beispiel der Verlauf einer Wasserstraße, beeinflussen die Bewegung der Schiffe. Folglich kann also angenommen werden, dass unter Berücksichtigung kontextueller Informationen das zukünftige Verhalten vorhergesagt werden kann. Darüber hinaus können meteorologische und ozeanographische Bedingungen dafür sorgen, dass Schiffe ihr Verhalten anpassen müssen. Bevor allerdings das wahrscheinlichste kontextsensitive Schiffsverhalten prädiziert werden kann, müssen jene kontextuellen Informationen identifiziert werden, die einen Einfluss auf das Verhalten der Schiffe haben.

TZ.2 Entwicklung einer Methode zur Extraktion von kontextsensitiven Verkehrsmustern.

Grundsätzlich gilt für diese Arbeit folgende Annahme: Schiffe verhalten sich in einem Seegebiet unter ähnlich vorherrschenden kontextuellen Gegebenheiten so, wie es andere Schiffe im gleichen Seegebiet unter ähnlichen kontextuellen Gegebenheiten in der Vergangenheit getan haben. Folglich kann mit dem Wissen über kontextsensitive Verkehrsmuster auf das zukünftige Schiffsverhalten geschlossen werden. Hierfür ist es notwendig ein Vorgehen zu konzipieren, mit dem historische Schiffsbewegungsdaten mit den zuvor identifizierten kontextuellen Bedingungen kombiniert werden können. Anschließend muss eine Methode entwickelt werden, mit der kontextsensitive Verhaltensmuster extrahiert werden können.

TZ3. Entwicklung einer Methode zur Modellierung kontextsensitiver Verkehrsmuster.

Eine einfache Form zur Repräsentation von Verkehrsmustern ist die Nutzung simpler statistischer Werte, wie zum Beispiel die Durchschnittsgeschwindigkeit in einem Seegebiet. Um die unterschiedlichen hydrodynamischen Eigenschaften von Schiffen zu modellieren, bietet es sich beispielsweise an, Schiffsklassen basierend auf der Schiffslänge, des Schiffstyps oder einer Kombination aus beiden Parametern zu bilden. Es ist anzunehmen, dass die Komplexität eines solchen Modells mit der Anzahl an Parametern steigt, mit denen die Verkehrsmuster gebildet wurden. Durch die Berücksichtigung kontextueller Informationen kommen weitere Parameter hinzu, die bei der Extraktion der Verkehrsmuster genutzt werden sollen. Diese müssen in einem entsprechenden Modell repräsentiert werden, damit das wahrscheinlichste Verhalten prädiziert werden kann. Somit ist ein weiteres Ziel dieser Arbeit die Entwicklung einer geeigneten Methode zur Modellierung kontextsensitiver Verkehrsmuster.

TZ.4 Entwicklung einer Methode zur Prädiktion des wahrscheinlichsten Schiffsverhaltens in küstennahen Gewässern unter Berücksichtigung kontextueller Informationen.

Basierend auf den Ergebnissen aus Zielen 1 bis 3 soll eine Methode zur Prädiktion des wahrscheinlichsten Schiffsverhaltens unter Berücksichtigung kontextueller Informationen entwickelt werden. Wie bereits in Abschnitt 1.1 beschrieben, treten Kollisionen insbesondere in küstennahen Gewässern und hoch frequentierten Bereichen auf. Die zu entwickelnde Prädiktionmethode muss für küstennahe Gewässer geeignet sein und soll die wahrscheinlichste Bahn, die das Schiff voraussichtlich befahren wird, als Ergebnis liefern. Eine Schiffsbahn besteht dabei aus Bahnpunkten, die durch Koordinaten definiert werden.

1.3 Anforderungen

Die aus den Forschungsfragen abgeleiteten Ziele der Arbeit werden durch Anforderungen an eine Lösung spezifiziert. Aus diesem Vorgehen ergibt sich das Zielsystem dieser Arbeit, welches auf Abbildung 2 dargestellt ist.




Abbildung 2: Das Zielsystem der Arbeit, bestehend aus Teilzielen und Anforderungen.

Aus der Forschungsfrage und der beiden Unterfragen ergibt sich das Ziel der Arbeit, welches wiederum in fünf Unterziele aufgeteilt ist. Neben der Spezifikation der Ziele sollen die Anforderungen zur Aufarbeitung der relevanten Grundlagen und der konkreten Umsetzung einer kontextsensitiven Prädiktionmethode dienen. Die Anforderungen werden des Weiteren zur Evaluierung der Arbeit genutzt werden: Wenn alle Anforderungen eines jeweiligen Ziels erreicht sind, so kann davon ausgegangen werden, dass das dazugehörige Ziel ebenfalls erreicht ist.

Entwicklung und Evaluation einer Methode, mit der das wahrscheinlichste Schiffsverhalten unter Berücksichtigung kontextueller Informationen vorhergesagt werden kann.

A.1 *Vorrausschauende Kollisionsvermeidung.* Die zu entwickelnde Prädiktionsmethode für Schiffsverhalten muss zur vorausschauenden Kollisionsvermeidung einsetzbar sein und somit zur Gefahrenbewertung auf See genutzt werden können. Diese Anforderung leitet sich aus den speziellen hydrodynamischen Eigenschaften der Schiffe ab und aus dem Praxiseinsatz heutiger Verfahren ab (vergleiche Abschnitt 1.1). Heutzutage ist maritime Kollisionsvermeidung vorausschauend, weil sie auf einer linearen Verhaltensprädiktion von Schiffen basiert (Berking und Brauner 2010). Die linearen Prädiktionen dienen als Grundlage für die Risikobewertung auf See. Sobald ein definierter, oft zeitlicher, Schwellenwert unterschritten ist, wird die Brückenbesatzung alarmiert. Es muss in einem geeigneten Evaluationsvorgehen geprüft werden, inwiefern die Methode zur Kollisionsvermeidung einsetzbar ist.

A.2 *Genauigkeit.* Eine kontextsensitive Methode zur Verhaltensprädiktion muss genauer sein als die klassische lineare Verhaltensprädiktion. Diese Anforderung leitet sich aus den Schwächen der linearen Verhaltensprädiktion ab, insbesondere in küstennahen Gewässern, die typischerweise kurvig sind. Grundsätzlich korreliert die Nutzbarkeit von Prädiktionsergebnissen in einem hohen Maße mit der Genauigkeit der Prädiktionsergebnisse. Dies gilt insbesondere für eine sicherheitskritische Anwendung, wie es die Schiffsverhaltensprädiktion im Rahmen der Kollisionsvermeidung ist.

A.3 *Gültigkeit.* Es muss sichergestellt werden, dass sowohl die extrahierten Verkehrsmuster als auch die auf Basis der Muster erstellten Verhaltensprädiktionen für das Seegebiet, in dem sich das Schiff aktuell befindet, gültig ist. Aus dem formulierten Teilziel 2 dieser Arbeit ergibt sich diese Anforderung. Es ist allerdings zu erwarten, dass sich Verkehrsmuster je nach Gebiet unterscheiden werden.

A.4 *Anomaliedetektion.* Es muss möglich sein, anomales Schiffsverhalten zu identifizieren. Die Anforderung wird aus der Arbeitsweise der Vessel Traffic Services (VTS) abgeleitet, die den Schiffsverkehr in küstennahen Gewässern hinsichtlich potenziell gefährlicher Situationen überwachen (Wiersma 2010). Um die VTS-Offiziere bei dieser Aufgabe zu unterstützen hat sich das Forschungsgebiet der Anomaliedetektion, mit dem Ziel automatisiert nicht normales Schiffsverhalten zu identifizieren, entwickelt. Als Grundlage dienen historische Schiffsbewegungsdaten, aus denen normale Bewegungsmuster extrahiert werden (Riveiro, Pallotta und Vespe 2018). Die Idee hinter

dieser Anforderung ist, dass anomales Schiffsverhalten auf potenziell gefährliches Verhalten hinweist und so zur Kollisionsvermeidung von Land aus eingesetzt werden kann. Folglich wird nicht das Wahrscheinlichste, sondern das am wenigsten wahrscheinliche Schiffsverhalten gesucht.

Identifizierung von kontextuellen Informationen, die das Schiffsverhalten beeinflussen.

A.5 Berücksichtigung meteorologische Bedingungen. Es müssen meteorologische Bedingungen bei der Extraktion der Verhaltensmuster sowie bei der Verhaltensprädiktion berücksichtigt werden. Grundlage für diese Anforderung ist die verpflichtende Vorgabe an das nautische Personal, während der Reiseplanung die Route unter Berücksichtigung der vorherrschenden beziehungsweise vorhergesagten meteorologischen Bedingungen zu planen. Während der Reise wird die geplante Route mit den aktuellen meteorologischen Bedingungen abgeglichen und, wenn nötig, angepasst (Berking und Brauner 2010; International Maritime Organization 1999). Für diese Arbeit müssen somit alle meteorologischen Bedingungen identifiziert werden, die einen Einfluss auf die Bewegung der Schiffe haben. Die identifizierten meteorologischen Faktoren müssen anschließend bei der kontextsensitiven Extraktion der Verkehrsmuster und zur Prädiktion von Schiffsverhalten verwendet werden.

A.6 Berücksichtigung ozeanographische Bedingungen. Es müssen ozeanographische Bedingungen bei der Extraktion der Verkehrsmuster sowie bei der Verhaltensprädiktion berücksichtigt werden. Analog zu A.5 leitet sich diese Anforderungen ebenfalls aus der bei der Reiseplanung zu berücksichtigen Informationen ab (Berking und Brauner 2010). Zu den ozeanographischen Bedingungen gehören beispielsweise die Strömung oder Wellenhöhe. Folglich müssen daher jene ozeanographischen Bedingungen identifiziert werden, bei denen eine Korrelation zum auftretenden Verkehrsmuster ersichtlich wird.

A.7 Seekarteninformationen. Bei der Extraktion von Verkehrsmustern und bei der Verhaltensprädiktion müssen Seekarteninformationen berücksichtigt werden. Abgeleitet wird dieses Anforderungen durch die Tatsache, dass der Schiffsverkehr in küstennahen und verkehrsreichen Gebieten durch Wasserstraßen reglementiert wird (Berking und Brauner 2010). Schiffsverhalten wird somit durch vorhandene Seezeichen, die auf einer digitalen Seekarte verzeichnet sind, beeinflusst.

A.8 Hydrodynamische Schiffseigenschaften. Bei der Verhaltensprädiktion müssen die hydrodynamischen Eigenschaften der jeweiligen Schiffe berücksichtigt werden. Diese Anforderung ist durch die hohe Trägheit und die damit einhergehende eingeschränkte Manövrierbarkeit von Schiffen begründet. Die Länge und Masse eines Schiffes sind jeweils wichtige Parameter, um die hydrodynamischen Eigenschaften der Schiffe approximieren zu können (Fossen 2011). Zur Extraktion von kontextsensitivem Schiffsverhalten gilt die Annahme, dass sich die unterschiedlichen hydrodynamischen Eigenschaften der Schiffe in den Bewegungsmustern von Schiffen wiederfinden lassen.

Entwicklung einer Methode zur Extraktion von kontextsensitiven Verkehrsmustern.

A.9 Nutzung historischer Verkehrsdaten. Typische Verkehrsmuster in einem Seegebiet geben Aufschluss darüber, wie sich Schiffe normalerweise innerhalb dieses Gebiets fortbewegen. Verkehrsmuster beschreiben, welche Gebiete von den Schiffen befahren werden, sowie mit welcher Geschwindigkeit und mit welchem Kurs sie typischerweise fahren. Historische Schiffsbewegungsdaten sind die Grundlage, um typische Verkehrsmuster erstellen zu können.

A.10 Datenanreicherung. Alle identifizierten kontextuellen Informationen müssen in einer geeigneten Weise mit historischen Schiffsbewegungsdaten angereichert werden. Durch diese Anforderung wird sichergestellt, dass eine kontextsensitive Verhaltensprädiktion erstellt werden kann. Die besondere Herausforderung hierbei sind die jeweils unterschiedlichen Dimensionen der jeweiligen Daten. Insbesondere die Kombination zeitlicher und geografischer Informationen aus unterschiedlichen Quellen ist eine zentrale Fragestellung in diesem Kontext.

Entwicklung einer Methode zur Modellierung kontextsensitiver Verkehrsmuster.

A.11 Abbildung hydrodynamischer Eigenschaften. Es muss eine Modellierungsform zur Repräsentierung kontextsensitiver Verkehrsmuster entwickelt werden, bei der die hydrodynamischen Eigenschaften respektive Unterschiede der jeweiligen Schiffe dargestellt werden können. Diese Anforderung ergibt sich aus A.8, bei dessen Umsetzung die Notwendigkeit entsteht, hydrodynamische Eigenschaften bei der Modellierung der extrahierten Muster zu berücksichtigen.

A.12 Abbildung kontextueller Bedingungen. Die zuvor identifizierten kontextuellen Bedingungen müssen so repräsentiert werden, dass sie zur Verhaltensprädiktion genutzt werden können. Dies kann durch die Bildung entsprechender Klassen erreicht werden, ähnlich wie bei der Bildung der Schiffsklassen. Dabei ist allerdings zu beachten, dass die gebildeten Klassen die zuvor extrahierten kontextuellen Bedingungen vollständig abbilden.

Entwicklung einer Methode zur Prädiktion des wahrscheinlichsten Schiffsverhaltens in küstennahen Gewässern unter Berücksichtigung kontextueller Informationen.

A.13 Kontextuelle Informationen zur Prädiktion. Es muss eine Prädiktionsmethode entwickelt werden, bei der kontextuelle Bedingungen berücksichtigt werden. Diese Anforderung ist die Konsequenz der zuvor formulierten Anforderungen. Folglich müssen die identifizierten kontextuellen Informationen bei der Prädiktionsmethode als Eingabewert genutzt werden, damit das wahrscheinlichste Verhalten unter den vorherrschenden Bedingungen prädiziert werden kann.

A.14 Vorhergesagte Bahnpunkte. Die zu entwickelte Prädiktionsmethode muss mittels des vorher entwickelten Repräsentationsmodells von kontextsensitiven Verkehrsmustern die nächsten Bahnpunkte eines Schiffes vorhersagen können. Bahnpunkte sind dabei geografische Punkte, die ein Schiff sequenziell abfahren wird, um zum prädizierten Ziel zu gelangen. Die Gesamtheit der Bahnpunkte ergibt die wahrscheinliche Bahn eines Schiffes, was in dieser Arbeit das Prädiktionsergebnis ist.

1.4 Aufbau der Arbeit

Die Arbeit hat das Ziel eine Methode zur kontextsensitiven Verhaltensprädiktion von Schiffen zu konzipieren und zu evaluieren. In dieser Arbeit wird aufgrund des hohen Praxisbezugs des Problems die ingenieurwissenschaftliche Forschungsmethodik (Blessing und Chakrabarti 2009; Peffers et al. 2007; Brinkkemper 1996) genutzt. Der Aufbau der Arbeit orientiert sich dabei dem allgemeinen ingenieurwissenschaftlichen Vorgehen und ist auf Abbildung 3 dargestellt.




Abbildung 3: Der Aufbau der Arbeit, der sich aus dem ingenieurwissenschaftlichen Vorgehen ergibt.

Abschnitt 1 leitet in das Thema ein und formuliert das zu lösende Problem, woraus sich die Zielstellung der Arbeit ergibt. Anschließend werden die Anforderungen abgeleitet, die notwendig sind, um die Zielstellung zu erreichen.

Im darauffolgenden Grundlagenteil (Abschnitt 2) werden die für den weiteren Verlauf der Arbeit relevanten Grundlagen erläutert. Dazu gehören sowohl maritime (beispielsweise Seekarten & Seezeichen) als auch methodische Grundlagen aus dem Forschungsgebiet des Data Science.

Die Anforderungen sind darüber hinaus für Abschnitt 3 relevant, da mit ihrer Hilfe der Stand der Wissenschaft und Technik erfasst und beschrieben wird. In diesem Abschnitt werden relevante Forschungsarbeiten zur Verhaltensprädiktion von Fahrzeugen (Automotive), Luftfahrzeugen

(Luftfahrt) und Schiffen (maritime Domäne) beschrieben. Wesentlicher Beitrag dieses Abschnitts ist die Identifizierung potenzieller Gemeinsamkeiten zwischen den domänenspezifischen Ansätzen sowie die Überprüfung, inwiefern domänenfremde Ansätze auf die maritime Domäne übertragen werden können. Abschließend wird Forschungslücke im Abgleich mit den eingangs aufgestellten Anforderungen formuliert.

Die Forschungslücke samt Anforderungen ist wesentlicher Input für Abschnitt 4. Dort wird der Ansatz zur kontextsensitiven Verhaltensprädiktion von Schiffen entwickelt. Dies beinhaltet die Beschreibung der wesentlichen Konzepte des methodischen Beitrags dieser Arbeit.

In Abschnitt 5 wird die prototypische Umsetzung der Methode zur kontextsensitiven Verhaltensprädiktion beschrieben. Anschließend wird in Abschnitt 6 (Evaluation) zunächst die verwendete Datenbasis beschrieben, woran sich die Beschreibung und Diskussion der Ergebnisse anschließt. Mit Hilfe der Evaluation wird in Abschnitt 6 diskutiert, inwiefern die zuvor entwickelte Methode zur kontextsensitiven Verhaltensprädiktion, die in Abschnitt 1 aufgestellten Anforderungen erfüllt sind und ob die Ziele der Arbeit erreicht wurden.

Der finale Abschnitt 7 (Fazit) beschreibt den wissenschaftlichen Beitrag dieser Arbeit sowie potenzielle zukünftige Anwendungsmöglichkeiten der entwickelten Lösung. Teil dieser Diskussion ist das Aufzeigen der Grenzen der Lösung. Die Arbeit schließt mit einem Ausblick, in dem Anknüpfungspunkte für zukünftige Forschungsarbeiten aufgezeigt werden.

Teile dieser Dissertation wurde bereits in wissenschaftlichen Publikationen veröffentlicht: Abschnitt 4.1 in (Dominik Filipiak et al. 2021) und Abschnitt 4.3.1 in (Steidel, Mentjes und Hahn 2020), sowie in (Steidel et al. 2019) und (Steidel und Hahn 2019).

2 Grundlagen

In diesem Abschnitt werden die Grundlagen vorgestellt, die für das weitere Verständnis der Arbeit und zur Beantwortung der Forschungsfragen relevant sind. Zunächst wird Abschnitt 2.1 das Automatic Identification System (AIS), welches sich aufgrund seiner Einfachheit und breiten Verfügbarkeit als typische Datenquelle zur Analyse maritimer Verkehrsdaten etabliert hat. In der Problemstellung dieser Arbeit wurde hergeleitet, dass das Seewetter einen maßgeblichen Einfluss auf das Verhalten der Schiffe hat und bei einer zu entwickelnden Lösung zu berücksichtigen ist. Aus diesem Grund werden in Abschnitt 2.2 die meteorologischen und ozeanographischen Grundlagen beschrieben. Neben dem Seewetter wird Schiffsverhalten in küstennahen Gewässern durch Seezeichen, die auf entsprechenden Seekarten verzeichnet sind, reglementiert. Abschnitt 2.3 bietet eine Einführung in die für diese Arbeit relevanten Grundlagen der Seekarten und Seezeichen. Der Grundlagenteil dieser Arbeit schließt mit einer Einführung in den Prozess des *Knowledge Discovery in Databases* (KDD) ab. Im Vergleich zum weit verbreiteten alternativen Prozess CRISP-DM (Cross Industry Standard Process for Data Mining) (Fayyad, Piatetsky-Shapiro und Smyth 1996; Wirth und Hipp 2023) bietet KDD weit gefächerten Prozess, der den gesamten Prozess der Wissensentdeckung in Daten abdeckt. Der CRISP-DM Prozess legt den Fokus auf das Data Mining. Für diese Arbeit sind allerdings dem Data Mining vorgelagerten Prozesse zur Wissensentdeckung wichtig, um die Anforderungen A.5 bis A.8 erfüllen zu können. Aus diesem Grund wird sich im Folgenden auf KDD beschränkt und für diese Arbeit verwendet.

2.1 Automatic Identification System

Das Automatic Identification System (AIS) ist ein System zur automatischen Selbstidentifizierung von Schiffen. Hierfür werden Informationen über das eigene Schiff mittels Funkübertragung in kontinuierlichen Abständen gesendet (International Telecommunication Union 2014). Schiffe, die sich in der Nähe befinden und mit einem entsprechenden Empfangsgerät ausgerüstet sind, können die AIS-Signale anderer Schiffe empfangen. Darüber hinaus existieren Landstationen, die AIS-Nachrichten empfangen können, was die landbasierte Überwachung der Seegebiete verbessert. In der Berufsschifffahrt ist es seit dem 31.12.2004 Pflicht, das Schiff mit einer AIS-Einheit ausgerüstet zu betreiben (International Maritime Organization 1974).

In diesem Kapitel soll die allgemeine Funktionsweise von AIS erklärt werden. Anschließend wird der Mehrwert für die Schifffahrt aufgezeigt, der sich durch die Verwendung von AIS ergibt. Abgrenzend zu den Mehrwerten sollen die Unzulänglichkeiten des Systems dargelegt werden. Den Abschluss dieses Kapitels bildet eine Beschreibung der Relevanz von AIS für diese Arbeit.

2.1.1 Aufbau und Funktionsweise

AIS ist zur Selbstidentifizierung konzipiert worden. Hierfür wird die AIS-Einheit bei der Installation an Bord eines Schiffes in die Bordsensorik integriert. Abbildung 4 illustriert die Integration einer AIS-Einheit.




Abbildung 4: Komponenten einer AIS-Einheit auf einem Schiff (vgl. (International Maritime Organization 1974)).

Die eigentliche AIS-Einheit ist der mittlere Block in der Abbildung. Eine AIS-Einheit besteht in der Regel aus einer Recheneinheit (CPU), einem UKW (Ultrakurzwelle)-Sender beziehungsweise Empfänger und einem Display samt Tastatur. Der UKW-Sender und Empfänger sind mit einer UKW-Antenne verbunden, die möglichst am höchsten Punkt des Schiffes befestigt wird. UKW wird dabei als Übertragungsmedium genutzt, auf technischer Ebene wird hier das High Level Data Link (HDLC) Protokoll verwendet. Grundsätzlich werden die Informationen über AIS immer in einem festen Zeitfenster versendet.

Zur Vermeidung von Überschneidungen beim Senden und Empfangen durch mehrere Nutzer auf dem UKW-Kanal, wird das SOTDMA-Prinzip (Self-organized Time Division Multiple Access) genutzt. Bei diesem Verfahren werden 4500 Zeitfenster pro Minute genutzt, um Informationen über UKW verbreiten zu können. Zur Festlegung der Sendereihenfolge zwischen mehreren Schiffen, werden bei jedem Senden zusätzliche Informationen zur zukünftigen beabsichtigten Zeitfensterbelegung versendet. Beim SOTDMA-Prinzip werden diese Informationen anschließend zur Koordinierung verwendet, sodass es zu keiner Überschneidung der Nutzer kommt (International Telecommunication Union 2014). Hierdurch wird ein störungsfreier Betrieb von AIS ermöglicht.

Die Sende- beziehungsweise Empfangsreichweite von AIS-Nachrichten hängt von der Installationshöhe der Antenne ab. Generell kann von einer Reichweite von 20-30 NM (Nautische Meilen) ausgegangen werden (Berking und Brauner 2010).

Als Informationsquelle nutzt eine AIS-Einheit unter anderem die Bordsensorik, an die sie direkt angeschlossen ist. Die Bordsensorik ist in Abbildung 4 auf der linken Seite dargestellt. Das Positionierungssystem GNSS (Global Navigation Satellite System) liefert Informationen über die Position des Schiffes, den Kurs über Grund (COG) und die Geschwindigkeit über Grund (SOG). Informationen zur Vorausrichtung des Schiffes wird durch die Anbindung an den Kreiselkompass bereitgestellt. Sowohl die die Anbindung an das GNSS als auch an den Kreiselkompass sind zwingend notwendig, damit das AIS ordnungsgemäß funktionieren kann. Optional hingegen ist die Anbindung an den Wendeanzeiger und das Log eines Schiffes. Ersteres liefert Informationen über die Drehgeschwindigkeit (Rate of Turn), letzteres hingegen die Geschwindigkeit durch das Wasser (International Telecommunication Union 2014; International Maritime Organization 1974).

Auf dem Display werden die empfangenen AIS-Informationen rudimentär dargestellt, über die Tastatur werden die benötigten Informationen eingegeben (Berking und Brauner 2010). Mit dem Anschluss der AIS-Einheit an die erforderliche Bordsensorik und der Nutzung des Displays und der Tastatur ist die AIS-Einheit prinzipiell nutzbar. In den SOLAS wird dennoch empfohlen, die AIS-Einheit an ein navigatorisches Displaysystem – sofern vorhanden – anzuschließen. Die Anbindung der AIS-Einheit an die ECIDS (Electronic Chart Display and Information System) oder das Radar soll mittels der in IEC 6116-2 definierten Verbindungsmöglichkeit erfolgen (International Maritime Organization 1974; International Electrotechnical Commission 1998).

2.1.2 AIS-Nachrichtentypen

AIS-Nachrichten werden in drei Kategorien in Bezug auf den Inhalt unterschieden. Auf Abbildung 5 sind die drei Kategorien von AIS-Nachrichten dargestellt. Demnach unterscheidet man zwischen statischen, dynamischen und reisebezogenen AIS-Nachrichten.

Die Informationen der statischen AIS-Nachrichten werden bei der Installation des Schiffes in die AIS-Einheit durch den Techniker eingegeben. Grundsätzlich sind in statischen AIS-Nachrichten Informationen zur Identifizierung eines Schiffes zu finden. Besonders hervorzuheben sind hier die MMSI (Maritime Mobile Service Identity) und die IMO-Nummer. Beide Nummern können zur eindeutigen Identifizierung der Schiffe genutzt werden (Berking und Brauner 2010). Statische AIS-Nachrichten werden automatisch alle sechs Minuten gesendet (International Maritime Organization 1974).




Abbildung 5: Unterschiedliche AIS-Nachrichtenarten samt Inhalt (International Maritime Organization 1974).

Im Gegensatz dazu beinhalten dynamische AIS-Nachrichten Informationen über den aktuellen Navigationsstatus eines Schiffes, wie zum Beispiel den aktuellen Kurs (COG), Geschwindigkeit (SOG) und Position. Abgesehen vom Navigationsstatus, der manuell aktualisiert werden muss, werden die versendeten Informationen automatisch über die Sensorik an Bord gesammelt. Das Sendeintervall hängt dabei maßgeblich von der Geschwindigkeit und ob sich der Kurs aktuell ändert ab (International Telecommunication Union 2014; International Maritime Organization 1974). Die jeweiligen Bedingungen sind in Tabelle 1 dargestellt.

Tabelle 1: Sendeintervall dynamischer AIS-Nachrichten (vgl. [Inte14, Inte74]).

Status des Schiffes	Sendeintervall
Schiff liegt vor Anker	3 Minuten
0-14 Knoten	12 Sekunden
0-14 Knoten und Kursänderungen	4 Sekunden
14-23 Knoten	6 Sekunden
14-23 Knoten und Kursänderungen	2 Sekunden
> 23 Knoten	3 Sekunden
> 23 Knoten und Kursänderungen	2 Sekunden

Reisebezogene Nachrichten sind vom nautischen Personal vorm Antritt einer jeden Reise neu einzugeben beziehungsweise zu aktualisieren. Hier sind jegliche Attribute eines Schiffes zu finden, die sich je nach Reise (Ziel, Route) und Beladung (Gefährliche Ladung, Tiefgang) ändern. Das Sendeintervall der reisebezogenen Nachrichten entspricht dem der statischen AIS-Nachrichten: alle

sechs Minuten werden reisebezogene Informationen über das AIS versendet. (International Telecommunication Union 2014; International Maritime Organization 1974).

Sicherheitsrelevante Nachrichten werden von Schiffen je nach Bedarf über das AIS versendet. Es existieren keine formalen Vorgaben für die Befüllung dieses Nachrichtenfeldes, wobei sicherheitsrelevante Nachrichten in erster Linie dazu gedacht sind, für die Sicherheit der Seefahrt relevante Kurzmeldungen verteilen zu können. Ein Anwendungsfall ist beispielsweise, wenn eine Tonne nicht mehr gesichtet werden kann oder die Position dieser Tonne sich verändert hat (Berking und Brauner 2010; International Maritime Organization 1974).

Abbildung 6 skizziert den Informationsaustausch der AIS-Nachrichten zwischen den jeweiligen Akteuren auf See. Schiffe senden automatisch die oben beschriebenen dynamischen, statischen und reisebezogenen Informationen im entsprechenden Intervall. Alle mit AIS ausgerüsteten Schiffe im Umkreis von 20-30 NM empfangen diese Nachrichten. Der Informationsgehalt der empfangenen Nachrichten wird entsprechend auf dem angebundenen Display-System dargestellt.




Abbildung 6: Nutzer und Informationsgehalt des AIS Gesamtsystems nach (International Maritime Organization 1974).

Parallel dazu senden Landstationen Informationen über andere Schiffe, Häfen oder mögliche Gefahren an alle Schiffe im Seegebiet. Im Gegenzug empfangen sie die statischen, dynamischen und reisebezogenen Informationen der Schiffe. Neben dem Versenden der AIS-Nachrichten über UKW ist es auch möglich, AIS-Nachrichten über Satelliten zu versenden und zu empfangen. Dadurch ist es möglich Schiffe von Land aus zu überwachen, auch wenn sie sich auf hoher See und somit außer Reichweite der UKW-Antennen befinden.

2.1.3 Mehrwert und Einschränkungen von AIS

Zur Vermeidung von Kollisionen und wegen der Allgemeinen Sicherheit werden in der Berufsschifffahrt ein kontinuierliches Lagebild mit Hilfe von AIS und Radar generiert und betrachtet. Im Gegensatz zur Radartechnologie ist ein Vorteil von AIS die Verwendung von UKW als Übertragungsmedium. Dies ermöglicht den Ausgleich von Nachteilen in der Wahrnehmung der Umgebung durch das Radar. Schiffe, die im Radar etwa durch Landmassen oder teilweise durch Wellen verdeckt wären, kann das AIS dennoch detektieren. Die Voraussetzung dafür ist, dass die fremden Schiffe auch mit AIS ausgerüstet sind (Berking und Brauner 2010).

Das automatisierte Senden und Empfangen von AIS-Nachrichten verbessert darüber hinaus den Informationsaustausch zwischen Schiffen auf See und Landstationen. Durch den Austausch von statischen Informationen wie die MMSI, den Schiffsnamen oder das Rufzeichen ist es möglich die Schiffe schneller und einfacher zu identifizieren, was die Kontaktaufnahme über Funk vereinfacht (Berking und Brauner 2010; International Maritime Organization 1974).

Durch die Übertragung der Drehgeschwindigkeit und der Vorausrichtung eines Schiffes über AIS ist es auf der Brücke zudem einfacher Manöver der Schiffe zu erkennen und zu interpretieren. Die Berechnung des CPA und TCPA ist mittels der Informationen aus dem AIS schneller möglich verglichen mit der Berechnung auf Basis von Radarinformationen (International Maritime Organization 1974).

Die verpflichtende Nutzung von AIS hat das Potential, die Sicherheit auf See und in der Berufsschifffahrt nachhaltig zu verbessern. Der Sicherheitsgewinn ist aber nur dann maximal, wenn man das AIS trotz seiner Grenzen zu nutzen weiß. Diese Grenzen ergeben sich zum einen aus der Funktionsweise des AIS: das gesamte Potential des AIS kann nur dann genutzt werden, wenn möglichst viele andere Schiffe mit einer AIS-Einheit ausgerüstet sind. Im Gegensatz zum Radar, was die Umgebung selbstständig wahrnimmt und damit autark funktioniert, kann eine AIS-Einheit nur dann sinnvoll genutzt werden, wenn auch andere Schiffe in der Umgebung mit einer AIS-Einheit ausgerüstet sind (Berking und Brauner 2010).

Darüber hinaus sind die Informationen und ihre Quellen ein limitierender Faktor des AIS. Zu keiner Zeit ist es gesichert, dass die über das AIS übertragenen und empfangenen Informationen richtig sind (Berking und Brauner 2010). Von allen Informationen, die mittels AIS versendet werden, sind die Informationen über die ROT, das THDG am unzuverlässigsten (Banyś, Noack und Gewies 2012; Felski und Jaskólski 2012; Felski und Jaskolski 2013). Ein Faktor, um die Zuverlässigkeit der Informationen zu bewerten, scheint hierbei die Informationsquelle zu sein. Es deutet darauf hin, dass Informationen, die auf Basis von Sensorik berechnet werden müssen (THDG, ROT) unzuverlässiger sind, als die Informationen, die direkt von der Sensorik kommen (SOG, COG, Position) (Banyś, Noack und Gewies 2012). Weitere Fehlerursachen in diesem Kontext ist

defekte Sensorik (Banyś, Noack und Gewies 2012) oder Fehler bei der Installation der Sensorik beziehungsweise AIS-Einheit (Banyś, Noack und Gewies 2012; Felski und Jaskólski 2012; Felski und Jaskólski 2013).

Im Kontext dieser Arbeit ist sicherlich das Feld mit der Zielangabe im AIS mit am interessantesten, da es Aufschluss über das Ziel der Schiffsreise geben kann. Da es sich bei diesem Feld um ein Freitextfeld handelt und diese Information händisch vor dem Antritt jeder Reise eingeben müssen, hat die IMO 2004 eine Richtlinie veröffentlicht, die die Angabe des Zielhafens in AIS vorgibt. Laut dieser Richtlinie muss der Zielhafen einer Reise unter der Verwendung des UN/LOCODES kodiert werden. Der UN/LOCODE ist eine Kodierung für Häfen und Orte. Jeder Hafen wird durch ein Kürzel für das Land identifiziert, gefolgt von einem Kürzel für den Hafen. Ein Land wird, basierend auf der DIN ISO 3166 (DIN-Normenausschuss Information und Dokumentation (NID) 2018), durch zwei Buchstaben identifiziert, wobei ein Hafen mit drei Buchstaben abgekürzt wird. Ein Beispiel hierfür wäre DE HAM, das den Hamburger Hafen in Deutschland kennzeichnet. Darüber hinaus ist festgelegt, dass ebenfalls der Starthafen angegeben werden muss. Tabelle 2 zeigt das empfohlene Format.

Tabelle 2: Die von der IMO empfohlenes Format zur Zielangabe in AIS ((Steidel et al. 2019)).

Zu verwendende Abkürzung	Beschreibung
DE HAM>NL RTM	Fahrt von Hamburg nach Rotterdam
DE HAM>?? ???	Fahrt von Hamburg zu einem unbekanntem Ziel
XX XXX>DE HAM	Fahrt von einem unbekanntem Starthafen nach Hamburg
===Orrviken	Bekanntem Zielhafen, aber ohne UN/LOCODE. Die Zeichenfolge === gefolgt vom englischen Namen des Hafens wird dann empfohlen zu nutzen.
DE HAM>===US WC	Wenn das Ziel der Reise kein Hafen, sondern ein generelles Seegebiet ist, soll diese Variante genutzt werden.

Da dieses Feld jedoch ein Freitextfeld ist, sind die Angaben zu großen Teilen fehlerbehaftet. Existierende Studien in der Literatur zeigen, dass die häufigsten Fehler hier Rechtschreibfehler oder die Nutzung falscher Abkürzungen zu finden sind (Bailey, Ellis und Sampson 2008; Harati-Mokhtari et al. 2007). Allerdings fehlen in diesen Studien generelle Angaben zur Verbreitung und Nutzung des UN/LOCODES. Im Rahmen dieser Arbeit wurde eine entsprechende Studie durch-

geführt, die dies untersuchte und zu dem Schluss kommt, dass nur rund 1,3% der 13.216 untersuchten AIS-Nachrichten den UN/LOCODE in der in Tabelle 2 dargestellten Form nutzen. Die große Mehrheit (rund 88,9%) der betrachteten AIS-Nachrichten enthielten eine Zielangabe, die nicht konform zur Empfehlung der IMO ist. Des Weiteren wurden in knapp der Hälfte der Nachrichten (rund 52,2%) weitere Fehler im Feld der Zielangabe, wie zum Beispiel Rechtschreibfehler oder die Nutzung falscher Abkürzungen, erkannt (Steidel et al. 2019).

Auf Grund all dieser Einschränkungen empfiehlt die IMO das AIS nur in Verbindung mit einem geeigneten Radar-Tracking zu verwenden. Aus diesem Grund können zum einen die Einschränkungen von Radargeräten minimiert werden und zum anderen können so nicht plausible AIS-Informationen identifiziert werden. In Kombination mit dem Radar ermöglicht die Verwendung von AIS ein präziseres Lagebild der unmittelbaren Umgebung zu generieren (International Maritime Organization 1974).

2.2 Meteorologische und ozeanographische Grundlagen

Die IMO definiert in den SOLAS die Richtlinie, dass jede kommerzielle Schiffsreise in Abhängigkeit der relevanten nautischen Seekarten, den meteorologischen und ozeanographischen Bedingungen geplant wird. Auf Basis dieser Informationen ist ein Reiseplan zu erstellen, der eine sichere Reise in Abhängigkeit des Tiefganges des Schiffes und der Wassertiefe, des Umweltschutzes und möglicher Gefahren durch das Seewetter sicherstellt (International Maritime Organization 1974).

Als entsprechendes Verfahren hat sich hierfür das Wetter-Routing etabliert. Hierbei werden Wetter- und Seegangsvorhersagen bei der Routenplanung mit einbezogen. In Kombination mit nautischen Seekarten werden entsprechende Routen geplant und – falls es durch die Wetter- und Seegangsvorhersagen ersichtlich ist – Ausweichkurse geplant, um auf schlechte Seewetterbedingungen reagieren zu können (Berking und Brauner 2010).

Da Schiffe ihre Reisen also auf Basis von Seekarten, Wetter- und Seegangsvorhersagen planen und während der Reise entsprechend auf sich ändernde Bedingungen reagieren, sind diese Parameter für Extraktion von kontextsensitiven Verkehrsmustern relevant. Im Folgenden werden die relevanten Begriffe in diesem Zusammenhang erläutert.

Wind

Der entscheidende Faktor, wenn es um die Entstehung von Wind geht, ist der vorherrschende Luftdruck. Der Luftdruck beschreibt den Druck, den die Luftmassen auf die Fläche unter ihnen ausüben. Eine Luftsäule besteht wiederum aus unterschiedlichen Schichten, wobei die Temperatur

in jeder Schicht auf Grund der Ein- und Ausstrahlung auf der Erdoberfläche schwankt. Diese Temperaturschwankungen resultieren in einer Schwankung der jeweiligen Luftmassen. Auf Schiffen wird der Luftdruck während einer Reise kontinuierlich mit einem Barometer dokumentiert. Der Normaldruck auf der Erdoberfläche beträgt 1013,2 hPa (Hektopascal).

Wind entsteht, wenn der Luftdruck an zwei Orten unterschiedlich ist. Ausschlaggebend hierfür ist die Druckgradientenkraft, die die horizontalen Differenzen im Luftdruck und die Entfernung zwischen zwei Gebieten beschreibt. Je größer der Druckunterschied zwischen zwei Gebieten, desto größer ist folglich die Druckgradientenkraft. Um den Druckunterschied auszugleichen, kommt es zu einer Bewegung der Luftteilchen vom Gebiet mit dem höheren Luftdruck (Hoch) hin zum Gebiet mit dem geringeren Luftdruck (Tief). Aufgrund der Corioliskraft wird die Bewegung der Luftteilchen entsprechend der Rotationsbewegung der Erde abgelenkt, sodass sich die Luftteilchen nicht direkt von einem Hoch zu einem Tief bewegen können. Die Corioliskraft wächst dabei mit der Windgeschwindigkeit, ist proportional zur Winkelgeschwindigkeit der Erde und hängt von der geografischen Breite ab: An den Polen ist sie am größten, am Äquator ist sie null. Neben der Druckgradientenkraft und der Corioliskraft ist die Zentrifugalkraft verantwortlich für die Bewegungsrichtung der Luftmassen. Das Produkt aus allen drei Kräften ergibt den Gradientenwind. Aufgrund des Zusammenwirkens aller drei Kräfte bewegen sich die Luftteilchen auf der Nordhalbkugel der Erde in ein Tief hinein und aus einem Hoch heraus.

Digitale Wetterinformationen

Meteorologische Informationen sind Beobachtungsdaten. Zu diesem Zweck existieren auf der Erde Beobachtungsstationen, die sich entweder auf Land, See oder in der Luft befinden. Für das Seewetter sind besonders die See- und Luftstationen relevant. Hierzu sammeln Schiffe oder driftende Bojen Informationen über das Seewetter, wie zum Beispiel Strömung, Wassertemperatur oder Salzgehalt. Des Weiteren sammeln Radiosonden, die von Schiffen aus gestartet werden, Informationen über das vertikale Profil der Atmosphäre. Das Wetter wird kontinuierlich alle drei Stunden beobachtet. Die Beobachtungsdaten werden an Land gesammelt und zur Berechnung von globalen und lokalen Wettervorhersagen unter der Verwendung entsprechender Modelle genutzt. Aus diesen Vorhersagen kann anschließend das mittlere Seewetter abgeleitet werden, was als Grundlage für die nautische Reiseplanung dient. Die meteorologischen Beobachtungs- sowie Vorhersagedaten werden auf Wetterkarten abgebildet (Berking und Brauner 2010).

Neben Wetterkarten werden Wetterinformationen im GRIB-Format (General Regularly-distributed Information in Binary form) abgespeichert. Das GRIB-Format ist ein international festgelegtes Format zum digitalen Austausch meteorologischer Informationen und wurde von der World Meteorological Organization (WMO) standardisiert. Das GRIB-Format wurde im Laufe der Jahre

modifiziert und verbessert, sodass mittlerweile zwei Versionen – GRIB-Edition 1 und GRIB Edition 2 – unterschieden werden können. GRIB 2 ist die aktuelle Version (Deutscher Wetterdienst 2019; World Meteorological Organization 2003). Der Aufbau einer GRIB 2 Datei wird im Folgenden weiter erläutert.

Eine Datei im GRIB-Format kann unterschiedliche Informationen enthalten. Zur Strukturierung dieser Informationen besteht eine GRIB 2-Datei aus neun Sektionen. Tabelle 3 beschreibt die jeweiligen Sektionen einer GRIB 2-Datei.

Sektion	Beschreibung
Sektion 0: Indikatorsektion	Definiert die Art der Daten, die GRIB-Edition und die Länge der Datei.
Sektion 1: Identifizierungssektion	Enthält Informationen über den Autor der Datei, die enthaltenen Tabellen und die abgedeckte Zeitperiode.
Sektion 2: Optionale Sektion	Beinhaltet lokale Informationen, die bspw. vom lokalen Wetterdienst gefüllt werden.
Sektion 3: Gitterdefinition	Beschreibt, welcher Ausschnitt der Erde mit einem entsprechenden Gitter versehen wurde und wie das Gitter aufgebaut ist.
Sektion 4: Produktdefinition	Definiert das enthaltene Produkt. Kann z.B. Vorhersage enthalten.
Sektion 5: Daten-Repräsentationssektion	Definiert die Art und Weise, wie die Daten abgespeichert sind.
Sektion 6: Bitmaskensektion	Optionale Informationen über eine verwendete Bitmaske, die die Speicherung der Daten genauer spezifizieren. Beispielsweise kann hier angegeben werden, dass nur Daten betrachtet werden, die auf dem Wasser liegen.
Sektion 7: Datensektion	Hier sind die eigentlichen Daten und Informationen der GRIB-Datei abgespeichert.
Sektion 8: Endsektion	Beendet die Datei.

Tabelle 3: Die enthaltenen Sektionen einer Datei im GRIB 2 Format ((Deutscher Wetterdienst 2019; World Meteorological Organization 2003)).

Hierbei hervorzuheben sind die Sektionen drei bis acht, die in Bezug auf ihren Inhalt wiederverwendet werden können (Deutscher Wetterdienst 2019; World Meteorological Organization 2003). Der eigentliche Informationsgehalt einer GRIB 2 Datei kann aus Sektion 7 extrahiert werden. Hierfür sind Informationen aus Sektion 5 erforderlich, die angeben, wie die Daten komprimiert wurden.

Anschließend müssen die extrahierten Informationen aus Sektion 7 mit den Informationen aus Sektion 3 kombiniert werden. In dieser Sektion ist beschrieben, welches Gebiet auf der Erde die Informationen abdecken und in welcher Auflösung das Gitter definiert wurde (Deutscher Wetterdienst 2019).

Seegang

Als Seegang bezeichnet man Wellen auf der Wasseroberfläche, wobei sich mehrere einzelne Wellen überlagern können und so ein Seegangsspektrum ergeben. In Abbildung 7 ist eine fortlaufende Welle und alle dabei relevanten Begrifflichkeiten illustriert.




Abbildung 7: Die Ordinalbewegung einer Welle (Angelehnt an (Berking und Brauner 2010)).

Grundsätzlich ist eine Welle eine periodische vertikale und horizontale kreisförmige Bewegung von Wasserteilchen: Diese Bewegung wird auch als Ordinalbewegung bezeichnet. Der höchste Punkt einer Welle wird als Wellenkamm bezeichnet, in der Mitte liegt das Wellental. Die Wellenhöhe ist der Abstand zwischen dem Wellental und dem Wellenkamm und wird in Seewetterberichten als signifikante Wellenhöhe angegeben. Die signifikante Wellenhöhe entspricht dabei dem Mittel des oberen Drittels der Wellenhöhen und nicht die maximal zu erwartende Wellenhöhe. Grundsätzlich kann man davon ausgehen, dass die maximale Wellenhöhe doppelt so hoch sein kann wie die signifikante Wellenhöhe. Ein weiterer wichtiger Parameter zur Charakterisierung von Wellen ist die Wellenlänge, die durch die Distanz zwischen zwei Wellenkämmen definiert ist.

Für die Entstehung von Seegang sind des Weiteren die Begriffe Windsee und Dünung relevant. Als Windsee bezeichnet man die direkt durch Wind verursachten Wellen, die durch eher spitze Wellenkämme und ihrer ungleichmäßigen Erscheinung auffallen.

Im Gegensatz zu Wellen aus der Windsee sind Wellen der Dünungswellen länger und haben abgerundete Wellenkämme. Zu beobachten sind sie, wenn der Wind nachlässt und infolgedessen der Seegang ausläuft. Durch ihre höhere kinematische Energie bleiben sie bei einem Ablauf des

Seegangs länger erhalten und sind somit noch wahrnehmbar. Grundsätzlich bewegen sich die langen Dünungswellen schneller als die kurzen Windseewellen, sodass sie dem Windfeld vorausseilen. Aus diesem Grund können Dünungswellen ein Indikator für ein sich näherndes Wind- beziehungsweise Sturmfeld sein (Berking und Brauner 2010).

Strömung

Grundsätzlich sind die Meeresströmungen und die Gezeitenströmungen voneinander zu unterscheiden. Die Meeresströmungen entstehen im Allgemeinen dadurch, dass der Wind auf die Meeresoberfläche wirkt, wodurch die Wasserteilchen in Bewegung gesetzt werden. Dabei ziehen die Wasserteilchen in den oberen Schichten die Wasserteilchen in den unteren Schichten mit und setzen sie ebenfalls in Bewegung. Diese Kausalkette lässt sich mit der Ekman-Spirale beschreiben, die in Abbildung 8 dargestellt ist.




Abbildung 8: Der Zusammenhang der Windrichtung, Oberflächenströmung und der Ekman-Spirale (Angelehnt an (Berking und Brauner 2010)).

In einem 45° Winkel bezogen auf die Windrichtung entsteht die Oberflächenströmung. Für diese Driftströmung ist die Corioliskraft verantwortlich. Auf Abbildung 8 ist zu erkennen, dass mit einer zunehmenden Wassertiefe die Strömung stärker driftet. Gleichzeitig ist zu beobachten, dass mit zunehmender Tiefe die Strömungsgeschwindigkeit abnimmt.

Durch die vorherrschende atmosphärische Zirkulation der Luftmassen existieren stabile Luftströme, die kontinuierlich auf die Wasseroberfläche wirken, wodurch Strömungen, wie zum Beispiel der Golfstrom, entstehen. Durch die Corioliskraft bewegen sich die Strömungen auf der Nordhalbkugel im Uhrzeigersinn, auf der Südhalbkugel gegensätzlich. Mit Ausnahme des Indischen Ozeans existieren auf der Nord- und Südhalbkugel immer zwei Strömungskreise. Im Indischen Ozean sorgt die Monsunzirkulation dafür, dass es lediglich einen Strömungskreis gibt.

Neben den Meeresströmungen existieren Gezeitenströmungen, die sich durch ein rhythmisches Steigen und Fallen des Wassers und den damit einhergehenden Wasserbewegungen auszeichnen.

Ausgelöst wird dies durch die Anziehungskraft des Mondes und der Sonne. Bei der Umrundung des Mondes um die Erde wirken die auf Abbildung 9 illustrierten Kräfte.




Abbildung 9: Das Wirken der Kräfte, die für die Entstehung der Gezeiten verantwortlich sind (Angelehnt an (Berking und Brauner 2010)).

Grundsätzlich wirken hier zwei Kräfte gegeneinander: Die Gravitationskraft des Mondes und die Zentrifugalkraft der Erde. Je nach Position des Mondes in Relation zur Erde wirken die Gravitationskräfte unterschiedlich stark auf die Erde. Auf die dem Mond zugewandte Seite der Erde wirken die Gravitationskräfte des Mondes stärker als auf der abgewandten Seite des Mondes. Die durch die Rotationsbewegung entstehende Zentrifugalkraft auf der Erde ist allerdings überall gleich groß. Als Ergebnis der beiden wirkenden Kräfte entstehen gezeitenerzeugende Kräfte, die letztlich für die Bewegung der Wassermassen verantwortlich sind.

Durch die Gezeitenströmungen entsteht ein sogenannter Tidenhub. Im Gegensatz zum offenen Meer, wo lediglich mit durchschnittlich 75 cm an Tidenhub zu rechnen ist, ist entlang der Nordseeküste mit einem Tidenhub von rund 3 Metern zu rechnen. Somit entstehen hier neben dem Auftreten von Gezeitenströmungen auch Unterschiede im Wasserstand (Berking und Brauner 2010).

2.3 Seekarten und Seezeichen

Die SOLAS definieren, dass auf jeder Schiffsreise alle für die Reise relevanten und aktuellen Seekarten mitzuführen sind. Neben Papierkarten ist es möglich, die Seekarten in elektronischer Form mitzuführen und sie über ein Electronic Chart Display and Information System (ECDIS) zu nutzen (International Maritime Organization 1974).

Die wichtigsten Inhalte der Seekarten in Bezug auf diese Arbeit sind die Wassertiefe und die Information über den Verlauf von Wasserstraßen. In Bezug auf die Wassertiefe ist es wichtig zu erwähnen, dass die angegebenen Wassertiefen immer den niedrigsten Wasserstand in Relation zur Tide angibt. Somit können die angegebenen Wassertiefen immer als zugesicherte Mindestwassertiefe betrachtet werden (Berking und Brauner 2010).

Wasserstraßen werden durch Seezeichen markiert, die ein wesentliches Hilfsmittel der konventionellen Schiffsnavigation sind. Im Allgemeinen werden Seezeichen zur Orientierung und Warnung von Gefahrenstellen verwendet. Eingesetzt werden Seezeichen in küstennahen Gewässern und können dabei entweder fest installiert sein oder schwimmend. Seezeichen können für eine bessere Identifizierung bei Nacht beleuchtet sein. In diesem Fall spricht man von Leuchtufern (Berking und Brauner 2010). Die IALA (International Association of Lighthouse Authorities) reglementiert in der Recommendation 1001 das Aussehen und den Einsatz von Seezeichen und Leuchtufern (International Association of Lighthouse Authorities 2018). Zu den von der IALA definierten Leuchtufern gehören Richt-, Leit- und Sektorenfeuer.

Ein Richtfeuer unterstützt die Brückenbesatzung beim exakten Befahren einer Kurslinie und bei der korrekten Identifizierung der Fahrwasserrichtung. Hierfür besteht ein Richtfeuer aus einem Unter- und Oberfeuer. Blickt die Brückenbesatzung auf ein Richtfeuer und das Unter- und Oberfeuer befinden sich exakt übereinander, so ist das Schiff auf der richtigen Kurslinie. Je nachdem ob das Schiff zu weit rechts oder links ist, erscheint das Unter- und Oberfeuer versetzt voneinander (Berking und Brauner 2010; International Association of Lighthouse Authorities 2018).

Im Gegensatz zu Richtufern werden Leitfeuer zum sicheren Leiten der Schiffe in besonderen Gebieten verwendet. In Hafeneinfahrten werden Leitfeuer dazu verwendet, Schiffe den sicheren Weg in den Hafen zu weisen. Ein anderer Einsatzzweck von Leitufern sind Gebiete, in denen sich Untiefen befinden. Dort werden die Leitfeuer von der Brückenbesatzung zur sicheren Navigation entlang der Untiefen verwendet. Darüber hinaus können Leitfeuer durch Sektorenfeuer ergänzt werden. Diese Kombination unterstützt die Besatzung bei der Identifikation der korrekten Fahrseite (Berking und Brauner 2010; International Association of Lighthouse Authorities 2018).

Neben den gerade beschriebenen Leuchtufern sind Seetonnen wichtige Elemente, um das befahrbare Seegebiet sichtbar abzustecken. Seetonnen werden genutzt um konkrete Seewege beziehungsweise Fahrwasser abzustecken, Hierfür das Lateralsystem verwendet, bei dem die Seetonnen die Seiten des Fahrwassers markieren (Berking und Brauner 2010). In der Reglementierung werden von der IALA zwei Betonungssysteme unterschieden, die je nach Region angewendet werden. In Europa wird Betonungssystem A, in den USA Betonungssystem B verwendet (Berking und Brauner 2010; International Association of Lighthouse Authorities 2018).

Abbildung 10 zeigt eine schematische Abbildung der im Betonungssystem A verwendeten Seetonnen. Schiffe, die im Fahrwasser fahren und von See kommend sind, müssen die grünen Seetonnen auf ihrer Steuerbordseite halten. Die grünen Seetonnen kommen in der Form entweder als Kegel, Säule oder Holm vor. Wenn ein Toppzeichen vorhanden ist, dann ist diese kegelförmig und zeigt nach oben. Für den Fall, dass sich ein Schiff in Richtung See bewegt, so muss es die roten Seetonnen auf seiner Steuerbordseite halten. Rote Seetonnen sind von ihrer Form her entweder als Säule, Holm oder Zylinder vor. Das Toppzeichen eine rote Seetonne ist ein stumpfer Zylinder. Im Betonungssystem A werden die grünen Tonnen mit geraden und die roten Tonnen mit ungeraden Ziffern nummeriert. In Gewässern, in denen Betonungssystem B gilt, sind die Farben umgekehrt (International Association of Lighthouse Authorities 2018).




Abbildung 10: Die Seetonnen des Lateralsystems A der IALA (Angelehnt an (International Association of Lighthouse Authorities 2018)).

Neben den Seetonnen zur Markierung des Fahrwassers existieren noch Kardinal-, Ansteuerungs-, Einzelfahren- und Wracktonnen. Kardinaltonnen markieren Gebiete in denen Gefahren für die sicheren Betrieb von Schiffen herrschen. Dies können beispielsweise Gebiete sein, in denen ein Wrack liegt und das Wasser dort nicht mehr ausreichend tief ist. Je nach Aussehen der Kardinalstonne ergibt sich die Passierichtung für die Schiffe. Im Gegensatz zur Kardinalstonne markiert die Einzelfahrenstonne die gefährliche Stelle, indem sie über der Gefahrenstelle schwimmt. Somit kann eine solche Tonne von einem Schiff an beliebigen Seiten passiert werden.

