

Datenbasierte Modellierung der aerodynamischen Lasten auf Überwasserschiffe

Vom Promotionsausschuss der
Technischen Universität Hamburg
zur Erlangung des akademischen Grades

Doktor-Ingenieur (Dr.-Ing.)

genehmigte Dissertation

von
Rupert Pache

aus
Stuttgart

2023

Gutachter:

1. Gutachter: Prof. Dr.-Ing. Thomas Rung
2. Gutachter: Prof. Dr.-Ing. Benedikt Kriegesmann

Tag der mündlicher Prüfung:

6. Oktober 2023

Vorsitzender des Prüfungsausschusses:

Prof. Dr.-Ing. Robert Seifried

Copyright © Rupert Pache, 2023

Digital Object Identifier (DOI): 10.15480/882.8718

Open Researcher & Contributor ID (ORCID): 0000-0001-7086-3707



Dieses Werk ist unter einer *Creative Commons* Lizenz vom Typ *Namensnennung 4.0 International* zugänglich. Um eine Kopie dieser Lizenz einzusehen, konsultieren Sie <https://creativecommons.org/licenses/by/4.0/> oder wenden Sie sich brieflich an *Creative Commons*, Postfach 1866, Mountain View, California, 94042, USA.

Kurzfassung

Beim realen Betrieb fluiddynamischer Systeme sind häufig eine große Zahl unterschiedlicher Systemparameter von Relevanz. Der Simulationsaufwand, um das gesamte Spektrum an Systemparametern eines solchen Systems zu betrachten, ist für klassische Simulationsmethoden enorm. Um dennoch Vorhersagen für beliebige Betriebsparameter zu ermöglichen, werden datenbasierte Surrogatmodelle eingesetzt. Das Anwendungsfeld der vorliegenden Arbeit ist die aerodynamische Umströmung von Überwasserschiffen. Die aus der Umströmung resultierenden Lasten sind für den energieoptimierten Betrieb als Zusatzwiderstand oder als externe Kräfte beim Manövrieren und dynamischen Positionieren von Bedeutung. Um die wirkenden Lasten an Bord in Entscheidungsunterstützungssysteme integrieren zu können, ist eine nahezu-Echtzeit Vorhersage der Lasten für unterschiedliche Betriebsparameter notwendig.

Für die Entwicklung der datenbasierten Surrogatmodelle wird eine umfangreiche und qualitativ hochwertige Datengrundlage benötigt. Dazu dienen zeitlich gemittelte Strömungsfelder, welche mittels hochauflösender Finite-Volumen-Simulationen erstellt werden. Bei den Decksaufbauten und der Ladung an Deck von Schiffen handelt es sich größtenteils um stumpfe Körper, deren Umströmung von starker Ablösung geprägt ist. Um möglichst genaue Simulationsergebnisse zu erhalten, wird ein hybrides RANS/LES-Turbulenzmodell angewendet. Die Simulationsergebnisse werden durch Messungen im Windkanal validiert.

Für die datenbasierte Modellierung wird im ersten Schritt eine Dimensionsreduktion der Datenbasis erstellt. Dazu werden zwei unterschiedliche Methoden verwendet. Zum einen die orthogonale Matrixzerlegung (POD) und zum anderen faltungsbasierte Autoencoder (CNN-Autoencoder). Für die Autoencoder basierte Dimensionsreduktion lassen sich deutlich kompaktere Darstellungen finden. Um ein vollständiges Ersatzmodell zu erhalten, ist in einem weiteren Schritt die Regression der in der Dimensionsreduktion auftretenden Koeffizienten erforderlich. Für diesen Schritt werden ebenfalls unterschiedliche Methoden eingesetzt: die Polynomregression, die Regression basierend auf Gaußprozessen oder auf Neuronalen Netzen. Zusätzlich wird das gleichzeitige Lernen der Dimensionsreduktion und einer Polynom basierten Regression innerhalb eines Trainingsprozesses durchgeführt. Die reduzierten Koeffizienten innerhalb des Autoencoders werden dabei für die Polynomregression optimiert gelernt.

Die Modelle werden für zwei unterschiedlich komplexe Datensätze erstellt und verglichen. Die Datensätze unterscheiden sich in der Komplexität der enthaltenen Beladungskonfigurationen. Die entwickelten datenbasierten Surrogatmodelle erzielen gute Übereinstimmungen bei der Rekonstruktion der Druckfelder für unbekannte Systemparameter. Für die aus den Druckfeldern resultierenden Lasten zeigt sich ebenfalls eine gute Übereinstimmung mit den Referenzdaten. Für die unterschiedlichen Varianten der Gesamtmodellierung ergeben sich geringfügige Unterschiede in der Vorhersagequalität.

Danksagung

Diese Arbeit entstand während meiner Beschäftigung am Institut für Fluidodynamik und Schiffstheorie der Technischen Universität Hamburg.

Zuallererst möchte ich mich bei Prof. Dr.-Ing. Thomas Rung für die Betreuung der Arbeit und die Möglichkeit, im spannenden Themenfeld der numerischen Strömungssimulation und der datenbasierten Modellierung zu forschen, bedanken. Die fachlichen Diskussionen und die konstruktiven Ratschläge haben die Ergebnisse dieser Arbeit auf entscheidende Weise geprägt. Für die Übernahme des Zweitgutachters bedanke ich mich bei Prof. Dr.-Ing. Benedikt Kriegesmann, sowie für die Übernahme des Prüfungsvorsitzes des Promotionsverfahrens bei Prof. Dr.-Ing. Robert Seifried.

Allen Kollegen am Institut danke ich für die schöne Zeit, den fachlichen Austausch und die angenehme Arbeitsatmosphäre. Insbesondere danke ich meinem langjährigen Büronachbarn Philip Streckwall für die angenehme Atmosphäre und den netten Austausch.

Bei meiner Familie, insbesondere bei meinen Eltern und Brüdern, bedanke ich mich von Herzen für die Unterstützung und Motivation während meiner Studien- und Promotionszeit. Meiner lieben Frau Hannah danke ich für ihre Geduld, die Unterstützung und ihr Verständnis während der verschiedenen Phasen meiner Promotion. Zu guter Letzt möchte ich meiner Tochter Ida danken, die mir mit ihrem Lächeln Kraft und Freude für die Schlussphase meiner Dissertation schenkte.

Inhaltsverzeichnis

Kurzfassung	3
Danksagung	5
Symbolverzeichnis	11
1 Einleitung	15
1.1 Stand der Forschung	17
1.1.1 Experimentelle und numerische Betrachtung der Aerodynamik von Schiffen	17
1.1.2 Datenbasierte Modellierung komplexer Strömungsfelder	20
1.2 Ziele der Arbeit	22
1.3 Gliederung der Arbeit	23
2 Mathematische und physikalische Grundlagen	25
2.1 Transportgleichungen	25
2.1.1 Massenerhaltung	26
2.1.2 Impulserhaltung	26
2.2 Finite-Volumen-Methode	27
2.2.1 Approximation der Volumen- und Flächenintegrale	27
2.2.2 Zeitliche Ableitung	28
2.2.3 Approximation von Gradientenfeldern	29
2.2.4 Rekonstruktion der Variablenwerte in den Zellgrenzflächen	30
2.2.5 Randbedingungen	33
2.2.6 Numerische Implementierung	33
2.3 Turbulente Strömungen	34
2.3.1 Turbulente Energiekaskade	34
2.3.2 Wandgebundene Turbulenz	37
2.3.3 Abgelöste Umströmung stumpfer Körper	39
2.4 Turbulenzmodellierung	40
2.4.1 Reynoldsgemittelte-Turbulenzmodellierung	40
2.4.2 Grobstruktursimulation	45

2.4.3	Hybride Turbulenzmodelle	47
2.4.4	IDDES Modell	48
3	Experimentelle Untersuchungen im Windkanal	51
3.1	Natürliche Windverhältnisse	52
3.2	Eigenschaften des Windkanals	53
3.3	Messung der Kräfte und Momente	55
3.4	PIV-Messungen	56
3.5	Windkanalmodell eines Containerfeederschiffes	56
3.6	Ergebnisse der Kraft- und Momentenmessung im Windkanal	57
4	Simulation der aerodynamischen Schiffsumströmung	61
4.1	Simulationssetup	61
4.2	Einfluss der Gitterauflösung	65
4.3	Einfluss der Turbulenzmodellierung	71
4.4	Validierung der Simulationsmethode	77
5	Grundlagen und Methoden der Datenbasierten Modellierung	83
5.1	Orthogonale Matrixzerlegung	84
5.2	Grundlagen des Maschinellen Lernens	86
5.3	Künstliche Neuronale Netze	86
5.4	Training Neuronaler Netze	88
5.4.1	Backpropagation	89
5.4.2	Gradientenabstiegsverfahren	89
5.4.3	Adam-Optimierer	90
5.5	Faltende Neuronale Netze	91
5.6	Autoencoder	93
6	Datenbasierte Modellierung der aerodynamischen Schiffsumströmung	95
6.1	Dimensionsreduktion von Datensätzen	97
6.1.1	POD-Methode	98
6.1.2	CAE-Methode	99
6.2	Regression der Koeffizienten	100
6.3	Vorbereitung der Datenfelder	103
6.4	Erstellen und Lernen der Modelle	105
6.4.1	Generalisierbarkeit	105
6.4.2	Gütekriterien	106
6.4.3	Simultanes Lernen des Gesamtmodells	107

7 Ergebnisse der datenbasierten Modellierung	109
7.1 Eigenschaften der Datensätze	109
7.1.1 Datensatz A	110
7.1.2 Datensatz B	111
7.2 POD-basierte Dimensionsreduktion	113
7.3 CAE-basierte Dimensionsreduktion	117
7.3.1 Einfluss der Hyperparameter	117
7.3.2 Reduzierte Darstellung der Datensätze	127
7.4 Validierung des Gesamtmodells	131
7.4.1 Parametrisierung der Koeffizienten	132
7.4.2 Gesamtmodell Datensatz A	150
7.4.3 Gesamtmodell Datensatz B	151
7.5 Bewertung der Methodik und der Ergebnisse	159
8 Zusammenfassung	163
A Druckfelder Datensatz A	165
B Druckfelder Datensatz B	171
Literaturverzeichnis	179

Symbolverzeichnis

Lateinische Symbole

\tilde{p}_{ijk}	rekonstruiertes Druckfeld
a_i	Eingabeparameter eines NN
B	Schiffsbreite
b_i	Biaswerte innerhalb eines NN
B_{uu}, B_{vv}, B_{ww}	Zweipunktkorrelationen
C_M^*	relative Modellkomplexität
c_X, c_Y, c_{Mz}	dimensionlose Kraft- und Momentenbeiwerte
d	Distanzvektor
d_i	Werte der versteckten Schicht eines NN
E_P, E_X, E_Y	mittlere Fehler der Druckfelder, der Längskräfte und der Querkräfte
F	Kraft
f_i	volumenspezifischer Kraftvektor
h_C	Höhe der Containerstapelung
k	kinetische turbulente Energie
K_{ij}	Kovarianzmatrix
l	Längenmaß
L_{pp}	Länge zwischen den Loten
l_r	Lernrate
LoA	Länge über Alles
M	Moment
m, \dot{m}	Masse, Massenfluss
n_B	Batch-Größe
n_C	Anzahl CNN-Faltungsoperationen
n_E	Anzahl Epochen
n_F	Anzahl Filter
n_K	Anzahl Knoten
n_L	Anzahl Schichten
n_{param}	Anzahl der Parameter eines Modells
n_P	Polynomgrad
n_R	Anzahl berücksichtigter POD-Moden bzw. reduzierter Variablen

n_x, n_y, n_z	Anzahl kartesischer Gitterpunkte
P	turbulente Produktionsrate
p, p_{ijk}	Druck, Druckfeld
q_Φ	volumenspezifischer Quellterm
q_{ijk}	allgemeines Strömungsfeld
Q_{ij}	Snapshot-Matrix der Strömungsfelder
r_i	Vektor der POD-Koeffizienten bzw. reduzierten Variablen
Re	Reynoldszahl
S	Oberfläche
S_{ij}	Deformationstensor
t	Zeit
t^*	relativer Grenzwert der Deaktivierung
T_{ij}	Spannungstensor
u	Geschwindigkeit,
u_τ	Wandschubspannungsgeschwindigkeit
V	Volumen
w_F	CNN-Filterweite
W_{ij}	Gewichte eines NN
$x_i, (x, y, z)$	Kartesische Koordinaten
y^+	dimensionsloser Wandabstand

Griechische Symbole

Ξ_{ij}	Matrix der Polynomregression
α_i	Systemparameter
β	Windwinkel
$\Delta S_i, \Delta S$	Vektor der Grenzfläche, Fläche der Grenzfläche
Δt	Zeitschritt
ΔV	Kontrollvolumen
δ	Grenzschichtdicke
Δ_x	Gitterabstand
δ_{ij}	Einheitstensor
ϵ	Energietransferrate
γ	Verhältnis der aufgelösten zur gesamten turb. kinetischen Energie
Γ	Diffusionskoeffizient
κ	Karman-Konstante, Wellenzahl, kumulative Energie
λ_f	Interpolationsfaktor
μ_t	turbulente Viskosität

ν	kinematische Viskosität
ω	Frequenz der dissipativen Wirbel
Φ	allgemeine Transportgröße
Φ_{ij}	Matrix der POD-Moden
ψ	Aktivierungsfunktion
ρ	Dichte
σ_i	Singularwert
τ_w	Wandschubspannung
ξ_i	Koeffizienten der Polynomregression

Hochstellungen

n	aktuelle Zeitebene
$n - 1, n - 2$	vorherige Zeitebenen

Tiefstellungen

Dec	Decoder
Enc	Encoder
F	Zentrum der Zellgrenzfläche
$mean$	Mittelwert
MG	Metagitter
mod	modellierte Größe
P, N	betrachtetes Zellzentrum und benachbartes Zellzentrum
res	aufgelöste Größe

Operatoren

$\ \cdot\ $	Euklidische Norm
$\overline{(\cdot)}$	Mittelwert

Abkürzungen

AE	Autoencoder
ANN	Artificial Neural Network
CAE	Convolutional Neural Network basierter Autoencoder
CDS	Central Differencing Scheme
CNN	Convolutional Neural Network
DDES	Delayed Detached Eddy Simulation
DES	Detached Eddy Simulation
DNS	Direkte Numerische Simulation

FreSco ⁺	Finite-Volumen-Löser
HO	High Order
IDDES	Improved Delayed Detached Eddy Simulation
KV	Kontrollvolumen
LES	Large Eddy Simulation
ML	Maschinelles Lernen
MPI	Message Passing Interface
NN	Neuronales Netzwerk
PIV	Particle Image Velocimetry
POD	Proper Orthogonal Decomposition
QUICK	Quadratic Upstream Interpolation of Convective Kinematics
RANS	Reynolds gemittelte Navier-Stokes-Gleichungen
RBF	Radial Basis Function
SIMPLE	Semi-Implicit Method for Pressure-Linked Equations
SST	Shear Stress Transport
TDW	Tons Dead Weight
TEU	Twenty-foot Equivalent Unit
UDS	Upwind Differencing Scheme

1 Einleitung

Der internationale Handel erfordert den Transport großer Warenmengen über lange Distanzen, welcher größtenteils durch die weltweite Schifffahrt bewältigt wird. Im Vergleich zu anderen land- oder luftgebundenen Transportmöglichkeiten ist der Transport von Waren mit Schiffen die effizienteste Möglichkeit in Bezug der Kosten pro Tonne. Dennoch trägt auch die Schifffahrt einen Anteil zu den weltweiten klimaschädlichen Emissionen bei. Durch ein erweitertes weiteres Wachstum der Schifffahrt in den kommenden Jahren kann dieser Wert weiter ansteigen (IMO, 2021). Um die Effizienz der Schifffahrt zu erhöhen und damit die Emissionen zu reduzieren, werden die Entwürfe und Konzeption neu gebauter Schiffe immer weiter verbessert. Zusätzlich werden im Betrieb befindliche Schiffe angepasst und umgebaut. Neben den ökologischen Interessen wirkt sich die Einsparung von Kraftstoff und somit Kosten auf die ökonomische Wettbewerbsfähigkeit der Reeder aus. Durch immer weiter verbesserte Schiffsentwürfe ist bereits ein Großteil des Optimierungspotentials erreicht. Hierdurch rückt die Steuerung eines optimierten Schiffsbetriebs zusehends in den Fokus der Reeder der Schiffe.

Das Optimierungspotential besteht in unterschiedlichen Bereichen des Schiffsbetriebs, wie dem optimierten Betrieb der unterschiedlichen Maschinenanlagen an Bord oder einer wetterbasierten Optimierung der Reiseroute. Für die Optimierung des Schiffsbetriebes muss der Energiefluss des Gesamtsystems Schiff analysiert und quantifiziert werden. Zur Routenoptimierung werden Systeme zur Entscheidungsunterstützung für das Personal an Bord bereitgestellt, welche die Potentiale zur Einsparung unterschiedlicher Routen aufzeigen und Handlungsempfehlungen geben. Aufbauend auf diesen Systemen kann auch bei zukünftig autonom fahrenden Schiffen der Kraftstoffverbrauch im Betrieb optimiert werden.

Bei einer Routenoptimierung wird die Route des Reiseverlaufs während einer Fahrt so angepasst, dass der Kraftstoffverbrauch möglichst gering ist. Häufig ist dabei eine feste Ankunftszeit für den nächsten anzulaufenden Hafen vorgegeben. Zusätzlich müssen viele weitere Bedingungen berücksichtigt werden, wie z.B. sicherheitsrelevante Vorschriften. Bei vielen Schiffen ist es üblich, dass während des ersten Teils der Reise durch eine höhere Fahrtgeschwindigkeit eine zeitliche Sicherheit aufgebaut wird, welche dann durch eine geringere Geschwindigkeit am Ende der Passage ausgeglichen wird. Für einen Kraftstoff optimierten Routenverlauf ist hingegen eine möglichst gleichmäßige und niedrigere Geschwindigkeit von Vorteil. Abhängig von der Wetterlage ist nicht der direkte Weg der optimale, wenn z.B. durch eine leichte Änderung des Kurses während der Reise die wetterbedingten Zusatzwiderstände reduziert werden können.

Die eingesetzte Primärenergie in Form des Kraftstoffs wird dabei hauptsächlich zum Überwinden des fluiddynamischen Widerstandes benötigt. Der Widerstand setzt sich aus unterschiedlichen Anteilen zusammen: dem Glattwasserwiderstand und den wetterbedingten Zusatzwiderständen durch Welle, Wind und Eis. Für eine Optimierung der Route ist eine möglichst genaue Bestimmung und Modellierung der Widerstandsanteile in Abhängigkeit der unterschiedlichen Betriebs- und Umweltparameter nötig. Diese muss in nahezu-Echtzeit erfolgen, um direkte Handlungsempfehlungen während des Betriebs aufzeigen zu können. Die unterschiedlichen Betriebs- und Umweltbedingungen liegen aus Sensordaten an Bord sowie Wettervorhersagen vor und dienen als Basis der Bestimmung der vorliegenden Widerstandsanteile.

Die bereits existierenden Methoden der Routenoptimierung verwenden zur Modellierung der Widerstandsanteile des Schiffes im Betrieb vorwiegend empirische Methoden. Die empirischen Methoden werden nicht für das spezifische Schiff angepasst, wodurch eine relativ ungenaue Abschätzungen der Widerstandsanteile erfolgt. Diese Prognosen erhalten daher große Unsicherheiten, welche bei einer Routenoptimierung oftmals in der Größenordnung der potentiellen Einsparungen liegen und damit nicht für eine zuverlässige Routenoptimierung ausreichen. Daher werden für die einzelnen Widerstandsanteile präzisere Vorhersagen bei geringem Rechenaufwand benötigt. In der vorliegenden Arbeit liegt der Schwerpunkt auf der effizienten und möglichst genauen Bestimmung der aerodynamischen Lasten, welche durch den Eigenfahrtwind und meteorologischen Wind auf das Überwasserschiff wirken.

Neben der Betrachtung der Windlasten als Zusatzwiderstand sind die aerodynamischen Lasten auch beim Manövrieren und dynamischen Positionieren von Schiffen von großer Relevanz. Hierbei kann eine Echtzeit-nahe Bestimmung der Lasten und Darstellung auf der Brücke zum sicheren und effizienten Manövrieren beitragen. Darüber hinaus hat die Bestimmung und Analyse der aerodynamischen Umströmung von Schiffen Relevanz für weitere Fragestellungen, wie dem Passagierkomfort an Bord von Fahrgastschiffen oder dem sicheren Betrieb von Helikoptern bei Spezialschiffen.

Um die exakten aerodynamischen Lasten eines einzelnen Schiffes zu bestimmen, müssen für jedes spezifische Schiff umfangreiche Simulationen durchgeführt werden. Dabei entstehen große Datenmengen, bei welchen häufig nur die integralen Größen von Interesse sind. Hier bilden die datenbasierten Modellierungsmethoden eine gute Möglichkeit, die aus den Simulationen erhaltenen Felddaten weiter zu verwenden und ebenfalls für andere Schiffe als Modellierungsbasis einzusetzen. Die datenbasierte Modellierung bietet darüber hinaus die Möglichkeit Daten aus unterschiedlichen Quellen, wie zum Beispiel Windkanalversuchen oder Messungen an Bord und numerischen Simulationen gemeinsam in einem Gesamtmodell zu kombinieren.

Ziel der vorliegenden Arbeit ist die möglichst genaue Bestimmung der aerodynamischen Schiffsumströmung mit Methoden der numerischen Strömungssimulationen und der Validie-

rung dieser Methoden durch Windkanalversuche. Basierend auf den Daten der numerischen Simulationen wird anschließend eine datenbasierte Surrogatmodellierung durchgeführt, um die Lasten für unterschiedliche Betriebszustände und Umweltparameter mit geringem Rechenaufwand bzw. nahezu in Echtzeit bestimmen zu können. Der aktuelle Stand der Forschung sowie die darauf aufbauenden Entwicklungen im Rahmen dieser Arbeit werden in den beiden folgenden Abschnitten dargelegt.

1.1 Stand der Forschung

Im Folgenden wird ein Überblick über den aktuellen Stand der Forschung im Bereich der experimentellen und numerischen Betrachtung der Aerodynamik von Schiffen sowie der datenbasierten Modellierung in der Strömungsmechanik gegeben. Hierfür werden jeweils die Methoden der Modellierung sowie einige zugehörigen Anwendungsfelder dargestellt.

1.1.1 Experimentelle und numerische Betrachtung der Aerodynamik von Schiffen

Historisch betrachtet hatte die Aerodynamik bei windangetriebenen Segelschiffen eine zentrale Bedeutung. Seit der Einführung des Dampf- und Dieselantriebs in der Schifffahrt hat die Bedeutung der aerodynamischen Umströmung des Überwasserschiffes im Vergleich zur hydrodynamischen Betrachtung des Unterwasserschiffes jedoch abgenommen. In den letzten Jahren hat die Betrachtung der Aerodynamik auch bei Schiffen wieder stärker an Bedeutung gewonnen. Handelsschiffe, insbesondere Containerschiffe, werden immer größer, wodurch die Windangriffsflächen größer und die damit verbundenen Windlasten größer werden und schwieriger zu beherrschen sind. Die relative Antriebsleistung hingegen nimmt aufgrund ökologischer Gesichtspunkte und verringerter Geschwindigkeiten ab, was beim Manövrieren und dem gleichzeitigen Wirken großer Windlasten zu Problemen führen kann. Teilweise werden auch wieder Konzepte mit zusätzlichen windgetriebenen Antriebskonzepten in Betracht gezogen.

In der Regel dienen experimentelle Untersuchungen im Modellmaßstab als Grundlage zur Betrachtung der aerodynamischen Umströmung von Schiffen. Umfangreiche Experimente für unterschiedliche Schiffstypen mit gleichmäßiger Zuströmung wurden von Blendermann (1986, 1996) durchgeführt und veröffentlicht. Die aus den Messungen bestimmten Lasten für die Längs- und Querkraft sowie das Gier- und Rollmoment werden als dimensionslose Koeffizienten für alle Windwinkel dargestellt. Die Koeffizienten können auf die Großausführung übertragen werden. Dabei kann die Reynolds'sche Ähnlichkeit nicht eingehalten werden. Auf Grund der geometrisch klar definierten Ablösekanten der Überwasserschiffsgeometrie kann

von einem geringen Einfluss der Reynoldszahl ausgegangen werden. Für ein spezifisches Schiff werden häufig keine eigenen Windkanalversuche durchgeführt, sondern auf die Koeffizienten eines ähnlichen Schiffes zur Modellierung der Lasten zurückgegriffen. Bei der Übertragung der Messwerte auf die Großausführung müssen der Versperrungseffekt des Windkanals sowie der Einfluss der unterschiedlichen Zuströmbedingungen berücksichtigt werden. Daneben dienen die Ergebnisse der Messungen im Windkanal in jüngster Zeit ebenso zur Validierung der unterschiedlichen eingesetzten numerischen Simulationsmethoden.

Bei den meisten Schiffstypen ändert sich die Topologie und damit die Windangriffsfläche nur marginal während des Betriebes. Bei Containerschiffen hingegen ändert sich die Topologie häufig. Durch die Stauung der Container an Deck wird bei jedem Be- und Entladen die Topologie und damit die aerodynamische Umströmung des Überwasserschiffes beeinflusst. Die Verteilung der Container erfolgt dabei betrieblichen Regeln und der Einfluss auf die Aerodynamik wird nicht berücksichtigt. Der Einfluss der Verteilung der Containerbeladung an Deck auf die aerodynamischen Lasten wurde von Blendermann (1997) für zwei unterschiedlich große Containerschiffe untersucht. Auf Basis durchgeführter Windkanalversuche für unterschiedliche Windwinkel wird hierbei der Einfluss der Verteilung der Container an Deck quantifiziert. Ähnliche Experimente werden von Andersen (2013) für ein 9000 TEU-Containerschiff mit unterschiedlichen Beladungskonfigurationen durchgeführt. Je nach Verteilung der Container zeigt sich ein deutlicher Anstieg der aerodynamischen Längskräfte im Vergleich zur Konfiguration mit maximaler Containerbeladung an Deck.

Obwohl Windkanalmessungen zur Bewertung der aerodynamischen Eigenschaften von Schiffen weiterhin verbreitet sind, nimmt die Bedeutung numerischer Simulationen stetig zu. Die numerischen Methoden werden zur Simulation der aerodynamischen Umströmung unterschiedlicher Schiffstypen und Fragestellungen eingesetzt: Janssen et al. (2017) und Prpić-Oršić et al. (2020) untersuchen die Aerodynamik von Containerschiffen, Wnek und Guedes Soares (2015), Haddara und Guedes Soares (1999) und Koop et al. (2012) für verschiedene Typen von Tankschiffen, Forrest und Owen (2010); Forrest et al. (2016) und Mora (2014) studieren vereinfachte Modelle von Fregatten mit Schwerpunkt auf der Operation von Helikoptern im Nachlauf der Strömung hinter Aufbauten. Die Windlasten von Kreuzfahrtschiffen im Hafenumfeld werden von Ricci et al. (2020) analysiert und der Einsatz von Flettner-Rotoren als windbasierter zusätzlicher Antrieb für Handelsschiffe wird von Tillig und Ringsberg (2020) beschrieben. Um die Ergebnisse der numerischen Simulationen mit vorhandenen Windkanalmessungen vergleichen zu können, ist eine möglichst genaue Abbildung der Verhältnisse im Windkanal erforderlich (Koop et al., 2012; Wnek und Guedes Soares, 2015; Janssen et al., 2017). Zum einen betrifft dies die Versperrung im Windkanal, die je nach Größe des Modells im Verhältnis zum Querschnitt des Kanals einen signifikanten Einfluss auf die gemessenen aerodynamischen

Lasten haben kann, und typischerweise unterhalb von 5% liegen sollte. Zum anderen das Geschwindigkeitsprofil der Zuströmung. Das Geschwindigkeitsprofil im Windkanal wird von der Düsengeometrie und dem Vorlauf des Windkanals festgelegt und kann meist in Experimenten schlecht beeinflusst werden. Für spezielle Anwendungen wird das Grenzschichtprofil im Windkanal z.B. durch das Einbringen von Spires im Vorlauf der Strömung (Irwin, 1981) angepasst. Für die experimentelle Untersuchung von Segelyachten werden teilweise spezielle Windkanäle mit verdrilltem Geschwindigkeitsprofil (Flay, 1996) verwendet. Das reale Geschwindigkeitsprofil, welches sich durch die Zuströmung des Windes und des Eigenfahrtwindes zusammensetzt unterscheidet sich daher vom Windprofil im Windkanal.

Für die meisten Anwendungen sind die zeitlich gemittelten, integralen aerodynamischen Lasten von Interesse. Zur Bestimmung der Lasten werden daher hauptsächlich stationäre Simulationen mit RANS-basierter Turbulenzmodellierung angewendet (Koop et al., 2012; Wnek und Guedes Soares, 2015; Janssen et al., 2017; Prpić-Oršić et al., 2020; Ricci et al., 2020). Simulationen mit skalenauflösender Turbulenzmodellierung werden aufgrund des höheren Simulationsaufwandes seltener eingesetzt. Dies erfolgt üblicherweise, wenn neben den gemittelten Lasten auch die turbulenten Eigenschaften des Strömungsfeldes von Interesse sind, zum Beispiel bei der Beurteilung der sicheren Durchführbarkeit von Helikopteroperationen auf Schiffen (Forrest und Owen, 2010; Forrest et al., 2016; Mora, 2014). Dennoch wird der Einsatz von RANS-Verfahren vielfach kritisch gesehen.

Je nach Schiffsgometrie und Windwinkel der Zuströmung treten bei RANS-Simulation größere Ungenauigkeiten bei der Prognose der aerodynamischen Kräfte auf. In einigen Arbeiten (Koop et al., 2012; Ricci et al., 2020) wird auf das Potential der instationären Betrachtung und der Anwendung skalenauflösender Turbulenzmodellierung zur Verringerung der auftretenden Ungenauigkeiten hingewiesen, wobei gleichzeitig der deutlich höhere Berechnungsaufwand herausgestellt wird.

Eine Möglichkeit der datenbasierten Modellierung der aerodynamischen Koeffizienten der Schiffsumströmung wird von Haddara und Guedes Soares (1999) vorgestellt. Basierend auf den projizierten Flächen in transversaler und lateraler Richtung als Eingabewerte, werden die dimensionslosen Koeffizienten mit Hilfe eines kleinen Neuronalen Netzes modelliert. Hiermit wird der grobe Verlauf der Koeffizienten über den Zuströmwinkel vorhergesagt. Die Koeffizienten für das Training des Neuronalen Netzes basieren auf Windkanalversuchen. Prpić-Oršić et al. (2020) beschreiben die datenbasierte Modellierung der aerodynamischen Koeffizienten für unterschiedliche Beladungszuständen bei Containerschiffen. Die Kontur der Containerstapel und der Aufbauten wird mathematisch durch eine elliptische Fourier Beschreibung (engl. elliptic fourier descriptor) modelliert. Basierend auf dieser Darstellung der Containerverteilung, werden Generalisierte-Regression-Neuronale-Netze (engl. generalized regression neural networks,

GRNN) zum Modellieren der numerische mittels RANS-Modellierung bestimmten aerodynamischen Koeffizienten eingesetzt. Die datenbasierten Modelle basieren jedoch einzig auf den aerodynamischen Koeffizienten und zielen nicht auf die Rekonstruktion der Strömungsfelder ab.

1.1.2 Datenbasierte Modellierung komplexer Strömungsfelder

Zu den ersten Techniken, die zur Dimensionsreduktion und der datenbasierten Modellierung im Bereich der Strömungsmechanik eingesetzt wurden, zählt die Karhunen-Loève-Zerlegung (engl. proper orthogonal decomposition, POD). Die POD ist eine Technik der Modalanalyse und wurde zuerst von Lumley (1967) in der Strömungsmechanik eingeführt und später ebenfalls von Sirovich (1987) angewendet. Sie ist eng mit dem Begriff der Singulärwertzerlegung (SVD) verknüpft. Einen Überblick über weitere Methoden der Modalanalyse für strömungsmechanische Problemstellungen findet sich bei Taira et al. (2017). Mit Hilfe der POD-Methode lässt sich eine orthogonale Basis finden, durch welche sich eine möglichst kompakte und parametrisierbare Darstellung der zu Grunde liegenden Felddaten erstellen lässt.

Die POD-Methode wird für ein breites Spektrum unterschiedlicher Anwendungen in der Strömungsmechanik eingesetzt. Beim modellbasierten Ansatz wird mit Hilfe der Methode und Felddaten eine reduzierte Darstellung der zu Grunde liegenden Gleichungen, wie z.B. der Navier-Stokes-Gleichungen, gefunden. Häufig erfolgt die Modellierung aber rein datenbasiert auf sogenannten Snapshots des Strömungsfeldes, wie z.B. von Ly und Tran (2001) für eine Rayleigh-Bénard-Konvektion gezeigt wurde. Weitere Anwendungsfälle der POD Literatur sind der Entwurf und die Optimierung komplexer Systeme. Eine Übersicht zum Einsatz der POD für dynamische Systeme findet sich bei Benner et al. (2015). Dort wird auch die Verwendung der POD-Methode zur Entwicklung von Surrogatmodellen beschrieben. Um ein vollständiges Surrogatmodell zu erhalten, ist eine Regression der Koeffizienten des POD-Modells notwendig. Die Bestimmung der Koeffizienten der reduzierten POD-Basis wird auch als nicht-intrusive Modellierung bezeichnet. Für die Regression der Koeffizienten werden unterschiedliche Methoden verwendet: Walton et al. (2013) verwenden radiale Basisfunktionen für die Regression und wenden die Modellierung für die Umströmung eines oszillierenden Flügels an. Ein System zur Unterstützung von Entscheidungen für den Betrieb von Luftfahrzeugen wird von Mainini und Willcox (2015) beschrieben. Für die Regression innerhalb des Surrogatmodells werden sog. „self organising maps“ angewendet. Verschiedene Alternativen der Koeffizienten-Regression werden von Swischuk et al. (2019) beschrieben und vergleichend dargestellt. Dazu werden die Polynomregression, k-nearest neighbor Ansätze, Entscheidungsbäume und Neuronale Netze verwendet. Basierend auf der POD-Methode und der unterschiedlichen Regressionstechniken wird ein Ersatzmodell für die Profilmströmung bei unterschiedlichen Anstellwinkeln und Mach-Zahlen entwickelt, wobei die Unterschiede zwischen den alternativen Regressionsme-

thoden gering sind.

Für die POD-basierte Dimensionsreduktion lässt sich die reduzierte Darstellung der Datenfelder aufgrund der Linearität der Methode mit geringem Aufwand berechnen. Gleichzeitig schränkt die Linearität das Potential der Dimensionsreduktion für nichtlineare Phänomene, z.B. komplexe Strömungsfelder, ein. Für nichtlineare Problemstellungen werden deswegen vermehrt Methoden des Maschinellen Lernens (ML) angewendet. In der Strömungsmechanik werden die Methoden bereits für eine Vielzahl von Problemstellungen eingesetzt. Genetische Algorithmen in Kombination mit künstlichen Neuronalen Netzen werden beispielsweise für die Entwurfsoptimierung von Kompressorschaukeln eingesetzt (Ghalandari et al., 2019). Ebenfalls auf Neuronalen Netzen basierende Autoencoder (AE) werden ferner zur nichtlinearen Extraktion von Merkmalen dynamischer Systeme verwendet. Insbesondere Autoencoder werden für unterschiedliche Anwendungsfälle innerhalb der Strömungsmechanik vermehrt eingesetzt (Brunton et al., 2020). Durch Anwendung einer linearen Aktivierungsfunktion und nur einer versteckten Schicht zwischen der Eingabe- und Ausgabeschicht kann gezeigt werden, dass die Lösung des linearen Autoencoders mit der POD-Methode übereinstimmt (Baldi und Hornik, 1989). Der Einsatz nichtlinearer Aktivierungsfunktionen und komplexer Netzwerkstrukturen in Autoencodern ermöglicht eine deutlich kompaktere bzw. genauere Darstellung der Datenfelder im Vergleich zur POD-Methode. Die Überlegenheit eines Autoencoder gegenüber der POD zur Dimensionsreduktion wird von Milano und Koumoutsakos (2002) für eine wandnahe turbulente Strömung eindrucksvoll demonstriert.

Bei einem vollständig verbundenem Neuronalem Netz wird die räumliche Korrelation benachbarter Datenpunkte, wie sie in einem dreidimensionalen Strömungsfeld vorliegt, nicht gut berücksichtigt. Daher ist die Verwendung Faltungs basierter Neuronaler Netze (engl. convolutional neural network, CNN) für räumlich strukturierte Daten sehr verbreitet und CNN-Autoencoder (CAE) werden häufig zur Dimensionsreduktion von Strömungsfeldern eingesetzt. Für die Umströmung eines Zylinders vergleicht Agostini (2020) einen CAE- und eine POD-basierte Variante zur Darstellung des Strömungsfeldes. Basierend auf der dimensionsreduzierten Darstellung der Strömungsfelder wird ein dynamisches Modell und die Rekonstruktion des Strömungsfeldes aus unvollständigen Eingabedaten, wie z.B. Sensoren, vorgestellt. Murata et al. (2020) vergleichen die Moden der Datenbasis des Strömungsfeldes für POD- und CAE-basierte Varianten, wobei gezeigt wird, dass sich basierend auf der CAE-Darstellung kompaktere Modelle bilden lassen.

Champion et al. (2019) verwenden Autoencoder zum Transformieren der Daten in ein geeignetes Koordinatensystem, in welchem eine möglichst kompakte Darstellung der Dynamik in Form von Gleichungen gefunden werden soll. Dies wird insbesondere durch das gleichzeitige Lernen des Autoencoders und der Terme der Gleichungen zur Beschreibung der Dynamik erreicht.

Für die zweidimensionale Umströmung variabler Geometrien stumpfer Körper beschreiben Hasegawa et al. (2020) eine Methode basierend auf einem CAE und einem LSTM (engl. long short-term memory) zur Modellierung der instationären Strömungsfelder. Die variablen Geometrien der umströmten stumpfen Körper werden durch trigonometrische Funktionen beschrieben. Die Besonderheit der Arbeit ist, dass für variable Geometrien eine Modellierung des zeitlichen Verlaufs der Strömungsfelder erfolgt.

1.2 Ziele der Arbeit

Das Ziel des ersten Teils der Arbeit ist die numerische Simulation der aerodynamischen Umströmung von Überwasserschiffen mit möglichst genauer Vorhersage der zeitlich gemittelten Strömungsfelder bei massiver Ablösung und der aerodynamischen Lasten. Die Strömungsfelder dienen als Datengrundlage für den zweiten Teil der Arbeit. Ziel ist es hierbei datenbasierte Surrogatmodelle zu entwickeln, welche die effiziente und genaue Vorhersage der aerodynamischen Lasten induzierenden Felder für unterschiedliche Betriebs- und Umweltparameter ermöglichen. Eine hohe Genauigkeit und Zuverlässigkeit der Surrogatmodelle setzt eine qualitativ hochwertige Datenbasis voraus. Die Methoden können anschließend in Entscheidungshilfesysteme an Bord integriert werden.

Zur Erstellung der Datenbasis der Ersatzmodelle wird eine große Anzahl an Strömungsfeldern mit unterschiedlichen Systemparametern benötigt. Durch die hohe Anzahl erforderlicher Simulationen müssen diese mit möglichst geringem Simulationsaufwand, bei gleichzeitig hoher Qualität, durchgeführt werden. Basierend auf dem im vorherigen Abschnitt dargestellten aktuellen Stand der Forschung werden im Rahmen der Arbeit folgende Ziele für die numerische Simulation der aerodynamischen Umströmung von Überwasserschiffen festgelegt:

- Mittels numerischer Simulationen soll der Einfluss der Verteilung von Containern an Deck auf die Umströmung analysiert und quantifiziert werden. Im Vordergrund stehen aerodynamische Lasten für unterschiedliche Beladungszustände, die mit Windkanalversuchen verglichen werden.
- Für die Simulation der Umströmung von Überwasserschiffen soll der Einfluss unterschiedlicher Turbulenzmodelle auf die Genauigkeit der Simulationsergebnisse analysiert werden. Die Form der Überwasserschiffe ist geprägt von stumpfen Körpern. An den Kanten der Geometrie löst die Strömung stark ab und bildet große, offene Wirbelstrukturen. Daher kann die Genauigkeit der Simulationsergebnisse durch skalenauflösende Turbulenzmodellierung verbessert werden. Die Unterschiede im Vergleich zur klassischen RANS-basierten Modellierung sollen dargestellt werden.

- Der Anteil der turbulenten Effekte, welcher räumlich direkt aufgelöst wird, wird durch die Auflösung des Gitters festgelegt. Gleichzeitig steigt mit verfeinertem Gitter der Simulationsaufwand stark an. Daher soll der Einfluss der Gitterauflösung auf die Genauigkeit der Ergebnisse untersucht werden. Ziel ist eine möglichst hohe Qualität der Ergebnisse bei möglichst geringem Simulationsaufwand.

Ziel des zweiten Teils ist es Surrogatmodelle für die zeitlich gemittelte Strömung zu entwickeln. Für diesen Teil der Arbeit ergeben sich folgende Teilziele:

- Surrogatmodellierung der zeitlich gemittelten, simulierten dreidimensionalen Druckfelder, der Simulationsergebnisse. Auf Basis der Druckfelder werden die aus dem Druck resultierenden Lasten bestimmt.
- Unterschiedliche bereits für fluiddynamische Anwendungen eingesetzte datenbasierte Modellierungstechniken sollen für den vorliegenden Anwendungsfall angepasst werden. Bisher werden die Methoden vorwiegend zur Modellierung einfacher Strömungsprobleme bei kleinen Reynoldszahlen ($Re = \mathcal{O}(10^4)$) eingesetzt. Bei der hier vorliegenden Problemstellung handelt es sich um die Umströmung von Überwasserschiffen im Großausführungsmaßstab bei sehr großen Reynoldszahlen ($Re = \mathcal{O}(10^8)$).
- Zusätzlich werden unterschiedliche Topologien der Geometrie durch unterschiedliche Containerbeladungszustände innerhalb der Modellierung berücksichtigt.
- Für die Erstellung der Ersatzmodelle werden unterschiedliche Methoden der Dimensionsreduktion und unterschiedliche Regressionstechniken verglichen. Ebenfalls wird der Einfluss der unterschiedlichen Hyperparameter für die unterschiedlichen Modellvarianten aufgezeigt.

1.3 Gliederung der Arbeit

Die beiden Hauptbestandteile der Arbeit, die numerischen bzw. experimentellen Untersuchungen der aerodynamischen Schiffsumströmung sowie die datenbasierte Modellierung finden sich in der Gliederung der Arbeit wieder.

Im zweiten Kapitel werden die mathematischen und physikalischen Grundlagen der Strömungssimulation und der Turbulenzmodellierung erläutert. Im darauffolgenden Kapitel 3 werden die durchgeführten Windkanalversuche beschrieben. Diese dienen als Grundlage der Validierung der Methoden zur numerischen Simulation der aerodynamischen Umströmung in Kapitel 4.

Der zweite Teil der Arbeit beginnt mit einem Überblick der Theorie der datenbasierten Modellierung sowie den Methoden des Maschinellen Lernens. Dieser dient als Grundlage des Kapitels

6, welches die Strategie und das Vorgehen bei der datenbasierten Modellierung der aerodynamischen Schiffsumströmungen beschreibt. Die Ergebnisse der unterschiedlichen Modellvarianten werden schließlich in Kapitel 7 ausgeführt und analysiert. Abschließend erfolgt im letzten Kapitel eine Zusammenfassung der Arbeit und der erzielten Ergebnisse.

2 Mathematische und physikalische Grundlagen

Die aerodynamische Umströmung von Überwasserschiffsgeometrien wird im Rahmen dieser Arbeit, neben experimentellen Messungen, auf Basis numerischer Simulationen betrachtet. Die Grundlage dazu bildet die numerische Betrachtung der Navier-Stokes-Gleichungen. Dabei wird für die mathematische Beschreibung der Strömung das Fluid als Kontinuum betrachtet. In der Kontinuumsmechanik erfolgt die Beschreibung der Fluideigenschaften über Eulersche Bilanzgleichungen, welche im Folgenden näher erläutert werden. Für eine ausführliche Beschreibung der numerischen Methoden wird auf Ferziger und Perić (2008) verwiesen. Da die aerodynamische Schiffsumströmung stark von Turbulenz geprägt ist, wird im zweiten Teil dieses Kapitels auf die Eigenschaften sowie die Modellierung turbulenter Effekte eingegangen.

Vektoren und Tensoren beziehen sich ausnahmslos auf kartesische Koordinaten. Für die Beschreibung der Gleichungen wird die Einstein'sche Summenkonvention angewendet, treten in einem Term Koordinatenindizes doppelt auf, so wird über diese summiert. Zur Beschreibung der Einheitsmatrix wird das Kronecker-Delta δ_{ij} verwendet.

2.1 Transportgleichungen

Die Transportgleichung beschreibt den Transport einer physikalischen Eigenschaft durch äußere Einwirkung auf das Fluid. In der Strömungsmechanik wird dazu meist die (raumfeste) Eulersche Betrachtungsweise gewählt. Die Beschreibung erfolgt in kartesischen Koordinaten. Es wird von einem festen Volumen V ausgegangen, dessen Oberflächen S sich nicht bewegen. Der Transport einer beliebigen Eigenschaft Φ des Fluidfeldes wird durch die generische Transportgleichung in der Integralform beschrieben

$$\int_V \frac{\partial(\rho\Phi)}{\partial t} dV + \oint_S \rho\Phi u_j dS_j = \oint_S \left(\Gamma \frac{\partial\Phi}{\partial x_j} \right) dS_j + \int_V q_\Phi dV. \quad (2.1)$$

Hierin bezeichnet der erste Term die zeitliche Änderung der physikalischen Eigenschaft und der zweite Term die Konvektion über die geschlossene Oberfläche S . Der erste Term der rechten Seite der Gleichung beschreibt die Diffusion durch die geschlossene Oberfläche S und der zweite

Term ist der Quellterm.

In der Transportgleichung bezeichnet t die Zeit, ρ die Dichte, u_j die kartesischen Komponenten des Geschwindigkeitsvektors, S_j die kartesischen Komponenten des Oberflächenvektors, Γ die Diffusionskonstante und q_Φ den volumenspezifischen Quellterm.

2.1.1 Massenerhaltung

Da die Masse in der Strömung weder erzeugt noch vernichtet werden kann, muss für die zeitliche Änderung der Masse in quellfreien Feldern ($q_\Phi = 0$) gelten $\frac{dm}{dt} = 0$. Wird in die generische Transportgleichung (2.1) für die betrachtete Eigenschaft $\Phi = 1$ gesetzt, folgt die Gleichung für die Massenerhaltung

$$\int_V \frac{\partial \rho}{\partial t} dV + \oint_S \rho u_j dS_j = 0, \quad (2.2)$$

welche auch als Kontinuitätsgleichung bezeichnet wird. Für die hier betrachteten inkompressiblen Strömungen ist die Dichte konstant und die Gleichung vereinfacht sich zur Erhaltung des Volumens

$$\oint_S u_j dS_j = 0. \quad (2.3)$$

2.1.2 Impulserhaltung

Das zweite Newtonsche Gesetz beschreibt unter anderem den translatorischen Impuls: Die zeitliche Änderung der Geschwindigkeit ist gleich der Summe der äußeren Kräfte $\frac{dm u_i}{dt} = \sum f_i$. Für $\Phi = u_i$ folgt aus (2.1) die Gleichung der Impulserhaltung

$$\int_V \frac{\partial(\rho u_i)}{\partial t} dV + \oint_S \rho u_i u_j dS_j = \oint_S T_{ij} dS_j + \int_V f_i dV. \quad (2.4)$$

Die auf das Fluid wirkende Kräfte setzen sich aus Oberflächen- und Volumenkräften zusammen. Die Oberflächenkräfte werden durch den Spannungstensor T_{ij} dargestellt. Die auf das Fluid wirkenden Volumenkräfte f_i resultieren z.B. aus dem Gravitationsfeld der Erde (z.B. $f_i = -g\delta_{i3}$). Für die hier ausschließlich betrachteten Newtonsche Fluide gilt für den Spannungstensor die Annahme

$$T_{ij} = - \left(p + \frac{2}{3} \mu \frac{\partial u_m}{\partial x_m} \right) \delta_{ij} + \mu \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right). \quad (2.5)$$

In Gleichung (2.5) wird die dynamische Viskosität mit μ bezeichnet und der statische Druck mit p . Aufgrund der Kontinuitätsgleichung verschwindet die Divergenz im ersten Term der rechten Seite für inkompressible Strömungen. Der Spannungstensor setzt sich somit aus dem in negativer Normalenrichtung wirkenden statischen Druck und den viskosen Schubspannungen zusammen

$$T_{ij} = -p\delta_{ij} + \tau_{ij} = -p\delta_{ij} + \mu \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right). \quad (2.6)$$

Die gezeigten Gleichungen der Massen- und Impulserhaltung werden zusammen als Navier-Stokes-Gleichungen für inkompressible Fluide bezeichnet.

2.2 Finite-Volumen-Methode

Für die im vorherigen Abschnitt eingeführten Navier-Stokes-Gleichungen (2.3) und (2.4) lassen sich nur für sehr einfache Problemstellungen direkte analytische Lösungen finden. Für die Betrachtung realer Problemstellungen der Strömungsmechanik ist daher eine numerische Behandlung der gekoppelten Gleichungen erforderlich. Dazu wird eine zeitliche und räumliche Diskretisierung angewendet, wobei die räumliche Diskretisierung mit Finiten-Volumen erfolgt. Das Rechengebiet wird dabei in eine endliche Anzahl von Kontrollvolumen ΔV unterteilt. Um komplexe Rechengebiete zu diskretisieren, werden Polyederelemente als Kontrollvolumen verwendet. Durch die beliebige Anzahl an Grenzflächen der Polyederelemente und deren Anordnung sind die Gitter unstrukturiert. Die nichtversetzte Speicherung der Variablen erfolgt dabei in den Zellzentren, wodurch eine Genauigkeit zweiter Ordnung bei Anwendung der Mittelpunkregel zur Approximation der Volumenintegrale erreicht wird. In Abbildung 2.1 sind ein beliebiges Kontrollvolumen ΔV_P sowie ein benachbartes Kontrollvolumen ΔV_N skizziert. Die beiden Kontrollvolumen haben die gemeinsame Zellgrenzfläche F . Durch die beliebige Form der Kontrollvolumen geht der Verbindungsvektor d_N nicht unbedingt durch den Mittelpunkt der Grenzfläche.

Für die Approximation der in den Navier-Stokes-Gleichungen auftretenden Terme werden bei der Finite-Volumen Approximation die jeweiligen Variablenwerte und deren Gradienten in den Zellgrenzflächenzentren benötigt. Diese werden durch Interpolation der in den Zellzentren gespeicherten Variablenwerte bestimmt. Da die Gitter unstrukturiert sind, sind nur die direkt angrenzenden Nachbarzellen bekannt. Daher können für die Interpolation der Variablenwerte in den Zellgrenzflächen nur die Werte der direkten Nachbarzellen verwendet werden und die Interpolation muss auf einer kompakten Darstellung basieren. In den folgenden Abschnitten werden die Approximation der Volumen- und Oberflächenintegrale, der Zeitableitung und der konvektiven und diffusiven Flüsse sowie die Bestimmung der Gradientenfelder für unstrukturierte Gitter erläutert.

2.2.1 Approximation der Volumen- und Flächenintegrale

Die Approximation der Volumenintegrale erfolgt mit der Mittelpunktsregel. Die Approximation ist von zweiter Ordnung genau. Für das Integral über das Volumen ΔV_P folgt mit dem Wert Φ_P im Zellzentrum

$$\int_{V_P} \Phi dV \approx \Phi_P \Delta V_P. \quad (2.7)$$




Abbildung 2.1: Darstellung des Kontrollvolumens P und des benachbarten Kontrollvolumens N . Der Verbindungsvektor der beiden Zellzentren ist d_F . Der Flächenschwerpunkt der Grenzfläche ist mit F bezeichnet und der lotrechte Fußpunkt des Flächenschwerpunktes auf dem Verbindungsvektor d_F mit F' . Der Flächenvektor der Grenzfläche ist ΔS_F .

Das Oberflächenintegral eines Kontrollvolumens lässt sich als Summe der Integrale über die Grenzflächen des Volumens darstellen. Die Integrale über die einzelnen Grenzflächen werden wiederum mit Hilfe der Mittelpunktsregel approximiert

$$\oint_S \Phi dS_j \approx \sum_F \Phi_F \cdot \Delta S_{j,F}. \quad (2.8)$$

Hierbei wird der Variablenwert im Flächenmittelpunkt der Grenzfläche mit Φ_F bezeichnet, der nach außen gerichtete Flächenvektor der Grenzfläche mit $\Delta S_{j,F}$.

2.2.2 Zeitliche Ableitung

Bei der Zeit handelt es sich um eine parabolische Größe. Daher wird die zeitliche Ableitung mit einer rückwärts-gerichteten impliziten finiten Differenzenformel approximiert. Die feste Zeitschrittweite wird mit Δt bezeichnet, die Variablenwerte der vorherigen Zeitebenen mit Φ^{n-1} . Bei Berücksichtigen einer vorangegangenen Zeitebene folgt eine von erster Ordnung genaue Approximation

$$\frac{\partial \Phi}{\partial t} \approx \frac{\Phi^n - \Phi^{n-1}}{\Delta t}. \quad (2.9)$$

Das Speichern einer zusätzlichen Zeitebene Φ^{n-2} ermöglicht eine von zweiter Ordnung genaue Zeitapproximation

$$\frac{\partial \Phi}{\partial t} \approx \frac{3\Phi^n - 4\Phi^{n-1} + \Phi^{n-2}}{2\Delta t}. \quad (2.10)$$

2.2.3 Approximation von Gradientenfeldern

Bei der Approximation basierend auf einer räumlichen Diskretisierung mit unstrukturierten Gittern werden die Gradientenfelder $\frac{\partial \Phi}{\partial x_j}$ der Variablen Φ in den Zellzentren benötigt. Im Allgemeinen werden für die Bestimmung der Gradientenfelder hauptsächlich zwei Verfahren angewendet: das Gauß-Theorem oder die Methode der kleinsten Fehlerquadrate. Beide Verfahren werden im Folgenden vorgestellt.

Gauß-Theorem

Mittels des Gaußschen Integralsatzes werden die Volumenintegrale in Oberflächenintegrale überführt

$$\int_{\Delta V} \frac{\partial \Phi}{\partial x_j} dV = \oint_S \Phi dS_j. \quad (2.11)$$

Mit den Variablenwerten der an das Kontrollvolumen angrenzenden Flächen Φ_F lässt sich dann der Gradient im Zellzentrum von 2. Ordnung genau bestimmen

$$\left(\frac{\partial \Phi}{\partial x_j} \right)_P \approx \frac{1}{\Delta V} \sum_F \Phi_F \Delta S_{j,F}. \quad (2.12)$$

Für die Methode werden die Variablenwerte in den Grenzflächen $S_{j,F}$ benötigt, für deren Approximation wiederum die erst noch zu bestimmenden Gradienten benötigt werden. Daher ist bei Anwendung des Gauß-Theorems zur Bestimmung der Gradienten ein iteratives Verfahren notwendig.

Methode der kleinsten Fehlerquadrate

Für die Bestimmung der Gradienten im Zellzentrum P können alternativ die Variablenwerte in den Zellzentren der benachbarten Volumen Φ_{N_k} herangezogen werden. Mit Hilfe der Taylorreihe lässt sich folgende von zweiter Ordnung genaue Approximation finden

$$\Phi_{N_k} \approx \Phi_P + \left(\frac{\partial \Phi}{\partial x_j} \right)_P d_{j,N_k}, \quad (2.13)$$

wobei der kartesische Abstand der Zellzentren mit d_{j,N_k} bezeichnet wird. Dabei ist die Anzahl der Nachbarzellen k stets größer als die Anzahl der Komponenten des Gradienten j , es handelt sich daher um ein überbestimmtes System. Durch die Anwendung der Methode der kleinsten Fehlerquadrate kann eine eindeutige Darstellung des approximierten Gradienten gefunden werden. Um eine problemlose Anwendung der Methode auch für Kontrollvolumen mit stark verzerrter Gestalt sicherzustellen, werden die einzelnen Beiträge der Nachbarzellen mit dem

reziproken Abstand der jeweils betrachteten Zellzentren $\frac{1}{d_{N_k}}$ gewichtet

$$\frac{1}{d_{N_k}} [\Phi_{N_k} - \Phi_P] \approx \frac{1}{d_{N_k}} D_{kj} \left(\frac{\partial \Phi}{\partial x_j} \right)_P \quad \text{mit } D_{kj} = d_{j,N_k}. \quad (2.14)$$

Dieses Vorgehen wird auch als gewichtete Methode der kleinsten Fehlerquadrate bezeichnet (Rung, 2008). Um ein quadratisches Gleichungssystem zu erhalten, wird eine algebraische Manipulation durchgeführt

$$\frac{1}{d_{N_k}} D_{mk}^T [\Phi_{N_k} - \Phi_P] \approx G_{mj} \left(\frac{\partial \Phi}{\partial x_j} \right)_P \quad \text{mit } G_{mj} = \frac{1}{d_{N_k}} D_{mk}^T D_{kj}, \quad (2.15)$$

womit der Gradient im Zellzentrum P wie folgt bestimmt wird

$$\left(\frac{\partial \Phi}{\partial x_j} \right)_P \approx \frac{1}{d_{N_k}} G_{jm}^{-1} D_{mk}^T [\Phi_{N_k} - \Phi_P]. \quad (2.16)$$

2.2.4 Rekonstruktion der Variablenwerte in den Zellgrenzflächen

In den Termen des konvektiven und diffusiven Transportes (vgl. Gleichung (2.1)) treten Oberflächenintegrale auf. Für die numerische Approximation der Oberflächenintegrale wird erneut die Mittelpunktsregel angewendet

$$\oint_S \rho \Phi u_j dS_j \approx \sum_F \Phi_F [\rho u_j \Delta S_j]_F = \sum_F \Phi_F \dot{m}_F. \quad (2.17)$$

Die Approximation des Integrals über eine Zellgrenzfläche F wird durch das Produkt des Variablenwertes in der Mitte der Zellgrenzfläche Φ_F und dem Fluss \dot{m}_F durch die Zellgrenzfläche gebildet. Da die Werte der Variablen nicht in den Grenzflächen, sondern im Mittelpunkt der Kontrollvolumen gespeichert werden, müssen die Werte in den Zellgrenzflächen rekonstruiert werden. Die einfachste Variante zur Rekonstruktion der Variablenwerte in einer Grenzfläche stellt die lineare Interpolation der in den Zellzentren gespeicherten Variablenwerte der beiden angrenzenden Nachbarzellen Φ_P und Φ_N dar. Die Interpolation für ein unregelmäßiges und unstrukturiertes Gitter ist in Abbildung 2.1 dargestellt. Wenn der Mittelpunkt der Zellgrenzfläche F nicht auf der Verbindungsgeraden der beiden Zellzentren liegt, wird durch die Interpolation der Wert der Variablen nicht im Punkt F , sondern im lotrechten Fußpunkt F' berechnet. Um die zweite Ordnung des Interpolationsverfahrens zu erhalten, muss eine zusätzliche Extrapolation auf Basis des Gradienten am Ort F' durchgeführt werden

$$\Phi_F \approx (1 - \lambda_F) \Phi_P + \lambda_F \Phi_N + (x_{j,F} - x_{j,F'}) \left(\frac{\partial \Phi}{\partial x_j} \right)_{F'}. \quad (2.18)$$

Der Interpolationsfaktor λ_F lässt sich dabei über folgenden geometrischen Zusammenhang bestimmen

$$\lambda_F = \frac{\Delta S_{j,F}(x_{j,F} - x_{j,F'})}{[\Delta S_j d_j]_F}. \quad (2.19)$$

Der Gradient wird entsprechend den Variablenwerten auf Basis der Gradienten in den beiden benachbarten Zellzentren interpoliert

$$\left(\frac{\partial \Phi}{\partial x_j}\right)_{F'} = (1 - \lambda_F) \left(\frac{\partial \Phi}{\partial x_j}\right)_P + \lambda_F \left(\frac{\partial \Phi}{\partial x_j}\right)_N. \quad (2.20)$$

Die dargestellte lineare Interpolation wird auch als Zentraldifferenzen-Approximation (engl. central differencing scheme, CDS) bezeichnet. Durch die Gradienten-basierte Korrektur bleibt die Kompaktheit des Verfahrens erhalten und es werden nur die Variablenwerte der unmittelbaren Nachbarpunkten benötigt. Das Verfahren lässt sich dadurch auch direkt für unstrukturierte Gitter anwenden.

Konvektiver Transport

Bei dem durch Gleichung (2.17) beschriebenen konvektiven Transport handelt es sich um eine physikalisch gerichtete Größe. Dies muss bei der Interpolation der Variablenwerte berücksichtigt werden und die zuvor gezeigten Zentraldifferenzen sind daher zur Approximation des konvektiven Terms ungeeignet. Für die Bestimmung der Konvektion sollten für eine physikalische konsistente Interpolation nur stromauf liegende Variablenwerte einbezogen werden. Dazu wird der Fluss durch die Zellgrenzfläche \dot{m}_F verwendet. Der Fluss wird mittels der Dichte ρ , der Geschwindigkeit u_j und des Flächenvektors ΔS_j bestimmt $\dot{m}_F = [\rho u_j \Delta S_j]_F$. Eine einfache Methode dazu stellt die Aufwind-Interpolation (engl. upwind differencing scheme, UDS) dar

$$\Phi_F \dot{m}_F \approx \Phi_P \cdot \max\{\dot{m}_F, 0\} - \Phi_N \cdot \max\{-\dot{m}_F, 0\}. \quad (2.21)$$

Dabei wird in Abhängigkeit der Orientierung des Flusses nur der Variablenwert im stromauf liegenden Nachbarpunkt berücksichtigt. Diese Interpolation ist von erster Ordnung genau. Um Terme höherer Ordnung für die Approximation zu berücksichtigen, wird der sogenannte Ansatz der verzögerten Korrektur (engl. deferred correction) verwendet

$$\Phi_F \approx \underbrace{\Phi_F^{UDS}}_{\text{implizit}} + \underbrace{(\Phi_F^{HO} - \Phi_F^{UDS})}_{\text{explizit}}. \quad (2.22)$$

Dabei wird neben dem Aufwind-Anteil Φ_F^{UDS} , welcher implizit behandelt wird, der Beitrag der Terme höherer Ordnung Φ_F^{HO} explizit in die Lösung eingebracht. Dies ermöglicht zum einen die einfache und flexible Implementierung der Terme höherer Ordnung, zum anderen wird durch

die ausschließliche Berücksichtigung des impliziten Anteils in der Koeffizientenmatrix die Diagonaldominanz stabilitätsfördernd gestärkt.

Die verschiedenen Approximationen höherer Ordnung lassen sich in einem einheitlichen Schema zusammenfassen. Für die Terme höherer Ordnung wird wiederum die verzögerte Korrektur angewendet. Das Schema wird auch als κ -Schema bezeichnet (Rung, 2008)

$$\Phi_F \approx \Phi_F^{UDS} + \frac{1}{2} \left[\kappa(\Phi_N - \Phi_P) - (1 - \kappa)d_{j,F} \left(\frac{\partial \Phi}{\partial x_j} \right)_P \right], \quad \kappa \in [-1,1]. \quad (2.23)$$

In Abhängigkeit des Faktors κ werden unterschiedliche Interpolationschemas angewendet. Für $\kappa = 0,5$ wird die QUICK-Approximation (engl. quadratic upstream interpolation of convective kinematics) (Leonard, 1979) herangezogen, die formal von zweiter Ordnung genau ist. Für $\kappa = 1,0$ wiederum wird eine Approximation basierend auf Zentraldifferenzen angewendet. Für die entsprechenden Zwischenwerte kann kontinuierlich zwischen beiden Verfahren überblendet werden.

Diffusiver Transport

Der Term des diffusiven Transportes in Gleichung (2.1) lässt sich ebenfalls durch die Summe über die Zellgrenzflächen darstellen und mit Hilfe der Mittelpunktsregel zu

$$\oint_S \left(\Gamma \frac{\partial \Phi}{\partial x_j} \right) dS_j \approx \sum_F \left[\Gamma \frac{\partial \Phi}{\partial x_j} \Delta S_j \right]_F \quad (2.24)$$

approximieren. Für die Auswertung des Terms wird der Wert des Gradienten in den Zellgrenzflächen benötigt. Da es sich bei der Diffusion um eine physikalisch ungerichtete Größe handelt, müssen bei der Approximation des Gradienten alle Raumrichtungen gleichermaßen Berücksichtigung finden. Die einfachste und kompakte Methode dazu stellen die Zentraldifferenzen dar, wobei es sich um eine Approximation von zweiter Ordnung handelt. Unter Berücksichtigung des geometrischen Zusammenhangs $\Delta S_{j,F} = \Delta A \cdot n_{j,F}$ lässt sich der Gradient zur einfacheren numerischen Implementierung mit Diagonaldominanz und Monotonie erhaltender Formeln in zwei Anteile

$$\left(\Gamma \Delta A \frac{\partial \Phi}{\partial n} \right)_F \approx \underbrace{(\Gamma \Delta A)_F \frac{\Phi_N - \Phi_P}{d_F}}_{\text{implizit}} + \underbrace{(\Gamma \Delta A)_F \left(\frac{\partial \Phi}{\partial x_j} \right)_F \left(n_{j,F} - \frac{d_{j,F}}{d_F} \right)}_{\text{explizit}} \quad (2.25)$$

aufteilen. Der erste Summand der rechten Seite des Terms beschreibt den Gradienten in Richtung des Verbindungsvektors d_j . Durch den zweiten Summanden wird der Unterschied der Orientierung des Verbindungsvektor d_j und der Normalenrichtung der Zellgrenzfläche $n_{F,j}$ für nichtorthogonale Gitter korrigiert. Dieser Korrekturanteil wird auf Basis der verzögerten Kor-

rektur im numerischen Verfahren explizit berücksichtigt.

2.2.5 Randbedingungen

An den Rändern des Lösungsgebietes sind die Flüsse durch die Zellgrenzflächen unbekannt und müssen daher gesondert betrachtet werden. Die Flüsse müssen entweder direkt vorgeben oder aus den Werten innerhalb des Lösungsgebietes extrapoliert werden. Bei der Dirichlet-Randbedingung werden die Werte für die Variable Φ am Rand vorgegeben. Bei der Neumann-Randbedingung hingegen werden die Werte des Gradienten $\frac{\partial\Phi}{\partial n}$ in Normalenrichtung vorgegeben. Darüber hinaus treten weitere Typen von Randbedingungen auf.

Am Einlassrand werden die Geschwindigkeitskomponenten und die Turbulenzgrößen als Dirichlet-Bedingung vorgegeben. Der Druck hingegen wird als Neumann-Bedingung aufgebracht. Eine Möglichkeit für den Ausströmrand ist die Annahme, dass die Ableitung aller Größen verschwindet. An reibungsfreien Wänden erfolgt eine getrennte Betrachtung der Geschwindigkeitskomponenten in Tangential- und Normalenrichtung. Alle Gradienten verschwinden in Normalenrichtung, nur für die Geschwindigkeit in Wandnormalenrichtung wird die Dirichlet-Bedingungen vorgegeben, sodass der Fluss durch die Wand gleich null ist. An reibungsbehafteten Wänden wird die Wandschubspannung für die Geschwindigkeit spezifiziert. Der Druck folgt aus einer Neumann-Randbedingung. Um eine realistische Modellierung der Turbulenz in Wandnähe zu erreichen, folgen die turbulenten Größen aus der Anwendung unterschiedlicher Wandturbulenzmodelle. Für weiter Details der Wandturbulenzmodelle wird auf Pope (2000) und für eine detaillierte Beschreibung der unterschiedlichen Randbedingungen auf Ferziger und Perić (2008) verwiesen.

2.2.6 Numerische Implementierung

Der Finite-Volumen-Löser FreSCo⁺ (Rung et al., 2009) löst die diskretisierten (Reynoldsgemittelten)-Navier-Stokes-Gleichungen und zusätzlich die für die Turbulenzmodellierung benötigten Transportgleichungen. Das Verfahren ist implizit und von zweiter Ordnung genau. Die Speicherung der Variablenwerte erfolgt im Zentrum der Kontrollvolumen. Zur Diskretisierung des Raums können unstrukturierte Gitter mit beliebigen Polyedern eingesetzt werden. Für die Modellierung der Turbulenz stehen verschiedene Reynoldsgemittelte Modelle (RANS), ein Grobstrukturmodell (LES) sowie hybride RANS/LES-Modelle zur Verfügung. Durch die räumliche Aufteilung des Rechengebietes basierend auf einem Graphen-Ansatz (Karypsis und Kumar, 1995) wird der Algorithmus parallelisiert. Zur Kommunikation zwischen den einzelnen Prozessen wird das MPI-Protokoll (engl. message passing interface) eingesetzt.

Die unterschiedlichen Transportgleichungen werden sequenziell gelöst. Die Kopplung des

Druckfeldes und des Geschwindigkeitsfeldes erfolgt über einen SIMPLE-Algorithmus, vgl. Ferziger und Perić (2008). Die Geschwindigkeitsfelder werden zunächst basierend auf einem geschätzten Druckfeld bestimmt. Danach wird die Korrektur des Druckfeldes berechnet, welche zur Korrektur der Massenerhaltung erforderlich ist. Im darauf folgenden Schritt werden die Geschwindigkeiten und der Druck entsprechend korrigiert. Anschließend werden die weiteren Transportgleichungen gelöst. Aufgrund der Nichtlinearitäten und der Kopplung der zu lösenden Gleichungen ist ein iteratives Vorgehen beim Lösen der Gleichungen erforderlich. Während der inneren Iterationen werden die linearisierten Gleichungen iterativ gelöst. Durch das Ausführen der äußeren Iterationen werden die gekoppelten Gleichungen auskonvergiert. Bei instationären Problemstellungen wird eine vorgegebene Anzahl an Zeitschritten gelöst.

2.3 Turbulente Strömungen

Turbulente Strömungen zeichnen sich durch starke räumliche und zeitliche Fluktuationen der Strömungsgrößen aus. Der turbulente Austausch findet dabei vor allem in Scherströmungen quer zur Hauptströmungsrichtung statt, weswegen turbulente Strömungen immer instationär und dreidimensional sind, auch wenn die zeitlich gemittelte Strömung zweidimensional ist. Es bilden sich dabei überlagerte Wirbelstrukturen aus, welche miteinander wechselwirken. Die kinetische Energie der Wirbelbewegungen stammt aus der Hauptströmung. Eine wichtige Kennzahl bei der Betrachtung turbulenter Strömungen stellt die Reynoldszahl Re dar. Auf Basis der charakteristischen Strömungsgeschwindigkeit u und -länge l_{Ref} sowie der kinematischen Viskosität ν , beschreibt sie das Verhältnis der Trägheitskräfte und der viskosen Kräfte

$$Re = \frac{u \cdot l_{Ref}}{\nu}. \quad (2.26)$$

Technische Strömungsprobleme sind fast ausschließlich turbulent und durch große Reynoldszahlen ($Re > 10^6$) gekennzeichnet. Im Rahmen dieser Arbeit werden ausschließlich voll turbulente Strömungen betrachtet. Laminare Strömungen sowie die Transition zu turbulenten Strömungen werden daher nicht weiter ausgeführt. Im folgenden Kapitel werden die Grundlagen der Turbulenz zusammengefasst. Eine ausführliche Beschreibung findet sich in Pope (2000).

2.3.1 Turbulente Energiekaskade

Die turbulente kinetische Energie der größten Wirbelstrukturen stammt aus der kinetischen Energie der Hauptströmung. Die Abmessungen der größten Wirbelstrukturen l_0 sind von gleicher Größenordnung wie die Abmessungen der zu Grunde liegenden Geometrie $l_0 \approx l_{Ref}$. Die großen Wirbelstrukturen weisen dabei stark anisotrope Eigenschaften auf. Durch die Streckung der Wirbelfäden aufgrund des Geschwindigkeitsgradienten der Hauptströmung werden

zusehends kleinere Wirbelstrukturen gebildet und gleichzeitig nimmt die Wirbelstärke aufgrund der Erhaltung des Drehimpulses zu. Durch die größere Wirbelstärke nimmt der Einfluss dissipativer Effekte zu. Innerhalb der sehr kleinen Wirbelstrukturen wird die turbulente kinetische Energie durch Dissipation in innere Energie und damit Wärmeenergie umgewandelt. Dieser Prozess wird auch als turbulente Energiekaskade infolge Wirbelstreckung bezeichnet.

Den auftretenden Wirbelstrukturen der Größe l und der Wellenzahl $\kappa = 2\pi/l$ wird eine charakteristische Geschwindigkeit $u(l)$ und Zeitskala $\tau(l) = l/u(l)$ zugeordnet. Für die größten energietragenden Wirbelstrukturen mit den Abmessungen l_0 , der Geschwindigkeit u_0 sowie der Zeitskala τ_0 ist die kinetische Energie in der Größenordnung u_0^2 . Diese bildet die Grundlage der transferierten kinetischen Energie des gesamten Prozesses, sodass die Dissipationsrate ϵ über die Energietransferrate abgeschätzt wird

$$\epsilon \sim \frac{u_0^3}{l_0}. \quad (2.27)$$

Die exakten Eigenschaften der Energiekaskade infolge Wirbelstreckung beschreibt Kolmogorov (1941) für hinreichend große Reynoldszahlen. Die großskaligen energiereichen Wirbelfäden l_0 sind anisotrop und werden stark von der Topologie und Geometrie des Strömungsgebietes beeinflusst. Die kleinsten Wirbelfädenstrukturen ($l \ll l_0$) hingegen beschreibt Kolmogorov in seiner Hypothese der lokalen Isotropie als statistisch isotrop. Die Abgrenzung der energietragenden Wirbelstrukturen vom isotropen Gleichgewichtsbereich erfolgt über das Längenmaß l_{EI} . Die (Richtungs-)Informationen über die Eigenschaften der großskaligen Turbulenzeffekte sowie der Hauptströmung sind im Gleichgewichtsbereich aufgrund der Isotropie nicht mehr vorhanden. Die kleinskaligen Strukturen haben einen universellen statistischen Charakter und werden eindeutig durch die kinematische Viskosität ν und die Dissipationsrate ϵ beschrieben. Das Längenmaß, die Geschwindigkeit und das Zeitmaß der kleinsten auftretenden Wirbelstrukturen werden als Kolmogorov-Größen bezeichnet und ergeben sich nach Dimensionsanalyse zu

$$\eta = (\nu^3/\epsilon)^{1/4}, \quad (2.28)$$

$$u_\eta = (\epsilon\nu)^{1/4}, \quad (2.29)$$

$$\tau_\eta = (\nu/\epsilon)^{1/2}. \quad (2.30)$$

Die Reynoldszahl auf Basis der Kolmogorov-Größen (u_η, η) ist gleich Eins. Hieraus lässt sich schließen, dass die Viskosität in diesem Bereich eine dominierende Rolle einnimmt und die turbulente kinetische Energie in Wärmeenergie dissipiert wird. Die Abmessungen der kleinsten Wirbel verringern sich je größer die Reynoldszahl des betrachteten Strömungsproblems ist. Zusammen mit Gleichung (2.27) lassen sich die Verhältnisse der Dimensionen in Abhängigkeit

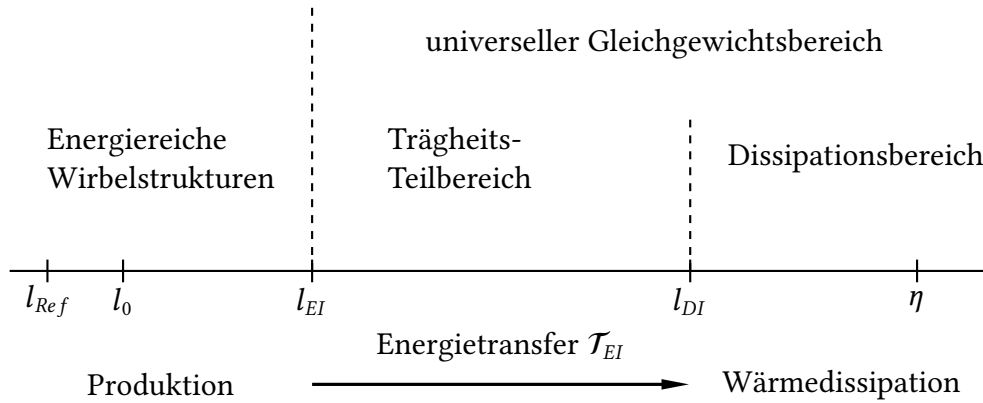


Abbildung 2.2: Darstellung der verschiedenen Bereiche der turbulenten Energiekaskade.

der Reynoldszahl beschreiben

$$\frac{\eta}{l_0} \sim \text{Re}^{-3/4}, \quad (2.31)$$

$$\frac{u_\eta}{u_0} \sim \text{Re}^{-1/4}, \quad (2.32)$$

$$\frac{\tau_\eta}{\tau_0} \sim \text{Re}^{-1/2}. \quad (2.33)$$

Die statistischen Eigenschaften des Skalenbereichs zwischen den großen, energiereichen Wirbelstrukturen und dem Bereich der Dissipation, in welchem die viskosen Effekte dominieren, beschreibt Kolmogorov mit seiner zweiten Ähnlichkeitshypothese. Die Wirbelstrukturen im Bereich $l_0 \ll l \ll \eta$ haben eine universelle Form, welche durch die Dissipationsrate ϵ eindeutig beschrieben wird und unabhängig der Viskosität ν ist. Daher wird, wie in Abbildung 2.2 dargestellt, der Gleichgewichtsbereich weiter unterteilt. In den Dissipationsbereich, in welchem sich das Längenmaß l dem Kolmogorov-Längenmaß η annähert und in den Trägheitsbereich $l_{DI} \ll l \ll l_{EI}$ in welchem die kinetische Energie an kleinere Wirbelstrukturen weitergereicht wird. Die Energietransferrate \mathcal{T}_{EI} ist dabei in der Größenordnung der Dissipation ϵ .

Die Verteilung der Energie über die unterschiedlichen Größenskalen, bzw. der Wellenzahl κ wird mittels des turbulenten Energiespektrums $E(\kappa)$ dargestellt. Das Energiespektrum im Trägheitsbereich kann aus den Hypothesen von Kolmogorov hergeleitet werden

$$E(\kappa) = C\epsilon^{2/3}\kappa^{-5/3}, \quad (2.34)$$

dabei ist C eine Konstante. Ein Modellspektrum für den gesamten Skalenbereich ist in Abbildung 2.3 exemplarisch für unterschiedliche Reynoldszahlen dargestellt. Für die kleinere Reynoldszahl $\text{Re}_{l_0} = 1000$ ist kein signifikanter Trägheitsbereich vorhanden und der Bereich der energiereichen Wirbelstrukturen und der Dissipationsbereich überschneiden sich. Für steigende Reynoldszahlen verbreitert sich der Trägheitsbereich und es bildet sich eine spektrale Lücke zwischen Turbulenzerzeugung und den dissipierenden Strukturen.