Ansteuerungstonnen markieren die Mitte eines Fahrwassers und sind rot-weiß gestreift mit einem roten Ball als Toppzeichen. In Fahrwassern, die durch das Lateralsystem betonnt sind, befinden sich Ansteuerungstonnen häufig am Anfang des Fahrwassers.

Wracktonnen weisen auf Gebiete hin, in denen sich ein neues Wrack befindet. Sie kommen zum Einsatz, wenn das Wrack zum einen noch nicht auf den Seekarten abgebildet ist und zum anderen das entsprechende Gebiet noch nicht durch Kardinaltonnen ausgewiesen ist (Berking und Brauner 2010; International Association of Lighthouse Authorities 2018).

2.4 Knowledge Discovery in Databases

Computergestützte Prädiktionen von Ereignissen beziehungsweise Verhalten sind heutzutage in vielen Bereichen zu finden. Onlinehändler versuchen auf Basis bisheriger Einkäufe und des Browserverlaufs den Zeitpunkt und die Waren zukünftiger Einkäufe von Kunden vorherzusagen. Die Vorhersagen von Tsunamis oder Erdbeben basieren auf Informationen und Gegebenheiten, die bei vorherigen Vorfällen passiert sind. Obwohl sich die Domänen erheblich unterscheiden können, haben alle solche Anwendungen das Ziel, Muster in historischen Daten zu erkennen und auf Basis dieser Muster Prognosen für die Zukunft abzugeben. Das Vorgehen, um in Daten Muster zu erkennen, wird als Data Mining bezeichnet. Ein Synonym dafür ist häufig Knowledge Discovery In Databases (KDD). Betrachtet man die Definition und Beschreibung des KDD-Prozesses in (Fayyad, Piatetsky-Shapiro und Smyth 1996), so wird deutlich, dass der synonyme Gebrauch dieser beiden Begriffe nicht richtig ist. Der KDD-Prozess beschreibt ein allgemeines und strukturiertes Vorgehen, um Muster in Daten zu erkennen und somit auch Wissen daraus extrahieren zu können. Data Mining ist ein Prozessschritt innerhalb des KDD, der die Anwendung bestimmter Algorithmen auf eine Datenmenge beschreibt (Fayyad, Piatetsky-Shapiro und Smyth 1996).

In diesem Kapitel werden der KDD-Prozess und die jeweiligen Prozessschritte beschrieben. Dabei werden die Herausforderungen aufgezeigt, die bei der Arbeit mit Daten entstehen und welche Lösungskonzepte dafür existieren. Während der Beschreibung des Data Mining-Schritts wird eine Auswahl an Algorithmen dargelegt, die gleichzeitig eine Einführung in das Forschungsfeld des maschinellen Lernens darstellen.

Der KDD-Prozess

Wie eingangs erläutert eignet es sich zur Lösung von Prädiktionsproblemen historische Daten so zu analysieren, dass Muster in ihnen erkannt und extrahiert werden können. Diese Muster werden im Anschluss zur Prädiktion in den unterschiedlichen Domänen verwendet. Früher waren für solche Analysen und Vorhersagen Analysten notwendig, die in ihrer Domäne auf die dafür spezifischen Daten Experten waren. Die Daten wurden auf eine Fragestellung hin manuell interpretiert und analysiert. Mit der fortschreitenden Digitalisierung in immer mehr Domänen wurden gleichzeitig auch mehr Daten verfügbar, die für solche Analysen verwendet werden können. Gleichzeitig wurden die manuellen Analysen durch computergestütztes Vorgehen ersetzt, was die Verarbeitung von mehr Daten in einer kürzeren Zeit erlaubte. Mit der Definition des KDD-Prozesses existiert ein Vorgehen, das die Gesamtheit der Probleme adressiert, die bei der Verarbeitung von Daten entstehen können (Fayyad, Piatetsky-Shapiro und Smyth 1996).

Abbildung 11 zeigt den KDD-Prozess nach Fayyad et al. (Fayyad, Piatetsky-Shapiro und Smyth 1996). Die blauen Kästchen zeigen die fünf Schritte, die beim KDD-Prozess durchlaufen werden. Die unterschiedlichen orangenen Formen zeigen die jeweiligen Zwischenergebnisse eines jedes Schritts.




Abbildung 11: Der KDD Prozess nach (Fayyad, Piatetsky-Shapiro und Smyth 1996).

Die Abbildung zeigt, dass der KDD-Prozess durchaus als ein iteratives Vorgehen bezeichnet werden kann, bei dem auch auf vorherige Schritte zurückgesprungen wird. Dies kann unter Umständen notwendig sein, wenn beispielsweise nach dem Data Mining-Schritt ersichtlich wird, dass eine unzureichende Datenmenge verwendet wurde. In diesem Beispiel würde es der KDD-Prozess erlauben in den *Selection*-Schritt zurückzuspringen und die Datenauswahl zu erweitern [FaPS96].

Im Folgenden werden die jeweiligen Schritte des KDD-Prozesses näher erläutert. Aus der Beschreibung wird deutlich, dass KDD ein interdisziplinärer Ansatz ist, bei dem Methoden aus der Statistik, maschinellen Lernen, Datenbanktheorie, Visualisierungstechniken und Mustererkennung Anwendung finden.

Domänenverständnis und Zielsetzung

Bevor es mit dem ersten Schritt im KDD-Prozess beginnt, muss ein Verständnis über die Domäne und die vorliegenden Daten geschaffen werden. Dieses Verständnis hilft bei der späteren Auswahl und Vorverarbeitung der Daten, so dass sich beispielsweise domänenspezifische Fehler leichter in den Daten erkennen und erklären lassen. Eine weitere wichtige Aufgabe in diesem Schritt ist die Festlegung des Analyseziels. Im Kontext des KDD unterscheidet man zwei grundsätzliche Ziele:

Entweder führt man den Prozess zur Verifikation einer vorher aufgestellten Hypothese durch oder es geht um die Erkennung von neuen Mustern. Wenn es um die Erkennung neuer Muster geht, so werden hier die Unterziele Prädiktion oder Repräsentation unterschieden. Bei der Prädiktion sollen in den Daten Muster erkannt werden, anhand derer zukünftiges Verhalten der analysierten Objekte vorhergesagt werden kann. Geht es um die Repräsentation, so werden Muster gesucht, die einen Sachverhalt für einen Menschen verständlich abbilden (Fayyad, Piatetsky-Shapiro und Smyth 1996). In dieser Arbeit liegt der Fokus auf dem Prädiktionsziel.

Selection

In diesem Schritt wird aus einer gegebenen Menge an Daten eine Untermenge ausgewählt, aus der das Wissen extrahiert werden soll. Die Auswahl der Daten hängt vom vorher definierten Ziel ab (Fayyad, Piatetsky-Shapiro und Smyth 1996). Im Rahmen dieser Arbeit soll Schiffsverhalten in Abhängigkeit von kontextuellen Gegebenheiten prädiziert werden. Folglich ist hier die Auswahl geeigneter historischer Bewegungsdaten und Informationen zum Kontext der erste Schritt.

Preprocessing

Die ausgewählten Daten sind in den meisten Fällen Rohdaten und müssen zur weiteren Analyse entsprechend bereinigt und vorverarbeitet werden (Fayyad, Piatetsky-Shapiro und Smyth 1996; Runkler 2010). Rohdaten, die in definierten Zeitabständen durch Sensoren gemessen werden, liegen in Form einer Zeitreihe vor. Historische Schiffsbewegungsdaten sind Beispiele für Zeitreihen. Je nach verwendetem Sensor zur Aufzeichnung der Schiffsbewegungen, liegen die Daten in unterschiedlichen Zeitabständen vor. Die Besonderheit bei aufgezeichneten Schiffsbewegungsdaten ist die Erweiterung der zeitlichen Komponente um eine räumliche, die die Position der Schiffe abbilden. Im Allgemeinen entsteht eine Zeitreihe in dem ein kontinuierliches Zeitsignal zu einer definierten Abtastzeit T gemessen wird. Abbildung 12 illustriert exemplarisch die Umwandlung eines kontinuierlichen Zeitsignals (linke Seite) in eine diskrete Menge von Messwerten in Abhängigkeit zur Abtastzeit T (rechte Seite). Die einzelnen Messwerte sind als Dreieck dargestellt.




Abbildung 12: Links: Der kontinuierliche Verlauf einer Zeitreihe. Rechts: Die einzelnen Messwerte der linken Zeitreihe (Dreiecke) und der sich daraus ergebende Verlauf der Zeitreihe.

Bei der Betrachtung der Abbildung wird deutlich, dass die Menge der Messwerte nicht die Gesamtheit, die in dem kontinuierlichen Zeitsignal enthaltenen Informationen beinhaltet. Zum Ausgleich dieses Informationsverlustes existieren zwei Möglichkeiten: Zum einen kann mit einer geringen Abtastzeit T der Sensoren der Zeitraum zwischen den einzelnen Messungen verringert werden, was allerdings in einer erhöhten Menge an Rohdaten resultiert, die folglich schwerer zu verarbeiten sind. Eine zweite Möglichkeit ist die Annäherung des kontinuierlichen Zeitsignals auf Basis der Messwerte. Hier finden Polynomzüge Anwendung, die, je nach gewähltem Grad, das kontinuierliche Zeitsignal unterschiedlich gut nachbilden (Runkler 2010).

Wie weiter oben beschrieben haben Schiffsbewegungsdaten eine zeitliche und geografische Komponente, wodurch sie als Geodaten bezeichnet werden können. Mittels Geodaten existiert die Möglichkeit, geografische Gegebenheiten abzubilden und so in einer für die Computerverarbeitung geeignete Form zu bringen. Die konkrete Ausgestaltung solch einer Modellierung ist mit der ISO 19107 definiert (Brinkhoff 2013; International Organization for Standardization 2003).

Ein Geodatum wird zum einen durch geometrische Eigenschaften definiert, die ihre Lage im Raum und Ausdehnung beschreiben. Hierbei unterscheidet man zwei Modelle zur Beschreibung: Beim Rastermodell wird der Abdeckungsraum der Daten in gleich große Zellen unterteilt, wobei die Lage der jeweiligen Geodaten dann durch die Angabe der jeweiligen Rasterzellen beschrieben wird. Im Gegensatz dazu werden Geodaten mit dem Vektormodell durch Punkte und Linien beschrieben, die diese Punkte miteinander verbinden. Hieraus ergeben sich dann als Repräsentationsform entweder Streckenzüge oder Polygone. Die Punkte werden in Form von Koordinaten angegeben, die je nach dem verwendeten Bezugssystem anders zu interpretieren sind. Solche Bezugssysteme setzen sich aus einem Koordinatensystem, einem Geltungsbereich und Angaben zusammen, die eine Abbildung auf einem globalen System definieren. Im Gegensatz zu kartesischen Koordinatensystemen beziehen sich georeferenzierende Bezugssysteme auf die Erdoberfläche. Hier

unterscheidet man nach (Brinkhoff 2013) zwischen geografischen und projizierenden Koordinatensystemen. In geografischen Koordinatensystemen wird die Erde als Ellipsoid modelliert. Je nach Form, Ausrichtung und Mittelpunkt unterscheidet man verschiedene geografische Koordinatensysteme, wie beispielsweise das WGS84. Koordinaten können in einem geografischen System als 3D-Koordinaten angegeben werden, wobei ein Parameter die Abweichung vom Mittelpunkt beschreibt, der durch den Kern des Ellipsoids definiert wird. Im Gegensatz dazu werden geografische Koordinaten im Winkelmaß bezogen auf den Äquator und einem Nullmeridian angegeben. Dargestellt ist dies auf Abbildung 13.




Abbildung 13: Angabe der Position P in einem geografischen Koordinatensystem, definiert durch geografische Länge (λ) und Breite (φ) nach (Brinkhoff 2013).

Der Punkt P wird durch die geodätischen Daten der geografischen Länge λ und der geografischen Breite Φ definiert, wobei beide Parameter mit Bezug auf den Äquator (geografische Breite) und Nullmeridian (geografische Länge) angegeben werden.

Ein Nachteil dieser Repräsentationsart ist die hohe Intensität, die beim Rechnen mit diesem Modell entsteht. Um diesen Nachteil auszugleichen können projizierte Koordinatensysteme verwendet werden. Hierfür werden die Koordinatenangaben durch ein mathematisches Modell auf eine Ebene projiziert, wobei allerdings Eigenschaften und damit auch Informationen verloren gehen können. Der Vorteil bei der Verwendung der projizierten Koordinatensysteme ist allerdings der Fakt, dass das Rechnen mit solchen Systemen weniger intensiv ist als mit geografischen Koordinatensystemen (Brinkhoff 2013).

Unabhängig davon in welchem Format oder ob die Rohdaten als Zeitreihe vorliegen, sie sind in den meisten Fällen fehlerbehaftet. Fehler können dabei zufällig oder systematisch entstehen. Zufällige Fehler treten in Form von Mess- oder Übertragungsfehler auf, die beispielsweise auf defekte Sensorik zurückzuführen sind. Systematische Fehler entstehen im Gegensatz dazu durch eine

falsche Skalierung oder Kalibrierung der Sensorik. Ist diese Abweichung bekannt, so können systematisch auftretende Fehler in der Regel komplett erkannt und korrigiert werden. Eine häufig verwendete Methode zur Korrektur zufälliger Fehler ist die Modellierung des Fehlers durch additives Rauschen.

In der Vorverarbeitung im KDD-Prozess ist eine weitere Herausforderung die Erkennung und Behandlung von Ausreißern, die die Muster verändern können. Als populäre Methode hierfür ist die 2-Sigma-Regel zu nennen, bei der bestimmt wird, ob es sich bei einem Wert um einen Ausreißer handelt, indem die Abweichung von der Standardabweichung berechnet wird. Ist sie mehr als doppelt so groß, so ist der Wert als Ausreißer zu behandeln. Zum Umgang mit Ausreißern werden in (Runkler 2010) unterschiedliche Verfahren beschrieben: Ausreißer können durch einen minimalen respektive maximalen Wert ersetzt werden oder durch eine lineare Interpolation korrigiert werden. Etwas Ähnliches wird durch die Anwendung einer linearen oder polynomialen Regression erreicht. Eine weitere Möglichkeit einen Ausreißer zu behandeln ist die Schätzung mit Hilfe der Wahrscheinlichkeitsdichte. Des Weiteren können Ausreißer auch nur markiert werden, sodass sie im späteren Verlauf während der Analyse gesondert behandelt werden können.

Je nach Anwendungsfall können Ausreißer und Rauschen durch Filtrierung mit gleitenden statistischen Maßen erreicht werden. Bei diesem Verfahren wird von allen bekannten Werten ein statistisches Maß gebildet, wie zum Beispiel der Mittelwert. Ein aktueller Wert wird anschließend betrachtet und kann beispielsweise durch den gleitenden Mittelwert ersetzt werden. Im Gegensatz zu gleitenden statistischen Maßen zur Filtrierung gehen exponentielle Filter davon aus, dass ein aktueller Wert sich nur um einen definierten Bruchteil verändern kann.

Typisch für die Arbeit mit Rohdaten ist die Tatsache, dass die besagten Daten zumeist aus unterschiedlichen Quellen stammen und unterschiedliche Wertebereiche abdecken. Folglich bedeutet dies, dass die Daten aus unterschiedlichen Quellen mit Bezug aufeinander zur Analyse zusammengeführt werden müssen. Anschließend kann das Problem der unterschiedlichen Wertebereiche adressiert werden. Hierfür standardisiert man die Daten, indem der Merkmalsraum künstlich begrenzt wird. Die benötigten Grenzen werden entweder selbst gewählt oder werden durch beobachtete Werte repräsentiert. Ein Verfahren in diesem Zusammenhang ist die μ - σ -Standardisierung, bei der der Mittelwert und die Standardabweichung zur Standardisierung genutzt wird (Runkler 2010).

Transformation

In diesem Schritt ist das vorrangige Ziel den Datenbestand zur weiteren Verarbeitung zu reduzieren. Hierbei werden nicht benötigte Spalten oder Einträge entfernt. Die Kriterien zur Entscheidung ob und welcher Eintrag beziehungsweise welche Spalte entfernt wird, hängt von dem zu Beginn

definierten Ziel des Analyseprozesses ab. Ein Vorteil, den die Datenreduktion mit sich bringt, ist die gleichzeitige Reduktion des Gesamtdatenbestands. Dies wirkt sich wiederum positiv auf die Rechenzeit aus, die die nachfolgende Analyse voraussichtlich benötigen wird.

Das zuvor ausgegebene Analyseziel dient in diesem Schritt darüber hinaus zur Identifizierung von nützlichen Features, die im Rahmen der Analyse genutzt werden sollen (Fayyad, Piatetsky-Shapiro und Smyth 1996). Features bilden im Allgemeinen Eigenschaften eines realen Objektes ab, die im späteren Verlauf beispielsweise zur Erkennung von Mustern beitragen können. Allerdings ist hierfür Domänenwissen erforderlich, welches im KDD-Prozess zu Beginn aufgebaut werden muss (Fayyad, Piatetsky-Shapiro und Smyth 1996; Shalev-Shwartz und Ben-David 2014). Das Vorgehen, welches für die Analyse relevante Feature auswählt, wird in der Literatur als Feature Engineering bezeichnet. Nach Shalev-Schwartz und Ben-David (Shalev-Shwartz und Ben-David 2014) existieren folgende drei Herausforderungen beim Feature Engineering:

1. **Feature Selection:** Aus einer Menge an potenziellen Features muss die Untermenge gewählt werden, die für die spätere Analyse und zur Erreichung des definierten Ziels notwendig sind. Eine Möglichkeit dies zu tun ist das zufällige Ausprobieren verschiedener Kombinationen der Features. Häufig gibt es hier allerdings eine große Menge an Kombinationsmöglichkeiten und die Algorithmen können eine hohe Rechenzeit haben, sodass dieses Vorgehen nicht praktikabel ist. Bewährte Ansätze zur Feature Selection sind unter anderem die Verwendung von Filtermethoden, bei denen die Features unabhängig voneinander bewertet werden. Ein Beispiel ist hier der Pearson-Korrelationskoeffizient. Eine andere Möglichkeit ist die Anwendung von Greedy-Algorithmen, die allerdings mit dem später verwendeten Algorithmus verbunden sein müssen. Ist dies der Fall, so wird erst mit einem Feature und dem späteren Algorithmus gelernt und die Performanz gemessen. Anschließend werden sukzessive weitere Features hinzugenommen. Am Ende wird jene Kombination gewählt, die die beste Performanz aufweist.
2. **Feature Manipulation und Normalisierung:** Wie bereits oben beim Preprocessing erwähnt, müssen die vorliegenden Daten unter Umständen vorverarbeitet und normalisiert werden, damit sie später verwendet werden können. Gleiches gilt für die selektierten Features. Mögliche Methoden hierfür sind oben im Abschnitt Preprocessing beschrieben. Durch eine entsprechende Manipulation und Normalisierung der Features können etwaige Fehler verringert und die Laufzeit der später angewendeten Algorithmen verbessert werden.
3. **Feature Learning:** Das in Punkt 1 dargelegte Vorgehen zur Feature Selection ist ein manueller Prozess, bei dem der Anwender zum einen selbst entscheidet, welches Gütemaß zur

Bewertung der Features herangezogen wird und zum anderen darüber, welche Features überhaupt zur Auswahl stehen. Unter Feature Learning versteht man im Allgemeinen die Automatisierung dieses Prozesses. Als Beispiele für Ansätze, die automatisiert eine Untermenge von Features auswählen können, sei hier das k-Means Clustering oder die Principal Component Analysis (PCA) genannt.

Data Mining

Fayyad et al. beschreiben in (Fayyad, Piatetsky-Shapiro und Smyth 1996) Data Mining als einen Teilschritt des KDD-Prozesses und nicht als alleinstehendes Vorgehen. Befassen sich die vorherigen Schritte im KDD-Prozess mit der Auswahl und Reinigung der Rohdaten, so ist das Ziel des Data Mining-Schritts die Anwendung von Algorithmen auf diese Rohdaten, um Muster zu erkennen. Dieser Schritt wird in der Regel hintereinander wiederholt, wobei jedes Ergebnis einer Iteration zur Verbesserung der Performanz der Algorithmen beiträgt. Die eingangs erwähnte Interdisziplinität des KDD-Prozesses spiegelt sich auch in den Algorithmen wider, die im Rahmen des Data Minings angewendet werden. Grundsätzlich haben alle Methoden in einer Form Schnittmengen mit den Bereichen des maschinellen Lernens, Mustererkennung oder der Statistik (Fayyad, Piatetsky-Shapiro und Smyth 1996; Runkler 2010).

In den letzten Jahren hat sich insbesondere das maschinelle Lernen stetig weiterentwickelt und wird häufig zur Lösung von Klassifikations- oder Regressionsproblemen gelöst. Die Funktionsweise des maschinellen Lernens orientiert sich dabei an dem menschlichen Lernprozess, der sich durch Lernen durch Erfahrung auszeichnet. Algorithmen des maschinellen Lernens eignen sich besonders gut um Aufgaben zu übernehmen, die die Kapazitätsgrenze des Menschen überschreitet, wie das zum Beispiel bei der Verarbeitung sehr großer Datenmengen der Fall ist (Shalev-Shwartz und Ben-David 2014).

Im Kontext des maschinellen Lernens wird Lernen als das Vorgehen bezeichnet, bei dem in einer Menge an Daten Muster erkannt werden können. Die Gesamtheit der gelernten Parameter zur Identifizierung der jeweiligen Muster bezeichnet man als Modell. Somit lernen diese Algorithmen Modelle, die abbilden, wie Muster in einer gegebenen Menge an Daten erkannt werden können und wie dies für eine neue Menge an Daten erreicht werden kann (Shalev-Shwartz und Ben-David 2014).

Im Folgenden soll anhand des Beispiels eines Spamfilters für E-Mails die unterschiedlichen Formen des Lernens und der Begriff des Modells im Bereich des maschinellen Lernens erläutert werden. Beim Spamfilter für E-Mails geht es darum, aus einer Menge an gegebenen E-Mails das Muster erkennen und extrahieren zu können, mit dem zukünftigen E-Mails als Spam oder nicht als

Spam klassifiziert, werden können. Zum Lernen existieren im Machine Learning unterschiedliche Konzepte:

- **Supervised Learning (überwachtes Lernen):** Hier bekommt das lernende System eine Menge an Daten, bei denen die jeweilige Zielklasse gekennzeichnet ist. Aufgabe des lernenden Systems ist dann, auf Grundlage dieser Zusatzinformation und weiterer Feature der Daten die Muster zu extrahieren. Für das Beispiel mit dem Spamfilter heißt das, dass in einer Menge an E-Mails verzeichnet ist, welche E-Mails Spam sind und welche nicht.
- **Unsupervised Learning (nicht überwachtes Lernen):** Im Gegensatz zum Supervised Learning fehlen dem lernenden System bei dieser Lernform jegliche Zusatzinformationen zu den gegebenen Daten. Das extrahierte Muster als Ergebnis dieses Lernprozesses unterscheidet sich im Vergleich zum Supervised Learning dahingehend, dass das lernende System eine Art Zusammenfassung über die zur Verfügung gestellten Daten herausgibt. Diese Zusammenfassung ist eine automatisierte Zuweisung der Ergebnisse, zum Beispiel in Form von Clustern. Für das Beispiel des Spamfilters wären zwei Cluster das Ergebnis: eines mit den E-Mails, die das lernende System als Spam identifiziert hat und das andere mit den E-Mails, die nicht als Spam identifiziert wurden.
- **Reinforcement Learning (verstärkendes Lernen):** Supervised und Unsupervised Learning sind zwei gegensätzliche Ansätze zum Lernen. Zwischen diesen beiden Ansätzen ist das Reinforcement Learning einzuordnen. Hierbei verfügt das lernende System über zusätzliche Informationen über die gegebenen Daten. Zusätzlich existiert noch eine Bewertungsfunktion, die während des Lernprozesses versucht wird zu maximieren.
- **Aktives versus passives Lernen:** Unter aktivem Lernen versteht man im Kontext des Machine Learnings das Vorgehen, bei dem das lernende System die Möglichkeit hat mit seiner Umwelt zu interagieren. Beim passiven Lernen hat das lernende System nicht die Fähigkeit, mit der Umwelt zu interagieren und kann somit nur die von der Umwelt zur Verfügung gestellten Daten beobachten. Aktives Lernen im Kontext des Spamfilters bedeutet, dass die zur Verfügung gestellten E-Mails während des Lernprozesses von einem Nutzer entsprechend markiert werden können. Das System stellt in so einem Fall eine entsprechende Anfrage an einen Nutzer während des Lernprozesses. Im Gegensatz dazu kann bei einem passiv lernenden System nur auf die E-Mails samt ihren Informationen zurückgegriffen werden, die dort enthalten sind.

- **Online versus Batch-Learning:** Ein lernendes System, welches während des Lernprozesses schon Ergebnisse bereitstellen muss, lernt online. Im Gegensatz dazu werden beim Batch-Learning erst alle zur Verfügung gestellten Daten analysiert und das entsprechende Muster gebildet. Das Ergebnis ist somit erst nach dem Lernprozess verfügbar.

Alle oben beschriebenen Lernparadigmen haben die Gemeinsamkeit, Muster zu extrahieren und diese im Anschluss auf neue Daten anzuwenden, um Klassifikations- oder Regressionsprobleme lösen zu können. Beim Training wird angenommen, dass den vorliegenden Daten eine unbekannte Wahrscheinlichkeitsverteilung D zu Grunde liegt. Das extrahierte Muster ist somit der Versuch diese Wahrscheinlichkeitsverteilung durch ein geeignetes Modell zu repräsentieren. Deshalb wird dieses Modell häufig als statistisches Modell bezeichnet. Um solch ein Modell bilden zu können, benötigen lernende Systeme Trainingsdaten. Diese werden gebildet, indem eine Gesamtmenge an Daten in Trainings- und Testdaten aufgeteilt werden, was häufig im Verhältnis 80/20 (Trainingsdaten/Testdaten) oder 70/30 geschieht. Die Trainingsdaten $X = \{x_1, \dots, x_n\}$ werden anschließend mit einer Menge an Labels $Y = \{y_1, \dots, y_n\}$ versehen. Das kartesische Produkt beider Mengen $X \times Y$ ergibt die Menge an Trainingsdaten $S = ((x_1, y_1), \dots, (x_n, y_n))$.

Des Weiteren wird davon ausgegangen, dass zur Generierung von S eine korrekte Zuordnungsfunktion existiert, die durch $f: X \rightarrow Y$ definiert ist, sodass $y_i = f(x_i) \forall i$ gilt. Letztlich ist es das Ziel der Algorithmen aus dem Bereich des Machine Learnings, diese Zuordnungsfunktion bestmöglich anzunähern. Hierfür stellt das lernende System eine Hypothese h auf, die durch $h: X \rightarrow Y$ definiert ist. Die Hypothese (auch Predictor genannt) kann später auf neue Datenpunkte angewandt werden.

Um die Güte der Hypothese beurteilen zu können, werden Testdaten genutzt. Testdaten T werden mit der gleichen Zuordnungsfunktion gebildet, wie die Daten in der Menge S , womit $T \subset X$ gilt. Am Ende gilt es folglich zu prüfen, ob $h(x)$ gleich $f(x)$ ist, wobei $x \in T$ (Shalev-Shwartz und Ben-David 2014).

Künstliche neuronale Netze

Das maschinelle Lernen mit künstlichen neuronalen Netzen (KNN) wurde erstmals Mitte des 20. Jahrhunderts erforscht und vorgeschlagen (Shalev-Shwartz und Ben-David 2014). Inspiriert ist diese Form des Lernens durch die Funktionsweise des Gehirns bei diesem Prozess.

Biologische Organismen haben neuronale Netze, die aus Neuronen bestehen und zur Signalweiterleitung miteinander verbunden sind. Das Lernen in solchen neuronalen Netzen geschieht

nach der Hebb'schen Lernregel: Wenn zwei Neuronen immer zusammen aktiviert werden oder sich immer gegenseitig aktivieren, so werden sie auch bei neuen Signalen in dem neuronalen Netz immer bevorzugt aufeinander reagieren (Hebb 2002).

KNN werden in Form eines Graphen aufgebaut, die von der Form neuronaler Netze inspiriert ist. Der Aufbau von KNN ist in Abbildung 14 schematisch dargestellt.




Abbildung 14: Schematische Darstellung eines künstlichen neuronalen Netzes nach (Shalev-Shwartz und Ben-David 2014).

Grundsätzlich besteht ein KNN aus drei Schichten. Die Knoten des Graphen sind die Neuronen und bilden eine Berechnungseinheit ab. Jede Schicht kann aus einer unterschiedlich großen Zahl an Neuronen bestehen, wobei die Zahl der Neuronen im Input-Layer von der Zahl an Features abhängen, die zur Generierung der Hypothese verwendet werden sollen. Die eigentliche Berechnung der Hypothese geschieht im Hidden-Layer. Das Ergebnis der Berechnung wird abschließend an die Ausgangsschicht weitergeleitet. Das Bilden der Hypothese wird bei KNN dann so erreicht, dass die Gewichtung der Kanten so lange variiert wird, bis $h(x)$ gleich $f(x)$ ist. Die Anpassung der Gewichtungen repräsentiert das eigentliche Lernen der KNN. Die Regeln, die bestimmen wie die jeweiligen Kanten gewichtet werden und wie diese Gewichtung zu ändern ist, wird durch die Verwendung von Lernregeln bestimmt. Neben der eingangs erwähnten Hebb'schen Lernregel sind weitere typische Regeln die Backpropagation oder Delta-Regeln (Shalev-Shwartz und Ben-David 2014).

Für die Verarbeitung und Prädiktion von Sequenzen sind KNN in ihrer grundlegenden Form nur bedingt geeignet. Wie oben dargelegt, lernen KNN vorwärtsgerichtet. Das bedeutet, es gibt einen Input-Output Vektor, mit dem das KNN lernt. Sequenzen können mit dieser Methode nur isoliert verarbeitet und zum Lernen genutzt werden. Abbildung 15 zeigt den Lernprozess in diesem

Zusammenhang. Dort ist auf der linken Seite ein vereinfachtes KNN dargestellt, bestehend aus einem Input Vektor, einer Hidden Layer und einem Output Vektor.




Abbildung 15: Exemplarische Darstellung eines KNN, wenn es zum Lernen einer zeitlichen Sequenz genutzt werden soll.

Wenn nun aus einer zeitlichen Sequenz S mit den Elementen $S = \{x_0, x_1, x_2, \dots, x_n\}$ ein Prädiktionsmodell generiert werden soll, so muss mit einem herkömmlichen KNN jedes einzelne Element der Sequenz genutzt werden um eine Prädiktion y_n zu erstellen. Folglich gilt $y_n = f(x_n)$.

Die auf diese Weise entstehenden Prädiktionsmodelle ignorieren allerdings die Tatsache, dass zwischen den einzelnen Zeitschritten einer Sequenz ein Zusammenhang existiert, der für die Vorhersagequalität entscheidend sein kann (Graves 2012b). Dieses Problem wird mit sogenannten rekurrenten neuronalen Netzen (RNN) adressiert. Das Konzept der KNN wird durch das hinzufügen einer sogenannten Gedächtnisfunktion erweitert. Mit dieser Gedächtnisfunktion wird mit der Grundregel herkömmlicher KNNs gebrochen, dass keine zyklischen Verbindungen zwischen den jeweiligen Neuronen innerhalb der Hidden-Layer möglich sind. Dadurch kann ein RNN beim Lernen theoretisch auf alle gesamten vorherigen Inputvektoren zugreifen und diese nutzen. Auf Abbildung 16 ist das Konzept dieser Gedächtnisfunktion vereinfacht dargestellt.




Abbildung 16: RNN erweitern den Ansatz von KNN um eine Gedächtnisfunktion, mit deren Hilfe der Zellzustand h_n im Rahmen des Lernprozesses an die nachfolgenden Zellen weitergegeben werden kann.

Der Zustand des Hidden-Layers wird beim Lernen als h_n an die nachfolgende Zelle weitergegeben. Folglich wird der Zellzustand bei der Berechnung des Outputs berücksichtigt, sodass der Output,

im Gegensatz zum KNN, nicht mehr nur eine Funktion des Inputs ist. Der Output ist eine Funktion des Inputs und dem vorherigen Zellzustand, was definiert ist als $y_n = f(x_n, h_{n-1})$. Der Zellzustand bleibt allerdings nicht konstant, sondern wird bei jedem Zeitschritt der Sequenz aktualisiert. Somit korreliert der Zellzustand sowohl mit dem eigentlichen Input als auch mit dem vorherigen Zellzustand. Daher werden Zellzustand und Input mit ihren jeweiligen Gewichtungen multipliziert und addiert. Als Aktivierungsfunktion wird der Tangens hyperbolicus verwendet, sodass für die Berechnung des Zellzustands gilt: $h_n = \tanh(W_{hh}^T h_{t-1} + W_{xh}^T x_t)$. Der Zellzustand wird bei jedem Zeitschritt im Rahmen des Lernens aktualisiert. Um den Output y_n zu berechnen wird der interne Zustand mit einer eigenen Gewichtung multipliziert, was also eine modifizierte Form des internen Zustands ist und gleichzeitig die Vorhersage des Outputs ist. Folglich gilt für die Berechnung des Outputs $y_t = W_{hy}^T h_t$ (Graves 2012b).

Allerdings haben RNN das Problem des verschwindenden Gradienten, sobald die Netze tief werden, also viele Zellen im Hidden-Layer haben. Der Grund dafür ist, dass zwischen jedem Zeitschritt eine Multiplikation des Zellzustands h_n mit der Gewichtung stattfindet. In Kombination mit der Verwendung des Tangens hyperbolicus als Aktivierungsfunktion sind die Werte stets kleiner als eins. Je weiter man in der Zellschicht also voranschreitet, desto kleiner wird der Gradient, sodass ab einem gewissen Punkt die Gewichtsänderungen in den tiefen Schichten eines RNNs nahe null sind und das Netz nicht mehr weiter trainiert werden kann. Abstrahiert dargestellt bedeutet das, dass ein Netz den Input vergisst (Graves 2012a; 2012b; Hochreiter 1991).

Um das Problem des verschwindenden Gradienten zu adressieren kann zum einen mit der Wahl einer geeigneten Aktivierungsfunktion (zum Beispiel Rectified Linear Unit ReLU) oder einer vorausschauenden Initialisierung der Gewichtungsparameter verhindert werden, dass der Gradient schnell kleiner als eins wird und so die Tiefe der Netze erweitert werden kann.

In der Literatur hat sich hierfür allerdings die Modifikation der RNN-Architektur durchgesetzt. Hochreiter und Schmidhuber (Hochreiter und Schmidhuber 1997) haben hierfür das Konzept der Long Short-Term Memory (LSTM) Netze vorgestellt. LSTM-Netze behalten den Grundgedanken der RNN bei, nämlich das Informationen von oberen Netzschichten an untere Netzschichten im Rahmen des Lernens weitergegeben werden sollen. Sie modifizieren die Zellen zu einem komplexeren Konstrukt, was auf Abbildung 17 abgebildet dargestellt ist.




Abbildung 17: Grundstruktur der Neuronen in LSTM-Netzen, die das Konzept der Gated Cells umsetzen und dafür standardmäßige KNN-Operationen verwenden.

Die Neuronen sind entsprechend dem Konzept der Gated Cells aufgebaut, wodurch die Weitergabe von Informationen besser kontrolliert werden soll im Vergleich zu herkömmlichen RNN. Hierfür wird eine Reihe im Kontext von KNN grundlegender mathematischer Operationen, wie beispielsweise die Nutzung der Sigmoidfunktion als Aktivierungsfunktion, verwendet.

Durch diese Struktur und den Aufbau sind Gated Cells in der Lage zu kontrollieren, welche Informationen während des Lernprozesses weiterverwendet werden sollen und welche nicht mehr genutzt werden sollen. Informationen können so praktisch über einen längeren Zeitraum im Rahmen des Lernprozesses genutzt werden, was mit RNN so nicht möglich ist. Die Basis hierfür sind die vier grundsätzlichen Operationen *Forget*, *Store*, *Update* und *Output*. Für jede dieser vier Operationen sind unterschiedliche Funktionen der Gated Cells verantwortlich, was auf Abbildung 18 dargestellt ist. Die *Forget*-Funktion wird durch eine punktbezogene Multiplikation und einer Sigmoid-Funktion definiert, wodurch sich entweder ein Wert von 0 und ein Wert von 1 ergeben. Auf diese Weise kann gesteuert werden, welche Information im weiteren Lernprozess nicht mehr berücksichtigt werden sollen. Nach einem vergleichbaren Prinzip funktioniert die *Store*-Funktion der Gated Cells. Das Ergebnis dieser Funktion entscheidet darüber, welche Informationen im Rahmen des Lernprozesses weiter berücksichtigt werden sollen. Mittels der *Update*-Funktion wird entschieden, mit welchen Informationen der Zellzustand aktualisiert werden sollen. Wie auf Abbildung 18 zu erkennen ist, arbeitet die *Update*-Funktion mit den Ergebnissen der *Store* und *Forget*-Funktion und summiert die Ergebnisse zu dem neuen Zellzustand c_n . Die *Output*-Funktion ist für die Weitergabe von Informationen an die nachfolgenden Zellen verantwortlich und nutzt hierfür die gleichen Funktionsbausteine, wie die *Store*-Funktion (Graves 2012a; Hochreiter und Schmidhuber 1997).




Abbildung 18: Für jede der vier Operationen *Forget*, *Store*, *Update* und *Output* sind unterschiedliche Funktionen der der Gated Cells verantwortlich.

Validierung von Regressionsmodellen

Fester Bestandteil des Trainings von Regressionsmodellen ist die Validierung der Modelle. Hierfür wird der Fehler berechnet, der während der Anwendung des Regressionsmodells auftritt. Entscheidend für die Güte der Regressionsmodelle ist die richtige Wahl der Hyperparameter. Wie oben beschrieben, wird jedes Regressionsmodell über eigene Hyperparameter spezifiziert und definiert. Während des Trainings sollen die Hyperparameter so gewählt werden, dass der Fehler der Regressionsmodelle minimiert wird (Feurer und Hutter 2019; Runkler 2010).

Runkler (Runkler 2010) unterscheidet in diesem Kontext zwischen Generalisierungs-, Trainings- und Validierungsfehler. Der Generalisierungsfehler ist dabei der Fehler, den das Regressionsmodell produziert, wenn es auf ungesehene Daten angewendet wird. Dieser Fehler wird abgeschätzt, indem der Trainings- und Validierungsfehler berechnet wird. Hierzu wird zunächst die Gesamtdatenmenge in disjunkte Trainings- und Validierungsmengen unterteilt. Die Aussagekraft der Trainings- und Validierungsfehler korreliert in einem hohen Maße mit der Zusammensetzung der Trainings- und Validierungsmengen. Um einen möglichst großen Bias in den jeweiligen Datenmengen zu vermeiden, werden spezielle Verfahren zur Aufteilung angewendet. Alle der in Abbildung 19 dargestellten Verfahren unterteilen die vorhandenen Daten in Trainings- und Testdaten.




Abbildung 19: Unterschiedliche Verfahren zur Unterteilung der Gesamtdatenmenge in Trainings- und Testdaten (orange gefärbt).

Je nach Verfahren unterscheiden sich die Prinzipien der Unterteilung. Beim Leave-One-Out-Verfahren (LOO) wird jeder einzelne Datensatz iterativ betrachtet. Es wird immer genau ein einzelner Datensatz als Testdatensatz deklariert (Webb et al. 2011). Die übrigen Datensätze sind die Trainingsdaten, mit denen das Regressionsmodell zunächst trainiert wird. Bei diesem Verfahren wird so lange iteriert, bis jeder Datensatz genau einmal als Testdatensatz genutzt wurde. Nach jedem Training und Test wird der Fehler der Iteration berechnet. Am Ende wird der Mittelwert aller Einzelfehler gebildet. Der Vorteil von LOO liegt in der Einfachheit bei der Anwendung, was dieses Verfahren insbesondere für kleine Datenmengen und wenig komplexe Regressionsmodelle attraktiv macht. Grundsätzlich ist dieses Verfahren sehr rechenintensiv, was somit bei großen Datenmengen oder komplexen Modellen problematisch ist. Hinzu kommt, dass der durch LOO berechnete Fehler häufig zu optimistisch ist und das trainierte Regressionsmodell auf ungesehenen Daten schlechtere Ergebnisse liefert (Runkler 2010; Webb et al. 2011).

Bei der k-fachen Kreuzvalidierung (Abbildung 18 (b)) werden die Datensätze in k Bereiche Teilmengen unterteilt, wobei die Teilmengen in etwa gleich groß sind (Shultz et al. 2011). Die Teilmengen werden anschließend nach einem definierten Verhältnis (zum Beispiel 70:30 oder 80:20) in Trainings- und Testdaten unterteilt. Wie schon bei LOO wird bei der k-fachen Kreuzvalidierung iterativ unterschiedliche Trainings- und Testdatenkombinationen zum Training genutzt. Nach jeder Iteration wird der Fehler gemessen. Nach der letzten Iteration wird der mittlere Fehler aus allen Iterationen gebildet (Runkler 2010). Eine häufig genutzte Variante ist die 10-fache Kreuzvalidierung, die im Vergleich zu LOO potenziell bessere Ergebnisse liefern kann. Insbesondere im Hinblick auf die Laufzeitkomplexität, die bei LOO deutlich höher ist im Vergleich zur 10-fach Kreuzvalidierung (Fonseca-Delgado und Gomez-Gil 2013). Burman (Burman 1989) hat eine grundsätzliche

Eigenschaft der k -fachen Kreuzvalidierung gezeigt: Wenn k größer wird ist zu erwarten, dass der mittlere Fehler und die Standardabweichung der Fehler sinken wird.

Im Unterschied zur k -fachen Kreuzvalidierung wird bei der Monte Carlo Kreuzvalidierung (MCK) (Abbildung 18 (c)) der Datensatz randomisiert in k (in etwa) gleich große Teilmengen unterteilt. Das bedeutet, in jeder Iteration werden die Datensätze des Trainings- und Testdatensatzes randomisiert nach einem festgelegten Verhältnis unterteilt (Fonseca-Delgado und Gomez-Gil 2013; Picard und Cook 1984). Das anschließende iterative Trainingsverfahren entspricht dem Vorgehen der k -fachen Kreuzvalidierung. In der Praxis hat sich jedoch gezeigt, dass MCK besser geeignet ist, wenn es darum geht ein Regressionsmodell für eine Zeitreihenanalyse zu validieren (Fonseca-Delgado und Gomez-Gil 2013).

Bei der stratifizierten Kreuzvalidierung (Abbildung 18 (d)) wird die Datenmenge so in Teilmengen unterteilt, dass die ursprüngliche statistische Merkmalsverteilung in den Datenmengen erhalten bleibt (Martin et al. 2011). Das anschließende Verfahren zur Modellbildung und der Fehlerberechnung entspricht dem Vorgehen der k -fachen Kreuzvalidierung.

Hyperparameteroptimierung

Bevor ein Regressionsmodell trainiert werden kann, wird es über sogenannte Hyperparameter weiter spezifiziert. Hyperparameter definieren spezielle Eigenschaften der Algorithmen und bestimmen über die konkrete Funktionsweise (Kuhn und Johnson 2013; Yang und Shami 2020). Hyperparameter müssen für jeden Anwendungsfall und jeden Datensatz neu definiert werden (Feurer und Hutter 2019). Kohavi und John (Kohavi und John 1995) haben bereits 1995 in ihrer Studie gezeigt, dass Lernalgorithmen ein besseres Ergebnis liefern, wenn die Hyperparameter während des Trainings auf das betrachtete Datenset angepasst werden.

Das Problem der Hyperparameteroptimierung (HPO) ist folglich ein Optimierungsproblem, was durch Feuerer und Hutter (Feurer und Hutter 2019) wie folgt definiert wird:

$$\lambda^* = \min_{\lambda \in \Lambda} E_{(D_{train}, D_{valid}) \sim D} V(L, A_\lambda, D_{train}, D_{valid}) \quad (1)$$

Ziel ist es, für einen Algorithmus A das Set an konkreten Hyperparametern (A_λ) aus einer Menge an möglichen Hyperparametern ($\Lambda = \Lambda_1 \times \Lambda_2 \times \dots \times \Lambda_n$) zu identifizieren, bei dem der Fehler des Algorithmus auf Trainings- und Testdaten ($V(L, A_\lambda, D_{train}, D_{valid})$) möglichst gering ist (Feurer und Hutter 2019).

Eine manuelle Identifikation der Hyperparameter ist aufgrund der Komplexität der Algorithmen und der Größe des Suchraums potenzieller Hyperparameter nicht hinreichend gut möglich.

Insbesondere bei komplexen Modellen ist eine Evaluation sehr rechenintensiv (Feurer und Hutter 2019; Yang und Shami 2020). Feuerer und Hutter (Feurer und Hutter 2019) argumentieren darüber hinaus, dass nicht immer eindeutig ist, welche Hyperparameter für das vorliegende Problem zu optimieren sind.

In diesem Kontext hat sich das Forschungsgebiet des AutoML (Automated Machine Learning) entwickelt, bei dem eine automatisierte HPO im Vordergrund steht. Um die Komplexität zu reduzieren und die eingangs beschriebenen Herausforderungen im Rahmen des HPO zu adressieren, hat es sich etabliert Algorithmen zur Suche der Hyperparameter anzuwenden (Feurer und Hutter 2019; Yang und Shami 2020).

Grid und Random Search sind zwei beliebte Algorithmen für HPO, die aufgrund ihrer geringen Komplexität häufig Anwendung finden. Beide Algorithmen haben das Ziel, die (global) optimalen Ausprägungen von Hyperparametern zu finden. Beim Grid Search (Abbildung 20, linke Seite) wird dafür zunächst manuell der Parameterraum definiert. Anschließend werden alle möglichen Hyperparameterkombinationen innerhalb des Parameterraumes getestet (Feurer und Hutter 2019; Yang und Shami 2020). In Abhängigkeit davon, wie der Parameterraum definiert wurde besteht bei Grid Search die Gefahr in einem lokalen Optimum stecken zu bleiben. Hinzu kommt, dass Grid Search sehr rechenintensiv sein kann. Die Anzahl der Evaluierungen des Lernalgorithmus steigt exponentiell mit der Dimension des Hyperparameterraumes (Feurer und Hutter 2019).




Abbildung 20: Grid und Random Search zur Hyperparameteroptimierung.

Random Search (Abbildung 20, rechte Seite) funktioniert nach einem ähnlichen Prinzip, allerdings wird der Parameterraum - und damit auch die möglichen Parameterkombinationen – randomisiert gewählt (Feurer und Hutter 2019; Yang und Shami 2020). Im Gegensatz zum Grid Search werden

beim Random Search so lange zufällige Parameterkombinationen probiert, bis ein vorher definiertes Budget aufgebraucht ist. Somit wird bei jeder Iteration genau eine mögliche Kombination aller Parameter getestet (Feurer und Hutter 2019).

Random Search ist häufig ein guter Kompromiss zwischen Geschwindigkeit und Genauigkeit. Die Ergebnisse liefern folglich eine erste Grundlage zur HPO (Feurer und Hutter 2019).

Sowohl Grid als auch Random Search betrachten bei der Funktionsevaluierung die Parameter unabhängig voneinander. Im Gegensatz dazu ist die Bayes'sche Optimierung ein iteratives Vorgehen, bei dem der nächste Parameter auf Basis der vorher getesteten Parametersets gewählt wird (Feurer und Hutter 2019; Yang und Shami 2020). Eine zentrale Funktion hat hierbei ein sogenanntes *Surrogate Model*, welches ein einfaches Ersatzmodell ist. Als *Surrogate Model* werden häufig Gauß'sche Prozesse oder Random Forrests genutzt. Diese Verfahren haben den Vorteil, dass sie weniger komplex sind und die Evaluation der Parameter damit weniger rechenintensiv ist. Eine *Acquisition Function* bewertet anschließend die Güte des *Surrogate Models* und entscheidet somit, ob der betrachtete Parameter weiter berücksichtigt wird (Feurer und Hutter 2019). Im Vergleich zum Grid und Random Search sind bei der Bayes'schen Optimierung daher weniger Iterationen notwendig, um ein hinreichend gute Wahl der Hyperparameter zu treffen (Yang und Shami 2020).

Clustering-Algorithmen

Clustering-Algorithmen versuchen aus einer Menge von Daten Gruppen, sogenannte Cluster, zu bilden. In jedem Cluster befinden sich dabei Daten, die sich ähnlich sind. Daten unterschiedlicher Cluster sind sich folglich unähnlich. Cluster-Algorithmen kommen immer dann zum Einsatz, wenn sich am Beginn der Arbeit mit einem unbekanntem Datensatz schnell ein Überblick über die gesamte Datenmenge verschafft werden soll. Hierbei werden Gemeinsamkeiten der und Unterschiede der Daten herausgestellt (Shalev-Shwartz und Ben-David 2014). Cluster-Algorithmen können des Weiteren zur Generierung des Trainingsdatensatzes S eingesetzt werden, wenn beispielsweise die Klassenzugehörigkeit der Daten nicht vorhanden ist oder die Bestimmung dieser sehr aufwändig wäre (Runkler 2010). Somit lernen Clustering-Algorithmen also nicht überwacht. Dies bedingt auch das Problem, dass die gebildeten Cluster nur schwer zu evaluieren sind, da keine Grundwahrheit der Daten vorliegt (Shalev-Shwartz und Ben-David 2014). Im Allgemeinen unterscheidet man zwischen partitionierenden, hierarchischen und dichtebasierten Verfahren (Runkler 2010).

Ein sehr populärer Clustering-Algorithmus ist der k-Means Ansatz. K-Means versucht das Problem des Clusterings durch Optimierung zu lösen. Hierfür muss zu Beginn festgelegt werden, wie viele Cluster existieren, wobei jedes Cluster einen Mittelpunkt hat. Dieser Mittelpunkt wird

anschließend bei der Berechnung der Distanz zu anderen Datenpunkten genutzt, indem die quadratische Distanz zwischen einem Datenpunkt und dem Clustermittelpunkt berechnet wird. Von all diesen Distanzen wird anschließend der Mittelwert gebildet und die Abweichung der quadratischen Distanz zum Mittelwert für jeden Datenpunkt bestimmt. Je nach Abweichung und Clusteranzahl werden die Daten anschließend gruppiert (Shalev-Shwartz und Ben-David 2014).

Zum Extrahieren von typischen Schiffsbewegungsdaten, was Gegenstand dieser Arbeit ist, werden hauptsächlich Geodaten verwendet. Werden Cluster von Geodaten gebildet, so erkennt man, dass diese Cluster unterschiedliche Formen annehmen können, wie zum Beispiel elliptisch, linear oder länglich sein. Partitionierende Clustering-Algorithmen, wie zum Beispiel k-Means, sind nicht in der Lage diese Cluster herauszustellen. Um diese Probleme zu adressieren, wurde der DBSCAN (Density Based Spatial Clustering of Applications with Noise) entwickelt. Im Gegensatz zum k-Means Algorithmus, muss bei der Verwendung des DBSCAN-Algorithmus nicht die Zahl der Cluster bekannt sein. Es muss lediglich die minimale Anzahl an Punkten (*minPts*) angegeben werden, die innerhalb eines Abstandes ϵ mindestens vorhanden sein müssen, damit sie zu einem Cluster gehören (Ester et al. 1996).

Der Unterschied in den Ergebnissen, der nach der Anwendung beider Algorithmen auf die gleichen Geodaten entsteht, wird bei der Betrachtung von Abbildung 21 deutlich.




Abbildung 21: Das Ergebnis nach der Anwendung des DBSCAN und k-Means Algorithmus auf das gleiche Datenset.

Auf der linken Seite sind die zwei durch den DBSCAN herausgestellte Cluster illustriert. Die unterschiedliche Farbe zeigt die Zugehörigkeit zu einem Cluster. Auf der rechten Seite ist das Ergebnis des k-Means Algorithmus auf Basis der gleichen spatialen Daten zu sehen. Im Vergleich zu DBSCAN stellt k-Means ebenfalls zwei Cluster heraus (orange und grün). Allerdings existieren auf der rechten Seite auch graue Datenpunkte, die die mittlere quadratische Abweichung überschreiten. Interpretiert man die Datenpunkte beispielhaft als Bewegungsdaten von Schiffen, so würde das Ergebnis des k-Means Algorithmus nicht den vollständigen Raum aufdecken können, in denen sich die Schiffe, die zu den grünen Datenpunkten gehören, bewegen.

Interpretation, Evaluierung und Anwendung

Aus dem Data Mining Schritt des KDD-Prozesses ergeben sich Muster, die anschließend interpretiert, evaluiert werden müssen. Fayyad et al. (Fayyad, Piatetsky-Shapiro und Smyth 1996) weisen darauf hin, dass die in diesem Schritt gesammelten Erkenntnisse es notwendig machen zu einem der vorherigen Schritte zurückzuspringen und entsprechende Anpassungen im jeweiligen Schritt vorzunehmen. Zu beachten ist hier, dass der KDD-Prozess somit zu einem iterativen Prozess wird, der mehrfach durchlaufen werden kann bis ein zufriedenstellendes Ergebnis existiert. Zum Vorgehen in diesem Schritt empfehlen Fayyad et al. (Fayyad, Piatetsky-Shapiro und Smyth 1996) sich die extrahierten Muster mit einer entsprechenden Methode zu visualisieren und so zu interpretieren. Runkler (Runkler 2010) präsentiert für die Darstellung hochdimensionaler Daten entsprechende Projektionsmethoden, sodass diese dargestellt werden können.

Nach der Interpretation und Evaluation der Muster ist der letzte Schritt des KDD-Prozesses die Anwendung jener Muster. Dies geschieht in der Regel so, dass die Muster und das extrahierte Wissen in andere Anwendungen übertragen werden und dort zur Lösung der gleichen Probleme genutzt werden können. Daneben kann es sich im Rahmen der Anwendung auch um eine einfache Dokumentation des generierten Wissens sein. Eine solche Dokumentation kann dann den entsprechenden Stakeholdern in aufbereiteter Form zur Verfügung gestellt werden (Fayyad, Piatetsky-Shapiro und Smyth 1996).

3 Stand der Wissenschaft und Technik

Die Prädiktion von zukünftigem Verhalten von sich bewegenden Fahrzeugen im Sinne der Kollisionsvermeidung ist eine domänenübergreifende Fragestellung. Sowohl im Automotive-Bereich als auch in der Luftfahrt hat sich bereits ein breites Forschungsgebiet zu diesem Thema entwickelt. Aus diesem Grund werden im Folgenden relevante Arbeiten zur Prädiktion von Fahrzeugen auf der Straße und in der Luft beschrieben. Ziel dieses Abschnitts ist die Identifizierung von Lösungsansätzen, die für das Problem der Verhaltensprädiktion von Schiffen verwendet werden können.

Im Anschluss daran werden existierende Forschungsarbeiten zur maritimen Verhaltensprädiktion beschrieben. Aus den präsentierten Arbeiten wird ein gemeinsames Vorgehensmodell zur Verhaltensprädiktion von Schiffen abgeleitet. Dieses Vorgehensmodell soll im Rahmen der Methodenkonzeption als Grundlage genutzt werden. Der Überblick über den Stand der Wissenschaft und Technik wird mit einer kritischen Würdigung der präsentierten Ansätze geschlossen, in deren Rahmen ein Abgleich mit den in Abschnitt 1.3 definierten Anforderungen stattfindet.

3.1 Verhaltensprädiktion im Automotive-Bereich

Durch die Bestrebungen der Automobilindustrie zur Entwicklung autonomer und hochautomatisierter Fahrzeuge entstehen neue technologische Herausforderungen, die einen maßgeblichen Einfluss auf den sicheren Betrieb solcher Fahrzeuge haben. Insbesondere Fragestellungen hinsichtlich der automatisierten Detektion von gefährlichen Verkehrssituationen bekommen eine große Bedeutung. In der Literatur ist dieses Problem dem Forschungsfeld der Verhaltensprädiktion zugeordnet (Hermes et al. 2010; 2009; Lefèvre, Vasquez und Laugier 2014; Tan, Flannagan und Elliott 2018; Wu et al. 2012).