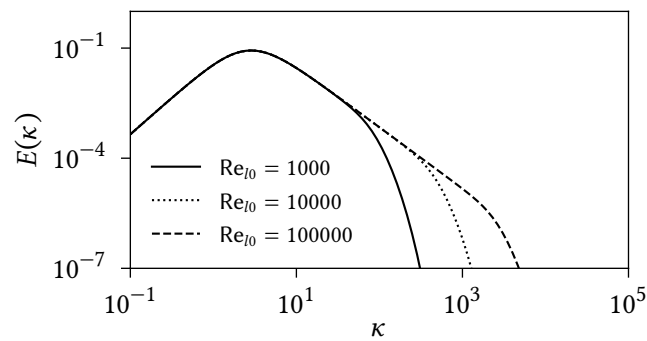


Abbildung 2.3: Modellenergiespektrum $E(\kappa)$ für unterschiedliche Reynoldszahlen Re_{l0} (nach Pope (2000))

2.3.2 Wandgebundene Turbulenz

Die Anisotropie der Turbulenz entsteht vorrangig durch die Wechselwirkung reibungsbehafteter Wände mit der Strömung. Wandnahe turbulente Strukturen werden insbesondere in Normalenrichtung stark gedämpft, wodurch die turbulente Energie nahe der Wand größtenteils auf die wandtangentialen Komponenten übertragen wird. Hierdurch wird die Anisotropie der Turbulenz verstärkt. In unmittelbarer Wandnähe verschwinden die Fluktuationen vollständig und Strömung wird durch viskose Effekte dominiert. Durch die unterschiedlichen dominierenden Phänomene innerhalb der Grenzschicht, lässt sich diese in Zonen unterteilen. Die Charakteristik der Grenzschicht wird meist am Beispiel der ebene Plattenströmung oder einer Kanalströmung diskutiert. An den Wänden ist der Geschwindigkeitsgradient in wandnormaler Richtung sehr groß. Mit Hilfe des Geschwindigkeitsgradienten an der Wand, der Dichte des Fluids ρ und der kinematischen Viskosität ν wird die Wandschubspannung zu

$$\tau_w = \rho \nu \left(\frac{\partial u}{\partial y} \right)_w \quad (2.35)$$

bestimmt. Mit dem Betrag der Wandschubspannung wiederum wird die Wandschubspannungsgeschwindigkeit ermittelt

$$u_\tau = \sqrt{\frac{|\tau_w|}{\rho}}. \quad (2.36)$$

Aus den beiden Gleichungen (2.35) und (2.36) folgt als Näherung für die Geschwindigkeit im wandnächsten Zellzentrum u_{PW} mit dem Abstand y_W zur Wand

$$\frac{u_\tau^2}{\nu} = \left(\frac{\partial u}{\partial y} \right)_w \Rightarrow u_{PW} = \frac{y_W u_\tau^2}{\nu}. \quad (2.37)$$




Abbildung 2.4: Mittleres Geschwindigkeitsprofil einer Kanalströmung für $Re_\tau = 4200$. Vergleich der DNS-Daten (Lozano-Durán und Jiménez, 2014) mit dem linearen und logarithmischen Verlauf.

Basierend auf der Wandschubspannungsgeschwindigkeit u_τ kann ebenfalls eine Reynoldszahl Re_τ zusammen mit der Grenzschichtdicke δ gebildet werden

$$Re_\tau = \frac{u_\tau \delta}{\nu}. \quad (2.38)$$

Die Schubspannungsgeschwindigkeit dient zur dimensionslosen Beschreibung des Wandabstandes y^+ sowie der Geschwindigkeit u^+ im wandnahen Bereich (2.37)

$$y^+ = \frac{u_\tau y_w}{\nu}, \quad u^+ = \frac{u}{u_\tau}. \quad (2.39)$$

Das Wandgesetz (engl. law of the wall) beschreibt vereinfacht den zweidimensionalen Verlauf der wandnahen tangentialen Geschwindigkeitskomponente. Die dargestellte Betrachtung wird aber auch für komplexere technischen Strömungen, wie sie im Rahmen dieser Arbeit betrachtet werden, als Näherung verwendet. Das reale Geschwindigkeitsprofil wird z.B. aufgrund gekrümmter Oberflächen, oder an Ablöse- und Wiederanlegepunkten verzerrt. Das mittlere Geschwindigkeitsprofil einer Kanalströmung ist beispielhaft in Abbildung 2.4 dargestellt. Das dargestellte Geschwindigkeitsprofil basiert auf DNS-Daten von Lozano-Durán und Jiménez (2014) für die Reynoldszahl $Re_\tau = 4200$. In der viskosen Unterschicht, welche in unmittelbarer Wandnähe ausgebildet wird, ist die Geschwindigkeit linear zum Wandabstand

$$u^+ = y^+. \quad (2.40)$$

In der viskosen Unterschicht sind die durch die turbulenten Fluktuationen verursachten Reynoldsspannungen vernachlässigbar und die viskose Schubspannung dominiert. Bis zu einem

Wandabstand von $y^+ \approx 50$ nimmt der Einfluss der molekularen Viskosität kontinuierlich ab und ist in der weiter außen liegenden Region vernachlässigbar. Der logarithmische Bereich der Grenzschicht beginnt bei $y^+ \approx 30$ und nimmt dort folgenden Verlauf an

$$u^+ = \frac{1}{\kappa} \ln y^+ + B. \quad (2.41)$$

Die Konstante κ beschreibt den Exponenten des Geschwindigkeitsprofils und wird auch als Karman-Konstante bezeichnet. Die häufig verwendeten Werte der beiden Konstanten $\kappa = 0,41$ und $B = 5,2$ werden aus Experimenten oder DNS-basierten Daten extrahiert.

2.3.3 Abgelöste Umströmung stumpfer Körper

Zu den stumpfen Körpern (engl. bluff bodies) im strömungsmechanischen Kontext zählen geometrische Formen mit starker Störung bzw. Umlenkung der Strömung durch Kanten, Formgebung oder der Ausrichtung der Geometrie zur Strömung. Das Gegenteil sind schlanke bzw. stromlinienförmige Körper. Im Folgenden wird eine kurze Übersicht der Charakteristik der turbulenten Effekte bei der Umströmung stumpfer Körper gegeben. Für eine ausführliche Beschreibung der Phänomene wird auf Hucho (2012) verwiesen.

Die Umströmung stumpfer Körper ist geprägt von starker Ablösung der Strömung mit stark ausgeprägtem Totwasser und instationärem Charakter. Dadurch wirken sich umströmte stumpfe Körper deutlich stärker auf ihr Umfeld aus als stromlinienförmige Körper, was z.B. bei der Untersuchung im Windkanal relevant ist. Die am Körper angreifenden Lasten werden vom Druckanteil dominiert und die Reibungskräfte sind von untergeordneter Bedeutung. Auch die Strömung entlang eines stromlinienförmigen Körpers löst ab, wenn dieser nicht stromlinienförmig ausgerichtet überströmt wird. Bei stark angestellten Profilen zum Beispiel folgt die Grenzschicht nur bedingt der Kontur des Körpers. Hinter der dicksten Stelle des Profils verringert sich die Strömungsgeschwindigkeit und der Druck steigt an. Wird die Geschwindigkeit durch die Kontur des Körpers stromab weiter stark verzögert, kann die Grenzschichtströmung nicht mehr bis zum Ende des Körpers gegen den von der Außenströmung aufgeprägten Druckanstieg anströmen und löst ab. Bei turbulenten Strömungen ist der Geschwindigkeitsgradient an der Wand im Vergleich zur laminaren Strömung größer, wodurch turbulente Strömungen in der Nähe der Wand energiereicher sind und im Vergleich zu laminaren Strömungen später ablösen. Am Punkt der Ablösung verschwindet der Gradient der Geschwindigkeit $\frac{\partial u}{\partial y} = 0$ sowie die Wandschubspannung $\tau_w = 0$ vollständig. Teilweise werden diese Bedingungen daher zur Definition des Ablösepunktes verwendet. Tritt die Ablösung allerdings an einer scharfen Kante auf, werden diese Bedingungen nicht erfüllt. Unmittelbar vor der Kante ist in der Grenzschicht weder der Geschwindigkeitsgradient noch die Wandschubspannung nahe null. Durch

das plötzliche Auftreten der Kante im Strömungsverlauf bildet sich eine instabile Scherschicht aus und es kommt zur Bildung eines Totwassers hinter der Kante.

Die aerodynamische Schiffsumströmung wird zumeist von der Umströmung des Deckshauses dominiert. Wird Ladung an Deck transportiert, wie z.B. bei Containerschiffen, hat diese ebenfalls einen großen Einfluss auf die aerodynamischen Lasten. Die Umströmung des Deckshauses lässt sich dabei näherungsweise durch einen Quader auf einer Bodenplatte darstellen, wobei die Bodenplatte in diesem Fall der Wasseroberfläche entspricht. Bei der Umströmung des Quaders bilden sich mehrere Wirbel aus, wie ausführlich von Martinuzzi und Tropea (1993) beschrieben wird. An der Vorderkante in Bodennähe bildet sich ein hufeisenförmiger Wirbel, hinter dem Quader ein bogenförmiger Wirbel. An den seitlichen und der oberen Vorderkante des Quaders löst die Strömung ebenfalls ab. Im Bereich hinter dem Quader bildet sich somit ein komplexes instationäres Rezirkulationsgebiet aus.

2.4 Turbulenzmodellierung

Prinzipiell kann die Turbulenz des Strömungsfeldes innerhalb der numerischen Simulation vollständig aufgelöst werden. Dies wird als direkte numerische Simulation (DNS) bezeichnet. Die direkte Auflösung aller räumlichen und zeitlichen Skalen des Turbulenzfeldes erfordert allerdings einen immensen räumlichen und zeitlichen Diskretisierungsaufwand, da für komplexe Strömungsprobleme mit großen Reynoldszahlen sehr kleine räumliche und zeitliche Skalen auftreten (vgl. Gleichungen (2.31) und (2.33)). Um dennoch turbulente technische Strömungsprobleme mit praktikablem Aufwand, d.h. unteraufgelöst, zu simulieren, stehen verschiedene Turbulenzmodellkonzepte zur Verfügung. Die jeweiligen Modelle weisen unterschiedliche Stärken und Schwächen auf, weshalb die Auswahl des Turbulenzmodells das Simulationsergebnis teils erheblich beeinflusst.

2.4.1 Reynoldsgemittelte-Turbulenzmodellierung

Eine Möglichkeit zur effizienten numerischen Simulation turbulenter Strömungen ist, ausschließlich das statistisch gemittelte Strömungsfeld zu betrachten und die turbulenten Fluktuationen weder räumlich noch zeitlich aufzulösen. Die Größen des Strömungsfeldes Φ lassen sich nach Reynolds (1895) als Summe des statistisch gemittelten Anteils $\bar{\Phi}$ und der Fluktuationen Φ' darstellen. In der Praxis wird anstelle des statistischen Mittelwertes in der Regel der zeitliche Mittelwert benutzt

$$\Phi(x_i, t) = \bar{\Phi}(x_i) + \Phi'(x_i, t). \quad (2.42)$$

Für inkompressible Strömungen können die Stoffwerte (Dichte und Viskosität) als nicht fluktuierende Größen angenommen werden. Wird die Mittelung auf die Navier-Stokes-Gleichungen (2.3) und (2.4) angewandt, verschwinden in der gemittelten Betrachtung die in den Fluktuationen linearen Terme z.B. $\overline{\Phi'} = 0$. Aufgrund der Nichtlinearität der Gleichungen treten durch Anwendung der zeitlichen Mittelung zusätzliche unbekannte Größen auf, welche zur Schließung der Bilanzen für die gemittelten Größen modelliert werden müssen. Daraus resultieren die Reynolds-gemittelten Navier-Stokes-Gleichungen (engl. Reynolds averaged Navier-Stokes-Equations, RANSE)

$$\oint_S \rho \bar{u}_j dS_j = 0, \quad (2.43)$$

$$\int_V \frac{\partial(\rho \bar{u}_i)}{\partial t} dV + \oint_S (\rho \bar{u}_i \bar{u}_j + \overline{\rho u'_i u'_j}) dS_j = \oint_S (-\bar{p} \delta_{ij} + \bar{\tau}_{ij}) dS_j + \int_V f_i dV. \quad (2.44)$$

Der zusätzliche auftretende Term $\overline{\rho u'_i u'_j}$ wird als Reynoldsspannungstensor bezeichnet. Dieser beschreibt den Einfluss der Turbulenz auf das zeitlich gemittelte Strömungsfeld. Basierend auf der Annahme, dass der Einfluss der Turbulenz über eine zusätzliche Viskosität in Analogie zur molekularen Viskosität modelliert werden kann, wird die Boussinesq-Hypothese zur Modellierung der Reynoldsspannungen angewendet

$$-\overline{\rho u'_i u'_j} = \mu_t \left(\frac{\partial \bar{u}_i}{\partial x_j} + \frac{\partial \bar{u}_j}{\partial x_i} \right) - \frac{2}{3} \rho \delta_{ij} k = 2\mu_t \bar{S}_{ij} - \frac{2}{3} \rho \delta_{ij} k. \quad (2.45)$$

Die kinetische Energie der Turbulenz ist $k = \frac{1}{2} \overline{u'_i u'_i}$, der zeitlicher Mittelwert der Deformationsrate des Feldes ist \bar{S}_{ij} und $\mu_t = \rho \nu_t$ wird als Wirbelviskosität bezeichnet. Um die Gleichungen vollständig zu schließen, muss die Wirbelviskosität modelliert werden. Die Modellierung der Wirbelviskosität kann, analog zum E-Modul, tensorbasiert erfolgen, um die enge Kopplung der Turbulenz von der Scherrate des Strömungsfeldes zu lösen. Bei isotropen Wirbelviskositätsmodellen wird die Wirbelviskosität hingegen vereinfacht als isotroper Skalar modelliert. Zur Bestimmung der Wirbelviskosität werden in der Regel zwei weitere Transportgleichungen gelöst. Die erste Gleichung beschreibt dabei die kinetische Energie des Turbulenzfeldes, die zweite das turbulente Längen- oder Zeitmaß.

k- ϵ -Zweigliedungsmodell

Das k- ϵ -Zweigliedungsmodell betrachtet den Transport der turbulenten kinetischen Energie k und der turbulenten Dissipationsrate ϵ . Das k- ϵ -Modell wurde zuerst von Jones und Launder (1972) beschrieben und wird häufig zur Turbulenzmodellierung eingesetzt. Zweigliedungsmodelle sind relativ einfach zu implementieren, robust und weitestgehend universell anwendbar. Die semi-empirischen Modellkonstanten basieren auf der experimentellen oder DNS Untersuchung spezifischer analytisch lösbarer turbulenter Strömungen. Für die beiden betrachteten

turbulente Größen k und ϵ können, angelehnt an die allgemeinen Transportgleichung (2.1), die Differentialgleichungen zur Beschreibung des Transportes beschrieben werden

$$\int_V \frac{\partial(\rho k)}{\partial t} dV + \oint_S (\rho \bar{u}_j k) dS_j = \oint_S \left[\left(\mu + \frac{\mu_t}{\sigma_k} \right) \frac{\partial k}{\partial x_j} \right] dS_j + \int_V (P - \rho \epsilon) dV, \quad (2.46)$$

$$\int_V \frac{\partial(\rho \epsilon)}{\partial t} dV + \oint_S (\rho \bar{u}_j \epsilon) dS_j = \oint_S \left[\left(\frac{\mu_t}{\sigma_\epsilon} \right) \frac{\partial \epsilon}{\partial x_j} \right] dS_j + \int_V \left(C_{\epsilon 1} P \frac{\epsilon}{k} - \rho C_{\epsilon 2} \frac{\epsilon^2}{k} \right) dV. \quad (2.47)$$

Darin ist σ_k die turbulente Prandtl-Zahl. Die in den Gleichungen enthaltene Produktionsrate der turbulenten kinetischen Energie lässt sich direkt bestimmen

$$P = \mu_t \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) \frac{\partial u_i}{\partial x_j}. \quad (2.48)$$

Basierend auf den turbulenten Größen k und ϵ lässt sich die turbulente Viskosität berechnen

$$\mu_t = \rho C_\mu \frac{k^2}{\epsilon}. \quad (2.49)$$

Für die in den Modellgleichungen enthaltenen fünf Modellkonstanten werden meist folgende Werte verwendet

$$C_{\epsilon 1} = 1,44; \quad C_{\epsilon 2} = 1,92; \quad C_\mu = 0,09; \quad \sigma_k = 1,0; \quad \sigma_\epsilon = 1,3. \quad (2.50)$$

Das k - ϵ -Turbulenzmodell eignet sich gut zur Simulation von freien Scherschichtströmungen mit mäßigem Druckgradienten. Für die Modellierung von Strömungen im wandnahen Bereich ist das Modell ungenau, da es das Gesetz der zähen Unterschicht (2.40) nicht ohne zusätzliche Manipulationen wiedergeben kann.

k- ω -Zweigliedungsmodell

Alternativ kann ein Zweigliedungsmodell mit der turbulenten kinetischen Energie k und der charakteristischen Frequenz der dissipierenden Wirbel ω beschrieben werden. Das ebenfalls häufig eingesetzte Turbulenzmodell wurde zuerst von Wilcox (1988) beschrieben. Für die Frequenz gilt $\omega = \epsilon / (C_\mu k)$. Auch hier lassen sich Transportgleichungen für die Größen k und ω aufstellen

$$\int_V \frac{\partial(\rho k)}{\partial t} dV + \oint_S (\rho \bar{u}_j k) dS_j = \oint_S \left[\left(\mu + \frac{\mu_t}{\sigma_k^*} \right) \frac{\partial k}{\partial x_j} \right] dS_j + \int_V (P - \rho \beta^* k \omega) dV, \quad (2.51)$$

$$\int_V \frac{\partial(\rho \omega)}{\partial t} dV + \oint_S (\rho \bar{u}_j \omega) dS_j = \oint_S \left[\left(\mu + \frac{\mu_t}{\sigma_\omega^*} \right) \frac{\partial \omega}{\partial x_j} \right] dS_j + \int_V \left(\alpha P \frac{\omega}{k} - \rho \beta \omega^2 \right) dV. \quad (2.52)$$

Die Gleichung (2.52) ließe sich auch mittels der Kettenregel aus $\epsilon = \omega C_\mu k$ entwickeln. Diese Herleitung offenbart einen weiteren Term ($\sim \nabla\omega \cdot \nabla k$), der bewusst unterdrückt wird, um das Gesetz der zähen Unterschicht (2.40) wiedergeben zu können. Die Produktionsrate wird, wie zuvor nach Gleichung (2.48) bestimmt. Für die Modellparameter des k - ω -Modell werden meist folgende Konstanten verwendet

$$\alpha = \frac{5}{9}; \quad \beta = 0,075; \quad \beta^* = C_\mu = 0,09; \quad \sigma_k^* = 2,0; \quad \sigma_\omega^* = 2,0. \quad (2.53)$$

Die turbulente Viskosität wird mit Hilfe der turbulenten kinetischen Energie k und der turbulenten Frequenz ω aus (2.49) bestimmt

$$\mu_t = \rho \frac{k}{\omega}. \quad (2.54)$$

Die Stärke des k - ω -Modells liegt in der Modellierung der wandnahen Strömung, während die Modellierung des turbulenten Fernfelds schwächer ist.

k- ω SST-Modell

Das k - ω SST-Modell (engl. shear stress transport, SST) kombiniert die Vorteile der beiden zuvor dargestellten Zweigleichungsmodelle. Das von Menter (1994) vorgestellte Turbulenzmodell verwendet im wandnahen Bereich die k - ω -Modellierung und im wandfernen Bereich die k - ϵ -Modellierung. Zur Kombination der beiden Turbulenzmodelle wird ein Überblendungsterm eingeführt. Die im weiteren vorgestellte Modellvariante berücksichtigt einige leichte Modifikationen (Menter et al., 2003) zum ursprünglich vorgestellten k - ω SST-Modell.

Für die Transportgleichung der turbulenten kinetischen Energie k wird ein modifizierter Produktionsterm \tilde{P} verwendet

$$\int_V \frac{\partial(\rho k)}{\partial t} dV + \oint_S (\rho \bar{u}_j k) dS_j = \oint_S \left[\left(\mu + \frac{\mu_t}{\sigma_k} \right) \frac{\partial k}{\partial x_j} \right] dS_j + \int_V (\tilde{P} - \rho \beta^* k \omega) dV. \quad (2.55)$$

Durch die Modifikation wird der Term der turbulenten Produktion limitiert, um rotationsarme Prallstrahleffekte besser darzustellen

$$\tilde{P} = \min(P, 10\beta^* \rho \omega k). \quad (2.56)$$

Der limitierte Produktionsterm wird ebenfalls in der Transportgleichung der Dissipationsrate ω berücksichtigt

$$\int_V \frac{\partial(\rho\omega)}{\partial t} dV + \oint_S (\rho \bar{u}_j \omega) dS_j = \oint_S \left[(\mu + \mu_t \sigma_\omega) \frac{\partial \omega}{\partial x_j} \right] dS_j + \int_V \left[2(1 - F_1) \frac{\sigma_\omega}{\omega} \frac{\partial k}{\partial x_j} \frac{\partial \omega}{\partial x_j} \right] dV + \int_V \left(\frac{\alpha}{\mu_t} \tilde{P} - \rho \beta \omega^2 \right) dV. \quad (2.57)$$

Für den Übergang der beiden Modellzweige wird der Faktor F_1 eingeführt

$$F_1 = \tanh(\text{arg}_1^4), \quad (2.58)$$

dabei ist $F_1 = 1$ im wandnahen Bereich und im wandfernen Bereich ist $F_1 = 0$. Zur Bestimmung des Faktors wird das Argument arg_1 benötigt

$$\text{arg}_1 = \min \left[\max \left(\frac{\sqrt{k}}{\beta^* \omega d_w}, \frac{500\mu}{\rho d_w^2 \omega} \right), \frac{4\rho\sigma_\omega k}{CD_{k\omega} d_w^2} \right], \quad (2.59)$$

d_w ist hierbei der Wandabstand. Der Faktor $CD_{k\omega}$ wird wie folgt berechnet

$$CD_{k\omega} = \max \left(2\rho\sigma_\omega \frac{1}{\omega} \frac{\partial k}{\partial x_j} \frac{\partial \omega}{\partial x_j}, 10^{-10} \right). \quad (2.60)$$

Mittels des Scherratenparameters S wird die turbulente Viskosität für das Modell berechnet

$$\mu_t = \frac{\rho a_1 k}{\max(a_1 \omega, S \cdot F_2)}, \quad S = \sqrt{2S_{ij}S_{ij}}. \quad (2.61)$$

Für die Bestimmung der turbulenten Viskosität wird einer weiterer Faktor F_2 benötigt

$$F_2 = \tanh(\text{arg}_2^2), \quad (2.62)$$

wobei das Argument in diesem Fall folgendermaßen bestimmt wird

$$\text{arg}_2 = \max \left(2 \frac{\sqrt{k}}{\beta^* \omega d_w}, \frac{500\mu}{\rho y^2 \omega} \right). \quad (2.63)$$

Einige der Modellkonstanten für die Berechnungen werden mit Hilfe der Überblendung $\Phi = F_1\Phi_1 + (1 - F_1)\Phi_2$ bestimmt

$$\begin{aligned} \alpha_1 &= \frac{5}{9}; & \alpha_2 &= 0,44 \\ \sigma_{k1} &= 0,85; & \sigma_{k2} &= 1,0. \end{aligned} \quad (2.64)$$

Die weiteren benötigten Modellkonstanten sind

$$\beta^* = 0,09; \quad \kappa = 0,41 \quad a_1 = 0,31. \quad (2.65)$$

Durch die die Kombination der Vorteile des k - ϵ - und des k - ω -Turbulenzmodells eignet sich das k - ω SST-Modell für die Modellierung turbulenter Strömungen in einem breiten Anwendungsspektrum.

Instationäre RANS-Simulationen

Die Entwicklung der Reynolds-gemittelten Turbulenzmodelle basiert häufig auf der Annahme einer statistisch stationären Strömung. Für transiente Strömungsprobleme kann statt des statistischen Mittelwertes (vgl. Gleichung (2.42)) auch eine Ensemble-Mittelung angenommen werden. Dabei werden die turbulenten Fluktuationen durch die Mittelung erfasst. Die transienten Prozesse der gemittelten Strömung, welche durch die Randbedingungen bedingt sind, werden durch die Simulation aufgelöst. Um eine Differenzierung der beiden Felder zu ermöglichen muss das Zeitmaß der transienten Bewegung deutlich größer (mindestens 1-2 Größenordnungen) (Rung, 2000) als das Zeitmaß der turbulenten Fluktuationen sein, was auch als spektrale Lücke bezeichnet wird. Ist diese klare Trennung der Zeitskalen nicht gegeben, treten nichtlineare Impuls- und Energieflüsse zwischen beiden Anteilen auf. Bei vielen technischen Anwendungsfällen tritt keine klare spektrale Lücke auf und eine RANS-basierte Modellierung ist dadurch nicht möglich.

2.4.2 Grobstruktursimulation

Eine weitere Option zur Modellierung der Turbulenz stellt die Grobstruktursimulation (engl. large eddy simulation LES) dar. Im Gegensatz zur RANS-basierten Turbulenzmodellierung werden die dreidimensionalen turbulenten großskaligen Wirbelstrukturen direkt aufgelöst und der Einfluss der kleinskaligen dissipativen Bewegungen wird modelliert. Die Diskretisierung erfolgt bei Anwendung der Grobstruktursimulation immer räumlich dreidimensional und zeitlich instationär. Der Aufwand im Vergleich zu RANS-basierten Simulationen ist daher erheblich größer. Bei der Anwendung von LES-basierten Modellen ist davon auszugehen, dass genauere Ergebnisse erreicht werden. Insbesondere für Strömungsprobleme mit großskaligen Instabilitäten, wie z.B. bei der Umströmung stumpfer Körper mit starker Ablösung, tritt ein erheblicher Teil der Energie in Form großskaliger Fluktuationen auf. Diese sind meist von stark anisotropem Charakter und hängen von der Positionierung der Geometrien im Strömungsfeld ab.

Die Charakteristik der kleinskaligen turbulenten Bewegungen ist hingegen meist isotrop und von universellem Charakter, weshalb diese mit vergleichsweise simplen Modellen gut abgebildet werden kann. Die LES-Modellierung basiert auf der Trennung beider Skalenbereiche durch

Anwendung eines Filters

$$\Phi(x,t) = \bar{\Phi}(x,t) + \Phi'(x,t). \quad (2.66)$$

Hierbei kennzeichnen $\bar{\Phi}(x,t)$ die gefilterten und fluktuierenden Größen des Strömungsfeldes und $\Phi'(x,t)$ die kleinskaligen Fluktuationen außerhalb der Filterweite, welche nicht aufgelöst werden. Der Filter wirkt wie eine regionale Mittelung über den Bereich der Filterweite Δ . Bei Anwendung einer expliziten Filterung, wie z.B. eines Gauß-Filters erfolgt die Filterung mit einer spezifizierten Filterweite Δ . Dabei sollte die Filterweite mindestens in der Größenordnung der Gitterweite sein. Eine alternative Möglichkeit zur Filterung der Fluktuationen besteht, in der Anwendung einer impliziten Gitterfilterung, welche z.B. durch die Wahl des Diskretisierungsschemas für die Konvektion erfolgt. Der Vorteil einer expliziten Filterung ist, dass die bekannte Filterfunktion eine exakte Trennung der groß- und kleinskaligen Fluktuationen ermöglicht, sofern implizite Beiträge vernachlässigbar sind. Diese Variante wird daher in der Praxis bevorzugt.

Wird die Filterung (2.66) auf die Navier-Stokes-Gleichungen angewendet, tritt in den resultierenden Gleichungen der unbekannte nichtlineare Term $\overline{u_i u_j}$ auf. Der Term kann in den Anteil der im Feld aufgelösten turbulenten Fluktuationen $\overline{u_i u_j}$ und dem Rest-Spannungstensor τ_{ij}^r aufgeteilt werden

$$\overline{u_i u_j} = \overline{u_i u_j} + \tau_{ij}^r. \quad (2.67)$$

Durch den Rest-Spannungstensor wird der Einfluss der kleinskaligen, nicht aufgelösten Wirbelstrukturen berücksichtigt. Für dessen Modellierung wird häufig das Smagorinsky-Wirbelviskositätsmodell (Smagorinsky, 1963) verwendet. Um eine Lösung für das Schließungsproblem zu erhalten, ist eine modellbasierte Beschreibung des Rest-Spannungstensors τ_{ij}^r erforderlich. Mit Hilfe des isotropen Wirbelviskositätsmodells

$$\tau_{ij}^r = -2\nu_t \bar{S}_{ij}, \quad (2.68)$$

wird der Zusammenhang zwischen dem Rest-Spannungstensor und der gefilterten Scherrate \bar{S}_{ij} beschrieben. Hierfür wird der Proportionalitätsfaktor, die Wirbelviskosität ν_t benötigt. Die Wirbelviskosität wird mit einer Mischweghypothese ($\nu_t \sim L_t \cdot u_t \sim \Delta \cdot \bar{S}\Delta$) bestimmt

$$\nu_t = (C_S \Delta)^2 \cdot \bar{S}. \quad (2.69)$$

Neben der modellspezifischen Smagorinsky-Konstante C_S und der Filterweite Δ wird die Größe \bar{S} benötigt

$$\bar{S} = \sqrt{2\bar{S}_{ij}\bar{S}_{ij}}. \quad (2.70)$$

Der Transfer der turbulenten Energie findet dabei immer in Richtung des gefilterten Feldes hin zu den Residual-Bewegungen statt und niemals in die entgegengesetzte Richtung.

2.4.3 Hybride Turbulenzmodelle

Das Ziel der hybriden RANS/LES-Modellierung ist es, die Stärken der RANS-basierten und der LES-basierten Turbulenzmodellierung zu kombinieren und dadurch die jeweiligen Schwächen der Modelle auszugleichen. RANS-basierte Modelle haben Schwierigkeiten bei der Modellierung (massiv) abgelöster Strömungen und bei skalenauflösender Modellierung (LES) ist die Auflösung der sehr feinen turbulenten Strukturen in der Grenzschicht sehr aufwendig und für technisch relevante Strömungen bei hoher Reynoldszahl nicht umsetzbar. Das Vorgehen der hybriden Modellierung ist daher in Bereichen mit ausreichend feiner Gitterauflösung ein LES-Modell anzuwenden und im wandnahen Bereich ein RANS-Modell. Das ursprüngliche DES-Modell (engl. detached eddy simulation) wurde zuerst von Spalart et al. (1997) beschrieben. Aufgrund der einfachen Umsetzbarkeit basierte es auf dem Spalart-Allmaras-Eingleichungsturbulenzmodell (Spalart und Allmaras, 1992), wurde aber im Weiteren auf weitere RANS-Modelle übertragen, z.B. auf das k - ω -SST Modell (Menter, 1994). In Bereichen, in welchen die Gitterauflösung ausreicht, um die turbulenten Strukturen aufzulösen, operiert das hybride Modell im skalenauflösenden (LES-)Modus und in den übrigen Bereichen, insbesondere in der Wandgrenzschicht im RANS-Modus. Die Lösung des Strömungsfeldes ist daher stark an das verwendete Gitter gekoppelt. Im skalenauflösenden Bereich lässt sich die Formulierung unter der Annahme eines turbulenten Gleichgewichtszustandes auf das Smagorinsky-Modell (vgl. Abschnitt 2.4.2) zurückführen. Diese Art der hybriden Modellierung ist nicht zonal, das heißt die einzelnen Bereiche, in denen das jeweilige Modell aktiv ist, werden nicht vom Nutzer fest vorgegeben und können sich dynamisch ändern.

Die ursprüngliche Formulierung des Modells weist einige Probleme auf, für welche verbesserte Formulierungen entwickelt wurden. Einen Überblick über die verschiedenen Varianten der hybriden Turbulenzmodellierung und deren Entwicklung ist bei Mockett (2009) zu finden. Darüber hinaus gibt es neben der DES eine große Anzahl weiterer Ansätze für hybride Modelle. Eine Übersicht sowie der Versuch einer Klassifizierung findet sich bei Fröhlich und von Terzi (2008).

Im Folgenden wird ein Überblick über die möglichen Probleme der ursprünglichen DES-Modellierung von Spalart et al. (1997) gegeben. Ist das Gitter parallel zur Wand im Bereich der Grenzschicht zu fein aufgelöst, was z.B. bei lokaler Verfeinerung auftreten kann, kann bereits innerhalb der Grenzschicht der LES-Modus des hybriden Modells aktiviert werden. Dadurch wird die turbulente Viskosität im Vergleich zum RANS-Modus reduziert, ohne dass die turbulenten Fluktuationen in diesem Bereich hinreichend aufgelöst werden. Die Reynoldsspan-

nungen werden somit weder modelliert noch aufgelöst, was wiederum zur Bestimmung einer zu geringen Durchmischung und deutlich herabgesetzter Reibung an der Wand führt. Durch diese kann es zu einer verfrühten oder gänzlich falsch vorhergesagten Ablösung der Strömung kommen. Dies wird auch als **Gitter induzierte Ablösung** (engl. grid-induced separation, GIS) bezeichnet. Das Problem wird durch die Erweiterung des ursprünglichen DES-Modells hin zum DDES-Modell (engl. delayed detached eddy simulation) (Spalart et al., 2006) weitgehend vermieden. Dazu wird das Umschalten des hybriden Modells in den LES-Modus innerhalb der Grenzschicht durch eine zusätzliche Modellfunktion unterbunden.

Ein weiteres Problem tritt durch den Mangel an turbulenten Fluktuationen unmittelbar nach dem Umschalten vom RANS-Modus zum LES-Modus auf. Unmittelbar nach dem Umschalten bilden sich im LES-Bereich keine ausreichenden turbulenten Fluktuationen aus, um die modellierte turbulente kinetische Energie zu repräsentieren. In diesem Bereich liegt dann weder eine RANS-Modellierung noch eine LES-Modellierung vor. Dies wird auch als **Grauzonenproblem** (engl. grey area problem) bezeichnet. Das Problem der Grauzone betrifft alle hybriden Turbulenzmodelle. Wie schwerwiegend das Problem ist, hängt vom betrachteten Strömungsproblem ab. Für stark abgelöste Strömungen mit klar definierter räumlicher Ablösung, wie sie z.B. bei stumpfen Körpern auftreten, sorgt die Rezirkulation im Ablösegebiet für eine ausreichende Fluktuation direkt hinter der Ablösekannte. Beim Auftreten druckinduzierter Ablösung hingegen, treten mehr Probleme auf.

Eine alternative hybride Turbulenzmodellierung besteht darin, das RANS-Modell nur zonal z.B. in der Grenzschicht, zu aktivieren und im übrigen Gebiet ein LES-Modell zu verwenden. Dieses Vorgehen unterscheidet sich vom DES-Ansatz und wird als wandmodellierendes LES-Modell (engl. wall modelled large eddy simulation, WMLES) bezeichnet. Dabei ist der wandnahe Bereich, in welchem die RANS-basierte Modellierung erfolgt, deutlich dünner im Vergleich zur DES Methode. Das Interface zwischen RANS und LES-Modellierung befindet sich in der Regel innerhalb der Grenzschicht im logarithmischen Bereich (vgl. Abbildung 2.4). Beim Auswerten des Geschwindigkeitsprofils lässt sich in diesem Bereich häufig ein Knick beim Übergang vom RANS hin zum LES-Modell beobachten. Dieses Phänomen wird auch als **log-layer mismatch (LLM)** bezeichnet. Durch eine Weiterentwicklung des DDES-Ansatzes wird beim IDDES-Modell (engl. improved delayed detached eddy simulation) (Gritskevich et al., 2012) das Verhalten der Modellierung im logarithmischen Bereich verbessert.

2.4.4 IDDES Modell

Im Folgenden wird das IDDES-Modell detaillierter beschrieben. Für die Simulationen im weiteren Verlauf dieser Arbeit wird dieses Modell für die Turbulenzmodellierung angewendet. Die Implementierung des IDDES-Ansatzes stellt zwei Zweige der Modellierung zur Verfügung: zum einen den DDES-Zweig und zum anderen einen WMLES-Zweig. Der DDES-Zweig ist aktiv,

wenn keine turbulenten Fluktuationen am Einlassrand vorherrschen und der WMLES-Zweig ist aktiv, wenn turbulente Fluktuationen am Einlass vorgegeben werden. Durch die Verzweigung steigt die Komplexität des Modells deutlich im Vergleich zum ursprünglichen DES-Modell, dafür werden die im vorherigen Abschnitt genannten Probleme minimiert bzw. gelöst. Eine Implementierung ist für unterschiedliche RANS-Turbulenzmodelle möglich, wobei jeweils eine Kalibrierung der Modellkonstanten erforderlich ist. Hier wird die Umsetzung basierend auf dem k - ω -SST Modell (Menter, 1994) (vgl. Abschnitt 2.4.1) dargestellt.

Für die Implementierung des Modells wird nur der Term des turbulenten Längenmaßes in der Transportgleichung der turbulenten kinetischen Energie k des k - ω -SST Modells (vgl. Gleichung (2.55)) angepasst

$$\int_V \frac{\partial(\rho k)}{\partial t} dV + \oint_S (\rho \bar{u}_j k) dS_j = \oint_S \left[\left(\mu + \frac{\mu_t}{\sigma_k} \right) \frac{\partial k}{\partial x_j} \right] dS_j + \int_V \left(\tilde{P} - \rho \frac{k^{3/2}}{l_{IDDES}} \right) dV. \quad (2.71)$$

Hierdurch wird eine Reduzierung der Wirbelviskosität im Bereich des LES-Modus erreicht. Die Transportgleichung der charakteristischen turbulenten Frequenz ω wird vom k - ω SST-Modell (Gleichung (2.57)) direkt übernommen. In dieser Arbeit wird die vereinfachte Variante des IDDES-Modells beschrieben und angewendet. Für eine ausführliche Beschreibung des Modells wird auf Gritskevich et al. (2012) verwiesen. Mit Hilfe eines Faktors \tilde{f}_d wird das Längenmaß zwischen dem RANS- und LES-Modus überblendet

$$l_{IDDES} = \tilde{f}_d \cdot l_{RANS} + (1 - \tilde{f}_d) \cdot l_{LES}. \quad (2.72)$$

Das Längenmaß für den LES-Teil wird mit Hilfe der Modellkonstanten C_{DES} und der Gitterweite Δ bestimmt

$$l_{LES} = C_{DES} \Delta. \quad (2.73)$$

Die Modellkonstante C_{DES} wird dabei basierend auf dem Überblendungsfaktor des SST-Modells (Gleichung (2.58)) zwischen den beiden Konstanten C_{DES1} und C_{DES2} ebenfalls überblendet

$$C_{DES} = C_{DES1} \cdot F_1 + C_{DES2} \cdot (1 - F_1). \quad (2.74)$$

Das Längenmaß im RANS-Modus wird mit den beiden Transportgrößen k und ω des Turbulenzmodells und der Konstanten β^* berechnet

$$l_{RANS} = \frac{\sqrt{k}}{\beta^* \omega}. \quad (2.75)$$

Das Gitter-Längenmaß Δ wird basierend auf den lokal vorliegenden geometrischen Eigenschaften des Gitters bestimmt

$$\Delta = \min\{C_w \max[d_w, h_{max}], h_{max}\}, \quad (2.76)$$

wobei C_w eine Modellkonstante, h_{max} die maximale Kantenlänge der Gitterzelle und d_w der Wandabstand sind, da beim IDDES-Modell das Gitter-Längenmaß nicht nur vom Gitter, sondern auch vom Wandabstand abhängt.

Der für die Überblendung zwischen dem LES- und RANS-Modus benötigte Faktor \tilde{f}_d wird mittels der folgenden Gleichungen bestimmt

$$\tilde{f}_d = \max[(1 - f_{dt}), f_b], \quad (2.77)$$

$$f_{dt} = 1 - \tanh \left[(C_{dt1} \cdot r_{dt})^{C_{dt2}} \right], \quad (2.78)$$

$$r_{dt} = \frac{v_t}{\kappa^2 d_w^2 \sqrt{0,5 \cdot (S^2 + \Omega^2)}}, \quad (2.79)$$

$$f_b = \min \left[2 \exp(-9\alpha^2), 1, 0 \right], \quad (2.80)$$

$$\alpha = 0,25 - d_w/h_{max}. \quad (2.81)$$

Hierbei ist S der in Gleichung (2.61) benutzte Scherratenparameter und Ω der Betrag des Wirbelstärkentensors. Neben den Modellkonstanten des $k-\omega$ SST-Modells, welche in Gleichung (2.65) beschrieben sind, werden für das IDDES-Modell die folgenden Konstanten verwendet

$$\begin{aligned} C_{DES1} &= 0,78; & C_{DES2} &= 0,61; \\ C_{dt1} &= 20; & C_{dt2} &= 3; & C_w &= 0,15. \end{aligned} \quad (2.82)$$

In den Bereichen, in welchen der LES-Modus aktiv ist, stellt das IDDES-Modell die gleichen Anforderungen an die Erstellung des numerischen Gitters, wie das klassische LES-Modell.