Lefèvre et al. (Lefèvre, Vasquez und Laugier 2014) geben in ihrer Arbeit einen Überblick über den Forschungsstand der Verhaltensprädiktion von Fahrzeugen im Automotive-Bereich. Folgt man ihrer Klassifikation, so sind die existierenden Arbeiten in drei Kategorien einzuteilen, die sich hinsichtlich des verwendeten Prädiktionsmodells unterscheiden lassen:

- Physikalische Bewegungsmodelle
- Manöverbasierte Bewegungsmodelle
- Interaktionsbasierte Bewegungsmodelle

3.1.1 Physikalische Bewegungsmodelle

Physikalische Bewegungsmodelle sind die am häufigsten verwendeten Prädiktionsansätze, bei denen dynamische und kinematische Fahrzeugmodelle genutzt werden. Diese Modelle werden je nach Ansatz durch weitere Fahrzeugeigenschaften und Steuerbefehle, wie zum Beispiel Lenkbefehle, erweitert. Dynamische Fahrzeugmodelle beschreiben die Bewegung der Fahrzeuge durch den Einfluss von Kräften, wie zum Beispiel Reifenkräfte oder den Neigungswinkel der Straße. Kinematische Fahrzeugmodelle nutzen eine geometrische Beschreibung der Fahrzeugbewegung, wobei Bewegungsparameter des Fahrzeugs (Position, Geschwindigkeit, Beschleunigung u.a.) mit äußeren Einflussparametern in einen mathematischen Zusammenhang gebracht werden. Kinematische Fahrzeugmodelle werden in der Literatur häufiger verwendet als dynamische, da sie im Allgemeinen einfacher sind und für eine kurzfristige Prädiktion ausreichen (Lefèvre, Vasquez und Laugier 2014).

Laut Lefèvre et al. (Lefèvre, Vasquez und Laugier 2014) unterscheiden sich Ansätze zur Verhaltensprädiktion von Fahrzeugen unter der Verwendung von physikalischen Bewegungsmodellen darin, wie sie die Unsicherheiten in der Bewegung der Fahrzeuge modellieren. Die einfachsten Ansätze hierfür sind jene, die annehmen, dass das aktuelle Wissen über den Zustand des eigenen und der anderen Fahrzeuge vollständig ist und das verwendete Bewegungsmodell die potenzielle Bewegung der Fahrzeuge perfekt modellieren können. Solche Ansätze präzisieren jeweils eine Trajektorie für ein Fahrzeug, was bezogen auf die Laufzeit vorteilhaft ist (Brannstrom, Coelingh und Sjoberg 2010; Lefèvre, Vasquez und Laugier 2014; Miller und Qingfeng Huang 2002).

Im Gegensatz dazu existieren Ansätze, die die Unsicherheit bezogen auf den Fahrzeugzustand und der Bewegung mittels einer Gauß'schen Normalverteilung modellieren. Ein populärer Ansatz in der Literatur ist die Verwendung des Kalman Filters, mit dem der Fahrzeugzustand rekursiv durch Sensormessungen approximiert wird. Solche Ansätze präzisieren das zukünftige Fahrzeugverhalten in zwei Schritten: Zu Beginn wird der angenommene Fahrzeugzustand zur Zeit t als Input für das physikalische Bewegungsmodell genutzt. Mittels des Bewegungsmodells wird der Zustand zur Zeit $t+1$ präzisiert, was als Gauß'sche Normalverteilung modelliert wird. Anschließend wird der durch die vorhandene Sensorik wahrgenommene Fahrzeugzustand zur Zeit $t+1$ mit der Prädiktion zum gleichen Zeitpunkt kombiniert und ebenfalls als Gauß'sche Normalverteilung modelliert. Dieses Vorgehen wird iterativ wiederholt. Nach jedem Schritt wird das Ergebnis mit den vorherigen zusammengefasst. Am Ende werden alle vorhergesagten Teiltrajektorien zu einer Trajektorie zusammengefasst, die eine Beschreibung der Unsicherheit zu jeden Zeitabschnitt enthält (Ammoun und Nashashibi 2009; Batz, Watson und Beyerer 2009; Lefèvre, Vasquez und Laugier 2014; Tan und Huang 2006)

Die Modellierung von Unsicherheiten im Wissen über den Zustand und die mögliche Bewegung von Fahrzeugen mit der Gauß'schen Normalverteilung ist allerdings nur dann möglich, wenn Annahmen über die jeweiligen Parameter getroffen werden können beziehungsweise Sensorik zur Messung vorhanden ist. Für Fälle, in denen Messungen nicht möglich sind und keine Annahmen über den Zustand getroffen werden können, wird in der Literatur die Monte-Carlo-Simulation genutzt. Die fehlenden Parameter zur Prädiktion mit dem physikalischen Bewegungsmodell werden hierfür in einem Zufallsexperiment gezogen, womit der jeweilige Fahrzeugzustand approximiert werden kann. Anschließend kann mit diesen Parameter die zukünftige Trajektorie des Fahrzeugs prädiziert werden (Althoff und Mergel 2011; Broadhurst, Baker und Kanade 2005; Eidehall und Petersson 2008; Lefèvre, Vasquez und Laugier 2014).

3.1.2 Manöverbasierte Bewegungsmodelle

Manöverbasierte Bewegungsmodelle funktionieren unter der Annahme, dass die ausgeführten Manöver unabhängig von denen anderer Verkehrsteilnehmer ausgeführt werden. Generell basieren die Ansätze auf einer frühestmöglichen Identifizierung der geplanten Manöver. Die Vorhersage des zukünftigen Verhaltens der Fahrzeuge geschieht anschließend unter der Prämisse, dass sich die Fahrzeuge an das identifizierte Manöver halten werden. Existierende Arbeiten in diesem Kontext lassen sich nach Lefèvre et al. (Lefèvre, Vasquez und Laugier 2014) in jene unterteilen, die aus historischen beziehungsweise prototypischen Trajektorien entsprechende Prädiktionsmodelle extrahieren und in jene, die geplante Manöver vorhersagen.

Ansätze, die zur Prädiktion prototypische Trajektorien nutzen, basieren auf historischen Fahrzeugbewegungsdaten. In einer Trainingsphase werden typische Bewegungsmuster aus historischen Fahrzeugbewegungsdaten extrahiert. Ähnliche Muster werden jeweils in Cluster zusammengefasst. Laut Lefèvre et al. (Lefèvre, Vasquez und Laugier 2014) existieren im Allgemeinen drei Möglichkeiten zur anschließenden Repräsentation der extrahierten Bewegungsmuster. Zum einen existiert die Möglichkeit, alle Bewegungsmuster eines Clusters zusammenzufassen und stochastisch zu beschreiben. Auf der anderen Seite können die Bewegungsmuster weiter extrahiert werden und durch einen Graphen beschrieben werden. Die dritte Möglichkeit nach Lefèvre et al. (Lefèvre, Vasquez und Laugier 2014) ist die Abbildung typischer Bewegungsmuster als Gauß'scher Prozess. Zur Prädiktion nutzen manöverbasierte Bewegungsmodelle die extrahierten Bewegungsmuster und vergleichen sie mit dem zum Prädiktionszeitpunkt bisherigen und bekannten Verlauf der Trajektorie des jeweiligen Fahrzeugs und den extrahierten Bewegungsmustern. Zum Vergleich der Trajektorien wird je nach Prädiktionsansatz ein unterschiedliches Maß verwendet (Buzan, Sclaroff und Kollios 2004; Hermes et al. 2009; Lefèvre, Vasquez und Laugier 2014; Weiming Hu et al. 2006).

Eine andere Möglichkeit die zukünftige Bewegung von Fahrzeugen zu präzisieren ist die Vorhersage von Manövern, die die Fahrer als nächstes ausführen werden. Anschließend wird unter der Verwendung eines Bewegungsmodells die Trajektorie vorhergesagt, die das Fahrzeug unter Berücksichtigung des präzisierten Manövers nehmen wird (Lefèvre, Vasquez und Laugier 2014). Als mögliche Manöver, die in der Literatur betrachtet werden, nennen Lefèvre et al. (Lefèvre, Vasquez und Laugier 2014) unter anderem das Halten an einem Stoppschild oder das Folgen eines anderen Fahrzeugs (Greene et al. 2011; Kumar et al. 2013; Lefèvre, Vasquez und Laugier 2014; Laugier et al. 2011).

3.1.3 Interaktionsbasierte Bewegungsmodelle

Im Vergleich zu den beiden vorher genannten Bewegungsmodellen existieren nur wenige Ansätze, die interaktionsbasierte Bewegungsmodelle zur Verhaltensprädiktion von Fahrzeugen nutzen. Solche Arbeiten funktionieren unter der Prämisse, dass die Fahrzeugbewegungen besser antizipiert werden, wenn die Beeinflussung anderer Fahrzeuge auf die Bewegung berücksichtigt wird. Dies gibt einen besseren Gesamtüberblick über eine Verkehrssituation und somit sind solche Ansätze besser zur Risiko- und Kollisionsbewertung geeignet (Lefèvre, Vasquez und Laugier 2014).

Die in der Literatur existierenden Ansätze lassen sich hinsichtlich ihrer verwendeten Prädiktionsmethode unterscheiden. Analog zum vorherigen Abschnitt existieren Arbeiten, die auf Basis prototypischer Trajektorien das zukünftige Verhalten präzisieren. Die Beeinflussung anderer Fahrzeuge auf das zukünftige Verhalten wird dann allerdings nicht in der Trainingsphase berücksichtigt sondern bei der Auswahl ähnlicher, prototypischer Trajektorien (Käfer et al. 2010; Lawitzky et al. 2013; Lefèvre, Vasquez und Laugier 2014).

Im Gegensatz zu Ansätzen, die die Beeinflussung anderer Fahrzeuge bei der Prädiktion mittels prototypischer Trajektorien nutzen, existieren Arbeiten die Dynamic Bayesian Networks nutzen. Hierbei werden überwiegend Hidden Markov Models (HMM) genutzt, die ein stochastisches Modell zur Vorhersage von Zustandsänderungen (Brand, Oliver und Pentland 1997; Lefèvre, Laugier und Ibañez-Guzmán 2013; Lefèvre, Vasquez und Laugier 2014; Oliver und Pentland 2000; Russell, Norvig und Davis 2010) anwenden.

3.2 Verhaltensprädiktion in der Luftfahrt

Ein elementarer Bestandteil in der Luftfahrt ist die Flugplanung, beziehungsweise die Routenplanung. Unter Berücksichtigung der Luftfahrtstraßen, etwaiger Beschränkungen im Luftraum, sowie den meteorologischen Gegebenheiten wird eine Route geplant, die aus Wegpunkten besteht. In der Praxis ist allerdings zu beobachten, dass die Luftfahrzeuge von der geplanten Route abweichen.

Der Grund hierfür ist ein Gesamtkonstrukt aus sich ändernden meteorologischen Bedingungen, temporären Luftraumsperrungen sowie die Verkehrslage (Zeng et al. 2022).

Um dennoch eine effiziente Organisation und Abwicklung des Luftverkehrs zu ermöglichen, werden in der Luftraumüberwachung Methoden zur Bewegungsprädiktion von Luftfahrzeugen genutzt. Ziel der Methoden ist es, die zukünftige Trajektorie eines Luftfahrzeugs vorherzusagen. Die die FAA (Federal Aviation Administration) und EUROCONTROL (Europäische Organisation zur Sicherung der Luftfahrt) haben gemeinsam definiert, dass eine Trajektorie aus einer Sequenz von Wegpunkten besteht, die wiederum durch einen vierdimensionalen Vektor beschrieben werden. Dieser Vektor enthält Informationen zum Breiten- und Längengrad, der Geschwindigkeit, Höhe und Zeit des Luftfahrzeugs (FAA/EUROCONTROL 2010).

Um eine kohärente Funktionsweise der Prädiktionsmethoden zu gewährleisten, existiert ein Framework, welches das allgemeine Vorgehen zur Trajektorienprädiktion in der Luftfahrt definiert. Das Framework ist ein gemeinsames Werk der FAA und EUROCONTROL und auf Abbildung 22 dargestellt.

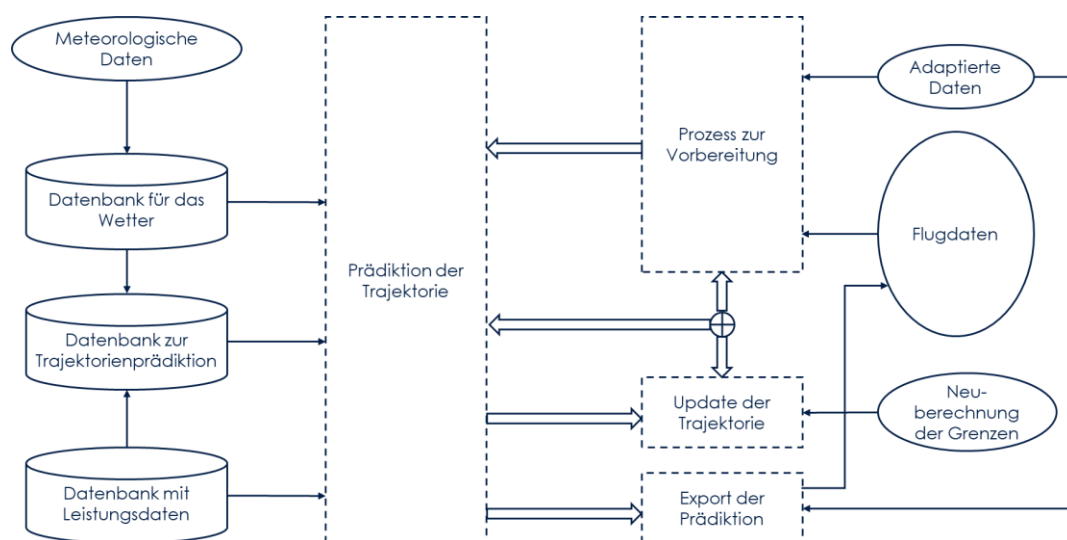


Abbildung 22: Allgemeines Vorgehen zur Trajektorienprädiktion in der Luftfahrt, adaptiert von (FAA/EUROCONTROL 2010).

Dem Framework ist zu entnehmen, dass sowohl der eigentliche Prädiktionsprozess als auch die zu verwendeten Daten definiert sind. Die Prädiktion beginnt mit dem Prozess zur Vorbereitung, bei dem aktuelle Flugdaten verwendet werden. Anschließend findet die eigentliche Trajektorienprädiktion statt, die neben den vorbereiteten Flugdaten auch die meteorologischen Daten und für das Luftfahrzeug spezifische Leistungsdaten verwendet. Das Prädiktionsergebnis wird zum einen als Basis für eine fortführende Prädiktion verwendet, sodass das Ergebnis in den Vorbereitungsprozess mit einfließt. Zum anderen wird das Ergebnis exportiert und steht somit als finale Vorhersage zur Verfügung (FAA/EUROCONTROL 2010).

Die eigentlichen Prädiktionsmethoden sind Gegenstand eines entsprechenden Forschungsgebiets. Zeng et al. (Zeng et al. 2022) unterteilen in ihrem Literaturreview die existierenden Arbeiten entsprechend ihres Prädiktionshorizonts und in Bezug auf die eingesetzten Methoden.

Kurzfristige Prädiktionsmethoden fokussieren sich demnach auf einige wenige Minuten. Weil der Prädiktionshorizont so kurz ist, werden neben Flugdaten keine weiteren Informationen, wie zum Beispiel Wetterinformationen, berücksichtigt. Aus dem gleichen Grund ist es allerdings notwendig konkrete Annahmen zur Prädiktion zu treffen. Beispielsweise werden für steigende oder sinkende Luftfahrzeuge im Rahmen der kurzfristigen Prädiktion konstante Steig- respektive Sinkraten vorausgesetzt. Methoden mit einem kurzfristigen Prädiktionszeitraum werden zur Kollisionsvermeidung eingesetzt, indem potenzielle Konfliktsituationen zwischen Luftfahrzeugen auf Basis der prädizierten Trajektorien identifiziert werden.

Von einer langfristigen Trajektorienprädiktion der Luftfahrzeuge spricht man nach Zeng et al. (Zeng et al. 2022) dagegen, wenn der Prädiktionszeitraum zehn Minuten oder mehr abdeckt. Aufgrund des größeren Zeitraums müssen zusätzliche Informationen, wie zum Beispiel das Wetter, berücksichtigt werden, weil diese Gegebenheiten einen direkten Einfluss auf die Bewegung des Luftfahrzeuges haben. Eine wichtige Eigenschaft langfristiger Prädiktionsmethoden ist die Tatsache, dass die Genauigkeit der Prädiktion mit einem größer werdenden Prädiktionszeitraum abnimmt. Im Gegensatz zu kurzfristigen Prädiktionsmethoden werden langfristige Methoden nicht direkt zur unmittelbaren Kollisionsvermeidung eingesetzt. Es hat sich etabliert, diese Methoden im Rahmen des Verkehrsmanagements einzusetzen, um den Verkehrsfluss antizipieren und optimieren zu können.

Im Folgenden wird ein Überblick über die eingesetzten Methoden zur Trajektorienprädiktion gegeben. Die Unterteilung orientiert sich dabei am Vorschlag von Zeng et al. (Zeng et al. 2022).

3.2.1 Zustandsraumbeschreibung

Ein verbreiteter Ansatz zur Prädiktion ist die Abschätzung des zukünftigen Zustands des Luftfahrzeugs. Die grundlegende Idee hinter diesem Ansatz ist die mathematische Modellierung der Trajektorie über den Zustand des physikalischen Systems (Luftfahrzeug), welches sich auf der Trajektorie bewegen wird. Ansätze in diesem Kontext basieren auf den Funktionsprinzipien der Regelungstechnik, was bedeutet, dass Input, Output und eine Menge an Variablen zur Verfügung stehen, um den Zustand des Systems modellieren, beziehungsweise die Änderungen am physikalischen System beschreiben zu können. Typischerweise wird das physikalische System durch ein komplexes Gleichungssystem repräsentiert, welches die bei der Prädiktion relevanten Zusammenhänge abbilden können. Um auf Basis dieses Gleichungssystem zukünftiges Verhalten zu prädizieren, wird häufig

der Kalman Filter angewendet. Der Kalman Filter ist ein mathematisches Verfahren, mit dem zukünftige Systemzustände basierend auf zeitdiskreten Messwerten abgeschätzt werden können. Dabei ist es möglich, den Kalman Filter iterativ anzuwenden. Das Verfahren geht auf den Mathematiker Rudolf E. Kalman zurück (Marchthaler und Dingler 2017).

In der Luftfahrt nutzt man Messpunkte zur Position, Geschwindigkeit, Höhe, Steig- und Sinkrate, um mittels des Kalman Filters das zukünftige Verhalten zu berechnen (Chatterji 1999; Avanzini 2004). Lympelopoulos und Lygeros (Lympelopoulos und Lygeros 2010) schlagen vor, die zukünftige Zustandsänderungen der Luftfahrzeuge stochastisch abzuschätzen. In ihrer Arbeit untersuchen sie verschiedene sequenzielle Monte Carlo Methoden und arbeiten eine effizientere Variante heraus, die sie zur Prädiktion von Luftfahrzeugen anwenden. Dabei fokussieren sie sich zunächst auf Luftfahrzeuge, die konstant auf einer Höhe fliegen (Lympelopoulos und Lygeros 2010).

(Ayhan und Samet 2016; Yi Lin et al. 2019; Lin, Zhang und Liu 2018) interpretieren die Bewegung von Luftfahrzeugen beziehungsweise die Vorhersage als Markov Prozess. Charakteristisch für einen Markov Prozess ist die Annahme, dass der zukünftige Zustand des Systems einzig vom aktuellen Zustand abhängt und nicht von den vorherigen Zuständen (Stroock 2014).

Der Bewegung von Luftfahrzeugen liegen komplexe physikalische Vorgänge zugrunde, deren Berücksichtigung bei der Verhaltensprädiktion die Prädiktionsgüte verbessern kann. Hierfür hat sich die Verhaltensmodellierung unter der Verwendung multipler Modelle etabliert. Das Problem wird dabei als *Stochastic Linear Hybrid System* (SLHS) interpretiert, bei dem die Flugbewegungen in unterschiedliche Flugphasen eingeteilt werden. Jede Flugphase wird als ein simples Zustandssystem modelliert. Im Allgemeinen hat sich gezeigt, dass die Lösung von SLHS sehr rechenintensiv ist (Zeng et al. 2022).

Der IMM-Algorithmus (Interacting Multiple Model) hat gezeigt, dass die Lösung eines SLHS in diesem Zusammenhang in einer angemessenen Laufzeit möglich ist. Hierfür hat es sich in der Literatur etabliert, die Übergänge zwischen den jeweiligen Flugphasen mit Hilfe einer Wahrscheinlichkeitsmatrix zu prädizieren. Exemplarisch kann hierfür die Arbeit von Song, Cheng und Mu (Song, Cheng und Mu 2012) genannt werden. Ihr Lösungsansatz sieht vor, typische Flugbahnen durch die Analyse historischer Bahnen zu extrahieren. Die so erhaltenen Flugbahnen werden zum Approximieren der Übergangswahrscheinlichkeit zwischen den einzelnen Flugphasen genutzt, wodurch das Verhalten der Luftfahrzeuge prädiziert wird (Song, Cheng und Mu 2012). Andere Ansätze modellieren die Gesamtheit aller Flugphasen als Markov-Prozess und bestimmen zur Verhaltensprädiktion die Übergangswahrscheinlichkeiten zwischen den jeweiligen Phasen (Bar-Shalom, Li und Kirubarajan 2001; Seah und Hwang 2007).

3.2.2 Kinematische Modelle

Um Verhalten von Luftfahrzeugen mittels kinematischer Modelle präzisieren zu können werden Gleichungssysteme erstellt, mit denen der Zusammenhang zwischen den Eigenschaften des Luftfahrzeugs (z.B. Kurs, Geschwindigkeit und Position), den vorherrschenden meteorologischen Bedingungen sowie den allgemeinen Absichten des Luftfahrzeugs (Steigrate oder geplante Geschwindigkeit) zu modellieren. Ein Ansatz zur Aufstellung und Lösung solcher Gleichungssysteme ist das Point Mass Model (PMM), welches physikalische Kräfte und Luftfahrzeugseigenschaften in einen Zusammenhang bringt und zur Verhaltensprädiktion nutzt. Ergebnis dieser Gleichungssysteme sind sowohl einfache Bewegungsmodelle als auch komplexe, die sechs Freiheitsgrade berücksichtigen (Weitz 2015; Schuster 2015; Fukuda, Shirakawa und Senoguchi 2010; Zeng et al. 2022).

Aufgrund der hohen physikalischen Komplexität hat es sich in diesem Zusammenhang etabliert, spezifische Leistungsdaten der Luftfahrzeuge aus entsprechenden Datenbanken zu nutzen (siehe Abbildung 22). Hierfür hat sich die *Base of Aircraft Data* (BADA) als zentrale Datenbank etabliert. Dies ermöglicht beispielsweise die Abstraktion des für ein Luftfahrzeug spezifischen Luftwiderstand und reduziert die Komplexität der Gleichungssysteme (Zeng et al. 2022).

Um die zukünftigen Absichten eines Luftfahrzeugs zu modellieren und bei der Prädiktion zu berücksichtigen, wurde die formale Modellierungssprache *Flight Script* (FS) entwickelt. Ein FS beschreibt dabei die Art und Weise, wie ein menschlicher Pilot beziehungsweise ein Flight Management System (FMS) das Flugzeug steuern würden (Lopez Leones 2008). Um ein FS zu erstellen, sind Flugplaninformationen, An- und Abflugrouten sowie Wissen über spezifische Prozeduren von Fluggesellschaften notwendig (Porretta et al. 2008; Schuster, Ochieng und Porretta 2010; Schuster, Porretta und Ochieng 2012).

3.2.3 Machine Learning

Der Einsatz von Machine Learning Methoden zur Prädiktion von zukünftigen Flugbahnen basiert auf der Analyse historischer Flugbahnen. Das Ziel ist, typische Bewegungsmuster zwischen einem Start- und Zielflughafen zu extrahieren. Anschließend werden diese Bewegungsmuster mit der aktuellen Bewegung eines Luftfahrzeugs abgeglichen und die zukünftige Bewegung vorhergesagt. Eine Eigenheit in der Luftfahrt ist, dass der Luftraum in Luftstraßen unterteilt ist, die wiederum aus Wegpunkten bestehen. Nach bewegen sich die Luftfahrzeuge zwischen den Wegpunkten, wodurch sich typische Bewegungsmuster ergeben.

Lineare und polynomiale Regressionsmodelle werden genutzt, um auf Basis der Parameter Geschwindigkeit, Position, Höhe und Kurs die zukünftige Bewegung zu präzisieren. Hierfür werden historische Daten genutzt, um einen entsprechenden Zusammenhang zwischen gegebenen Para-

metern und historischen durch lineare oder polynomiale Regressionsmodelle herzustellen. Die zukünftige Bewegung der Luftfahrzeuge wird durch Regressionsmodelle folglich durch die gerade erwähnten Parameter beschrieben (Zeng et al. 2022).

Die nächste Komplexitätsstufe bilden neuronale Netze. Es hat sich in der Literatur etabliert die neuronalen Netze so aufzubauen, dass sie die für das Verhalten relevanten Parameter als Inputvektoren nutzen können. Da die Bewegung der Luftfahrzeuge in einem hohen Maße von externen Gegebenheiten, wie zum Beispiel dem Wetter, abhängen, werden neben den klassischen Parametern (beispielsweise Kurs, Position, Höhe) auch meteorologische Gegebenheiten (beispielsweise Windrichtung und -geschwindigkeit) mitberücksichtigt (Zeng et al. 2022; Pang und Liu 2020a; Tang, Chen und Zhang 2015). Für das Training der neuronalen Netze und der anschließenden Prädiktion ergibt sich somit ein komplexes Konstrukt an Parametern. Je nach Ansatz werden auf Basis dieser Parameter entweder die verbleibende Flugzeit, eine einzelne Position in der Zukunft oder ganze Flugbahnen prädiziert (Zeng et al. 2022). Je nach Interpretation des Prädiktionsproblems unterscheidet sich das eingesetzte neuronale Netz. LSTM-Netze kommen zum Einsatz, wenn eine Flugbahn als Zeitreihe interpretiert wird. Für diesen Lösungsansatz wird davon ausgegangen, dass eine beobachtete und unvollständige Flugbahn einen Aufschluss darüber geben kann, wie die nachfolgende Flugbahn aussieht (Zeng et al. 2022; Shi et al. 2018; Xu et al. 2021; Zeng et al. 2020). Daneben finden sich Ansätze, die die Wahrscheinlichkeit für eine zukünftige Flugbahn vorhersagen, beispielsweise unter der Verwendung eines Bayes'schen neuronalen Netzes (Pang und Liu 2020b).

Neben neuronalen Netzen sind Ansätze verbreitet, die die Nutzung von Clustering-Algorithmen vorschlagen. Ziel dieser Ansätze ist es zumeist, ähnliche historische Flugbahnen zu clustern, beispielsweise mit dem k-means (Tang, Chen und Zhang 2015) Algorithmus oder dem DBSCAN-Algorithmus (Wang, Liang und Delhaye 2017) und somit ein Ähnlichkeitsmaß zu entwickeln (Zeng et al. 2022). Zur Prädiktion werden die beobachteten Flugbahnen als Basis des entwickelten Ähnlichkeitsmaßes mit den extrahierten und geclusterten Flugbahnen abgeglichen und der ähnlichsten Flugbahn zugeordnet. Es gilt dann die Annahme, dass das Luftfahrzeug am wahrscheinlichsten der ähnlichsten Flugbahn folgen wird (Zeng et al. 2022; Tang, Chen und Zhang 2015; Wang, Liang und Delhaye 2017; Fernandez et al. 2017; Verdonk Gallego et al. 2018).

3.3 Analyse maritimer Verkehrsdaten

Durch die verpflichtende Nutzung von AIS in der Berufsschifffahrt (International Maritime Organization 1974) ist es möglich geworden, Schiffsbewegungsdaten mit entsprechender Sensorik aufzuzeichnen. Hieraus haben sich Geschäftsmodelle entwickelt, bei denen die AIS-Nachrichten zum Tracking angezeigt werden können und in Datenbanken gespeichert werden. Als bekannteste Vertreter sind MarineTraffic¹, VesselTracker², VesselFinder³ oder Fleetmon⁴ zu nennen. Bei allen Anbietern ist es möglich, den aktuellen Schiffsverkehr auf einer Karte zu verfolgen und Detailinformationen zur jeweiligen Fahrt mit einem Klick auf die Schiffssymbole abzurufen. Der Zugriff auf historische Daten ist allerdings beschränkt und kostenpflichtig, da die jeweiligen Unternehmen die AIS-Daten verarbeiten und daraus neues Wissen generieren. Ein Beispiel hierfür ist MarineTraffic, dort ist eine HeatMap⁵ verfügbar, die die Frequentierung der Schifffahrtsrouten darstellt.

Es existiert darüber hinaus auch eine Spezialisierung dieses Geschäftsmodells mit dem Fokus auf Reedereien. Ein Beispiel ist hier der NavTracker von Navtor⁶. Eine Reederei kann spezielle Boxen auf ihren Schiffen installieren, die relevanten Daten der Reise über das eigene Schiffe, sowie die empfangenen AIS-Daten während der Reise, aufzeichnet und an eine Landstation schickt. Auf dieser können Reeder ihre Flotte weltweit verfolgen.

Darüber hinaus haben sich die zwei Forschungsgebiete der Schiffsverhaltensprädiktion und der Detektion von anomalem Schiffsverhalten (im Folgenden: Anomaliedetektion) etabliert. Die Arbeiten aus dem Bereich der Verhaltensprädiktion haben dabei zwei grundsätzliche Anwendungsfelder. Zum einen erlaubt eine Prädiktion von Schiffsverhalten eine präzise Vorhersage der Ankunftszeit, was für das Funktionieren von effektiven und effizienten moderner Logistikketten verantwortlich ist (Dobrkovic et al. 2016). Zum anderen ist die Verhaltensprädiktion, wie eingangs beschrieben, ein wichtiges Hilfsmittel zur proaktiven Kollisionsvermeidung (Berking und Brauner 2010; Steidel und Hahn 2019).

Bei der Anomaliedetektion geht es darum, automatisiert anomales Schiffsverhalten zu identifizieren. Die Idee dahinter ist, dass anomales Schiffsverhalten auf verbotenes und potenziell gefährliches Schiffsverhalten hindeutet. Einsatzgebiete sind die Seeraumüberwachung, das Detektieren von illegaler Fischerei und der Schutz der eigenen Hoheitsgewässer und kritischer Infrastruktur, wie beispielsweise Hafenanlagen (Riveiro, Pallotta und Vespe 2018).

¹ <https://www.marinetraffic.com/> (Letzter Abruf 24.06.2023)

² <https://www.vesseltracker.com/de> (Letzter Abruf 24.06.2023)

³ <https://www.vesselfinder.com/de> (Letzter Abruf 24.06.2023)

⁴ <https://www.fleetmon.com/> (Letzter Abruf 24.06.2023)

⁵ <https://www.marinetraffic.com/en/online-services/single-services/advanced-density-map> (Letzter Abruf 24.06.2023)

⁶ <https://www.navtor.com/navtracker.html> (Letzter Abruf 24.06.2023)

Beide Forschungsgebiete haben zwar unterschiedliche Anwendungsfälle, teilen aber einen gemeinsamen Ansatz: Die grundlegende Idee beider Forschungsgebiete ist die Nutzung von Verhaltensnormalmodellen, die mit Hilfe von Data Mining Techniken aus historischen AIS-Daten generiert werden (Cazzanti und Pallotta 2015; Riveiro, Pallotta und Vespe 2018).

Im Folgenden wird zunächst ein Überblick über ein Tool der IALA gegeben, mit dem historische AIS-Daten zur Bestimmung des Kollisionsrisiko ausgewertet werden können. Anschließend werden relevante Forschungsarbeiten aus den Bereichen der Anomaliedetektion und der Verhaltensprädiktion beschrieben.

3.3.1 IWRAP

Die IALA bietet mit IWRAP (IALA Waterway Risk Assessment Program) ein Tool mit dem auf Basis historischer AIS-Daten in einem definierten Seegebiet die Wahrscheinlichkeit für Kollisionsrisiken approximiert wird. Für die Berechnung dieser Wahrscheinlichkeiten ist eine Modellierung des Seegebiets in IWRAP notwendig (International Association of Lighthouse Authorities 2017).

Das Seegebietsmodell setzt sich aus topologischen Informationen und verkehrsbezogenen Informationen zusammen. Für die Seegebietstopologie kann der Verlauf der Wasserstraßen mit Informationen aus Seekarten manuell modelliert werden. Durch das Hinzufügen von bathymetrischen Informationen kann der Detailierungsgrad erhöht werden.

Verkehrsbezogene Informationen sind für die Modellierung des Schiffsverkehrs innerhalb des betrachteten Seegebiets notwendig. Hierfür empfiehlt die IALA historische AIS-Daten aus dem Seegebiet zu verwenden und statistisch hinsichtlich einer lateralen Verteilung zu analysieren. Des Weiteren wird empfohlen, die Ergebnisse in Form einer HeatMap darzustellen. Mittels der HeatMap kann manuell der geometrische Verlauf typischer Schiffsbahnen innerhalb des Seegebiets modelliert werden, was in IWRAP in Form eines Graphen geschieht (International Association of Lighthouse Authorities 2017).

Die Kanten zwischen den jeweiligen Knoten des Graphen werden in IWRAP als Leg bezeichnet. Zur präziseren Modellierung des Verkehrs entlang der Legs können in IWRAP Wahrscheinlichkeitsverteilungen für die Verkehrsdichte einzelner Schiffstypen definiert werden. Diese Informationen müssen zuvor ebenfalls aus den historischen AIS-Daten separat extrahiert werden. Neben der allgemeinen Verkehrsdichte ist es in IWRAP ebenfalls möglich eine laterale Verteilung des Verkehrs zu modellieren, womit die tatsächliche Verkehrsmodellierung präzisiert werden kann.

Um die Kollisionswahrscheinlichkeit in einem Seegebiet zu approximieren, werden in IWRAP Wahrscheinlichkeiten für Kollisionsursachen genutzt. Mögliche Ursachen sind hier unter anderem eine potenzielle Kollision bei einem Überholvorgang oder das auf Grund laufen wegen einer Untiefe. Die jeweiligen Wahrscheinlichkeiten sind von der IALA festgelegt. In Kombination mit den

zuvor modellierten geometrischem Verlauf der Wasserwege und der statistischen Verteilung entlang der einzelnen Legs errechnet IWRAP die jährliche Wahrscheinlichkeit der jeweiligen Kollisionsarten im modellierten Seegebiet (International Association of Lighthouse Authorities 2017).

3.3.2 Anomaliedetektion im Schiffsverhalten

Arguedas et al. (Fernandez Arguedas, Pallotta und Vespe 2018) präsentieren eine Methode zur Extraktion und Repräsentation typischer Verkehrsmuster mittels Verkehrsnetzwerke. Die Autoren konzentrieren sich auf wiederkehrende Routen und adressieren die Tatsache, dass Schiffe mit dem gleichen Ziel auf unterschiedlichen Wegen dorthin gelangen können. Hierfür führen sie die Begriffe *Semantic Routes* und *Routes* ein. *Semantic Routes* beschreiben grundsätzlich die Existenz einer Route zwischen einem Start- und Zielhafen. Um die Variation im eigentlichen Verhalten der Schiffe entlang der *Semantic Routes* zu modellieren, beschreiben die *Routes* eine konkrete Ausprägung einer *Semantic Route*. Je *Semantic Route* können unterschiedlich viele *Routes* existieren (Fernandez Arguedas, Pallotta und Vespe 2018). Zur Generierung ihrer Verkehrsnetze analysieren die Autoren historische AIS-Daten mittels des TREAD (Traffic Route Extraction and Anomaly Detection) Frameworks von Pallotta et al. (Fernandez Arguedas, Pallotta und Vespe 2018; Pallotta, Vespe und Bryan 2013).

Das TREAD-Framework ist ein Ansatz, um unüberwacht Verkehrsmuster aus historischen AIS-Daten zu extrahieren. Die grundlegende Idee von TREAD ist es, charakteristische Punkte in einem Seegebiet zu extrahieren und anhand der Schiffsbewegungen die Verbindungen zwischen diesen Punkten herauszustellen. Hierfür definieren sie unterschiedliche Objekte: Das *Vessel*-Objekt repräsentiert Schiffe, die durch ihre MMSI identifiziert werden und zusätzlich alle statischen und dynamischen Informationen beinhalten, die über AIS übertragen werden. Die übrigen Objekte werden durch das Verhalten der Schiffe identifiziert. *Stationary Point*-Objekte sind die Punkte, an denen die Geschwindigkeit der Schiffe einen definierten Schwellenwert unterschreitet. Diese Punkte können entweder einen Hafen oder eine Offshore-Plattform abbilden. *Waypoint*-Objekte sind die geografischen Punkte, an denen Schiffe entweder stoppen oder wieder Fahrt aufnehmen. Die *Entry* und *Exit*-Objekte sind jene Punkte im betrachteten Seegebiet, an dem das erste beziehungsweise letzte Mal eine AIS-Nachricht von einem Schiff empfangen wurde. Nachdem für jedes *Vessel*-Objekt und seine historischen Bewegungsdaten die entsprechenden *Waypoint*, *Stationary Points*, *Entry* und *Exit*-Objekte identifiziert wurden, schlagen Pallotta et al. (Pallotta, Vespe und Bryan 2013) die Anwendung des DBSCAN-Algorithmus zur Konsolidierung der jeweiligen Punkte vor. Als letzten Schritt ist im TREAD Framework die Bildung von Routenobjekten vorgesehen. Hierfür wird untersucht, welche Objekte das *Vessel*-Objekt auf seiner Fahrt durch das Seegebiet

besuchte. Um die eigentlichen Verkehrsmuster herauszustellen, wenden die Autoren auf die Routenobjekte den DBSCAN-Algorithmus an. Zur Demonstration der Funktionsweise des TREAD-Frameworks analysieren Pallotta et al (Pallotta, Vespe und Bryan 2013) historische AIS-Daten aus unterschiedlichen Seegebieten.

Nachdem Fernandez Arguedas et al. (Fernandez Arguedas, Pallotta und Vespe 2018) TREAD angewendet haben, extrahieren sie in einem nächsten Schritt die *Semantic Routes* aus den historischen AIS Daten indem alle historischen Tracks mit dem gleichen Start und Ziel werden zusammengefasst werden. Um die *Semantic Routes* weiter in spezielle *Routes* zu unterteilen, wenden die Autoren die Hausdorff-Distanz an. Mit der Hausdorff-Distanz kann die Ungleichheit zweier nicht leerer Mengen bestimmt werden (Huttenlocher, Klanderman und Rucklidge 1993). Mittels dieses Vorgehens erhält man folglich die typischen und wiederkehrenden Routen zwischen einem Start und Ziel (*Semantic Routes*), sowie unterschiedliche Ausprägungen der jeweiligen *Semantic Routes*, die *Routes*. Um die Komplexität ihres Verkehrsnetzes zu reduzieren, wenden die Autoren auf die identifizierten *Routes* den Douglas-Peucker Algorithmus an. Der Douglas-Peucker Algorithmus wird zur Kurvenglättung (Douglas und Peucker 1973) angewendet. Die Knoten aus dem erhaltenen Verkehrsnetz sind die mittels TREAD identifizierten Punkte und die Kanten werden durch die identifizierten *Routes* beschrieben (Fernandez Arguedas, Pallotta und Vespe 2018).

Um anomale Schiffsmanöver zu erkennen, stellen Lamm und Hahn (Lamm und Hahn 2019) einen Ansatz zur Extraktion von Manöverpunkten aus historischen AIS-Daten vor. Die Autoren definieren ein Manöver als eine Kurs- oder Geschwindigkeitsänderung, womit sie Fossens (Fossen 2011) Definition eines Manövers folgen. Zur Identifizierung eines Manövers in den Daten wenden die Autoren die kumulierte Summe (CUSUM) an. CUSUM ist ein Verfahren zur Detektion von Änderungen in Datenreihen mittels eines definierten Schwellenwertes, der häufig durch den gleitenden Mittelwert festgelegt wird (Hawkins und Olwell 1998). Zur Manöverdetektion werden zunächst die zusammengehörigen historischen AIS-Daten zu Schiffstracks zusammengefasst und daraufhin die sequenzielle Abfolge der Schiffskurse mittels CUSUM auf potenzielle Manöverpunkte untersucht. Als Schwellenwert schlagen die Autoren die Nutzung des gleitenden Mittelwerts vor. Zur Konsolidierung der extrahierten Manöverpunkte wird der DBSCAN-Algorithmus angewendet. Aus jedem so erhaltenen Cluster wird abschließend der Medoid berechnet, der wiederum die Repräsentation eines jeden Clusters ist. Mittels der historischen Schiffsbahnen wird in einem finalen Schritt die Erreichbarkeit der Clusterpunkte untereinander determiniert. Um die unterschiedliche Manövrierfähigkeit der jeweiligen Schiffe zu berücksichtigen schlagen Lamm und Hahn (Lamm und Hahn 2019) vor, für jede Schiffsklasse (z.B. Tanker oder GeneralCargo) ein dediziertes Manövernetz zu erstellen. Das so erhaltene Manövernetz wird zur Anomaliedetektion genutzt, indem die Annahme gilt, dass Schiffe in dem Seegebiet immer im Umkreis der Manöverpunkte aus dem

Manövernetz ein Manöver vollziehen. Unter dieser Annahme demonstrieren die Autoren, wie aus einer gegebenen Menge an historischen AIS-Daten ihrer Definition nach anomale Manöver detektiert werden können (Lamm und Hahn 2019).

Ristic (Ristic 2014) präsentiert einen rasterbasierten Ansatz zur Anomaliedetektion. Die grundlegende Idee ist, typisches Schiffsverhalten in jeder Zelle statistisch zu modellieren. Schiffsverhalten definiert der Autor über Positions- und Geschwindigkeitsparameter der Schiffe. Im Zuge der Komplexitätsreduktion wird angenommen, dass der Positionsparameter durch die Zelle, in der sich ein Schiff befindet, hinreichend definiert ist. Das Geschwindigkeitsprofil eines Schiffes in jeder Zelle wird durch einen Poisson-Prozess modelliert, deren Parameter während der Lernphase automatisch festgelegt werden. Die dafür notwendige Wahrscheinlichkeitsverteilung wird durch die Kerndichteschätzung (KDE) approximiert, wobei der Autor einen Gausskern verwendet. Der Autor führt aus, dass mit dieser Art der Verhaltensmodellierung zwei Arten von Anomalien detektiert werden können: Positionsbezogene Anomalien sind hierbei Schiffe, die sich in Zellen aufhalten, in denen sie sich normalerweise nicht aufhalten sollten. Basierend auf der Wahrscheinlichkeitsverteilung der Geschwindigkeiten in einer jeden Zelle können Geschwindigkeitsanomalien in jeder Zelle erkannt werden. Der dafür notwendige Schwellenwert wird durch die Datenmenge definiert. Falls eine beobachtete Geschwindigkeit sich unter dem definierten Schwellenwert befindet, wird sie als Anomalie deklariert. Die Anwendbarkeit dieses Konzepts demonstriert Ristic mit historischen AIS-Daten aus dem Hafen von Sydney, die den Zeitraum vom 23.01 bis zum 25.05.2009 abdecken. Aus der Gesamtmenge der Daten wird mit dem oben beschriebenen Vorgehen Normalmodelle für jede Zelle berechnet. Ein Testdatensatz, der die zwei anschließenden Wochen umfasst, wird anschließend auf Anomalien untersucht. Die detektierten Anomalien deuten laut Ristic darauf hin, dass diese Methode großes Potential hat, den Menschen bei der Seeraumüberwachung beziehungsweise der Anomaliedetektion zu unterstützen (Ristic 2014).

In ihrer Arbeit vergleichen Laxhammar et al. (Laxhammar, Falkman und Sviestins 2009) zwei Methoden für die statistische Anomaliedetektion in Schiffsverhalten. Die Autoren definieren Verhalten aus den vier Parametern Breiten- und Längengrad der aktuellen Position sowie die Geschwindigkeit in Richtung der Breiten- und Längengrade. Der Zusammenhang dieser Parameter untereinander modellieren die Autoren durch eine Wahrscheinlichkeitsdichtefunktion, für deren Berechnung sie zwei unterschiedliche statistische Methoden verwenden: Gauß'sche Mischmodelle (GMM) (Reynolds 2015) und Kerndichteschätzung (KDE) (Gramacki 2018). GMMs bestehen aus k -multivariaten Gaußverteilungen, wobei jede Komponente k ein eigenes Parameterset hat, welches wiederum die Verteilung definiert. Laxhammar et al. (Laxhammar, Falkman und Sviestins 2009) nutzen zur Definition der Parameter den Erwartungs-Maximierungs-Algorithmus, der aus-

gehend von einem zufällig aufgestellten Parameterset eine optimale Parameterwahl iterativ errechnet (Dempster, Laird und Rubin 1977). Im Gegensatz dazu ist der KDE nichtparametrisch, die durch diese Methode errechnete Wahrscheinlichkeitsdichtefunktion ergibt sich somit ausschließlich aus den verwendeten Trainingsdaten und wird nicht durch die Parameterwahl beeinflusst (Laxhammar, Falkman und Sviestins 2009). Um die Komplexität der Berechnungen zu minimieren, schlagen die Autoren die Unterteilung des betrachteten Seegebiets durch ein Raster vor, wobei für jede Zelle eine Wahrscheinlichkeitsdichtefunktion durch den KDE und den GMM berechnet wird. Zur Evaluation nutzen die Autoren historische AIS-Daten in einem Seegebiet vor dem Hafen Göteborgs, unterteilen das Seegebiet in ein Raster (2km x 2km) und berechnen für jede Zelle die Wahrscheinlichkeitsdichtefunktion für die oben genannten Parameter unter der Verwendung des KDE und des GMM. Um die Fähigkeit Anomalien identifizieren zu können bewerten zu können, erstellen die Autoren zufällige Schiffstracks im gleichen Gebiet, die sich von den Normalmodellen unterscheiden und somit als Verhaltensanomalien erkannt werden müssen. Ein Vergleich zwischen dem KDE und GMM-Modell zeigt, dass keiner der beiden Algorithmen bessere Ergebnisse erzielt als der andere. Vielmehr erkennen die Autoren an, dass sowohl die Wahrscheinlichkeitsdichtefunktion des KDE und die des GMMs beide nur eine suboptimale Performanz in der Anomaliedetektion abliefern (Laxhammar, Falkman und Sviestins 2009).

3.3.3 Verhaltensprädiktion von Schiffen

Alizadeh et al. (Alizadeh, Alesheikh und Sharif 2021) präsentieren und vergleichen drei Vorhersagemodelle für Schiffsverhalten. Alle drei Ansätze haben gemeinsam, dass sie mit einem Ähnlichkeitsmaße arbeiten, um die Ähnlichkeit zwischen einem aktuellen AIS-Datenpunkt und historischen AIS-Datenpunkten zu bestimmen, die zur Vorhersage des zukünftigen Verhaltens verwendet werden. Die Ähnlichkeit wird mit Hilfe des Kurses, der Geschwindigkeit und der Position eines Schiffes berechnet. Das erste Vorhersagemodell ist eine punktbasierte Vorhersage, bei der für einen gegebenen AIS-Datenpunkt ein ähnlicher Datenpunkt gesucht wird und der Abstand zwischen den beiden Punkten berechnet wird. Für die Vorhersage nehmen die Autoren an, dass der Startpunkt einen ähnlichen Abstand zum historisch ähnlichen Datenpunkt hat. (Alizadeh, Alesheikh und Sharif 2021)

Die zweite Vorhersage ist trajektorienbasiert. Ähnlich wie bei der punktbasierten Vorhersage ermitteln die Autoren die ähnlichste historische Trajektorie mit Hilfe von Dynamic Time Warping (DTW). Um die zukünftige Trajektorie vorherzusagen, schlagen die Autoren vor, den Unterschied zwischen dem Verlauf, der Geschwindigkeit und der Position des aktuellen Datenpunktes mit dem

ähnlichsten aus der historischen Trajektorie zu berechnen. Sie erstellen eine vorhergesagte Trajektorie unter der Annahme, dass die Unterschiede für Kurs, Geschwindigkeit und Position konstant bleiben (Alizadeh, Alesheikh und Sharif 2021).

Für das dritte Vorhersagemodell verwenden die Autoren ein künstliches rekurrentes neuronales Netzwerk mit Langzeitgedächtnis (Long Short-Term Memory, LSTM). Ähnlich wie bei ihrer trajektorienbasierten Vorhersage wenden die Autoren DTW an, um die ähnlichste historische Trajektorie im Vergleich zur aktuellen Trajektorie zu finden. Als Input für das Training des LSTMs werden die Abstände zwischen jedem Datenpunkt der historischen und der aktuellen Trajektorie berechnet. Basierend auf diesen Zahlen wird das LSTM so trainiert, dass es eine Folge von Abständen vorhersagt, die die endgültige vorhergesagte Trajektorie ergibt (Alizadeh, Alesheikh und Sharif 2021).

In (Daranda 2016) wird ein Ansatz zur Verhaltensprädiktion mittels eines neuronalen Netzes präsentiert. Ziel des Ansatzes ist es, die gesamte Bahn des Schiffes auf seiner Reise vorhersagen zu können. Die Grundidee des Ansatzes sieht vor, durch die Vorhersage der Abfolge sogenannter Manöverpunkte (*Turning Points*) die gesamte Bahn vorhersagen zu können. Um solche Manöverpunkte herauszustellen, werden historische AIS-Daten analysiert. Ein Manöverpunkt ist dabei der Punkt auf der Bahn eines Schiffes, bei dem eine Kursänderung von mindestens vier Grad im Vergleich zum vorherigen Datenpunkt vorliegt. Um die Menge an sehr ähnlichen Manöverpunkten zu aggregieren, wird der DBSCAN-Algorithmus angewendet. Somit beinhaltet jedes Cluster den Bereich, in dem die Schiffe das oben definierte Manöver ausführen. Zur Generierung eines Prädiktionsmodells nutzt der Autor ein künstliches neuronales Netzwerk (KNN). Als Input wird dem KNN die Position des aktuellen und nächsten Manöverpunktes, Geschwindigkeit, Kurs, MMSI und der Schiffstyp zur Verfügung gestellt, mit dem Ziel, den nächsten Manöverpunkt zu präzisieren. Anschließend wird der vorhergesagte Manöverpunkt wiederum mit den jeweiligen Parametern als Input genommen, um den übernächsten Manöverpunkt zu präzisieren. Der Autor schlägt vor, dieses Vorgehen so lange zu iterieren, bis der vorhergesagte Manöverpunkt keinen Nachfolger mehr hat. Am Ende werden alle vorhergesagten Manöverpunkte in der Prädiktionsreihenfolge miteinander verbunden, woraus sich die prädisierte Bahn des Schiffes ergibt. Zur Evaluation berechnet der Autor die Distanz zwischen allen prädisierten Manöverpunkten und den Clustermittelpunkten. Die Analyse der Ergebnisse lassen den Schluss zu, dass die prädisierten Manöverpunkte zu keinem Punkt den Durchmesser der Cluster überschreiten. Folglich liegen sie also immer innerhalb der Cluster. Darüber hinaus unterliegt die Distanz einer hohen Schwankung, was der Autor auf den Parameter ϵ zurück. ϵ beschreibt die maximal erlaubte Distanz eines Punktes vom Kernpunkt des Clusters, damit der Punkt noch zu dem Cluster zugeordnet werden kann. Die Genauigkeit der Prädiktion könnte durch eine Anpassung von ϵ verbessert werden (Daranda 2016).

Hexeberg et al. (Hexeberg et al. 2017) präsentieren in ihrer Arbeit einen Ansatz zur Prädiktion von Schiffstrajektorien. Die Autoren betonen, dass ihr Prädiktionsansatz für einen Zeitraum von wenigen Minuten bis maximal 15 Minuten gültig ist. Dieser Fakt unterscheidet sie von existierender Literatur, in der die meisten Ansätze im Bereich von Stunden voraus prädictieren. Des Weiteren legen die Autoren dar, dass für ihren Ansatz keine Vorverarbeitung der historischen Trajektorien notwendig ist. Für ihren Ansatz entwickeln die Autoren einen Algorithmus, der eine Nachbarschaftssuche in einer Menge historischer Schiffstrajektorien verwendet. Hierfür definieren die Autoren das Verhalten von Schiffen als eine Aneinanderreihung von Zuständen. Ein Zustand wird durch einen Vektor beschrieben, der aus der MMSI des Schiffes, seinem aktuellen Kurs und Geschwindigkeit, sowie seiner Position bestehen. Des Weiteren ist ein Zustand in einen a priori und a posteriori Zustand zu unterteilen. Der a priori Zustand hat die gleiche Position wie der eigentliche Zustand, der Kurs und die Geschwindigkeit werden allerdings durch die Differenz mit dem vorherigen Zustand gebildet. Analog dazu werden die Werte für Kurs und Geschwindigkeit des a posteriori Zustands durch die Differenz mit dem nachfolgenden Zustand gebildet. Zu Prädiktion betrachten Hexeberg et al. (Hexeberg et al. 2017) anschließend den Zustand eines Schiffes und vergleichen diesen Punkt mit einer Menge historischer Trajektorien mittels einer Nachbarschaftssuche. Die Nachbarschaft eines Zustandes ist definiert durch einen räumlichen Radius und einem Schwellenwert, der die maximale Abweichung des Kurses definiert. Alle Trajektorienpunkte, die sich innerhalb der Nachbarschaft des aktuellen Zustandes befinden, werden für den weiteren Prädiktionsprozess verwendet. Im folgenden Schritt berechnen Hexeberg et al. (Hexeberg et al. 2017) den Median und den Durchschnitt aller Kurse und Geschwindigkeiten der Trajektorienpunkte aus der Nachbarschaft. Die Autoren nehmen abschließend an, dass sich der Median beziehungsweise Durchschnitt des Kurses und der Geschwindigkeit der Trajektorienpunkte aus der Nachbarschaft dem zukünftigen Zustand entspricht und somit die Prädiktion ist. Evaluieren haben Hexeberg et al. (Hexeberg et al. 2017) ihren Ansatz mit historischen AIS Daten, die im Trondheimsfjord in Norwegen 2010 aufgezeichnet wurden. Aus diesem Datensatz ziehen sie zufällig 2500 AIS-Nachrichten, die sie als jeweiligen Zustand zur Prädiktion nutzen. Um die Güte der Prädiktion zu bewerten, kalkulieren die Autoren die Differenz zwischen dem prädictierten Kurs respektive Geschwindigkeit und den tatsächlichen Werten und bilden den Root Mean Square Error (RMSE). Es ergibt sich bei der Kursprädiktion ein hoher RMSE von rund 33.5° und bei der Geschwindigkeitsprädiktion von rund 5.5 Knoten (Hexeberg et al. 2017).