3 Experimentelle Untersuchungen im Windkanal

Ein Ziel der Arbeit ist, auf Basis numerischer Simulationen und datenbasierten Ersatzmodellen die auf Schiffe wirkenden simulierten aerodynamischen Lasten möglichst exakt zu bestimmen. Als Grundlage für die Validierung der numerischen Simulationen und zur Darstellung der Charakteristik und Quantifizierung der aerodynamischen Schiffsumströmung werden Versuche im Windkanal durchgeführt. In den im Rahmen dieser Arbeit durchgeführten Versuchen wird ein Modell eines Containerfeederschiffes benutzt, welches im Anschluss daran im Modellmaßstab validiert und in der Großausführung untersucht wird. Das Modell im Windkanal ist in Abbildung 3.1 dargestellt. Der Schwerpunkt der Experimente liegt dabei in der Messung der auf das Modell wirkenden Kräfte und Momente für unterschiedliche Beladungsfälle sowie Zuströmbedingungen (vgl. Abschnitt 3.3). Zusätzlich werden zeitlich gemittelte Geschwindigkeitsfelder im Nachlauf des Modells mit Hilfe der PIV-Methode (vgl. Abschnitt 3.4) ermittelt. Für eine ausführliche Beschreibung der Strömungsmesstechnik wird auf die Literatur von Eckelmann (1997) und für die PIV-Methode auf Raffel et al. (2007) verwiesen.




Abbildung 3.1: Modell des Containerfeederschiffes mit vollständiger Beladung im Windkanal.

Zur Beschreibung der wirkenden aerodynamischen Kräfte wird ein modell- bzw. schiffsfestes Koordinatensystem X_S , Y_S und Z_S verwendet. Die Orientierung der einzelnen Achsen ist in Ab-




Abbildung 3.2: Windkanalfestes und schiffsfestes Koordinatensystem für die Messungen der aerodynamischen Lasten im Windkanal. Ein positiver Gierwinkel β entspricht einer Zuströmung zum Modell von der Backbordseite.

Abbildung 3.2 dargestellt. Die X_S -Achse zeigt positiv nach vorne, die Y_S -Achse positiv nach Steuerbord und die Z_S -Achse ist positiv nach unten orientiert. Der Ursprung des Koordinatensystems befindet sich auf halber Schiffslänge $L_{pp}/2$ (Mitte des Drehtisches), mittschiffs auf Höhe des Windkanalbodens, bzw. der Wasserlinie. Neben dem schiffsfesten Koordinatensystem wird das windkanalfeste Koordinatensystem X_W, Y_W und Z_W definiert. Entsprechend Abbildung 3.2 zeigt die positive X_W Richtung in Strömungsrichtung, die positive Z_W Richtung vertikal nach unten. Die scheinbare Windrichtung wird mit dem Gierwinkel β zwischen der Zuströmrichtung und der schiffsfesten Längsachse des Modells gemessen. Wind aus Richtung Backbord entspricht einem positiven Winkel β um die Z-Achse. Die auftretenden aerodynamischen Kräfte und Momente werden üblicherweise als:

F_x Widerstandskraft/Längskraft,

F_y Querkraft,

F_z Auftriebskraft,

M_x Rollmoment,

M_y Nickmoment,

M_z Giermoment,

bezeichnet. Für den Fall der aerodynamischen Schiffsumströmung, welcher in dieser Arbeit betrachtet wird, sind die Auftriebskraft und das Nickmoment nicht direkt von Bedeutung. Das Rollmoment hat ebenfalls eine untergeordnete Bedeutung.

3.1 Natürliche Windverhältnisse

Ein Schiff in natürlicher Umgebung auf dem Ozean ist neben dem Eigenfahrtwind auch dem atmosphärischen bzw. meteorologischen Wind ausgesetzt. Die Zuströmung, welche das Über-




Abbildung 3.3: Windprofile durch Eigenfahrtwind (a) und meteorologisch bedingten Wind (b).

wasserschiff erfährt, setzt sich daher aus zwei unterschiedlichen Geschwindigkeitsprofilen zusammen. Beide Geschwindigkeitsprofile sind in Abbildung 3.3 dargestellt. Das Windprofil, welches durch die translatorische Bewegung des Schiffes (Eigenfahrtwind) verursacht wird hat keine Grenzschicht an der Wasseroberfläche und ist daher ein räumlich homogenes Profil, vgl. Abbildung 3.3 (a). Aufgrund der Haftreibung an der Wasseroberfläche bildet sich für den Wind über dem Ozean ein turbulentes Grenzschichtprofil aus (Abbildung 3.3 (b)). Diese in natürlicher Umgebung vorherrschenden Zuströmbedingungen können im Windkanal nicht bzw. nur schwer direkt nachgebildet werden. Die Zuströmung im Windkanal besitzt deshalb leicht abweichende Eigenschaften, auf welche im Abschnitt 3.2 näher eingegangen wird.

Für die Windgeschwindigkeit der atmosphärischen Grenzschicht nach Abbildung 3.3 (b) wird üblicherweise folgendes Profil näherungsweise verwendet

$$u(z) = u_{ref} \left(\frac{z}{z_{ref}} \right)^\alpha \quad (3.1)$$

Die Referenzhöhe z_{ref} , an welcher die Referenzgeschwindigkeit u_{ref} vorliegt wird meistens für den Wert $z_{ref} = 10m$ über der Wasseroberfläche angegeben. Der Exponent liegt für Windprofile über dem Ozean im Bereich $\alpha = 0,11 \dots 0,14$.

Der Winkel des atmosphärischen Windes hängt von der relativen Fahrtrichtung des Schiffes zum Wind ab ($\beta^* = 0^\circ - 360^\circ$), während der Eigenfahrtwind stets von vorne auf das Schiff wirkt ($\beta^* = 0^\circ$). Durch die vektorielle Addition beider Anteile ergibt sich der scheinbare Wind. Sowohl der Absolutwert, als auch der Winkel des scheinbaren Windes variieren aufgrund des atmosphärischen Grenzschichtprofils in der Höhe, wie in Abbildung 3.4 veranschaulicht wird.

3.2 Eigenschaften des Windkanals

Alle experimentellen Untersuchungen am Schiffsmodell werden im Windkanal des Instituts für Fluidodynamik und Schiffstheorie der TU Hamburg durchgeführt. Der Windkanal wurde in Göttinger Bauart als geschlossenes System betrieben. Durch Strömungssiebe vor der Messstrecke




Abbildung 3.4: Scheinbarer Winkel der vektoriellen Zuströmungsgeschwindigkeit in unterschiedlichen Höhen über der Wasseroberfläche.

wird ein räumlich und zeitlich möglichst konstanter Luftstrom mit einem geringen Turbulenzgrad von $Tu < 0,3\%$ erzeugt, der durch

$$Tu = \frac{\sqrt{1/3(\overline{u_x'^2} + \overline{u_y'^2} + \overline{u_z'^2})}}{u_{ref}} \quad (3.2)$$

definiert ist. Der Turbulenzgrad beschreibt dabei die Qualität der Zuströmung im Windkanal. Die 3/4 offene Messstrecke des Kanals hat einen Querschnitt von $3m \times 2m$ und die Länge der Messstrecke beträgt ca. $5m$. In der Messstrecke ist das Modell um 360° rotierbar auf einem Drehteller mit integrierter 6-Komponentenwaage installiert. Die Messung und Auswertung der Kräfte und Momente wird in Abschnitt 3.3 beschrieben.

Windkanalgrenzschicht

Für eine möglichst genaue Übertragung der Messergebnisse der Windkanalversuche auf die Großausführung ist eine exakte Abbildung der natürlichen Windverhältnisse erstrebenswert. Allerdings ist eine genaue Nachbildung der natürlichen Windverhältnisse im Windkanal sehr aufwendig und wird daher im Rahmen dieser Arbeit nicht umgesetzt. Für die reine Validierung der numerischen Methoden ist dies ohnehin nicht erforderlich. Die gemessenen Lasten sind hingegen nur begrenzt auf die Großausführung unter realen Bedingungen übertragbar.

Durch die Haftreibung der Strömung am Boden des Windkanals bildet sich eine Grenzschicht aus. Das Schiffsmodell wird bündig über dem Windkanalboden eingebracht und die Zuströmung zum Modell wird durch die Windkanalgrenzschicht bestimmt. Das Geschwindigkeitsprofil der Windkanalgrenzschicht unterscheidet sich dabei deutlich vom natürlichen Grenzschichtprofil über dem Ozean, welches in Abschnitt 3.1 erläutert wird. Mit Hilfe mehrerer übereinander angeordneter Staudrucksonden lässt sich das Grenzschichtprofil erfassen. Das so in der Mitte des Drehtellers gemessene Grenzschichtprofil ist in Abbildung 3.5 dargestellt. Um dieses Grenzschichtprofil für die numerischen Simulationen als Randbedingung anzuwenden, wird es mit

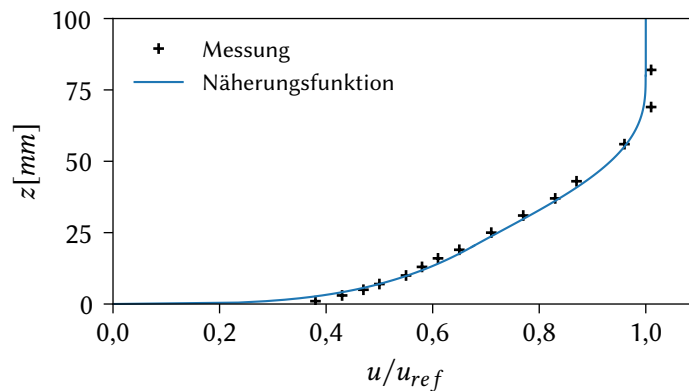


Abbildung 3.5: Gemessenes Grenzschichtprofil am Boden des Windkanals in der Mitte der Messstrecke. Zum Vergleich ist die analytische Funktion zur Näherung des Geschwindigkeitsprofils ebenfalls abgebildet.

folgendem analytischen Profil angenähert

$$\frac{u(z)}{u_{ref}} = \begin{cases} \left(\frac{z}{80,0}\right)^{0,285} & \text{für } z \leq 20\text{mm} \\ 3,111 \cdot 10^{-8}z^4 - 6,578 \cdot 10^{-6}z^3 + 3,84 \cdot 10^{-4}z^2 & \text{für } 20\text{mm} \leq z \leq 80\text{mm} \\ +1,136 \cdot 10^{-3}z + 0,5449 & \\ 1 & \text{für } z > 80\text{mm}. \end{cases} \quad (3.3)$$

3.3 Messung der Kräfte und Momente

Die Messung der Kräfte und Momente im Windkanal erfolgt über eine 6-Komponentenwaage, welche unterhalb der Messstrecke installiert ist. Im Drehteller der Waage ist eine Aufnahme für das Modell integriert. Die Kraftübertragung zwischen Modell und Waage erfolgt reibungsfrei. Das Modell und die Waage werden gedreht, um einen vorgegebenen Gierwinkel einzustellen. Die Längsachse der Kraftmessung stimmt immer mit der Längsachse des Modells überein bzw. mit der X_S -Achse des schiffsfesten Koordinatensystems (Abbildung 3.2). Der Gierwinkel der gesamten Einheit ist über den kompletten Winkelbereich $\beta = 0^\circ - 360^\circ$ einstellbar. Innerhalb der Waage werden die unterschiedlichen Lasten über Stäbe auf insgesamt 6 Kraftmessdosen übertragen. Dort wird die lastproportionale Spannung elektronisch aufgenommen und weiterverarbeitet. Die Kraftkomponenten sind weitestgehend voneinander entkoppelt. Weitere Ungenauigkeiten werden durch die Kalibrierung der Waage ausgeglichen.

Aufgrund der Bauweise der Waage ist die Messung der Kräfte träge und es können nur stationäre Kräfte gemessen werden. Im vorliegenden Fall unterliegen die Lasten großen instationären Schwankungen, allerdings sind in dieser Arbeit die zeitlichen Mittelwerte der Kräfte und Momente von Interesse. Die zeitliche Mittelung der Lasten erfolgt über einen ausreichend großen

Zeitraum von $T = 10s$.

3.4 PIV-Messungen

Bei der PIV-Methode (engl. particle image velocimetry) handelt es sich um ein berührungsloses optisches Verfahren zur Bestimmung räumlicher Geschwindigkeitsfelder. Hierzu werden Partikel in das Fluid eingebracht, die durch einen Laserschnitt in einer Messebene beleuchtet werden. Es werden mehrere Bilder in kurzen Abständen über einen Zeitraum von $T = 10s$ aufgenommen. Basierend auf Korrelationstechniken werden die Lichtpunkte bzw. Partikel der einzelnen Aufnahmen ausgewertet und daraus die zeitlich gemittelten Geschwindigkeiten in der Messebene bestimmt.

Für die Analyse des Geschwindigkeitsfeldes im Nachlauf hinter dem Deckshaus werden drei Ebenen für die Auswertung der Geschwindigkeiten ausgewählt. Diese befinden sich $0,15m$ ($X_S = -0,85$), $0,3m$ ($X_S = -1,00$) und $0,45m$ ($X_S = -1,15$) hinter dem Spiegel des Modells. Die mit Hilfe der PIV-Technik aufgenommenen Geschwindigkeitsfelder werden in Abschnitt 4.3 ausgewertet und mit den Simulationsergebnissen verglichen.

3.5 Windkanalmodell eines Containerfeederschiffes

Die Windkanalversuche werden an einem Modell eines Containerfeederschiffes durchgeführt. Das Containerschiff in der Großausführung hat eine Kapazität von 925 TEU und 12110 TDW. Die Länge über Alles (LoA) beträgt $LoA_S = 140m$ und die Breite $B_S = 22,8m$. Das Modell ist im Maßstab $\lambda = 1 : 100$ gefertigt und hat daher eine Länge von $LoA_M = 1,40m$ und eine Breite von $B_M = 0,22m$. Einige Details des realen Schiffes, wie z.B. Krane, das Rettungsboot und die Reling, können im Modellmaßstab nicht übernommen werden, wobei der Einfluss dieser Details auf die Umströmung vernachlässigbar gering ist (Blendermann, 1986). Das Deckshaus weist im hinteren Bereich eine Asymmetrie auf. Die Umströmung des Überwasserschiffes wird bei Containerschiffen stark durch die Verteilung der Ladung an Deck beeinflusst. Bei Containerschiffen variiert die dem Wind ausgesetzte Geometrie durch die unterschiedliche Stauung von Containern an Deck stark. Die Stauung der Container hat folglich einen signifikanten Einfluss auf die aerodynamischen Kräfte, wie bereits in Arbeiten von Blendermann (1997) und Andersen (2013) gezeigt wurde.

Für die Modellversuche werden drei unterschiedliche Konfigurationen für die Verteilung der Container an Deck betrachtet. Eine Konfiguration ohne Decksladung (Konfiguration A), eine zweite mit teilweiser Beladung (Konfiguration B) sowie eine weitere maximal möglicher Beladung (Konfiguration C). Die Konfiguration mit teilweiser Beladung tritt am häufigsten im realen Betrieb des Schiffes auf. Die unterschiedlichen Beladungskonfigurationen sind in Abbil-

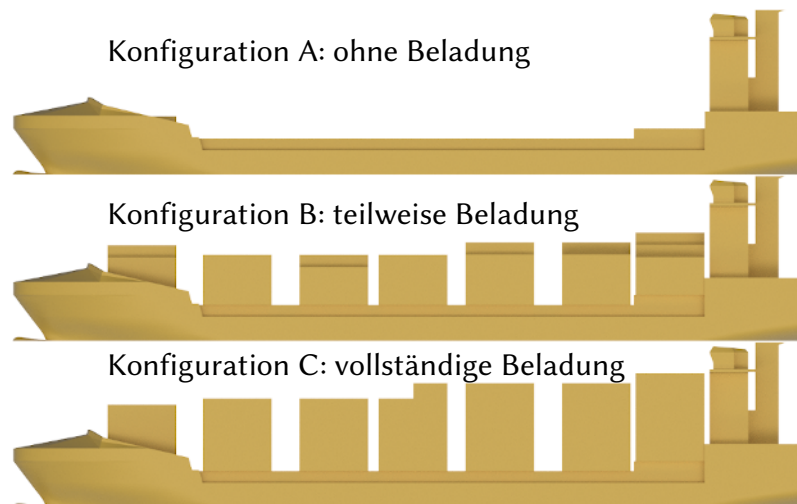


Abbildung 3.6: Darstellung der unterschiedlichen im Windkanal untersuchten Beladungsfälle des Modells des Containerfeederschiffes.

dung 3.6 dargestellt. Für den teilweisen Beladungsfall sind die Container asymmetrisch verteilt. Die durch die Abmessungen des Modells verursachte Versperrung im Messbereich des Windkanals ist für den Fall mit Zuströmung von vorne ($\beta = 0^\circ$) ca. 1% und für seitliche Zuströmung ($\beta = \pm 90^\circ$) im Bereich 2 – 4% abhängig vom Beladungsfall.

3.6 Ergebnisse der Kraft- und Momentenmessung im Windkanal

Alle Messungen werden bei geometrischer Ähnlichkeit durchgeführt. Die dynamische Ähnlichkeit kann dabei nicht eingehalten werden und die Reynoldszahl im Modellversuch Re_M unterscheidet sich von der in der Großausführung Re_S . Für die Reynoldszahlen der Großausführung und des Modells ergeben sich bei einem Maßstab von $\lambda = 100$, bei gleichen Fluideigenschaften sowie der gleichen Geschwindigkeit ein Verhältnis von $Re_S = 100 \cdot Re_M$. Die Reynoldszahl der Windkanalversuchen ist dabei $Re = 1,8 \cdot 10^6$, basierend auf einer Zuströmgeschwindigkeit von $u_{ref} = 20m/s$. Wie bereits in Abschnitt 2.3.3 dargestellt, löst die Strömung stark an den unterschiedlichen Kanten des Modells ab und es wird von einem geringen Reynoldszahleneinfluss auf die Umströmung des Überwasserschiffes ausgegangen. Zudem hat sich in den Versuchen durch eine Variation der Geschwindigkeit von $u = 15m/s$ und $u = 25m/s$ kein messbarer Einfluss auf die dimensionslosen Kräfte gezeigt, weshalb Transitionseffekte ausgeschlossen werden können.

Die Kräfte F_X und F_Y und das Momente M_Z werden im schiffsfesten Koordinatensystem ange-

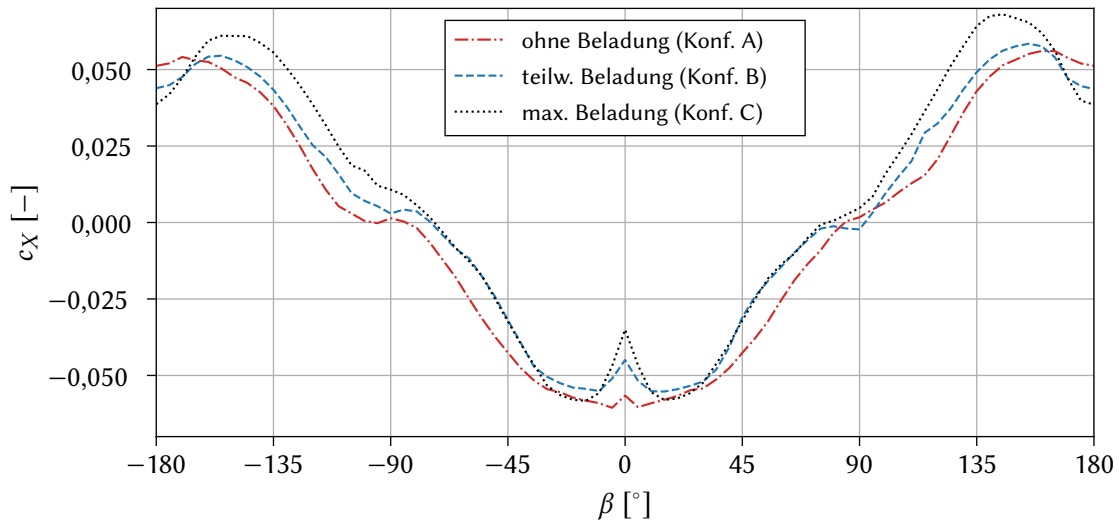


Abbildung 3.7: Verlauf der gemessenen dimensionslosen Längskräfte c_x (X-Richtung) im Windkanal für drei unterschiedlichen Beladungskonfigurationen.

geben (vgl. Abbildung 3.2) und werden wie folgt dimensionslos dargestellt

$$c_x = \frac{F_x}{0.5 \cdot \rho \cdot u_{ref}^2 \cdot A}, \quad (3.4)$$

$$c_y = \frac{F_y}{0.5 \cdot \rho \cdot u_{ref}^2 \cdot A}, \quad (3.5)$$

$$c_{MZ} = \frac{M_z}{0.5 \cdot \rho \cdot u_{ref}^2 \cdot A \cdot L}. \quad (3.6)$$

Neben der Dichte ρ und der Zuströmgeschwindigkeit u_{ref} wird für die Fläche $A = 1m^2$ verwendet. Dadurch skalieren die dimensionslosen Beiwerte mit der Größe der gemessenen Kräfte und lassen sich für die unterschiedlichen Beladungszustände direkt vergleichen. Für die Momente wird entsprechend zusätzlich die Länge $L = 1m$ verwendet. Die statistischen 99% Konfidenzintervalle der Messungen betragen für die Längskraft $c_x \pm 4,8 \cdot 10^{-4}$, für die Querkraft $c_y \pm 4,8 \cdot 10^{-4}$ und für das Giermoment $c_{MZ} \pm 2,2 \cdot 10^{-4}$.

Die Messungen der Kräfte werden für die drei unterschiedlichen Beladungskonfigurationen (vgl. Abbildung 3.6) über den gesamten Winkelbereich $\beta = 0^\circ - 360^\circ$ mit einem Inkrement von $\Delta\beta = 5^\circ$ durchgeführt. Die in Längsrichtung gemessenen Kräfte für die drei betrachteten Beladungsfälle sind in Abbildung 3.7 dimensionslos aufgetragen. Für die Anströmung von vorne unter $\beta = 0^\circ$ unterscheiden sich die Kräfte für die drei Beladungsfälle deutlich. Für den Fall der vollständigen Containerbeladung wird die geringste Kraft, für den Fall ohne Container an Deck die größte Kraft gemessen. Diese Beobachtung stimmt mit den Ergebnissen von Blendermann




Abbildung 3.8: Verlauf der gemessenen Querkräfte c_Y (Y-Richtung) im Windkanal für drei unterschiedlichen Beladungskonfigurationen.

(1997) überein. Die Asymmetrie im hinteren Bereich des Deckshaus wirkt sich auf den Verlauf der Kräfte im Bereich $\beta = \pm 90^\circ \dots \pm 180^\circ$ aus. In Abbildung 3.8 sind die jeweils gemessenen Querkräfte (Y-Richtung) für die drei betrachteten Containerkonfigurationen aufgetragen. Der Betrag der gemessenen Querkräfte skaliert dabei überproportional mit der jeweiligen seitlich projizierten Fläche der Beladungsfälle und erreicht sein Maximum bei etwa 60° aufgrund des Lee-seitigen Wirbels mit starkem Unterdruck. Das in den Windkanalversuchen gemessene Giermoment, welches um die Z-Achse wirkt, ist in Abbildung 3.9 über dem Zuströmwinkel dargestellt. Im Bereich der Anströmung von vorne $\beta = 0^\circ \dots \pm 90^\circ$ ist das Giermoment relativ klein. Der maximale Betrag des Giermomentes wird jeweils bei schräg achterlicher Anströmung des Modells gemessen ($\beta \approx 130^\circ$).

In Übereinstimmung mit Arbeiten anderer Autoren zeigt sich auch für das hier betrachtete Containerfeederschiff ein deutlicher Einfluss der Containerbeladung auf die wirkenden aerodynamischen Lasten. Bei Zuströmung direkt von vorne sind die Unterschiede der Längskräfte am größten. Die Maximalwerte der Querkräfte skalieren weitestgehend mit der projizierten Fläche in Querrichtung. Durch die festgelegten Bedingungen im Windkanal lassen sich die Messungen nicht direkt auf reale Bedingungen auf See übertragen. Der Fokus der Messungen liegt hier in der Bereitstellung geeigneter Validierungsdaten für die Beurteilung der Ergebnisse der numerischen Simulationemethode im nächsten Kapitel.

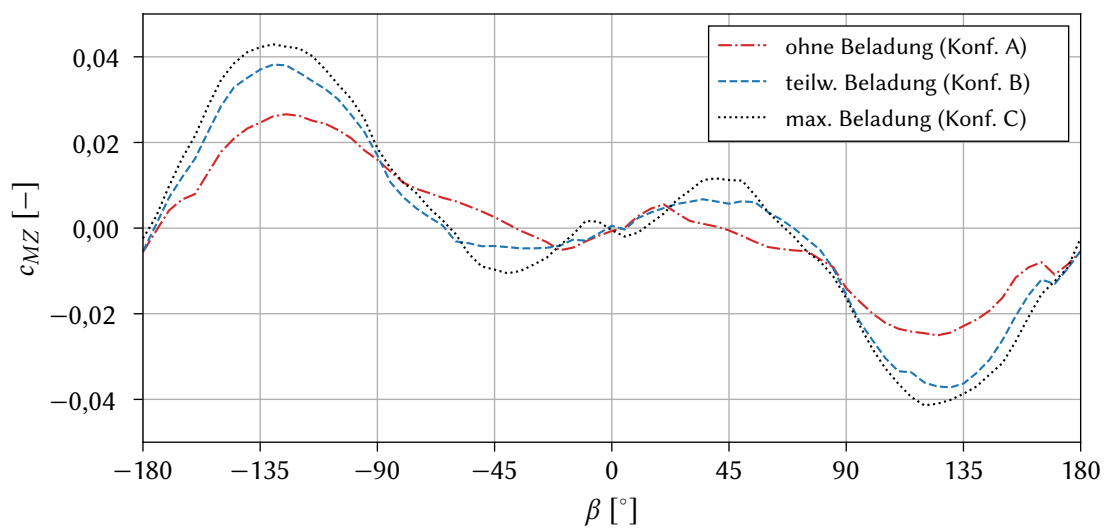


Abbildung 3.9: Verlauf der gemessenen Giermomente c_{M_Z} (Z-Achse) im Windkanal für drei unterschiedlichen Beladungskonfigurationen.

4 Simulation der aerodynamischen Schiffsumströmung

Zusätzlich zu den durchgeführten experimentellen Untersuchungen im Windkanal werden numerische Simulationen zur Bewertung der Umströmung des Überwasserschiffes für unterschiedliche Betriebs- und Umgebungsbedingungen herangezogen. Die durchgeführten Windkanalmessungen dienen als Validierungsgrundlage für die eingesetzten numerischen Simulationen. Um für die Validierung die Vergleichbarkeit der Messungen und Simulationen zu gewährleisten, werden die Simulationen unter den gleichen Bedingungen wie die experimentellen Versuche durchgeführt. Insbesondere wird die Versperrung durch das Modell im Windkanal durch die Wahl und Positionierung der Randbedingungen der numerischen Simulationen nachgebildet.

In diesem Kapitel folgt zunächst eine Übersicht über die unterschiedlichen Simulationsparameter und Randbedingungen. Der Einfluss der Gitterauflösung auf die Simulationsergebnisse wird im darauf folgenden Abschnitt beschrieben. Außerdem werden die Ergebnisse der skalenauflösenden hybriden Turbulenzmodellierung und der URANS-Modellierung für die aerodynamische Schiffsumströmung verglichen. Im Anschluss werden die im Windkanal gemessenen Kräfte mit den simulationsbasierten Kräften und die PIV-basierten Geschwindigkeitsfelder mit den simulationsbasierten Geschwindigkeitsfeldern verglichen, um die verwendeten numerischen Methoden abschließend zu validieren.

4.1 Simulationssetup

Im Folgenden wird ein Überblick über die gewählten Simulationsparameter gegeben, die zunächst für die Validierung der numerischen Methoden und später für die Simulationen zur Erstellung der Daten für die Ersatzmodelle in Kapitel 7 gewählt werden.

Die numerischen Simulationen werden mit dem gleichen Maßstab ($\lambda = 100$) wie die Windkanalversuche durchgeführt (vgl. Abschnitt 3.5). Die Geometrie entspricht dabei hinsichtlich des Detaillierungsgrades ebenfalls dem Windkanalmodell. Die Zuströmgeschwindigkeit $u_{ref} = 20\text{m/s}$ wird ebenfalls gleich gewählt, wodurch die Reynoldszahl $Re = 1,8 \cdot 10^6$ beträgt.

Die Geometrie wird bei Schräganströmung um die Z-Achse rotiert.

Die Randbedingungen des Simulationsgebietes werden so gewählt, dass sie soweit möglich mit den Bedingungen im Windkanal übereinstimmen. Dies ist wichtig, um die Vergleichbarkeit der numerisch und experimentell bestimmten Lasten zu gewährleisten (Koop et al., 2012; Janssen et al., 2017). Am Einlassrand werden das Geschwindigkeitsprofil des Windkanals sowie die gemittelten RANS-Turbulenzgrößen vorgegeben. Aufgrund der geometrisch definierten Positionen der Ablösung ist allerdings von einem geringen Einfluss der am Einlassrand vorgegebenen Turbulenzgrößen auszugehen. Die seitliche und obere Begrenzung der Messstrecke im Windkanal ist zum Plenum hin offen, wodurch die Strömung etwas aufweitet. Dies wird in der Simulation nicht berücksichtigt, stattdessen werden an der seitlichen und oberen Begrenzung des Rechengebietes reibungsfreie Wände vorgegeben. Die seitliche Abmessung des Rechengebietes ($3m$) und dessen Höhe ($2m$) entsprechen dabei den Abmessungen der Messstrecke im Windkanal. Die Versperrung bei Anströmung von vorne ($\beta = 0^\circ$) beträgt ca. 1% und bei seitlicher Zuströmung ($\beta = 90^\circ$) maximal 4% und entspricht der Versperrung im Windkanalversuch. Bei der Durchströmung der Messstrecke im Windkanal verändert sich das Grenzschichtprofil im Bodenbereich über die Lauflänge. In der Simulation hingegen wird vereinfacht das Windkanalgrenzschichtprofil in der Mitte der Messstrecke direkt am Einlass vorgegeben. Damit dieses nicht von der Randbedingung am Boden des Simulationsgebietes beeinflusst wird, ist dort ebenfalls eine reibungsfreie Wand definiert. Am Auslass des Rechengebietes wird ein konstanter Druck vorgegeben.

Die räumliche Diskretisierung des Rechengebietes erfolgt durch ein unstrukturiertes Hexaedergeritter. Bei schräger Zuströmung zum Modell wird die Ausrichtung des Gitters der Ausrichtung des Modells angepasst. Im Nahbereich des Modells und im Nachlauf werden soweit möglich isotrope Zellen eingebracht, um den Anforderungen der skalenauflösenden Turbulenzmodellierung in stark abgelösten Strömungen gerecht zu werden. Der Einfluss der Gitterauflösung auf die Ergebnisse der Simulation wird im Abschnitt 4.2 detailliert beschrieben.

Für die Turbulenzmodellierung wird das auf dem $k - \omega$ -SST-Modell basierende IDDES-Modell (vgl. Abschnitt 2.4.4) verwendet. In Abschnitt 4.3 werden zusätzlich Simulationen mit einem einfachen instationären RANS-Verfahren ($k - \omega$ -SST-Modell vgl. Abschnitt 2.4.1) durchgeführt. Die Notwendigkeit zur Verwendung eines hybriden, teilweise skalenauflösenden Modells wird durch den Vergleich der Ergebnisse für beide Turbulenzmodelle aufgezeigt.

Für eine hybride RANS/LES-Simulation werden im LES aktiven Bereich die gleichen Anforderungen an das Konvektionsschema gestellt, wie für eine reine LES-Simulation. Die LES-Turbulenzmodellierung basiert unter anderem auf der Annahme, dass die Dissipation der kleinen Wirbelstrukturen vollständig durch das Sub-Grid-Scale (SGS)-Modell erfasst wird. Neben

dieser modellierten turbulenzbasierten Dissipation treten die viskositätsbedingte molekulare Dissipation und, in Abhängigkeit der Approximation der Konvektionsterme, zusätzlich numerische Diffusion auf. Die numerische Diffusion kann dabei größer als die Turbulenzmodellbasierte Dissipation sein. Wird zum Beispiel eine UDS-Approximation gewählt, werden die turbulenten Schwankungen großer Wellenzahlen gedämpft (Mockett, 2009). Daher sollte das eingesetzte numerische Verfahren eine geringe numerische Diffusion aufweisen oder die Modellkonstanten auf das Konvektionsschema abgestimmt werden. Dazu wird in dieser Arbeit für die Diskretisierung der konvektiven Terme ein hybrides Verfahren aus Zentraldifferenzen (CDS) und QUICK-Verfahren basierend auf dem κ -Schema (2.23) angewendet. Die CDS/QUICK Gewichtung erfolgt dabei im Verhältnis 80/20 und wird mittels des κ -Schemas umgesetzt ($\kappa = 0,9$). Dies ermöglicht eine geringe numerische Diffusion bei gleichzeitiger ausreichender numerischer Stabilität. Da im Bereich starker Ablösegebiete, welche sich geometrieinduziert aufgrund der Umströmung scharfer Kanten ausbilden, der Einfluss der numerischen Diffusion geringer ist (Mockett, 2009), ist anzunehmen, dass mit diesem Vorgehen eine ausreichende Genauigkeit der Simulationsergebnisse erreicht wird.

Der Einfluss wandnaher Effekte auf die Außenströmung wird durch Wandfunktionen gesteuert. Der Zielwert für den dimensionslosen Abstand der wandnächsten Gitterzellen ist in dieser Studie $y^+ \approx 50$. Grundsätzlich ist der Einsatz von Wandfunktionen für nicht-gleichgewichtige bzw. abgelöste Grenzschichten diskutabel. In der gezeigten Untersuchung ist nur ein geringer Einfluss der Grenzschicht auf die Außenströmung zu erwarten, da die Strömung von den geometrieinduzierten Ablösegebieten dominiert wird.

Die zeitliche Diskretisierung erfolgt basierend auf drei Zeitschrittebenen (vgl. Abschnitt 2.2.2). Der Zeitschritt skalenauflösender Simulationen muss klein genug gewählt werden, um zeitbasierte Filtereffekte der aufgelösten turbulenten Fluktuationen zu vermeiden. Um eine Balance zwischen zeitlicher und räumlicher Auflösung des Verfahrens zu gewährleisten, wird eine Courantzahl im Bereich $Co = \Delta t U / \Delta x < 1$ für das gesamte Simulationsgebiet angestrebt (Spalart und Strelets, 2001), wobei für die Gitterweite Δx zur Berechnung der Courantzahl der mittlere Gitterabstand des im Ablösegebiet isotropen Gitters verwendet wird. Dadurch wird eine gute Vorhersagequalität des Strömungsfeldes sichergestellt. Wegen des impliziten Ansatzes handelt es sich dabei nicht um ein Kriterium zur Sicherstellung der numerischen Stabilität.

Aufgrund des turbulenten und stark instationären Strömungsfeldes sind die auf das Modell wirkenden Kräfte zeitlich ebenfalls stark fluktuierend. Die Qualität der zeitlich gemittelten Strömungsgrößen hängt daher vom Zeitraum der Mittelung ab. In Abbildung 4.1 ist der zeitliche dimensionslose Kraftverlauf beispielhaft für die Simulation mit teilweiser Beladung und Zuströmung von vorne ($\beta = 0^\circ$) dargestellt. Die Dauer der Simulation beträgt 40000 Zeitschritte, was einer Gesamtdauer von $T = 3s$ oder $T \cdot u_{ref} / L_{oA} \approx 42$ Schiffslängenüberströmungen entspricht. Die Kräfte des ersten Teils der Simulation werden verworfen, da die Strömung noch

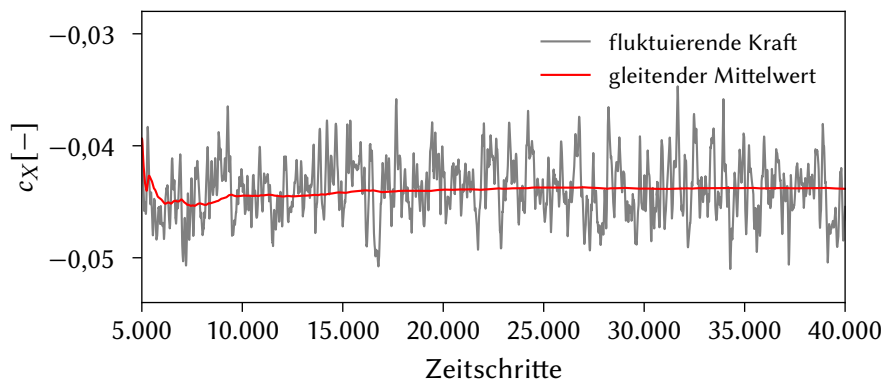


Abbildung 4.1: Vergleich des turbulenzbedingten fluktuierenden dimensionslosen Kraftverlaufs über die Zeitschritte mit dem gleitenden Mittelwert.

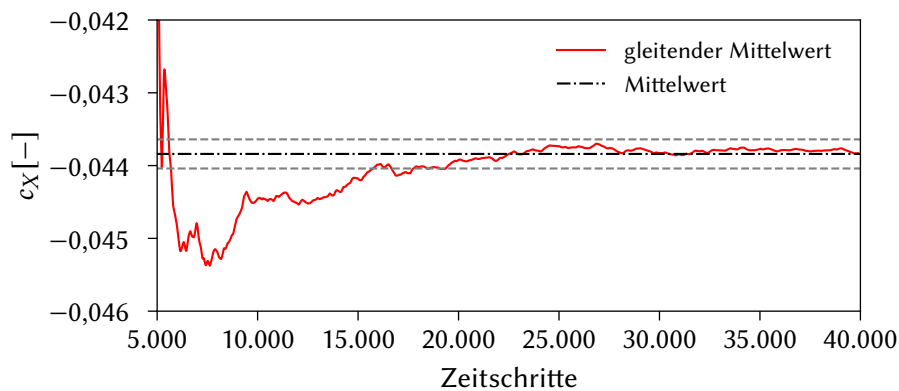


Abbildung 4.2: Abschätzung der statistischen Unsicherheit auf Basis der zeitlichen dimensionslosen Mittelung der Kräfte.

nicht vollständig ausgebildet ist. Daher werden die Kraftwerte der ersten 5000 Zeitschritte ($T = 0,375s$) nicht für die Mittelung verwendet.

Ein statistischer Konvergenzfehler existiert auch nach einem sehr langen Mittelungszeitraum. Um eine Abschätzung des Konvergenzfehlers zu ermöglichen, wird der gleitende Mittelwert der Beispielsimulation in Abbildung 4.2 im Vergleich zum Mittelwert am Ende der Mittelung gezeigt. Auf Grundlage der eingezeichneten gestrichelten Grenzen in Abbildung 4.2 erfolgt eine konservative Abschätzung des zu erwartenden Konvergenzfehlers im Bereich von $\pm 2 \cdot 10^{-4}$, was einem prozentualen Fehler von $\pm 0,5\%$ entspricht. Zum Vergleich beträgt das statistische 99% Konfidenzintervall des Mittelwertes basierend auf der Standardabweichung des Mittelwertes $\pm 3,6 \cdot 10^{-5}$, woraus sich ein prozentualer Fehler von $< \pm 0,1\%$ ergibt.

4.2 Einfluss der Gitterauflösung

Die skalenauflösende Turbulenzmodellierung stellt besondere Anforderungen an das numerische Gitter. Die Auflösung des Gitters muss fein genug sein, um einen Großteil der relevanten Wirbelstrukturen räumlich abzubilden. Daher wird im Folgenden die Sensitivität der Gitterauflösung auf die zeitlich gemittelten Felder und Kräfte der Simulationsergebnisse untersucht und dargestellt.