Perera und Soares (Perera und Soares 2010) präsentieren zur Verhaltensprädiktion von Schiffen einen ausschließlich mathematischen Ansatz. Zu Beginn modellieren die Autoren die Bewegung der Schiffe. Als grundsätzliche Überlegung in diesem Kontext führen die Autoren an, dass Schiffe in der Realität typischerweise eine parabolische Bahn fahren, wodurch sich die Modellierung der

Schiffsbewegungen mittels eines kinematischen 2D Modells anbietet. Die eigentliche Bahn wird dann durch ein zeitkontinuierliches und kurvenförmiges Bewegungsmodell angenähert, dessen Modellierung auf der Verarbeitung von Beobachtungsdaten basiert. Als Beobachtungsdaten nutzen die Autoren lediglich Schiffspeditionen, die aus AIS-Nachrichten stammen. Unter der Verwendung eines erweiterten Kalman-Filters werden anschließend die zukünftigen Systemzustände der Schiffe abgeschätzt. Der Systemzustand eines Schiffe setzt sich hierbei aus seiner Position, Geschwindigkeit und Beschleunigung zusammen, wobei die Geschwindigkeit und die Beschleunigung auf Basis der beobachteten Schiffspeditionen durch das zeitkontinuierliche Bewegungsmodell angenähert wird (Perera und Soares 2010).

Zur Prädiktion einer zukünftigen Schiffspeditionen schlagen Tang et al. (Tang, Yin und Shen 2019) die Nutzung eines LSTM Netzwerks vor. Die grundlegende Idee der Autoren ist es, zehn Minuten an Schiffspeditionen zu beobachten und auf Basis dieser Beobachtung die Position in zehnminütiger Zukunft vorherzusagen. Jede Schiffspedition, die dabei berücksichtigt wird, wird durch die zusätzliche Berücksichtigung des Kurses und der Geschwindigkeit des Schiffes an der Position konkretisiert. In diesem Zusammenhang heben die Autoren die Wichtigkeit einer guten Datenvorverarbeitung hervor. Hierdurch sollen die Datenbasis von Fehlern bereinigt werden, um die Prädiktionsperformanz des Modells zu maximieren. Tang et al. (Tang, Yin und Shen 2019) schlagen vor, die Datenbasis so zu bereinigen, dass nur noch historische AIS-Bahnen übrig sind, die mindestens 1000 Sekunden lang sind. Darüber hinaus wenden die Autoren eine kubische Splinefunktion an, um die verbliebenen AIS-Bahnen zu glätten. Dieses Vorgehen begründen die Autoren damit, dass durch die Nutzung geglätteter AIS-Bahnen ein besseres Prädiktionsergebnis zu erwarten ist (Tang, Yin und Shen 2019). Um nun eine zukünftige Schiffspedition zu prädizieren, schlagen die Autoren vor, eine Menge an Schiffspeditionen inklusive der Kurse und Geschwindigkeiten zu beobachten und diese Menge als Input für ein LSTM-Netzwerk zu nutzen. Dabei bilden die beobachteten Schiffspeditionen einen Zeitraum von zehn Minuten ab und die zu prädizierende Schiffspedition liegt dabei zehn Minuten in der Zukunft. Zur Evaluation konstruieren die Autoren ein Experiment, in dem sie historische AIS-Daten aus dem Hafengebiet von Tianjin, China, zunächst entsprechend ihres Datenvorverarbeitungsschritts vorbereiten und dann ihr LSTM-Netzwerk nach dem oben skizzierten Vorgehen mit den Beobachtungsdaten trainieren. Um die Güte der Prädiktion bestimmen zu können, kalkulieren die Autoren die euklidische Distanz zwischen der prädizierten Schiffspedition und der tatsächlichen Schiffspedition, die aus den historischen AIS-Daten entnommen werden kann. Um ihre Prädiktionsergebnisse einzuordnen, implementieren die Autoren die Ansätze von (Perera und Soares 2010) und (Tingting Xu, Xiaoming Liu und Xin Yang 2012) und nutzen ebenfalls die gleichen AIS-Bahnen um die Positionen prädizieren zu können. (Tang, Yin und Shen 2019) legen im Folgenden dar, dass ihre Prädiktionemethode einen

geringen Prädiktionsfehler aufweist, als die Methoden von (Perera und Soares 2010) und (Tingting Xu, Xiaoming Liu und Xin Yang 2012). Darüber hinaus stellen die Autoren fest, dass ihr eigener Ansatz schlechter wird, wenn der Prädiktionszeitraum größer wird. Ab einem Prädiktionszeitraum von 40 Minuten nimmt die Prädiktionsgüte ab, was die Autoren auf eine ungleiche Verteilung innerhalb der Datenbasis zurückführen (Tang, Yin und Shen 2019).

Mazzarella et al. (Mazzarella, Arguedas und Vespe 2015) präsentieren eine Architektur, mit der Positionsinformationen für Schiffe von unterschiedlichen Anbietern fusioniert werden können. Aus der Menge der historischen AIS-Daten werden anschließend Schiffsbahnen extrahiert. Ziel der Autoren ist es, ein Prädiktionsmodell zu erstellen, mit dem ausgehend von einem gegebenen Teilabschnitt einer Schiffsbahn die zukünftige Bahn vorhergesagt werden kann. Dieses Problem interpretieren Mazzarella et al. (Mazzarella, Arguedas und Vespe 2015) als Klassifikationsproblem, bei dem die dynamische AIS-Nachricht einer historischen Bahn zugeordnet werden soll. Zur Lösung des Klassifikationsproblems schlagen die Autoren die Nutzung der *k-Nearest-Neighbor* (k-NN) Methode vor. Die k-NN Methode ist eine Klassifikationsmethode, bei der die Distanz zwischen ungesehene Daten und einer Menge an Trainingsdaten berechnet wird und auf dieser Basis die Ähnlichkeit zwischen den jeweiligen Datensätzen bestimmt wird. Mazzarella et al. (Mazzarella, Arguedas und Vespe 2015) argumentieren, dass die Güte der Klassifikation mittels der k-NN Methode stark mit dem verwendeten Distanzmaß korreliert. Aus diesem Grund entscheiden sie sich für die Verwendung der Mahalanobis-Distanz, die die quadratische Distanz zwischen den gegebenen Datensätzen in einem mehrdimensionalen Vektorraum berechnet. Zur Berechnung der Ähnlichkeit zwischen einem gegebenen Track und einer Menge an historischen Tracks stellen die Autoren der k-NN Methode einen Vektor zur Verfügung, der aus den Längen- und Breitengraden der Schiffsposition, dem Kurs über Grund und der Geschwindigkeit über Grund besteht. Nachdem der ähnlichste Track mit der geringsten Mahalanobis-Distanz identifiziert wurde, wird die zukünftige Bewegung vorhergesagt. Hierfür nutzen die Autoren zwei unterschiedliche Ansätze. Der erste Ansatz ist nutz ein konstantes Geschwindigkeits- und Kursmodell zur Vorhersage der zukünftigen Bewegung. Hierfür nehmen sie die ähnlichsten Datenpunkte aus dem gegebenen und historischen Track und kalkulieren den Median zwischen den jeweiligen Kursen und Geschwindigkeiten. Anschließend wird basierend auf den Medianen die zukünftigen Bahnenpunkte des Schiffs berechnet. Der zweite Ansatz nutzt die sequenzielle Monte Carlo Methode, mit der die zukünftige Bahn des Schiffs stochastisch approximiert wird. Hierfür wird angenommen, dass die Bahn eines Schiffes eine Aneinanderreihung von Zuständen des Schiffes ist, wobei jeder einzelne Datenpunkt entlang der Bahn den jeweiligen Zustand durch oben beschriebenen Vektor (Kurs, Position, Geschwindigkeit) beschreibt. Mit der sequenziellen Monte Carlo Methode wird die Wahrscheinlichkeitsdichte-

funktion der jeweiligen Zustandsvektoren errechnet und im Anschluss verwendet, um die zukünftigen Zustände der Schiffe stochastisch zu schätzen. Zur Evaluation nutzen Mazzarella et al. (Mazzarella, Arguedas und Vespe 2015) AIS Daten aus dem gesamten März 2014. Die Daten lassen sich zu 100 historische Schiffsbahnen aggregieren, die zwischen der Straße von Gibraltar und der Straße von Dover und umgekehrt verlaufen. Beide Prädiktionsansätze werden iterativ so lange ausgeführt, bis die gesamte Bahn zwischen dem Start- und Endpunkt vorhergesagt wurde. Zur Bewertung der Prädiktionsgüte berechnen Mazzarella et al. (Mazzarella, Arguedas und Vespe 2015) die Distanz zwischen den tatsächlichen AIS-Datenpunkten und den vorhergesagten entlang der gesamten Bahn. Die Autoren kommen zu dem Ergebnis, dass die Genauigkeit der Prädiktion geringer wird, je weiter in die Zukunft prädiziert wird. Des Weiteren ist ihrer Beschreibung zu entnehmen, dass der Prädiktionsansatz, der die sequenzielle Monte Carlo Methode verwendet, einen geringen Prädiktionsfehler aufweist als der Ansatz, der ein konstantes Geschwindigkeits- und Kursmodell verwendet (Mazzarella, Arguedas und Vespe 2015).

In (Pallotta et al. 2014) präsentieren die Autoren eine Prädiktionsmethode von Schiffsverhalten auf Basis eines statistischen Prozesses. Um die Datenbasis zu schaffen und wiederkehrende Verkehrsmuster zu identifizieren, wird das bereits oben eingeführte TREAD-Framework von Pallotta et al. (Pallotta, Vespe und Bryan 2013) genutzt. Die durch das TREAD-Framework extrahierten Wegpunkte werden als Basis genommen, um die Bewegung zwischen ihnen zu prädizieren. Als Prämisse legen die Autoren zunächst fest, dass Schiffe in einem Seegebiet zwar Gemeinsamkeiten im Verhalten haben (hier in Form von Wegpunkten), allerdings bewegen sich die Schiffe zwischen den gemeinsamen Wegpunkten unterschiedlich. Um dies zu berücksichtigen, schlagen die Autoren die Modellierung der Bewegung als stochastischen Prozess vor, um die Eigenheiten der einzelnen Schiffe bei der Prädiktion abbilden zu können. In einem Experiment wenden sie dieses Konzept an. Hierfür nutzen die Autoren historische AIS-Nachrichten aus einem 400 x 600 nautische Meilen großem Mittelmeergebiet und verarbeiten die Daten zunächst entsprechend des TREAD-Frameworks. Anschließend wird das Verhalten zwischen den extrahierten Wegpunkten als Ornstein-Uhlenbeck-Prozess modelliert, dessen Variation vom Schiffstyp abhängig ist. Das so erstellte Modell nutzen die Autoren, um zukünftige Schiffspositionen mehrere Stunden im Voraus zu prädizieren. Die Autoren stellen dabei eine Abweichung zwischen prädizierter Position und tatsächlicher Position von mehreren Kilometern fest (Pallotta, Vespe und Bryan 2013).

In ihrer Arbeit treffen (Ristic et al. 2008) die Annahme, dass typische Bewegungsmuster in Hafengebieten bereits aus historischen AIS-Daten extrahiert wurden. Mittels der vorliegenden Bewegungsmuster versuchen, die Autoren zum einen eine Bewegungsanomalie der Schiffe und zum anderen die nächste Position in der Zukunft vorhersagen zu können. Hierfür formulieren (Ristic et al. 2008) die Nullhypothese, dass sich Schiffe in Zukunft immer so verhalten werden, wie es

andere Schiffe in der Vergangenheit bereits getan haben. Die Nullhypothese hilft zum einen bei der Feststellung einer Anomalie: sobald ein Schiff sich anders verhält als es Schiffe in der Vergangenheit getan haben liegt eine Anomalie vor. Des Weiteren kann die Nullhypothese zur Prädiktion des zukünftigen Verhaltens genutzt werden. Zu diesem Zweck wenden die Autoren die Kerndichteschätzung an und präzisieren so in einem Hafengebiet die nächsten Schiffspositionen in 10, 32 und 70 Minuten in der Zukunft (Ristic et al. 2008).

Eine Herausforderung der Forschungsarbeiten im Kontext der Verhaltensprädiktion von Schiffen ist die Arbeit mit großen Mengen raumzeitlicher Daten. Diese Herausforderung adressieren (Wijaya und Nakamura 2013) mit ihrem Ansatz indem sie zur Speicherung und Analyse der historischen AIS-Daten Apache HBase nutzen. Ähnlich wie bei den oben genannten arbeiten ist der erste Schritt die Bildung von Bahnen aus historischen AIS-Daten. Die gebildeten Schiffsbahnen werden anschließend mit schiffsspezifischen Informationen, wie Schiffstyp, Tiefgang und Herkunftsland annotiert und in einer Datenbank (Apache HBase) gespeichert. Für die Prädiktion fokussieren sich die Autoren auf die Vorhersage von Containerschiffsverhalten in viel befahrenen Gegenden. Grundsätzlich basiert ihr Prädiktionsansatz auf einer Ähnlichkeitssuche, bei der für ein gegebenes Schiff ein möglichst ähnliches in der zuvor erstellten Datenbank mit den Schiffsbahnen gesucht wird. Die Suche wird durch die Parameter Position, Kurs, Geschwindigkeit, Schiffstyp, Tiefgang, Reiseziel, Navigationsstatus und Herkunftsland spezifiziert. Für die Suche haben die Autoren einen Klassifikationsalgorithmus entwickelt, der basierend auf den Parametern die ähnlichste historische Schiffsbahn liefert. Für die eigentliche Prädiktion nehmen die Autoren an, dass das aktuell betrachtete Schiff sich wie das Schiff aus den historischen Daten verhalten wird. Um ihren Ansatz zu bewerten, extrahieren die Autoren Bahnen aus historischen AIS-Daten im Hafenbereich vor Los Angeles. Die Datenmenge deckt vier Monate ab. Eine Erkenntnis der Autoren ist, dass die Genauigkeit der Prädiktion davon abhängt, ob die zur Prädiktion die Nationalität als Parameter genutzt wurde. Wenn dies der Fall war, dann befanden sich rund 34 Prozent der vorhergesagten Schiffspositionen in einem Umkreis von 500 Metern von der realen Position entfernt. Konträr dazu sind nur knapp 20 Prozent der vorhergesagten Positionen in einem Umkreis von 500 Metern von der realen Position entfernt, wenn die Nationalität nicht als Parameter verwendet wurde (Wijaya und Nakamura 2013).

(Xiao et al. 2017) stellen in ihrer Arbeit die Wichtigkeit von Wissen über typische Wasserwege und das Verhalten der Schiffe in diesen Wasserwegen dar. Hierfür präsentieren sie einen ganzheitlichen Ansatz, in dem solches Wissen aus historischen AIS-Daten in zwei Schritten extrahiert wird. Der erste Schritt ist auf die Extraktion von Wasserstraßen fokussiert. Zu diesem Zweck wird das zu betrachtete Seegebiet in ein Gitter unterteilt, wobei die Zellen eine Auflösung von 0,01 Dezimalgrad in Bezug auf Längen- und Breitengrade haben. Zur Extraktion typischer Wasserwege aus

historischen AIS-Daten nutzen die Autoren den DBSCAN-Algorithmus, den sie zur Anwendung auf einer Gitterstruktur abgewandelt haben und die Positionsangaben aus den AIS-Daten verwendet. Am Ende können alle benachbarten Gitterzellen, die der DBSCAN Algorithmus herausgestellt hat, in ihrer Gesamtheit als Wasserwege genutzt werden. Im darauffolgenden Schritt wird das typische Verhalten innerhalb der extrahierten Wasserwege aus den historischen AIS-Daten erstellt. Um die Variation der Bewegungen zwischen den benachbarten Zellen zu modellieren, nutzen die Autoren die Kerndichteschätzung. Die eigentliche Prädiktion des Schiffsverhaltens basiert auf den zwei vorherigen Schritten. Aus den historischen Bewegungsdaten wird eine Bahn gesucht, auf der das Schiff fahren könnte. Anschließend wird die voraussichtliche Reisedistanz errechnet. Beides dient als Grundlage zur Berechnung einer Menge an Positionen, an denen das Schiff in Zukunft wahrscheinlich sein wird. Der Weg, den das Schiff zu einem der vorhergesagten Punkte nehmen wird, wird mittels der oben beschriebenen Kerndichteschätzung und Gitterzellen beschrieben. Zur Evaluation ihres Ansatzes präzisieren die Autoren Schiffsverhalten in Zeitintervallen von 5, 30 und 60 Minuten. Als Gütemaß wird die geografische Distanz zwischen den tatsächlichen und prädisierten Positionen berechnet. Die Autoren heben hervor, dass die Güte ihres Prädiktionsansatzes mit der Auflösung der Zellgröße des Gitters korreliert. Darüber hinaus ist zu erkennen, dass die Prädiktionsergebnisse für einen Zeitraum von 5 Minuten in die Zukunft die stabilsten Ergebnisse liefern. Grundsätzlich nimmt die Prädiktionsgüte mit dem Prädiktionshorizont ab (Xiao et al. 2017).

Ähnlich wie in (Daranda 2016) schlagen Zissis et al. (Zissis, Xidias und Lekkas 2016) die Anwendung eines KNNs zur Prädiktion vor. Allerdings fokussieren sie sich in ihrer Arbeit auf Passagierfähren, die regelmäßig zwischen den Inseln im ägäischen Meer verkehren. Hierfür teilen sie eine Menge an historischen AIS-Daten in 70% an Trainings- und 30% in Testdaten auf. Die Autoren trainieren ein KNN unter Verwendung der Resilient Backpropagation, um etwaige Prädiktionsfehler zu minimieren. Als Inputvektor werden die letzten vier Positionen des Schiffes genutzt, die aus den AIS-Daten extrahiert werden können. Das KNN hat folglich acht Inputneuronen (Längen- und Breitengrade für vier Positionen) und wird zur Vorhersage einer Position in 15 Minuten trainiert. Am Ende des Trainings ergibt sich ein KNN mit einer verdeckten Schicht, die 53 Neuronen beinhaltet. Die verbliebenen 30% der Daten werden zur Evaluation genutzt, in der Zissis et al. (Zissis, Xidias und Lekkas 2016) die prädisierten Breiten- und Längengrade mit den tatsächlichen vergleicht und die Fehlerrate angibt. Für die Breitengrade geben die Autoren eine Fehlerrate zwischen rund 0,04% und 1,4% an. Die Fehlerrate der prädisierten Längengrade befindet sich in einem Intervall von rund 0,1% und 2,2% (Zissis, Xidias und Lekkas 2016).

3.4 Zusammenfassung und Bewertung

Die Verhaltensprädiktion im Automotive-Bereich ist vorrangig eine sicherheitsrelevante Anwendung, bei der es darum geht, potenziell gefährliche Begegnungssituationen zwischen Fahrzeugen so früh wie möglich zu erkennen. Die Literatur bestätigt, dass im Automotive-Bereich die kurzfristige Verhaltensprädiktion wichtiger ist als eine langfristige. Dementsprechend nutzen die betrachteten Ansätze unterschiedliche Bewegungsmodelle, um das zukünftige Verhalten der Fahrzeuge zu approximieren. Der Klassifikation von Lefèvre et al. (Lefèvre, Vasquez und Laugier 2014) folgend, können die Ansätze hinsichtlich des verwendeten Bewegungsmodells unterschieden werden. Der Prädiktionshorizont liegt aus diesem Grund innerhalb weniger Sekunden.

Der geringe Prädiktionshorizont ist der Hauptgrund, warum die existierenden Prädiktionsansätze nicht auf die maritime Domäne übertragen werden können. Durch die hohe Trägheit der Schiffe (Fossen 2011) ist ein kleiner Prädiktionshorizont von wenigen Sekunden nicht sinnvoll nutzbar. Auch wenige Minuten im Voraus das Verhalten der Schiffe zu präzisieren hat nur in besonderen Szenarien einen Sinn. Die Prädiktion des Manövers des letzten Augenblicks ist ein Beispiel für die einen Prädiktionshorizont von wenigen Minuten im maritimen Bereich (Steidel und Hahn 2019). Die Betrachtung existierender Ansätze zur maritimen Verhaltensprädiktion bestätigen diese Annahmen. Üblicherweise werden Prädiktionszeiträume zwischen 30 und 60 Minuten adressiert, mit Ausnahme bei Hexeberg et al. (Hexeberg et al. 2017) und Zissis et al. (Zissis, Xidias und Lekkas 2016), die fünf beziehungsweise 15 Minuten voraus präzisieren.

In der Luftfahrt hat sich ein Framework etabliert, welches den allgemeinen Prädiktionsprozess von Flugbahnen definiert. Die existierenden Methoden können in kurzfristige (wenige Minuten) und langfristige (ab zehn Minuten) Ansätze unterteilt werden. Darüber hinaus ist es innerhalb des Frameworks explizit vorgesehen Wetterbedingungen bei der Prädiktion zu berücksichtigen. Ein elementarer Parameter bei der Prädiktion ist neben der Position und Zeit die dazugehörige Höhe der Luftfahrzeuge. Die Steig- und Sinkraten der Luftfahrzeuge korrelieren dabei mit dem jeweiligen Flugzeugtypen. Aus diesem Grund sieht das Prädiktionsframework vor, standardisierte Performance-Datenbanken, wie zum Beispiel beispielsweise BADA⁷ zu verwenden (Zeng et al. 2022). In der Luftfahrt ist dies möglich, weil es im Vergleich zur Schifffahrt eine geringere Variantenvielfalt an Luftfahrzeugen gibt und diese zumeist auch standardisiert sind. In der maritimen Welt ist so ein Vorgehen nicht möglich, da die Schiffe grundsätzlich in ihrer Fertigung Einzelstücke sind und zumeist eine Lebensdauer von rund 25 Jahren haben (United Nations 2018). Solche Informationen können zur Vorhersage von Schiffsverhalten nicht genutzt werden, weil diese Daten im dafür notwendigen Detaillierungsgrad nicht zur Verfügung stehen.

⁷ <https://www.eurocontrol.int/model/bada>, Zuletzt abgerufen am 12.06.2023

Die Vorgehensweise der existierenden Arbeiten zur Schiffsverhaltensprädiktion ist vergleichbar mit den manöverbasierten Bewegungsmodellen (Lefèvre, Vasquez und Laugier 2014) aus dem Automotive-Bereich und in der Luftfahrt mit den Prädiktionsmethoden vergleichbar, die Machine Learning Methoden einsetzen (Zeng et al. 2022). In beiden Bereichen werden aus historischen Bewegungsdaten typische Bewegungsmuster abgeleitet, die anschließend zur Prädiktion verwendet werden (Zeng et al. 2022; Lefèvre, Vasquez und Laugier 2014). Dieses Vorgehen hat sich ebenfalls in der maritimen Domäne etabliert und auf Abbildung 23 skizziert.




Abbildung 23: Schematische Darstellung des generellen Vorgehens zur Verhaltensprädiktion in der Literatur.

Alle betrachteten Arbeiten beginnen mit der Extraktion von typischen Bewegungsmustern in einem Gebiet. Hierfür nutzen alle vorgestellten Arbeiten historische AIS-Nachrichten, die zuvor verarbeitet werden. Je nach Ansatz wird die Datengrundlage zunächst gesäubert und zur Weiterverarbeitung aufbereitet. Die Musterextraktion unterscheidet sich je nach Ansatz, allerdings ist die Berechnung und Verwendung von Clustering-Algorithmen weit verbreitet in der Literatur (Dobrovic et al. 2016; Riveiro, Pallotta und Vespe 2018). Da die historischen Bewegungsdaten von Schiffen die allgemeine Bewegung ebenerer in einem Gebiet beschreiben, unterscheiden sich Formen und Größen der Cluster je nach den geografischen Gegebenheiten der betrachteten Seegebiete. Dies begründet auch die Tatsache, dass die Zahl der Cluster vor der Anwendung eines Algorithmus nicht bekannt ist, womit partitionierende Clusterverfahren zu keinem zufriedenstellenden Ergebnis kommen. Um dieses Problem zu adressieren, werden in der Literatur üblicherweise dichte-basierte Clusteralgorithmen, wie zum Beispiel den DBSCAN-Algorithmus, verwendet.

Nach der Musterextraktion wird ausgehend von aktuellen AIS-Datenpunkten das zukünftige Verhalten prädiziert, wofür unterschiedliche Methoden eingesetzt werden: neben regelbasierten Verfahren (Wijaya und Nakamura 2013) werden künstliche neuronale Netze (Alizadeh, Alesheikh und Sharif 2021; Daranda 2016; Tang, Yin und Shen 2019; Zissis, Xidias und Lekkas 2016) oder Methoden aus der Statistik (Hexeberg et al. 2017; Mazzarella, Arguedas und Vespe 2015; Pallotta

et al. 2014; Ristic et al. 2008; Xiao et al. 2017) eingesetzt. Das Ergebnis der jeweiligen Prädiktionsansätze reicht von der Vorhersage des nächsten geografischen Punktes (Zissis, Xidias und Lekkas 2016), mehrerer geografischer Bahnenpunkte in der Zukunft (Ristic et al. 2008) bis zur Vorhersage einer kompletten Bahn oder Trajektorie (Hexeberg et al. 2017; Mazzarella, Arguedas und Vespe 2015; Pallotta et al. 2014; Wijaya und Nakamura 2013; Xiao et al. 2017).

Der Beitrag der diskutierten Arbeiten zur Lösung des in Abschnitt 1.2 formulierten Problems wird mit Hilfe der Tabelle 4 beleuchtet. In der Tabelle wird die Anforderungsabdeckung der oben beschriebenen Arbeiten mit den in Abschnitt 1.3 aufgestellten Anforderungen zusammengefasst.

Tabelle 4: Anforderungsabdeckung existierende Ansätze zur Verhaltensprädiktion von Schiffen.

Anforderung	(Alizadeh, Alesheikh und Sharif 2021)	(Daranda 2016)	(Hexeberg et al. 2017)	(Mazzarella, Arguedas und Vespe 2015)	(Pallotta et al. 2014)	(Perera und Soares 2010)	(Tang, Yin und Shen 2019)	(Ristic et al. 2008)	(Wijaya und Nakamura 2013)	(Xiao et al. 2017)	(Zisis, Xiclas und Lekkas 2016)
A.01 Vorrusschauende Kollisionsvermeidung	○	○	○	○	○	○	○	○	○	○	○
A.02 Genauigkeit	○	○	○	○	○	○	○	○	○	○	○
A.03 Gültigkeit	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
A.04 Anomaliedetektion	X	X	X	X	X	X	X	✓	X	X	X
A.05 Berücksichtigung Meteorologische Bedingungen	X	X	X	X	X	X	X	X	X	X	X
A.06 Berücksichtigung Ozeanographische Bedingungen	X	X	X	X	X	X	X	X	X	X	X
A.07 Seekarteninformationen	X	X	X	X	X	X	X	X	X	X	X
A.08 Hydrodynamische Schiffseigenschaften	X	X	X	X	✓	X	X	X	✓	X	○
A.09 Nutzung historischer Schiffsbewegungsdaten	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
A.10 Datenanreicherung	X	X	X	X	X	X	X	X	X	X	X
A.11 Abbildung hydrodynamischer Eigenschaften	X	X	X	X	✓	X	X	X	✓	X	○
A.12 Abbildung kontextueller Bedingungen	X	X	X	X	X	X	X	X	X	X	X
A.13 Kontextuelle Informationen zur Prädiktion	X	X	X	X	X	X	X	X	X	X	X
A.14 Vorhergesagte Bahnpunkte	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

✓ = Anforderung erfüllt, ○ = Anforderung teilweise erfüllt, X = Anforderung nicht erfüllt

Aus der Tabelle geht hervor, dass die hier diskutierten Ansätze alle Bahnenpunkte (A.14) präzisieren und bei der Extraktion typischer Bewegungsmuster historische Schiffsbewegungsdaten (A.09) nutzen, die für das jeweils betrachtete Seegebiet gültig sind (A.03). Im Rahmen der Musterextraktion berücksichtigen allerdings nur (Pallotta et al. 2014) und (Wijaya und Nakamura 2013) die unterschiedlichen hydrodynamischen Schiffseigenschaften (A.08 & A.11) indem sie bei der Musterextraktion und Prädiktion jeweils den Schiffstyp mit einbeziehen. Als einzige der vorgestellten Arbeiten ist bei (Ristic et al. 2008) beschrieben, wie der Ansatz zur Verhaltensprädiktion auch zur Detektion von anomalem Schiffsverhalten genutzt werden kann.

Wie eingangs in dieser Arbeit beschrieben ist die Verhaltensprädiktion von Schiffen Grundlage für eine proaktive Kollisionsvermeidung auf See, und zwar unabhängig von der konkreten Ausgestaltung der Prädiktionemethode. Grundsätzlich ist somit jede der präsentierten Arbeiten zur Kollisionsvermeidung nutzbar, allerdings ist keine der diskutierten Arbeiten konkret auf einen späteren praktischen Anwendungsfall zur Kollisionsvermeidung (A.1) eingegangen und hat die Methode diesbezüglich evaluiert. Die Arbeiten wurden zwar hinsichtlich ihrer Prädiktionsgenauigkeit evaluiert (A.2), allerdings fehlt bei allen ein Transfer der Evaluationsergebnisse auf eine spätere Praxisanwendung. Das bedeutet, dass zwar eine Aussage über die Genauigkeit der Prädiktionsergebnisse getroffen wurde. Inwiefern die jeweilige Methode allerdings in Praxis zur Kollisionsvermeidung nutzbar ist, wurde von keiner diskutiert.

Zusätzlich zu den historischen Schiffsbewegungsdaten nutzt kein Ansatz Informationen aus den Seekarten, über meteorologische oder ozeanographische Bedingungen im Rahmen der Musterextraktion, Mustermmodellierung und Prädiktion (A.5 – A.8, A.10 – A.13).

4 Kontextsensitive Verhaltensprädiktion von Schiffen

Bei der Durchführung einer Schiffsreise kommt dem wachhabenden Offizier (OOW – Officer On Watch) eine besondere Rolle zu. Neben der kontinuierlichen Überwachung des allgemeinen Schiffszustands verantwortet der OOW die sichere Navigation unter Berücksichtigung der COLREGs. Im Rahmen der Kollisionsvermeidung hat der OOW sich zu jeder Zeit mit allen ihm zur Verfügung stehenden Mitteln ein möglichst komplettes Lagebild der Verkehrssituation um das Schiff herum zu machen, was insbesondere die Detektion gefährlicher Schiffsbegegnungen beinhaltet (Berking und Brauner 2010; International Maritime Organization 1972; 1974).

Wie bereits in Abschnitt 1.1 eingeführt, hat sich zur Beurteilung einer potenziellen Kollisionsgefahr die Nutzung von Bewegungsvektoren etabliert. Stand der Technik ist hierbei das ARPA, welches die Bewegung fremder Schiffe über Radar und AIS wahrnimmt und entsprechende Bewegungsvektoren kalkuliert (Berking und Brauner 2010; International Maritime Organization 1974). Für offene Gewässer, in denen Schiffsrouten hauptsächlich gerade verlaufen, funktionieren diese Bewegungsvektoren hinreichend gut.

Anders sieht es in küstennahen Gewässern aus, in denen Wasserstraßen die befahrbaren Gewässer kennzeichnen (Berking und Brauner 2010; International Association of Lighthouse Authorities 2018). Lineare Bewegungsvektoren approximieren das zukünftige Verhalten nur in küstennahen Gewässern hinreichend präzise, in denen die Wasserstraßen geradeaus verlaufen. Kurvige Wasserstraßen, wie sie beispielsweise in der Elbe oder dem Nord-Ostsee-Kanal zu finden sind, kann diese Prädiktionsmethode nicht berücksichtigen. Im Folgenden sollen die Schwächen dieses Prädiktionsansatzes exemplarisch anhand der Abbildung 24 erläutert werden.




Abbildung 24: Ein Eigenschiff (hellblau) und Fremdschiff (dunkelblau) begegnen sich in einer Wasserstraße. Der relative Bewegungsvektor des Fremdschiffes zeigt dabei eine potenzielle Kollisionsgefahr mit dem Eigenschiff an.

Ein Eigenschiff (dunkelblau) und ein Fremdschiff (hellblau) fahren in entgegengesetzte Richtungen in einem durch Tonnen markiertes Fahrwasser. Beide Schiffe nehmen sich gegenseitig über das Radar und den AIS-Transceiver wahr, woraufhin das ARPA die kontinuierlichen und linearen Bewegungsvektoren vom Eigenschiff und dem Fremdschiff berechnet. In Abbildung 24 sind die Bewegungsprädiktionen als Verlängerungen an den Spitzen der Schiffe dargestellt. Grundsätzlich werden die Bewegungsvektoren auf Basis der aktuellen Geschwindigkeit, des Kurses und der Position der Fremd- und Eigenschiffe berechnet. Die Länge des Bewegungsvektors des Eigenschiffs hängt von einer festgelegten Zeit T ab (Berking und Brauner 2010).

Zur Interpretation der Bewegungsvektoren ist es gängige Praxis, zwei numerische Werte zur Hilfe zu nehmen, die vom ARPA errechnet werden: Der geringste Passierabstand (Closest Point of Approach; CPA) zwischen den beiden Schiffen und darauf basierend die Zeit, die das Eigenschiff benötigt, bis es am CPA angekommen ist (Time to CPA; TCPA). Bei einer bevorstehenden, potenziell gefährlichen Begegnungssituation generiert das ARPA einen Alarm, sobald ein bestimmter Schwellenwert für den TCPA unterschritten ist. Der Schwellenwert kann im ARPA durch die Besatzung definiert werden, sodass die unterschiedliche Manövrierfähigkeit eines jeden Schiffes bei der Alarmgenerierung und Bewertung einer solchen Begegnungssituation berücksichtigt werden kann (Berking und Brauner 2010).

Das in Abbildung 24 illustrierte Vorgehen hat allerdings einen entscheidenden Nachteil. Die Berechnung und Nutzung linearer Bewegungsvektoren ist nicht für jedes Seegebiet geeignet. Auf der Abbildung ist ein Beispiel konstruiert, für das diese Methode kein zufriedenstellendes Ergebnis

liefert. Sowohl das Eigenschiff als auch das Fremdschiff segeln in der Abbildung in einer Wasserstraße. Da beide Schiffe verpflichtet sind, den Wasserstraßen zu folgen und sich so weit rechts wie möglich auf ihrer Fahrseite zu halten (International Maritime Organization 1972), ist bei dem Fremdschiff ein Steuerbordmanöver zu erwarten und beim Eigenschiff ein Backbordmanöver. Auf Basis der Bewegungsvektoren wird der CPA berechnet und ist in der Abbildung entsprechend markiert. Die tatsächliche Bahn des Fremdschiffes ist ebenfalls in der Abbildung dargestellt und als gestrichelte hellblaue Linie eingezeichnet. Vergleicht man die tatsächliche Bahn des Fremdschiffes mit dem prädizierten Bewegungsvektor und dem darauf berechneten CPA wird schnell ersichtlich, dass der berechnete CPA ungültig ist. Für dieses Beispiel würde der CPA weiter vor dem Eigenschiff liegen. Als Konsequenz der fehlerhaften Berechnung ist der berechnete TCPA ebenfalls ungültig.

Im obigen Beispiel würde das ARPA auf der Brücke einen Kollisionsalarm generieren, was die Aufmerksamkeit des nautischen Personals erfordert, die wiederum die Gültigkeit des Alarms prüfen müssen. Das ist insofern kritisch zu betrachten, als dass die Arbeitsbelastung für das nautische Personal in verkehrsreichen Gebieten weiter steigt. Mehr Arbeitsbelastung bedeutet im Umkehrschluss auch ein höheres Risiko für Fehler, die im schlimmsten Fall Schiffskollisionen mit einem hohen Schaden für die Umwelt, Menschen und Maschine nach sich ziehen.

Darüber hinaus ist eine präzisere Prädiktionsmethode zur Kollisionsvermeidung Grundlage für die Entwicklung hochautomatisierter Schiffe, bei denen das nautische Personal weitestgehend aus der Verantwortung genommen werden sollen. Hierfür ist die Entwicklung einer ebensolchen Prädiktionsmethode, die eine, wie in den COLREGs geforderte, proaktive Kollisionsvermeidung (International Maritime Organization 1972) ermöglicht, notwendig.

4.1 Fallstudie: Graph-basierte Verkehrsmusterextraktion und Modellierung in der Deutschen Bucht und Ostsee

Die Wichtigkeit kontextueller Bedingungen bei der Verkehrsmusterextraktion im maritimen Kontext wird im Folgenden am Beispiel einer Fallstudie gezeigt. Für die Fallstudie (Dominik Filipiak et al. 2021) wurde ein zweistufiger Algorithmus umgesetzt, der eine Graph-basierte Modellierung von typischen Verkehrsmustern in der Deutschen Bucht und Ostsee als Ergebnis hat. Die Idee des Graphen orientiert sich hierbei lose an dem Grundgedanken des ACCSEAS North Sea Region Route Topology Model (NSR-RTM) (Jan-Hendrik Oltman 2015). Der grundlegende Unterschied ist jedoch, dass das NSR-RTM lediglich eine topologische Repräsentation von einem Verkehrsnetz ist. Die Knoten des Graphen sind dabei geographische Punkte, an denen das nautische Personal an Bord eine Entscheidung treffen, wie sie weiter fahren werden. Folglich modellieren die Knoten

Kreuzungen und Abzweigungen, an denen es typischerweise zu offensichtlichen Kursänderungen kommen kann. Die Kanten zeigen lediglich die Erreichbarkeit von einem Knoten zu einem anderen Knoten. Somit kann der Fall auftreten, bei dem die Kanten über Land führen. (Jan-Hendrik Oltman 2015). Das NSR-RTM ist somit lediglich zur Beschreibung topologischer Bahnen geeignet.

Die Knoten aus dem Graphen der Fallstudie sollen zunächst den Grundgedanken der Knoten des NSR-RTM übernehmen und geographische Punkte modellieren, an denen Schiffe deutliche Kursänderungen vollziehen. Allerdings sollen die Kanten nicht nur die Erreichbarkeit der Knoten untereinander modellieren, sondern einen Korridor vorgeben, in dem sich die Schiffe zwischen den Knoten fortbewegen. Es gilt somit die Anforderung an die Korridore, dass sie nur über schiffbare Gewässer führen. Ein Korridor, der beispielsweise über Land führt ist in diesem Graphen somit nicht möglich (Dominik Filipiak et al. 2021).

Das Verfahren zur Extraktion des Graphen ist auf Abbildung 25 dargestellt. Zunächst werden die zu analysierenden AIS aufgrund ihrer geographischen Attribute räumlich in einen k-d-Baum unterteilt. Ein k-d-Baum ist eine effiziente Datenstruktur zur Speicherung und Suche von raumbezogenen Daten, bei dem der Raum in unterschiedlich (räumlich gesehen) große Partitionen unterteilt wird (Bentley 1990; Skrodzki 2019). Jede Partition enthält dabei ungefähr gleich viele Datenpunkte, wodurch ein balancierter Suchbaum entsteht (Bentley 1990). Dieses Vorgehen folgt damit der Argumentation von (Dobrkovic, Iacob und van Hillegersberg 2018), die eine solche Unterteilung bei der Anwendung eines genetischen Algorithmus empfehlen (nachfolgender Schritt).




Abbildung 25: Die Extraktion des Graphen besteht aus der Extraktion von Manöverpunkten, ihrer Konsolidierung und einer abschließenden Berechnung der Kanten des Graphen.

Bevor es zur Anwendung eines genetischen Algorithmus kommt, werden allerdings zunächst Manöverpunkte identifiziert. Hierfür wird der in Abschnitt 3.3 vorgestellte CUSUM-Algorithmus von Lamm und Hahn (Lamm und Hahn 2019) angewendet. In diesem Abschnitt ist eine detaillierte Beschreibung des Vorgehens zu finden. CUSUM wird iterativ für jede Partition des k-d-Baums angewendet.

Der anschließende Schritt fokussiert die Konsolidierung der identifizierten Manöverpunkte durch einen genetischen Algorithmus. Das im Folgenden beschriebene Funktionsweise des genetischen Algorithmus orientiert sich dabei lose an dem von Dobrkovic, Iacob und van Hillegersberg vorgestellten Verfahren (Dobrkovic, Iacob und van Hillegersberg 2018).

Für jede Partition werden die zuvor extrahierten Manöverpunkte als Gene codiert. Ein Gen besteht hier aus den Längen- und Breitengraden der Manöverpunkte sowie aus einem Radius um den Manöverpunkt. Gene werden zusammengefasst als Chromosom bezeichnet. Diese werden zufallsbasiert aus den verfügbaren Genen gezogen. Chromosomen werden typischerweise über eine Fitnessfunktion evaluiert, die dabei optimiert werden soll. Bei der Fallstudie wird die Fitness eines Chromosoms mit Hilfe der Radien der einzelnen Gene bestimmt: Je mehr andere Wegpunkte sich innerhalb des Radius eines Gens befinden, desto besser ist die Fitness. Die Überlegung dahinter ist, dass ein Manöverpunkt mit besonders vielen anderen Manöverpunkten in seiner unmittelbaren Umgebung wahrscheinlich der repräsentativste Manöverpunkt ist.

Unter anderem wird damit das Problem von CUSUM adressiert. CUSUM nutzt den DBSCAN-Algorithmus zur Konsolidierung der Manöverpunkte (Lamm und Hahn 2019). Wie in (Steidel, Mentjes und Hahn 2020) dargelegt, führt dies insbesondere in heterogenen Seegebieten zu fehlerhaften Manövernetzen mit Kanten, weil der DBSCAN-Algorithmus für Cluster mit einer sehr ähnlichen Dichte gute Ergebnisse liefert. Unterscheiden sich die Clusterdichten, was in heterogenen Gebieten häufig der Fall ist, liefert DBSCAN nicht zufriedenstellende Ergebnisse.

Genetische Algorithmen werden klassischerweise zur Lösung eines Optimierungsproblems eingesetzt. Um die Fitness der Chromosomen zu optimieren, haben genetische Algorithmen die Standardoperationen *Selektion*, *Crossover* und *Mutation* (Katoch, Chauhan und Kumar 2021).

In der Fallstudie werden im Rahmen der *Selektion* zufallsbasiert Manöverpunkte ausgewählt. Der *Crossover*-Operator wurde dabei so gewählt, dass immer genau ein Gen aus einem Chromosom mit einem Gen aus einem anderen Chromosom punktuell ersetzt wird. Mit dem *Mutations*-Operator werden in jeder Epoche zufallsbasiert ein Gen aus einem Chromosom mit einem bisher nicht berücksichtigten Gen ausgetauscht. Am Ende einer jeden Epoche werden die Fitnessfunktionen der Chromosomen evaluiert. Die schlechtesten Gene werden zufallsbasiert durch neue ersetzt. Im Rahmen der Fallstudie sind schlechte Gene jene, die nur wenige andere Manöverpunkte im definierten Radius haben. Das Ergebnis ist eine Liste der konsolidierten Wegpunkte, die den Knoten des finalen Graphen entsprechen.

Der nachfolgende Schritt (siehe Abbildung 25) ist die Berechnung valider Kanten zwischen den jeweiligen Knoten. Dafür werden die historischen AIS-Daten verwendet, in denen die Schiffsbahnen als Ganzes enthalten sind. Für jeden AIS-Datenpunkt einer jeden Schiffsbahn wird berechnet, welcher der extrahierten Knoten am nächsten ist. Auf diese Weise entsteht für jede Schiffsbahn eine Sequenz an Knoten. Auf diese Weise wird die Erreichbarkeit der Knoten untereinander ermittelt. Am Ende können so die Kanten hinzugefügt werden, wodurch der finale Graph entsteht. Das Ergebnis der Fallstudie ist auf Abbildung 26 zusehen.




Abbildung 26: Der mittels CUSUM und einem genetischen Algorithmus extrahierte Graph aus der Fallstudie (Dominik Filipiak et al. 2021).

Die ausschließliche Fokussierung auf AIS-Daten in der Fallstudie hat viel befahrene Gebiete in der Deutschen Bucht, wie beispielsweise die Verkehrstrennungsgebiete oder den Beginn der Elbe, gut erfasst. Die gelben Kanten sind besonders viel befahren. Allerdings zeigt das Ergebnis ein Problem von Ansätzen zur Extraktion typischer Bewegungsmuster, die sich ausschließlich auf AIS-Daten analysieren. Wenn sich nicht plausible Datenpunkte in dem Datensatz befinden und diese nicht bereinigt werden, hat dies negative Auswirkungen auf die Qualität der extrahierten Bewegungsmuster. Auf Abbildung 26 ist dies in der Fallstudie extrahierten Graph erkennbar: Es existieren Kanten, die über Land führen. Insbesondere das küstennahe Gebiet zwischen den Ostfriesischen Inseln und dem Festland weist hier Probleme auf. Solche Kanten sind auch in Schleswig-Holstein beziehungsweise dem südlichen Dänemark zu erkennen.

Aus praktischer Sicht ist es besonders problematisch, dass die Qualität des Graphen in küstennahen Gebieten im Vergleich zu offenen Gewässern (zum Beispiel Verkehrstrennungsgebiete) abnimmt. Wie oben eingeführt, haben küstennahe Gewässer eine höhere Verkehrsdichte bei gleichzeitig größer werdenden Beschränkungen, wie beispielsweise Untiefen, Wasserstraßen oder Landmassen.

Werden neben historischen AIS-Daten noch weitere Informationen zum allgemeinen Kontext berücksichtigt, können fehlerhafte AIS-Daten bereits zu Beginn identifiziert und entsprechend behandelt werden. Zusätzliche Kontextinformationen haben folglich das Potenzial, typische Ver-

kehrsmuster präziser zu extrahieren und zu modellieren. Damit einher erhöht sich die Wahrscheinlichkeit, zukünftiges Schiffsverhalten unter Verwendung der präziseren Verkehrsmuster genauer prädizieren zu können.

Dies deckt sich mit den Erkenntnissen der Analyse des Stands der Wissenschaft und Technik in Abschnitt 3.3. Aus den dort beschriebenen Arbeiten kann das grundsätzliche Vorgehen zur Extraktion von Verkehrsmustern und einer anschließenden Verhaltensprädiktion beschrieben werden. Die wichtigste Erkenntnis in diesem Abschnitt ist dabei, dass bisher keine der diskutierten Arbeiten kontextuelle Informationen im Rahmen der Verhaltensprädiktion einsetzt. Das Ziel dieser Arbeit ist somit, diese Forschungslücke zu adressieren und eine Lösung dafür zu konzipieren. Abbildung 27 (b) zeigt den Ansatz, um die Forschungslücke zu schließen.




Abbildung 27: Auf (b) ist die konzeptionelle Idee für das eigene Vorgehen für einen Ansatz zur kontextsensitiven Verhaltensprädiktion von Schiffen zu sehen. Dieses Vorgehen orientiert sich an dem in der Literatur etablierten Vorgehensmodell (a) zur Prädiktion Schiffsverhalten.

Die Idee ist das in Abschnitt 3.4 identifizierte Vorgehen (Abbildung 27 (a)) so zu erweitern, dass kontextuelle Informationen sowohl bei der Musterextraktion als auch bei der Prädiktionsmethode verwendet werden. Somit entstehen Verkehrsmuster, die in Abhängigkeit des vorherrschenden Kontexts extrahiert wurden. Darüber hinaus kann bei ähnlichen kontextuellen Bedingungen das zukünftige Schiffsverhalten prädiziert werden.

In den folgenden Abschnitten wird das Konzept dieser Arbeit im Detail erläutert. Zu Beginn wird beschrieben, wie die kontextuellen Informationen identifiziert werden, die bei der Verhaltensprädiktion relevant sein können. Anschließend wird beschrieben, wie kontextuelle Informationen und historische Schiffsbewegungsdaten miteinander assoziiert werden und zur Extraktion

der historischen Bewegungsmuster genutzt werden sollen. Dieses Kapitel schließt mit einer Beschreibung der eigentlichen Prädiktionmethode unter Nutzung der zuvor extrahierten kontextsensitiven Bewegungsmuster.

4.2 Identifizierung von kontextsensitiven Informationen

Zur Identifizierung von Kontextinformationen, die Rahmen von Schiffsverhalten relevant sein könnten, bietet sich ein Blick in die Praxis an. In der Berufsschifffahrt ist das beobachtbare Schiffsverhalten das Ergebnis einer Reisplanung und der konkreten Ausführung der geplanten Reise. Grundsätzlich ist das nautische Personal dazu verpflichtet, ihre Reise vom Liegeplatz des Starthafens bis zum Liegeplatz des Zielhafens zu planen (International Maritime Organization 1974). Neben der Sicherheit spielen bei der Planung auch wirtschaftliche Gedanken eine Rolle: Es muss eine Entscheidung zwischen der schnellsten und der wirtschaftlichsten Route getroffen werden. Die wirtschaftlichste Route ist in der Regel eine treibstoffoptimierte Route. Die Reiseplanung als solche ist von der IMO in den „Guidelines for Voyage Planning“ definiert (International Maritime Organization 1999). In diesem Rahmenwerk sind für die Reiseplanung vier grundsätzliche Phasen beschrieben, die auf Abbildung 28 dargestellt sind.




Abbildung 28: Die vier Phasen der Reiseplanung aus den "Guidelines for Voyage Planning" der IMO (International Maritime Organization 1999) und den Informationen, die während der jeweiligen Phasen genutzt werden müssen.

Die Reiseplanung beginnt mit der Begutachtung der allgemeinen Lage, in der sich das nautische Personal einen Überblick über den Zustand des Schiffes, die zu transportierende Ladung und die Crew verschaffen. Darüber hinaus wird sowohl die Großwetterlage für die das Reisegebiet als auch die jeweils gültigen Gezeitenkalender betrachtet (International Maritime Organization 1999).

An diese Phase schließt sich die eigentliche Seereiseplanung an. Unter Berücksichtigung der zuvor gesammelten und gesichteten Informationen wird die Route, bestehend aus Wegpunkten, geplant. Dies beinhaltet die Festlegung der Reisegeschwindigkeit zwischen den Wegpunkten. Zu berücksichtigen ist hier der Tiefgang der Schiffe, die zu erwartende Großwetterlage und die Informationen aus dem Tidenkalender. Neben einer möglichst effizient geplanten Route soll die Route

vorrangig die Sicherheit von Menschen, der Umwelt und des Schiffes sichern. Hierzu gehört auch das Festlegen etwaiger Ausweichrouten und Notfallprozeduren, die im Falle von extrem schlechten Wetter anzuwenden sind (International Maritime Organization 1999).

Die zwei folgenden Phasen müssen in Verbindung miteinander betrachtet werden. In der Ausführungsphase wird die geplante Route abgefahren, wohingegen in der Überwachungsphase die korrekte Ausführung kontrolliert wird. Insbesondere die vorherrschenden meteorologischen und ozeanographischen Bedingungen werden dabei berücksichtigt. Bei sich stark ändernden Bedingungen kann eine Anpassung der geplanten Route notwendig sein. Um weiterhin eine sichere Reise zu gewährleisten wird die Route entsprechend angepasst (International Maritime Organization 1999). Hier existiert eine Rückkopplung zwischen der Ausführungs- und Planungsphase.

Aus dieser Richtlinie lassen sich zwei Arten von Schiffsverhalten ableiten und klassifizieren: Das geplante Schiffsverhalten, welches in der Planungsphase unter Berücksichtigung der Großwetterlage, Seekarteninformationen, der Schiffseigenschaften und der Gezeiten entsteht. Daneben existiert das ungeplante Schiffsverhalten, mit dem auf sich ändernde Bedingungen reagiert wird. Die Gründe für sich ändernde Bedingungen können vielfältig sein. Neben den ozeanographischen und meteorologischen Gegebenheiten ist hier Reaktion auf die Verkehrslage auf See zu nennen. Im weiteren Verlauf dieser Arbeit sollen beide Arten von Schiffsverhalten betrachtet werden. Beim ungeplanten Schiffsverhalten wird für diese Arbeit aber das Verhalten als Reaktion auf andere Verkehrsteilnehmer explizit ausgeschlossen.

Bei der obigen Auflistung der Informationen und Gegebenheiten, die für die Entstehung beider Verhaltensarten verantwortlich sind, können schiffsbezogene Informationen und Kontextinformationen unterschieden werden. Die schiffsbezogenen Informationen sind unter anderem die Geschwindigkeit und die Dimensionen der Schiffe, inklusive des Tiefgangs. Die zu verwendeten Kontextinformationen, die aus der Richtlinie der IMO hervorgehen, sind meteorologische, ozeanographische und Seekarteninformationen. Um diese bei der Extraktion historischer Bewegungsmuster und einer anschließenden Verhaltensprädiktion verwenden zu können, müssen die Kontextinformationen weiter spezifiziert werden, was im folgenden Abschnitt beschrieben wird.

4.2.1 Informationen aus Seekarten

Eine Übersicht über die zu befahrenden Seegebiete bieten Seekarten. Hier sind befahrbare Gewässer, Untiefen und die Betonung verzeichnet (Berking und Brauner 2010). Grundsätzlich können zwei Arten von Seegebieten unterschieden werden, die in Seegebieten verzeichnet sind. Abbildung 29 zeigt den Ausschnitt zweier Seekarten aus der Deutschen Bucht, auf denen beide Seegebietsarten zu sehen sind.




Abbildung 29: Ausschnitt der Deutschen Bucht mit zwei Ausschnitte, die jeweils beschränkte und unbeschränkte Seegebiete zeigen. ((«Navionics ChartViewem» 2020))

Links unten ist ein Seekartenausschnitt von einem unbeschränkten Seegebiet zu sehen. Was hier auffällt ist, dass die befahrbaren Gebiete für Schiffe nicht klar ausgewiesen sind, wie das zum Beispiel in Wasserstraßen durch eine entsprechende Betonung geschieht. Für die eingangs beschriebene Reiseplanung bedeutet dies, dass das nautische Personal hier lediglich die Wassertiefen berücksichtigen müssen und grundsätzlich die kürzeste Route planen können (Berking und Brauner 2010).

Auf der unteren rechten Seite von Abbildung 29 ist der Ausschnitt eines beschränkten Seegebiets zu sehen. Beschränkte Seegebiete zeichnen sich dadurch aus, dass die für die Schiffe befahrbaren Gewässer explizit ausgezeichnet sind. In der Regel sind dies Wasserstraßen, die durch das Betonnungssystem gekennzeichnet sind. Für jede Wasserstraße wird in der Seekarte eine feste Minimaltiefe angegeben. Das ist jene Tiefe, die den niedrigsten Wasserstand beschreibt. Wenn ein Schiff sich in einem beschränkten Seegebiet bewegt, so müssen sich die Schiffe möglichst weit rechts innerhalb der Wasserstraße fahren (Berking und Brauner 2010; International Association of Lighthouse Authorities 2018). Neben den klassischen Wasserstraßen existieren darüber hinaus Verkehrstrennungsgebiete, mit denen der Verkehr auf See geordnet wird. Insbesondere in küstennahen Gebieten, in denen ein hohes Verkehrsaufkommen herrscht, kann sind Wasserstraßen zu finden (Berking und Brauner 2010).

Diese Systematik soll während des Extraktionsprozesses von typischem Schiffsverhalten und einer darauf basierenden Prädiktionmethode genutzt werden. In küstennahen und beschränkten Gewässern sind die Wasserstraßen ein Anhaltspunkt, wo sich Schiffe fortbewegen werden. Eine

Berücksichtigung dieser Informationen erlaubt es folglich, den potenziellen Lösungsraum für eine Verhaltensprädiktion einzuschränken.

4.2.2 Meteorologische und ozeanographische Informationen

Meteorologische und ozeanographische Bedingungen beeinflussen Schiffsverhalten sowohl während der Planung einer Reise als auch bei der Durchführung. Bei der Planung wird die Route unter Berücksichtigung der prognostizierten meteorologischen und ozeanographischen Bedingungen geplant. Bei sich ändernden Bedingungen wird die geplante Route bei der Durchführung so angepasst, dass die Sicherheit zu jederzeit gewährleistet ist (Berking und Brauner 2010; International Maritime Organization 1999).

Die IMO hat für diesen Zweck eine Richtlinie (International Maritime Organization 2007) herausgegeben, in der sie unter anderem jene meteorologischen und ozeanographischen Parameter definiert, die vom nautischen Personal zu beobachten sind. Insbesondere soll die Richtlinie dabei helfen, widrige und somit potenziell gefährliche Seewetterlagen erkennen und darauf reagieren zu können. Dieser Richtlinie folgend ist die Kombination aus vorherrschenden Windbedingungen und Seegang maßgebend, ob eine Seewetterlage vorliegt, auf die das nautische Personal zu reagieren hat. Ergänzt wird dies durch die Tide. Insbesondere in küstennahen Gewässern hat die Tide einen signifikanten Einfluss in die Schiffbarkeit der Gewässer. Je nach Tidenstand ändert sich die Fläche der schiffbaren Gewässer, weil sich mitunter die Wassertiefe stark ändert. (International Maritime Organization 2007). Abbildung 30 illustriert den Einfluss, den Wind und der Seegang auf ein Schiff haben kann.




Abbildung 30: Der Wind drückt das Schiff in die entgegengesetzte Richtung (a). Der Seegang ist dabei für Bewegungen der Schiffe in unterschiedlichen Dimensionen verantwortlich (b).

Auf der linken Seite ist der Windeinfluss auf das Schiff beziehungsweise auf das eigentliche Schiffsverhalten zu sehen (a). In Abhängigkeit der Schiffsgröße und des Typs hat der Wind eine mehr oder weniger große Angriffsfläche, auf die er wirken kann. In dem Beispiel auf Abbildung 30 (a) kommt der Wind aus Westen und drückt das Schiff von seiner typischen Bahn weg. Die gestrichelte Linie zeigt die Bahn, die das Schiff auf Grund des Winds tatsächlich fährt.

Der Einfluss des Seegangs auf das Schiffsverhalten ist komplexer als der Windeinfluss. Bevor das eigentliche Verhalten der Schiffe beeinflusst wird, verändert der Seegang zunächst wie sich das Schiff weiter fortbewegt. Je nachdem wie stark der Seegang ist, also wie hoch die Wellen sind, in welcher Frequenz und aus welcher Richtung die Wellen auf das Schiff treffen, bewegt sich das Schiff entlang einer oder mehrerer Bewegungsrichtungen, die auf Abbildung 30 (b) dargestellt sind. Der Einfluss kann in gefährliche Schiffsbewegungen, wie beispielsweise synchrones oder parametrisches Rollen des Schiffes, resultieren (International Maritime Organization 2007). Hierdurch kann sich das Schiff also so aufschaukeln, dass beispielsweise Container über Bord gehen. Im schlimmsten Fall kippt das Schiff um.

Um diese Situationen zu vermeiden ist das nautische Personal dazu angehalten während der Reise die meteorologischen und ozeanographischen Bedingungen kontinuierlich zu beobachten. Wenn sich für die Besatzung Indizien ergeben, die auf einen gefährlichen Seegang hinweisen, so müssen sie das Schiff so steuern, dass die Gefahren minimiert werden (Berking und Brauner 2010; International Maritime Organization 2007).

In diesem Kontext hat sich in der Wissenschaft das Forschungsgebiet des Wetter routings (engl. Ship Weather Routing) etabliert. Ziel der Forschungsarbeiten ist es, wirtschaftlich optimierte Rou-

ten zwischen einem Start- und Zielhafen unter Berücksichtigung meteorologischer und ozeanographischer Bedingungen zu generieren (Zis, Psaraftis und Ding 2020). Zis et al. (Zis, Psaraftis und Ding 2020) geben in ihrer Arbeit einen vollumfänglichen Überblick über den Stand der Wissenschaft in diesem Forschungsgebiet. In ihrer Arbeit ist darüber hinaus ein Vergleich kommerzieller Werkzeuge für das Wetterrouting zu finden. Laut Zis et al. (Zis, Psaraftis und Ding 2020) nutzen sowohl die kommerziellen Werkzeuge als auch die Forschungsarbeiten Wind- und Welleninformationen im Rahmen der jeweiligen Routenplanung.

Aus dieser praxisnahen Betrachtung für die Reiseplanung, -durchführung und -überwachung können die meteorologischen und ozeanographischen Parameter, die im Rahmen dieser Arbeit verwendet werden sollen, abgeleitet werden. Sowohl die Empfehlung der IMO (International Maritime Organization 2007; 1999) kommerzielle Werkzeuge zur Reiseplanung (Zis, Psaraftis und Ding 2020) als auch wissenschaftliche Arbeiten zum Thema Wetterrouting (Zis, Psaraftis und Ding 2020) berücksichtigen Wind- und Welleninformationen. Diese Informationen sind ein Einflussfaktor bei der Entstehung von konkretem Schiffsverhalten. Folglich werden in dieser Arbeit Wind-, Wellen- und Tideinformationen bei der Extraktion typischer Verkehrsmuster sowie bei einer anschließenden Prädiktion berücksichtigt.

4.3 Extraktion kontextsensitive Bewegungsmuster

Für die Extraktion der Bewegungsmuster wird zunächst das küstennahe Seegebiet in ein Gitter unterteilt. Als Orientierung für die Gittererstellung werden die Wasserstraßen, genauer gesagt die dazugehörige Betonung, im Seegebiet genutzt. Auf Abbildung 31 ist das Prinzip der Gittereinteilung dargestellt.




Abbildung 31: (a) Die geografischen Positionen der lateralen Tonnen (eingekreist in orange) dienen als Grundlage zur Modellierung des Seegebiets als Gitter (b).

Abbildung 31 (a) zeigt einen Ausschnitt einer digitalen Seekarte, auf der rote und grüne Tonnen die Wasserstraße definieren. Auf Abbildung 31 (b) ist die Seestraße entsprechend der eingangs skizzierter Idee modelliert. Zunächst werden die Tonnen auf jeder Seite aufsteigend nummeriert, wobei die grünen Tonnen mit bs_n und die roten Tonnen mit bp_n gekennzeichnet werden. Eine Zelle c_n setzt sich immer aus den vier Tonnen $bp_n, bp_{n+1}, bs_n, bs_{n+1}$ zusammen. Darüber hinaus wird von jeder Tonne ihre geografische Position verwendet, um eine entsprechende Datenstruktur aufzubauen.

Das entstandene Gitter besteht aus Zellen, die sich in ihrer Form und Größe unterscheiden, da sich sowohl benachbarte als auch gegenüberliegende Tonnen in Bezug auf ihre geografischen Positionen nicht immer auf einer Linie befinden. Anzumerken ist ebenfalls, dass Kurven von Wasserstraßen durch diesen Modellierungsansatz eher als Trapez geformt sind.

Für die Verkehrsmusterextraktion bietet dieses Konzept den Vorteil, dass die Komplexität des Problems reduziert wird. So können zunächst typische Verhaltensmuster je Zelle extrahiert werden. In ihrer Gesamtheit repräsentieren diese Muster das typische Verhalten durch das gesamte Gitter ab.

Damit dies funktioniert, müssen allerdings historische Schiffsbewegungsdaten in Relation zu den jeweiligen Gitterzellen gesetzt werden. Dabei gilt folgende Annahme: Schiffe bewegen sich innerhalb einer Zelle auf einer Ideallinie. Die Ideallinie ist die kürzeste Verbindung zwischen zwei benachbarten Zellen. Die Annahme basiert auf dem Wirtschaftlichkeitsgrundsatz, der im Rahmen der Routenplanung vom nautischen Personal zu berücksichtigen ist (Berking und Brauner 2010; International Maritime Organization 1999). Da in Wasserstraßen zu jeder Zeit eine Minimaltiefe vorherrscht, können Schiffe mit einem entsprechenden Tiefgang sicher in der Wasserstraße navigieren. Eine wirtschaftliche Route ist eine direkte Verbindung zwischen zwei Punkten, was auf Zellbasis dem kürzesten Weg durch die Zelle entspricht. Dem Gedanken folgend, verhalten sich Schiffe innerhalb einer Zelle linear. Die sequenzielle Aneinanderreihung des linearen Schiffsverhalten ergibt das Gesamtverhalten eines Schiffes durch das Gitter.

Die Art und Weise wie Schiffsverhalten extrahiert und modelliert wird, wird einen direkten Einfluss auf die Prädiktionmethode und -güte haben. Aus diesem Grund wird Modellierungsmethode im Rahmen einer Vorstudie überprüft. Im Folgenden wird die Vorstudie beschrieben, gefolgt von einer anschließenden Darstellung und Diskussion der Ergebnisse.

4.3.1 Vorstudie der gitterbasierten Verkehrsmustermodellierung und Prädiktion

Der Betrachtungsraum für die Vorstudie ist die Wasserstraße der Elbe, die von Hamburg in die Nordsee führt. Die Abbiegung der Wasserstraße in Richtung Nord-Ostsee-Kanal wird dabei nicht mitberücksichtigt.

Modellierung der Wasserstraße als Gitter

Das oben beschriebene Verfahren zur Gitterbildung unter Nutzung der geografischen Positionen der Betonung ergibt das Gitter, welches auf Abbildung 32 dargestellt ist. Bei der Betrachtung der Abbildung wird die oben beschriebene Heterogenität der Zellformen deutlich. Insbesondere in den Kurvenbereichen und den langen Geraden wird dies deutlich.




Abbildung 32: Ein Ausschnitt der in die Gitterstruktur unterteilte Wasserstraße der Elbe.

Extraktion von typischem Schiffsverhalten

Als nächstes wird typisches Schiffsverhalten innerhalb der Gitterstruktur extrahiert. Hierfür werden historische AIS-Nachrichten verwendet. Abbildung 33 zeigt die Datenbasis, wobei die Fahrtrichtung der Schiffe mit lila (zur See fahrend) und blau (von der See kommend) unterschieden wird.



Abbildung 33: Die für die Machbarkeitsstudie verwendete Datenbasis, bestehend aus AIS-Nachrichten. Bei den AIS-Nachrichten werden Schiffe unterschieden, die in Richtung See fahren (lila) und die von der See kommend sind (blau).

Die Charakteristiken der Datenbasis werden in Tabelle 5 zusammengefasst.

Tabelle 5: Kennzahlen zur verwendeten Datengrundlage der Machbarkeitsstudie

Kategorie	Ausprägung
Erste AIS-Nachricht	2018-08-01 14:11 Uhr
Letzte AIS-Nachricht	2018-10-22 02:45 Uhr
Betrachteter Schiffstyp	GeneralCargo
Berücksichtigte Schiffslängen (in Meter)	120-400
Anzahl der Bahnen	653
Davon zur See fahrend	316
Davon von der See kommend	337
Durchschnittliche Fahrtdauer (in Stunden)	2:35
Längste Fahrtdauer (in Stunden)	3:31
Kürzeste Fahrtdauer (in Stunden)	1:52

Für die Machbarkeitsstudie wurden AIS-Daten von *General Cargo*-Schiffen genutzt, deren Länge zwischen 120 und 400 Metern ist. Insgesamt besteht die Datenbasis aus 653 historischen Schiffsbahnen, die den Zeitraum vom 01.08.2018 bis zum 22.10.2018 abdecken. Eine Schiffsbahn besteht dabei aus fusionierten dynamischen und statischen AIS-Nachrichten, die von Schiffen während einer Reise gesendet werden. 316 Bahnen verlaufen dabei von der Elbe in Richtung Nordsee, 337 Schiffsbahnen in die entgegengesetzte Richtung (von der Nordsee kommend und durch die Elbe). Im Mittel sind die Schiffsbahnen 2:35 Stunden lang, wobei die längste Fahrtzeit 3:31 Stunden und die kürzeste Fahrtzeit 1:52 Stunden betragen.

In Abhängigkeit der jeweiligen Zelle wird die Ideallinie der Schiffe berechnet. Um Verhaltensschwankungen entlang der Ideallinie zu berücksichtigen, wird die Ideallinie als Korridor modelliert. Da die Ideallinie abhängig von der Fahrtrichtung der Schiffe ist, wird es je Zelle zwei Korridore in Abhängigkeit der Fahrtrichtung geben. Im Folgenden werden diese Korridore deshalb *direktionale Korridore* genannt. Das Konzept der *direktionalen Korridore* ist auf Abbildung 34 für zwei Schiffe skizziert.




Abbildung 34: COG, SOG und d_{star} als Parameter, aus denen sich Schiffsverhalten in einer jeden Zellen zusammensetzt.

Ein direktionaler Korridor bildet das Gebiet je Fahrtrichtung innerhalb einer Zelle ab, in dem sich 90% der Schiffe bewegen. Wie oben beschrieben, wird das Verhalten durch den Erwartungswert für den Kurs (COG), die Geschwindigkeit (SOG) und dem Parameter d_{star} in einem Korridor modelliert. Der Parameter d_{star} beschreibt die Distanz zwischen dem jeweiligen Schiff und dem Rand der Wasserstraße zur rechten Seite des Schiffes, womit der Gedanke der Idealline berücksichtigt werden soll.

Zur Verkehrsmusterextraktion werden zunächst die AIS-Daten den jeweiligen Zellen auf Basis der Positionsangaben zugeordnet. Auf Basis des COGs der Schiffe können die direktionalen Korridore berechnet werden. Anschließend werden die Daten in jedem direktionalen Korridor genutzt, um mittels Kerndichteschätzung je eine Wahrscheinlichkeitsdichtefunktion für den Parameter COG, SOG und d_{star} zu berechnen. Als letzter Schritt der Verkehrsmusterextraktion werden die Erwartungswerte für die drei Parameter aus den Wahrscheinlichkeitsdichtefunktionen je direktonalem Korridor bestimmt.

Prädiktion des wahrscheinlichsten Verhaltens

Auf Basis des extrahierten Verhaltens kann das wahrscheinlichste Schiffverhalten durch die Wasserstraße prädiziert werden. Auf Abbildung 35 ist die Logik zur Verhaltensprädiktion abgebildet.




Abbildung 35: Das Verhalten wird prädiziert, indem die Erwartungswerte für die Parameter COG, SOG und d_{star} sequenziell aneinandergereiht werden.

Ausgehend von der aktuellen Zelle C_1 , in der sich das Schiff befindet, werden die Erwartungswerte für die Parameter COG, SOG und d_{star} genutzt, um die Teilbahn durch Zelle C_2 zu prädizieren. Dieses Vorgehen wird so lange wiederholt, bis die letzte Zelle C_n betrachtet wird. Abschließend erhält man durch die sequenzielle Aneinanderreihung aller Teilbahnen der Zellen $C_1 \dots C_n$ die Gesamtprädiktion durch die Wasserstraße.

Evaluation der Vorstudie

Die oben beschriebene Datengrundlage wird für die Evaluation zufallsbasiert im Verhältnis 70:30 unterteilt. 70% der Schiffsbahnen werden für die Extraktion der Verhaltensmuster verwendet, wohingegen die verbleibenden 30% als Testdaten zur eigentlichen Prädiktion und somit zur Evaluation genutzt werden. Um die Prädiktionsgüte zu beurteilen, wird die Differenz zwischen dem prädizierten und tatsächlichen Werten für COG, SOG und d_{star} berechnet. Die Ergebnisse sind in Tabelle 6 zu sehen. Hier ist der Mittelwert (\bar{X}) Median (\tilde{x}), die Standardabweichung (σ) und der Root Mean Square Error (RMSE) für die einzelnen Parameter aufgeführt. Der RMSE ist ein Standardmaß zur Bewertung der Prädiktionsgüte.

Tabelle 6: Gemessene Prädiktionsgüte in der Vorstudie.

Kategorie	RMSE	\bar{X}	\tilde{x}	σ
Δ SOG (in Knoten)	3,24	2,58	1,54	2,19
Δ COG (in Grad)	12,51	8,64	5,44	8,99
Δ d _{star} (in Meter)	88,49	68,94	56,20	55,14

Bei der Betrachtung des RMSE wird deutlich, dass die Prädiktion von d_{star} den größten Fehler (88,49 Metern) aufweist. Den geringsten Prädiktionsfehler weist die SOG-Prädiktion auf (3,24 Knoten), gefolgt von der COG-Prädiktion (12,51 Grad). Um den Prädiktionsfehler einzuordnen, hilft eine vergleichende Betrachtung zwischen der Standardabweichung und dem RMSE. Bei allen drei Parametern liegt der Prädiktionsfehler über der Standardabweichung, bei d_{star} sogar deutlich.

Diskussion der Ergebnisse

Um den hohen Prädiktionsfehler zu erklären, lohnt es sich nochmals das verwendete Prädiktionsverfahren zu betrachten. Die Modellierung des Verhaltens mittels direktonaler Korridore und den Erwartungswerten der Parameter SOG, COG und d_{star} abstrahiert das Verhalten als lineare Bewegung in einer Zelle. Die anschließende Prädiktion ist eine Aneinanderreihung der linearen Bewegung innerhalb der Zellen. Die Schwächen dieser Modellierungs- und Prädiktionsmethode werden offensichtlich, sobald man die extrahierten Korridore und Prädiktionen in den Kurven der Wasserstraßen betrachtet.

Auf Abbildung 36 sind vier Kurvenbereiche der modellierten Wasserstraße exemplarisch dargestellt. Die direktonalen Korridore sind je nach Fahrtrichtung gefärbt (blau zur See fahrend, lila von See kommend).




Abbildung 36: Vier Beispiele, bei denen große Abweichungen zwischen den direktionalen Korridoren benachbarter Zellen zu erkennen sind.

Es ist zu erkennen, dass beim Zellübergang zwischen den Kurven zum Teil ein großer Versatz zwischen den direktionalen Korridoren vorhanden ist. Darüber hinaus sind Überlappungen der Korridore zwischen Zellen feststellbar. Diese Eigenschaften haben wiederum eine direkte Auswirkung auf die Prädiktion des wahrscheinlichsten Schiffverhaltens.

Auf Abbildung 37 ist exemplarisch die Prädiktion einer Schiffsbahn aus der Vorstudie dargestellt. Die roten Datenpunkte sind dabei die tatsächlichen Positionsdaten des Schiffes, in blau ist die zellweise prädiizierte Schiffsbahn dargestellt. Die betrachtete Bahn verläuft dabei zur See fahrend in Richtung Westen.




Abbildung 37: Vergleich einer prädiizierten und tatsächlichen Schiffsbahn mit dem oben beschriebenen Prädiktionsvorgehen (Steidel, Mentjes und Hahn 2020).

Auf der linken Seite ist die globale Ansicht zwischen Prädiktion und tatsächlicher Bahn dargestellt. In dieser Detaillierungsstufe sind wenig Diskrepanzen feststellbar. Betrachtet man allerdings eine

Kurve im Detail (rechte Seite), so zeigt sich das oben beschriebene Problem der Modellierungs- und Prädiktionmethode in den Daten deutlich. Der bereits bei den direktionalen Korridoren identifizierte Versatz zwischen benachbarten Zellen spiegelt sich bei der prädizierten Bahn in Form eines Zickzack-Muster wider.

Somit ist die Abstraktion von Schiffsverhalten innerhalb der Zelle als strikte lineare Bewegung nicht geeignet, um Kurvenbereiche adäquat zu modellieren und für die Prädiktion zu nutzen. Die Unterteilung des Problems in Teilprobleme, die über die direktionalen Korridore gelöst werden sollten, abstrahieren den Gedanken der Idealline zu weit. Vielmehr scheint es so zu sein, dass die Schiffe Kurven als Ganzes schneiden, um den Weg möglichst zu verkürzen. Eine adäquate Verhaltensprädiktion in Kurvenbereichen ist mit diesem Vorgehen somit nicht möglich. Folgende Schlussfolgerungen können aus der Vorstudie abgeleitet und zur Konzeptanpassung genutzt werden.

Verhalten in Zelle n hängt vom Verhalten in Zelle $n - 1$ ab

Das Schiffsverhalten einer Zelle korreliert mit dem Verhalten in der vorherigen Zelle. Sowohl Abbildung 36 als auch Abbildung 37 unterstützt diese Erkenntnis. Offensichtlich ist diese Tatsache in den Kurvenbereichen einer Wasserstraße. Schneidet ein Schiff beispielsweise die Kurve sehr eng, wird es die Fahrt durch die Zelle wahrscheinlich mit einem sehr geringen Abstand zum Wasserstraßenrand fortsetzen. Eine Verkehrsmustermodellierung, die auf linear abstrahierten direktionalen Korridoren basiert, kann solche Variationen nicht abbilden. Hinzu kommt, dass die Verhaltensprädiktion als sequenzielle Aneinanderreihung der Erwartungswerte solche Variationen ebenfalls nicht berücksichtigen kann.

Je mehr Informationen berücksichtigt werden, desto mehr und spezifischere Normalmodelle entstehen

Wie weiter oben eingeführt, lassen sowohl der Typ als auch die Dimension eines Schiffes Rückschlüsse auf die hydrodynamischen Eigenschaften zu. Im Rahmen der Vorstudie wurden nur Schiffe des Typs *GeneralCargo* mit einer Länge zwischen 120 und 400 Metern berücksichtigt. Wenn die genutzte Datenbasis allerdings größer ist und zusätzliche Schiffstypen mit unterschiedlichen Dimensionen enthält, so wären zunächst für jeden Schiffstyp Schiffsklassen zu bilden, deren Einteilung auf der Schiffslänge basiert. Für jede Schiffsklasse eines Schiffstyp müsste anschließend ein Normalmodell gebildet werden.

Wenn meteorologische und ozeanographische Informationen berücksichtigt werden sollen, würde dies ebenfalls die Bildung von sogenannten Wetterklassen voraussetzen. Infolgedessen

müsste für jede Wetterklasse und jeden Schiffstyp einer Schiffsklasse ein entsprechendes Normalmodell erstellt werden.

Für eine anschließende Prädiktion, die die unterschiedlichen Normalmodelle nutzen soll, müsste ein zusätzlicher Schritt eingeführt werden. Zu Beginn wäre demnach zu prüfen, welche Wetterbedingungen zum Zeitpunkt der Prädiktion vorherrschen und welcher Wetterklasse sie zuzuordnen sind. Gleiches gilt für die Schiffsklasse. Das so ausgewählte Normalmodell würde anschließend zur Prädiktion genutzt werden.

4.3.2 Verhaltensmodellierung durch Übergangspunkte

Die Vorstudie hat gezeigt, dass eine diskretisierte Verkehrsmusterextraktion, -modellierung und Verhaltensprädiktion mit einem gitterbasierten Ansatz unzureichende Prädiktionsergebnisse liefert. Insbesondere die sequenzielle Aneinanderreihung der Teilprädiktionen sorgt in Kurvenbereichen für einen großen Prädiktionsfehler. Eine weitere Schwäche dieses Ansatzes ist, dass Abzweigungen und Kreuzungen in Wasserstraßen nicht modelliert werden können. Genauer gesagt kann nicht prädiziert werden, welche Abbiegung das Schiff nehmen könnte.

Die Schlussfolgerung ist, dass insbesondere die Prädiktion kontinuierlich über mehrere Zellen vorhersagen muss. Zusätzlich muss ein Ansatz gefunden werden, wie Abbiegeverhalten in Wasserstraßen modelliert und prädiziert werden kann.

Die dafür notwendige Anpassung der Modellierungsmethode ist die Abkehr der richtungsbezogenen Bewegungskorridore innerhalb der Zelle, da dieses Konzept die Verhaltensmodellierung zu sehr diskretisiert. Sie werden durch sogenannten Übergangspunkte (im Folgenden TP_n für engl. Transition Points) ersetzt, deren Idee auf Abbildung 38 skizziert ist.




Abbildung 38: Ein Übergangspunkt TP_n ist der geografische Schnittpunkt einer Schiffsbahn mit der vertikalen Zellengrenze.

Ein Übergangspunkt TP_n ist der geographische Schnittpunkt, an dem sich eine Schiffsbahn mit einer Zellgrenze schneidet. Aus Abbildung 38 geht eine weitere Eigenschaft der Übergangspunkte hervor: Übergangspunkte sind spezifisch in Bezug auf eine Schiffsbahn. Jede der zwei Schiffsbahnen auf der Abbildung (blau und orange) hat eine Sequenz an einzigartigen Übergangspunkten. Somit setzt sich eine Schiffsbahn Sb durch eine Sequenz von spezifischen Übergangspunkten zusammen. Folglich gilt Sb :

$$Sb = \{TP_n \dots TP_{n+m}\}. \quad (2)$$

Aus Abbildung 38 wird darüber hinaus die Taxonomie der Nummerierung deutlich. Die Nummer eines Übergangspunkts TP_n entspricht der Zellnummer c_n , sodass eine eindeutige Zuordnung vorgenommen werden kann.

Ein Übergangspunkt TP_n setzt sich dabei aus schiffsspezifischen, meteorologischen und ozeanographischen Daten zusammen. TP_n ist dabei durch den folgenden Vektor definiert:

$$TP_n = \begin{bmatrix} \beta \\ SOG \\ d_{starboard} \\ m \\ o \end{bmatrix}. \quad (3)$$

Die Parameter m und o stehen dabei für die jeweils gültigen meteorologischen und ozeanographischen Informationen. Die Zusammensetzung der schiffsspezifischen Parameter ist auf Abbildung 39 dargestellt.




Abbildung 39: Die schiffsspezifischen Parameter am Übergangspunkt TP_n .

Die Fahrt über Grund (SOG) eines Schiffes soll Aufschluss darüber geben, ob das Schiff bei Kreuzungen und Verzweigungen Abbiegen wird. Aus der Vorstudie ist der Grundgedanke des Parameters d_{star} übernommen worden. Die Distanz zum Fahrbahnrand kann zum einen ebenfalls ein Indikator dafür sein, ob das Schiff eine Abzweigung nehmen wird. Zum anderen kann dieser Parameter darauf hindeuten, wie das Schiff beispielsweise eine Kurve durchfahren (z.B. eng schneiden oder weiter Außen) wird. Der dritte schiffsspezifische Parameter ist β , der mithilfe des Schiffskurses (COG) berechnet wird. Hierfür wird die Differenz vom COG und der Peilung der unteren Tonne einer Zelle zur oberen Tonne berechnet. Somit beschreibt der Parameter β die relative Ausrichtung des Schiffes in Relation zur Zelle beim Einfahren in diese Zelle. In Kombination mit der Fahrt über Grund und der Distanz zum Fahrbahnrand soll die Ausprägung von β ebenfalls ein Indikator für den nachfolgenden Übergangspunkt geben.

4.3.3 Kombination historischer Wetter- und Schiffsbewegungsdaten

Neben topologische Faktoren, wie beispielsweise Wasserstraßen, wird Schiffsverhalten maßgeblich von den vorherrschenden meteorologischen und ozeanographischen Bedingungen beeinflusst. Das nautische Personal ist verpflichtet, während der Planung und Durchführung einer Seereise, auf diese Bedingungen zu achten und die Fahrt entsprechend anzupassen (Berking und Brauner 2010; International Maritime Organization 2007; 1999).

Folglich gilt für diese Arbeit die These, dass prädiziertes Schiffsverhalten durch die Berücksichtigung von meteorologischen und ozeanographischen Informationen präziser wird. Damit dies ganzheitlich geschehen kann, müssen die historischen Schiffsbewegungsdaten schon vor der Musterextraktion mit den dazugehörigen meteorologischen und ozeanographischen Daten kombiniert werden. Die anschließend entstehenden Muster sind folglich wetterabhängig und liefern entsprechende Prädiktionsergebnisse. Wie in Abschnitt 4.2.2 hergeleitet, werden in dieser Arbeit historische Wind-, Wellen- und Tideninformationen genutzt.

Historische Wind- und Wellendaten sind hochdimensionale Daten. Wind- und Wellen sind dabei Phänomene, die kontinuierlich sind und sich nicht auf einen geografischen Punkt festgelegt werden können. Wie oben eingeführt, sind einzelne Beobachtungsdaten die Grundlage für komplexe Computermodelle, die die Ausbreitung über eine größere Fläche berechnen. Um mit diesen hochdimensionalen Daten umgehen zu können, werden historische Wind- und Wellendaten gitterbasiert gespeichert. Auf Abbildung 40 ist ein Ausschnitt von historischen Wellendaten zu sehen. Die dargestellten Daten basieren auf einem numerischen Wellenmodell, was auf Basis von diskreten Beobachtungsdaten ein kontinuierliches Modell berechnen kann.




Abbildung 40: Historische Daten zur signifikanten Wellenhöhe in der Deutschen Bucht, basierend auf einem numerischen Wellenmodell.

Auf der Abbildung ist die signifikante Wellenhöhe für die Deutsche Bucht dargestellt. Das Gebiet ist dabei in ein Gitter unterteilt, deren Zellen eine Größe von $0,014^\circ$ mal $0,03^\circ$ haben und stündlich zeitlich aufgelöst sind (European Union-Copernicus Marine Service 2019). Die Daten stammen aus Copernicus, dem Erdbeobachtungsprogramm der Europäischen Kommission. Die durch Satelliten- oder in situ Messungen gesammelten Daten, unter anderem Wind- und Wellendaten, sind für wissenschaftliche Zwecke frei zugänglich (European Commission 2015). Winddaten sind in Copernicus beispielsweise anders zeitlich und räumlich aufgelöst als Wellendaten. Die für die Deutsche Bucht verfügbaren Winddaten auf See basieren auf Satellitenbeobachtungen mit einer Auflösung von $0,25^\circ$ mal $0,25^\circ$. Für jede Zelle ist die durchschnittliche Windrichtung und -geschwindigkeit für einen Zeitraum von sechs Stunden verfügbar (European Union-Copernicus Marine Service 2022).

Um Wind- und Wellendaten während der Musterextraktion und der Prädiktion zu berücksichtigen, müssen sie mit historischen Schiffsbewegungsdaten kombiniert werden. Für den Fall, dass historische AIS-Daten als historische Schiffsbewegungsdaten verwendet werden sollen, können die

zeitlichen und geographischen Parameter der AIS-Nachrichten zur Kombination genutzt werden. Die grundsätzliche Logik hinter der Kombination ist auf Abbildung 41 dargestellt.

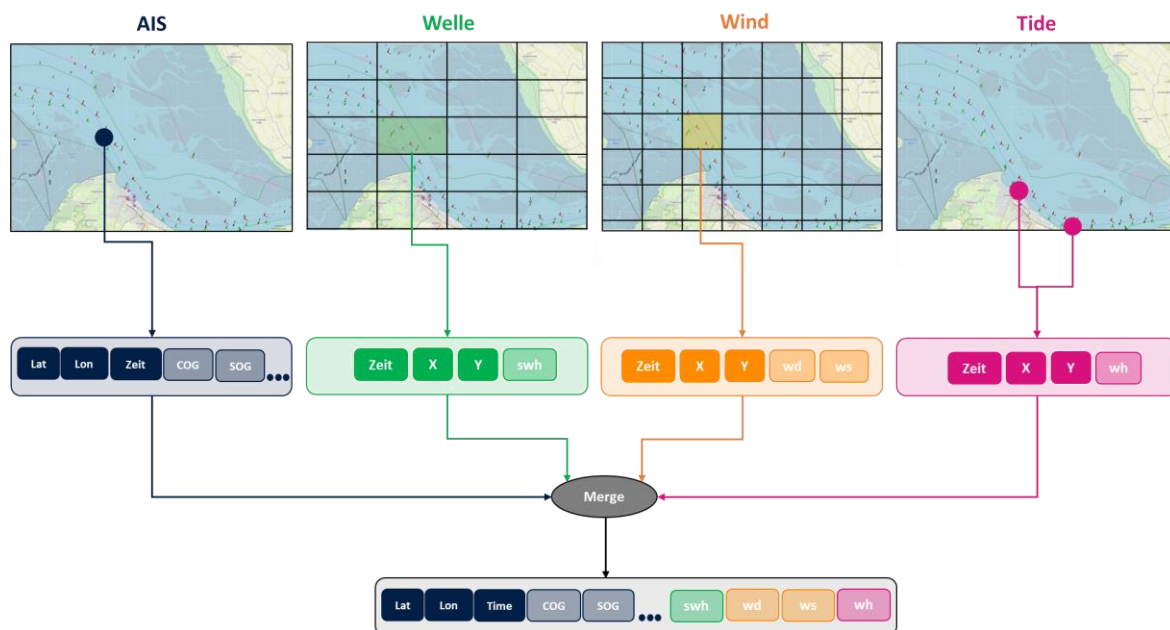


Abbildung 41: Kombination von historischen AIS, Wind- und Wellendaten über die zeitlichen und räumlichen Eigenschaften der jeweiligen Datensätze.

Da Wind- und Wellendaten in Gittern gespeichert werden, deren geographische Auflösung unterschiedlich sein kann, sind die zeitlichen und geographischen Informationen aus AIS-Daten die Grundlage für die Kombination der Daten. Zunächst wird basierend auf dem Zeitstempel der AIS-Nachricht der passende Datensatz für Wind und Wellen gewählt. Anschließend wird die geographische Position aus den AIS-Daten genutzt, um die jeweilige Zelle in den Wind- und Wellendaten zu finden, die die Position beinhaltet. Die relevanten Informationen zur signifikanten Wellenhöhe und, zur Windrichtung und -geschwindigkeit werden im Anschluss mit der betrachteten AIS-Nachricht kombiniert.

Konträr dazu stehen Tideinformationen als Beobachtungspunkte zur Verfügung, wobei die Beobachtungen stationär gemessen werden. Das bedeutet, dass für ein Fahrwasser, je nach Verfügbarkeit, mehrere Messdaten mit dem AIS-Datensatz kombiniert werden. Somit ist eine entsprechende Selektion sowohl in Bezug auf die räumliche Ausprägung der AIS-Daten als auch auf den Verlauf der Wasserstraßen zu vollziehen. Die eigentliche Kombination der Daten geschieht durch den Abgleich der räumlichen und zeitlichen Attribute der Messstationen und der AIS-Daten. Als Ergebnis erhält man den AIS-Datensatz, der um Wind- und Welleninformation erweitert wurde.

4.3.4 Long Short-Term Memory Netze zur Prädiktion

Die Änderung der Modellierung einer Schiffsbahn mittels Übergangspunkte zieht die Neuinterpretation des Prädiktionsproblems nach sich: Im Folgenden wird die Verhaltensprädiktion als Problem zur Vorhersage einer Sequenz von Übergangspunkten interpretiert. Auf Abbildung 42 ist die Lösungsidee skizziert.




Abbildung 42: Exemplarische Abbildung der sequenziellen Prädiktion von Übergangspunkten unter Berücksichtigung von drei vorherigen Übergangspunkten

Prädiziert werden soll die Schiffsbahn $Sb = \{TP_3 \dots TP_n\}$, wobei die Übergangspunkte als Menge $V = \{TP_0, TP_1, TP_2\}$ gegeben sind. Folglich wird vorheriges Verhalten berücksichtigt und gleichzeitig ergibt sich für die Lösung des Problems die Kondition, dass eine Menge (≥ 0) an Übergangspunkte gegeben sein muss, damit das zukünftige Verhalten prädiziert werden kann.

Folglich wird auf Abbildung 42 TP_3 unter Berücksichtigung von V und der jeweiligen Attribute der einzelnen Übergangspunkte prädiziert. Anschließend wird V dahingehend geändert, dass der älteste Übergangspunkt aus der Menge entfernt wird und der prädizierte Übergangspunkt in die Menge aufgenommen wird. Diese Prozedur wird so lange iterativ wiederholt, bis TP_n prädiziert wurde.

Es handelt sich somit um ein Regressionsproblem einer Zeitreihe. Folgende Fragestellung fasst das vorliegende Regressionsproblem zusammen:

Wie können aus einer gegebenen und unvollständigen Sequenz an Übergangspunkten die zukünftigen Übergangspunkte prädiziert werden?

Zur Lösung dieses Problem soll ein Long-Short Term Memory Netzen (LSTM) verwendet werden. Wie in Abschnitt 2.4 diskutiert, sind LSTM-Netze eine Sonderform von rekurrenten neuronalen Netzen, die im Wesentlichen die Berücksichtigung bekannter Informationen im Trainingsprozess ermöglichen. Durch die spezielle Struktur der Neuronen von LSTM-Netzen können diese jedoch,

verglichen mit einem RNN, besser mit längeren Sequenzen umgehen. Während des Trainings kommen zur Sequenz immer mehr Datenpunkte hinzu. Je länger eine Sequenz wird, desto mehr Daten werden über die Zeit von einem RNN vergessen. Dieses Phänomen wird als verschwindender Gradient bezeichnet und ist auf die verwendete Aktivierungsfunktion, beziehungsweise ihrer Ableitung, zurückzuführen. Bei RNN wird der Tangens hyperbolicus (\tanh) als Ableitungsfunktion genutzt. Formel (4) zeigt \tanh .

$$f(x) = 1 - \frac{2}{e^{2x} + 1} \quad (4)$$

Während des Lernens werden die Werte mit der Ableitung der Aktivierungsfunktion multipliziert. Eine Multiplikation mit der Ableitung von \tanh ergibt stets einen Wert zwischen 0 und 1. Je länger die Trainingssequenz wird, desto kleiner werden die Werte aufgrund der fortlaufenden Multiplikation. Ab einer gewissen Länge der Trainingssequenz tendieren die Werte gegen 0, sodass der Unterschied zwischen einem Wert und seinem Nachfolger sehr klein ist. Dies ist der Punkt, ab dem kein Lernfortschritt mehr mit einem RNN erreicht werden kann (Graves 2012a; Nwankpa et al. 2018).

Im Vergleich zum \tanh als Aktivierungsfunktion erreichen neuronale Netze, die die Rectified Linear Unit (ReLU, Formel (5)) als Aktivierungsfunktion nutzen, besser Ergebnisse (Dahl, Sainath und Hinton 2013; Nwankpa et al. 2018; Zeiler et al. 2013). Konträr zu \tanh ist ReLU eine lineare Aktivierungsfunktion, deren Einsatz als Aktivierungsfunktion in der Arbeit von Nair und Hinton vorgeschlagen wurde (Nair und Hinton 2010).

$$f(x) = \begin{cases} 0, & \text{wenn } x < 0 \\ x, & \text{wenn } x \geq 0 \end{cases} \quad (5)$$

Die grundlegende Funktion von ReLU ist eine Schwellenwertprüfung. Nach der Multiplikation wird geprüft, ob die Werte kleiner als 0 sind. Ist dies der Fall, so wird der Wert auf 0 gesetzt, andernfalls wird der Wert von ReLU übernommen. Die Idee ist, dass mit dieser Schwellenwertoperation das Auftreten immer kleiner werdender Werte vermieden werden soll, was das Problem des verschwindenden Gradienten adressiert.

Zur Lösung des oben formulierten Regressionsproblems soll ein LSTM-Netz typische Bewegungsmuster aus gegebenen historischen Übergangspunkten lernen: Die Übergangspunkte werden aus historischen Schiffsbahnen extrahiert und durch die oben eingeführten Parameter definiert. Die Übergangspunkte sind dabei spezifisch für das in dieser Arbeit verwendete Gittermodell. Aus

einer Sequenz von Übergangspunkten $x = \{TP_0, \dots, TP_n\}$ wird eine Subsequenz mit k Elementen (wobei $k < n$) extrahiert, sodass sich die Trainingssequenz $z = \{TP_i TP_{i+1}, \dots, TP_{i+k-1}\}$ ergibt. Mit der Trainingssequenz wird das LSTM-Netz trainiert, um den zukünftigen Übergangspunkt TP_{k+1} zu prädizieren. Dieses Verfahren wird so lange iterativ durchgeführt, bis der letztmögliche Übergangspunkt prädiziert wurde.

Es ist allerdings zu berücksichtigen, dass zu Beginn des Trainings keine geeigneten Werte für k bekannt sind. Hinzu kommt, dass konkrete Werte für die LSTM-spezifischen Hyperparameter selektiert werden müssen. Wie in Abschnitt 2.4 (Hyperparameteroptimierung) diskutiert, hat die Wahl geeigneter Werte für die Hyperparameter einen signifikanten Einfluss auf die trainierten Modelle. Aufgrund der Komplexität wird die Auswahl der Werte automatisiert durch einen dafür geeigneten Algorithmus geschehen (siehe Abschnitt 2.4): Hierfür wird Random Search verwendet, weil es einen guten Kompromiss zwischen Geschwindigkeit und Genauigkeit bietet.

Um zum einen die Güte unterschiedlicher Parameterkombinationen während der Hyperparameteroptimierung zu bewerten und zum anderen das trainierte Modell während des Lernprozesses zu bewerten, ist eine begleitende Validierung notwendig. Wie in Abschnitt 2.4 beschrieben, ist es zu diesem Zweck gängige Praxis die verfügbaren Daten in Test- und Trainingsdaten zu unterteilen. Hierfür soll die Monte Carlo Cross Validation (MCCV) als Verfahren genutzt werden. MCCV weist randomisiert Datensätze der Trainings- und Testdatenmenge zu. Für die Vorhersage von Zeitreihen ist das MCCV besser geeignet als die k -fache Kreuzvalidierung (siehe Abschnitt 2.4 und (Fonseca-Delgado und Gomez-Gil 2013)).

4.4 Anwendungsbezogenes Messen der Prädiktionsgüte

Zur Beurteilung einer Güte von Regressionsmodellen beziehungsweise einer Prädiktion, werden standardisierte Fehlermaße genutzt. Nach (Fahrmeir et al. 2016; Sammut und Webb 2010; Vogel 2015) haben sich in der Literatur die im Folgenden beschriebenen Verfahren etabliert.

Ein einfaches Fehlermaß ist der Mittlere Absolute Fehler (engl. Mean Absolute Error, MAE, Formel (6)), bei dem die Differenz zwischen der Prädiktion und dem tatsächlichen Wert berechnet wird. Anschließend wird der Mittelwert gebildet.

$$MAE = \frac{1}{n} \sum_{t=1}^n |\hat{y}_t - y_t| \quad (6)$$

Der Mittlere quadratische Fehler (engl. Mean Squared Error, MSE, Formel (7)) erweitert den MAE, indem die Differenz zwischen Prädiktion und tatsächlichem Wert quadriert wird. Durch die

Quadrierung der Fehler ergibt sich eine stärkere Gewichtung von hohen Abweichungen, die bei der Prädiktion auftreten. Wie aus Formel (7) zu entnehmen ist, entspricht dieses Fehlermaß der Varianz. Der MSE ist die Grundlage für die Berechnung des RMSE (Root Mean Squared Error, Formel (8)), bei dem die Wurzel des MSE berechnet wird und entspricht damit im weitesten Sinne der Berechnung der Standardabweichung der Prädiktionsfehler. In Kombination mit dem MAE hilft der RMSE folglich bei der Einordnung der Prädiktionsergebnisse.

$$MSE = \frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2 \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2} \quad (8)$$

Im Gegensatz zum einfachen und quadratischen Fehlermaß, zeigt der Mittlere prozentuale Fehler (MAPE, Formel (9)) die prozentuale Abweichung zwischen einem prädizierten Wert und dem tatsächlichen Wert. Mit dem MAPE wird folglich der relative Fehler zwischen einer Prädiktion und den tatsächlichen Werten aufgezeigt.

$$MAPE = 100 * \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{y}_t - y_t}{y_t} \right| \quad (9)$$

Normierte Fehlermaße, wie zum Beispiel der Determinationskoeffizient R^2 (Formel (10)), berechnen den Fehler in einem beschränkten Wertebereich zwischen 0 und 1. Die Stärke von normierten Fehlermaßen ist die einfache Interpretierbarkeit des Ergebnisses.

$$R^2 = \frac{(\sum_{t=1}^n (\hat{y}_t - \hat{\bar{y}}) * (y_t - \bar{y}))^2}{\sum_{t=1}^n (\hat{y}_t - \hat{\bar{y}})^2 * \sum_{t=1}^n (y_t - \bar{y})^2} \quad (10)$$

Der ex post Vergleich zwischen Prädiktion und tatsächlichem Wert als Gütemaß findet sich auch bei denen in Abschnitt 3.3.3 präsentierten Arbeiten wieder. Je nach Ansatz wird entweder der Fehler für einzelne prädizierte Positionen oder der Fehler in Abhängigkeit der Fahrtzeit (für prädizierte Bahnen) berechnet.

Eine Evaluation auf dieser Basis ermöglicht den direkten Vergleich zweier Prädiktionsmodelle zur Lösung des vorliegenden Problems. Wenn zwei Modelle mit dem gleichen Fehlermaß evaluiert werden, ist die Methode mit dem geringeren Fehlerwert präziser.

Dabei ist allerdings zu berücksichtigen, dass die Aussagekraft solcher Evaluationen in Bezug auf eine konkrete Praxisanwendung gering ist. Wird eine Prädiktion beispielsweise im Rahmen des

Verkehrsmanagements dazu genutzt, die Auslastung einer Wasserstraße zu bestimmten Zeiten vorherzusagen, so ist eine präzise Kursprädiktion nicht zwingend nötig. Vielmehr ist es für diesen Anwendungsfall wichtig, dass die Prädiktion den zeitlichen Ablauf der vorhergesagten Bahn möglichst genau approximieren kann.

Für diese Arbeit wurde in Abschnitt 1.3 als Anforderung definiert, dass die zu entwickelnde Prädiktionsmethode zur Kollisionsvermeidung eingesetzt werden kann. Wie bereits weiter oben eingeführt, ist die Kollisionsvermeidung eine kontinuierliche und vorausschauende Aufgabe, bei der Prädiktionsmethoden zum Einsatz kommen können. Grundsätzlich wird versucht vorherzusagen, wo es zu einer gefährlichen Schiff-zu-Schiff-Begegnung kommen kann. Für die Evaluation bedeutet dies, dass die Präzision nicht nur in Bezug auf eine vorhergesagte Position oder einen vorhergesagten Kurs bestimmt werden muss, sondern auch im Hinblick auf die Präzision zur Bestimmung des Kollisionsrisikos.

Aus diesem Grund werden im Folgenden zunächst bereits in der Literatur etablierte Methoden zur Kollisionsrisikobestimmung vorgestellt. Abschließend wird eine Methode ausgewählt, die zur Evaluation genutzt werden soll.

4.4.1 Methoden zur Bestimmung des Kollisionsrisikos

Xu und Wang (Xu und Wang 2014) teilen die existierenden Methoden zur Bestimmung des Kollisionsrisikos in die drei Blöcke *Traffic Flow Theory*, Schiffsdomänen und den Punkt der nächsten Annäherung (CPA) ein. Auf das Themenkomplex der CPA-Berechnung wird hier nicht mehr eingegangen. Die Details zu diesem Konzept wurden bereits in Abschnitt 1.1 beschrieben.

Im Rahmen der *Traffic Flow Theory* geht es darum, dass Begegnungs- und Gefährdungspotenzial auf Basis der Verkehrsdichte mittels statistischer Methoden zu bestimmen. Dabei wird die Wahrscheinlichkeit für Schiffsbegegnungen berechnet, die anschließend hinsichtlich des Gefährdungspotenzials bewertet werden (Xu und Wang 2014). Das in Abschnitt 3.3.1 beschriebene Tool IWARP ist ein Beispiel aus diesem Anwendungsbereich. Prädiktionsmethoden, die in diesem Kontext angewendet werden, müssen folglich möglichst zeitgenau vorhersagen können, wann Schiffe sich an welchen Positionen befinden werden. Für diese Arbeit ist die *Traffic Flow Theory* nicht relevant, da der oben beschriebene Ansatz schiffszentrisch ist und ein Ansatz zur Abkehr von linearen Bewegungsvektoren darstellt, der bis heute Stand der Technik ist. Eine gesamtumfassende Bewertung der Verkehrslage, so wie es bei der *Traffic Flow Theory* vorgesehen ist, ist mit dem entwickelten Konzept nicht vorgesehen und somit auch nicht möglich.

Das Konzept der Schiffsdomänen geht auf die Forschungsarbeiten von Fujii und Tanaka (Fujii und Tanaka 1971) zurück. Im Rahmen von Verkehrsbeobachtungen haben die Autoren erkannt, dass Schiffe immer einen bestimmten Bereich in ihrer unmittelbaren Umgebung frei von anderem

Verkehr halten. Diesen Bereich bezeichnen die Autoren als Schiffsdomäne und erarbeiteten das Konzept für eine elliptische Schiffsdomäne, die auf Abbildung 43 zu sehen ist.




Abbildung 43: Das Konzept der Schiffsdomäne nach Fujii und Tanaka (Fujii und Tanaka 1971). Links ist die Schiffsdomäne für offene See zu dargestellt, auf der rechten Seite für Wasserstraßen und Kanäle.

Die Größe der Schiffsdomäne korreliert mit der Länge des Schiffes, wodurch die hydrodynamischen Eigenschaften der Schiffe bei der Risikobewertung berücksichtigt werden können. Besonders große (also lange) Schiffe benötigen mehr Zeit zum Manövrieren als kleinere Schiffe. Entsprechend größer muss die Domäne sein. Darüber hinaus unterscheiden die Autoren bei der Berechnung der Domänengröße das Seegebiet, in dem die Schiffe unterwegs sind: die Schiffsdomänen für Reisen in offenen Gewässern sind größer als jene, deren Schiffe in beschränkten Gewässern, wie beispielsweise in Wasserstraßen, unterwegs sind (Fujii und Tanaka 1971).

Goodwin (Goodwin 1975) entwickelt den Grundgedanken der Schiffsdomäne weiter. Das Konzept ist auf Abbildung 44 (a) dargestellt. Die Schiffsdomäne ist demnach nicht mehr elliptisch, sondern kreisrund, wobei die Domäne in unterschiedlich große Sektoren eingeteilt ist. Diese Sektoren beziehen sich auf die COLREGs und den darin beschriebenen Regeln zur Auflösung kritischer Schiff-zu-Schiff-Begegnungen. So gilt beispielsweise bei Kreuzungssituationen rechts-vor-links. In Goodwins Schiffsdomäne ist der rechte Sektor entsprechend größer als der linke. Xu und Wang (Xu und Wang 2014) heben in ihrer Übersichtsarbeit nochmal hervor, dass diese Schiffsdomäne für die Kollisionsvermeidung besser geeignet ist als die Ellipse von Fujii und Tanakas (Fujii und Tanaka 1971).

Davis, Dove und Stockel (Davis, Dove und Stockel 1980; 1982) greifen den grundlegenden Gedanken von Goodwin in Bezug auf die Berücksichtigung der COLREGs auf (Abbildung 44 (b)) und konstruieren ebenfalls eine kreisrunde Schiffsdomäne. Der Unterschied zur Arbeit von Goodwin (Goodwin 1975) ist allerdings, dass die kreisrunde Domäne kontinuierlich ist, wodurch sie im Rahmen von Simulationen einfacher modelliert und genutzt werden kann (Davis, Dove und Stockel 1980; 1982; Xu und Wang 2014).




Abbildung 44: Runde und COLREG-konforme Schiffsdomänen. (a) diskontinuierliches Modell von (Goodwin 1975) und (b) kontinuierliches Modell von (Davis, Dove und Stockel 1980; 1982).

Darauf aufbauend haben sich immer komplexere Schiffsdomänen entwickelt, bei denen eine Abkehr von der kreisrunden Form zu beobachten ist. Gute Beispiele hierfür sind die Ansätze von Smierzchalski und Michalewicz (Smierzchalski und Michalewicz 2000) und Pietrzykowski (Pietrzykowski 2001), die auf Abbildung 45 gegenübergestellt sind.




Abbildung 45: (a) zeigt die hexagonale Schiffsdomäne nach Smierzchalski (Smierzchalski und Michalewicz 2000). (b) illustriert die polygonale Schiffsdomäne nach Pietrzykowski (Pietrzykowski 2001).

Die hexagonalen Schiffsdomänen können je nach Anwendungsgebiet, Schiffsgröße oder Risikobereitschaft unterschiedlich ausgebildet sein. Insbesondere bei Pietrzykowski (Pietrzykowski 2001) (Abbildung 45 b) ist dieser Gedanke zu sehen. Über den Parameter γ kann die Größe der jeweiligen Domänenbereiche individuell definiert werden. Auf diese Weise können unterschiedliche Sicherheitslevel implementiert und im Rahmen von Risikobewertungen berücksichtigt werden.

4.4.2 Zusammenfassung

Die eingangs vorgestellten Gütemaße zur Bewertung von Regressionsmodellen sind für den direkten Vergleich zwischen multiplen Regressionsmodellen geeignet. Insbesondere bei Zeitreihenanalysen, bei denen ein expliziter Punkt vorhergesagt werden soll, lassen sich mit den Fehlermaßen die Güte der Prädiktion bestimmen.

Für die Verhaltensprädiktion von Schiffen im Kontext der Kollisionsvermeidung sind diese Fehlermaße allerdings nur bedingt geeignet. Grundsätzlich kann bei der Betrachtung der Fehlermaße keine Aussage darüber getroffen werden, wie gut ein Prädiktionsmodell zur Kollisionsvermeidung eingesetzt werden kann. Hinzu kommt, dass Schiffsverhalten in der Realität zwar als Sequenz von geografischen Punkten beschrieben werden kann, allerdings nehmen Schiffe dabei auch immer eine Fläche ein. Je nach Schiffstyp kann diese Fläche unterschiedlich groß sein. Ein MAE bei einem Prädiktionsmodell von 10 Metern hat bei einem 400 Meter langen und 61 Metern breiten Schiff einen anderen Effekt als bei einem 8 Meter langem Sportboot. Für eine anwendungsbezogene Bewertung der Prädiktionsmodelle ist eine Einordnung der Fehlerwerte in den jeweiligen Anwendungskontext wichtig. Anders formuliert: Ab wann ist eine Prädiktionsmethode genau genug, um sie zur Kollisionsvermeidung nutzen zu können? Es ist zu erwarten, dass es einen Punkt gibt, an dem die Fehler eines Prädiktionsmodell größer als 0 sind, aber dennoch genau genug, um das Modell zur Kollisionsvermeidung nutzen zu können. Eine rein punktbasierte Evaluation der Prädiktionsergebnisse mit den klassischen Fehlerwerten ist somit nicht geeignet, um die Anwendbarkeit des Modells zur Kollisionsvermeidung zu bewerten.

Es wird folglich ein weiteres Fehlermaß benötigt. Hierfür bieten sich die vorgestellten Schiffsdomänen als grundlegendes Konzept zur Bewertung des Kollisionsrisikos an. Auf Abbildung 46 ist die Idee hierfür skizziert.




Abbildung 46: Konzept zur Berechnung der Prädiktionsgüte im Kontext der Kollisionsvermeidung.

Der tatsächliche Übergangspunkt aus der Realität ist in dunkelblau dargestellt. Um das Schiff ist die elliptische Schiffsdomäne nach Fujii und Tanaka (Fujii und Tanaka 1971) zu erkennen (ebenfalls dunkelblau). Für den prädizierten Übergangspunkt (helles blau) kann ebenfalls eine Domäne modelliert werden. Um die Prädiktionmethode im Kontext der Kollisionsvermeidung zu bewerten, kann die Überschneidung beider Domänen (grün schraffiert) berechnet werden. Je größer die Überschneidung, desto besser ist das Prädiktionsmodell zur Verhaltensprädiktion im Rahmen der Kollisionsvermeidung geeignet.

Dieses Konzept basiert auf der Überlegung, dass Schiffsdomänen aus schiffszentrischer Sicht zur Bewertung des Kollisionsrisikos genutzt werden. Die Domäne ist dabei der Bereich, in den kein Schiff eindringen darf. Befindet sich ein Schiff in der Schiffsdomäne, so ist das Kollisionsrisiko hoch. Folglich ist eine Prädiktionmethode für die Kollisionsvermeidung gut nutzbar, wenn die Überschneidung zwischen prädizierter und tatsächlicher Domäne sehr hoch ist, weil die Prädiktionmethode das Kollisionsrisiko im Vergleich zur Realität gut approximieren kann.

Für die Bewertung einer Prädiktionmethode bedeutet das, wenn die Überschneidung zwischen tatsächlicher und prädizierter Domäne sehr hoch ist, ist sie im Rahmen der Kollisionsvermeidung nutzbar. Eine Prädiktionmethode ist besser zur Kollisionsvermeidung nutzbar als eine andere Prädiktionmethode, wenn die Überschneidung der Domänen höher ist.

5 Umsetzung als KDD-Prozess

In diesem Abschnitt wird die Umsetzung des vorgestellten Konzepts beschrieben. Die Gesamtumsetzung ergibt sich aus der Umsetzung und Orchestrierung einzelner Teilschritte. Wie zu Beginn von Abschnitt 2 argumentiert, wird für die Umsetzung der KDD-Prozess (Fayyad, Piatetsky-Shapiro und Smyth 1996) als generelles Framework genutzt. Aus diesem Grund wird sich bei der Beschreibung der Umsetzung an den KDD-Prozessschritten orientiert.