Für den Bereich der Strömung mit aktivierter skalenauflösender Modellierung des hybriden Modells gelten die gleichen Anforderungen an das Gitter, wie bei einer reinen LES-Simulation. Häufig wird als Messgröße der aufgelösten Turbulenz das Verhältnis der aufgelösten zur modellierten turbulenten kinetischen Energie verglichen. Pope (2000) gibt für dieses Verhältnis an, dass der Anteil der aufgelösten turbulenten Energie mindestens 80% betragen sollte. Im Bereich stark abgelöster Strömung ist allerdings fraglich, wie aussagekräftig der Vergleich der aufgelösten und modellierten kinetischen Energie ist (Davidson, 2009; Mockett, 2009). Davidson (2009) schlägt daher die Betrachtung von Zweipunktkorrelationen zur Beurteilung der Gitterauflösung vor. Weiterhin beschreibt Mockett (2009) eine geringe Sensibilität der Lösung auf unterschiedliche Niveaus der Wirbelviskosität stromauf des Ablösegebietes bei Anwendung hybrider Turbulenzmodellierung für eine Profilmströmung bei großem Anstellwinkel und starker Ablösung. Eine größere Wirbelviskosität in Gebieten stromauf der Ablösung führt damit nicht zu einer geringeren Instabilität im Ablösegebiet. Es wird davon ausgegangen, dass der geforderte Anteil aufgelöster Turbulenz von 80% ist in dem stromauf-liegenden Bereich daher kein sinnvolles Gütekriterium für Strömungsprobleme mit Geometrie-induzierter und stark ausgeprägter Ablösung ist. Die aerodynamische Schiffsumströmung ist aufgrund der Geometrie des Überwasserschiffes ebenfalls von starker Ablösung geprägt. Daher wird von einer geringen Sensitivität der Lösung gegenüber unterschiedlicher Level der Wirbelviskosität stromauf der Ablösung ausgegangen.

Um den Einfluss der Gitterauflösung auf die Umströmung des Überwasserschiffes zu quantifizieren, werden die numerischen Lösungen und die daraus bestimmten aerodynamischen Lasten für vier unterschiedliche Gitterauflösungen verglichen. Zur Beurteilung der in der numerischen Simulation aufgelösten turbulenten Skalen werden ergänzend die Zweipunktkorrelationen an einem Referenzpunkt im Nachlauf des Deckshauses ausgewertet. Zusätzlich werden die aufgelöste und die modellierte turbulente kinetische Energie im Strömungsfeld bewertet. Der modellierte Anteil der turbulenten kinetischen Energie k_{mod} liegt direkt als Transportgröße vor (vgl. Gleichung (2.51)) und wird zur Bewertung über die letzten 35000 Zeitschritte der Simulation gemittelt. Die zeitlich gemittelte Größe wird mit \bar{k}_{mod} bezeichnet. Die Bestimmung des aufgelösten Anteils der turbulenten kinetischen Energie basiert auf der Auswertung und zeitlichen Mittelung der turbulenten Fluktuationen des Geschwindigkeits-

vektors im Strömungsfeld. Die zeitlich gemittelten Reynoldsspannungen werden kumulativ während der numerischen Simulation bestimmt

$$\overline{u'_i u'_j}(\mathbf{x}) = \frac{1}{N} \sum_{t=1}^N (u_i(\mathbf{x}, t) - \bar{u}_i(\mathbf{x}, t))(u_j(\mathbf{x}, t) - \bar{u}_j(\mathbf{x}, t)). \quad (4.1)$$

Basierend auf der Spur des zeitlich gemittelten Reynoldsspannungstensors wird der aufgelöste Anteil der turbulenten kinetischen Energie für jeden Feldpunkt \mathbf{x} berechnet

$$\bar{k}_{res} = \frac{1}{2} \overline{u'_i u'_i}. \quad (4.2)$$

Zur Beurteilung der aufgelösten turbulenten Fluktuationen wird das Verhältnis γ der aufgelösten zur gesamten turbulenten kinetischen Energie im Strömungsfeld ausgewertet

$$\gamma = \frac{\bar{k}_{res}}{\bar{k}_{mod} + \bar{k}_{res}}. \quad (4.3)$$

Als weiteres Kriterium zur Beurteilung der Gitterauflösung bei skalenauflösenden Simulationen dienen Zweipunktkorrelationen. Diese werden basierend auf den instantanen Fluktuationen für die jeweiligen Geschwindigkeitskomponenten bezogen auf einen Referenzpunkt im Strömungsfeld ausgewertet. Auch für die Zweipunktkorrelationen erfolgt eine zeitliche Mittelung über die letzten 35000 Zeitschritte der Simulation. Für die drei unterschiedlichen Raumrichtungen und die zugehörigen Geschwindigkeitskomponenten werden die Zweipunktkorrelationen wie folgt bestimmt

$$B_{uu}(\hat{x}) = \overline{u'(x)u'(x - \hat{x})}, \quad (4.4)$$

$$B_{vv}(\hat{y}) = \overline{v'(y)v'(y - \hat{y})}, \quad (4.5)$$

$$B_{ww}(\hat{z}) = \overline{w'(z)w'(z - \hat{z})}. \quad (4.6)$$

Die Zweipunktkorrelationen werden mit der zugehörigen Reynoldsspannung normiert. Der Wert der Zweipunktkorrelation am Punkt der Auswertung $\hat{x} = 0, \hat{y} = 0, \hat{z} = 0$ entspricht der jeweiligen Reynoldsspannung.

Um den Einfluss der Gitterauflösung auf die Simulationsergebnisse zu quantifizieren, werden vier unterschiedliche Gittervarianten (A - D) betrachtet. Alle Gittervarianten beziehen sich auf den Fall der teilweisen Containerbeladung und Wind von vorne ($\beta = 0^\circ$) im Modellmaßstab. Von der groben Gitterauflösung A ausgehend wird die Anzahl der Zellen im Bereich über der Schiffsgeometrie und dem Nachlauf hinter dem Deckshaus jeweils verdoppelt. Die Auflösung des Gitters an der Oberfläche der Geometrie ist für alle Varianten gleich, da ansonsten die Topologie der Geometrie nicht durch das Gitter diskretisiert wird. Die resultierenden isotro-

Tabelle 4.1: Übersicht der vier unterschiedlichen Gittervarianten A - D und der zugehörigen zeitlich gemittelten Kraftbeiwerten sowie die jeweilige prozentuale Abweichung zur Windkanalmessung.

Variante	Anzahl KVs [$\cdot 10^6$]	$\Delta_x = \Delta_y = \Delta_z$ [m]	Kraftbeiwert c_x [-]	Abweichung [%]
A	1,9	0,025	-0,0432	3,8
B	2,3	0,0125	-0,0446	0,7
C	4,1	0,00625	-0,0444	1,1
D	15,3	0,003125	-0,0432	3,8
Windkanal			-0,0449	

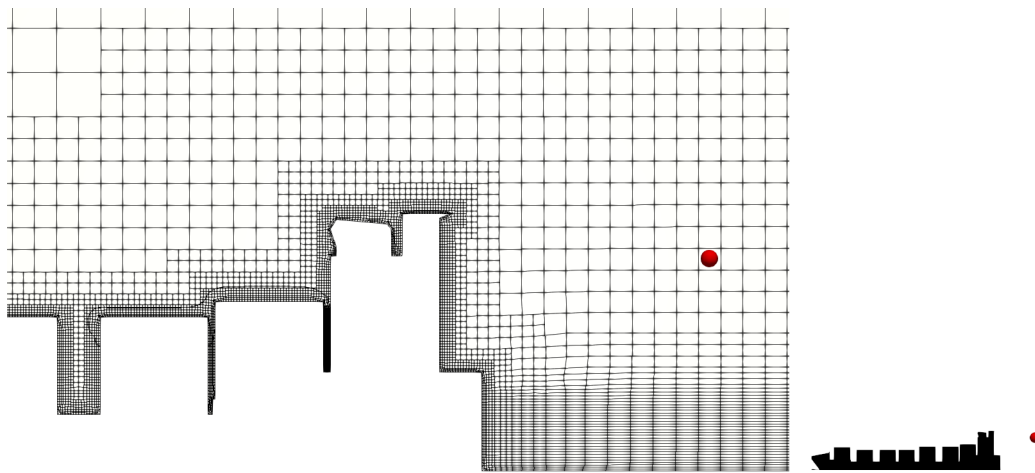


Abbildung 4.3: Position zur Auswertung der Zweipunktkorrelation im Nachlauf hinter dem Deckshaus. Hier dargestellt ist die Gittervariante A.

pen Gitterabstände $\Delta_x = \Delta_y = \Delta_z$ im Bereich über der Schiffsgeometrie und im Nachlauf des Deckshauses sowie die resultierende Anzahl an Kontrollvolumen sind in Tabelle 4.1 zusammengefasst.

Für die vier unterschiedlichen Gittervarianten A - D sind die zeitlich gemittelten integralen Längskraftbeiwerte (3.4) ebenfalls in Tabelle 4.1 dargestellt. Die tabellierten Werte zeigen keine klare Tendenz für eine Abhängigkeit der bestimmten Kraftbeiwerte von der Gitterauflösung. Für alle Gittervarianten stimmen die bestimmten Längskräfte gut mit dem Ergebnis der Windkanalmessung $c_x = -0,0449$ überein. Die größten Abweichungen von den Messungen treten dabei mit 3,8% für die Gittervarianten A und D auf. Für die Varianten B und C sind die Abweichungen mit 0,7% und 1,1% etwas geringer.

Die Zweipunktkorrelationen werden an einem Punkt $x = -0,95m; y = 0m; z = -0,25m$ im Nachlauf hinter dem Deckshaus ausgewertet. Die genaue Position der Auswertung ist in Abbildung 4.3 dargestellt. Im Bereich der Auswertung der Korrelationen ist das Gitter wegen der isotropen Kontrollvolumen quasi strukturiert, wodurch eine einfache Auswertung der Zweipunktkorrelation ermöglicht wird. Die Auswertung erfolgt für einen Punkt, wodurch die




Abbildung 4.4: Zweipunktkorrelation der X-Geschwindigkeitskomponente u in Längsrichtung (X-Richtung).

Aussagekraft der Zweipunktkorrelationen räumlich beschränkt ist. Da jedoch ein Großteil der Instabilität der Strömung durch die Ablösung am Deckshaus verursacht wird, ist zu erwarten, dass die Auflösung der Wirbelstrukturen im Nachlauf des Deckshauses die Strömung dominiert. Die Verläufe der ausgewerteten Zweipunktkorrelationen sind in den Abbildungen 4.4-4.6 jeweils für die vier betrachteten Gittervarianten A - D dargestellt. Mit Hilfe der Zweipunktkorrelationen lassen sich die durchschnittlichen Abmessungen der turbulenten Wirbel abschätzen. Es kann somit die Anzahl der verwendeten Kontrollvolumen zur Auflösung einer charakteristischen Wirbelstruktur quantifiziert werden. Es wird angenommen, dass normierte Zweipunktkorrelationen im Bereich $B/\overline{u_i'u_i} > 0,3$ zur selben Wirbelstruktur gehören. Die Anzahl der Zellen für die Auflösung einer durchschnittlichen turbulenten Wirbelstruktur wird mit n_{KV} bezeichnet. In Abbildung 4.4 ist die Zweipunktkorrelation für die Längsgeschwindigkeit u und damit der Hauptströmungsrichtung dargestellt. Es zeigt sich deutlich, dass mit feiner werdender Gitterauflösung die Größe der durchschnittlichen turbulenten Wirbelstrukturen abnimmt. Für Gittervariante A ist diese im Bereich von $0,25L_{pp}$, für Gittervariante D bei ca. $0,08L_{pp}$. Während die Größe der durchschnittlichen Wirbelstrukturen für ein feiner aufgelöstes Gitter abnimmt, nimmt die Anzahl der Zellen zur Auflösung der Wirbelstrukturen zu. Bei der Gittervariante A ist $n_{KV} \approx 15$ und steigt bei Gittervariante D auf $n_{KV} \approx 40$. Da sich der Punkt zur Auswertung der Zweipunktkorrelation deutlich hinter der Geometrie befindet, sind die Verläufe der Zweipunktkorrelationen für die unterschiedlichen Gitterauflösungen nahezu achsensymmetrisch. In größerer Entfernung korreliert die Geschwindigkeit nicht mehr mit der Geschwindigkeit am Punkt der Auswertung. Für die beiden weiteren Korrelationen der Quer- und Vertikalgeschwindigkeitskomponenten zeigt sich eine ähnliche Tendenz wie für die Längsgeschwindigkeit. Allerdings sind die mittleren Abmessungen der Wirbelstrukturen im Vergleich zur Längsrichtung kleiner. Für die Komponente B_{vv} in Schiffsquerrichtung ist der Verlauf wiederum erwartungsgemäß achsensymmetrisch, da das Strömungsfeld in diese




Abbildung 4.5: Zweipunktkorrelation der Y-Geschwindigkeitskomponente v in Querrichtung (Y-Richtung).




Abbildung 4.6: Zweipunktkorrelation der Z-Geschwindigkeitskomponente w in vertikaler Richtung (Z-Richtung).

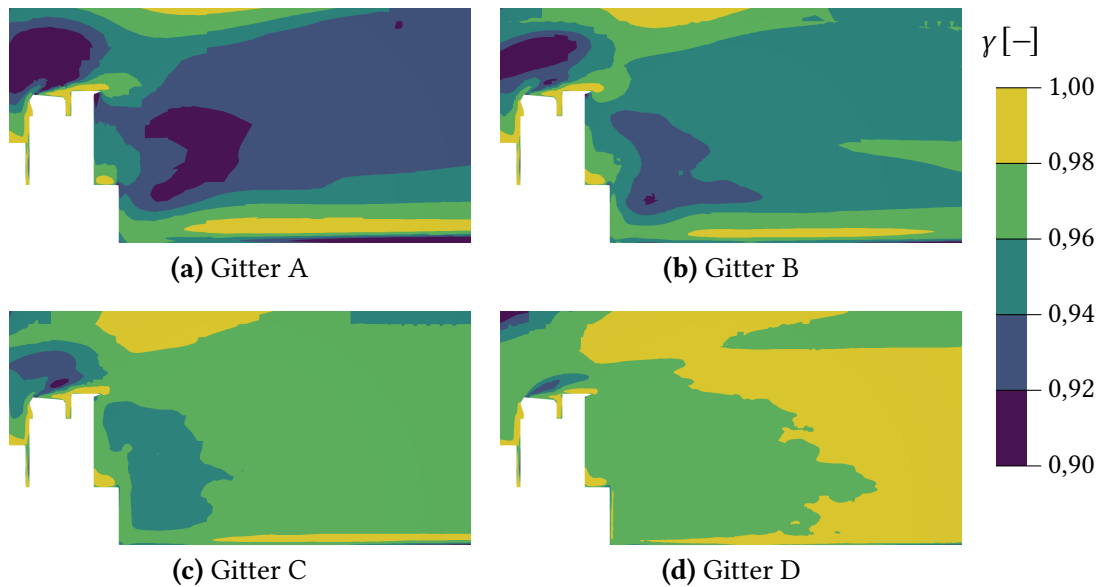


Abbildung 4.7: Vergleich der Verhältnisse γ der aufgelösten turbulenten kinetischen Energie und der gesamten turbulenten kinetischen Energie für die vier untersuchten Gittervarianten A - D.

Raumrichtung ebenfalls nahezu symmetrisch ist. Für die Horizontalkomponente B_{ww} zeigt sich eine leichte Asymmetrie, welche durch das anisotrope Gitter in Bodennähe des Rechengebietes verursacht wird.

Als weitere Größe zur Beurteilung der Gitterauflösung für die skalenauflösenden Simulationen wird das Verhältnis γ der aufgelösten turbulenten kinetischen Energie zur gesamten turbulenten kinetischen Energie betrachtet. Für den Bereich der Strömung im Nachlauf des Deckshauses ist das Verhältnis γ für die vier unterschiedlichen Gitterauflösungen A - D in Abbildung 4.7 dargestellt. Das Verhältnis γ ist nahezu im gesamten Bereich größer 90% ($\gamma > 0,9$) und damit deutlich über dem von Pope (2000) vorgeschlagenen Wert von 80%. Lediglich für die Gittervariante A sinkt der Wert im Nahbereich der Geometrie hinter dem Deckshaus unter $\gamma < 0,9$. Für alle Varianten ist der Anteil der modellierten turbulenten kinetischen Energie im direkten Nachlauf der oberen Vorderkante der Brücke größer als im übrigen Simulationsgebiet.

Für die weiteren Simulationen wird auf die Gitterparameter der Gittervariante C zurückgegriffen. Diese ist ein guter Kompromiss aus ausreichender Auflösung der turbulenten Strukturen sowie einer vergleichsweise kleinen Anzahl an Kontrollvolumen. Somit wird eine größere Anzahl an Simulationen bei unterschiedlichen Beladungszuständen und Zuströmwinkeln bei vertretbarem numerischem Aufwand ermöglicht. Die Genauigkeit der Diskretisierung ist ausreichend: der Durchmesser einer durchschnittlichen turbulenten Wirbelstruktur wird mit ca. 30 Kontrollvolumen räumlich diskretisiert und nahezu die komplette turbulente kinetische Ener-

gie wird aufgelöst ($\gamma > 0,94$). Der Kraftbeiwert der ausgewerteten Beispielsimulation beträgt $c_X = -0,0444$ und ist ca. 1,1 % größer als der im Windkanal gemessene Wert $c_X = -0,0449$.

4.3 Einfluss der Turbulenzmodellierung

Für die Simulation stark abgelöster Strömungen, wie sie bei der Umströmung stumpfer Körper auftreten, liefert eine RANS-basierte Modellierung der Turbulenz häufig ungenaue Resultate, insbesondere wenn diese im Mittel stark instationär sind und nichtlineare Wechselwirkungen zwischen Turbulenz und Transienz auftreten. Um den genauen Unterschied zwischen einer RANS-basierten Turbulenzmodellierung und hybriden RANS-LES Modellierung auf die Umströmung des Überwasserschiffes aufzuzeigen, werden im Folgenden die Ergebnisse für beide Modellierungen verglichen. Zur Beurteilung der Qualität der Simulationsergebnisse werden die Geschwindigkeitsfelder im Nachlauf hinter dem Deckshaus, der zeitlich gemittelte Druck an der Oberfläche der Geometrie sowie die zeitlich gemittelten Lasten im Vergleich zu Messungen analysiert. Dabei werden zwei unterschiedliche Beladungskonfigurationen ohne Containerbeladung an Deck (Container Konfiguration A) und mit teilweiser Beladung (Container Konfiguration B) und die zwei Winkel ($\beta = 0^\circ$ und $\beta = 30^\circ$) betrachtet.

Bei der vorliegenden stark abgelösten Strömung ist das Turbulenzfeld von stark anisotropem Charakter. Die Zweigleichungsturbulenzmodelle basieren auf der Boussinesq-Approximation (2.45), die für die Anisotropie des Spannungstensors eine relativ rudimentäre Modellierung vornimmt und dadurch den anisotropen Charakter nicht ausreichend erfasst. Bei der skalenauflösenden Modellierung hingegen wird die Anisotropie durch die Auflösung des Turbulenzfeldes erfasst. Ferner treten im Bereich der großen Ablösegebiete weite Zonen mit starker Stromlinienkrümmung auf. Stromlinienkrümmung führt zur deutlichen Änderung der Spannungs-/Scherraten-Korrelation und daher zu sehr ungenauen Wirbelzähigkeitsbeziehungen.

Die Randbedingungen des hier betrachteten Strömungsproblems sind alle stationär. Durch die starken Schwankungen, welche durch die Ablösung an den scharfen Kanten der Geometrie verursacht werden, ist das Strömungsfeld auch bei RANS-basierter Betrachtung instationär. Bei der Anwendung RANS-basierter Turbulenzmodelle für instationäre Strömungen muss die Existenz einer spektralen Lücke gewährleistet werden, um eine vollständig konsistente Modellierung zu erhalten (vgl. Abschnitt 2.4.1). Zur Abschätzung der spektralen Lücke werden im Folgenden die turbulenten Längenmaße der aufgelösten Turbulenz und der Modellierung ausgewertet.

Zum Vergleich der RANS-basierten Turbulenzmodellierung und der hybriden RANS/LES-Modellierung werden numerische Simulationen mit dem $k-\omega$ -SST-Modell (vgl. Abschnitt 2.4.1)




Abbildung 4.8: Zeitlich gemittelte dimensionslose Längsgeschwindigkeiten u_x^* in der Ebene $x = -0,85m$ ($0,15m$ hinter dem Spiegel des Modells) für den Beladungsfall ohne Container an Deck (Konfiguration A). Vergleich der Messergebnisse (PIV) mit den Simulationsergebnissen der beiden Turbulenzmodellen IDDES und URANS.

und dem IDDES-Modell (vgl. Abschnitt 2.4.4) durchgeführt. Für beide Simulationsvarianten werden, abgesehen von der Wahl des Turbulenzmodells, die sonstigen Simulationsparameter einschließlich des Konvektionsschemas identisch gewählt (vgl. Abschnitt 4.1).

Um eine Abschätzung der turbulenten Skalen vorzunehmen, wird das Längenmaß der aufgelösten Wirbel mit dem Längenmaß der Modellierung verglichen. Dies wird beispielhaft für den Beladungsfall A und die Zuströmung von vorne $\beta = 0^\circ$ ausgewertet. Die Längenmaß der aufgelösten Turbulenz wird auf Basis der dominierenden Frequenz der Längskraftfluktuationen zusammen mit der Geschwindigkeit der Zuströmung $u_{ref} = 20m/s$ bestimmt. Für den vorliegenden Fall beträgt das turbulente Längenmaß $L_{Turb} \approx 10^{-1}m$. Die Größenordnung des Längenmaßes der aufgelösten Turbulenz stimmt dabei für die RANS- und die IDDES-Modellierung überein. Das Längenmaß der Turbulenzmodellierung wird mittels der turbulenten kinetischen Energie k und der turbulenten Dissipationsrate ω berechnet

$$L_{mod} = \frac{\sqrt{k}}{\omega}. \quad (4.7)$$

Die Auswertung für das Strömungsfeld im Nachlauf hinter dem Deckshaus ergibt das Längenmaß $L_{mod} \approx 10^{-2}m$ für die RANS-Modellierung und für die IDDES-basierte Modellierung $L_{mod} \approx 10^{-3}m$. Für die RANS-basierte Modellierung liegt zwischen den beiden Längenmaßen lediglich eine Größenordnung, für die IDDES-Modellierung zwei Größenordnungen. Es kann daher davon ausgegangen werden, dass für die hier vorliegenden Umströmung der stumpfen Geometrie die spektrale Lücke für die RANS-basierte Modellierung nicht ausreichend vorhanden ist.




Abbildung 4.9: Zeitlich gemittelte dimensionslose Längsgeschwindigkeiten u_x^* in der Ebene $x = -1m$ ($0,30m$ hinter dem Spiegel des Modells) für den Beladungsfall ohne Container an Deck (Konfiguration A). Vergleich der Messergebnisse (PIV) mit den Simulationsergebnissen der beiden Turbulenzmodellen IDDES und URANS.

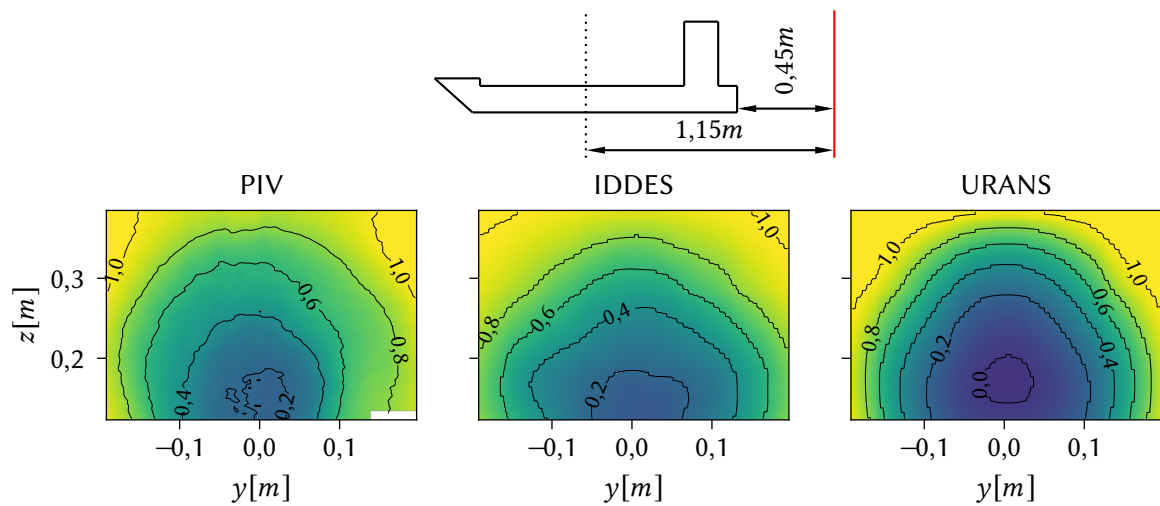


Abbildung 4.10: Zeitlich gemittelte dimensionslose Längsgeschwindigkeiten u_x^* in der Ebene $x = -1,15m$ ($0,45m$ hinter dem Spiegel des Modells) für den Beladungsfall ohne Container an Deck (Konfiguration A). Vergleich der Messergebnisse (PIV) mit den Simulationsergebnissen der beiden Turbulenzmodellen IDDES und URANS.




Abbildung 4.11: Zeitlich gemittelte dimensionslose Längsgeschwindigkeiten u_x^* in der Ebene $x = -0,85m$ ($0,15m$ hinter dem Spiegel des Modells) für den Fall mit teilweiser Containerbeladung an Deck (Konfiguration B). Vergleich der Messergebnisse (PIV) mit den Simulationsergebnissen der beiden Turbulenzmodellen IDDES und URANS.

Für die beiden Beladungskonfigurationen A und B wurden im Windkanal PIV-Messungen (vgl. Abschnitt 3.4) im Nachlauf hinter dem Deckshaus vorgenommen. Es werden drei Ebenen betrachtet: jeweils $0,15m$, $0,30m$ und $0,45m$ hinter dem Spiegel des Windkanalmodells ($x = -0,85m$, $x = -1m$ und $x = -1,15m$). Die Messergebnisse werden mit den Simulationsergebnissen der beiden Turbulenzmodelle verglichen. Für die Beladungskonfiguration A ohne Containerbeladung an Deck sind die ermittelten Strömungsfelder der dimensionslosen Längsgeschwindigkeit $u_x^* = u_x/u_{ref}$ in den Abbildungen 4.8 - 4.10 dargestellt. Für den Beladungsfall A ist die erste Ebene hinter dem Windkanalmodell in Abbildung 4.8 dargestellt. Die Ausdehnung des Ablösegebietes $u_x^* < 0$ in Y-Richtung ist für das PIV-Messergebnis etwas geringer als für die beiden Simulationen. Die Werte der Geschwindigkeit in dieser Ebene sind für beide betrachteten Turbulenzmodelle vergleichbar. Für die weiter stromab liegenden Ebenen $x = -1m$ und $x = -1,15m$, werden die Geschwindigkeitsfelder in den Abbildungen 4.9 und 4.10 gezeigt. In diesen unterscheiden sich die Geschwindigkeitsfelder der beiden Turbulenzmodelle deutlich voneinander. Die IDDES-basierten Geschwindigkeiten stimmen dabei merklich besser mit den PIV-basierten Messungen im Windkanal überein. Die Ausdehnung des Ablösegebietes in X-Richtung wird vom URANS-basierten Strömungsfeld deutlich überschätzt und ist in den Ergebnissen für das IDDES Modell wesentlich realistischer. Die Ausdehnung in Querrichtung (Y-Richtung) hingegen ist beim URANS-Modell deutlich geringer als für die Messung und das IDDES-Modell.

Für die Betrachtung der Geschwindigkeiten für den Fall mit teilweiser Containerbeladung




Abbildung 4.12: Zeitlich gemittelte dimensionslose Längsgeschwindigkeiten u_x^* in der Ebene $x = -1m$ ($0,30m$ hinter dem Spiegel des Modells) für den Fall mit teilweiser Containerbeladung an Deck (Konfiguration B). Vergleich der Messergebnisse (PIV) mit den Simulationsergebnissen der beiden Turbulenzmodellen IDDES und URANS.

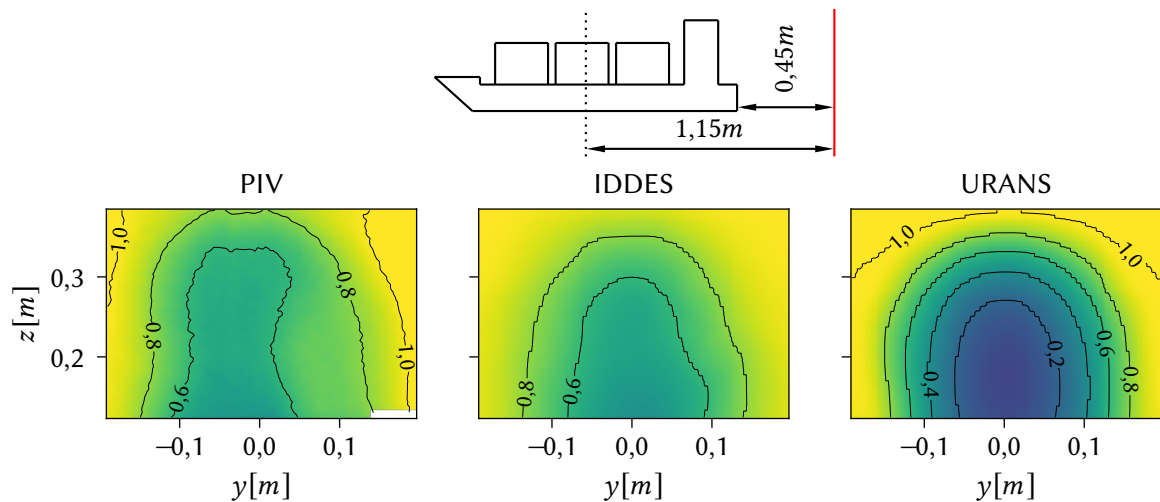


Abbildung 4.13: Zeitlich gemittelte dimensionslose Längsgeschwindigkeiten u_x^* in der Ebene $x = -1,15m$ ($0,45m$ hinter dem Spiegel des Modells) für den Fall mit teilweiser Containerbeladung an Deck (Konfiguration B). Vergleich der Messergebnisse (PIV) mit den Simulationsergebnissen der beiden Turbulenzmodellen IDDES und URANS.

Tabelle 4.2: Vergleich der zeitlich gemittelten Längskraftbeiwerte c_x für die beiden Varianten der Turbulenzmodellierung. Containerkonfiguration A und B bei Zuströmung von vorne ($\beta = 0^\circ$).

Beladungsfall	Windkanal $c_x[-]$	IDDES $c_x[-]$	Abweichung [%]	URANS $c_x[-]$	Abweichung [%]
Container A	-0,0566	-0,0533	2,3	-0,0469	17,1
Container B	-0,0449	-0,0444	1,1	-0,0396	11,8

(Konfiguration B) ergibt sich für die drei Ebenen hinter dem Deckshaus in den Abbildungen 4.11 - 4.13 eine ähnliches Bild, wie zuvor für den Fall ohne Container an Deck. Die Geschwindigkeitsfelder der PIV-Messung und der IDDES-basierten Simulation stimmen qualitativ und quantitativ deutlich besser überein als die Messungen und die RANS-basierte Simulation. Die Ausdehnung des Ablösegebietes in Längsrichtung stromab ist wiederum für die RANS-basierten Geschwindigkeitsfelder deutlich größer, während die Ausdehnung des Nachlaufgebietes $u_x^* < 1,0$ in Querrichtung deutlich kleiner ist. Insgesamt stimmen die Geschwindigkeitsfelder der IDDES-basierten Turbulenzmodellierung wesentlich besser mit den Messergebnissen überein als die Ergebnisse der RANS-basierten Turbulenzmodellierung.

In der Praxis sind hauptsächlich die zeitlich gemittelten Kräfte und Momente der aerodynamischen Schiffsumströmung von Interesse. Die resultierenden Lasten aus den mit beiden Turbulenzmodellen durchgeführten Simulationen werden daher ebenfalls mit den Messergebnissen aus dem Windkanal verglichen. Die dimensionslosen Beiwerte der Längskraft c_x sind für den Fall der Zuströmung von vorne $\beta = 0^\circ$ in Tabelle 4.2 zusammengefasst. Für die Längskraft zeigt sich eine gute Übereinstimmung der bestimmten Lasten im Windkanal und der Lasten der IDDES-Simulation. Die Abweichungen der URANS-basierten Simulationsergebnisse von den Messergebnissen sind hingegen signifikant, mit einer maximalen Abweichung von 17,1% für den Fall ohne Containerladung an Deck (Konfiguration A). Die schräge Zuströmung von vorne unter $\beta = 30^\circ$ wird hier ebenfalls betrachtet. Für diesen Fall liegen keine PIV-Messergebnisse der Geschwindigkeitsfelder vor, sondern nur die im Windkanal gemessenen aerodynamischen Lasten. Die bestimmten dimensionslosen Beiwerte der Längskräfte c_x und Querkräfte c_y werden in Tabelle 4.3 für die teilweise Containerbeladung (Konfiguration B) dargestellt. Für die beiden Kraftbeiwerte zeigt sich für die Simulation mit URANS-Modellierung auch für diesen Anströmwinkel eine signifikante Abweichung von über 6 – 8%. Die Abweichungen des IDDES-Modells sind im Vergleich deutlich geringer.

Um nicht nur die integralen Lasten, sondern auch deren räumliche Verteilung zu analysieren, ist in Abbildung 4.14 der jeweils auf die Oberfläche der Geometrie wirkende Druck dargestellt.

Tabelle 4.3: Vergleich der zeitlich gemittelten Längs- c_X und Querkraftbeiwerte c_Y für die beiden Varianten der Turbulenzmodellierung. Containerkonfiguration B und Wind von schräg vorne ($\beta = 30^\circ$).

	Windkanal $c_X/c_Y[-]$	IDDES $c_X/c_Y[-]$	Abweichung [%]	URANS $c_X/c_Y[-]$	Abweichung [%]
Längskraft	-0,0520	-0,0478	8,1	-0,0463	11,0
Querkraft	0,0896	0,0889	0,8	0,0842	6,0

Der Druck wird in den Darstellungen auf Basis des Druckbeiwertes dimensionslos dargestellt

$$c_p = \frac{p - p_{ref}}{0,5 \cdot \rho u_{ref}^2}, \quad (4.8)$$

wobei ρ die Dichte, u_{ref} die Referenzgeschwindigkeit und p_{ref} der Referenzdruck ist. Der auf das Deckshaus wirkende aerodynamische Widerstand wird durch den Staudruck an der Vorderseite des Deckshauses und den Unterdruck auf der Rückseite, welcher größtenteils durch das Ablösegebiet verursacht wird, dominiert. Die Druckfelder für den Fall ohne Containerbeladung (A) und Zuströmung direkt von vorne ($\beta = 0^\circ$) sind für das IDDES-Modell in Abbildung 4.14 (a) und für das URANS-Modell in Abbildung 4.14 (b) dargestellt. Ein Unterschied in der Verteilung von Drücken nahe dem Staudruck ($c_p \approx 1$) zeigt sich auf der Vorderseite. Für die Simulation mit IDDES-Modell bildet sich auf der Rückseite ein stärker ausgeprägtes Unterdruckgebiet. Für den Fall der teilweisen Beladung (B) werden die Druckfelder in den Abbildungen 4.14 (c) und (d) verglichen. Für das URANS-Ergebnis ist der Staudruckbereich an der Vorderseite etwas großflächiger ausgeprägt und für das IDDES-Ergebnis ist wiederum der Unterdruck an der hinteren Stirnfläche stärker ausgeprägt. Für den letzten hier betrachteten Fall der Containerkonfiguration B und leicht schräger Zuströmung von Backbord $\beta = 30^\circ$ sind die Druckfelder in den Abbildungen 4.14 (e) und (f) dargestellt. Die Verteilung des Druckes an der Vorderseite stimmt für beide Varianten gut überein. Auf der Rückseite zeigen sich kleinere Abweichungen zwischen den beiden Varianten, die die geringen Längskraftunterschiede aus Tabelle 4.3 erzeugen.

4.4 Validierung der Simulationsmethode

Um die für die Anwendungen in Kapitel 7 eingesetzten numerischen Methoden und die Konfiguration des Strömungslösers zu validieren, werden im Folgenden die zeitlich gemittelten Lasten der Simulationsergebnisse der IDDES Modellierung und der Windkanalmessungen für ein Spektrum an Windwinkeln verglichen. Dabei wird für die drei unterschiedliche Beladungszustände (Abbildung 3.6) des Modells jeweils der positive Winkelbereich von $\beta = 0^\circ - 180^\circ$




Abbildung 4.14: Vergleich der zeitlich gemittelten dimensionslosen Druckfelder am Überwasserschiff für beide Turbulenzmodelle (IDDES und URANS). Ansicht jeweils von vorne (links) und achtern (rechts).




Abbildung 4.15: Beispielhafte Darstellung des Wirbelsystems der aerodynamischen Umströmung bei Schräganströmung ($\beta = 30^\circ$) aus zwei unterschiedlichen Perspektiven, Beladungskonfiguration B.

betrachtet. Die Simulationsparameter entsprechen der Beschreibung in Abschnitt 4.1. Die Randbedingungen werden dabei so gewählt, dass sie möglichst den Bedingungen im Windkanal entsprechen. Auf Basis der Ergebnisse der Studie zur Gitterauflösung in Abschnitt 4.2 wird die Auflösung des Gitters nach Variante C gewählt.

Durch die Ablösung an den Kanten des Deckshauses und der Containerstapel bildet sich bei der Umströmung der Geometrie ein komplexes Wirbelsystem aus. Für den Fall der schrägen Anströmung von vorne sind die sich ausbildenden Wirbel in Abbildung 4.15 dargestellt. Der sich um die Geometrie ausbildende Hufeisenwirbel ist ebenfalls zu sehen.

Die simulationsbasierten Lasten werden mit den Windkanalmessergebnissen verglichen. Die statistischen 99% Konfidenzintervalle der Windkanalmessungen betragen für die Längskraft $c_X \pm 4,8 \cdot 10^{-4}$, für die Querkraft $c_Y \pm 4,8 \cdot 10^{-4}$ und für das Giermoment $c_{MZ} \pm 2,2 \cdot 10^{-4}$. Die Ergebnisse der zeitlich gemittelten Längskräfte sind in Abbildung 4.16 dargestellt. Die Kräfte werden erneut wie in (3.4) - (3.6) angegeben dimensionslos dargestellt. Es zeigt sich eine gute Übereinstimmung der simulationsbasierten Kräfte mit den Messungen im Windkanal. Lediglich für den Winkel $\beta = 60^\circ$ treten leichte Abweichungen für die Beladungsfälle ohne und mit teilweiser Containerbeladung auf. Für den gesamten Winkelbereich entsteht ein Großteil der Last in Schiffslängsrichtung am Deckshaus.

Die simulationsbasierten gemittelten Querkräfte werden in Abbildung 4.17 mit den Messergebnissen der Windkanalversuche verglichen. Auch die simulierten Querkräfte stimmen sehr gut überein. In Abbildung 4.18 sind die Werte für das Giermoment um die Z-Achse dargestellt. Die Simulationsergebnisse befinden sich ebenfalls in guter Übereinstimmung mit den im Windkanal gemessenen Momenten. Nur für den Beladungsfall A und einen Winkel von $\beta = 120^\circ$ ergibt sich eine deutlichere Abweichung der Werte. Die aerodynamischen Kräfte am Überwasser-




Abbildung 4.16: Vergleich der gemessenen und simulierten dimensionslosen Längskraft c_X für drei unterschiedliche Beladungskonfigurationen (A - C).

schiff setzen sich aus einem Reibungsanteil und einem Druckanteil zusammen. Aufgrund der stark abgelösten Charakteristik der Strömung werden die Kräfte vom Druckanteil dominiert. Dieser ist um ca. zwei Größenordnungen größer als der Reibungsanteil. Dies ist für die spätere reduzierte Modellierung wichtig.

Die Differenzen zwischen den Messungen und Simulationsergebnissen lassen sich zu Teilen mit den leicht unterschiedlichen Bedingungen im Windkanal und der Simulation begründen. Zwar sind die Randbedingungen der Simulation so gewählt worden, dass diese möglichst mit den Bedingungen im Windkanal übereinstimmen, allerdings lassen sich keine vollständig identischen Bedingungen realisieren. So werden zum Beispiel die Stromlinien der Modellumströmung trotz der 3/4 offenen Messstrecke durch die Versperrung je nach Zuströmwinkel β unterschiedlich stark beeinflusst. Die Versperrungseffekte wirken sich stärker aus, wenn die Strömung stärker ablöst und dadurch der Totwasserbereich deutlich ausgeprägter ist. Dies ist im Bereich der seitlichen Zuströmung von vorne $\beta \approx 60^\circ$ der Fall.

In anderen Arbeiten zur Simulation von Umströmungen von Überwasserschiffen werden bisher kaum skalenauflösende Turbulenzmodelle eingesetzt, obwohl die Schwächen der RANS-basierten Modellierung für diesen Anwendungsfall oft herausgestellt werden. In der vorliegenden Arbeit belegt der Vergleich der Geschwindigkeitsfelder und der aerodynamischen Lasten für die RANS- und die hybride RANS/LES-Modellierung signifikante Vorteile skalenauflösender Turbulenzmodellierung für die Simulation von Überwasserschiffen. Die Strömungsfelder und die Lasten stimmen wesentlich besser mit den experimentellen Daten überein. Die genaue Wahl des hybriden Turbulenzmodells ist hingegen von moderater Bedeutung, da für den vorliegenden Anwendungsfall die räumliche Position der Ablösung klar durch die scharfen




Abbildung 4.17: Vergleich der gemessenen und simulierten dimensionslosen Querkraft c_y für drei unterschiedliche Beladungskonfigurationen (A - C).




Abbildung 4.18: Vergleich des gemessenen und simulierten dimensionslosen Giermoments $c_{M/Z}$ für drei unterschiedliche Beladungskonfigurationen (A - C).

Kanten der Geometrie vorgegeben ist und der überwiegende Teil der turbulenten Schwankungsbewegungen nicht modelliert, sondern aufgelöst wird. Der Einfluss des verwendeten Konvektionsschemas ist ebenfalls gering. Geringe Beiträge numerischer Diffusion stehen einer massiven und dominierenden Erzeugung turbulenter kinetischer Energie im Bereich der Ablösegebiete gegenüber und haben somit nur unerheblichen Einfluss auf das Ergebnis der Simulation.

Die Analyse der unterschiedlichen Gitterauflösungen zeigt, dass bereits mit relativ grober Auflösung vergleichsweise gute Simulationsergebnisse erzielt werden. Eine gute Grundlage für die Beurteilung der Gitterauflösung sind Zweipunktkorrelationen, welche besser als der Vergleich der modellierten und aufgelösten turbulenten kinetischen Energie geeignet sind. Durch die gröbere Gitterauflösung ist auch die notwendige zeitliche Auflösung geringer. Der Simulationsaufwand im Vergleich zu einer RANS-basierten Modellierung steigt daher nur moderat.

Zusammenfassend ist die vorgestellte Simulationsmethodik sehr gut geeignet, um eine ausreichend genaue Simulation aerodynamischer Schiffsumströmungen zu ermöglichen. Die Übereinstimmung mit den Validierungsdaten der Windkanalversuche ist sehr gut. Die Strömungsfelder der Simulation dienen als qualitativ hochwertige Datenbasis für die in Kapitel 7 vorgestellten Surrogatmodelle.

5 Grundlagen und Methoden der Datenbasierten Modellierung

In den letzten Jahren werden vermehrt datenbasierte Methoden in der Strömungsmechanik zur Analyse großer Datenfelder eingesetzt. Wie auch in anderen Bereichen, ist dies in der Verfügbarkeit leistungsfähiger Hardware und weiterentwickelter Algorithmen begründet. Zusätzlich existieren immer umfangreichere Datensätze zum Trainieren der Modelle. Die Daten der Strömungsfelder stammen dabei zum Teil aus unterschiedlichen Datenquellen, wie z.B. Experimenten oder numerischen Simulationen mit unterschiedlichen räumlichen und zeitlichen Auflösungen. Die Methoden der datenbasierten Modellierung im Bereich des Maschinellen Lernens (ML) ermöglichen das Extrahieren von unterschiedlichen Informationen aus der Datenbasis. Zum Beispiel können dominierende Moden bzw. Vorgänge innerhalb komplexer Strömungsvorgänge visualisiert werden.

Eine Möglichkeit bzw. Teilschritt zur Anwendung datenbasierter Methoden stellt die Dimensionsreduktion eines Datensatzes dar. Die Daten liegen dabei beispielsweise für unterschiedliche Zeitschritte, Geometrien oder Systemparameter vor. Durch die Extraktion der charakteristischen Merkmale der Strömungsfelder lässt sich eine reduzierte Darstellung der Koordinaten finden, welche die vorhandenen Strömungsphänomene kompakt und effizient beschreibt. Bei dieser modalen Zerlegung des Strömungsfeldes bleiben die dominanten und wichtigsten Eigenschaften erhalten. Es existieren verschiedene Methoden zur modalen Darstellung von Strömungsfeldern. Eine Übersicht der Methoden findet sich bei Taira et al. (2017). Im Rahmen dieser Arbeit werden eine POD-basierte und eine Autoencoder basierte Methoden verwendet. Die POD ist eine klassische (deterministische) Strategie, Autoencoder werden häufig mit Techniken des Maschinellen Lernens kombiniert.

Die reduzierte Darstellung der Strömungsfelder für unterschiedliche Systemparameter wird als Grundlage zur reduzierten Modellierung eingesetzt. Ein solches Modell kann z.B. für die Beschreibung der Entwicklung des Strömungsfeldes in Abhängigkeit unterschiedlicher Systemparameter entwickelt werden. In Kombination mit IoT basierten Messungen von Systemparametern kann so ein Entscheidungshilfesystem generiert werden.

Für die daten- und dimensionsreduzierende Modellbildung wird zwischen zwei unterschiedlichen Ansätzen unterschieden, vgl. Agostini (2020):

- Beim **modellbasierten Ansatz** wird mittels der vorhandenen Datenbasis die Dimension der zu Grunde liegenden Gleichungen reduziert. Die Identifikation einer solchen reduzierten Darstellung der Gleichungen kann mit großem rechnerischem Aufwand verbunden sein. Der Aufwand zum Lösen der reduzierten Gleichungen ist zwar im Vergleich zur Lösung der ursprünglichen Gleichungen deutlich geringer, aber für die meisten Anwendungen dennoch nicht unerheblich.
- Beim rein **datenbasierten Ansatz** werden die zu Grunde liegenden Gleichungen bei der Modellbildung nicht berücksichtigt. Dieser Ansatz wird auch als modellunabhängiger Ansatz (engl. model free approach) bezeichnet und die Modellbildung erfolgt rein datenbasiert.

Da im Rahmen dieser Arbeit ein Modell entwickelt werden soll, welches für beliebige Kombinationen von Systemparametern die Strömungsfelder bzw. Lasten nahezu in Echtzeit bestimmen kann, wird der datenbasierte Ansatz gewählt.

Bei strömungsmechanischen Problemstellungen handelt es sich meist um multidimensionale nichtlineare Systeme. Dabei sind häufig unterschiedliche räumliche oder zeitliche Skalen von Interesse. Für solch komplexe Systeme ist es anspruchsvoll geeignete dimensionsreduzierte Darstellungen zu finden. Für datenbasierte Methoden ist häufig das Vorliegen räumlich strukturierter Daten als Eingabe erforderlich. Die Vorbereitung und Anpassung der Datensätze ist daher ein wichtiger vorbereitender Schritt bei der Erstellung datenbasierter Modelle, der in Abschnitt 6.3 im Kontext dieser Arbeit erörtert wird.

Im weiteren Verlauf des Kapitels wird zunächst eine Methode zur Dimensionsreduktion mittels linearer Algebra die sogenannte orthogonale Matrixzerlegung bzw. Singulärwertzerlegung zusammengefasst. Im Weiteren werden die Grundlagen des Maschinellen Lernens und der Modellbildung mit Neuronalen Netzen sowie die des erforderlichen Trainingsprozesses beschrieben. Im Anschluss werden faltungsbasierte Netzwerkarchitekturen und Autoencoder eingeführt.

5.1 Orthogonale Matrixzerlegung

Bei der orthogonalen Matrixzerlegung (engl. proper orthogonal decomposition, POD) bzw. Singulärwertzerlegung werden die in einer Matrix gespeicherten Daten durch einen hierarchisch geordneten Satz von Moden dargestellt. Dadurch wird die optimale Approximation der Matrix mit niedrigem Rang gefunden. Die Technik wird häufig zur Analyse von Strömungsfeldern eingesetzt. Zur Bestimmung der Moden wird die Singulärwertzerlegung (engl. singular value decomposition, SVD) verwendet. Die SVD ist eine Verallgemeinerung der Eigenwertzerlegung

und kann für beliebige rechteckige Matrizen bestimmt werden. Eine ausführliche Beschreibung methodischer Varianten und deren fluidmechanischen Einsatz findet sich bei Taira et al. (2017). Häufig wird die POD-Technik zur Analyse zeitabhängiger Strömungsfelder eingesetzt. Im Rahmen dieser Arbeit hingegen werden stationäre bzw. zeitlich gemittelte Strömungsfelder für viele unterschiedliche Betriebsbedingungen betrachtet. Eine Größe des Strömungsfeldes in Abhängigkeit der räumlichen Koordinate $\mathbf{x} \in \mathbb{R}^n$ und der Systemparameter $\boldsymbol{\alpha} \in \mathbb{R}^m$ wird mit $q(\mathbf{x}, \boldsymbol{\alpha})$ beschrieben. Die Anzahl der Snapshots wird mit m und die Anzahl der diskreten räumlichen Punkte mit n bezeichnet. Die Daten des Strömungsfeldes für unterschiedliche Systemparameter werden als Spaltenvektoren bzw. Snapshots in einer Matrix $\mathbf{Q} \in \mathbb{R}^{n \times m}$ gespeichert. Für die Matrix \mathbf{Q} lässt sich die Singulärwertzerlegung bestimmen

$$\mathbf{Q} = \boldsymbol{\Phi} \boldsymbol{\Sigma} \mathbf{V}^T, \quad (5.1)$$

wobei die linken und rechten Singulärvektoren in den unitären Matrizen $\boldsymbol{\Phi} \in \mathbb{R}^{n \times n}$ und $\mathbf{V} \in \mathbb{R}^{m \times m}$ enthalten sind. Die Spaltenvektoren der Matrix $\boldsymbol{\Phi}$ werden auch als POD-Moden bezeichnet, wobei mit $\boldsymbol{\Phi}_i$ der i -te Spaltenvektor bzw. die i -te POD-Mode ausgewählt wird. Die rechteckige Diagonalmatrix $\boldsymbol{\Sigma} \in \mathbb{R}^{n \times m}$ enthält die Singulärwerte $(\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_g)$ der Matrix \mathbf{Q} mit Rang g . Für die reduzierte Darstellung des Datensatzes werden nur die ersten R Moden $\boldsymbol{\Phi}_R = [\boldsymbol{\Phi}_1, \boldsymbol{\Phi}_2, \dots, \boldsymbol{\Phi}_R]$ berücksichtigt. Diese orthonormale Basis repräsentiert die effizienteste dimensionsreduzierte Darstellung der Strömungsfelder $q(\mathbf{x}, \boldsymbol{\alpha})$ basierend auf der SVD. Betrachtet man alle möglichen orthonormalen Basen vom Rang R , wird der L_2 -Fehler durch die POD-Basis minimiert (Swischuk et al., 2019)

$$\min_{\boldsymbol{\Phi}_R \in \mathbb{R}^{n \times R}} \|\mathbf{Q} - \boldsymbol{\Phi}_R \boldsymbol{\Phi}_R^T \mathbf{Q}\| = \sum_{k=R+1}^m \sigma_k^2. \quad (5.2)$$

Der Fehler wird durch Aufsummieren der Quadrate der Singulärwerte, welche nicht für die Rekonstruktion berücksichtigt werden, berechnet. Daher bieten die Singulärwerte einen Anhaltspunkt für die Abschätzung der Anzahl zu verwendender Moden.

Durch die lineare Kombination der ersten R POD-Moden wird eine Approximation des Strömungsfeldes \tilde{q} zu

$$\tilde{q}(\mathbf{x}, \boldsymbol{\alpha}) = \sum_{i=1}^R \boldsymbol{\Phi}_i(\mathbf{x}) r_i(\boldsymbol{\alpha}) \quad (5.3)$$

bestimmt. Die POD-Koeffizienten werden dabei mit $r_i(\boldsymbol{\alpha})$ bezeichnet. Durch die Approximation erfolgt eine Trennung der räumlichen Abhängigkeit und der Abhängigkeit der Systemparameter. Die Moden $\boldsymbol{\Phi}_i(\mathbf{x})$ enthalten die räumliche Abhängigkeit, während die Koeffizienten $r_i(\boldsymbol{\alpha})$ die Abhängigkeit von den Systemparametern enthält. Die in (5.3) benötigten Koeffizienten für eine

bestimmten Snapshots werden über eine Projektion der Moden in die Datenbasis bestimmt

$$r_i(\boldsymbol{\alpha}) = \Phi_i^T \mathbf{q}(\boldsymbol{\alpha}), \quad i = 1, \dots, R. \quad (5.4)$$

Mittels dieser Gleichung werden die POD-Koeffizienten für den vorhandenen Datensatz bestimmt. In einem weiteren Schritt wird durch Regression die Abhängigkeit der Koeffizienten von den Systemparametern ($\boldsymbol{\alpha} \mapsto r_i$) durch maschinelles Lernen bestimmt (vgl. Abschnitt 6.2).

5.2 Grundlagen des Maschinellen Lernens

Beim Maschinellen Lernen (ML) werden keine vorprogrammierten Algorithmen eingesetzt, sondern Algorithmen, die auf Basis von Datensätzen während eines Trainingsprozesses angepasst werden. Das Verhalten des Algorithmus wird nicht durch den Programmierer vorgegeben, sondern wird während des Trainings durch Optimieren des Algorithmus festgelegt. Dazu wird die Performance des Algorithmus gemessen und die Fähigkeit zur Vorhersage gegebener (Trainings-)Daten kontinuierlich verbessert. Die Methoden des Maschinellen Lernens werden in einem sehr breiten Spektrum von unterschiedlichsten Anwendungsfeldern eingesetzt. In der vorliegenden Arbeit wird insbesondere auf die Verwendung im Bereich der Strömungsmechanik eingegangen.

Häufig ist das Klassifizieren oder die Regression von Daten Aufgabe des Maschinellen Lernens. Bei der Klassifizierung werden die Eingabedaten aufgrund ihrer Eigenschaften in unterschiedliche Klassen eingeteilt. Werden diese nicht im Vorfeld vorgegeben, sondern vom Algorithmus eigenständig gefunden, wird dies auch als unüberwachtes Lernen (engl. unsupervised learning) bezeichnet. Solche Methoden des Maschinellen Lernens werden z.B. zur Klassifizierung der Topologie des Nachstroms für unterschiedliche Profilmströmungen (Colvert et al., 2018) eingesetzt. Sind die Ausgabe des Modells kontinuierliche Werte, wie z.B. der Auftrieb und Widerstand eines Profils, handelt es sich um eine Regressionsaufgabe.

Die mathematischen Details der Methoden des Maschinellen Lernens und ihres Trainings werden in den folgenden Abschnitten erläutert.

5.3 Künstliche Neuronale Netze

Ein künstliches Neuronales Netz (engl. artificial neural network ANN oder NN) ist ein von den Neuronen des menschlichen Gehirns inspiriertes Modell des Maschinellen Lernens. Die Flexibilität und Leistungsfähigkeit künstlicher Neuronaler Netze basieren auf der Kombination einzelner künstlicher Neuronen. Die einfachste Form eines Neuronalen Netzes ist eine einzige Schicht aus einem oder mehreren Neuronen. Wird eine große Anzahl an Schichten hinterein-

ander geschaltet, wird dies als tiefe Netzwerkstruktur bezeichnet (engl. deep neural network DNN). Durch die Anordnung der Neuronen hintereinander werden die Eingabedaten mit zunehmendem Abstraktionsgrad verarbeitet. Durch die Anwendung ausreichen tiefer Netzwerke lassen sich beliebige Verläufe von Funktionen approximieren (Hornik et al., 1989).




Abbildung 5.1: Skizze eines einzelnen Neurons mit Eingaben a_i , den Gewichten w_i , dem Biaswert b und der Ausgabe d .

Ein einzelnes Neuron ist in Abbildung 5.1 dargestellt. Die Eingabewerte a_i werden gewichtet aufsummiert und der Bias-Wert b addiert. Der Bias hat keinen Eingabewert und beeinflusst mittels der Gewichtung den Ausgabewert des Neurons. Auf die Summe wird eine Aktivierungsfunktion ψ angewendet. Die jeweiligen Ausgabewerte d_j einer Netzwerkschicht werden wie folgt berechnet

$$d_j = \psi(W_{ji} \cdot a_i + b_j). \quad (5.5)$$

Die Matrix W_{ji} enthält dabei die Gewichte aller Verbindungen zwischen den Eingabewerten a_i und allen Neuronen d_j der betrachteten Schicht. Werden die einzelnen Schichten hintereinander angeordnet ergibt sich das vollständige Netzwerk.

In Abbildung 5.2 ist ein Netzwerk mit mehreren Eingabe- und Ausgabewerten sowie einer versteckten Netzwerkschicht beispielhaft skizziert. Die Werte der Matrix W_{ij} sowie die Bias-Werte b_j der einzelnen Schichten werden während des Trainings des Netzwerkes optimiert, sodass die




Abbildung 5.2: Skizze eines Neuronalen Netzwerks mit einer versteckten Schicht (engl. hidden layer). Die Werte der Eingabe sind \mathbf{a} , die Werte der versteckten Schicht $\mathbf{d}^{(1)}$ und die Ausgabewerte \mathbf{y} .

Verlust- bzw. Zielfunktion E minimiert wird

$$E = \frac{1}{M} \sum_j^M (\hat{y}_j - y_j)^2. \quad (5.6)$$

Dabei werden die Fehler gegenüber dem Zielwert y_j im Fall mehrere Ausgabewerte M üblicherweise gemittelt. Neben der hier gezeigten mittleren quadratischen Abweichung (engl. mean squared error, MSE) können auch andere Maße zur Bestimmung der Verlustfunktion verwendet werden. Alternativ werden die mittlere absolute Abweichung (engl. mean absolute error, MAE) oder weitere Maße in Anlehnung an übliche Normen des Differenzvektors $(\hat{y}_j - y_j)$ verwendet.

Für die Aktivierungsfunktion $\psi(\cdot)$ können unterschiedliche Funktionen verwendet werden. Die einfachste ist die lineare Funktion

$$\psi(z) = z. \quad (5.7)$$

Um allerdings eine nichtlineare Transformation zwischen dem Eingabe- und Ausgaberaum zu ermöglichen, ist die Verwendung einer oder mehrerer nichtlinearer Aktivierungsfunktionen erforderlich. Eine häufig verwendete Aktivierungsfunktion ist die *ReLU*-Funktion (engl. rectified linear unit). Diese gibt für negative Eingabewerte den Wert 0 und für positive Eingabewerte den Wert selbst zurück

$$\psi(z) = \begin{cases} z & \text{wenn } z > 0 \\ 0 & \text{wenn } z \leq 0. \end{cases} \quad (5.8)$$

Eine ähnliche Aktivierungsfunktion ist die *elu*-Funktion (engl. exponential linear unit) (Clevert et al., 2015), welche zusätzlich negative Ausgabewerte erzeugen kann

$$\psi(z) = \begin{cases} z & \text{wenn } z > 0 \\ \alpha \cdot (e^z - 1) & \text{wenn } z \leq 0. \end{cases} \quad (5.9)$$

Bei dieser Aktivierungsfunktion tritt die zusätzliche Konstante α mit einem positiven Wert auf. Außerdem werden für die Aktivierungsfunktion weitere Funktionen verwendet, z.B. die *tanh*-Funktion.

5.4 Training Neuronaler Netze

Zur Bestimmung der zuvor gezeigten Gewichte W_{ij} der Neuronalen Netze (5.5) werden Trainingsdaten verwendet. Ziel ist dabei die optimalen Gewichte aller Netzwerkschichten \mathbf{W} zu finden, sodass die Verlust- bzw. Zielfunktion minimiert wird. Die Gewichte werden dabei allgemein auch als Parameter bezeichnet, während die Hyperparameter die Eigenschaften der Modellierung, wie z.B. den Initialisierungs-Algorithmus der Netzwerkgewichte oder die ver-

wendeten Aktivierungsfunktionen, etc. festlegen. Beim Training Neuronaler Netze werden die Hyperparameter meistens vorab vorgegeben und während des Lernens nicht mehr angepasst. Das Anpassen der Gewichte basiert auf einem Gradientenabstiegsverfahren. Dabei werden die Gradienten der Gewichte in Bezug auf die Zielfunktion benötigt, welche mit Hilfe der Backpropagation bestimmt werden. Im Folgenden werden beide Verfahren zusammengefasst. Für eine ausführliche Beschreibung wird auf Aggarwal (2019) bzw. Brunton und Kutz (2019) verwiesen.

5.4.1 Backpropagation

Mittels des Backpropagation-Algorithmus (Rumelhart et al., 1986) werden die für die Optimierung benötigten Gradienten des gesamten Netzwerkes bestimmt. Das Vorgehen wird auch als Fehlerrückführung bezeichnet. Der Algorithmus basiert auf der Kettenregel der Differentialrechnung, womit auch für mehrschichtige Neuronale Netze die Gradienten bestimmt werden können. Der Backpropagation-Algorithmus besteht aus zwei Schritten:

- **Vorwärtsschritt:** Die Eingabewerte des Trainingsdatensatzes werden in das Netzwerk gegeben. Auf Basis der aktuellen Gewichte wird die Ausgabe des Netzwerkes bestimmt, auf die gleiche Weise, wie es bei einer Vorhersage erfolgt. Durch Vergleichen der Ausgabewerte mit den Zielwerten des Trainingsdatensatzes innerhalb der Verlustfunktion wird der Fehler bestimmt.
- **Rückwärtsschritt:** Im rückwärts gerichteten Schritt bewertet der Algorithmus den Beitrag jeder Ausgabe zum Gesamtfehler. Basierend auf der Kettenregel wird für jeden Knotenpunkt des Netzwerkes der Gradient des Fehlers $\frac{\partial E}{\partial w_{ij}}$ bestimmt. Die Gradienten werden wiederum im Optimierungsschritt zum Anpassen jedes einzelnen Gewichtes verwendet.

Für die erfolgreiche Konvergenz des Verfahrens ist eine Initialisierung der Gewichte des Netzes mit zufälligen Werten erforderlich.

5.4.2 Gradientenabstiegsverfahren

Gradientenabstiegsverfahren werden für die Lösung eines breiten Spektrums an Optimierungsproblemen beispielsweise zur nichtlinearen Optimierung eingesetzt. Die grundsätzliche Idee der Methode ist, der Richtung des steilsten Abstiegs zu folgen und sich so iterativ dem lokalen Minimum anzunähern. Beim Trainieren Neuronaler Netze besteht die Optimierungsaufgabe in der Bestimmung optimaler Gewichte \mathbf{W} des Netzes, sodass die Verlustfunktion E minimiert wird.

Zunächst wird die allgemeine Funktion $f : \mathbb{R}^n \mapsto \mathbb{R}$ betrachtet. Das Ziel ist die Bestimmung

des Minimums dieser Funktion

$$\min_{\mathbf{x} \in \mathbb{R}^n} [f(\mathbf{x})]. \quad (5.10)$$

Ausgehend von einem Startpunkt \mathbf{x}_0 wird mittels des Gradienten iterativ der dem Minimum näher gelegene Punkt bestimmt

$$\mathbf{x}_{k+1}(\delta) = \mathbf{x}_k - \delta \nabla f(\mathbf{x}_k). \quad (5.11)$$

Dabei wird der zusätzliche Parameter δ als Schrittweite des Verfahrens genutzt. δ wird auch als Lernrate bezeichnet und beeinflusst die Konvergenzgeschwindigkeit.

Beim Training Neuronaler Netze wird das Gradientenabstiegsverfahren zum Anpassen der Gewichte des Netzwerkes verwendet, wobei die Matrix \mathbf{W}_k alle Gewichte des Netzwerkes zum k -ten Iterationsschritt bezeichnet. Der Startpunkt entspricht der Initialisierung der Gewichte \mathbf{W}_0

$$\mathbf{W}_{k+1}(\delta) = \mathbf{W}_k - \delta \nabla E(\mathbf{W}_k). \quad (5.12)$$

Die Bestimmung der Gradienten erfolgt mit Hilfe des Backpropagation-Algorithmus (vgl. Abschnitt 5.4.1). Die Fehlerfunktion E wird hierbei für den gesamten Trainingsdatensatz gemittelt ausgewertet.

Für sehr große Datensätze ist es nicht praktikabel Funktionen bzw. das zu trainierende Neuronale Netz für den kompletten Datensatz auszuwerten. Zusätzlich wird das Lernen für sehr große Datensätze bei gleichzeitiger Berücksichtigung aller Daten sehr langsam. Um diesen Nachteilen entgegenzuwirken, wird beim stochastischen Gradientenabstiegsverfahren (engl. stochastic gradient descent) der gesamte Datensatz stochastisch in mehrere Teildatensätze aufgeteilt. Für jeden dieser Teildatensätze j wird jeweils ein Trainingsdurchlauf ausgeführt. Der Fehler E_j wird nur für den Teildatensatz bestimmt und die Gewichte des Netzwerkes ansprechend angepasst

$$\mathbf{W}_{k+1}(\delta) = \mathbf{W}_k - \delta \nabla E_j(\mathbf{W}_k). \quad (5.13)$$

Im nächsten Schritt wird dann das Training basierend auf dem nächsten Teildatensatz $j + 1$ durchgeführt. Aufgrund der stochastischen Eigenschaften des Verfahrens kommt es teilweise zu einem oszillierenden Verlauf der Fehlerfunktion im Iterationsprozess.

5.4.3 Adam-Optimierer

Beim Adam-Verfahren (Kingma und Ba, 2015) handelt es sich um ein erweitertes stochastisches Gradientenabstiegsverfahren, bei welchem zusätzlich eine adaptive Schätzung der Momente erster und zweiter Ordnung berücksichtigt wird. Dabei bleiben die Effizienz und Speicheranforderungen der ursprünglichen Methode erhalten. Die Gewichte des Neuronalen Netzes werden

mit folgender Formulierung in jedem Iterationsschritt aktualisiert

$$\mathbf{W}_{k+1}(\delta, \beta_1, \beta_2, \epsilon) = \mathbf{W}_k - \delta \frac{\hat{M}_{k+1}}{\sqrt{\hat{R}_{k+1} + \epsilon}}, \quad (5.14)$$

wobei δ die Lernrate und ϵ ein numerischer Parameter ist. Das erste Moment wird dabei mittels der Gradienten und des Hyperparameters β_1 berechnet

$$M_{k+1} = \beta_1 M_k + (1 - \beta_1) \nabla E_j(\mathbf{W}_k). \quad (5.15)$$

Zusätzlich wird eine Bias-Korrektur für das Moment angewendet

$$\hat{M}_{k+1} = \frac{M_{k+1}}{1 - \beta_1^{(k+1)}}, \quad (5.16)$$

wobei $\beta_1^{(k+1)}$ die Potenz mit der Basis β_1 und dem Zeitschritt abhängigen Exponenten $(k + 1)$ ist. Für das Moment 2. Ordnung wird die Berechnung entsprechend mit dem Hyperparameter β_2 durchgeführt

$$R_{k+1} = \beta_2 R_k + (1 - \beta_2) (\nabla E_j(\mathbf{W}_k))^2, \quad (5.17)$$

$$\hat{R}_{k+1} = \frac{R_{k+1}}{1 - \beta_2^{(k+1)}}. \quad (5.18)$$

Die vorgeschlagenen Werte für die Hyperparameter sind $\beta_1 = 0,9$, $\beta_2 = 0,999$ und $\epsilon = 10^{-8}$. Für die meisten Anwendungen wird mit dem Adam-Verfahren im Vergleich zum klassischen Gradientenabstiegsverfahren insbesondere bei großen Datensätzen eine schnellere Konvergenz erreicht.

5.5 Faltende Neuronale Netze

Eine spezialisierte Netzwerkarchitektur für räumlich (oder zeitlich) strukturierte Daten bilden die Convolutional Neuronale Netze (CNN), welche auch als faltungsbasierte Neuronale Netze bezeichnet werden. Eine Schicht des CNN besteht aus einer Faltungs-Schicht mit Anwendung der Aktivierungsfunktion sowie einer Pooling-Schicht. Das komplette Netzwerk besteht in den meisten Fällen aus mehreren dieser kombinierten Schichten und wird teilweise mit zusätzlichen vollständig vernetzten Schichten ergänzt. Der Aufbau und die Funktion der einzelnen Schichten werden im Folgenden knapp erläutert. Eine ausführliche Beschreibung findet sich bei Goodfellow et al. (2016).

Die **Faltungs-Schicht** (Convolution) basiert auf der allgemeinen diskreten Faltung zweier

Funktionen a und W am Punkt x mit den Werten i des Summationsbereichs

$$(a * W)(x) = \sum_i a(i)W(x - i), \quad (5.19)$$

wobei a als Eingangsfunktion und W als der Kern der Faltung (engl. kernel) bezeichnet wird. Die Ausgabe wird häufig Feature genannt. Innerhalb des CNNs sind die Eingangsgrößen und die jeweiligen Kerne mehrdimensionale Tensoren. Die Werte des Kerns werden während des Trainings des Netzwerkes optimiert und somit bestimmt. In der vorliegenden Arbeit sind die Eingabedaten dreidimensionale Felddaten. Daher wird die Faltung ebenfalls im dreidimensionalen Raum berechnet

$$(a * W)(x,y,z) = \sum_i \sum_j \sum_k a(x + i, y + j, z + k) \cdot W(i,j,k), \quad (5.20)$$

wobei hier nicht die eigentliche Faltung, sondern die Kreuzkorrelation aufgrund der einfacheren Implementierung verwendet wird. Im Zusammenhang des Maschinellen Lernens wird dies dennoch als Faltung (Convolution) bezeichnet. Für jede CNN-Schichten werden meist mehrere Kerne implementiert und trainiert. Die Anzahl der Featureebenen der Ausgabe einer CNN-Schicht entspricht dabei der Anzahl der implementierten Kerne dieser Schicht. Zusätzlich wird für jeden Filter jeweils ein Biaswert b innerhalb der CNN-Schichten berücksichtigt. Die Ausgabe einer Schicht ergibt sich zu

$$z(x,y,z,m) = (a * W)(x,y,z,m) + b(m) = \sum_n \sum_i \sum_j \sum_k a(x + i, y + j, z + k, n) \cdot W(i,j,k,m) + b(m). \quad (5.21)$$

Der Index n beschreibt die Anzahl der Features der vorherigen Schicht bzw. der Eingabedaten, während der Index m die Anzahl der Features der aktuellen Schicht bezeichnet.

Auf die Ausgabe der Faltungsschicht wird die Aktivierungsfunktion $\psi(\cdot)$ wie in (5.5) angewendet

$$d(x,y,z,m) = \psi(z(x,y,z,m)). \quad (5.22)$$

Der Vorteil einer CNN-Architektur ist die reduzierte Interaktion der räumlichen Punkte im Vergleich zu einem vollständig vernetzten Netzwerk. Die Ausgabewerte des Kerns werden nur von den benachbarten Punkten beeinflusst, während weiter entfernte Punkte keinen Einfluss haben. Durch die deutlich geringeren Abmessungen des Kerns im Vergleich zur Größe des Feldes ist die Anwendung auf räumliche Gitter wesentlich effizienter als die Verwendung von vollständig vernetzten Netzwerken.

Um die räumliche Dimension innerhalb der Netzwerkschichten zu reduzieren werden **Pooling-Schichten** eingesetzt. Dabei wird innerhalb eines räumlichen Quaders mit definierten

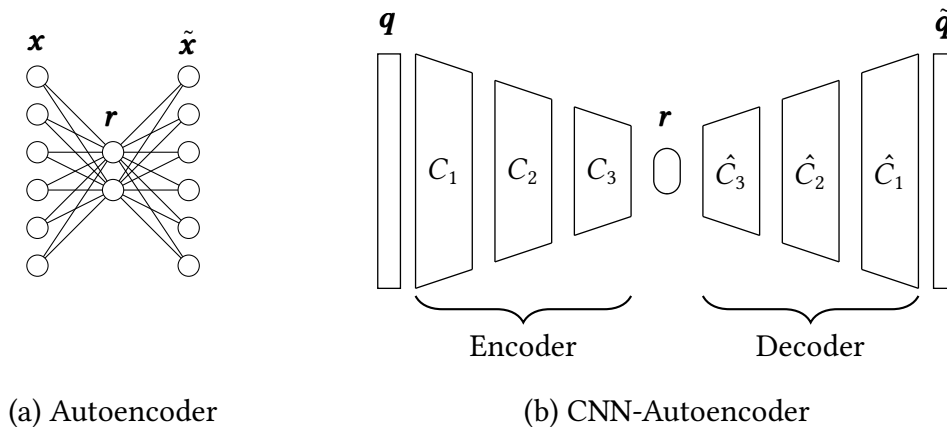


Abbildung 5.3: (a) Struktur eines Autoencoders. Die Ausgabe $\tilde{\mathbf{x}}$ ist eine Rekonstruktion der Eingabedaten \mathbf{x} mit den dazwischenliegenden reduzierten Variablen \mathbf{r} . (b) Schematische Darstellung eines CNN-basierten Autoencoders mit je drei CNN-Schichten für den Encoder und Decoder.

Abmessungen nur der maximale Wert der benachbarten Punkte berücksichtigt. Betragen die Abmessungen des Quaders beispielsweise $2 \times 2 \times 2$ und ist die Schrittweite ebenfalls 2, werden die räumlichen Dimensionen durch den Pooling-Layer jeweils halbiert, während die Anzahl der Features erhalten bleibt. Neben dem Max-Pooling existieren weitere Pooling Varianten, welche allerdings nur selten eingesetzt werden und daher in dieser Arbeit keine Berücksichtigung finden.

5.6 Autoencoder

Bei einem Autoencoder werden die Schichten des Neuronalen Netzwerkes so angeordnet, dass die Ausgabe des Netzwerkes eine Rekonstruktion der Eingabedaten darstellt. Ziel ist dabei eine möglichst exakte Rekonstruktion der Eingabedaten zu erhalten. Damit das Lernen des Netzwerkes nicht trivial ist, wird die Anzahl der Neuronen in der Mitte des Netzwerkes beschränkt. Die Werte der begrenzten Knotenpunkte bzw. reduzierten Variablen stellen eine komprimierte Darstellung der Eingabedaten dar. Die Rekonstruktion der ursprünglichen Eingabedaten in der Ausgabeschicht ist dabei verlustbehaftet.

Der grundsätzliche Aufbau eines Autoencoders ist in Abbildung 5.3 (a) skizziert. Die Struktur des Netzwerkes besteht aus drei Teilen: einem Encoder $\mathcal{F}_{Enc}(\mathbf{q}) = \mathbf{r}$, den reduzierten Variablen \mathbf{r} sowie dem Decoder $\mathcal{F}_{Dec}(\mathbf{r}) = \tilde{\mathbf{q}}$. Der Encoder und Decoder können dabei jeweils aus einer einzelnen oder mehreren Neuronenschicht bestehen. Das Trainieren des Netzwerkes erfolgt durch Minimieren der Verlustfunktion

$$E(\mathbf{q}, \mathcal{F}_{Dec}(\mathcal{F}_{Enc}(\mathbf{q}))), \quad (5.23)$$

wobei die Verlustfunktion E die Unterschiede zwischen den Eingabedaten und den rekonstruierten Ausgabedaten misst.

Werden für den Encoder und Decoder lineare Aktivierungsfunktionen verwendet und entspricht die Verlustfunktion der L_2 -Norm, lernt der Autoencoder die gleiche lineare Repräsentation im reduzierten Raum wie die POD-Methode (vgl. Abschnitt 5.1). Werden für den Autoencoder nichtlineare Aktivierungsfunktionen verwendet, entspricht das Vorgehen einer nichtlinearen Erweiterung der POD-Darstellung und es wird davon ausgegangen, dass für nichtlineare Problemstellungen kompaktere Formen der Dimensionsreduktion gefunden werden.

Für die Schichten des Encoders und Decoders werden wahlweise Convolutional-Layer verwendet. Dies wird als Convolution Neuronales Netzwerk basierter Autoencoder (CAE) bezeichnet. Dieses Vorgehen ist insbesondere zur Dimensionsreduktion räumlich dreidimensionaler Datensätze geeignet. Durch das Verwenden mehrerer CNN-Schichten werden die Dimensionen des Datensatzes hierarchisch reduziert. Die schematische Struktur eines CNN-basierten Autoencoders ist in Abbildung 5.3 (b) skizziert.

6 Datenbasierte Modellierung der aerodynamischen Schiffsumströmung

Das Ziel der datenbasierten Modellierung in dieser Arbeit ist die Vorhersage der Strömungsfelder aerodynamischer Schiffsumströmungen. Der Fokus liegt auf Druckfeldern und den daraus resultierenden aerodynamischen Lasten für unterschiedliche Systemparameter, welche die Betriebs- und Umweltbedingungen des Schiffes beschreiben und durch Sensoren an Bord der Schiffe erfasst werden. Dazu wird in dieser Arbeit ein Surrogatmodell entwickelt, mit dem Ziel eine geringe Laufzeit der Vorhersagen für beliebige Systemparameter zu ermöglichen. Die Modellierung ist illustrativ in Abbildung 6.1 dargestellt. Im Folgenden wird eine Übersicht über die Anforderungen und Eigenschaften der Modellerstellung gegeben. In den darauf folgenden Abschnitten werden die einzelnen Schritte der Modellerstellung detailliert beschrieben und die im vorherigen Kapitel eingeführten Methoden für den Anwendungsfall der aerodynamischen Schiffsumströmung angepasst.




Abbildung 6.1: Illustrative Darstellung der Surrogatmodellierung. In Abhängigkeit der Systemparameter α wird eine Rekonstruktion des Druckfeldes \tilde{p} modelliert. Auf Basis des Druckfeldes werden die aerodynamischen Lasten bestimmt.

In dem vorliegenden Anwendungsfall wird die Umströmung des Überwasserschiffes von verschiedenen Betriebs- und Umweltbedingungen beeinflusst. Dies sind z.B. die Fahrgeschwindigkeit, der Tiefgang oder der Windeinfluss bestehend aus der Windgeschwindigkeit und dem relativen Windwinkel. Die unterschiedlichen Parameter für die Modellbildung werden dabei

als Systemparameter bezeichnet. Für den adressierten Anwendungsfall sind nur die zeitlich gemittelten Lasten von Interesse. Daher werden im Rahmen dieser Arbeit für die Modellbildung ausschließlich zeitlich gemittelte Strömungsfelder verwendet. Diese werden basierend auf Finite-Volumen-Simulationen unter Verwendung skalenauflösender Turbulenzmodellierung und den im Kapitel 4 gezeigten Rechenmodellen bestimmt und dienen als Basis für die datenbasierte Modellierung. Für eine datenbasierte Modellierung wird ein möglichst umfangreicher Datensatz benötigt. Die Größe des benötigten Datensatzes hängt hierbei von unterschiedlichen Einflussfaktoren, wie der Varianz und Anzahl der betrachteten Systemparameter ab. Die simulationsbasierte Erstellung der Datensätze für verschiedene Systemparameter ist mit großem Aufwand verbunden. Gleichzeitig ist die räumliche Auflösung der Strömungsfelder hoch und es sind räumlich sehr viele Datenpunkte vorhanden. Die räumlichen Strömungsfelder weisen dabei wiederkehrende Strukturen auf, welche durch die datenbasierte Analyse und Modellierung abgebildet werden sollen. Das Ziel ist möglichst viele Informationen und die Charakteristik der Strömungsfelder zu extrahieren, um eine Prognose für im Betrieb auftretende (unbekannte) Systemparameter zu ermöglichen, während die Anzahl der Datenpunkte für unterschiedliche Systemparameter möglichst gering ist.