Technisch umgesetzt wurden die einzelnen KDD-Prozessschritte in Python⁸. Für Python sind eine Vielzahl von Bibliotheken frei verfügbar, mit denen die wissenschaftliche Bearbeitung von Fragestellungen im Kontext der Datenanalyse gelöst werden können. Von *Pandas*⁹ wurden die effizienten Datenstrukturen und wiederkehrende Funktionen zur Datenanalyse verwendet. Insbesondere die Funktionen zum Im- und Export der Daten sowie die notwendigen Datenmanipulationen zur Weiterverarbeitung wurden in dieser Arbeit genutzt.

Für die Datenbeschreibung und Auswertung wurden die Funktionen von *NumPy*¹⁰ genutzt. *NumPy* bietet Implementierungen für Funktionen, mit denen numerische Probleme auf eine effiziente Art und Weise gelöst werden können. Die Fähigkeit der *NumPy*-Implementierung mit hochdimensionalen Daten arbeiten zu können ist für diese Arbeit von besonderer Relevanz.

Alle in dieser Arbeit verwendeten Daten haben einen geographischen Bezug. Insbesondere die historischen AIS-Daten und die Betonungsinformationen sind in räumlicher Relation zueinander zu betrachten. Die Arbeit mit Geodaten weist einige Besonderheiten auf (siehe Abschnitt 2.4). Die Bibliothek *GeoPandas*¹¹ wurde genutzt, um geometrische Operationen auf Geodaten durchzuführen, wie zum Beispiel die relative Lage zueinander zu berechnen. Eine Besonderheit von *GeoPandas* ist, dass Funktionen der Bibliothek *shapely*¹² so erweitert worden sind, dass sie mit Geodaten arbeiten können.

Für die Umsetzung des LSTM-Modells wurden die beiden Frameworks *TensorFlow*¹³ und *Keras*¹⁴ in Verbindung miteinander verwendet. *TensorFlow* beinhaltet Funktionen, um Machine Learning Modelle zu implementieren. Für die Definition der Modelle wurde *Keras* verwendet, was eine standardisierte Programmierschnittstelle zur Umsetzung solcher Modelle und zur Definition der Aktivierungs-, Optimierungs- und Verlustfunktionen bietet.

⁸ <https://www.python.org/doc/> (letzter Abruf 24.06.2023)

⁹ <https://pandas.pydata.org/docs/> (letzter Abruf 24.06.2023)

¹⁰ <https://numpy.org/doc/stable/> (letzter Abruf 24.06.2023)

¹¹ <https://geopandas.org/en/stable/docs.html> (letzter Abruf 24.06.2023)

¹² <https://shapely.readthedocs.io/en/stable/manual.html> (letzter Abruf 24.06.2023)

¹³ https://www.tensorflow.org/api_docs/python/tf (letzter Abruf 24.06.2023)

¹⁴ <https://keras.io/guides/> (letzter Abruf 24.06.2023)

Im Folgenden werden die umgesetzten KDD-Prozessschritte, die auf Abbildung 47 dargestellt sind, im Detail erläutert. Der restliche Abschnitt ist dabei entsprechend den KDD-Schritten strukturiert. Aufgrund der Anforderung 1 (Vorausschauende Kollisionsvermeidung) und Anforderung 4 (Anomaliedetektion) ist der Prozessschritt *Data Mining* zweigeteilt. Es werden zunächst die notwendigen Schritte beschrieben, um Anforderung 1 zu adressieren. Anschließend wird die Umsetzung im *Data Mining* zur Anomaliedetektion (Anforderung 4) dargelegt.

Ein Sonderfall ist der finale Schritt *Interpretation/Evaluation*, in dem sowohl das Evaluationsvorgehen einsortiert ist als auch die eigentliche Evaluation beziehungsweise Auswertung der Ergebnisse. Aus diesem Grund findet sich die Beschreibung dieses Schritts in Abschnitt 6.1 wieder.




Abbildung 47: Die einzelnen Analyseschritte zur Evaluation der Prädiktionsmethode. Die Schritte sind entsprechend dem KDD-Prozess von (Fayyad, Piatetsky-Shapiro und Smyth 1996).

5.1 Selection

Ziel des Schritts ist die Festlegung des Betrachtungsgebiets und -zeitraum. Basierend auf dieser Festlegung werden die passenden AIS-, Seewetter-, und Seekartendaten selektiert.

Wie in Abschnitt 1.3 definiert, fokussiert sich diese Arbeit auf Grund der hohen Unfallgefahr auf küstennahe Gewässer. Folglich werden die drei verkehrsreichen Wasserstraßen in der Jade, Weser und Elbe betrachtet. Historische AIS-Daten für diese Wasserstraßen werden über das maritime Testfeld eMIR (e-maritime Integrated Reference Platform) bezogen. Wesentlicher Bestandteil von eMIR sind Sensorboxen, die in Brunsbüttel, Cuxhaven und Wilhelmshaven stationiert sind. Die Sensorboxen sind unter anderem mit AIS-Antennen ausgerüstet, sodass der Schiffsverkehr AIS-basiert in den drei Seegebieten aufgezeichnet und in einer PostgreSQL-Datenbank gespeichert

wird (Rüssmeier, Lamm und Hahn 2019). Eine entsprechende Abfrage wurde mit dem Datenbankadapter *Psycopg*¹⁵ umgesetzt.

Die dazugehörigen meteorologischen und ozeanographischen Daten können über den Climate Data Store (CDS)¹⁶ bezogen werden. Der CDS ist im Rahmen des Copernicus Erdbeobachtungsprogramms der Europäischen Union¹⁷ entstanden. Die Daten werden durch das ECMWF (European Center for Medium-Range Weather Forecasts) kostenfrei über eine API¹⁸ zur Verfügung gestellt.

Hierbei ist zu berücksichtigen, dass sowohl Wind- und Wellendaten gitterbasiert im CDS gespeichert sind. Beide Daten basieren auf Modelldaten, die auf Basis von Beobachtungsdaten entstehen. Historische Winddaten sind dabei mit einer Auflösung von $0,25^\circ \times 0,25^\circ$ (je Zelle, bezogen auf Längen- und Breitengrad) verfügbar. Die Berechnungsgrundlage für die Windgeschwindigkeit (angegeben in Meter pro Sekunde) ist der horizontale Vektorwind, der den Wind in östlicher und nördlicher Richtung modelliert. Die Windrichtung wird in Relation zum magnetischen Nordpol angegeben und beschreibt die Richtung, aus der der Wind weht (Hersbach et al. 2020; ECMWF 2023).

Die für diese Arbeit verwendete Informationen über Wellen ist die signifikante Wellenhöhe (siehe Abschnitt 2.2). Die im CDS verfügbaren Welleninformationen entstehen, genauso wie die Winddaten, durch eine nachträgliche Analyse von Beobachtungs- und Modelldaten. Für die Deutsche Bucht stehen die Informationen aus dem WAM- Wellenmodell (Waves for the Atlantic and Mediterranean) zur Verfügung, welches auch in dieser Arbeit genutzt wird. Die Welleninformationen, beziehungsweise die Information zur signifikanten Wellenhöhe, werden mit einer Auflösung von $0,5^\circ \times 0,5^\circ$ (in Bezug auf Längen- und Breitengrad) gespeichert und sind in Metern angegeben (Hersbach et al. 2020; ECMWF 2023). Die für diese Arbeit relevanten Gitter in der Jade, Weser und Elbe werden entsprechend selektiert.

Sowohl die historischen Wind- als auch die historischen Wellendaten stehen in dem in Abschnitt 2.2 beschriebenen GRIB2-Format zur Verfügung. Zur Extraktion der Werte aus dem GRIB2-Format wurde die Bibliothek *pygrib*¹⁹ verwendet.

Im Gegensatz zu den Wellen- und Windinformationen stehen Tideinformationen als Beobachtungsdaten zur Verfügung, die sich stets auf den Standort der Mareografen (engl. TG für Tide Gauge) beziehen. Die für die Jade, Weser und Elbe relevanten Mareografen sind auf Abbildung 48

¹⁵ <https://www.psycopg.org/docs/index.html> (letzter Abruf 20.06.2023)

¹⁶ <https://cds.climate.copernicus.eu/#!/home> (letzter Abruf 18.11.2023)

¹⁷ <https://www.copernicus.eu/en> (letzter Abruf 23.06.2023)

¹⁸ <https://cds.climate.copernicus.eu/api-how-to> (letzter Abruf 18.11.2023)

¹⁹ <https://github.com/jswhit/pygrib> (letzter Abruf 20.6.2023.)

dargestellt. Je Wasserstraßen werden immer zwei Standorte verwendet, sodass Tideinformationen am Beginn und Ende der jeweiligen Wasserstraßen verfügbar sind.



Abbildung 48: Übersicht über verwendeten Mareografen.

Für die Jade werden die Mareografen vor Wangerooge und Wilhelmshaven genutzt. Alte Weser und Bremerhaven liefern die Messwerte für das Weserfahrwasser. Die Messerwerte der Mareografen vor Cuxhaven und St. Pauli werden für das Elbfahrwasser verwendet. Im Gegensatz zu Wind- und Welleninformationen stehen keine flächendeckenden Messdaten zur Verfügung, sondern lediglich einzelne Messpunkte. Die historischen Messdaten der Mareografen werden durch das CMEMS (Copernicus Marine Environment Monitoring)²⁰ bereitgestellt und sind in Intervallen von zehn Minuten verfügbar. Angegeben werden die Wasserstände in Metern in Bezug zu Normalnull an der Messstelle. Je nach Stand der Tide ergeben sich somit positive oder auch negative Messwerte. Über das CMEMS sind die Tidedaten im netCDF-Format verfügbar. Die Daten wurden in Python mit *netCDF4*²¹ extrahiert.

Um die Übergangspunkte der Schiffsbahnen innerhalb der Fahrwasser berechnen zu können, sind die Betonungsinformationen aus der Jade, Weser und Elbe notwendig. Hierfür steht ein industrieller Kartenserver der Firma 7Cs (Chartworld GmbH) zur Verfügung²². Die eigentlichen Informationen zur lateralen Betonung (siehe Abschnitt 4.2.1) wurde über einen *Web Feature Service* (WFS) abgefragt. Hierfür ist der S-57 Standard der IHO relevant, in dem der digitale Austausch von Seekarteninformationen definiert ist. Folglich werden aus den ENCs die Objekte *BOYLAT*

²⁰ <https://marineinsitu.eu/dashboard/> (letzter Abruf 18.11.2023)

²¹ <https://unidata.github.io/netcdf4-python/> (letzter Abruf 18.11.2023)

²² <https://www.sevencs.com/chartserver/wms-chartserver/> (letzter Abruf 18.11.2023)

extrahiert. Um das im Konzept beschriebene Gitter aufbauen zu können, sind die Positionsangaben der lateralen Betonung relevant. Hierfür hat das Objekt *BOYLAT* ein entsprechendes *INFORM* Attribut, in dem unter anderem die Positionsangaben vermerkt sind (International Hydrographic Organisation 2000; 2018).

Als Ergebnis dieses Prozessschritts stehen historischen AIS-, Seewetter- und Seekartendaten zur Verfügung, die entsprechend des zuvor festgelegten Betrachtungsgebiets und -zeitraum zur selektiert wurden.

5.2 Preprocessing

Die zuvor selektierten Daten werden in diesem Schritt gesäubert (*Data Cleansing*). Dies beinhaltet die Identifizierung von unplausiblen oder inkonsistenten Daten, sowie von Fehlern in den Daten. Des Weiteren ist ein Ziel dieses Schrittes die Konsolidierung zusammengehöriger AIS-Daten zu einer Schiffsbahn. Auf diese Weise entstehen historische Schiffsbahnen, die die Basis für die nachfolgenden Schritte darstellen.

Für das *Data Cleansing* werden zunächst unplausible Geschwindigkeitsinformationen identifiziert und herausgefiltert. Hierzu gehören Geschwindigkeitsinformationen, die 30 Knoten überschreiten. Eine Überprüfung auf unplausible Positionsdaten ist nicht notwendig, da durch die raumbasierte Abfrage der AIS-Daten fehlerhafte Positionsdaten ausgeschlossen sind.

Wie im Konzept beschrieben sind die Informationen über die Dimension eines Schiffes für die Prädiktion relevant. Um mögliche Inkonsistenzen zu identifizieren, wird überprüft, ob zu einer MMSI AIS-Nachrichten mit unterschiedlichen Schiffslängen existieren. Ist dies der Fall, so werden die Nachrichten der entsprechenden MMSI herausgefiltert.

Nachdem das *Data Cleansing* abgeschlossen ist, werden die AIS-Nachrichten entsprechend der MMSI und des Zeitstempels sortiert, sodass die Nachrichten je MMSI in chronologischer Reihenfolge vorliegen. Um eine Schiffsbahn aus den AIS-Nachrichten zu erstellen, ist die Differenz der Zeitstempel nachfolgender AIS-Nachrichten mit derselben MMSI sowie der navigatorische Status ausschlaggebend. Wenn das Schiff nicht vor Anker liegt (navigatorischer Status), die zeitliche Differenz kleiner als drei Minuten ist und die MMSI beider Nachrichten übereinstimmen, gehören die Nachrichten zu einer Schiffsbahn. Für den Fall, dass die MMSI gleich ist, das Schiff nicht vor Anker liegt und die zeitliche Differenz größer als drei Minuten ist, dann beginnt eine neue Schiffsbahn. AIS-Nachrichten mit dem navigatorischen Status „ankernd“ werden in dieser Arbeit nicht berücksichtigt. Das Ergebnis dieses Schritts sind gereinigte AIS-Daten, die zu Schiffsbahnen konsolidiert worden sind.

5.3 Transformation

Auf Basis der vorherigen Schritte werden im Folgenden die historischen Schiffsbahnen, Seewetter- und Seekartendaten miteinander kombiniert. Ziel des Schrittes ist die Berechnung der Übergangspunkte (siehe Abschnitt 4). Die Reihenfolge der dafür notwendigen Verarbeitungsschritte ist auf Abbildung 49 dargestellt.




Abbildung 49: Aktivitätsdiagramm zur Transformation aller genutzten Daten

Die parallele Verarbeitung beginnt mit der Erstellung der Gitter in den Wasserstraßen der Jade, Weser und Elbe mit Hilfe der zuvor extrahierten Betonungsinformationen. Das Vorgehen hierfür wurde in Abschnitt 4.3.1 und 4.3.2 erläutert.

Die historischen AIS-Daten werden mit den historischen Wind-, Wellen- und Tideninformationen kombiniert. Hierfür wird das in Abschnitt 4.3.3 beschriebene Verfahren angewendet, bei dem die zeitlichen und räumlichen Informationen aller Daten genutzt und bei einer entsprechenden Übereinstimmung miteinander kombiniert werden.

Zur Kombination von Tideninformationen und historischen AIS-Daten wird zunächst geprüft, in welchem Fahrwasser sich der jeweilige AIS-Datenpunkt befindet. Anschließend werden die zum Fahrwasser passenden Mareografen (siehe oben) ausgewählt und basierend auf der zeitlichen Übereinstimmung zwischen AIS-Datum und Messwert miteinander kombiniert. Jeder AIS-Datenpunkt wird folglich um zwei Messwerte erweitert.

Wie in Abbildung 49 zu erkennen ist, existiert ebenfalls ein Datensatz, der nicht mit Seewetterinformationen kombiniert wurde. Dieser Datensatz soll als Referenz dienen, um eine Aussage darüber treffen zu können, inwiefern die Berücksichtigung von Seewetterinformationen die Prädiktionsgüte verbessern kann.

Der verbleibende Transformationsschritt ist die Berechnung der Übergangspunkte. Wie in Abschnitt 4.3.2 dargelegt, werden dafür die Grenzen zwischen benachbarten Zellen im Gitter und den AIS-Datenpunkte genutzt, um den Schnittpunkt der Schiffsbahn mit den Zellgrenzen zu berechnen. Als Ergebnis erhält man eine transformierte Schiffsbahn, die im Folgenden nicht mehr als Sequenz von AIS-Datenpunkten modelliert wird, sondern als Sequenz von Übergangspunkten.

5.4 Data Mining

Die transformierten Daten können anschließend im Rahmen des *Data Mining* sowohl zur Verhaltensprädiktion im Rahmen der vorausschauenden Kollisionsvermeidung als auch zur Anomalieerkennung verwendet werden. Zunächst wird die Umsetzung zur Verhaltensprädiktion beschrieben.

In Abschnitt 4.3.4 wurde das Problem zur Vorhersage von Schiffsverhalten als Regressionsproblem einer Zeitreihe interpretiert. Zur Lösung des Regressionsproblems soll ein LSTM-Modell trainiert und zur Prädiktion verwendet werden. Die Modelle werden auf Basis von einer beobachteten Sequenz an Übergangspunkten zur Vorhersage des nächsten Übergangspunktes trainiert. Dieses Training funktioniert nach dem in Abschnitt 4.3.4 beschriebenen Prinzip.

Ein wesentlicher Hyperparameter ist folglich die Größe der zu berücksichtigten Sequenz an vorherigen Übergangspunkten. Es ist zu erwarten, dass die Wahl der Anzahl zu berücksichtigender Übergangspunkte einen Einfluss auf die Prädiktionsgüte haben wird. Hinzu kommt, dass eine höhere Zahl an historischen Übergangspunkten die Datenmenge zum Training reduziert. Im Rahmen des Hyperparametertunings für die LSTM-Modelle wurden unterschiedliche Sequenzlängen an vorherigen Übergangspunkten (k) getestet. Tabelle 7 zeigt die Trainingsfehler beziehungsweise -genauigkeit der getesteten Sequenzlängen.

Tabelle 7: Die Güte der Prädiktionsmodelle bei einer unterschiedlich großen Sequenz an zu berücksichtigen Übergangspunkten (k).

k	Loss	Accuracy
1	0.025866882316768168	0.9527989566326142
2	0.022369113750755787	0.9580203056335449
3	0.022151252068579198	0.9581051945686341
4	0.02181730456650257	0.9578494429588318

Es ist zu erkennen, dass die Genauigkeit mit größer werdendem k zunächst zunimmt. Sobald k drei ist, nimmt die Genauigkeit allerdings ab. Für das Training aller LSTM-Modelle wird im Folgenden die Sequenz an vorherigen Übergangspunkten auf zwei festgesetzt.

Diese Entscheidung ist ein Kompromiss zwischen Genauigkeit der Modelle und Datenverfügbarkeit. Je mehr Daten als historische Sequenz genutzt werden müssen, desto weniger Daten stehen für das Training respektive für das Testen der LSTM-Modelle zur Verfügung. Des Weiteren ist die räumliche und zeitliche Distanz zwischen den Übergangspunkten ein Faktor bei dieser Entscheidung. Typischerweise sind die Zellen zwischen 1,5 und 2 Kilometer lang. Bei einer Sequenz von zwei werden die Schiffe somit im Schnitt zwischen drei und vier Kilometer beobachtet, was auf Basis der Unterschiede in der Genauigkeit zwischen einer Sequenz von zwei und drei als hinreichend lange gewertet wird.

Für das Tuning der übrigen Hyperparameter wurde *KerasTuner*²³ eingesetzt, was Teil der Keras-API ist und eine effiziente Suche nach den besten Hyperparametern ermöglicht. *KerasTuner* verwendet dafür die in Abschnitt 2.4 Strategien, um ein optimales Hyperparameterset basierend auf dem verwendeten Modell und Datenset zu finden.

Die Modelle beinhalten 128 Units und werden mit einer Dropout-Rate von 0,2 trainiert. Dropout ist ein Mechanismus, der im Lernprozess von neuronalen Netzen genutzt wird, um overfitting zu verhindern. Hierbei werden randomisiert Neuronen ausgesucht, die bei einem Trainingsdurchlauf nicht berücksichtigt werden sollen (Graves 2012a; Feurer und Hutter 2019; Yang und Shami 2020). In diesem Fall bedeutet es, dass 20% der Neuronen zufallsbasiert nicht berücksichtigt werden. Als Fehlermaß wird der MSE genutzt und die Modelle werden in maximal 100 Epochen trainiert. Sobald allerdings in den letzten zehn Epochen keine signifikante Verbesserung des MSE zu erkennen ist, wird das Training beendet. Die Daten werden in einem Verhältnis von 80:20 in Trainings- und Testdaten aufgeteilt.

²³ https://keras.io/keras_tuner/ (letzter Abruf 24.06.2023)

In Abschnitt 1.3 definiert Anforderung 4, dass die Methode auch zu Anomaliedetektion geeignet sein muss. Folglich ist die Detektion von Anomalien der zweite Bestandteil des Data-Mining-Schritts. Anomales Schiffsverhalten wird im Folgenden als jenes Verhalten definiert, welches auf Basis der zuvor extrahierten Bewegungsmuster (hier d_{star} , Kurs und Geschwindigkeit, siehe Abschnitt 4.3) am unwahrscheinlichsten ist. Die Idee zur Anomaliedetektion ist auf Abbildung 50 dargestellt.




Abbildung 50: Vorgehen zur Berechnung des wahrscheinlichsten beziehungsweise unwahrscheinlichsten Verhaltens zur Anomaliedetektion.

Für jede Zellgrenze, an denen zuvor die Übergangspunkte berechnet wurden, wird in Bezug auf die Fahrtrichtung der Schiffe zunächst das wahrscheinlichste Verhalten extrahiert. Hierfür werden die zur Verfügung stehenden Übergangspunkte im Verhältnis von 80:20 aufgeteilt. Um das wahrscheinlichste Verhalten abzuschätzen, wird die Kerndichteschätzung auf die 80% der Daten angewendet, um die zugrunde liegende Wahrscheinlichkeitsdichtefunktion für jeden der drei Parameter zu approximieren. Es wird angenommen, dass die Daten normalverteilt sind. Anschließend kann für jede Wahrscheinlichkeitsdichtefunktion der Mittelwert und die Standardabweichung berechnet werden. Es wird angenommen, dass ein Schiff sich normal verhält, wenn es sich so verhält wie 95% der Schiffe an diesem Übergangspunkt. Im Umkehrschluss gilt, sobald sich ein Schiff so verhält, wie sich die verbleibenden 5% der Schiffe verhalten, so ist dieses Verhalten eine Anomalie. Zur Berechnung der Wertebereiche wird die 2-Sigmaumgebung berechnet (siehe Abbildung 50). Dieser Vorgang wird für alle Übergangspunkte in Bezug auf die steuerbordseitige Distanz zur steuerbordseitigen Tonne (d_{star}), für den Kurs (COG) und die Geschwindigkeit (SOG) durchgeführt.

6 Evaluation in der Jade, Weser und Elbe

Die in Abschnitt 5 beschriebene Umsetzung wurde genutzt, um das in Abschnitt 4 vorgestellte Verfahren zur kontextsensitiven Verhaltensprädiktion zu evaluieren. Das Fundament für dieses Konzept bilden die Anforderungen (Abschnitt 1.3), die sich aus der Zielstellung beziehungsweise Forschungsfrage ergeben.

Im Folgenden wird zunächst ein Überblick über die durchgeführte Evaluation gegeben. Diese Beschreibung ist der finale Schritt des zuvor umgesetzten KDD-Prozesses (siehe Abschnitt 5). Anschließend wird die Datengrundlage der Evaluation beschrieben, gefolgt von den Ergebnissen. Basierend auf den Ergebnissen wird im Anschluss diskutiert, inwiefern die Anforderungen und somit die Ziele der Arbeit erfüllt sind.

6.1 Vorgehen zur Evaluation

An den Data Mining Schritt des KDD-Prozesses (vergleiche Abschnitt 5 und 5.4) schließt sich der Schritt zur Evaluation und Interpretation an. Das in dieser Arbeit entwickelte Konzept zur kontextsensitiven Verhaltensprädiktion wird mit Verkehrsdaten aus den drei Wasserstraßen Jade, Weser und Elbe evaluiert (Vergleiche Abschnitt 5.1).

Für die Evaluation einer sicherheitskritischen Anwendung sind diese Gebiete von besonderer Relevanz. Die navigierbaren Gewässer in diesen Gebieten sind stark beschränkt. Ausschlaggebend hierfür sind die Gezeiten, die einen starken Einfluss auf die allgemeine Wassertiefe in diesen Gebieten haben. Um den Verkehr in Gewässern mit einer konstanten Wassertiefe zu strukturieren, existieren in diesen Gebieten Wasserstraßen (siehe Abschnitt 2.3).

Hinzu kommt, dass die Jade, Weser und Elbe drei Hauptwasserstraßen in der Deutschen Nordsee sind, über denen der größte Teil des Güterverkehrs abgehandelt wird (Generaldirektion Wasserstraßen und Schifffahrt (GWDS) 2023).. Die großen Seehäfen Wilhelmshaven (Jade), Bremerhaven, Bremen (beide Weser), Cuxhaven und Hamburg (beide Elbe) werden über die jeweiligen Wasserstraßen angefahren. In 2022 wurde in der Jade 11.449, in der Weser 28.270 und in der Elbe 81.433 Schifffahrtbewegungen gezählt (Generaldirektion Wasserstraßen und Schifffahrt (GWDS) 2023). Das macht diese drei Wasserstraßen zu den Gebieten in der Deutschen Nordsee mit der höchsten Verkehrsdichte.

Die Kombination zwischen hohen Verkehrszahlen, dem starken Tideeinfluss und eine daraus folgende hohe Komprimierung des Verkehrs lässt das Kollisionsrisiko in diesen Gebieten ansteigen, was sich mit der Argumentation aus Abschnitt 1.2 deckt: In küstennahen Gewässern existiert ein erhöhtes Risiko für Schiff-zu-Schiff-Kollisionen (Wróbel, Montewka und Kujala 2017).

Die Evaluation der kontextsensitiven Verhaltensprädiktion und der Anomaliedetektion funktioniert für die drei Gebiete nach dem auf Abbildung 51 dargestellten Prinzip.

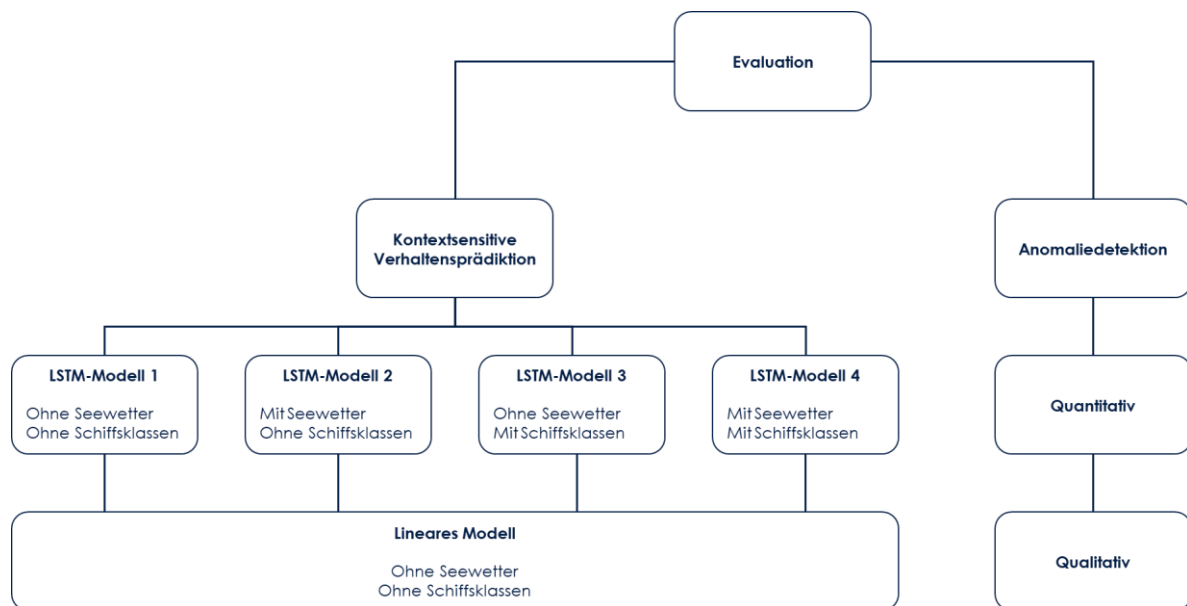


Abbildung 51: Das Evaluationsvorgehen in der Arbeit.

Für die kontextsensitive Verhaltensprädiktion werden insgesamt vier unterschiedliche LSTM-Modelle trainiert. Der Unterschied zwischen den jeweiligen Modellen ist die Datenbasis, die zum Training genutzt werden. Auf diese Weise können unterschiedliche Kombinationen evaluiert werden, um das Konzept auf den Deckungsgrad der Anforderungen zu untersuchen. Zur Beschreibung der Ergebnisse werden die LSTM-Modelle im Folgenden als Modell 1, Modell 2, Modell 3 und Modell 4 bezeichnet (vergleiche Abbildung 51).

Wie in der Abbildung zu sehen ist, dient bei der Evaluation der kontextsensitiven Verhaltensprädiktion das lineare Prädiktionsverfahren, welches heute standardmäßig auf Schiffsbrücken zum Einsatz kommt, als Vergleichsgrundlage. Dies ergibt sich aus Anforderung 2 *Genauigkeit*. Dort ist definiert, dass die Methode zur kontextsensitiven Verhaltensprädiktion präziser sein muss als das lineare Prädiktionsverfahren.

Die Evaluation basiert des Weiteren auf der Berechnung und dem Vergleich von Prädiktionsfehlern (als RMSE, siehe Abschnitt 4.4). Die wesentlichen Messwerte sind die Distanz zur steuerbordseitigen Tonne (d_{star}), der Kurs (COG) und die Geschwindigkeit (SOG). In diesem Kontext ist es wichtig hervorzuheben, dass das lineare Prädiktionsverfahren zwar ausgehend von einem Übergangspunkt angewendet wird, das Verfahren aufgrund seiner Funktionsweise allerdings eine geografische Position liefert. Daher wird der Fehler des linearen Prädiktionsverfahren berechnet, indem die Distanz zwischen der prädizierten und tatsächlichen Position kalkuliert wird. Gleiches gilt für SOG und COG.

Um die in Abschnitt 4.4 vorgestellte Idee zur anwendungsbezogenen Messung der Prädiktionsgüte wird sowohl für das lineare Verfahren als auch für die kontextsensitive Prädiktion die prozentuale Überschneidung der Schiffsdomänen (prädierte versus tatsächliche Domäne) berechnet.

Wie bereits aus Abbildung 51 entnommen werden kann, wird die Anomaliedetektion in dieser Arbeit sowohl quantitativ als auch qualitativ evaluiert. Die quantitative Bewertung ergibt sich aus der Detektion der Anomalien, welche dem am wenigsten wahrscheinlichen Verhalten entsprechen. Somit kann gezeigt werden, ob und wie viele Anomalien das oben vorgestellte Vorgehen im Testdatensatz identifizieren. Allerdings ist die qualitative Beurteilung der detektierten Anomalien das zweite wichtige Kriterium im Evaluationsvorgehen. Die qualitative Beurteilung wird durch die Befragung einer Person mit nautischer Ausbildung vorgenommen. Hierbei ist allerdings zu beachten, dass die Beurteilung der Kritikalität von Verkehrssituationen im Allgemeinen subjektiv ist und in vielen Fällen von der Erfahrung der jeweiligen Person abhängt. Die Person wird gebeten zu beurteilen, ob es sich bei der dargestellten Anomalie aus ihrer Sicht tatsächlich um eine Anomalie im Verhalten des Schiffes handelt. Durch dieses Verfahren werden für jede Anomaliekategorie die False-Positive-Rate berechnet.

Zur Berechnung der Stichprobengröße n wurde die in der Literatur verbreitete Methode verwendet, die durch Formel (11) abgebildet ist (Fahrmeir et al. 2016).

$$n = \frac{\frac{z^2 * p(1 - p)}{e^2}}{1 + \left(\frac{z^2 * p(1 - p)}{e^2 * N}\right)} \quad (11)$$

, wobei e der zu erwartenden Fehlermarge der Stichprobe entspricht, p der erwarteten Variation beziehungsweise Standardabweichung, z ergibt sich aus dem festgelegten Konfidenzniveau als standardisierter Wert, N Grundgesamtheit. Bei der Festlegung der Werte für die Fehlermarge und dem Konfidenzniveau ist zu beachten, dass die Wahl der Werte einen Einfluss auf die Stichprobengröße und somit auf die Aussagekraft haben. Je kleiner der gewählte Wert für die Fehlermarge, desto präziser bildet die Stichprobe die Grundgesamtheit ab. Allerdings nimmt die Stichprobengröße zu. Ähnliches gilt für das Konfidenzniveau (je höher, desto präziser, allerdings größere Stichprobe). Damit die Stichprobengröße der zu bewertenden Anomalien für die fachkundige Person nicht zu groß wird, wird von einer Fehlermarge $e = 0,1$ und eine Konfidenzniveau von 90% ausgegangen. Aus dem Konfidenzniveau von 90% ergibt sich für $z = 1,65$ (Fahrmeir et al. 2016).

6.2 Datenbasis

Die im Rahmen der Evaluation verwendeten historischen AIS-Daten in der Jade, Weser und Elbe decken einen Zeitraum von drei Monaten ab (Januar 2020 bis Ende März 2020). Im selektierten Datensatz befinden sich unterschiedliche Schiffstypen, deren absolute Häufigkeit auf Abbildung 52 dargestellt ist. Bei der Anzahl der Schiffstypen handelt es sich um einzigartige Schiffe, die anhand ihrer MMSI unterschieden werden können.




Abbildung 52: Verteilung der Schiffsklassen innerhalb des Datensatzes.

Aufgrund der absoluten Häufigkeit von Cargo-Schiffen und Tankern werden ausschließlich diese beiden Schiffstypen im weiteren Verlauf der Evaluation betrachtet. Da für das Training der LSTM-Modelle die Daten in ein Trainings- und Validierungsset aufgeteilt werden, eignen sich die anderen Schiffsklassen aufgrund ihrer absoluten Häufigkeit weniger, um aussagekräftige Modelle generieren zu können. Das Ergebnis des Preprocessing-Schritts (siehe Abschnitt 5.2) sind die historischen Schiffsbahnen für Tanker und Cargo-Schiffe und auf Abbildung 53 dargestellt.




Abbildung 53: Die Datengrundlage der Evaluation nach der Vorverarbeitung in der Jade, Weser und Elbe.

Wie aus Tabelle 8 zu entnehmen ist, befinden sich in dem Datensatz 18.154 einzigartige Schiffsbahnen, die von 1767 einzigartigen Cargo-Schiffen und 577 einzigartigen Tankern stammen.

Tabelle 8: Übersicht der Schiffe und Schiffsbahnen im verwendeten Datensatz

Kategorie	Ausprägung
Einzigartige Schiffe	1767 (Cargo), Tanker (577)
Einzigartige Schiffsbahnen	18.154
Dimensionen Cargo-Schiffe (in Meter)	Min.: 9, Max.: 523, Mean: 156,62
Dimensionen Tanker (in Meter)	Min.:75, Max.: 333, Mean: 112,20

Zur Berücksichtigung der spezifischen hydrodynamischen Eigenschaften werden die Längeninformationen der Schiffe genutzt, um Schiffsklassen zu bilden. Zur Komplexitätsreduktion wird ferner angenommen, dass Schiffe der gleichen Klasse ähnliche hydrodynamische Eigenschaften besitzen. Auf Abbildung 71 und Abbildung 72 (siehe

Anhang) sind die Verteilung der Schiffslängen für die Cargo-Schiffe und Tanker des Datensatzes dargestellt. Auf Basis der Verteilung wurden die in Tabelle 9 dargestellten Schiffsklassen gebildet.

Tabelle 9: Einteilung von Schiffsklassen basierend auf der Schiffsklasse und dem in dieser Arbeit verwendeten Datensatz

Cargo		Tanker	
Klasse	Intervall (in Meter)	Klasse	Intervall (in Meter)
Klein	$x \leq 75$	Klein	–
Mittel	$76 \leq x \leq 130$	Mittel	$75 \leq x \leq 150$
Groß	$131 \leq x \leq 300$	Groß	$x > 150$
Sehr groß	$x > 300$	Sehr groß	–

Die Längenverteilung der Cargo-Schiffe im Datensatz ist grundsätzlich breiter als die der Tanker. Dies spiegelt sich darin wider, dass Cargo Schiffe in vier Klassen, und damit doppelt so viele wie die Tanker, eingeteilt werden.

Im Rahmen der anschließenden *Transformation* (siehe Abschnitt 5.3) werden die historischen Schiffsbahnen mit den Seewetter- und Seekartendaten kombiniert und die Übergangspunkte berechnet. Abbildung 54 zeigt die Verteilung der Windgeschwindigkeiten und der signifikanten Wellenhöhe in den jeweiligen Seegebieten.




Abbildung 54: Die Verteilung der Windgeschwindigkeit (links, in Knoten) und signifikanten Wellenhöhe (rechts, in Meter) in den jeweiligen Seegebieten.

Für den Zeitraum herrschten sowohl für die Windgeschwindigkeit als auch für die Wellenhöhe in der Elbe und Weser vergleichbare Bedingungen. In den Daten ist zu entnehmen, dass in der Jade eine höhere Windgeschwindigkeit als auch Wellenhöhe vorlag. Die Windrichtung war für die Elbe (125,40°), Jade (125,12°) und Weser (122,46) im Schnitt ähnlich.

Abbildung 55 zeigt exemplarisch die extrahierten Übergangspunkte in der Elbe als Ergebnis des Verarbeitungsschritts.



Abbildung 55: Historische Schiffsbahnen durch das Elbefahrwasser, die als Sequenz von Übergangspunkten modelliert sind.

Der finale Schritt (*Data Mining*, siehe Abschnitt 5.4) ist das Training der LSTM-Modelle und die Berechnung des am wenigsten wahrscheinlichen Verhaltens zur Anomaliedetektion.

Die Lernrate zweier LSTM-Modelle ist exemplarisch auf Abbildung 56 (Modell 1, vergleiche Abbildung 51) und Abbildung 57 (Modell 2, vergleiche Abbildung 51) zu sehen. Das Modell 1 konvergiert nach 63 Epochen, wohingegen Modell 2 nach 81 Epochen konvergiert.




Abbildung 56: Lernrate von Modell 1.

Die Differenz in den Epochen spiegelt die unterschiedliche Komplexität der Modelle wider. Beide Modelle zeigen einen ähnlichen Trainingsverlauf: Der zu Beginn stark fallende Trainingsfehler nimmt im weiteren Trainingsverlauf weniger stark ab, bewegt sich am Ende für beide Modelle auf einem ähnlichen Niveau. Grundsätzlich zeigen keine Abbildungen Anzeichen für ein over- beziehungsweise underfitting der Modelle.




Abbildung 57: Lernrate von Modell 2.

6.3 Ergebnisse

Zunächst werden die Ergebnisse zur Evaluation der Verhaltensprädiktion beschrieben, gefolgt von den quantitativen und qualitativen Ergebnissen der Anomaliedetektion. Für die Verhaltensprädiktion werden die Prädiktionsfehler in diesem Abschnitt mit dem RMSE verglichen. Die diesem Gütemaß zugrunde liegenden Fehler sind im Anhang aufgeführt. Wie bereits in Abschnitt 4.4 eingeführt, werden für den RMSE die Fehlerwerte quadriert und anschließend der Mittelwert gebildet (MSE, siehe Abschnitt 4.4). Abschließend wird vom MSE die Wurzel gezogen. Wichtig zu erwähnen ist hierbei, dass der RMSE aufgrund der Quadrierung der Fehlerwerte stark auf Ausreißer reagiert (Fahrmeir et al. 2016; Sammut und Webb 2010; Vogel 2015). Da es sich in dieser Arbeit um eine sicherheitskritische Methode handelt (A.1 Vorausschauende Kollisionsvermeidung, siehe Abschnitt 1.3), sind große Prädiktionsfehler besonders kritisch, sodass es sich beim RMSE um ein geeignetes Gütemaß für den Modellvergleich handelt.

Auf Abbildung 58 sind die Prädiktionsfehler (RMSE) der prädizierten Positionen für die lineare Prädiktion, des LSTM-Modells ohne Seewetterinformationen und ohne Schiffsklassen (Modell 1) und des LSTM-Modells mit Seewetterinformationen und ohne Schiffsklassen (Modell 2) in den Seegebieten Elbe, Jade und Weser dargestellt.

Zunächst fällt auf, dass die lineare Prädiktion in allen drei Seegebieten höhere Fehler produziert als die beiden LSTM-Modelle. Am größten ist der Fehler der linearen Prädiktion in der Jade. Modell 1 hat im Vergleich dazu einen geringeren Prädiktionsfehler, allerdings beträgt die Differenz insbesondere in der Elbe und Weser nur jeweils rund sechs Meter, was keine signifikante Verbesserung

darstellt. Anders sieht es in der Jade aus, wo eine Verbesserung von rund 45 Metern zu erkennen ist.

Modell 2 weist hingegen einen signifikant geringeren Prädiktionsfehler auf. In allen drei Seegebieten bewegt sich der RMSE auf einem vergleichbaren Niveau. Die größte Verbesserung im Vergleich zur linearen Prädiktion ist in der Jade zu erkennen. Dort kann unter Berücksichtigung der Seewetterdaten der Prädiktionsfehler von 265,75 m auf 150,25 m reduziert werden.

Ein Boxplot der zugrunde liegenden Prädiktionsfehler sind im Anhang auf Abbildung 73 (Seite 173) zu sehen, der erwartungsgemäß die Beobachtung bestätigt. In dieser Darstellung fällt auf, dass das Modell 2 in Bezug auf die Streuung der Ergebnisse stabiler ist als die beiden anderen Modelle. Somit zeigt sich auch in diesem Kontext der positive Einfluss der berücksichtigten Seewetterinformationen auf die Prädiktionsgüte.




Abbildung 58: RMSE der linearen Prädiktion, LSTM-Modell 1 und 2.

Die Verbesserung der LSTM-Prädiktion durch die Nutzung von Seewetterinformationen wird auch ersichtlich, wenn man die Vorhersagen auf einer Seekarte betrachtet. Auf Abbildung 59 ist ein Ausschnitt aus dem Weserfahrwasser zu sehen. Links ist das LSTM-Modell ohne Seewetterinformationen, rechts das LSTM-Modell mit Seewetterinformationen abgebildet. Die prädizierten TPs sind in blau dargestellt und die tatsächlichen TPs in orange.

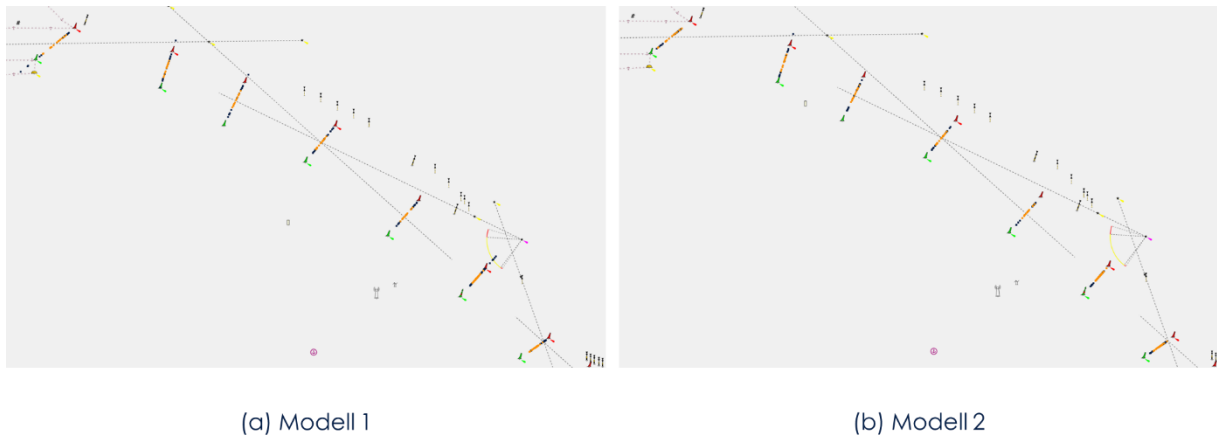


Abbildung 59: Prädizierte (blau) und tatsächliche (orange) Übergangspunkte in einem Abschnitt des Weserfahrwassers.

In diesem Fahrwasserabschnitt prädiziert das Modell 1 häufig die TPs außerhalb des Fahrwassers. Besonders deutlich wird es bei dem Tonnenpaar in der Mitte des Bildes. Wenn Seewetterdaten beim Training des LSTM-Modells berücksichtigt werden (Modell 2, rechte Seite der Abbildung), so produziert das Modell weniger Vorhersagen außerhalb des Fahrwassers. In diesem Abschnitt scheint das Wetter einen signifikanten Einfluss auf den Verlauf der Bahn zu haben, sodass die Berücksichtigung von Seewetterinformationen insgesamt zu einer Verringerung des Prädiktionsfehlers führt.

Eine Herausforderung in diesem Zusammenhang ist die Vorhersage des Verhaltens in Kurven. Obwohl der Fehler bei Modell 2 geringer ist, hat das Modell Probleme bei der korrekten Vorhersage einer Kurvenbahn. Auf Abbildung 60 ist ein Ausschnitt der Prädiktionsergebnisse aus dem Elbefahrwasser zu sehen.




Abbildung 60: Prädizierte (blau) und tatsächliche (orange) Übergangspunkte in einem Kurvenabschnitt des Elbefahrwassers.

Hier wird deutlich, dass die tatsächlichen Übergangspunkte (orange) der Schiffe sich in der Mitte des Fahrwassers konzentrieren. Die prädizierten Übergangspunkte (TP) sind hingegen weiter außen. Das Modell kann das Kurvenschneiden der Schiffe nicht adäquat aus den Trainingsdaten extrahieren und entsprechend vorhersagen.

Erwartungsgemäß sieht es für gerade Abschnitte der Fahrwasser konträr dazu aus. Abbildung 61 zeigt die Prädiktion von Modell 2. Die prädizierten und tatsächlichen Übergangspunkte liegen in unmittelbarer Nachbarschaft.




Abbildung 61: Prädizierte (blau) und tatsächliche (orange) Übergangspunkte in einer Gerade des Elbefahrwassers.

Hierbei ist allerdings hervorzuheben, dass alle Prädiktionsmodelle in diesem Abschnitt am besten funktionieren.

Um die Eignung der drei Prädiktionsmodelle für die Kollisionsvermeidung zu beurteilen, ist auf Abbildung 62 die prozentuale Überschneidung der Schiffsdomänen (siehe Abschnitt 4.4.2) je Seegebiet dargestellt. Die Darstellung bestätigt grundsätzlich die Beobachtung aus Abbildung 73. Das Modell 2 weist eine höhere prozentuale Überschneidung bei den Schiffsdomänen auf. Folgt

man der oben formulierten These – Prädiktionsmodelle mit einer hohen Domänenüberschneidung sind besser für die Kollisionsvermeidung geeignet –, dann sind die Verhaltensvorhersagen durch das LSTM-Modell mit Seewetterinformationen besser für die Kollisionsvermeidung geeignet.

Auffällig ist allerdings, dass der Unterschied der Domänenüberschneidung zwischen der linearen Prädiktion und dem LSTM ohne Seewetterinformationen größer ist als es die Differenzen in Abbildung 73 vermuten lassen. Diese ist auf die Prädiktionsfehler bei der Vorhersage der zukünftigen Schiffskurse zurückzuführen. Im Gegensatz zu den beiden LSTM-Modellen arbeitet die lineare Prädiktion mit der Prämisse, dass Kurs und Geschwindigkeit im Rahmen der Prädiktion konstant sind. Die Fahrwasser in der Elbe, Jade und Weser sind allerdings kurvig, sodass die lineare Prädiktion einen falschen Kurs annimmt. Dies bestätigt sich, wenn man die Daten betrachtet.




Abbildung 62: Prozentuale Überschneidung der Schiffsdomänen (SD %) der linearen Prädiktion, des LSTM-Modells ohne (Modell 1) und mit Seewetter (Modell 2).

Abbildung 74 (Seite 173) zeigt die Fehler der Kursprädiktion aller drei Vorhersagemodelle oder berücksichtigte Schiffsklassen. Beide LSTM-Modelle haben einen vergleichbaren Fehler, der in allen drei Seegebieten geringer ist als beim linearen Modell. Insgesamt ist im Vergleich zu den beiden LSTM-Modellen eine hohe Schwankung in den Fehlerwerten zu erkennen. Für einen besseren Vergleich der Modelle wird auch hier der RMSE genutzt, der für alle drei Modelle und Seegebiete auf Abbildung 63 sind dargestellt ist. Wie weiter oben geschrieben, wird der Kurs während der Berechnung der Domänenüberschneidung zur korrekten Ausrichtung der jeweiligen Domäne genutzt. Die ellipsoide Domäne ist also entsprechend der Fahrtrichtung des Schiffes ausgerichtet. Da die Kursprädiktion von Modell 2 den Kurs deutlich präziser vorhersagt als das lineare Modell, ist die Überschneidung der Schiffsdomänen größer. Bei der linearen Prädiktion kommt es durch die

Prädiktionsfehler zu einer Verschiebung der Domänen, dessen Ergebnis eine geringe prozentuale Überschneidung ist.

Beide LSTM-Prädiktionen bewegen sich in Bezug auf die Kursprädiktion auf einem vergleichbaren Niveau, bei dem die Unterschiede marginal sind. Das Modell 2 prädiziert in der Elbe und Jade den Kurs genauer, das Modell 1 hat in der Weser den geringeren Fehler produziert.




Abbildung 63: Der Fehler (RMSE) der Kursprädiktion (COG, in Grad) für die lineare Prädiktion, LSTM-Modell 1 und LSTM-Modell 2.

Grundsätzlich lassen sich die oben beschriebenen Beobachtungen auch bei der Geschwindigkeitsprädiktion beobachten. In allen drei Seegebieten hat das lineare Modell einen höheren Fehler als beide LSTM-Modelle (Anhang Seite 174, Abbildung 75). Auf dieser Abbildung ist darüber hinaus zu erkennen, dass Modell 1 eine höhere Schwankung aufweist.

Beim Vergleich des RMSE aller drei Modelle bestätigt sich dieses Erkenntnis. Der geringste Fehler produziert das LSTM-Modell mit Seewetter in Elbe (0,94 Knoten). Allerdings ist bei der Bewertung der Ergebnisse zu berücksichtigen, dass sich die Fehlerwerte aller drei Prädiktionsmodelle auf einem niedrigen Niveau bewegen. Die größte Differenz zwischen der linearen Prädiktion und dem LSTM-Modell mit Seewetter beträgt 1,03 Knoten in der Weser. Des Weiteren sind die grundsätzlichen Schwankungen in den Sensormessdaten zu berücksichtigen, sodass alle drei Prädiktionsmodelle angemessene Ergebnisse liefern. Dennoch lässt sich auch hier festhalten, dass das Seewetter einen positiven Einfluss auf die Güte der Geschwindigkeitsprädiktion hat.

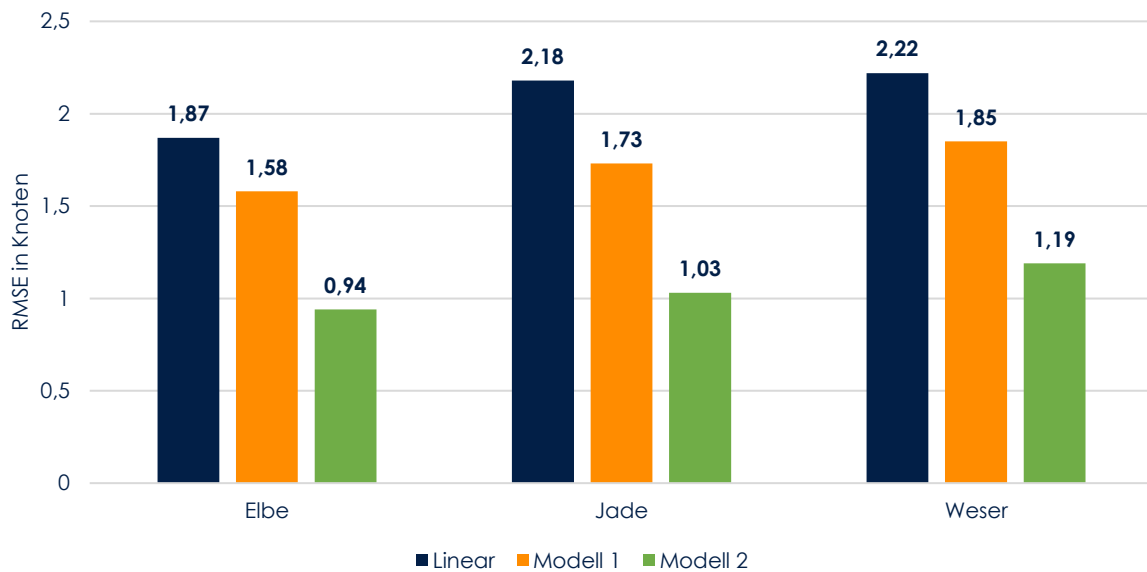


Abbildung 64: Der Fehler (RMSE) der Geschwindigkeitsprädiktion (SOG, in Knoten) für die linearen Prädiktion, des LSTM-Modells ohne (Modell 1) und mit Seewetter (Modell 2).

Um die eingangs aufgestellte Anforderung 8 (Hydrodynamische Schiffseigenschaften) bei der Prädiktion zu berücksichtigen, wurden die Modelle 3 und 4 trainiert (vergleiche Abbildung 51 in Abschnitt 6.1). LSTM-Modell 3 berücksichtigt die Schiffsklasse aber keine Seewetterdaten, wohingegen das Modell 4 sowohl die Schiffsklassen als auch die Seewetterdaten berücksichtigt. Zum Vergleich wurden die linearen Prädiktionsergebnisse entsprechend der Schiffsklassen aufgeteilt. Aufgrund des Umfangs befindet sich eine detaillierte Auflistung der Prädiktionsfehler je Prädiktionsmodell im Anhang. Tabelle 15 und Tabelle 16 beinhaltet die Ergebnisse der linearen Prädiktion je Schiffsklasse. Die Fehler der LSTM-Modells 3 (Tabelle 17 und Tabelle 18) sowie die des LSTM-Modells 4 (Tabelle 19 und Tabelle 20) befinden sich im Anhang. Für eine bessere Vergleichbarkeit wird im Folgenden der RMSE je Modell genutzt.

Auf Abbildung 65 ist der Prädiktionsfehler (RMSE, in Meter) der Position (lineares Modell) beziehungsweise d_{star} (LSTM-Modelle) in Bezug auf die definierten Schiffsklassen und Seegebiete dargestellt. Zunächst fällt auf, dass sowohl die LSTM-Modelle mit und ohne Seewetterinformationen bessere Prädiktionsergebnisse liefern als das lineare Modell. Dieser Trend zeigt sich unabhängig vom jeweiligen Seegebiet. Des Weiteren fällt auf, dass die Prädiktionsgüte für jede Schiffsklasse besser wird, wenn Seewetterinformationen berücksichtigt werden (Modell 4). Weiterhin fällt auf, dass bei größeren Schiffsklassen (unabhängig vom Seegebiet) ein größerer Prädiktionsfehler produziert wird. Vergleicht man darüber hinaus diese Ergebnisse auf Abbildung 65 mit den zuvor diskutierten Ergebnissen auf Abbildung 58 zeigt sich, dass die schiffsklassenspezifischen LSTM-Modelle einen geringeren Prädiktionsfehler produzieren.




Abbildung 65: Der TP-Fehler (RMSE, in Meter) für die spezifischen Schiffsklassen in den drei Seegebieten.

Ähnliches ist für die Prädiktion des Kurses (Abbildung 66) zu beobachten. Insbesondere bei der Vorhersage des Kurses zeigt sich, dass die kontextsensitive Verhaltensprädiktion der linearen Prädiktion überlegen ist. Allerdings zeigt sich hier, dass die Kursvorhersage weniger von der Berücksichtigung des Seewetters abhängt als d_{star} beziehungsweise die Position beim linearen Modell. Die LSTM-Modelle haben für diesen Parameter einen vergleichbaren RMSE.