Die Bestimmung der aerodynamischen Lasten erfolgt basierend auf dem räumlichen Druckfeld auf der Oberfläche der Geometrie. Es wird dabei ausschließlich der Druckanteil berücksichtigt. Die viskosen Kräfte auf das Schiff werden bei der Lastanalyse vernachlässigt, da diese, wie bereits in Abschnitt 4.4 aufgezeigt, ein bis zwei Größenordnungen kleiner sind als die auftretenden Druckkräfte. Man beachte, dass im Rahmen der Strömungssimulation alle Kräfte berücksichtigt werden.

Das Ziel der Modellierung ist die Vorhersage des Druckfeldes $\tilde{\mathbf{p}} \in \mathbb{R}^{n_x \times n_y \times n_z}$ für die Systemparameter $\boldsymbol{\alpha} \in \mathbb{R}^{n_\alpha}$. Die Anzahl der räumlichen Punkte der Felder sind n_x , n_y und n_z , und die Anzahl der Systemparameter ist n_α . Dazu wird ein funktionaler Zusammenhang f des Druckfeldes und der Systemparameter gesucht

$$\tilde{\mathbf{p}} = f(\boldsymbol{\alpha}). \quad (6.1)$$

Das Vorgehen wird auch als parametrisierte Modellierung bezeichnet. Die Erstellung des parametrisierten Modells erfolgt in zwei Schritten. Zunächst wird eine dimensionsreduzierte Basis des Datensatzes erstellt

$$\tilde{\mathbf{p}} = g(\mathbf{r}), \quad (6.2)$$

wobei die Modellkoeffizienten bzw. reduzierten Variablen mit $\mathbf{r} \in \mathbb{R}^{n_r}$ bezeichnet sind. Die Dimensionsreduktion ermöglicht die Darstellung des Strömungsfeldes in Abhängigkeit der Koeff-

fizienten \mathbf{r} . Um die Strömungsfelder in Abhängigkeit der Systemparameter darzustellen, ist im zweiten Schritt eine Regression erforderlich

$$\mathbf{r} = h(\boldsymbol{\alpha}). \quad (6.3)$$

Durch Kombination der beiden zuvor beschriebenen Schritte ist die Darstellung der Strömungsfelder in Abhängigkeit der Systemparameter möglich

$$\tilde{\mathbf{p}} = g(h(\boldsymbol{\alpha})) = f(\boldsymbol{\alpha}). \quad (6.4)$$

Das beschriebene Vorgehen baut auf dem Ansatz von Swischuk et al. (2019) zur Erstellung von datenbasierten Modellen auf, die dort jedoch nur für sehr einfache zweidimensionale Strömungsbeispiele mit geringer Systemparameteranzahl gezeigt werden. Swischuk et al. (2019) verwendet für die Dimensionsreduktion die POD-Methode (vgl. Abschnitt 5.1). Für die Regression der POD-Koeffizienten werden unterschiedliche Regressionstechniken verwendet und verglichen, unter anderem die Polynom-basierte und die auf kleinen Neuronalen Netzwerken basierende Regression. Diese werden auch in der vorliegenden Arbeit für die Regression verwendet und in Abschnitt 6.2 detailliert beschrieben. Wie in der Arbeit von Swischuk et al. (2019) wird ebenfalls die POD-Methode für die Erstellung der dimensionsreduzierten Darstellung verwendet. Zusätzlich werden Convolutional basierte Autoencoder (CAE) eingesetzt. Diese werden z.B. von Agostini (2020) für die fluiddynamische Anwendungen einer zweidimensionalen Zylinderumströmung benutzt. Agostini (2020) vergleicht ebenfalls die POD-Methode mit der CAE-Methode für den Schritt der Dimensionsreduktion. Die beiden Methoden zur Dimensionsreduktion werden im folgenden Abschnitt 6.1 näher erläutert.

Das Vorgehen der Modellierung wird in zwei Teile aufgeteilt. Zunächst erfolgt der Offline-Teil, in welchem die Modelle erstellt werden. Anschließend folgt der Online-Teil, in welchem dann das Modell angewendet wird. Zum Offline-Teil wird teilweise das Erstellen der Datensätze, in diesem Fall durch instationäre Strömungssimulationen, hinzugezählt. Der Aufwand des Offline-Teils ist in Abhängigkeit von der verwendeten Modellvariante somit erheblich, während der Aufwand des Online-Teils gering sein muss, um eine schnelle Laufzeit der Surrogatmodells zu gewährleisten und eine Echtzeit-nahe Prognose der Strömungsfelder zu erhalten.

6.1 Dimensionsreduktion von Datensätzen

Das Erstellen der dimensionsreduzierten Darstellung hat für die datenbasierte Modellierung zwei Vorteile. Zum einen wird eine deutlich reduzierte Darstellung für den gesamten Datensatz gefunden, was zu einem geringeren Speicheraufwand führt. Zum anderen hängen die




Abbildung 6.2: Schematische Darstellung der POD-basierten Dimensionsreduktion. Für die Snapshots \mathbf{p}_i werden mittels der Singulärwertzerlegung die POD-Moden Φ_i bestimmt. Basierend auf den ersten R POD-Moden und mit den Koeffizienten \mathbf{r}_i lässt sich die Rekonstruktion des Druckfeldes $\tilde{\mathbf{p}}_i$ modellieren.

Koeffizienten der POD-Methode bzw. die reduzierten Variablen der CAE-Methode lediglich von den Systemparametern ab. Die räumlichen Informationen der Felder sind hingegen in der POD-Basis bzw. dem Decoder enthalten.

6.1.1 POD-Methode

Während die Dimensionsreduktion basierend auf der POD-Methode einfach und effizient bestimmt wird, ist diese durch die Linearität der Methode für die Reduktion nichtlinearer Systeme beschränkt. Die Druckfelder der Datenbasis werden jeweils als Spaltenvektoren in einer Snapshot-Matrix $\mathbf{Q} \in \mathbb{R}^{n \times m}$ zusammengefasst. Die einzelnen Datenpunkte des Druckes müssen dabei jeweils auf dem gleichen räumlichen Gitter vorliegen. Ein strukturiertes Gitter ist hingegen nicht erforderlich, wird aber in der vorliegenden Arbeit verwendet, um die POD- und CAE-basierte Methoden besser vergleichen zu können und unterschiedliche Beladungszustände einfach erfassen zu können. Für die Snapshot-Matrix lässt sich die Singulärwertzerlegung mittels Gleichung (5.1) bestimmen. Die ersten n_R Spaltenvektoren der Matrix Φ werden für die dimensionsreduzierte Rekonstruktion des Druckfeldes $\tilde{\mathbf{p}}$ verwendet

$$\mathbf{g}(\mathbf{r}) = \tilde{\mathbf{p}} = \sum_{j=1}^{n_R} \Phi_j r_j. \quad (6.5)$$

Die Anzahl der für die Rekonstruktion verwendeten POD-Moden $n_R \ll m$ ist dabei deutlich kleiner als die Anzahl der für die POD verwendeten Datensätze m . Ein wichtiger Schritt der Modellbildung ist die Auswahl der Anzahl der für die Rekonstruktion berücksichtigten POD-Moden n_R . Dazu kann beispielsweise die relative kumulative Matrixenergie der Moden $\kappa(n_R)$ bestimmt werden

$$\kappa(n_R) = \frac{\sum_{j=1}^{n_R} \sigma_j^2}{\sum_{j=1}^m \sigma_j^2}, \quad (6.6)$$




Abbildung 6.3: Schematische Darstellung der CAE-basierten Dimensionsreduktion. Während des Trainingsprozesses werden die Gewichte des Encoders und des Decoders optimiert, um eine möglichst gute Rekonstruktion der Druckfelder $\tilde{\mathbf{p}}$ zu erreichen. Durch Vorgabe der reduzierten Variablen \mathbf{r}_i und Anwendung des Decoders wird die Modellierung der Druckfelder für unbekannte Systemparameter ermöglicht.

wobei σ_j die jeweiligen Singulärwerte sind. Häufig wird angenommen, dass eine ausreichende Anzahl an Moden berücksichtigt wird, wenn $\kappa(n_R) > 0,9$ gilt. Die POD-basierte Dimensionsreduktion ist schematisch in Abbildung 6.2 dargestellt. Im zweiten Schritt der Modellbildung der Regression der Koeffizienten werden für die im Trainingsdatensatz enthaltenen Druckfelder die Modellkoeffizienten durch Gleichung (5.4) bestimmt. Diese werden später zum Trainieren des Regressionsschrittes verwendet. Die unterschiedlichen Regressionsmethoden werden im Abschnitt 6.2 erläutert und diskutiert.

6.1.2 CAE-Methode

Die zweite im Rahmen dieser Arbeit angewendete Methode zur Dimensionsreduktion sind Autoencoder basierend auf Convolutional Neuronalen Netzen (CAE). Durch die Kombination mehrerer hierarchisch angeordneter nichtlinearer Schichten werden nichtlineare Trends in den Datenfeldern effizient extrahiert. CAEs werden bereits für verschiedene Problemstellungen der Strömungsmechanik angewendet. Für die nichtlineare Zerlegung von Moden eines Strömungsfeldes verwenden Murata et al. (2020) CNN-basierte Autoencoder. Agostini (2020) nutzt die nichtlineare Dimensionsreduktion basierend auf CAE für unterschiedliche Anwendungsbeispiele. Das grundlegende Konzept der Autoencoder wurde bereits in Abschnitt 5.6 beschrieben. Der Vorteil von CAE ist das Berücksichtigen räumlicher Korrelationen innerhalb der Modellierung. Die CNN-Schichten benötigen dadurch deutlich weniger Parameter für das gesamte Netzwerk als eine vollständig vernetzte Struktur. Die Eingabe der Daten in den Autoencoder erfolgt als dreidimensionaler Tensor und nicht wie bei der POD-Methode als Spaltenvektor. Während des Erstellens bzw. Trainierens des Modells werden die Gewichte des Encoder-Teils sowie des Decoder-Teils angepasst. Ziel ist dabei, dass die Ausgabe des Decoders mit der Eingabe des Encoders übereinstimmt. Für die spätere Anwendung des vollständig parametrisierten

Modells wird ausschließlich der Decoder Anteil benötigt und ausgeführt

$$g(\mathbf{r}) = \tilde{\mathbf{p}} = \mathcal{F}_{Dec}(\mathbf{r}). \quad (6.7)$$

Eine schematische Darstellung der CAE-basierten Dimensionsreduktion ist in Abbildung 6.3 zu finden. Die Eingabewerte der reduzierten Variablen \mathbf{r} werden in einem weiteren Schritt (6.4) durch Regression für die jeweiligen Systemparameter bestimmt. Durch die Anwendung der Convolutional Layer und der Pooling-Layer werden spezifische Anforderungen an die räumliche Struktur der Daten der Strömungsfelder gestellt. Diese müssen auf einem gleichmäßigen und räumlich strukturierten Metagitter vorliegen. Die Ausgabe des Autoencoders muss die gleichen Dimensionen wie die Eingabe haben. Die Dimensionen werden innerhalb des Autoencoders in den Pooling-Schichten des Encoders und den Schichten zur räumlichen Hochskalierung im Decoder modifiziert. Die Anzahl der Datenpunkte muss daher in alle Raumrichtungen ein Vielfaches von zwei betragen. Hierfür werden die Strömungsfelder der Finiten-Volumen-Simulation vor Anwendung der datenbasierten Modellierung entsprechend vorbereitet (vgl. Abschnitt 6.3).

Die einzelnen Netzwerkschichten des Encoders und Decoders werden symmetrisch angeordnet. Nach der letzten CNN-Schicht des Encoders werden die einzelnen Neuronen vollständig mit den Neuronen der reduzierten Ebene verbunden und auch wieder entsprechend mit der ersten CNN-Schicht des Decoders. Eine Schicht des Autoencoders besteht aus einer oder mehreren Faltungs-Schichten, der Anwendung der Aktivierungsfunktion und dem abschließenden Anwenden des Max-Poolings. Durch das Pooling wird die räumliche Dimension reduziert. Die Schichten werden im Encoder und entsprechend im Decoder mehrmals hintereinander angeordnet, sodass ein Netzwerk mit mehreren Schichten gebildet wird, vgl. Abschnitt 5.3.

Durch die Vorgabe unterschiedlicher Hyperparameter wird die Modellstruktur und der Trainingsprozess des CAE-Netzes beeinflusst. Die Hyperparameter und deren Einfluss auf die CAE-Modellierung werden ausführlich in Abschnitt 7.3.1 beschrieben. Das Lernen bzw. Trainieren der Netzwerkstruktur des Autoencoders erfordert viele Optimierungsdurchgänge. Im Vergleich zur POD-basierten Variante ist diese Variante deutlich aufwendiger für den Schritt der Dimensionsreduktion innerhalb des Offline-Teils.

6.2 Regression der Koeffizienten

Für beide zuvor vorgestellten Methoden, die POD-Methode und die CAE-Methode, liegen nach der Dimensionsreduktion POD-Koeffizienten oder reduzierten Variablen \mathbf{r} vor. Das Ziel der Regression ist, einen funktionalen Zusammenhang zwischen den Systemparametern $\boldsymbol{\alpha}$ und den Variablen \mathbf{r} des reduzierten Raumes aufzustellen ($\boldsymbol{\alpha} \mapsto \mathbf{r}$). Es wird angenommen, dass zwischen

den einzelnen Koeffizienten keine Korrelation besteht und diese daher unabhängig voneinander modelliert werden können. Für die Trainingsdaten werden die Koeffizientenwerte durch Dimensionsreduktion direkt bestimmt. Diese Werte dienen zusammen mit den bekannten Systemparametern als Trainingsdaten für den Regressionsschritt.

Im Rahmen dieser Arbeit werden drei unterschiedliche Methoden für den Regressionsschritt verwendet: die Polynomregression, die Regression basierend auf Neuronalen Netzen und die Gaußprozess-Regression. Die Details der drei Methoden werden im Folgenden erläutert.

Polynomregression

In der Polynom-basierten Regression wird der funktionale Zusammenhang zwischen den reduzierten Variablen \mathbf{r} und den Systemparametern $\boldsymbol{\alpha}$ durch Polynome approximiert

$$\mathbf{r}(\boldsymbol{\alpha}) = \xi_0 + \xi_1\alpha_1 + \xi_2\alpha_2 + \xi_3\alpha_1\alpha_2 + \xi_4\alpha_1^2 + \xi_5\alpha_2^2 + \dots, \quad (6.8)$$

wobei obiges Beispiel hier ein Polynom bis zum 2. Grad und $n_\alpha = 2$ Systemparameter darstellt. Die Gleichung lässt sich auch basierend auf Matrizen darstellen

$$\mathbf{r}(\boldsymbol{\alpha}) = \Xi \cdot \boldsymbol{\alpha}^*. \quad (6.9)$$

Die Matrix $\Xi \in \mathbb{R}^{n_R \times k}$ enthält die bisher unbekanntenen Regressionskoeffizienten $[\xi_0, \xi_1, \dots, \xi_k]$ und $\boldsymbol{\alpha}^* \in \mathbb{R}^{k \times j}$ die Polynomwerte der Systemparameter $\boldsymbol{\alpha}$ für den Datensatz der Größe j . Zur Bestimmung der Regressionskoeffizienten werden die für die Trainingsdaten bekannten Werte für $\boldsymbol{\alpha}$ und \mathbf{r} in das Gleichungssystem eingesetzt und das überbestimmte Gleichungssystem durch die Methode der kleinsten Fehlerquadrate approximiert. Wenn lediglich ein Teil der Daten je Approximationsschritt zur Verfügung steht, kann zur Approximation ein iteratives stochastisches Gradientenabstiegsverfahren angewendet werden.

NN-Regression

Die zweite Methode des Regressionsschrittes basiert auf kleinen, vollständig vernetzten, vorwärtsgerichteten Neuronalen Netzen. Als Eingabe werden die Systemparameter $\boldsymbol{\alpha}$ vorgegeben. Die Ausgabe besteht aus den Koeffizienten \mathbf{r} . Die versteckten Schichten dienen zur Approximation des funktionalen Zusammenhangs der reduzierten Variablen und der Systemparameter. Dazu werden einige wenige versteckte Schichten mit einer relativ geringen Anzahl an Neuronen verwendet. Für die nichtlineare Aktivierungsfunktionen innerhalb des Netzwerkes wird die *elu*-Funktion (vgl. Abschnitt 5.3) verwendet. Mit beispielhaft zwei versteckten Schichten

lautet die Approximation für die reduzierten Variablen \mathbf{r}

$$\mathbf{r}(\boldsymbol{\alpha}) = f_{Elu}(\mathbf{W}_3 \cdot f_{Elu}(\mathbf{W}_2 \cdot (f_{Elu}(\mathbf{W}_1 \cdot \boldsymbol{\alpha} + \mathbf{b}_1) + \mathbf{b}_2) + \mathbf{b}_3), \quad (6.10)$$

wobei \mathbf{W}_1 und \mathbf{W}_2 die Gewichte der versteckten Schichten und \mathbf{W}_3 die Gewichte der Ausgabeschicht sind. Die Größe der Matrizen hängt von der gewählten Anzahl an Knoten je Schicht ab. Die Bestimmung der Gewichte erfolgt durch Trainieren des Netzwerkes mittels der Adam-Optimierung. Die Optimierung des NN für die Regression erfolgt dabei unabhängig von der Optimierung des CAE.

Gaußprozess-Regression (Kriging)

Eine weitere Möglichkeit für die Regression der Koeffizienten ist die Verwendung von Gaußprozessen. Für die Interpolation räumlicher Punkte wird das Verfahren auch als Kriging bezeichnet. Der Gaußprozess ist ein stochastischer Prozess zur Beschreibung der Wahrscheinlichkeitsverteilung möglicher Funktionen

$$r(\boldsymbol{\alpha}) \sim \mathcal{GP}(m(\boldsymbol{\alpha}), k(\boldsymbol{\alpha}, \boldsymbol{\alpha}')). \quad (6.11)$$

Dabei besteht die Analogie zur Gauß-Normalverteilung und der Gaußprozess wird über die Erwartungswertfunktion $m(\boldsymbol{\alpha})$ und die Kovarianzfunktion $k(\boldsymbol{\alpha}, \boldsymbol{\alpha}')$ eindeutig beschrieben. Im Folgenden wird die Theorie der Gaußprozess-Regression zusammengefasst. Für eine ausführliche Beschreibung wird auf Rasmussen und Williams (2006) verwiesen.

Für die Erwartungswertfunktion wird der konstante Wert $m(\boldsymbol{\alpha}) = 0$ verwendet. Die Kovarianzfunktion $k(\boldsymbol{\alpha}, \boldsymbol{\alpha}')$ beschreibt die Kovarianz zwischen Paaren von Zufallsvariablen und wird auch als Kernel bezeichnet. Für einen gültigen Kernel muss die Matrix der Kovarianzen positiv definit sein. Ein häufig angewendeter Kernel ist der quadratisch exponentielle Kernel (RBF-Kernel)

$$k(\boldsymbol{\alpha}, \boldsymbol{\alpha}') = \sigma^2 \exp\left(-\frac{\|\boldsymbol{\alpha} - \boldsymbol{\alpha}'\|^2}{2l^2}\right). \quad (6.12)$$

Dabei beschreiben σ^2 die Varianz und l ein Längenmaß, welche als Hyperparameter der Methode während des Trainingsprozesses an die Charakteristik der Trainingsdaten angepasst werden. Zur Anpassung der Hyperparameter wird die Log-Marginal-Likelihood-Funktion eingesetzt, vgl. Rasmussen und Williams (2006). Für mehrdimensionale Eingabedaten, wie in dieser Arbeit $\boldsymbol{\alpha} \in \mathbb{R}^{n_\alpha}$, kann für jede Eingabe jeweils ein Längenmaß $l \in \mathbb{R}^{n_\alpha}$ bestimmt werden.

Durch Einbringen der Trainingsdaten als bekannte Stützstellen in das Verfahren, ergibt sich die a-posteriori-Wahrscheinlichkeitsverteilung. Zur Vorhersage unbekannter Werte $\mathbf{r}_*(\mathbf{A}_*)$ der

reduzierten Variablen wird die gemeinsame multivariate Verteilung von \mathbf{r} und \mathbf{r}_* verwendet

$$\begin{bmatrix} \mathbf{r} \\ \mathbf{r}_* \end{bmatrix} \sim \mathcal{N}\left(0, \begin{bmatrix} \mathbf{K} & \mathbf{K}_* \\ \mathbf{K}_*^T & \mathbf{K}_{**} \end{bmatrix}\right). \quad (6.13)$$

Hierbei sind $\mathbf{K} = K(\mathbf{A}, \mathbf{A})$ die Kovarianzmatrix der Parameter der Trainingsdaten, $\mathbf{K}_* = K(\mathbf{A}, \mathbf{A}_*)$ die gemischte Kovarianzmatrix und $\mathbf{K}_{**} = K(\mathbf{A}_*, \mathbf{A}_*)$ die Kovarianzmatrix der Parameter für welche die Koeffizienten bestimmt werden sollen. Um die Werte der zu bestimmenden Koeffizienten \mathbf{r}_* zu ermitteln, wird die bedingte Wahrscheinlichkeitsverteilung benötigt

$$\mathbf{r}_* | \mathbf{r}, \mathbf{A}, \mathbf{A}_* \sim \mathcal{N}(\mathbf{K}_*^T \mathbf{K}^{-1} \mathbf{K} \mathbf{r}, \mathbf{K}_{**} - \mathbf{K}_*^T \mathbf{K}^{-1} \mathbf{K}_*). \quad (6.14)$$

Zur Bestimmung der unbekanntenen Koeffizienten werden neben den Kovarianzmatrizen die Werte der bekannten Koeffizienten der Trainingsdaten \mathbf{r} benötigt.

Da für die Gaußprozess-basierte Modellierung keine Parameter bestimmt werden, handelt es sich um ein parameterfreies Modell. Bei der Polynomregression und der NN-basierten Regression hingegen handelt es sich um parameterabhängige Modelle, da jeweils die Eigenschaften der Regression in der Matrix $\mathbf{\Xi}$ bzw. den Gewichten \mathbf{W}_i als Parameter enthalten sind.

6.3 Vorbereitung der Datenfelder

Die Simulationsergebnisse der Finiten-Volumen-Methode liegen auf einem irregulären unstrukturierten Gitter vor. Die datenbasierten Methoden stellen Anforderungen an die Struktur der Daten. Für die Anwendung der CAE-Methode müssen die Daten räumlich strukturiert vorliegen. Daher ist die Interpolation der Strömungsfelder basierend auf den Finite-Volumen-Simulationen auf ein strukturiertes dreidimensionales Metagitter erforderlich. Für die POD-basierte Methode ist eine einheitliche Gitterstruktur für den gesamten Datensatz erforderlich und die Daten müssen nicht notwendigerweise strukturiert vorliegen. Aufgrund der unterschiedlichen Überwasserschiffsgeometrien durch die variierende Anzahl und die Verteilung der Ladung an Deck, variiert auch die Verteilung der Finiten-Volumen und es liegt keine einheitliche Gitterstruktur vor. Um für die CAE und POD-Methode ein einheitliches Vorgehen bei der Modellierung zu erreichen, werden für beide Methoden die gleichen Metagitterdaten verwendet.

Für das Metagitter wird ein isotropes kartesisches Punktegitter verwendet. Die Dimensionen des Metagitters sind n_x, n_y und n_z . Die räumliche Ausdehnung des Gitters umfasst ausschließlich das direkte Umfeld des Strömungsfeldes im Bereich der Geometrie und ist damit in den

Abmessungen deutlich kleiner als das Finite-Volumen-Gitter.

Die Interpolation der Daten erfolgt durch eine mit dem reziproken Abstand gewichteten Summe der umliegenden Feldgrößen. Um die Strömungsgrößen Φ an einem Punkt P_{MG} des Metagitters zu bestimmen, wird zunächst der nächstgelegene Zellmittelpunkt des Finite-Volumen-Gitters $P_{FV,0}$ gesucht. Die daran angrenzenden Zellenzentren $P_{FV,k}; k \geq 1$ und die zugehörigen Variablenwerte sind aus dem Finite-Volumen-Verfahren bekannt und werden innerhalb der Interpolation berücksichtigt

$$\Phi(P_{MG}) = \frac{\sum_{k=0}^{n_{FV}} \frac{1}{d_k} \Phi(P_{FV,k})}{\sum_{k=0}^{n_{FV}} \frac{1}{d_k}}, \quad (6.15)$$

wobei n_{FV} die Anzahl der benachbarten Zellzentren ist. Die jeweilige euklidische Distanz zwischen dem Punkt P_{MG} des Metagitters und dem Zellzentrum des Finite-Volumen-Gitters $P_{FV,k}$ wird mit d_k bezeichnet. Die Genauigkeit der durchgeführten Interpolation hängt von der Auflösung des Metagitters ab.

Durch die Betrachtung unterschiedlicher Verteilungen von Containerstapeln an Deck, ist die Ausdehnung des Fluidfeldes nicht konstant. Um eine einheitliche Darstellung des Strömungsfeldes zu erhalten, werden für die Punkte des Metagitters, welche innerhalb der Containerstapel liegen, Werte durch Extrapolation der Variablen des außenliegenden Fluidfeldes bestimmt. Hierdurch wird ein einheitliches Feld für das Durchführen der POD- oder CAE-basierten Dimensionsreduktion erzielt. Dies ermöglicht das einheitliche Anwenden der Methoden, trotz veränderlicher Geometrien. Für die weiteren Modellierungsschritte sind ausschließlich die Werte, welche außerhalb der Geometrie und der Containerstapel liegen von Interesse. Die innerhalb der Containerstapel liegende Werte des Strömungsfeldes werden nicht zur Bestimmung der aerodynamischen Lasten benötigt. Die innerhalb der Geometrie liegenden Punkte des Metagitters werden für die Modellierung ebenfalls nicht berücksichtigt. Die Punkte des Metagitters, welche innerhalb des Fluidfeldes oder welche innerhalb der Geometrie liegen, werden auf Basis der triangulierten Beschreibung der Geometrie bestimmt und als dreidimensionale Zustandsmatrix $\mathbf{M}_G \in \mathbb{R}^{n_x \times n_y \times n_z}$ gespeichert. Die Dimensionen entsprechen dabei den Dimensionen des Metagitters n_x, n_y und n_z .

Für die Bestimmung der resultierenden aerodynamischen Drucklasten auf dem Metagitter werden neben dem Druckfeld zusätzlich Informationen über die Geometrie des jeweiligen Überwasserschiffes benötigt. Die Bestimmung der aerodynamischen Lasten erfolgt basieren auf einer Matrix, welche die zu den jeweiligen Randpunkten des Metagitters zugehörigen Informationen über die Orientierung und Größe der Flächen enthält. Diese Informationen basieren auf der triangulierten Darstellung der Oberflächengeometrie. Für jede triangulierte Fläche wird der nächstgelegene Punkt des Metagitters bestimmt und an diesem der Flächeninhalt und die Orientierung der Oberfläche in der Kraftmatrix $\mathbf{M}_F \in \mathbb{R}^{n_x \times n_y \times n_z \times 3}$ gespeichert. Für einen Punkte k

der Matrix wird der dreidimensionale Vektor jeweils bestimmt

$$\mathbf{M}_{F,k} = \sum_{i=0}^{n_A} \mathbf{n}_{i,k} A_{i,k}, \quad (6.16)$$

wobei \mathbf{n}_i der Normalenvektor und A_i der Flächeninhalt der jeweiligen triangulierten Fläche der Geometrie sind. n_A beschreibt die Anzahl der triangulierten Flächen, welche dem betrachtete Punkt des Metagitters am nächsten liegen. Nur für die unmittelbaren Nachbarnpunkte der Oberfläche ist $n_A \neq 0$, für alle übrigen ist $n_A = 0$ und somit der Wert der Kraftmatrix ebenfalls 0. Mittels der Kraftmatrix werden die aerodynamischen Lasten basierend auf dem rekonstruierten Druckfeld $\tilde{\mathbf{p}}$ bestimmt

$$\mathbf{F} = \sum_{k=1}^N \mathbf{M}_{F,k} \cdot \tilde{\mathbf{p}}_k. \quad (6.17)$$

Die Anzahl aller räumlichen Punkte ist N . Durch die Approximation der Oberfläche der Geometrie durch die nächstgelegenen Punkte des Metagitters entstehen zusätzliche Ungenauigkeiten.

6.4 Erstellen und Lernen der Modelle

Im Folgenden wird auf anwendungsbezogene Aspekte der Modellerstellung bzw. des Trainingsprozesses eingegangen. Außerdem werden die Besonderheiten der vorliegenden Problemstellung dargestellt. Zunächst wird auf die Generalisierbarkeit der erstellten CAE- bzw. POD-basierten Modelle und die damit verbundenen Anforderungen an die Aufteilung des benötigten Datensatzes Bezug genommen. Des Weiteren werden verschiedene Gütekriterien beschrieben, welche für die quantitative Beurteilung der erstellten Modelle von Bedeutung sind.

Außerdem wird für die CAE-basierte Modellerstellung der Ansatz des kombinierten Trainings beider Modellierungsschritte eingeführt. Dabei wird die dimensionsreduzierte Darstellung und die Regression der Koeffizienten in einem gemeinsamen Trainingsprozess gelernt.

6.4.1 Generalisierbarkeit

Ziel der datenbasierten Modellierung ist die Erstellung eines generalisierten Modells, welches für vorher unbekannte Systemparameter eine zuverlässige und exakte Prognose des Druckfeldes erzeugt. Werden bei der Erstellung des Modells zu viele Parameter gelernt, passt sich das Modell zu sehr an die Charakteristik der Trainingsdaten an, was auch als Überanpassung (engl. *overfitting*) bezeichnet wird. Durch die Überanpassung ist die Genauigkeit für die Trainingsdaten sehr hoch, während die Genauigkeit für unbekannte Daten gering ist. Neben der geeigneten Auswahl des Modellierungsansatzes und der Hyperparameter, ist die Verwendung unterschiedlicher Teilmengen des Datensatzes für das Training, die Validierung und das Testen des Modells von Bedeutung, um ein generalisiertes Modell zu erhalten.

Die **Trainingsdaten** werden während des Trainings des Modells verwendet. Dabei werden die Parameter des Modells angepasst, um die Trainingsdaten möglichst exakt abzubilden. Der Großteil der zur Verfügung stehenden Daten wird während des Trainings genutzt.

Die **Validierungsdaten** dienen zur Beurteilung der Genauigkeit des Modells für unbekannte Daten während des Trainingsprozesses. Auf Grundlage der Genauigkeit des Modells zur Abbildung der Validierungsdaten wird das geeignetste Modell bzw. die geeignetsten Hyperparameter ausgewählt.

Die **Testdaten** dienen zur Beurteilung der Genauigkeit des finalen Modells und werden ausschließlich am Ende des Modellierungsprozesses ausgewertet, um eine zuverlässige Aussage der Vorhersagequalität des finalen Modells zu erhalten.

Für den Validierungsschritt wird innerhalb dieser Arbeit ausschließlich das Auslassen einer Teilmenge (engl. hold-out) angewendet. Nach dem Auslassen der Testdaten wird dabei ein kleiner Teil des restlichen Datensatzes für die Validierung verwendet und der restliche größere Teil für das Training. Bei der alternativen Kreuzvalidierung (engl. cross-validation) wird mehrfach die Teilmenge des Validierungsdatsatzes variiert und das Training des Modells mehrfach durchgeführt. Anschließend wird durch Mittelung der Modellgenauigkeit über alle Durchläufe die resultierende Genauigkeit bestimmt. Da die Kreuzvalidierung insbesondere für komplexe Modelle mit hohem Trainingsaufwand verbunden ist, wird innerhalb dieser Arbeit ausschließlich die Hold-Out-Variante zur Validierung eingesetzt.

Um eine Überanpassung der Modellierung zu vermeiden, werden unterschiedliche Techniken zur Regularisierung eingesetzt. Neben unterschiedlichen Anpassungen der Struktur des Modells ist eine weitere Möglichkeit das Training frühzeitig zu stoppen (engl. early stopping). Dabei wird das Training beendet, nachdem der Fehler der Validierungsdaten sich über eine bestimmte Anzahl von Trainingsdurchläufe nicht weiter verbessert hat.

6.4.2 Gütekriterien

Im Bereich des Maschinellen Lernens werden unterschiedliche Gütekriterien bzw. Metriken zur Beurteilung der trainierten Modelle genutzt. In Abhängigkeit von der Problemstellung sind dabei unterschiedliche Metriken von Interesse. Die Metriken werden dabei innerhalb der Zielfunktion für das Lernen des Modells (5.6) oder zur nachträglichen Beurteilung angewendet.

Für den vorliegenden Anwendungsfall der aerodynamischen Schiffsumströmung werden zur Beurteilung der Modelle unterschiedliche Metriken verwendet. Zur Beurteilung der Vorhersagequalität der dimensionslosen Druckfelder wird der Mittelwert des absoluten Fehlers über alle

Gitterpunkte N und über alle betrachteten Druckfelder des Datensatzes M gemittelt

$$E_P = \frac{1}{M} \sum_{k=1}^M |\tilde{\mathbf{c}}_{p_k} - \mathbf{c}_{p_k}|_{mean} = \frac{1}{M} \frac{1}{N} \sum_{k=1}^M \sum_{l=1}^N |\tilde{c}_{p_{k,l}} - c_{p_{k,l}}|. \quad (6.18)$$

Das Ziel der Surrogatmodellierung ist die Vorhersage der aerodynamischen Kräfte basierend auf dem Druckfeld. Daher werden ebenfalls die mittleren absoluten Fehler der abgeleiteten dimensionslosen Längs- E_X und Querkraft E_Y als Metriken bestimmt (6.17). Diese werden entsprechend mit dem wahren Wert c_k und der Rekonstruktion \tilde{c}_k gebildet und über den Datensatz gemittelt

$$E_X = \frac{1}{M} \sum_{k=1}^M \|\tilde{c}_{X_k} - c_{X_k}\|; \quad E_Y = \frac{1}{M} \sum_{k=1}^M \|\tilde{c}_{Y_k} - c_{Y_k}\|. \quad (6.19)$$

Für die Verlustfunktion des Trainings der CNN-basierten Autoencoder wird die Metrik des Druckfeldes E_P verwendet. Für die Analyse der Ergebnisse werden zusätzlich die mittleren Fehler der Kräfte E_X und E_Y herangezogen.

6.4.3 Simultanes Lernen des Gesamtmodells

Die Erstellung der Surrogatmodelle erfolgt in zwei Schritten: die parametrisierte Dimensionsreduktion des Datensatzes und die anschließende Regression der auftretenden Koeffizienten in Abhängigkeit der Systemparameter. Dabei werden die beiden Schritte der Modellbildung nacheinander durchgeführt. Die dimensionsreduzierte Darstellung des Datensatzes und damit der Verlauf der Koeffizienten lässt sich bei der Erstellung der POD-basierten Methode nicht beeinflussen. Bei der CAE-basierten Methode hingegen lassen sich die resultierenden Koeffizienten durch das Einbringen zusätzlicher Terme für die Zielfunktion beeinflussen. Dabei werden beide Schritte der Modellierung simultan gelernt.

Angelehnt an das Vorgehen von Champion et al. (2019), bei welchem eine Autoencoder basierte Darstellung der Koordinaten und das simultane Modellieren eines dynamischen Systems erfolgt, wird die CAE-Variante der Dimensionsreduktion simultan mit dem Polynom-basierten Regressionsschritt trainiert. Hierbei wird der Raum der reduzierten Variablen \mathbf{r} innerhalb des Autoencoders so trainiert, dass dieser sich leicht durch eine Polynomregression der Systemparameter darstellen lässt. Dazu werden die Parameter des Autoencoders sowie die Parameter der Polynomregression Ξ simultan innerhalb eines kombinierten Optimierungsschrittes iterativ angepasst. Die kombinierte Modellierung ist schematisch in Abbildung 6.4 dargestellt. Die Optimierung wird mittels des Adam-Gradientenabstiegsverfahrens durchgeführt. Für den Autoencoder und den Regressionsschritt wird eine kombinierte Zielfunktion vorgegeben

$$E = \lambda_1 |\tilde{\mathbf{p}} - \mathbf{p}|_{mean} + \lambda_2 |\hat{\mathbf{r}} - \mathbf{r}|_{mean} + \lambda_3 (|\Xi|_{mean} - \bar{\xi}_*). \quad (6.20)$$

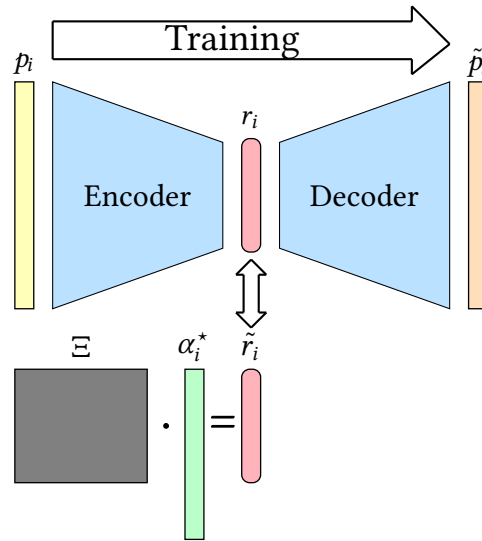


Abbildung 6.4: Schematische Darstellung des simultanen Trainings des Reduktions- (oben) und Regressions-schrittes (unten). Während des Trainings des Autoencoders werden simultan die Werte der Polynomregression Ξ angepasst, um ein optimiertes Gesamtmodell zu erhalten. Gekoppelt wird das Training durch Berücksichtigen der Abweichung der reduzierten Variablen r_i des Autoencoders und \tilde{r}_i der Polynomregression innerhalb der Zielfunktion des Trainings.

Der erste Teil der Zielfunktion $|\tilde{\mathbf{p}} - \mathbf{p}|$ entspricht der Zielfunktion des Autoencoders für das Druckfeld. Als zusätzlicher Term werden die reduzierten Variablen des Autoencoders \mathbf{r}

$$\mathbf{r} = F_{Enc}(\mathbf{p}), \quad (6.21)$$

mit den zugehörigen Werten des Regressions-schrittes $\hat{\mathbf{r}}$ (vgl. Gleichung (6.9)) verglichen

$$\hat{\mathbf{r}} = \Xi \cdot \boldsymbol{\alpha}^*. \quad (6.22)$$

Zusätzlich wird innerhalb der kombinierten Zielfunktion ein dritter Term $|\Xi| - \bar{\xi}_*$ berücksichtigt. So wird sichergestellt, dass nicht der Betrag der reduzierten Variablen \mathbf{r} durch die Optimierung reduziert wird, sondern die Abweichung der reduzierten Variablen $|\hat{\mathbf{r}} - \mathbf{r}|$. Der Wert für $\bar{\xi}_*$ wird so gewählt, dass er ungefähr dem Initialisierungswert für $|\Xi|$ entspricht. Die drei Anteile der Zielfunktion werden durch die jeweiligen Werte λ_i gewichtet. Die Größenordnungen der drei Anteile der Zielfunktion stimmen überein, weshalb auch die drei zugehörigen Gewichte λ_i in einer gleichen Größenordnung gewählt werden. Durch das kombinierte Training beider Modellierungsschritte steigt der Trainingsaufwand im Vergleich zum reinen Training des Autoencoders nur geringfügig an.