Die Fehler der Geschwindigkeitsprädiktion (Abbildung 67) zeigen im Gegensatz zur Kursprädiktion ein anderes Ergebnis. Obwohl die Fehler der kontextsensitiven Verhaltensprädiktion (Modelle 3 und 4) geringer sind als die der linearen Prädiktion, bewegen sich die Differenzen jedoch in den überwiegenden Fällen, also unabhängig der Schiffsklasse und des Seegebiets, von rund einem Knoten. Einzig in der Elbe ist für die Schiffsklasse *Cargo groß* ein signifikanter Unterschied bei den Prädiktionsfehlern zu erkennen.

Um die Eignung der schiffsklassenspezifischen Prädiktionsmodelle zur Kollisionsvermeidung zu bewerten ist Abbildung 68 zu betrachten. Für jede Schiffsklasse in jedem Seegebiet haben die Prädiktionsergebnisse der LSTM-Modelle mit Seewetterberücksichtigung die größte prozentuale Domänenüberschneidung. Das deckt sich mit der Erkenntnis aus Abbildung 65, da dieses Prädiktionsmodell den geringsten Fehler produziert hat. Hinzu kommt, dass die Domänenüberschneidung mit größer werdenden Schiffsklassen größer wird. Bezogen auf die Eignungswertung zur Kollisionsvermeidung fällt bei einem Vergleich von Abbildung 65 und Abbildung 68 ein Paradoxon auf. Obwohl der Fehler bei der Vorhersage von d_{star} (Abbildung 65) mit größer werdenden Schiffsklassen zunimmt, nimmt gleichzeitig auch die prozentuale Domänenüberschneidung zu (Abbildung 68). Zu sehen ist dieses Paradoxon beispielsweise bei einem Vergleich der Fehler der LSTM-Modelle mit Seewetterinformationen für kleine und sehr große Cargo-Schiffe in der Elbe. Auf Abbildung 65 ist zu erkennen, dass der Fehler für sehr große Cargo-Schiffe ungefähr doppelt so groß ist, wie der Fehler für kleine Cargo-Schiffe. Dennoch ist die Domänenüberschneidung (Abbildung 68) bei den sehr großen Cargo-Schiffen um rund 20 Prozentpunkt höher. Zurückzuführen ist das auf die Schiffsgröße und somit folglich auf die Fläche, die die jeweiligen Schiffe in den Klassen einnehmen. Die Domänen der sehr großen Cargo-Schiffe nehmen signifikant mehr Wasserfläche ein als die Domänen der kleinen Cargo-Schiffe. Folglich ergibt sich das gerade beschriebene Paradoxon in der Einordnung der jeweiligen Prädiktionsergebnisse. Je größer die Schiffe werden, desto höherer Prädiktionsfehler können kompensiert werden.

Abschließend können die drei Prädiktionsmethoden hinsichtlich ihrer Nutzbarkeit zur vorausschauender Kollisionsvermeidung bewertet werden. Die Darstellung in Abbildung 68 zeigt deutlich, dass das LSTM-Modell mit berücksichtigten Seewetterinformationen besser zur vorausschauender Kollisionsvermeidung geeignet ist als die beiden anderen Methoden. Diese Bewertung folgt der in Abschnitt 4.4.2 These zur anwendungsbezogenen Evaluation von Prädiktionsmethoden von

Schiffsverhalten: Je höher die prozentuale Domänenüberschneidung, desto besser ist die Methode zur Kollisionsvermeidung geeignet. Wie weiter oben gezeigt, sagt ein auf eine Geoposition bezogenes Fehlermaß nur bedingt etwas über die Eignung einer Methode zur Kollisionsvermeidung aus. Mit zusätzlichen Informationen, mit denen der Kontext der jeweiligen Prädiktion beschrieben wird, kann die Eignung zur vorrausschauender Kollisionsvermeidung besser bewertet werden.




Abbildung 66: Der COG-Fehler (RMSE, in °) für die spezifischen Schiffsklassen in den drei Seegebieten.




Abbildung 67: Der SOG-Fehler (RMSE, in Knoten) für die spezifischen Schiffsklassen in den drei Seegebieten.




Abbildung 68: Die prozentuale Überschneidung der Schiffsdomänen je Schiffsklasse und Seegebiet.

Anomaliedetektion

Tabelle 10 zeigt die Anzahl der detektierten Anomalien aus dem Testdatensatz für d_{star} , SOG und COG, unterteilt nach Seegebiet.

Tabelle 10: Detektierte Anomalien je Seegebiet und Kategorie

d_{star}	Elbe	268
	Jade	11
	Weser	166
COG	Elbe	44
	Jade	15
	Weser	42
SOG	Elbe	96
	Jade	13
	Weser	97

Grundsätzlich fällt auf, dass in der Jade – unabhängig von der Kategorie – signifikant weniger Anomalien detektiert wurden. In der Elbe und Weser wurden für den Kurs und die Geschwindigkeit nahezu gleich viele Anomalien detektiert. Einzig bei der Distanz zur Steuerbordseite wurden in der Elbe mit 268 deutlich mehr Anomalien identifiziert als in der Weser (166) und Jade (11).

Abbildung 69 zeigt exemplarisch eine Anomalie für d_{star} und für den Kurs. Die roten Quadrate zeigen die Schiffsposition, die Pfeile den Kurs. Die d_{star} Anomalie zeigt Schiffe, die zu weit in der Mitte des Fahrwassers fahren. An dieser Stelle ist das Fahrwasser rund einen Kilometer breit und die Schiffe fahren nahezu in der Mitte des Fahrwassers beziehungsweise fährt das untere Schiff (d_{star} von 547 m) auf der falschen Fahrwasserseite und kann somit eine potenzielle Gefahr für entgegengerichtete Schiffe darstellen. Die Kursanomalie auf der Abbildung zeigt zwei Schiffe, deren Kurse zu weit in westlicher Richtung zeigen. Insbesondere bei dem Schiff mit dem Kurs 247° erkennt man am eingezeichneten Bewegungspfeil, dass der eingeschlagene Kurs das Schiff weiter in Richtung Fahrwasserrand führen wird. In diesem Abschnitt des Fahrwassers ist Kurs zu erwarten, der weiter in Richtung Süden zeigt.

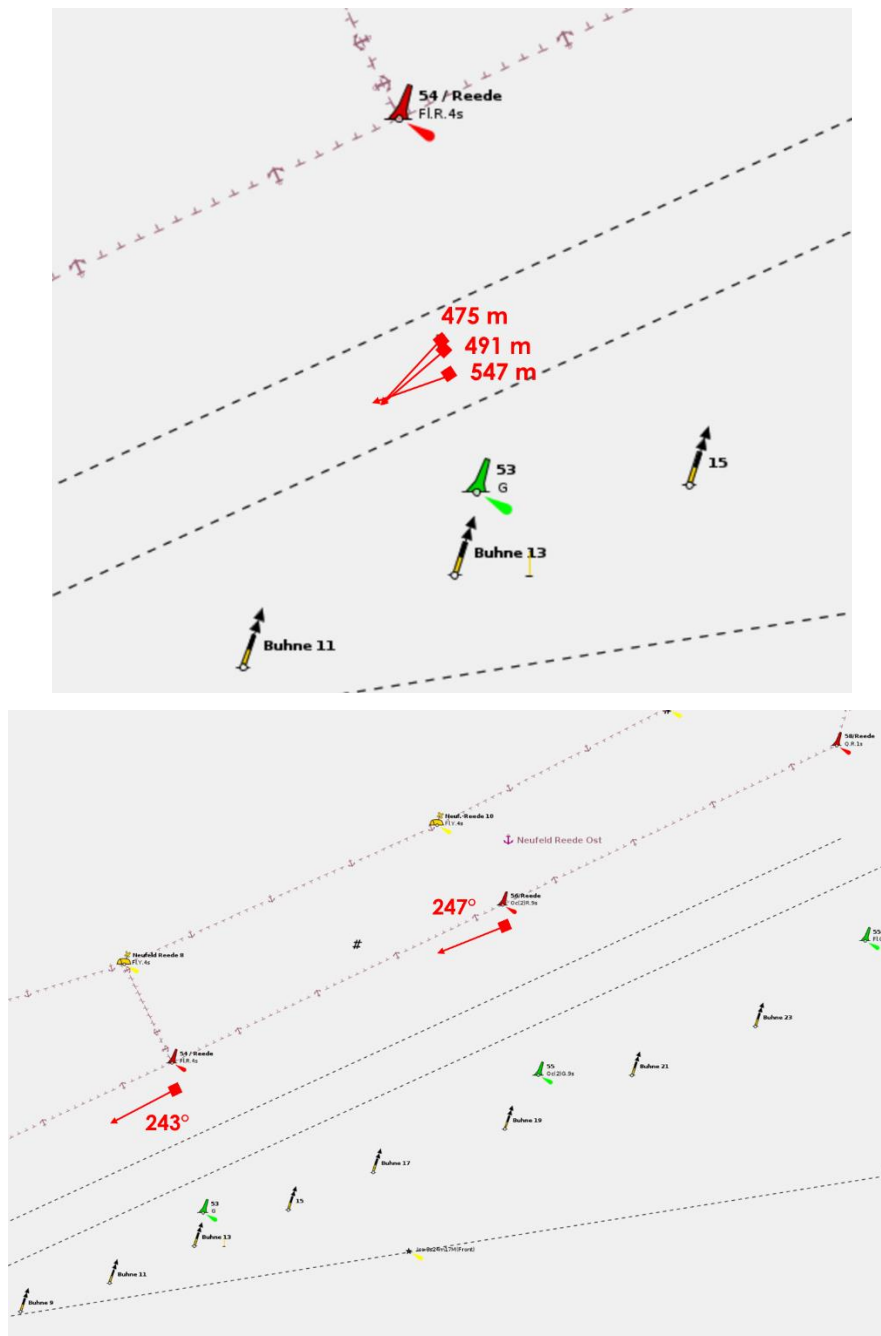


Abbildung 69: Detektierten Anomalien für d_{star} (oben) und für den Kurs (unten).

Um die Anomaliedetektion qualitativ bewerten zu können, wird eine Stichprobe der detektierten Anomalien einer fachkundigen Person mit nautischer Ausbildung vorgelegt. Der Person wird erklärt, wie die Anomalien berechnet werden. Zur Bewertung werden die ausgewählten Anomalien auf einer Seekarte dargestellt. Die als anomal bewerteten Werte (Distanz zur Steuerbordseite, Kurs oder Geschwindigkeit) werden ebenfalls dargestellt. Abbildung zeigt ein Beispiel, wie der fachkundigen Person Kursanomalien vorgelegt wurden.




Abbildung 70: Beispiel einer Kurs-Anomalie, die der fachkundigen Person vorgelegt wird.

Die Grundgesamtheit N ergibt sich je Anomaliekategorie aus den Summen der detektierten Anomalien in den jeweiligen Seegebieten (siehe Tabelle 10). Das Ergebnis der Bewertung ist die False-Positive-Rate (FPR) der jeweiligen Anomalien und wird in Tabelle 11 dargestellt.

Tabelle 11: Übersicht der False-Positive Rate (FPR) der detektierten Anomalien

	d_{star}	COG	SOG
Detektierte Anomalien	445	101	206
Stichprobengröße	59	41	52
Anzahl FP	21	21	6
FPR	0,3559	0,5122	0,1154

Auffällig ist zunächst die FPR für die COG-Anomalien. Die fachkundige Person hat die Hälfte aller Kursanomalien als normales Verhalten deklariert. Etwas mehr als zwei Drittel der Anomalien für d_{star} in der Stichprobe wurden als normal klassifiziert. Die geringste FPR ist bei der SOG zu verzeichnen. Aus der Stichprobe wurde nur rund jede zehnte Anomalie als normales Verhalten klassifiziert.

Grundsätzlich ist festzuhalten, dass die auf diese Weise detektierten Anomalie stets eine Momentaufnahme an der jeweiligen Zellgrenze sind. Die Ergebnisse in Tabelle 11 deuten zunächst darauf hin, dass dieses Verfahren für die Detektion von SOG-Anomalien in Relation zu den ande-

ren beiden Kategorien am zuverlässigsten ist. Mit Einschränkungen gilt ähnliches für d_{star} -Anomalien. Dass rund jede zweite Kursanomalie als FP bewertet wurde deutet darauf hin, dass Kurse im Rahmen der Anomaliedetektion nicht als einzige Momentaufnahme, sondern im Gesamtkontext bewertet werden müssen. Je nach Verlauf der Wasserstraße scheinen anomale Schiffskurse aus Sicht der befragten fachkundigen Person an der jeweiligen Stelle normal zu sein.

6.4 Zusammenfassung und Abdeckung der Anforderungen

Basierend auf den in Abschnitt 1.3 formulierten Anforderungen wurde eine Methode zur kontextsensitiven Verhaltensprädiktion in küstennahen Gewässern entwickelt und evaluiert. In dieser Arbeit wird der Kontext von Schiffsverhalten durch die relevanten Seekarten- und historische Seewetterinformationen definiert. Basierend auf ihren räumlichen und zeitlichen Eigenschaften wurde ein Vorgehen präsentiert, welches Seekarten- und historische Seewetterinformationen mit historischen AIS-Daten kombiniert (siehe Abschnitt 4).

Das Verfahren wurde prototypisch als KDD-Prozess umgesetzt (siehe Abschnitt 5) und mit historischen AIS-Daten, die einen Zeitraum von drei Monaten abdecken, in der Jade, Weser und Elbe evaluiert (siehe Abschnitt 6). Als Referenz zur Bewertung der Prädiktionsgüte wurde die lineare Verhaltensprädiktion umgesetzt und genutzt. Die Evaluation zeigt, dass die kontextsensitive Verhaltensprädiktion präzisere Prädiktionsergebnisse liefert als die lineare Verhaltensprädiktion. Des Weiteren geht aus den Daten hervor, dass die Güte der kontextsensitiven Verhaltensprädiktion durch die Berücksichtigung von historischen Seewetterinformationen gesteigert werden kann. Gleiches gilt für die Nutzung schiffsklassenspezifischer Modelle, mit denen die Prädiktionsgüte weiter gesteigert werden konnte.

Zur Bewertung der Nutzbarkeit der kontextsensitiven Verhaltensprädiktion zur vorrausschauender Kollisionsvermeidung wurde die Überschneidung der prädizierten und tatsächlichen Schiffsdomäne berechnet. Auch hier zeigt sich, dass die kontextsensitive Verhaltensprädiktion in küstennahen Gewässern besser zur vorrausschauenden Kollisionsvermeidung geeignet ist als die lineare Verhaltensprädiktion. Für die kontextsensitive Verhaltensprädiktion konnte im Vergleich zur linearen Prädiktionsmethode eine signifikant höhere prozentuale Überschneidung der Schiffsdomänen gemessen werden. Eine Aussage zu einem potenziellen Schwellenwert der prozentualen Überschneidung kann allerdings nicht getroffen werden.

Darüber hinaus konnte gezeigt werden, dass die kontextsensitive Verkehrsmusterextraktion und -modellierung zur Detektion von anomalem Schiffsverhalten geeignet ist. Im Rahmen der Evaluation wurde gezeigt, wie an den Übergangspunkten der Gitter das wahrscheinlichste Verhal-

ten extrahiert werden kann. Im Umkehrschluss ergibt das wahrscheinlichste Verhalten das unwahrscheinlichste an den jeweiligen Übergangspunkte, was als Anomalie definiert wurde. Dieses Vorgehen wurde genutzt, um anomales Schiffsverhalten in den verwendeten AIS-Daten (siehe oben) zu detektieren. Die detektierten Anomalien wurden anschließend qualitativ durch eine fachkundige Person bewertet. Hieraus wurde die FPR berechnet, die insbesondere bei Kursanomalien mit knapp 50% hoch ist.

Im Folgenden wird diskutiert, in welchem Maße die entwickelte Methode zur kontextsensitiven Verhaltensprädiktion die Ziele der Arbeit und die daraus abgeleiteten Anforderungen abdeckt. Die Bewertung erfolgt argumentativ.

A.1 *Vorrausschauende Kollisionsvermeidung.* Die Prädiktionsmethode ist besser für die vorrausschauende Kollisionsvermeidung in küstennahen Gewässern geeignet als die lineare Verhaltensprädiktion, die auf heutigen Schiffsbrücken zum Einsatz kommt. Mit der Berechnung der prozentualen Überschneidung der Schiffsdomänen wurde ein Evaluationsverfahren aufgezeigt, mit dem die vorrausschauende Gefahrenbewertung gemessen werden kann. Die unterschiedlichen hydrodynamischen Eigenschaften der Schiffe wurden durch die Bildung von Schiffsklassen berücksichtigt. Die Anforderung gilt als erfüllt.

A.2 *Genauigkeit* & A.3 *Gültigkeit.* Neben der kontextsensitiven Verhaltensprädiktion wurde das lineare Prädiktionsverfahren, welches heute auf Schiffsbrücken eingesetzt wird, prototypisch umgesetzt. Die Evaluation hat gezeigt, dass die Güte der kontextsensitiven Verhaltensprädiktion besser ist als die der linearen Verhaltensprädiktion.

Gleichzeitig wurde gezeigt, dass Verkehrsmuster, die zur Prädiktion genutzt und für bestimmte Schiffsklassen und Seegebiete gültig sind, präzisere Ergebnisse liefern. Beide Anforderungen gelten damit als erfüllt.

A.4 *Anomaliedetektion.* Basierend auf den Übergangspunkten kann das wahrscheinlichste Schiffsverhalten berechnet werden. Im Umkehrschluss ergibt sich hieraus das unwahrscheinlichste Verhalten, welches als anomales Verhalten definiert ist. Die in dieser Arbeit detektierten Anomalien wurden darüber hinaus qualitativ bewertet. Die Anforderung gilt als erfüllt.

A.5 *Berücksichtigung meteorologische Bedingungen* & A.6 *Berücksichtigung ozeanographischer Bedingungen.* Basierend auf den existierenden Verfahrensstandards und der Literatur wurden die relevanten meteorologischen (Windrichtung und -geschwindigkeit) und ozeanographi-

schen Bedingungen (signifikante Wellenhöhe und Tide) identifiziert. Basierend auf ihren räumlichen und zeitlichen Eigenschaften wurden die identifizierten Bedingungen mit historischen AIS-Daten kombiniert und zur Verkehrsmusterextraktion verwendet. Die Verkehrsmuster wurden anschließend zur Verhaltensprädiktion verwendet. Beide Anforderungen gelten als erfüllt.

A.7 Seekarteninformationen. Für die betrachteten küstennahen Seegebiete wurden aus elektronischen Seekarten die Betonungsinformationen der Fahrwasser extrahiert. Diese Informationen wurden anschließend dazu genutzt, ein Gitter aufzubauen, welches das Fahrwasser abbildet. Im Rahmen der Verkehrsmusterextraktion wurden das spezifische Verhalten an den Zellgrenzen berechnet (Übergangspunkte). Historische Schiffsbahnen wurden im Folgenden als Sequenz von Übergangspunkten modelliert. Die Anforderung gilt als erfüllt.

A.8 Hydrodynamische Schiffseigenschaften & A.11 Abbildung hydrodynamischer Eigenschaften. Für diese Arbeit gilt die These, dass Schiffe mit ähnlichen Dimensionen vergleichbare hydrodynamische Eigenschaften haben. Aus diesem Grund wurden basierend auf der Länge der Schiffe spezifische Schiffsklassen gebildet. Die Einteilung der Schiffsklassen wurde basierend auf dem verwendeten Datensatz explorativ vorgenommen. Für die kontextsensitive Verhaltensprädiktion wurden schiffsklassenspezifische Verkehrsmuster extrahiert und zur Prädiktion verwendet (via LSTM-Modelle). Folglich gelten beide Anforderungen als erfüllt.

A.9 Nutzung historischer Verkehrsdaten & A.10 Datenanreicherung: In dieser Arbeit werden historische AIS-Daten verwendet, um typische Bewegungsmuster zu extrahieren. Hierfür werden die AIS-Daten mit den zuvor identifizierten meteorologischen, ozeanographischen Daten sowie mit der Betonungsinformation aus der Seekarte basierend auf ihren räumlichen und zeitlichen Eigenschaften kombiniert (siehe Abschnitt 4.3). Beide Anforderungen gelten als erfüllt.

A.12 Abbildung kontextueller Bedingungen. Für die Extraktion der Verkehrsmuster wurde in Abschnitt 4.3 das Konzept der Übergangspunkte eingeführt. Ein Übergangspunkt wird durch den Abstand zur steuerbordseitigen Tonne, dem Kurs und der Geschwindigkeit definiert. Hinzu kommen die ozeanographischen und meteorologischen Bedingungen zum jeweiligen Zeitpunkt. Auf diese Weise bilden die Übergangspunkte die zuvor identifizierten kontextuellen Bedingungen ab. Die Anforderung gilt somit als erfüllt.

A.13 Kontextuelle Informationen zur Prädiktion. Die eigentliche Methode zur Verhaltensvorhersage der in dieser Arbeit entwickelten Methode zur kontextsensitiven Verhaltensprädiktion ist ein LSTM-Modell. Die im Rahmen des Trainings verwendeten Feature sind die Übergangspunkte, die, wie oben definiert, kontextuelle Bedingungen des jeweiligen Schiffsverhaltens abbilden. Somit werden diese Bedingungen beim Training und auch bei der eigentlichen Vorhersage berücksichtigt, wodurch diese Anforderung als erfüllt gilt.

A.14 Vorhergesagte Bahnpunkte. Für diese Arbeit wurde in Abschnitt 4.3 definiert, dass Schiffsbahnen aus einer Sequenz von Übergangspunkten bestehen. Wie oben beschrieben, werden diese Übergangspunkte zum Training des Vorhersagemodells genutzt. Ziel ist es, basierend auf einer Sequenz an beobachteten Übergangspunkten zukünftige Übergangspunkte zu präzisieren. Folglich sind die präzisierten Übergangspunkte die Bahnpunkte. Die Anforderung gilt als erfüllt.

Basierend auf dem Abdeckungsgrad der Anforderungen gelten die übergeordneten Ziele der Arbeit als erfüllt und die eingangs formulierten Forschungsfragen können beantwortet werden.

„Wie kann das wahrscheinlichste Schiffsverhalten unter Berücksichtigung von kontextbezogenen Informationen und Wissen über typisches Schiffsverhalten vorhergesagt werden?“

Mit den Unterfragen:

- 1. Wie müssen historische Bewegungsdaten mit Kontextinformationen verknüpft werden, damit das wahrscheinlichste Verhalten präzisiert werden kann?*
- 2. Wie sind kontextsensitive Verhaltensmuster zu repräsentieren, um sie zur Verhaltensprädiktion von Schiffen verwenden zu können?*

Die Evaluation hat gezeigt, dass in küstennahen Gewässern das wahrscheinlichste Verhalten unter der Verwendung von Seekarteninformationen (laterale Betonung), meteorologischen und ozeanographischen Informationen vorhergesagt werden kann. Durch die gemeinsamen räumlichen und zeitlichen Informationen können die jeweiligen Daten miteinander verknüpft werden. Schiffspositionen und Informationen über die laterale Betonung aus den Seekarten werden über den steuerbordseitigen Abstand der Schiffsposition und der Betonung miteinander verknüpft. Die Modellierung der kontextsensitiven Verhaltensmuster geschieht durch das Konzept der Übergangspunkte, die immer zwischen zwei lateralen Tonnen liegen. In der Evaluation wurde nachgewiesen,

dass mit der Methode der kontextsensitiven Verhaltensprädiktion Schiffsverhalten präziser vorhergesagt werden kann als mit dem linearen Verfahren, welches standardmäßig auf Schiffsbrücken zum Einsatz kommt.

7 Fazit

In dieser Arbeit wurde ingenieurwissenschaftlich eine Methode zur kontextsensitiven Verhaltensprädiktion in küstennahen Gewässern konzipiert und evaluiert. Hierfür wurde zunächst in Abschnitt 1 die Problemstellung identifiziert und hieraus Forschungsfragen abgeleitet. Wesentliches Ergebnis des Abschnitts sind die aus der Problemstellung und den Forschungsfragen abgeleiteten Anforderungen an ein Lösungskonzept.

Anschließend wurden in Abschnitt 2 die relevanten Grundlagen erläutert, die sowohl für das Verständnis des Stands der Wissenschaft und Technik als auch für den Konzeptionsteil relevant sind.

Basierend auf der Problemstellung und den Anforderungen aus Abschnitt 1 wurde der Stand der Wissenschaft und Technik in Abschnitt 3 analysiert. Neben der maritimen Domäne wurden Ansätze zur Verhaltensprädiktion von Fahrzeugen aus dem Automotive-Bereich und der Vorhersage des Luftfahrzeugsverhaltens betrachtet. Als Ergebnis wurde die für diese Arbeit relevante Forschungslücke identifiziert und beschrieben.

Im darauffolgenden Abschnitt 4 wurde das Konzept zur kontextsensitiven Verhaltensprädiktion entwickelt, um die identifizierte Forschungslücke zu schließen. Wesentliche Grundlage für die Konzeptionierung waren wieder die zu Beginn abgeleiteten Anforderungen.

Abschnitt 5 beinhaltet die Evaluation der kontextsensitiven Verhaltensprädiktion. Es wurde gezeigt, dass die in dieser Arbeit entwickelte Methode präziser Schiffsverhalten vorhersagen kann als die heute standardmäßig verwendete lineare Prädiktion. Gleichzeitig wurde gezeigt, inwiefern das Konzept der Übergangspunkte dazu geeignet ist, anomales Schiffsverhalten zu detektieren. Die identifizierten Anomalien wurden abschließend qualitativ von einer fachkundigen Person bewertet. Darüber hinaus konnte in dem Abschnitt 5 argumentativ aufgezeigt werden, dass die kontextsensitive Verhaltensprädiktion die definierten Anforderungen erfüllt und die Forschungsfragen beantwortet werden können. Das Ziel der Arbeit ist somit erreicht.

Im Folgenden wird der wissenschaftliche Beitrag der Arbeit herausgestellt. Daran schließt sich eine Diskussion an, in der potenzielle Anwendungsmöglichkeiten und Grenzen des entwickelten Konzepts aufgezeigt werden. Die Arbeit schließt, indem der weitere Forschungsbedarf aufgezeigt wird.

7.1 Wissenschaftlicher Beitrag

Die in Abschnitt 4 vorgestellte Methode zur kontextsensitiven Verhaltensprädiktion von Schiffen adressiert die in Abschnitt 3 identifizierte Forschungslücke. Der dabei entstandene wissenschaftliche Beitrag besteht aus drei Säulen.

Kontextsensitive Prädiktion: In Abschnitt 1 wurde dargelegt, dass das nautische Personal an Bord im Rahmen der Kollisionsvermeidung die Umgebung und die Seewetterbedingungen berücksichtigen. Auf Basis dieser Beobachtungen und der allgemeinen und ganz spezifischen Erfahrung des nautischen Personals wird die unzureichende lineare Verhaltensprädiktion der an Bord befindlichen Systeme ausgeglichen. Die hier vorgestellte Methode zur kontextsensitiven Verhaltensprädiktion berücksichtigt diese Kontextinformationen und generiert entsprechende kontextsensitive Verhaltensmuster, die zur Prädiktion genutzt werden. Damit liefert diese Arbeit einen Beitrag, um die in Abschnitt 3.4 identifizierte Forschungslücke zu schließen.

Präziser durch Seewetter: Ein zentrales Ergebnis von Abschnitt 3 ist die Erkenntnis, dass bisherige Forschungsarbeiten zur Verhaltensprädiktion von Schiffen weder meteorologische noch ozeanographische Informationen nutzen. In dieser Arbeit wurden zur Prädiktion die Windstärke und -geschwindigkeit, die signifikante Wellenhöhe und Tideinformationen verwendet. Die in Abschnitt 6 präsentierten Ergebnisse zeigen, dass die Prädiktionsgüte in Bezug auf die Kurs- und Positionsprädiktion steigt, sobald meteorologische und ozeanographische Informationen berücksichtigt werden. Die Arbeit trägt somit zu einem besseren Verständnis bei, inwiefern Seewetterinformationen bei der Prädiktion genutzt werden können und inwiefern sie die Prädiktionsgüte verbessern können.

Anwendungsorientierte Evaluation: In Abschnitt 4 wurde argumentiert, dass ein bewertender Vergleich zwischen Prädiktionsmethoden im Kontext einer späteren Anwendung geschehen muss. In dieser Arbeit wurde ein Verfahren demonstriert, mit dem Prädiktionsmethoden zur Anwendung der vorrausschauenden Kollisionsvermeidung evaluiert werden können. Hierfür wird das Konzept der Schiffsdomänen genutzt und die prozentuale Überschneidung zwischen der tatsächlichen und prädizierten Domäne berechnet. Eine Methode ist dann besser zur Verhaltensprädiktion im Rahmen der Kollisionsvermeidung geeignet, wenn sie eine höhere prozentuale Überschneidung hat als die Vergleichsmethode. Der wissenschaftliche Beitrag besteht somit darin, dass Prädiktionsalgorithmen hinsichtlich ihrer Nutzbarkeit für die vorrausschauende Kollisionsvermeidung miteinander verglichen werden können.

7.2 Anwendungsmöglichkeiten und Grenzen der Lösung

Praktische Anwendungsmöglichkeiten für die in dieser Arbeit entwickelten Methoden zur kontextsensitiven Verhaltensprädiktion bieten sich sowohl an Bord der Schiffe als auch an Land.

Auf Schiffsbrücken kann die Methode eingesetzt werden, um das nautische Personal bei der Identifizierung, Bewertung und Auflösung von gefährlichen Schiff-zu-Schiff-Begegnungen unterstützen. In küstennahen Gewässern, die durch Wasserstraßen reglementiert sind, können zukünftige Schiffsbewegungen präziser abgeschätzt werden, als wenn das lineare Modell zur Verhaltensprädiktion verwendet wird. Darüber hinaus ist ein solches System die Grundlage für zukünftige intelligente Assistenzsysteme, die für den sicheren Betrieb hochautomatisierter Schiffe benötigt werden. Ein solches Assistenzsystem kann beispielsweise auf Basis der Verhaltensprädiktionen ein intelligentes Verkehrslagebild erstellen, welches automatisiert ausgewertet wird. Ziel ist die automatisierte Identifizierung von kritischen Schiff-zu-Schiff-Begegnungen.

Eine weitere Anwendungsmöglichkeit ist die Anzeige der erwarteten Schiffsdomäne für das nautische Personal auf der Brücke. Die Anzeige der wahrscheinlich zu erwartenden Domäne kann dem nautischen Personal helfen, die Interpretation von Schiff-zu-Schiff-Begegnungen zu verbessern. So können Begegnungssituationen eindeutiger dargestellt werden, was potenzielle Missverständnisse in der Bewertung solcher Situationen reduzieren kann.

Landseitig kann die Methode zur kontextsensitiven Verhaltensprädiktion perspektivisch in einem Rechenzentrum in einem VTS eingesetzt werden. Dort kann es – analog zum Einsatz auf der Schiffsbrücke – zur Detektion gefährlicher Schiff-zu-Schiff-Begegnungen genutzt werden. Sobald eine solche Begegnung identifiziert ist, können die VTS-Operatoren benachrichtigt werden und unter Umständen durch eine rechtzeitige Kontaktaufnahme mit den beiden Schiffen Kollisionen vermeiden. Der Einsatz der Methode zur Anomaliedetektion hat das Potenzial, die Arbeitsbelastung der VTS-Operatoren zu reduzieren. Insbesondere in der Deutschen Bucht ist eine rein manuelle Verkehrsüberwachung aufgrund der hohen Verkehrsdichte eine kognitive Herausforderung. Das in dieser Arbeit präsentierte Vorgehen zur Anomaliedetektion kann anomales Verhalten automatisiert identifiziert werden. Durch einen entsprechenden Hinweis können die VTS-Operatoren benachrichtigt werden und können anschließend – basierend auf ihrer nautischen Expertise – entscheiden, inwiefern es sich bei der Situation tatsächlich um anomales Schiffsverhalten handelt.

Die Evaluation in Abschnitt 5 hat gezeigt, dass die zukünftige Geschwindigkeit der Schiffe mittels der kontextsensitiven Verhaltensprädiktion mit einem geringen Fehler vorhergesagt werden kann. Dies kann einen Beitrag zu einer präziseren ETA-Berechnung (Estimated Time of Arrival) der Schiffe führen, was die Grundlage für die maritime Verkehrssteuerung ist. So kann beispielsweise die Auslastung von Wasserstraßen besser abgeschätzt werden. Gleichzeitig kann das „Hurry

up and wait“-Phänomen in der Schifffahrt vermieden werden. Dieses Phänomen besagt, dass die Schiffe mit hoher Geschwindigkeit in Richtung Zielhafen segeln, nur um dann auf eine Rede warten zu müssen, weil der vorgesehene Liegeplatz noch belegt ist. Eine präzisere ETA-Berechnung und eine darauf basierend intelligente Verkehrssteuerung kann diesem Phänomen vorbeugen und so Logistikketten optimieren. Durch eine Verringerung der Geschwindigkeit kann darüber hinaus ein Beitrag zum maritimen Umwelt- und Klimaschutz geleistet werden.

Neben den potenziellen Anwendungsmöglichkeiten der Methode in der Praxis existieren allerdings auch Grenzen. Deutlich wird dies bei der Verfügbarkeit der hier verwendeten Daten während einer Seereise. Hervorzuheben sind hier insbesondere die Informationen zum Seegang beziehungsweise die signifikante Wellenhöhe. Grundsätzlich besteht die Möglichkeit, mittels eines am Schiff montierten Wellenradars die signifikante Wellenhöhe zu berechnen. Entsprechende Produkte sind am Markt verfügbar²⁴. Zum aktuellen Zeitpunkt besteht allerdings keine Ausrüstungspflicht für die Schiffe, sodass lediglich eine kleine Minderheit der Welthandelsflotte mit der entsprechenden Technologie ausgerüstet ist.

Während der Umsetzung beziehungsweise für die Evaluation wurden historische Verkehrsdaten verwendet, die eine dreimonatigen Zeitraum abbilden. Die daraus generierten kontextsensitiven Verhaltensmuster haben im Kontext einer späteren Anwendbarkeit in der Praxis wahrscheinlich einen geringen Nutzwert. Für einen Produktivbetrieb muss die Menge an historischen Verkehrsdaten sowie Seewetterdaten bedeutend größer sein, um aussagekräftige Muster extrahieren zu können.

Zur anwendungsorientierten Bewertung des Kollisionsrisikos wird in dieser Arbeit die Schiffsdomäne nach Fujii und Tanaka (Fujii und Tanaka 1971) genutzt. Diese Domäne ist eine Ellipse, sodass die anschließende Berechnung der Überschneidung zwischen zwei Domänen simpel ist. Die im weiteren Verlauf der Zeit entstandenen Domänen sind komplexer und zum Teil asymmetrisch. Insbesondere dann, wenn die spezifischen COLREG-Regeln abgebildet werden sollen (siehe Abschnitt 4.4.1). Komplexere und COLREG-spezifische Domänenmodelle haben zumindest das Potenzial, eine Anforderung an die Präzision bei der Prädiktion definieren zu können. Hinzu kommt, dass mit dem Domänenmodell lediglich eine weitere Maßzahl präsentiert wurde, die einen anwendungsorientierten Vergleich zwischen zwei Prädiktionsmethoden zur vorausschauenden Kollisionsvermeidung ermöglicht. Was in diesem Zusammenhang noch fehlt, ist ein Schwellenwert, aber wann die Prädiktionsgüte eines Verfahrens hinreichend gut ist, um zur Kollisionsvermeidung eingesetzt werden zu können.

²⁴ Beispielhaft: <https://nextocean.nl/technology.php> (Letzter Abruf 18.11.2023)

Im Rahmen der Anomaliedetektion ist hervorzuheben, dass mit dem oben präsentierten Verfahren Anomalien an fest definierten Orten (hier Übergangspunkte) detektiert werden können. Aufgrund der Eigenheit des lateralen Betonungssystem (siehe Abschnitt 2.3) schwankt die Distanz zwischen zwei Übergangspunkten zwischen 1,5 und 2 Kilometern. In diesem Abschnitt zwischen den Übergangspunkten existiert somit ein blinder Fleck, bei dem keine Anomalien detektiert werden können.

7.3 Ausblick

Diese Arbeit ist die Grundlage für weitere Forschungsaktivitäten rund um die Prädiktion von Schiffsverhalten. Im Folgenden werden potenzielle Anknüpfungspunkte erläutert, die sich aus der Methode als solche und aus den Erkenntnissen der Evaluation ergeben.

Präzisere Verkehrsmuster durch Radar. Die in dieser Arbeit verwendeten Verkehrsmuster basieren auf historischen AIS-Daten. Trotz der großen Verfügbarkeit der AIS-Daten ist immer zu berücksichtigen, dass die darin versendeten Informationen von fremder Sensorik stammen und unter Umständen manipuliert sein können. Für eine sicherheitskritische Anwendung der kontextsensitiven Verhaltensprädiktion ist dies ein Risiko. Durch die zusätzliche Berücksichtigung von Radardaten und einer entsprechenden Assoziation historischer AIS- und Radardaten kann die Präzision der Zuverlässigkeit der Verkehrsmuster potenziell gesteigert werden. Zumal in den SOLAS definiert ist, dass die ausschließliche Verwendung von AIS-Daten zur Kollisionsvermeidung nicht zulässig ist.

Laufende Aktualisierung der Verkehrsmuster. Für eine zukünftige Praxisanwendung der kontextsensitiven Verhaltensprädiktion ist es notwendig, dass sich die Verkehrsmuster laufend aktualisieren. Insbesondere, wenn sich beispielsweise die Verkehrsführung in einer Wasserstraße grundlegend ändert, liefern Prädiktionsmodelle, die auf nicht aktuellen Verkehrsdaten basieren, unzureichende Prädiktionsergebnisse. Aus datenwissenschaftlicher Sicht ist die kontextsensitive Verhaltensprädiktion einen Gesamtprozess zu integrieren, der bereits gelernte Verkehrsmuster mit neuen Bewegungsdaten aktualisieren kann. Dabei gilt es zu untersuchen, inwiefern eine höhere Gewichtung neuer Verkehrsdaten sinnvoll sein kann.

Schwellenwert für die Schiffsdomänen. Die prozentuale Überschneidung der Schiffsdomänen hilft bei der Bewertung des Prädiktionsfehler in Bezug auf die Dimensionen des Schiffes. Allerdings

fehlt ein Schwellenwert, der eine hinreichend präzise Prädiktionsgüte in Abhängigkeit der Schiffsdimensionen definiert. Um einen solchen Schwellenwert abzuleiten, können Unfälle oder Beinahekollisionen statistisch ausgewertet werden. Hierfür können die Situationen simulativ hinsichtlich ihrer Domänenüberschneidung untersucht werden.

Berücksichtigung weiterer meteorologische und ozeanographische Parameter. In dieser Arbeit wurde gezeigt, dass die Berücksichtigung von Seewetterinformationen einen positiven Einfluss auf die Prädiktionsgüte hat. Neben den bereits berücksichtigten Parametern existieren weitere, die möglicherweise einen Einfluss auf die Prädiktionsgüte haben. Die Sichtweite im Allgemeinen beziehungsweise Nebel im Speziellen können insbesondere in verkehrsreichen Gebieten das Schiffsverhalten deutlich beeinflussen. Gleiches gilt für die Strömung des Wassers, die je nach Stärke und Richtung einen Einfluss auf das Verhalten des Schiffes haben könnte.

Prädiktion der Interaktion zwischen zwei Schiffen. Das hier vorgestellten Prädiktionsverfahren berücksichtigt den potenziellen Einfluss anderer Schiffe auf das zukünftige Verhalten eines Schiffes nicht. Neben dem Seewetter kann die vorliegende Verkehrsdichte sowie der wahrscheinliche Verlauf der zukünftigen Bahnen anderer Schiffe einen Einfluss auf das Verhalten haben. Die Berücksichtigung dieser Informationen im Rahmen der Verkehrsmusterextraktion sowie der Verhaltensprädiktion kann im Rahmen zukünftiger Forschungsaktivitäten weiter untersucht werden.

Anomaliedetektion in der gesamten Zelle. Wie oben erläutert kann mit dem in dieser Arbeit vorgestellten Verfahren zur Anomaliedetektion lediglich anomales Schiffsverhalten an den Übergangspunkten detektiert werden. Zukünftige Forschung kann sich darauf fokussieren, anomales Verhalten in den Zellen des genutzten Gitters zu detektieren. Ein erster Ansatz bietet die in Abschnitt 4.3.1 beschriebene Vorstudie, in der Schiffsverhalten über richtungsbezogene Korridore modelliert wird. Im Zuge der Anomaliedetektion können diese Korridore das wahrscheinlichste Verhalten modellieren. Sobald sich ein Schiff dann außerhalb des jeweiligen Korridors bewegt, wäre sein Verhalten als anomal zu klassifizieren.

Literaturverzeichnis

- ALIZADEH, D., ALESHEIKH, A.A. und SHARIF, M., 2021. Vessel Trajectory Prediction Using Historical Automatic Identification System Data. *Journal of Navigation*, vol. 74, no. 1, pp. 156–174. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463320000442.
- ALLIANZ GLOBAL CORPORATE AND SPECIALTY, 2018. Safety and Shipping Review 2018 - An annual review of trends and developments in shipping losses and safety. [Online]. S.l.: [Zugriff am 26 November 2018]. Verfügbar unter: https://www.agcs.allianz.com/assets/PDFs/Reports/AGCS_Safety_Shipping_Review_2018.pdf.
- ALTHOFF, M. und MERGEL, A., 2011. Comparison of Markov Chain Abstraction and Monte Carlo Simulation for the Safety Assessment of Autonomous Cars. *IEEE Transactions on Intelligent Transportation Systems*, vol. 12, no. 4, pp. 1237–1247. ISSN 1524-9050. DOI 10.1109/ITITS.2011.2157342.
- AMMOUN, S. und NASHASHIBI, F., 2009. Real time trajectory prediction for collision risk estimation between vehicles. *2009 IEEE 5th International Conference on Intelligent Computer Communication and Processing*. Cluj-Napoca, Romania: IEEE, pp. 417–422. ISBN 978-1-4244-5007-7. DOI 10.1109/ICCP.2009.5284727.
- AVANZINI, G., 2004. Frenet-Based Algorithm for Trajectory Prediction. *Journal of Guidance, Control, and Dynamics*, vol. 27, no. 1, pp. 127–135. ISSN 0731-5090, 1533-3884. DOI 10.2514/1.9338.
- AYHAN, S. und SAMET, H., 2016. Aircraft Trajectory Prediction Made Easy with Predictive Analytics. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16*. San Francisco, California, USA: ACM Press, pp. 21–30. ISBN 978-1-4503-4232-2. DOI 10.1145/2939672.2939694.
- BAILEY, N., ELLIS, N. und SAMPSON, H., 2008. *Training and Technology Onboard Ship: How Seafarers learned to use the shipboard Automatic Identification System (AIS)*. Cardiff: Lloyd's Register Educational Trust. ISBN 978-1-900174-34-3.
- BANYŚ, P., NOACK, T. und GEWIES, S., 2012. Assessment of AIS Vessel Position Report Under the Aspect of Data Reliability. *Annual of Navigation*, vol. 19, no. 1, pp. 5–16. ISSN 1640-8632. DOI 10.2478/v10367-012-0001-0.
- BAR-SHALOM, Y., LI, X.-R. und KIRUBARAJAN, T., 2001. *Estimation with Applications to Tracking and Navigation*. New York, USA: John Wiley & Sons, Inc. ISBN 978-0-471-41655-5.
- BATZ, T., WATSON, K. und BEYERER, J., 2009. Recognition of dangerous situations within a cooperative group of vehicles. *2009 IEEE Intelligent Vehicles Symposium*. Xi'an, China: IEEE, pp. 907–912. ISBN 978-1-4244-3503-6. DOI 10.1109/IVS.2009.5164400.
- BENTLEY, J.L., 1990. K-d Trees for Semidynamic Point Sets. *Proceedings of the Sixth Annual Symposium on Computational Geometry - SCG '90*. Berkley, California, United States: ACM Press, pp. 187–197. ISBN 978-0-89791-362-1. DOI 10.1145/98524.98564.
- BERKING, B. und BRAUNER, R., 2010. *Navigatorsche Schiffsführung*. Hamburg: Seehafen-Verl., DVV Media Group. Handbuch Nautik, Bd. 1. ISBN 978-3-87743-821-3.

- BLESSING, L.T.M. und CHAKRABARTI, A., 2009. *DRM, A Design Research Methodology*. Dordrecht Heidelberg: Springer. ISBN 978-1-84882-586-4.
- BRAND, M., OLIVER, N. und PENTLAND, A., 1997. Coupled hidden Markov models for complex action recognition. *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. San Juan, Puerto Rico: IEEE Comput. Soc, pp. 994–999. ISBN 978-0-8186-7822-6. DOI 10.1109/CVPR.1997.609450.
- BRANNSTROM, M., COELINGH, E. und SJOBERG, J., 2010. Model-Based Threat Assessment for Avoiding Arbitrary Vehicle Collisions. *IEEE Transactions on Intelligent Transportation Systems*, vol. 11, no. 3, pp. 658–669. ISSN 1524-9050. DOI 10.1109/TITS.2010.2048314.
- BRINKHOFF, T., 2013. *Geodatenbanksysteme in Theorie und Praxis: Einführung in objektrationale Geodatenbanken unter besonderer Berücksichtigung von Oracle Spatial*. 3., überarbeitete und erweiterte Auflage. Berlin: Wichmann. ISBN 978-3-87907-513-3.
- BRINKKEMPER, S., 1996. Method engineering: engineering of information systems development methods and tools. *Information and Software Technology*, vol. 38, no. 4, pp. 275–280. ISSN 09505849. DOI 10.1016/0950-5849(95)01059-9.
- BROADHURST, A., BAKER, S. und KANADE, T., 2005. Monte Carlo road safety reasoning. *IEEE Proceedings. Intelligent Vehicles Symposium, 2005*. Las Vegas, NV, USA: IEEE, pp. 319–324. ISBN 978-0-7803-8961-8. DOI 10.1109/IVS.2005.1505122.
- BURMAN, P., 1989. A comparative study of ordinary cross-validation, v -fold cross-validation and the repeated learning-testing methods. *Biometrika*, vol. 76, no. 3, pp. 503–514. ISSN 0006-3444, 1464-3510. DOI 10.1093/biomet/76.3.503.
- BUZAN, D., SCLAROFF, S. und KOLLIOS, G., 2004. Extraction and clustering of motion trajectories in video. *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004*. Cambridge, UK: IEEE, pp. 521-524 Vol.2. ISBN 978-0-7695-2128-2. DOI 10.1109/ICPR.2004.1334287.
- CAZZANTI, L. und PALLOTTA, G., 2015. Mining maritime vessel traffic: Promises, challenges, techniques. *OCEANS 2015 - Genova*. Genova, Italy: IEEE, pp. 1–6. ISBN 978-1-4799-8736-8. DOI 10.1109/OCEANS-Genova.2015.7271555.
- CHATTERJI, G., 1999. Short-term trajectory prediction methods. *Guidance, Navigation, and Control Conference and Exhibit*. Portland,OR,U.S.A.: American Institute of Aeronautics and Astronautics, DOI 10.2514/6.1999-4233.
- CHAUVIN, C., 2011. Human Factors and Maritime Safety. *Journal of Navigation*, vol. 64, no. 04, pp. 625–632. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463311000142.
- CHAUVIN, C., LARDJANE, S., MOREL, G., CLOSTERMANN, J.-P. und LANGARD, B., 2013. Human and organisational factors in maritime accidents: Analysis of collisions at sea using the HFACS. *Accident Analysis & Prevention*, vol. 59, pp. 26–37. ISSN 00014575. DOI 10.1016/j.aap.2013.05.006.
- DAHL, G.E., SAINATH, T.N. und HINTON, G.E., 2013. Improving deep neural networks for LVCSR using rectified linear units and dropout. *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. Vancouver, BC, Canada: IEEE, pp. 8609–8613. ISBN 978-1-4799-0356-6. DOI 10.1109/ICASSP.2013.6639346.

- DARANDA, A., 2016. A Neuronal Network Approach To Predict Marine Traffic. *Baltic Journal of Modern Computing*, vol. 4, no. 3, pp. 483–495.
- DAVIS, P.V., DOVE, M.J. und STOCKEL, C.T., 1980. A Computer Simulation of Marine Traffic Using Domains and Arenas. *Journal of Navigation*, vol. 33, no. 2, pp. 215–222. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463300035220.
- DAVIS, P.V., DOVE, M.J. und STOCKEL, C.T., 1982. A Computer Simulation of Multi-Ship Encounters. *Journal of Navigation*, vol. 35, no. 2, pp. 347–352. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463300022177.
- DEMPSTER, A.P., LAIRD, N.M. und RUBIN, D.B., 1977. Maximum Likelihood from Incomplete Data Via the EM Algorithm. *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 39, no. 1, pp. 1–22. ISSN 00359246. DOI 10.1111/j.2517-6161.1977.tb01600.x.
- DEUTSCHER WETTERDIENST, 2019. GRIB: General Regularly-distributed Information in Binary form. [Online]. [Zugriff am 27 Dezember 2019]. Verfügbar unter: https://www.dwd.de/DE/derdwd/it/_functions/Teasergroup/grib_de.html.
- DIN-NORMENAUSSCHUSS INFORMATION UND DOKUMENTATION (NID), 2018. *DIN EN ISO 3166-1:2014 „Codes für die Namen von Ländern und deren Untereinheiten - Teil 1: Codes für Ländernamen“*. 19 April 2018. S.l.: s.n.
- DOBRKOVIC, A., IACOB, M.-E. und VAN HILLEGERSBERG, J., 2018. Maritime pattern extraction and route reconstruction from incomplete AIS data. *International Journal of Data Science and Analytics*, vol. 5, no. 2–3, pp. 111–136. ISSN 2364-415X, 2364-4168. DOI 10.1007/s41060-017-0092-8.
- DOBRKOVIC, A., IACOB, M.-E., VAN HILLEGERSBERG, J., MES, M.R.K. und GLANDRUP, M., 2016. Towards an Approach for Long Term AIS-Based Prediction of Vessel Arrival Times. Unter: H. ZIJM, M. KLUMPP, U. CLAUSEN und M. ten HOMPEL (Hrsg.), *Logistics and Supply Chain Innovation*. Cham: Springer International Publishing, pp. 281–294. ISBN 978-3-319-22287-5.
- DOMINIK FILIPIAK, MILENA STROZYNA, KRZYSTOF WECEL, MATTHIAS STEIDEL, und WITOLD ABRAMOWICZ, 2021. Application of AI and In-memory Computing for Extracting Vessel Movement Patterns from Historical Data. *14th NATO Operations Research and Analysis (OR&A) Conference: Emerging and Disruptive Technology: Meeting Proceedings*. S.l.: s.n., pp. 1–12. ISBN 978-92-837-2336-3.
- DOUGLAS, D.H. und PEUCKER, T.K., 1973. Algorithms for the Reduction of the Number of Points Required to Represent a Digitized Line or its Caricature. *Cartographica: The International Journal for Geographic Information and Geovisualization*, vol. 10, no. 2, pp. 112–122. ISSN 0317-7173, 1911-9925. DOI 10.3138/FM57-6770-U75U-7727.
- ECMWF, 2023. ERA5: data documentation. [Online]. [Zugriff am 14 Juni 2023]. Verfügbar unter: <https://confluence.ecmwf.int/display/CKB/ERA5%3A+data+documentation>.
- EIDEHALL, A. und PETERSSON, L., 2008. Statistical Threat Assessment for General Road Scenes Using Monte Carlo Sampling. *IEEE Transactions on Intelligent Transportation Systems*, vol. 9, no. 1, pp. 137–147. ISSN 1524-9050, 1558-0016. DOI 10.1109/TITS.2007.909241.

- ENDSLEY, M.R., 1988. Situation awareness global assessment technique (SAGAT). *Proceedings of the IEEE 1988 National Aerospace and Electronics Conference*. Dayton, OH, USA: IEEE, pp. 789–795. DOI 10.1109/NAECON.1988.195097.
- ESTER, M., KRIEGEL, H.-P., SANDER, J., XU, X., und OTHERS, 1996. A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise. *Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining* [Online]. S.l.: s.n., pp. 226–231. [Zugriff am 7 April 2017]. Verfügbar unter: <http://www.aaai.org/Papers/KDD/1996/KDD96-037>.
- EUROPEAN COMMISSION, 2015. *Copernicus - Europe's eyes on Earth* [Online]. 2015. S.l.: s.n. [Zugriff am 14 September 2021]. Verfügbar unter: https://marine.copernicus.eu/sites/default/files/Copernicus_Brochure_EN_WEB.pdf.
- EUROPEAN UNION-COPERNICUS MARINE SERVICE, 2019. *Atlantic - European North West Shelf - Ocean Wave Analysis and Forecast* [Online]. 2019. S.l.: Mercator Ocean International. [Zugriff am 19 November 2023]. Verfügbar unter: https://resources.marine.copernicus.eu/product-detail/NORTHWESTSHELF_ANALYSIS_FORECAST_WAV_004_014/INFORMATION.
- EUROPEAN UNION-COPERNICUS MARINE SERVICE, 2022. *Global Ocean Hourly Sea Surface Wind and Stress from Scatterometer and Model* [Online]. 2022. S.l.: Mercator Ocean International. [Zugriff am 19 November 2023]. Verfügbar unter: https://resources.marine.copernicus.eu/product-detail/WIND_GLO_PHY_I4_NRT_012_004/INFORMATION.
- FAA/EUROCONTROL, 2010. ACTION PLAN 16: Trajectory Prediction-Related Terminology. [Online]. Brüssel, Belgien: [Zugriff am 18 März 2023]. Verfügbar unter: <https://sites.google.com/site/trajectorymgt/ap16---white-paper>.
- FAHRMEIR, L., HEUMANN, C., KÜNSTLER, R., PIGEOT, I. und TUTZ, G., 2016. *Statistik - Der Weg zur Datenanalyse*. Berlin, Heidelberg: Springer Berlin Heidelberg. Springer-Lehrbuch. ISBN 978-3-662-50371-3.
- FAYYAD, U.M., PIATETSKY-SHAPIRO, G. und SMYTH, P., 1996. From Data Mining to Knowledge Discovery: An Overview. Unter: U.M. FAYYAD, G. PIATETSKY-SHAPIRO, P. SMYTH und R. UTHURUSAMY (Hrsg.), *Advances in Knowledge Discovery and Data Mining*. Menlo Park, CA, USA: American Association for Artificial Intelligence, pp. 1–34.
- FELSKI, A. und JASKÓLSKI, K., 2012. Analysis of AIS availability. *European Journal of Navigation*, vol. 10, no. 1, pp. 39–43.
- FELSKI, A. und JASKÓLSKI, K., 2013. The Integrity of Information Received by Means of AIS During Anti-collision Manoeuvring. *TransNav, the International Journal on Marine Navigation and Safety of Sea Transportation*, vol. 7, no. 2, pp. 95–100. ISSN 2083-6473. DOI 10.12716/1001.07.01.12.
- FERNANDEZ ARGUEDAS, V., PALLOTTA, G. und VESPE, M., 2018. Maritime Traffic Networks: From Historical Positioning Data to Unsupervised Maritime Traffic Monitoring. *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 3, pp. 722–732. ISSN 1524-9050, 1558-0016. DOI 10.1109/ITTS.2017.2699635.

- FERNANDEZ, E.C., CORDERO, J.M., VOUIROS, G., KRAVARIS, T., GEORGIU, H., FUCHS, G., ANDRIENKO, N., ANDRIENKO, G., CASADO, E., SCARLATTI, D., COSTAS, P. und AYHAN, S., 2017. A machine-learning approach to trajectory prediction and demand-capacity balancing. *Proceedings of the SESAR Innovation Day SID*. Belgrad, Serbien: s.n., pp. 8.
- FEURER, M. und HUTTER, F., 2019. Hyperparameter Optimization. Unter: F. HUTTER, L. KOTTHOFF und J. VANSCHOREN (Hrsg.), *Automated Machine Learning*. Cham: Springer International Publishing, The Springer Series on Challenges in Machine Learning, pp. 3–33. ISBN 978-3-030-05317-8.
- FONSECA-DELGADO, R. und GOMEZ-GIL, P., 2013. An assessment of ten-fold and Monte Carlo cross validations for time series forecasting. *2013 10th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*. Mexico City, Mexico: IEEE, pp. 215–220. ISBN 978-1-4799-1461-6. DOI 10.1109/ICEEE.2013.6676075.
- FOSSON, T.I., 2011. *Handbook of Marine Craft Hydrodynamics and Motion Control: Fossen/Handbook of Marine Craft Hydrodynamics and Motion Control*. Chichester, UK: John Wiley & Sons, Ltd. ISBN 978-1-119-99413-8.
- FUJII, Y. und TANAKA, K., 1971. Traffic Capacity. *Journal of Navigation*, vol. 24, no. 4, pp. 543–552. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463300022384.
- FUKUDA, Y., SHIRAKAWA, M. und SENOGUCHI, A., 2010. A. Development and Evaluation of Trajectory Prediction Model. *Proceedings of the 27th International Congress of the Aeronautical Sciences*. Nizza, Frankreich: s.n.,
- GENERALDIREKTION WASSERSTRASSEN UND SCHIFFFAHRT (GWDS), 2023. *Verkehrsbericht 2022*. 10 Juni 2023. S.l.: WSV.
- GOODWIN, E.M., 1975. A Statistical Study of Ship Domains. *Journal of Navigation*, vol. 28, no. 3, pp. 328–344. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463300041230.
- GRAMACKI, A., 2018. *Nonparametric Kernel Density Estimation and Its Computational Aspects*. Cham: Springer International Publishing. Studies in Big Data. ISBN 978-3-319-71687-9.
- GRAVES, A., 2012a. Long Short-Term Memory. Unter: A. GRAVES, *Supervised Sequence Labelling with Recurrent Neural Networks*. Berlin, Heidelberg: Springer Berlin Heidelberg, Studies in Computational Intelligence, pp. 37–45. ISBN 978-3-642-24796-5.
- GRAVES, A., 2012b. Neural Networks. Unter: A. GRAVES, *Supervised Sequence Labelling with Recurrent Neural Networks*. Berlin, Heidelberg: Springer Berlin Heidelberg, Studies in Computational Intelligence, pp. 15–35. ISBN 978-3-642-24796-5.
- GREENE, D., LIU, J., REICH, J., HIROKAWA, Y., SHINAGAWA, A., ITO, H. und MIKAMI, T., 2011. An Efficient Computational Architecture for a Collision Early-Warning System for Vehicles, Pedestrians, and Bicyclists. *IEEE Transactions on Intelligent Transportation Systems*, vol. 12, no. 4, pp. 942–953. ISSN 1524-9050, 1558-0016. DOI 10.1109/ITITS.2010.2097594.
- HARATI-MOKHTARI, A., WALL, A., BROOKS, P. und WANG, J., 2007. Automatic Identification System (AIS): Data Reliability and Human Error Implications. *Journal of Navigation*, vol. 60, no. 03, pp. 373. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463307004298.

- HAWKINS, D.M. und OLWELL, D.H., 1998. *Cumulative Sum Charts and Charting for Quality Improvement*. New York, NY: Springer New York. ISBN 978-1-4612-7245-8.
- HEBB, D.O., 2002. *The organization of behavior: a neuropsychological theory*. Mahwah, N.J.: L. Erlbaum Associates. ISBN 978-0-8058-4300-2. BF181 .H4 2002
- HERMES, C., EINHAUS, J., HAHN, M., WOHLER, C. und KUMMERT, F., 2010. Vehicle tracking and motion prediction in complex urban scenarios. *2010 IEEE Intelligent Vehicles Symposium*. San Diego, CA: IEEE, pp. 26–33. ISBN 978-1-4244-7868-2. DOI 10.1109/IVS.2010.5548014.
- HERMES, C., WOHLER, C., SCHENK, K. und KUMMERT, F., 2009. Long-term vehicle motion prediction. *2009 IEEE Intelligent Vehicles Symposium*. Xi'an, China: IEEE, pp. 652–657. ISBN 978-1-4244-3503-6. DOI 10.1109/IVS.2009.5164354.
- HERSBACH, H., BELL, B., BERRISFORD, P., HIRAHARA, S., HORÁNYI, A., MUÑOZ-SABATER, J., NICOLAS, J., PEUBEY, C., RADU, R., SCHEPERS, D., SIMMONS, A., SOCI, C., ABDALLA, S., ABELLAN, X., BALSAMO, G., BECHTOLD, P., BIAVATI, G., BIDLOT, J., BONAVITA, M., CHIARA, G., DAHLGREN, P., DEE, D., DIAMANTAKIS, M., DRAGANI, R., FLEMMING, J., FORBES, R., FUENTES, M., GEER, A., HAIMBERGER, L., HEALY, S., HOGAN, R.J., HÓLM, E., JANISKOVÁ, M., KEELLY, S., LALOYAUX, P., LOPEZ, P., LUPU, C., RADNOTI, G., ROSNAY, P., ROZUM, I., VAMBORG, F., VILLAUME, S. und THÉPAUT, J., 2020. The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, vol. 146, no. 730, pp. 1999–2049. ISSN 0035-9009, 1477-870X. DOI 10.1002/qj.3803.
- HETHERINGTON, C., FLIN, R. und MEARN, K., 2006. Safety in shipping: The human element. *Journal of Safety Research*, vol. 37, no. 4, pp. 401–411. ISSN 00224375.
- HEXEBERG, S., FLATEN, A.L., ERIKSEN, B.-O.H. und BREKKE, E.F., 2017. AIS-based vessel trajectory prediction. *2017 20th International Conference on Information Fusion (Fusion)*. Xi'an, China: IEEE, pp. 1–8. ISBN 978-0-9964527-0-0. DOI 10.23919/ICIF.2017.8009762.
- HOCHREITER, J., 1991. *Untersuchungen zu dynamischen neuronalen Netzen*. Diplomarbeit im Fach Informatik an der Technischen Universität München: s.n.
- HOCHREITER, S. und SCHMIDHUBER, J., 1997. Long Short-Term Memory. *Neural Computation*, vol. 9, no. 8, pp. 1735–1780. ISSN 0899-7667, 1530-888X. DOI 10.1162/neco.1997.9.8.1735.
- HUTTENLOCHER, D.P., KLANDERMAN, G.A. und RUCKLIDGE, W.J., 1993. Comparing images using the Hausdorff distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 15, no. 9, pp. 850–863. ISSN 01628828. DOI 10.1109/34.232073.
- INTERNATIONAL ASSOCIATION OF LIGHTHOUSE AUTHORITIES, 2017. *G1123 - The use of IALA Waterway Risk Assessment Programme (IWRAP MKII)* [Online]. Juni 2017. S.l.: s.n. [Zugriff am 17 August 2021]. Verfügbar unter: <https://www.iala-aism.org/product/g1123-use-iala-waterway-risk-assessment-programme-iwrap-mkii/>.
- INTERNATIONAL ASSOCIATION OF LIGHTHOUSE AUTHORITIES, 2018. *R1001 The IALA Maritime Buoyage System*. 1 November 2018. S.l.: s.n.

- INTERNATIONAL CHAMBER OF SHIPPING, 2018. Shipping and World Trade. *Shipping and World Trade* [Online]. [Zugriff am 6 März 2019]. Verfügbar unter: <http://www.ics-shipping.org/shipping-facts/shipping-and-world-trade>.
- INTERNATIONAL ELECTROTECHNICAL COMMISSION, 1998. *IEC 61162-2:1998 Maritime navigation and radiocommunication equipment and systems - Digital interfaces - Part 2: Single talker and multiple listeners, high-speed transmission*. 11 September 1998. S.l.: s.n.
- INTERNATIONAL HYDROGRAPHIC ORGANISATION, 2000. *S-57 Appendix A - IHO Object Catalogue* [Online]. November 2000. S.l.: s.n. [Zugriff am 5 November 2023]. Verfügbar unter: <https://iho.int/uploads/user/pubs/standards/s-57/31ApAch1.pdf>.
- INTERNATIONAL HYDROGRAPHIC ORGANISATION, 2018. *S-57 Appendix B.1 - Use of the Object Catalogue for ENC* [Online]. Januar 2018. S.l.: s.n. [Zugriff am 5 November 2023]. Verfügbar unter: https://iho.int/iho_pubs/standard/S-57Ed3.1/S-57%20Appendix%20B.1%20Annex%20A%20UOC%20Edition%204.1.0_Jan18_EN.pdf.
- INTERNATIONAL MARITIME ORGANIZATION, 1972. *COLREGS - International Regulations for Preventing Collisions at Sea* [Online]. 1972. S.l.: s.n. [Zugriff am 14 Dezember 2023]. Verfügbar unter: <https://www.imo.org/en/About/Conventions/Pages/COLREG.aspx>.
- INTERNATIONAL MARITIME ORGANIZATION, 1974. *International Convention for the Safety of Life At Sea, 1974*. 11 Januar 1974. S.l.: s.n.
- INTERNATIONAL MARITIME ORGANIZATION, 1999. Resolution A.893 (21) Guidelines for Voyage Planning. [Online]. S.l.: International Maritime Organization. [Zugriff am 13 Januar 2023]. Verfügbar unter: [https://wwwcdn.imo.org/localresources/en/Knowledge-Centre/IndexofIMOResolutions/AssemblyDocuments/A.893\(21\).pdf](https://wwwcdn.imo.org/localresources/en/Knowledge-Centre/IndexofIMOResolutions/AssemblyDocuments/A.893(21).pdf).
- INTERNATIONAL MARITIME ORGANIZATION, 2007. *Revised Guidance to the Master for Avoiding Dangerous Situations in Adverse Weather and Sea Conditions* [Online]. 2007. S.l.: s.n. [Zugriff am 14 Dezember 2023]. Verfügbar unter: <https://wwwcdn.imo.org/localresources/en/OurWork/Safety/Documents/Stability/MSC.1-CIRC.1228.pdf>.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, 2003. *ISO 19107:2003 Geographic information -- Spatial schema*. Mai 2003. S.l.: s.n.
- INTERNATIONAL TELECOMMUNICATION UNION, 2014. Technical characteristics for an automatic identification system using time division multiple access in the VHF maritime mobile frequency band. . S.l.: Recommendation ITU-R M.1371-5.
- JAN-HENDRIK OLTMAN, 2015. ACCSEAS North Sea Region Route Topology Model (NSR-RTM). [Online]. ACCSEAS Project Report. S.l.: Federal Waterways and Shipping Administration. [Zugriff am 13 Januar 2023]. 1. Verfügbar unter: https://www.iala-aism.org/content/uploads/2016/08/accseas_route_topology_model_report.pdf.
- KÄFER, E., HERMES, C., WÖHLER, C., RITTER, H. und KUMMERT, F., 2010. Recognition of situation classes at road intersections. *2010 IEEE International Conference on Robotics and Automation*. Anchorage, AK: IEEE, pp. 3960–3965. ISBN 978-1-4244-5038-1. DOI 10.1109/ROBOT.2010.5509919.

- KATOCH, S., CHAUHAN, S.S. und KUMAR, V., 2021. A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*, vol. 80, no. 5, pp. 8091–8126. ISSN 1380-7501, 1573-7721. DOI 10.1007/s11042-020-10139-6.
- KOHAVI, R. und JOHN, G.H., 1995. Automatic Parameter Selection by Minimizing Estimated Error. *Machine Learning Proceedings 1995*. S.l.: Elsevier, pp. 304–312. ISBN 978-1-55860-377-6.
- KONGSBERG, 2017. YARA and KONGSBERG enter into partnership to build world's first autonomous and zero emissions ship - Kongsberg Maritime. [Online]. [Zugriff am 10 November 2018]. Verfügbar unter: <https://www.kongsberg.com/ks/web/nokbg0238.nsf/All-Web/98A8C576AEFC85AFC125811A0037F6C4?OpenDocument>.
- KUHN, M. und JOHNSON, K., 2013. *Applied Predictive Modeling*. New York, NY: Springer New York. ISBN 978-1-4614-6848-6.
- KUMAR, P., PERROLLAZ, M., LEFÈVRE, S. und LAUGIER, C., 2013. Learning-based approach for online lane change intention prediction. *2013 IEEE Intelligent Vehicles Symposium (IV)*. Gold Coast City, Australia: IEEE, pp. 797–802. ISBN 978-1-4673-2755-8. DOI 10.1109/IVS.2013.6629564.
- LAMM, A. und HAHN, A., 2019. Statistical Maneuver Net Generation for Anomaly Detection in Navigational Waterways. *2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)*. Paris, France: IEEE, pp. 1438–1443. ISBN 978-1-72810-521-5. DOI 10.1109/CoDIT.2019.8820641.
- LAUGIER, C., PAROMTCHIK, I.E., PERROLLAZ, M., YONG, M.Y., YODER, J., TAY, C., MEKHNACHA, K. und NEGRE, A., 2011. Probabilistic Analysis of Dynamic Scenes and Collision Risks Assessment to Improve Driving Safety. *IEEE Intelligent Transportation Systems Magazine*, vol. 3, no. 4, pp. 4–19. ISSN 1939-1390. DOI 10.1109/MITS.2011.942779.
- LAWITZKY, A., ALTHOFF, D., PASSENBERG, C.F., TANZMEISTER, G., WOLLHERR, D. und BUSS, M., 2013. Interactive scene prediction for automotive applications. *2013 IEEE Intelligent Vehicles Symposium (IV)*. Gold Coast City, Australia: IEEE, pp. 1028–1033. ISBN 978-1-4673-2755-8. DOI 10.1109/IVS.2013.6629601.
- LAXHAMMAR, R., FALKMAN, G. und SVIESTINS, E., 2009. Anomaly detection in sea traffic—a comparison of the gaussian mixture model and the kernel density estimator. *Information Fusion, 2009. FUSION'09. 12th International Conference on*. S.l.: IEEE, pp. 756–763.
- LEFÈVRE, S., LAUGIER, C. und IBAÑEZ-GUZMÁN, J., 2013. Intention-Aware Risk Estimation for General Traffic Situations, and Application to Intersection Safety. . Forschungsbericht. S.l.: Inria Research Report, 8379.
- LEFÈVRE, S., VASQUEZ, D. und LAUGIER, C., 2014. A survey on motion prediction and risk assessment for intelligent vehicles. *ROBOMECH Journal*, vol. 1, no. 1, pp. 1. ISSN 2197-4225. DOI 10.1186/s40648-014-0001-z.
- LIN, Y., ZHANG, J. und LIU, H., 2018. An algorithm for trajectory prediction of flight plan based on relative motion between positions. *Frontiers of Information Technology & Electronic Engineering*, vol. 19, no. 7, pp. 905–916. ISSN 2095-9184, 2095-9230. DOI 10.1631/FITEE.1700224.

- LOPEZ LEONES, J., 2008. *Definition of an aircraft intent description language for air traffic management applications*. Glasgow, Schottland: University of Glasgow.
- LYMPEPOPOULOS, I. und LYGEROS, J., 2010. Sequential Monte Carlo methods for multi-aircraft trajectory prediction in air traffic management. *International Journal of Adaptive Control and Signal Processing*, vol. 24, no. 10, pp. 830–849. ISSN 08906327. DOI 10.1002/acs.1174.
- MARCHTHALER, R. und DINGLER, S., 2017. *Kalman-Filter*. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN 978-3-658-16727-1.
- MARINETRAFFIC, 2020. MarineTraffic: Global Ship Tracking Intelligence. [Online]. [Zugriff am 6 März 2019]. Verfügbar unter: <https://www.marinetraffic.com/en/ais/home/centerx:83.0/centery:22.6/zoom:2>.
- MARITIME & COASTGUARD AGENCY, 2018. Dover Strait crossings: channel navigation information service (CNIS). *GOV.UK* [Online]. [Zugriff am 7 März 2019]. Verfügbar unter: <https://www.gov.uk/government/publications/dover-strait-crossings-channel-navigation-information-service/dover-strait-crossings-channel-navigation-information-service-cnis>.
- MARTIN, E., KASKI, S., ZHENG, F., WEBB, G.I., ZHU, X., MUSLEA, I., TING, K.M., VLACHOS, M., MIIKKULAINEN, R., FERN, A., OSBORNE, M., RAEDT, L.D., KERSTING, K., ZEUGMANN, T., ZHANG, X., BAIN, M., CZUMAJ, A., SOHLER, C., SAMMUT, C., NOVAK, P.K., LAVRAČ, N., WEBB, G.I., ZHANG, X., SANNER, S. und KERSTING, K., 2011. Stratified Cross Validation. Unter: C. SAMMUT und G.I. WEBB (Hrsg.), *Encyclopedia of Machine Learning*. Boston, MA: Springer US, pp. 928–928. ISBN 978-0-387-30768-8.
- MAZZARELLA, F., ARGUEDAS, V.F. und VESPE, M., 2015. Knowledge-based vessel position prediction using historical AIS data. *2015 Sensor Data Fusion: Trends, Solutions, Applications (SDF)*. Bonn, Germany: IEEE, pp. 1–6. ISBN 978-1-4673-7175-9. DOI 10.1109/SDF.2015.7347707.
- MILLER, R. und QINGFENG HUANG, 2002. An adaptive peer-to-peer collision warning system. *Vehicular Technology Conference. IEEE 55th Vehicular Technology Conference. VTC Spring 2002 (Cat. No.02CH37367)*. Birmingham, AL, USA: IEEE, pp. 317–321. ISBN 978-0-7803-7484-3. DOI 10.1109/VTC.2002.1002718.
- NAIR, V. und HINTON, G.E., 2010. Rectified Linear Units Improve Restricted Boltzmann Machines. *Proceedings of International Conference on Machine Learning (ICML)*. Haifa, Israel: s.n., pp. 807–814.
- Navionics ChartViewer. [Online], 2020. [Zugriff am 29 Juli 2020]. Verfügbar unter: <https://webapp.navionics.com/#boating@10&key=gcsGlarhu%40>.
- NWANKPA, C., IJOMAH, W., GACHAGAN, A. und MARSHALL, S., 2018. *Activation Functions: Comparison of trends in Practice and Research for Deep Learning*. 8 November 2018. S.l.: arXiv. arXiv:1811.03378.
- OLIVER, N. und PENTLAND, A.P., 2000. Graphical models for driver behavior recognition in a SmartCar. *Proceedings of the IEEE Intelligent Vehicles Symposium 2000 (Cat. No.00TH8511)*. Dearborn, MI, USA: IEEE, pp. 7–12. ISBN 978-0-7803-6363-2. DOI 10.1109/IVS.2000.898310.

- OOCL, 2017. OOCL - OOCL reaches milestone with the christening of the OOCL Hong Kong. [Online]. [Zugriff am 26 November 2018]. Verfügbar unter: <https://www.oocl.com/eng/pressandmedia/pressreleases/2017/Pages/12may17.aspx>.
- PALLOTTA, G., HORN, S., BRACA, P. und BRYAN, K., 2014. Context-enhanced vessel prediction based on Ornstein-Uhlenbeck processes using historical AIS traffic patterns: Real-world experimental results. *Information Fusion (FUSION), 2014 17th International Conference on*. S.l.: IEEE, pp. 1–7.
- PALLOTTA, G., VESPE, M. und BRYAN, K., 2013. Vessel Pattern Knowledge Discovery from AIS Data: A Framework for Anomaly Detection and Route Prediction. *Entropy*, vol. 15, no. 6, pp. 2218–2245. ISSN 1099-4300. DOI 10.3390/e15062218.
- PANG, Y. und LIU, Y., 2020a. Conditional Generative Adversarial Networks (CGAN) for Aircraft Trajectory Prediction considering weather effects. *ALAA Scitech 2020 Forum*. Orlando, FL: American Institute of Aeronautics and Astronautics, ISBN 978-1-62410-595-1. DOI 10.2514/6.2020-1853.
- PANG, Y. und LIU, Y., 2020b. Probabilistic Aircraft Trajectory Prediction Considering Weather Uncertainties Using Dropout As Bayesian Approximate Variational Inference. *ALAA Scitech 2020 Forum*. Orlando, FL: American Institute of Aeronautics and Astronautics, ISBN 978-1-62410-595-1. DOI 10.2514/6.2020-1413.
- PARIS, C., 2017. Norway Takes Lead in Race to Build Autonomous Cargo Ships. *Wall Street Journal* [Online]. 22 Juli 2017. [Zugriff am 3 Juli 2019]. ISSN 0099-9660. Verfügbar unter: <https://www.wsj.com/articles/norway-takes-lead-in-race-to-build-autonomous-cargo-ships-1500721202>.
- PEFFERS, K., TUUNANEN, T., ROTHENBERGER, M.A. und CHATTERJEE, S., 2007. A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, vol. 24, no. 3, pp. 45–77. ISSN 0742-1222, 1557-928X. DOI 10.2753/MIS0742-1222240302.
- PERERA, L.P. und SOARES, C.G., 2010. Ocean vessel trajectory estimation and prediction based on Extended Kalman filter. *The Second International Conference on Adaptive and Self-Adaptive Systems and Applications*. S.l.: Citeseer, pp. 14–20.
- PICARD, R.R. und COOK, R.D., 1984. Cross-Validation of Regression Models. *Journal of the American Statistical Association*, vol. 79, no. 387, pp. 575–583. ISSN 0162-1459, 1537-274X. DOI 10.1080/01621459.1984.10478083.
- PIETRZYKOWSKI, Z., 2001. The Analysis of a Ship Fuzzy Domain in a Restricted Area. *IFAC Proceedings Volumes*, vol. 34, no. 7, pp. 45–50. ISSN 14746670. DOI 10.1016/S1474-6670(17)35057-7.
- PORRETTA, M., DUPUY, M.-D., SCHUSTER, W., MAJUMDAR, A. und OCHIENG, W., 2008. Performance Evaluation of a Novel 4D Trajectory Prediction Model for Civil Aircraft. *Journal of Navigation*, vol. 61, no. 3, pp. 393–420. ISSN 0373-4633, 1469-7785. DOI 10.1017/S0373463308004761.
- REYNOLDS, D., 2015. Gaussian Mixture Models. Unter: S.Z. LI und A.K. JAIN (Hrsg.), *Encyclopedia of Biometrics*. Boston, MA: Springer US, pp. 827–832. ISBN 978-1-4899-7487-7.

- RISTIC, B., 2014. Detecting Anomalies from a Multitarget Tracking Output. *IEEE Transactions on Aerospace and Electronic Systems*, vol. 50, no. 1, pp. 798–803. ISSN 0018-9251. DOI 10.1109/TAES.2013.130377.
- RISTIC, B., LA SCALA, B., MORELANDE, M. und GORDON, N., 2008. Statistical analysis of motion patterns in AIS data: Anomaly detection and motion prediction. *information fusion, 2008 11th international conference on*. S.l.: IEEE, pp. 1–7.
- RIVEIRO, M., PALLOTTA, G. und VESPE, M., 2018. Maritime anomaly detection: A review. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 8, no. 5, pp. e1266. ISSN 19424787. DOI 10.1002/widm.1266.
- RUNKLER, T.A., 2010. *Data Mining: Methoden und Algorithmen intelligenter Datenanalyse ; mit 7 Tabellen*. 1. Aufl. Wiesbaden: Vieweg + Teubner. Computational intelligence. ISBN 978-3-8348-0858-5.
- RUSSELL, S.J., NORVIG, P. und DAVIS, E., 2010. *Artificial intelligence: a modern approach*. 3rd ed. Upper Saddle River: Prentice Hall. Prentice Hall series in artificial intelligence. ISBN 978-0-13-604259-4. Q335 .R86 2010
- RÜSSMEIER, N., LAMM, A. und HAHN, A., 2019. A generic testbed for simulation and physical-based testing of maritime cyber-physical system of systems. *J. Phys.: Conf. Ser.*, vol. 1357, pp. 012025. ISSN 1742-6588, 1742-6596. DOI 10.1088/1742-6596/1357/1/012025.
- SAMMUT, C. und WEBB, G.I., 2010. *Encyclopedia of Machine Learning* [Online]. Boston, MA: Springer US. [Zugriff am 12 Januar 2023]. ISBN 978-0-387-30768-8. Verfügbar unter: <http://link.springer.com/10.1007/978-0-387-30164-8>.
- SCHUSTER, W., 2015. Trajectory prediction for future air traffic management – complex manoeuvres and taxiing. *The Aeronautical Journal*, vol. 119, no. 1212, pp. 121–143. ISSN 0001-9240, 2059-6464. DOI 10.1017/S0001924000010307.
- SCHUSTER, W., OCHIENG, W. und PORRETTA, M., 2010. High-performance trajectory prediction for civil aircraft. *29th Digital Avionics Systems Conference*. Salt Lake City, UT, USA: IEEE, pp. 1.C.3-1-1.C.3-9. ISBN 978-1-4244-6616-0. DOI 10.1109/DASC.2010.5655515.
- SCHUSTER, W., PORRETTA, M. und OCHIENG, W., 2012. High-accuracy four-dimensional trajectory prediction for civil aircraft. *The Aeronautical Journal*, vol. 116, no. 1175, pp. 45–66. ISSN 0001-9240, 2059-6464. DOI 10.1017/S0001924000006618.
- SEAH, C.E. und HWANG, I., 2007. A Hybrid Estimation Algorithm for Terminal-Area Aircraft Tracking. *AIAA Guidance, Navigation and Control Conference and Exhibit*. Hilton Head, South Carolina: American Institute of Aeronautics and Astronautics, ISBN 978-1-62410-015-4. DOI 10.2514/6.2007-6691.
- SHALEV-SHWARTZ, S. und BEN-DAVID, S., 2014. *Understanding machine learning: from theory to algorithms*. New York, NY, USA: Cambridge University Press. ISBN 978-1-107-05713-5. Q325.5 .S475 2014
- SHI, Z., XU, M., PAN, Q., YAN, B. und ZHANG, H., 2018. LSTM-based Flight Trajectory Prediction. *2018 International Joint Conference on Neural Networks (IJCNN)*. Rio de Janeiro: IEEE, pp. 1–8. ISBN 978-1-5090-6014-6. DOI 10.1109/IJCNN.2018.8489734.

- SHULTZ, T.R., FAHLMAN, S.E., CRAW, S., ANDRITSOS, P., TSAPARAS, P., SILVA, R., DRUMMOND, C., LING, C.X., SHENG, V.S., DRUMMOND, C., LANZI, P.L., GAMA, J., WIEGAND, R.P., SEN, P., NAMATA, G., BILGIC, M., GETOOR, L., HE, J., JAIN, S., STEPHAN, F., JAIN, S., STEPHAN, F., SAMMUT, C., HARRIES, M., SAMMUT, C., TING, K.M., PFAHRINGER, B., CASE, J., JAIN, S., WAGSTAFF, K.L., NIJSSEN, S., WIRTH, A., LING, C.X., SHENG, V.S., ZHANG, X., SAMMUT, C., CANCEDDA, N., RENDERS, J.-M., MICHELUCCI, P., OBLINGER, D., KEOGH, E. und MUEEN, A., 2011. Cross-Validation. Unter: C. SAMMUT und G.I. WEBB (Hrsg.), *Encyclopedia of Machine Learning* [Online]. Boston, MA: Springer US, pp. 249–249. [Zugriff am 6 Januar 2023]. ISBN 978-0-387-30768-8. Verfügbar unter: http://link.springer.com/10.1007/978-0-387-30164-8_190.
- SKRODZKI, M., 2019. The k-d tree data structure and a proof for neighborhood computation in expected logarithmic time. , DOI 10.48550/ARXIV.1903.04936.
- SMIERZCHALSKI, R. und MICHALEWICZ, Z., 2000. Modeling of ship trajectory in collision situations by an evolutionary algorithm. *IEEE Transactions on Evolutionary Computation*, vol. 4, no. 3, pp. 227–241. ISSN 1089778X. DOI 10.1109/4235.873234.
- SONG, Y., CHENG, P. und MU, C., 2012. An improved trajectory prediction algorithm based on trajectory data mining for air traffic management. *2012 IEEE International Conference on Information and Automation*. Shenyang, China: IEEE, pp. 981–986. ISBN 978-1-4673-2237-9. DOI 10.1109/ICInfA.2012.6246959.
- STEIDEL, M. und HAHN, A., 2019. MTCAS – An Assistance System for Collision Avoidance at Sea. *18 th International Conference on Computer and IT Applications in the Maritime Industries*. Tullamore: s.n., pp. 261–273. ISBN 978-3-89220-709-2.
- STEIDEL, M., LAMM, A., FEUERSTACK, S. und HAHN, A., 2019. Correcting the Destination Information in Automatic Identification System Messages. Unter: W. ABRAMOWICZ und R. CORCHUELO (Hrsg.), *Business Information Systems Workshops* [Online]. Cham: Springer International Publishing, pp. 496–507. [Zugriff am 19 Dezember 2019]. ISBN 978-3-030-36690-2. Verfügbar unter: http://link.springer.com/10.1007/978-3-030-36691-9_42.
- STEIDEL, M., MENTJES, J. und HAHN, A., 2020. Context-Sensitive Prediction of Vessel Behavior. *Journal of Marine Science and Engineering*, vol. 8, no. 12, pp. 987. ISSN 2077-1312. DOI 10.3390/jmse8120987.
- STROOCK, D.W., 2014. *An Introduction to Markov Processes*. Berlin, Heidelberg: Springer Berlin Heidelberg. Graduate Texts in Mathematics. ISBN 978-3-642-40522-8.
- TAN, H.-S. und HUANG, J., 2006. DGPS-Based Vehicle-to-Vehicle Cooperative Collision Warning: Engineering Feasibility Viewpoints. *IEEE Transactions on Intelligent Transportation Systems*, vol. 7, no. 4, pp. 415–428. ISSN 1524-9050. DOI 10.1109/ITITS.2006.883938.
- TAN, Y.V., FLANNAGAN, C.A.C. und ELLIOTT, M.R., 2018. Predicting human-driving behavior to help driverless vehicles drive: random intercept Bayesian additive regression trees. *Statistics and Its Interface*, vol. 11, no. 4, pp. 557–572. ISSN 19387989, 19387997. DOI 10.4310/SII.2018.v11.n4.a1.
- TANG, H., YIN, Y. und SHEN, H., 2019. A model for vessel trajectory prediction based on long short-term memory neural network. *Journal of Marine Engineering & Technology*, pp. 1–10. ISSN 2046-4177, 2056-8487. DOI 10.1080/20464177.2019.1665258.

- TANG, X., CHEN, P. und ZHANG, Y., 2015. 4D trajectory estimation based on nominal flight profile extraction and airway meteorological forecast revision. *Aerospace Science and Technology*, vol. 45, pp. 387–397. ISSN 12709638. DOI 10.1016/j.ast.2015.06.001.
- TINGTING XU, XIAOMING LIU und XIN YANG, 2012. A Novel Approach for Ship Trajectory Online Prediction Using BP Neural Network Algorithm. *INTERNATIONAL JOURNAL ON Advances in Information Sciences and Service Sciences*, vol. 4, no. 11, pp. 271–277. ISSN 1976-3700, 2233-9345. DOI 10.4156/aiss.vol4.issue11.33.
- UNITED NATIONS, 2018. *Review of Maritime Transport 2018*. New York: United Nations. United Nations Conference on Trade and Development. ISBN 978-92-1-112928-1.
- VERDONK GALLEGO, C.E., GÓMEZ COMENDADOR, V.F., SÁEZ NIETO, F.J., ORENGA IMAZ, G. und ARNALDO VALDÉS, R.M., 2018. Analysis of air traffic control operational impact on aircraft vertical profiles supported by machine learning. *Transportation Research Part C: Emerging Technologies*, vol. 95, pp. 883–903. ISSN 0968090X. DOI 10.1016/j.trc.2018.03.017.
- VOGEL, J., 2015. *Prognose von Zeitreihen - Eine Einführung für Wirtschaftswissenschaftler*. 1. Wiesbaden: Springer Gabler Wiesbaden. ISBN 978-3-658-06836-3.
- WANG, Z., LIANG, M. und DELHAYE, D., 2017. Short-Term 4d Trajectory Prediction Using Machine Learning Methods. *Proceedings of the SESAR Innovation Day SID*. Belgrad, Serbien: s.n., pp. 9.
- WEBB, G.I., SAMMUT, C., PERLICH, C., HORVÁTH, T., WROBEL, S., KORB, K.B., NOBLE, W.S., LESLIE, C., LAGOUDAKIS, M.G., QUADRIANTO, N., BUNTINE, W.L., QUADRIANTO, N., BUNTINE, W.L., GETOOR, L., NAMATA, G., GETOOR, L., HAN, X.J., Jiawei, TING, J.-A., VIJAYAKUMAR, S., SCHAAL, S. und RAEDT, L.D., 2011. Leave-One-Out Cross-Validation. Unter: C. SAMMUT und G.I. WEBB (Hrsg.), *Encyclopedia of Machine Learning* [Online]. Boston, MA: Springer US, pp. 600–601. [Zugriff am 6 Januar 2023]. ISBN 978-0-387-30768-8. Verfügbar unter: http://link.springer.com/10.1007/978-0-387-30164-8_469.
- WEIMING HU, XUEJUAN XIAO, ZHOUYU FU, XIE, D., TIENIU TAN und MAYBANK, S., 2006. A system for learning statistical motion patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 28, no. 9, pp. 1450–1464. ISSN 0162-8828, 2160-9292. DOI 10.1109/TPAMI.2006.176.
- WEITZ, L.A., 2015. Derivation of a Point-Mass Aircraft Model used for Fast-Time Simulation. . Technical Report. Bedford, MA, USA: MITRE Corporation.
- WIERSMA, J.W.F., 2010. *Assessing Vessel Traffic Service Operator Situation Awareness*. Oisterwijk: BOXPress.
- WIJAYA, W.M. und NAKAMURA, Y., 2013. Predicting Ship Behavior Navigating through Heavily Trafficked Fairways by Analyzing AIS Data on Apache HBase. . S.l.: IEEE, pp. 220–226. ISBN 978-1-4799-2796-8. DOI 10.1109/CANDAR.2013.39.
- WIRTH, R. und HIPPEL, J., 2023. CRISP-DM: Towards a Standard Process Model for Data Mining. *Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining*. Manchester: s.n., pp. 29–40.

- WORLD METEOROLOGICAL ORGANIZATION, 2003. *Introduction to GRIB Edition1 and GRIB Edition 2*. Juni 2003. S.l.: s.n.
- WRÓBEL, K., MONTEWKA, J. und KUJALA, P., 2017. Towards the assessment of potential impact of unmanned vessels on maritime transportation safety. *Reliability Engineering & System Safety*, vol. 165, pp. 155–169. ISSN 09518320. DOI 10.1016/j.res.2017.03.029.
- WU, J., CUI, Z., ZHAO, P. und CHEN, J., 2012. Traffic Vehicle Behavior Prediction Using Hidden Markov Models. Unter: J. LEI, F.L. WANG, H. DENG und D. MIAO (Hrsg.), *Artificial Intelligence and Computational Intelligence*. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 383–390. ISBN 978-3-642-33477-1.
- XIAO, Z., PONNAMBALAM, L., FU, X. und ZHANG, W., 2017. Maritime Traffic Probabilistic Forecasting Based on Vessels' Waterway Patterns and Motion Behaviors. *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 11, pp. 3122–3134. ISSN 1524-9050, 1558-0016. DOI 10.1109/ITITS.2017.2681810.
- XU, Q. und WANG, N., 2014. A Survey on Ship Collision Risk Evaluation. *PROMET - Traffic & Transportation*, vol. 26, no. 6, pp. 475–486. ISSN 1848-4069, 0353-5320. DOI 10.7307/ptt.v26i6.1386.
- XU, Z., ZENG, W., CHU, X. und CAO, P., 2021. Multi-Aircraft Trajectory Collaborative Prediction Based on Social Long Short-Term Memory Network. *Aerospace*, vol. 8, no. 4, pp. 115. ISSN 2226-4310. DOI 10.3390/aerospace8040115.
- YANG, L. und SHAMI, A., 2020. On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, vol. 415, pp. 295–316. ISSN 09252312. DOI 10.1016/j.neucom.2020.07.061.
- YI LIN, BO YANG, JIANWEI ZHANG, und HONG LIU, 2019. Approach for 4-D Trajectory Management based on Trajectory Similarity. *Journal of Marine Science and Technology*, vol. 27, no. 3. DOI 10.6119/JMST.201906_27(3).0007.
- ZEILER, M.D., RANZATO, M., MONGA, R., MAO, M., YANG, K., LE, Q.V., NGUYEN, P., SENIOR, A., VANHOUCHE, V., DEAN, J. und HINTON, G.E., 2013. On rectified linear units for speech processing. *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. Vancouver, BC, Canada: IEEE, pp. 3517–3521. ISBN 978-1-4799-0356-6. DOI 10.1109/ICASSP.2013.6638312.
- ZENG, W., CHU, X., XU, Z., LIU, Y. und QUAN, Z., 2022. Aircraft 4D Trajectory Prediction in Civil Aviation: A Review. *Aerospace*, vol. 9, no. 2, pp. 91. ISSN 2226-4310. DOI 10.3390/aerospace9020091.
- ZENG, W., QUAN, Z., ZHAO, Z., XIE, C. und LU, X., 2020. A Deep Learning Approach for Aircraft Trajectory Prediction in Terminal Airspace. *IEEE Access*, vol. 8, pp. 151250–151266. ISSN 2169-3536. DOI 10.1109/ACCESS.2020.3016289.
- ZIS, T.P.V., PSARAFTIS, H.N. und DING, L., 2020. Ship weather routing: A taxonomy and survey. *Ocean Engineering*, vol. 213, pp. 107697. ISSN 00298018. DOI 10.1016/j.oceaneng.2020.107697.

ZISSIS, D., XIDIAS, E.K. und LEKKAS, D., 2016. Real-time vessel behavior prediction. *Evolving Systems*, vol. 7, no. 1, pp. 29–40. ISSN 1868-6478, 1868-6486. DOI 10.1007/s12530-015-9133-5.

Anhang




Abbildung 71: Verteilung der Schiffslängen der Cargo-Schiffe im Datensatz.




Abbildung 72: Verteilung der Schiffslängen der Cargo-Schiffe im Datensatz.




Abbildung 73: Prädiktionsfehler in Meter der linearen Prädiktion, des LSTM-Modells 1 und 2.




Abbildung 74: Prädiktionsfehler für den Kurs der linearen Prädiktion, des LSTM-Modells 1 und 2.




Abbildung 75: Prädiktionsfehler für die Geschwindigkeit der linearen Prädiktion, des LSTM-Modells 1 und 2.

Tabelle 12: Zusammenfassung der Prädiktionsfehler des linearen Modells.

		Elbe	Jade	Weser
Position (in Meter)	Mittel	174,86	251,77	225,62
	Median	176,58	259,38	224,19
	σ	86,15	85,06	59,26
	RMSE	194,93	265,75	233,27
COG (in °)	Mittel	7,33	7,47	5,46
	Median	5,10	1,65	3,25
	σ	9,10	12,12	6,86
	RMSE	11,68	14,24	8,77
SOG (in Knoten)	Mittel	1,58	1,76	1,75
	Median	1,25	1,25	1,30
	σ	1,00	1,29	1,38
	RMSE	1,88	2,18	2,23
SD (in %)	Mittel	45,76	33,27	30,10
	Median	35,06	27,27	25,79
	σ	29,01	19,32	15,29

Tabelle 13: Zusammenfassung der Prädiktionsfehler des LSTM-Modells 1.

		Elbe	Jade	Weser
d_{star} (in Meter)	Mittel	139,43	180,86	173,88
	Median	103,02	171,38	136,24
	σ	126,35	126,36	146,79
	RMSE	188,17	220,63	227,56
COG (in °)	Mittel	2,23	2,32	1,88
	Median	1,71	1,62	1,40
	σ	2,19	2,28	1,80
	RMSE	3,12	3,26	2,60
SOG (in Knoten)	Mittel	1,12	1,38	1,46
	Median	0,72	1,07	1,22
	σ	1,11	1,10	1,16
	RMSE	1,58	1,73	1,85
SD (in %)	Mittel	52,57	48,73	47,88
	Median	44,35	37,02	36,03
	σ	32,94	33,00	29,63

Tabelle 14: Zusammenfassung der Prädiktionsfehler des LSTM-Modells 2.

		Elbe	Jade	Weser
d_{star} (in Meter)	Mittel	101,40	115,31	109,00
	Median	74,76	94,21	79,63
	σ	100,75	96,32	101,50
	RMSE	142,94	150,25	148,94
COG (in °)	Mittel	2,17	1,87	2,22
	Median	1,72	1,40	1,59
	σ	1,90	1,81	2,28
	RMSE	2,88	2,61	3,18
SOG (in Knoten)	Mittel	0,65	0,71	0,81
	Median	0,44	0,50	0,58
	σ	0,68	0,75	0,87
	RMSE	0,94	1,03	1,19
SD (in %)	Mittel	62,41	69,17	59,97
	Median	60,31	76,27	53,84
	σ	31,81	31,04	31,01

Tabelle 15: Zusammenfassung der Prädiktionsfehler des linearen Modells je Cargo-Schiffsklasse.

Cargo klein													
	Elbe				Jade				Weser				
	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD	
Mittel	105,60	7,59	1,55	44,43	-	-	-	-	-	-	-	-	
Median	82,21	5,30	1,30	30,72	-	-	-	-	-	-	-	-	
σ	63,43	9,46	0,97	34,61	-	-	-	-	-	-	-	-	
RMSE	123,18	12,13	1,83	-	-	-	-	-	-	-	-	-	
Cargo mittel													
Mittel	113,19	7,79	1,53	40,83	-	-	-	-	185,03	6,73	1,55	12,60	
Median	94,71	4,77	1,25	32,66	-	-	-	-	185,57	3,40	1,30	11,34	
σ	61,84	11,05	0,96	28,77	-	-	-	-	45,57	9,19	1,03	4,63	
RMSE	128,99	13,52	1,80	-	-	-	-	-	190,56	11,39	1,86	-	
Cargo groß													
Mittel	184,23	7,18	1,58	44,57	252,85	9,11	1,62	24,27	227,37	5,46	1,76	28,01	
Median	191,58	4,90	1,25	31,34	238,49	2,25	1,20	21,90	228,73	3,20	1,30	24,80	
σ	90,86	8,87	0,98	29,10	90,86	13,66	1,11	13,44	74,96	6,89	1,36	12,88	
RMSE	236,11	11,41	1,86	-	268,68	16,42	1,97	-	214,71	8,79	2,22	-	
Cargo sehr groß													
Mittel	201,20	7,11	1,66	51,95	281,69	8,78	1,91	35,70	219,33	5,29	1,86	44,85	
Median	210,08	5,90	1,30	42,55	291,29	1,55	1,40	28,70	213,35	3,40	1,35	39,53	
σ	74,96	7,69	1,08	25,24	85,86	13,80	1,34	17,77	62,73	6,08	1,56	19,32	
RMSE	214,74	10,48	1,99	-	294,49	16,36	2,34	-	228,12	8,07	2,43	-	

Tabelle 16: Zusammenfassung der Prädiktionsfehler des linearen Modells je Tanker-Schiffsklasse.

Tanker mittel												
Elbe				Jade				Weser				
	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD
Mittel	153,11	7,96	1,52	41,14	218,02	15,06	1,90	19,24	197,22	4,37	1,24	19,00
Median	142,67	5,45	1,25	27,28	267,09	6,30	1,42	11,34	202,76	2,00	1,20	15,77
σ	81,28	10,59	0,97	30,07	74,76	11,84	1,09	17,64	47,81	5,95	0,20	11,21
RMSE	173,35	13,25	1,80	–	230,48	24,91	1,19	–	202,93	7,39	1,26	–
Tanker groß												
Mittel	167,40	7,13	1,53	50,44	236,71	6,12	1,71	36,26	227,65	6,17	1,68	25,55
Median	167,05	4,57	1,25	34,77	249,41	1,60	1,25	28,78	223,58	3,67	1,20	23,88
σ	88,47	8,34	0,98	32,53	80,78	9,66	1,32	20,63	58,42	8,62	1,75	9,84
RMSE	189,34	10,98	1,82	–	251,11	11,44	2,16	–	235,03	10,60	2,43	–

Tabelle 17: Zusammenfassung der Prädiktionsfehler des LSTM-Modells 3 je Cargo-Schiffsklasse.

Cargo klein												
	Elbe				Jade				Weser			
	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD
Mittel	87,36	2,30	1,31	42,78	-	-	-	-	-	-	-	-
Median	61,97	1,27	1,10	26,07	-	-	-	-	-	-	-	-
σ	75,79	2,44	1,01	35,86	-	-	-	-	-	-	-	-
RMSE	115,65	3,35	1,66	-	-	-	-	-	-	-	-	-
Cargo mittel												
Mittel	100,96	2,24	1,03	38,26	-	-	-	-	109,10	2,97	0,88	33,11
Median	82,02	1,68	0,72	25,46	-	-	-	-	81,85	1,78	0,68	21,645
σ	82,30	1,97	1,01	30,66	-	-	-	-	100,31	3,35	0,89	29,33
RMSE	130,05	2,98	1,42	-	-	-	-	-	148,21	4,48	1,25	-
Cargo groß												
Mittel	140,58	2,21	1,09	54,37	127,51	2,22	0,92	50,94	172,04	1,90	1,47	49,03
Median	104,54	1,72	0,67	46,68	135,26	1,68	0,78	33,70	128,85	1,42	1,21	37,69
σ	124,85	1,98	1,11	32,53	94,94	2,31	0,64	31,99	148,89	1,82	1,18	33,41
RMSE	188,02	2,97	1,56	-	158,97	3,21	1,12	-	227,52	2,63	1,89	-
Cargo sehr groß												
Mittel	173,36	2,10	1,211	62,03	185,00	2,83	1,78	54,71	220,04	1,67	1,66	48,85
Median	123,10	1,74	0,78	61,89	173,71	1,51	1,65	47,59	204,20	1,32	1,533	37,10
σ	147,03	1,72	1,19	31,53	128,53	2,87	1,12	28,82	149,76	1,45	1,10	30,45
RMSE	227,32	2,72	1,70	-	225,27	4,03	2,10	-	266,17	2,21	1,99	-

Tabelle 18: Zusammenfassung der Prädiktionsfehler des LSTM-Modells 3 je Tanker-Schiffsklasse.

Tanker mittel												
Elbe				Jade				Weser				
	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD
Mittel	157,56	2,35	1,15	37,10	199,36	3,25	0,86	41,77	165,06	1,90	0,85	49,94
Median	122,71	1,72	0,79	25,02	203,17	2,11	0,55	26,48	168,48	1,97	0,95	39,43
σ	134,10	2,46	1,11	30,00	157,14	3,24	0,90	33,09	128,08	1,04	0,79	26,14
RMSE	206,91	3,41	1,59	–	214,63	4,60	1,25	–	170,86	2,17	1,20	–
Tanker groß												
Mittel	142,99	2,17	1,12	51,39	193,47	3,27	0,82	44,17	135,21	2,235	0,66	49,80
Median	117,41	1,77	0,77	40,77	107,45	2,66	0,81	33,69	138,90	1,78	0,52	29,50
σ	115,80	1,82	1,03	31,04	174,92	3,21	0,93	28,50	39,51	2,63	0,14	34,74
RMSE	183,99	2,83	1,52	–	210,82	4,58	1,24	–	184,28	3,12	0,77	–

Tabelle 19 Zusammenfassung der Prädiktionsfehler des LSTM-Modells 4 je Cargo-Schiffsklasse.

Cargo klein												
	Elbe				Jade				Weser			
	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD
Mittel	62,44	2,26	0,50	47,77	–	–	–	–	–	–	–	–
Median	47,37	1,50	0,41	33,73	–	–	–	–	–	–	–	–
σ	58,95	2,18	0,46	33,65	–	–	–	–	–	–	–	–
RMSE	85,87	3,14	0,68	–	–	–	–	–	–	–	–	–
Cargo mittel												
Mittel	75,90	2,22	0,72	51,69	–	–	–	–	57,00	2,48	0,50	46,42
Median	52,62	1,75	0,39	40,32	–	–	–	–	49,92	1,72	0,49	36,06
σ	98,83	1,97	0,69	33,84	–	–	–	–	39,48	2,68	0,28	30,04
RMSE	124,61	2,97	0,91	–	–	–	–	–	69,34	3,66	0,57	–
Cargo groß												
Mittel	106,40	2,18	0,66	63,51	106,05	2,06	0,89	61,74	112,05	2,74	0,71	60,15
Median	81,35	1,73	0,44	59,90	73,38	0,60	0,37	57,23	92,19	1,42	0,50	54,06
σ	105,90	0,68	0,68	31,01	104,87	2,40	1,06	31,52	94,40	1,86	0,77	31,14
RMSE	150,12	2,90	0,95	–	149,15	3,17	1,38	–	146,52	2,66	1,06	–
Cargo sehr groß												
Mittel	128,43	2,02	0,74	71,13	120,90	2,74	0,933	78,01	156,21	1,65	0,80	60,97
Median	101,46	1,73	0,49	75,16	75,33	1,85	0,58	98,81	138,14	1,26	0,54	54,93
σ	110,37	1,67	0,84	28,63	134,18	2,93	1,11	29,90	110,49	1,52	0,79	29,56
RMSE	169,34	2,62	1,12	–	180,61	4,01	1,45	–	191,34	2,24	1,12	–

Tabelle 20: Zusammenfassung der Prädiktionsfehler des LSTM-Modells 4 je Cargo-Schiffsklasse.

Tanker mittel												
Elbe				Jade				Weser				
	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD	d_{star}	COG	SOG	SD
Mittel	107,39	2,30	0,50	51,39	99,36	3,25	0,68	48,72	65,06	1,90	0,15	58,13
Median	73,09	1,58	0,35	43,70	103,16	2,11	0,55	43,70	68,47	1,97	0,16	46,76
σ	103,15	2,47	0,50	33,55	57,14	3,23	0,90	34,00	28,07	1,04	0,08	27,12
RMSE	148,90	3,38	0,71	–	114,25	4,59	1,25	–	70,86	2,17	0,17	23,57
Tanker groß												
Mittel	102,94	2,15	0,64	61,54	99,67	2,01	0,70	67,73	135,21	2,23	0,66	55,93
Median	85,95	1,71	0,48	57,57	82,62	1,65	0,58	66,66	100,45	1,47	0,71	42,18
σ	80,89	1,75	0,56	30,46	76,56	1,67	0,56	30,09	125,21	2,17	0,38	37,66
RMSE	130,92	2,77	0,85	–	125,68	2,61	0,90	–	184,28	3,11	0,77	–

Tabelle 21: Fragebogen der qualitativen Bewertung der Anomaliedetektion für d_{star} .

ID	Art der Anomalie	False-Positive
1	d_{star}	X
2	d_{star}	
3	d_{star}	X
4	d_{star}	
5	d_{star}	X
6	d_{star}	X
7	d_{star}	
8	d_{star}	
9	d_{star}	X
10	d_{star}	
11	d_{star}	X
12	d_{star}	
13	d_{star}	
14	d_{star}	X
15	d_{star}	X
16	d_{star}	X
17	d_{star}	
18	d_{star}	
19	d_{star}	
20	d_{star}	
21	d_{star}	
22	d_{star}	X
23	d_{star}	
24	d_{star}	
25	d_{star}	
26	d_{star}	
27	d_{star}	X
28	d_{star}	
29	d_{star}	

ID	Art der Anomalie	False-Positive
30	d_{star}	X
31	d_{star}	X
32	d_{star}	
33	d_{star}	X
34	d_{star}	
35	d_{star}	X
36	d_{star}	
37	d_{star}	
38	d_{star}	
39	d_{star}	
40	d_{star}	
41	d_{star}	X
42	d_{star}	
43	d_{star}	
44	d_{star}	
45	d_{star}	
46	d_{star}	
47	d_{star}	
48	d_{star}	X
49	d_{star}	X
50	d_{star}	X
51	d_{star}	X
52	d_{star}	
53	d_{star}	
54	d_{star}	
55	d_{star}	X
56	d_{star}	
57	d_{star}	
58	d_{star}	
59	d_{star}	

Tabelle 22: Fragebogen der qualitativen Bewertung der Anomaliedetektion für *COG*.

ID	Art der Anomalie	False-Positive
1	<i>COG</i>	
2	<i>COG</i>	X
3	<i>COG</i>	X
4	<i>COG</i>	
5	<i>COG</i>	X
6	<i>COG</i>	
7	<i>COG</i>	
8	<i>COG</i>	X
9	<i>COG</i>	
10	<i>COG</i>	X
11	<i>COG</i>	
12	<i>COG</i>	
13	<i>COG</i>	X
14	<i>COG</i>	
15	<i>COG</i>	
16	<i>COG</i>	X
17	<i>COG</i>	
18	<i>COG</i>	X
19	<i>COG</i>	
20	<i>COG</i>	
21	<i>COG</i>	X

ID	Art der Anomalie	False-Positive
22	<i>COG</i>	X
23	<i>COG</i>	X
24	<i>COG</i>	
25	<i>COG</i>	X
26	<i>COG</i>	
27	<i>COG</i>	X
28	<i>COG</i>	X
29	<i>COG</i>	X
30	<i>COG</i>	X
31	<i>COG</i>	
32	<i>COG</i>	
33	<i>COG</i>	
34	<i>COG</i>	X
35	<i>COG</i>	
36	<i>COG</i>	X
37	<i>COG</i>	
38	<i>COG</i>	X
39	<i>COG</i>	X
40	<i>COG</i>	
41	<i>COG</i>	X

Tabelle 23: Fragebogen der qualitativen Bewertung der Anomaliedetektion für *SOG*.

ID	Art der Anomalie	False-Positive
1	<i>SOG</i>	
2	<i>SOG</i>	
3	<i>SOG</i>	
4	<i>SOG</i>	
5	<i>SOG</i>	
6	<i>SOG</i>	X
7	<i>SOG</i>	X
8	<i>SOG</i>	
9	<i>SOG</i>	
10	<i>SOG</i>	
11	<i>SOG</i>	
12	<i>SOG</i>	
13	<i>SOG</i>	
14	<i>SOG</i>	
15	<i>SOG</i>	
16	<i>SOG</i>	
17	<i>SOG</i>	
18	<i>SOG</i>	
19	<i>SOG</i>	
20	<i>SOG</i>	
21	<i>SOG</i>	
22	<i>SOG</i>	
23	<i>SOG</i>	X
24	<i>SOG</i>	
25	<i>SOG</i>	
26	<i>SOG</i>	
27	<i>SOG</i>	
28	<i>SOG</i>	

ID	Art der Anomalie	False-Positive
29	<i>SOG</i>	
30	<i>SOG</i>	
31	<i>SOG</i>	X
32	<i>SOG</i>	
33	<i>SOG</i>	
34	<i>SOG</i>	
35	<i>SOG</i>	
36	<i>SOG</i>	
37	<i>SOG</i>	
38	<i>SOG</i>	
39	<i>SOG</i>	
40	<i>SOG</i>	
41	<i>SOG</i>	X
42	<i>SOG</i>	
43	<i>SOG</i>	
44	<i>SOG</i>	
45	<i>SOG</i>	
46	<i>SOG</i>	
47	<i>SOG</i>	
48	<i>SOG</i>	
49	<i>SOG</i>	
50	<i>SOG</i>	
51	<i>SOG</i>	
52	<i>SOG</i>	
53	<i>SOG</i>	
54	<i>SOG</i>	X
55	<i>SOG</i>	
56	<i>SOG</i>	