7 Ergebnisse der datenbasierten Modellierung

Im Folgenden werden die einzelnen Schritte der Surrogatmodellierung für die aerodynamische Schiffsumströmung angewendet. Zur Validierung der einzelnen Schritte werden die Surrogatbasierten Druckfelder und resultierenden Kräfte mit den Finite-Volumenbasierten Metagitterdaten des Druckes und der Kräfte verglichen. Hierbei werden zwei unterschiedlich komplexe Datensätze betrachtet, die sich in der Anzahl der betrachteten Systemparameter unterscheiden. Durch die unterschiedlichen Eigenschaften und die Charakteristik der Datensätze müssen die Parameter für die Surrogatmodellbildung jeweils angepasst werden.

Zunächst werden die unterschiedlichen Datensätze und deren Eigenschaften vorgestellt. Um einen Überblick über die Möglichkeiten zur Dimensionsreduktion der Datensätze zu erhalten, wird die POD-basierte Analyse der Datensätze dargestellt. Für die CAE-basierte Dimensionsreduktion wird der Einfluss der unterschiedlichen Hyperparameter analysiert. Anschließend werden die Ergebnisse der datenbasierten Modellierung visualisiert und erläutert und für die unterschiedlichen Modellierungsvarianten und Datensätze vergleichend dargestellt.

Die Beurteilung der einzelnen Modellierungsschritte sowie der finalen Surrogatmodellen erfolgt durch die mittleren, dimensionslosen Fehler E_P , E_X und E_Y . Die Druckfelder sind mittels des Staudrucks $0,5\rho u^2$ dimensionslos. Für die dimensionslosen Kraftbeiwerte c_X und c_Y im schiffsfesten Koordinatensystem wird zur dimensionslosen Darstellung eine Einheitsfläche $A = 1m^2$ verwendet.

7.1 Eigenschaften der Datensätze

Die jeweiligen simulationsbasierten Druckfelder für unterschiedliche Systemparameter bilden die Grundlage der datenbasierten Modellierung. Für die dreidimensionalen Druckfelder werden jeweils unterschiedliche Beladungszustände und Windwinkel betrachtet. Die Datensätze A und B unterscheiden sich in der Anzahl der unterschiedlich berücksichtigten Höhen der Containerstapel. In Datensatz A haben alle Containerstapel eine einheitliche Höhe. In Datensatz B

haben jeweils zwei in Längsrichtung benachbarte Containerstapel die gleiche Höhe und es gibt drei variable Stapelhöhen. Der Umfang und die Eigenschaften der beiden Datensätze werden im Folgenden erläutert.

7.1.1 Datensatz A

Datensatz A basiert auf der Geometrie des Containerfeederschiffes, wie sie bereits im ersten Teil dieser Arbeit für die Untersuchungen im Windkanal und die Validierung der numerischen Methode (vgl. Abschnitt 3.5) verwendet wird. Da zur Erstellung des Datensatzes eine große Anzahl Simulationen für die unterschiedlichen Systemparameter notwendig ist, wird eine modifizierte, vereinfachte Geometrie des Containerfeederschiffes verwendet. Die Modifikation besteht in einer vereinfachten Modellierung der Rückseite des Deckshauses, und reduziert die Anzahl der benötigten Kontrollvolumen für die Simulationen bzw. den Simulationsaufwand. Die verwendete Geometrie ist in Abbildung 7.1 dargestellt.




Abbildung 7.1: Darstellung der Geometrie und der Verteilung der Container an Deck für Datensatz A. Die Höhe aller Containerstapel ist in der jeweiligen Variante einheitlich.

Im Unterschied zu den zuvor in Kapitel 4 durchgeführten Simulationen werden die Simulationen für die Datenbasis im Großausführungsmaßstab durchgeführt. Vereinfacht wird für die Geschwindigkeit der Zuströmung ein über die gesamte Höhe konstantes Geschwindigkeitsprofil vorgegeben. Die Geschwindigkeit beträgt $u_{ref} = 20\text{m/s}$. Damit ergibt sich eine Reynoldszahl $Re = 1,8 \cdot 10^8$.

Die Gitterauflösung im Nahbereich der Geometrie ist $\Delta x = \Delta y = \Delta z = 1\text{m}$ und entspricht damit in etwa der Auflösung B der im Abschnitt 4.2 beschriebenen Gitterstudie. Die Anzahl der Kontrollvolumen beträgt ca. $1,8 \cdot 10^6$, und variiert leicht je nach betrachtetem Beladungsfall. Die weiteren Parameter der Simulation stimmen mit dem zuvor vorgestellten Setup überein (vgl. Abschnitt 4.1). Für die Turbulenzmodellierung wird, wie bereits zuvor, das hybride RANS/LES-Modell (IDDES) angewendet. Als Datenbasis für die datenbasierte Modellierung dienen die zeitlich gemittelten Größen des simulierten transienten Strömungsfeldes. Die Mittelung umfasst ca. $35 L/u_{ref}$ Überströmungszeiten. Um eine einheitliche Struktur der Daten zu erhalten, werden die gemittelten Strömungsgrößen auf ein einheitliches strukturiertes Metagitter interpoliert (vgl. Abschnitt 6.3). Die Anzahl der Gitterpunkte beträgt dabei $n_x = 320$ und $n_y = n_z = 64$.

Die betrachteten Systemparameter sind der Zuströmwinkel β und die Höhe der Containerstapel an Deck h_C . Für Datensatz A wird zunächst nur eine gleichmäßige Höhe aller Containerstapel berücksichtigt. Somit ist die Gesamtzahl der Systemparameter $n_\alpha = 2$. Für die Höhe der Containerstapel wird die diskrete Stapelhöhe h_C im Bereich 0-6 variiert. In Abbildung 7.1 sind die unterschiedliche Beladungskonfigurationen des Datensatzes A dargestellt, welche für den Trainingsdatensatz verwendet werden. Die Höhe der Containerstapel beträgt $h_C \in \{0,2,4,6\}$. Der Windwinkel der Trainingsdaten liegt im Bereich $\beta \in [0^\circ, 180^\circ]$ mit einem Inkrement von $\Delta\beta = 20^\circ$, wodurch insgesamt 40 Druckfelder für das Erstellen bzw. Trainieren der Modelle zur Verfügung stehen. In Abbildung 7.2 sind die resultierenden Kraftbeiwerte in Längs- und Querrichtung des Trainingsdatensatzes sowie die des Validierungs- und Testdatensatzes dargestellt. Der Validierungsdatensatz besteht für die gleiche Containerhöhen aus den dazwischen

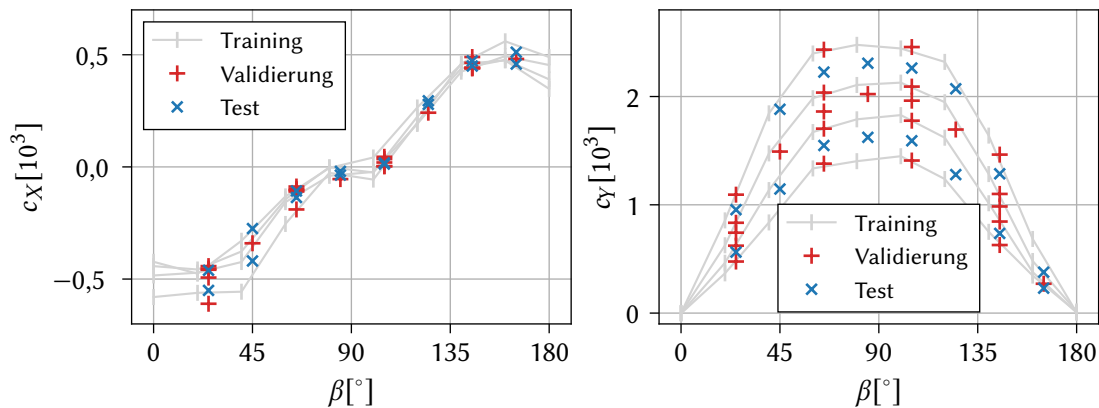


Abbildung 7.2: Verteilung der Kraftbeiwerte in Längs- c_x (links) und Querrichtung c_y (rechts). Die Darstellung erfolgt getrennt für Trainings-, Validierungs- und Testdaten über dem Windwinkel β für Datensatz A.

liegenden Windwinkeln sowie der Stapelhöhe $h_C = 3$. Der Datensatz zur Validierung besteht aus insgesamt 28 Druckfeldern. Zum Testen der finalen Modelle werden Druckfelder mit einer Stapelhöhe von $h_C = 1$ und $h_C = 5$ und jeweils 8 Windwinkeln bereitgehalten.

7.1.2 Datensatz B

Der zweite Datensatz B enthält neben den Beladungszuständen des Datensatzes A auch Zustände mit unterschiedlichen Stapelhöhen. Immer zwei in Längsrichtung benachbarte Stapel haben die gleiche Höhe, um die Anzahl der Systemparameter gering zu halten. Dadurch ergeben sich drei unterschiedliche Stapelhöhen $h_{C,j} \in \mathbb{R}^3$. Die Containerstapel haben dabei jeweils eine Länge von 2 TEU (engl. twenty foot equivalent unit) und jeweils eine Breite von 9 TEU. Vier beispielhafte Beladungskonfigurationen des Datensatzes B sind in Abbildung 7.3 dargestellt.

Für Datensatz B ergeben sich vier unterschiedliche Systemparameter $n_\alpha = 4$ (Windwinkel und 3 Stapelhöhen), welche in der Modellierung berücksichtigt werden. Die Schiffsgeometrie




Abbildung 7.3: Darstellung der Geometrie und der Verteilung der Container an Deck für Datensatz B. Die Höhe zweier in Längsrichtung benachbarter Containerstapels ist einheitlich.

sowie die Berechnungsparameter und die Reynoldszahl der durchgeführten numerischen Simulationen entsprechen dabei dem zuvor beschriebenen Datensatz A und es wird das gleiche Metagitter verwendet ($n_x = 320$ und $n_y = n_z = 64$).

Der Trainingsdatensatz enthält alle möglichen Kombinationen von Stapelhöhen der Container mit $h_{C,j} \in \{0,3,6\}$. Somit ergeben sich 27 unterschiedliche Beladungszustände. Der Windwinkel der Trainingsdaten liegt im Bereich $\beta \in [0^\circ, 180^\circ]$ mit einem Inkrement von $\Delta\beta = 20^\circ$. Insgesamt besteht der Trainingsdatensatz aus 270 Druckfeldern. Die Kraftbeiwerte der aus den Druckfeldern resultierenden Kräfte in Längs- sowie Querrichtung sind in Abbildung 7.4 dargestellt.

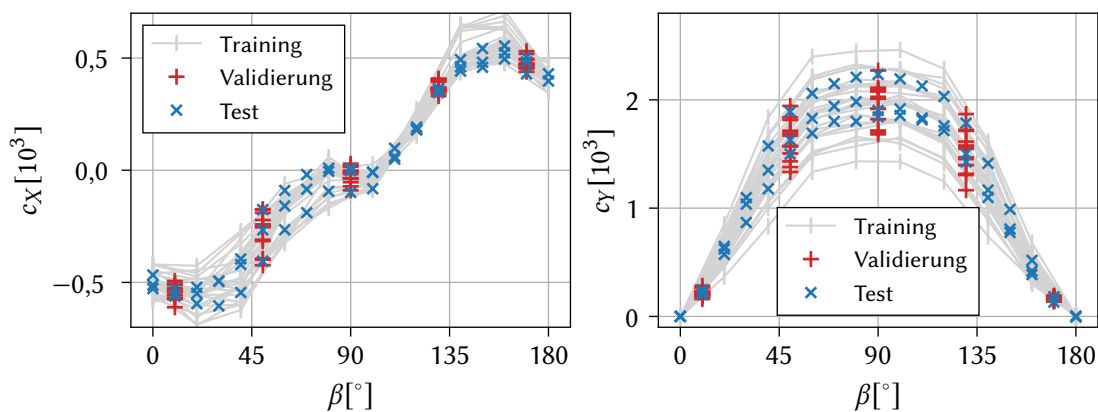


Abbildung 7.4: Verteilung der Kraftbeiwerte in Längs- c_x (links) und Querrichtung c_y (rechts). Die Darstellung erfolgt getrennt für Trainings-, Validierungs- und Testdaten über dem Windwinkel β für Datensatz B.

Ebenfalls dargestellt sind die Kraftbeiwerte der Validierungs- und Testdaten. Für die Validierungsdaten werden 11 zufällig ausgewählte, nicht in den Trainingsdaten enthaltene Beladungszustände gewählt. Die Winkel sind jeweils im Bereich $\beta \in [10^\circ, 170^\circ]$ mit einem Inkrement von $\Delta\beta = 40^\circ$. In Summe werden 55 Druckfelder zur Validierung genutzt. Für die Testdaten werden drei weitere Beladungskonfigurationen verwendet $h_c = (0,2,5)$, $h_c = (5,2,1)$ und $h_c = (5,4,4)$. Über dem Winkelbereich $\beta \in [0^\circ, 180^\circ]$ beträgt das Inkrement $\Delta\beta = 10^\circ$. Für das Testen der Modelle werden insgesamt 57 Druckfelder zurückgehalten.




Abbildung 7.5: Darstellung der Singulärwerte σ_j und der kumulativen Energie κ der POD für unterschiedliche Moden n_R für Datensatz A.

7.2 POD-basierte Dimensionsreduktion

Der erste Schritt der Modellierung ist die Identifikation einer dimensionsreduzierten Basis und der zugehörigen Koeffizienten. Zunächst wird die POD-basierte Methode für die beiden Datensätze analysiert. Der Vorteil der POD ist die einfache und effiziente Bestimmung der reduzierten Variablen (Moden) im Vergleich zur aufwendigeren CAE-basierten Methode. Auf Basis der für einen Datensatz bestimmten POD-Moden wird die Rekonstruktion der Datenfelder für unterschiedlich viele Moden bewertet. Die Auswertung für unterschiedlich viele Moden ist sehr einfach und effizient. Bei der CAE-Methode hingegen muss für jede betrachtete Modenzahl der CNN-Autoencoder vollständig neu trainiert werden. Daher wird im Folgenden die Abhängigkeit der Genauigkeit der Rekonstruktion von der Anzahl berücksichtigter Moden für die POD-Methode analysiert.

Datensatz A

Wie bereits in Abschnitt 6.1.1 erläutert, wird zur Beurteilung der benötigten Moden häufig die kumulative Matrixenergie κ (nach Gleichung (6.6)) in Abhängigkeit der Anzahl berücksichtigter Moden n_R herangezogen. Die ersten Moden enthalten die meiste Energie und damit die meisten Informationen über die Druckfelder des zu Grunde liegenden Datensatzes. Für die weiteren Moden nimmt die enthaltene Energie stetig ab.

Für Datensatz A sind die zugehörigen Singulärwerte σ und die kumulative Energie κ in Abbildung 7.5 für die unterschiedlichen Moden am Beispiel der 40 Druckfelder des Datensatzes A dargestellt. Der Verlauf der kumulativen Energie deutet auf die in den Daten enthaltene Varianz hin. Für Datensatz A ist 80% der Energie in den ersten 14 Moden und 90% der Energie in den ersten 22 Moden enthalten.

Die Singulärwerte und die kumulative Energie haben nur eine begrenzte Aussagekraft über die Anzahl der für die Modellierung benötigten Moden. Dies gilt insbesondere für die Rekonstruktion von Daten, welche nicht im Trainingsdatensatz enthalten sind. Daher wird zusätzlich

der mittlere Fehler der rekonstruierten Felder für die Trainings- und die Validierungsdaten in Abhängigkeit der berücksichtigten Anzahl an Moden n_R ausgewertet. Die mittlere Abweichung der Druckfelder E_P ist in Abbildung 7.6 dargestellt. Bis ca. $n_R = 13$ stimmen die Fehler E_P der Trainings- und der Validierungsdaten nahezu überein. Mit Hilfe der rekonstruierten Druck-




Abbildung 7.6: Mittlerer Fehler des Druckfeldes E_P für die Trainings- und Validierungsdaten in Abhängigkeit der Anzahl der berücksichtigten Moden n_R für Datensatz A.




Abbildung 7.7: Mittlerer Fehler der resultierenden Längs- E_X und Querkräfte E_Y in Abhängigkeit der berücksichtigten Anzahl an Moden n_R für Datensatz A. Die Bestimmung der Kräfte erfolgt basierend auf den rekonstruierten Druckfeldern.

felder werden die auf die Überwassergeometrie wirkenden aerodynamischen Kräfte bestimmt. Die mittleren Abweichungen der bestimmten dimensionslosen Kräfte in Längs- E_X und Quer- richtung E_Y in Abhängigkeit der berücksichtigten Moden n_R sind in Abbildung 7.7 dargestellt. Werden alle Moden berücksichtigt ($n_R = 40$), sind die mittleren Fehler der Trainingsdaten $E_P = E_X = E_Y = 0$, da die ursprünglichen Informationen des Datensatzes vollständig enthalten sind. In den Rekonstruktionen der unbekanntenen Druckfelder der Validierungsdaten treten erwartungsgemäß auch für die Berücksichtigung aller POD-Moden $n_R = 40$ noch signifikante Fehler auf. Der Verlauf der Validierungsdaten ist ab ca. $n_R = 20$ für die drei betrachteten Fehler nahezu konstant. Hieraus folgt, dass die Moden für $n_r > 20$ größtenteils für den Trainingsda- tensatz spezifische Informationen enthalten und damit für ein generalisiertes Modell nicht von

Relevanz sind.

Als Basis für die Ersatzmodelle ist daher maximal die Berücksichtigung der ersten 20 Moden sinnvoll. Allerdings muss für die Koeffizienten im 2. Schritt der funktionale Zusammenhang zu den Systemparametern darstellbar sein. Somit ist eine Festlegung der für die Modellierung berücksichtigten Moden streng genommen nur in Kombination mit dem Regressionsschritt sinnvoll möglich.

Datensatz B

Die POD-Dimensionsreduktion basiert auf dem Trainingsdatensatz B mit insgesamt 270 Druckfeldern. Zunächst werden wieder die Singulärwerte σ sowie die kumulative Energie κ der POD in Abbildung 7.8 betrachtet. 80% der kumulativen Energie ist in den ersten 50 Moden und 90%




Abbildung 7.8: Darstellung der Singulärwerte σ und der kumulativen Energie κ der POD für unterschiedliche Moden n_R für Datensatz B.

der Energie in den ersten 98 Moden der POD enthalten. Dies verdeutlicht die im Vergleich zu Datensatz A größere Varianz der Druckfelder. Neben der kumulativen Energie werden auch für Datensatz B die mittleren Fehler der Druckfelder E_P in Abhängigkeit der Anzahl berücksichtigter Moden n_R jeweils für die Trainings- und Validierungsdaten in Abbildung 7.9 betrachtet. Zur übersichtlicheren Darstellung ist der relevante Bereich $n_R < 120$ dargestellt. Während der Fehler der Trainingsdaten kontinuierlich abnimmt, verringert sich der Fehler der Validierungsdaten für $n_R > 40$ nur noch geringfügig.

In Abbildung 7.10 sind die Fehler der Längs- E_X und Querkräfte E_Y für den Bereich $n_R < 80$ dargestellt. Für die Fehler der Kräfte der Validierungsdaten zeigt sich für $n_R > 40$ eine lediglich geringe Verringerung der Fehler.

Die Fehler der Druckfelder sowie die der betrachteten Kräfte der Validierungsdaten sind für Datensatz B im Vergleich zum Datensatz A etwas größer, was auf die höhere Komplexität des Datensatzes B zurückzuführen ist. Allerdings lassen sich beide Datensätze nicht direkt vergleichen, da die Aufteilung der Trainings- und Validierungsdaten unterschiedlich ist. Die




Abbildung 7.9: Mittlere Fehler der Druckfelder E_P für die Trainings- und Validierungsdaten in Abhängigkeit der berücksichtigten Moden n_R für Datensatz B.




Abbildung 7.10: Mittlere Fehler der resultierenden Längs- E_X und Querkräfte E_Y in Abhängigkeit der berücksichtigten Moden n_R für Datensatz B. Die Bestimmung der Kräfte erfolgt basierend auf den rekonstruierten Druckfeldern.

Beladungsfälle der Validierungsdaten des Datensatzes A stimmen teilweise mit den Beladungsfällen des Trainingsatzes überein (und unterscheiden sich nur im Windwinkel), während bei Datensatz B die Beladungsfälle der Validierungsdaten sich von denen der Trainingsdaten vollständig unterscheiden.

Für beide Datensätze zeigt sich, dass die Analyse der kumulativen Matrixenergie κ für die hier betrachtete Anwendung nur eine begrenzte Aussagekraft hat. Der Vergleich der Fehler der Druckfelder sowie der Kräfte bietet hingegen eine bessere Orientierung der zur Dimensionsreduktion benötigten Anzahl an Moden. Eine geeignete Anzahl der zu berücksichtigenden Moden lässt sich erst nach kombinierter Betrachtung mit der Regression der Koeffizienten im zweiten Schritt der Modellierung festsetzen. Diese kombinierte Betrachtung erfolgt für beide Datensätze in Abschnitt 7.4.

7.3 CAE-basierte Dimensionsreduktion

Alternativ zur POD-Methode werden für die Dimensionsreduktion Autoencoder basierend auf CNNs (CAE) eingesetzt. Die grundlegenden Eigenschaften der Methode sind in Abschnitt 6.1.2 beschrieben. Ein CNN-basierter Autoencoder setzt sich aus mehreren Schichten und Funktionen zusammen. Zur Steuerung des Trainings und zur Vorgabe der Struktur des Autoencoders werden unterschiedliche Hyperparameter vorgegeben. Um das volle Potential der CAE-Methode auszuschöpfen, ist die Verwendung der optimalen Hyperparameter für die spezifische Problemstellung entscheidend.

7.3.1 Einfluss der Hyperparameter

Der Einfluss verschiedener Hyperparameter auf die Qualität der Dimensionsreduktion wird im Folgenden für Datensatz A untersucht. Die einzelnen Hyperparameter stehen dabei teilweise in Wechselwirkung mit anderen Hyperparametern. Um diese vollständig zu erfassen, wäre eine Betrachtung aller möglicher Kombinationen von Hyperparametern erforderlich. Bei solch einer vollständigen Gittersuche steigt die Anzahl der betrachteten Gitterpunkte exponentiell mit der Anzahl der betrachteten Hyperparameter an. Da dies aufgrund der großen Anzahl an Hyperparametern und des aufwendigen Trainings einer einzelnen Modellvariante nicht durchführbar ist, wird hier nur der Einfluss einzelner Hyperparameter unter Vernachlässigung der Wechselwirkungen mit anderen Hyperparametern untersucht. Zusätzlich wird das Training der getesteten Varianten vorzeitig beendet, um eine größere Anzahl unterschiedlicher Hyperparameter testen zu können. Dabei wird davon ausgegangen, dass die relative Performance der einzelnen Varianten sich beim Training bis zur finalen Konvergenz nicht entscheidend ändert (Aggarwal, 2019). In vergleichbaren Arbeiten wird, abgesehen von der Anzahl berücksichtigter

Tabelle 7.1: Übersicht der Standardwerte der für den Autoencoder verwendeten Hyperparameter.

Hyperparameter	Formelzeichen	Standardwert
Batch-Größe	n_B	2
Epochen	n_E	2500
Adam-Parameter 1	β_1	0,9
Adam-Parameter 2	β_2	0,999
Adam-Lernrate	l_r	$1 \cdot 10^{-4}$
Aktivierungsfunktion	ψ	elu
CNN-Filterweite	w_F	3
CNN-Faltungsoperationen	n_C	1
CNN-Pooling		Maximum
Anzahl latenter Variablen	n_R	5

latenter Variablen n_R , nur vereinzelt der Einfluss der unterschiedlichen Hyperparameter auf die Performance von CNN-Autoencodern dargestellt. Fukami et al. (2021) beschreiben neben der Anzahl latenter Variablen ebenfalls den Einfluss unterschiedlicher Aktivierungsfunktionen sowie die Anzahl trainierbarer Parameter.

Die Performance der einzelnen Modellvarianten wird auf Basis der Fehler der Druckfelder sowie der Längs- und Querkräfte beurteilt. Das Ziel ist eine möglichst hohe Qualität der Rekonstruktion, bei gleichzeitig möglichst geringer Komplexität des Modells zu erreichen. Die Komplexität wird durch die Anzahl der zu trainierenden Parameter des Modells festgelegt. Mit höherer Modellkomplexität steigt der Trainingsaufwand sowie die Ausführungszeit des späteren Surrogatmodells an. Um die Komplexität der CAE-Modelle jeweils zu vergleichen, wird die relative Modellkomplexität C_M^* eingeführt

$$C_M^* = \frac{n_{param,j}}{\max(n_{param})}. \quad (7.1)$$

Hierin bezeichnet $n_{param,j}$ die Anzahl der Parameter der jeweils betrachteten Modellvariante j und $\max(n_{param})$ die maximale Anzahl an Parametern aller betrachteten Modellvarianten. Entsprechend werden die relativen Metriken für das Druckfeld E_p^* sowie die Längs- E_x^* und Querkräfte E_y^* jeweils mit dem Maximum und Minimum der Fehler aller Varianten skaliert.

Die für den Autoencoder relevanten Hyperparameter sind in Tabelle 7.1 zusammengefasst. Ausgehend von den in der rechten Spalte enthaltenen Standardwerten erfolgt das Hyperparameter-Tuning. In den folgenden Abschnitten wird der Einfluss jeweils eines Hyperparameters auf die Qualität der Rekonstruktion des Autoencoders analysiert und dargestellt. Für den eingesetzten Adam-Optimierer werden keine Alternativen getestet, da sich dieser als Standard etabliert hat und ebenfalls in Arbeiten mit fluiddynamischer Anwendung erfolgreich verwen-

det wird (Agostini, 2020; Murata et al., 2020; Fukami et al., 2021; Omata und Shirayama, 2019). Für das Pooling innerhalb des CAE wird ausschließlich das Maximum-Pooling angewendet. Im Vergleich zu alternativen Pooling-Schichten bleiben durch die Berücksichtigung des Maximums die Extremwerte der Strömungsfelder erhalten, was für den vorliegenden Anwendungsfall von Bedeutung ist.

Anzahl der CNN-Schichten und Filteranzahl

Die CAE-Struktur wird durch die sequentielle Anordnung mehrerer CNN-Schichten für den Encoder und entsprechend gespiegelt für den Decoder gebildet, vgl. Abbildung 5.3 (b). Zwischen Encoder und Decoder liegt die Schicht der reduzierten Variablen, welche mit den Ausgabeknoten des Encoders und den Eingabeknoten des Decoders vollständig vernetzt ist. Die Anpassungsfähigkeit an die Charakteristik der Daten wird größtenteils durch die Anzahl und Verteilung der Filter für die einzelnen Schichten bestimmt. Die beiden Hyperparameter beeinflussen die Anzahl der freien Parameter innerhalb des Autoencoders und damit die Modellkomplexität C_M^* . Eine zu geringe Modellkomplexität führt zu einer geringen Anpassungsfähigkeit des Autoencoders und damit zu großen Fehlern innerhalb der rekonstruierten Strömungsfelder. Eine zu hohe Modellkomplexität führt zu einer Überanpassung des Autoencoders auf die Trainingsdaten und damit zu vergleichsweise größeren Fehlern innerhalb der unbekanntem Validierungs- und Testdaten. Im Folgenden wird der Einfluss der Anzahl an CNN-Schichten n_L sowie der jeweiligen Anzahl an Filtern je Schicht n_F auf die Anpassungsfähigkeit des Autoencoders analysiert.

Zunächst wird der einfachste Fall mit einer einheitlichen Anzahl an Filtern für alle CNN-Schichten betrachtet. In Abbildung 7.11 sind für $n_L \in \{3,4,5,6\}$ hintereinander angeordnete CNN-Schichten und jeweils $n_F \in \{16,32,64,128\}$ Filter je Schicht die mittleren relativen Fehler E_p^* , E_X^* und E_Y^* der Validierungsdaten über die relative Komplexität C_M^* aufgetragen. Die Beschreibung der Modellvariante z.B. [16,16,16] bezieht sich dabei auf die Anzahl der CNN-Schichten ($n_L = 3$) und die jeweilige Anzahl der Filter ($n_F = 16$) für die Schicht innerhalb des Encoders. Im Decoder sind die Anzahl der Filter entsprechend gespiegelt angeordnet.

Die größten relativen Fehler für das Druckfeld E_p^* sowie die beiden betrachteten relativen Fehler der Lasten E_X^* und E_Y^* zeigen sich dabei für die Varianten mit jeweils nur 3 CNN-Schichten. Die übrigen Varianten zeigen für ähnliche Modellkomplexitäten ähnlich große Fehler unterhalb der 3 CNN-Schichten Versionen, wobei sich der Fehler zwischen den beiden größten Filtern $n_F = 64,128$ kaum unterscheidet. Die Optima liegen in der Regel im Bereich von $C_M^* \approx 0,25 - 0,5$.

Eine weitere Möglichkeit der Verteilung der Filter innerhalb der Schichten ist eine ansteigende Filteranzahl. Zum Beispiel verwendet Agostini (2020) diese Variante der Anordnung. Die

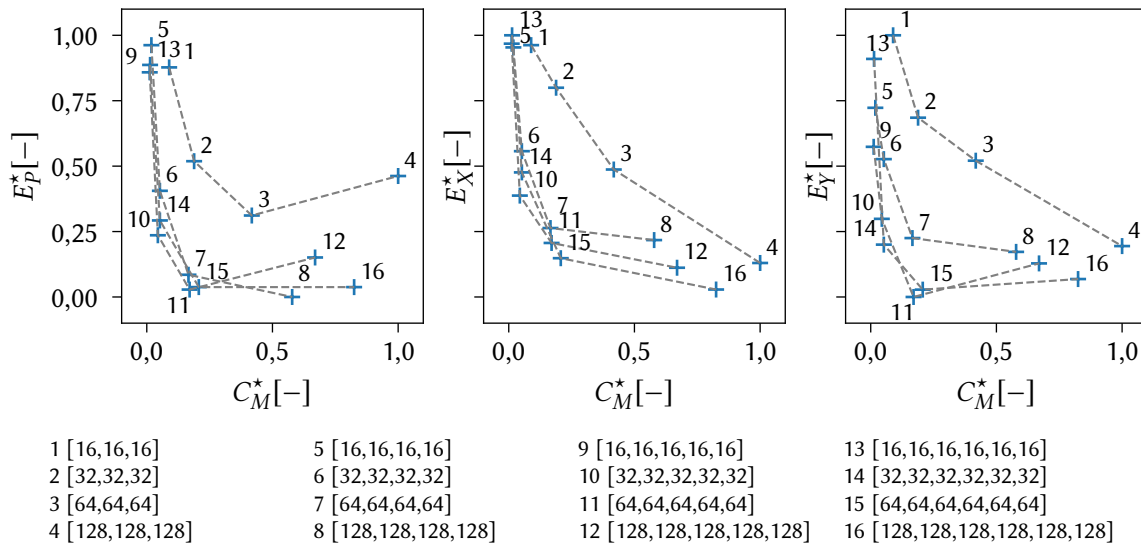


Abbildung 7.11: Darstellung der relativen mittleren Fehler der Validierungsdaten in Abhängigkeit der relativen Modellkomplexität C_M^* für 16 unterschiedliche Modellvarianten mit gleicher Anzahl an Filtern für alle Schichten. Verglichen werden die relativen Fehler der Druckfelder E_p^* und die relativen Fehler der Längskräfte E_x^* und der Querkräfte E_y^* .

Anzahl an Filtern je Schicht für den Encoder wird dabei jeweils verdoppelt. Die dafür resultierenden Fehler sind für $n_L \in \{4,5,6\}$ hintereinander angeordnete Schichten mit unterschiedlicher Anzahl an Filtern in Abbildung 7.12 zusammengefasst. Alle Fehlersensoren fallen bis zu einer ungefähren Modellkomplexität von $C_M^* = 0,2$ steil ab. Der mittlere Fehler der Druckfelder E_p^* nimmt mit zunehmender Anzahl an Filtern und zunehmender Modellkomplexität C_M^* weiter ab. Die mittleren Fehler der Kräfte E_x^* und E_y^* steigen hingegen für die jeweils größte Filteranzahl (Varianten 20,23 und 25) leicht an. Das Modell mit den geringsten relativen Fehlern und einer relativ geringen Modellkomplexität ist Modellvariante 19 [16,32,64,128].

Eine weitere Möglichkeit der Anordnung der unterschiedlichen Anzahl an Filtern ist eine absteigende Filteranzahl je Schicht. Diese Anordnung wird häufig in anderen fluiddynamischen Arbeiten verwendet (Murata et al., 2020; Fukami et al., 2021; Omata und Shirayama, 2019). Auch für diese Verteilung der Filteranzahl wird die Anzahl der CNN-Schichten $n_L \in \{4,5,6\}$ variiert. Die resultierenden mittleren relativen Fehler sind in Abbildung 7.13 wie zuvor über die relative Modellkomplexität C_M^* aufgetragen. Das erzielte Fehlerniveau ist grundsätzlich höher als in den anderen Studien. Die geringsten Fehler für die drei betrachteten Größen treten dabei für die Varianten 26,27 und 28 mit $n_L = 4$ auf. Im Vergleich zu den Modellvarianten mit $n_L = 5$ und $n_L = 6$ ist die Anzahl der Filter für die letzte Schicht vor den reduzierten Variablen größer, wodurch eine bessere Anpassung des Autoencoders erreicht wird.

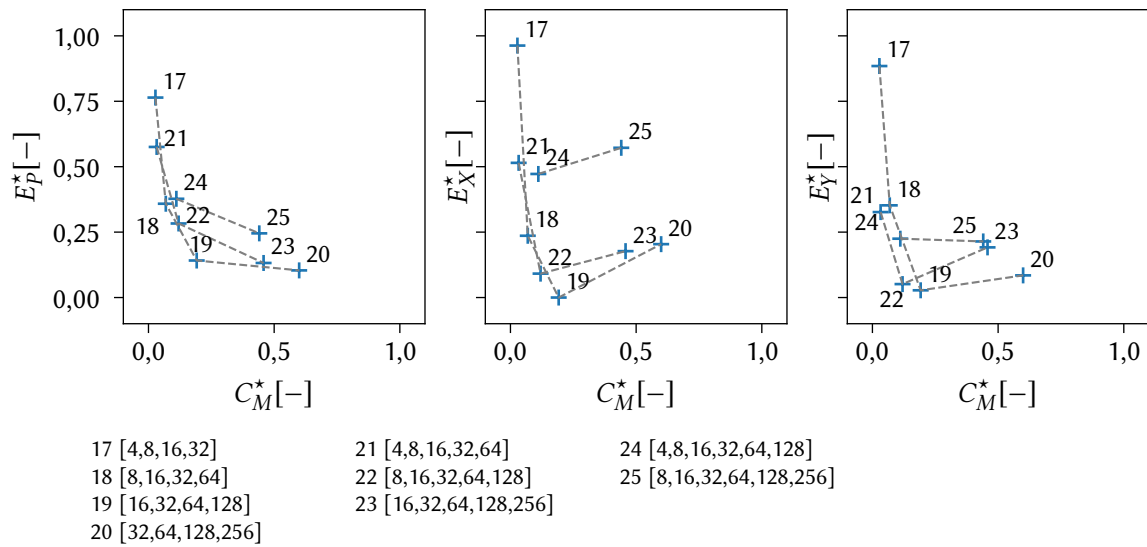


Abbildung 7.12: Darstellung der relativen mittleren Fehler der Validierungsdaten in Abhängigkeit der relativen Modellkomplexität C_M^* für neun unterschiedliche Modellvarianten mit ansteigender Anzahl an Filtern für die jeweiligen Schichten. Verglichen werden die relativen Fehler der Druckfelder E_p^* und die relativen Fehler der Längskräfte E_X^* und der Querkräfte E_Y^* .

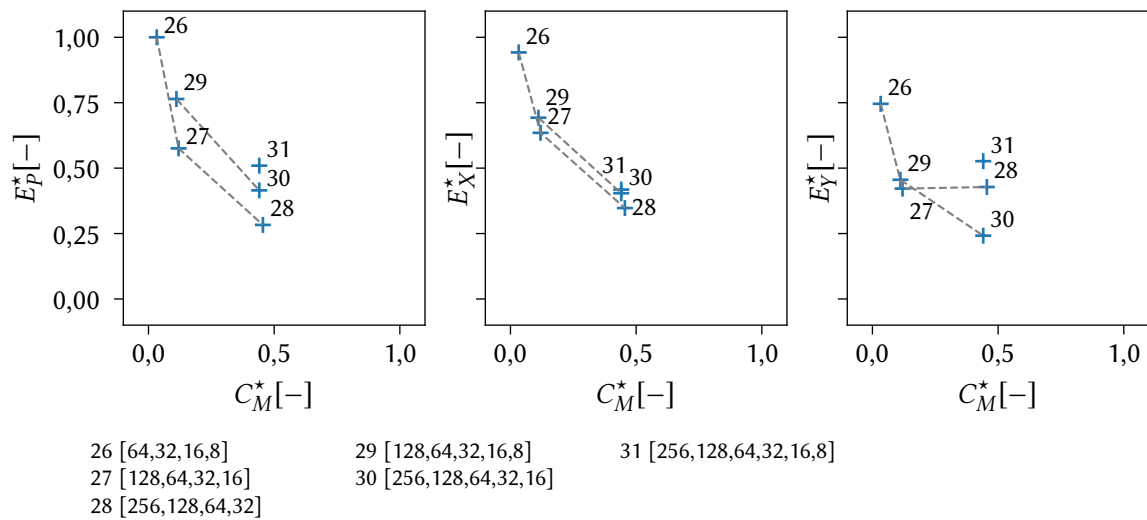


Abbildung 7.13: Darstellung der relativen mittleren Fehler der Validierungsdaten in Abhängigkeit der relativen Modellkomplexität C_M^* für acht unterschiedliche Modellvarianten mit absteigender Anzahl an Filtern für die jeweiligen Schichten. Verglichen werden die relativen Fehler der Druckfelder E_p^* und die relativen Fehler der Längskräfte E_X^* und der Querkräfte E_Y^* .

Die letzte hier betrachtete Möglichkeit der Anordnung der CNN-Filter ist, die Anzahl je Schicht ansteigend anzuordnen und dann wieder zu reduzieren. Für diese Variante sind die relativen Fehler der Modellvarianten in Abbildung 7.14 über der relativen Modellkomplexität C_M^* aufgetragen. Für die Modellvarianten 34 und 37 mit der jeweils größten Anzahl an Filtern zeigen




Abbildung 7.14: Darstellung der relativen mittleren Fehler der Validierungsdaten in Abhängigkeit der relativen Modellkomplexität C_M^* für sechs unterschiedliche Modellvarianten mit variierender Anzahl an Filtern für die jeweiligen Schichten. Verglichen werden die relative Fehler der Druckfelder E_p^* und die relativen Fehler der Längskräfte E_X^* und der der Querkräfte E_Y^* .

sich relativ kleine Fehler für das betrachtete Druckfeld E_p^* und die beiden daraus abgeleiteten Kräfte E_X^* und E_Y^* , bei gleichzeitig relativ geringer Modellkomplexität C_M^* .

Für die zuvor gezeigten Modellvarianten sind abschließend die jeweils besten Varianten in Abbildung 7.15 vergleichend dargestellt. Ausreißer mit dem größten relativen Fehler und der höchsten Modellkomplexität ist die Modellvariante 30 mit einer abnehmenden Anzahl an Filtern. Diese Modellstruktur wird häufig in anderen Arbeiten zur Dimensionsreduktion von Strömungsfeldern verwendet (Agostini, 2020; Murata et al., 2020; Fukami et al., 2021; Omata und Shirayama, 2019). Allerdings sind die dort betrachteten Beispielströmungen zweidimensional und von deutlich geringerer strömungstechnischer Komplexität und der Einfluss unterschiedlicher Strukturen des CAE auf die Anpassungsfähigkeit wird nicht dargestellt. Hiermit wird die Notwendigkeit einer umfassenden Studie der Hyperparameter für neue Datensätze verdeutlicht. Dies ist insbesondere der Fall wenn die Charakteristik der zu Grunde liegenden Daten sich von der Charakteristik zuvor betrachteter Datensätze unterscheidet.

Die Fehler und Komplexität der übrigen betrachteten Modellvarianten liegen sehr nah bei-

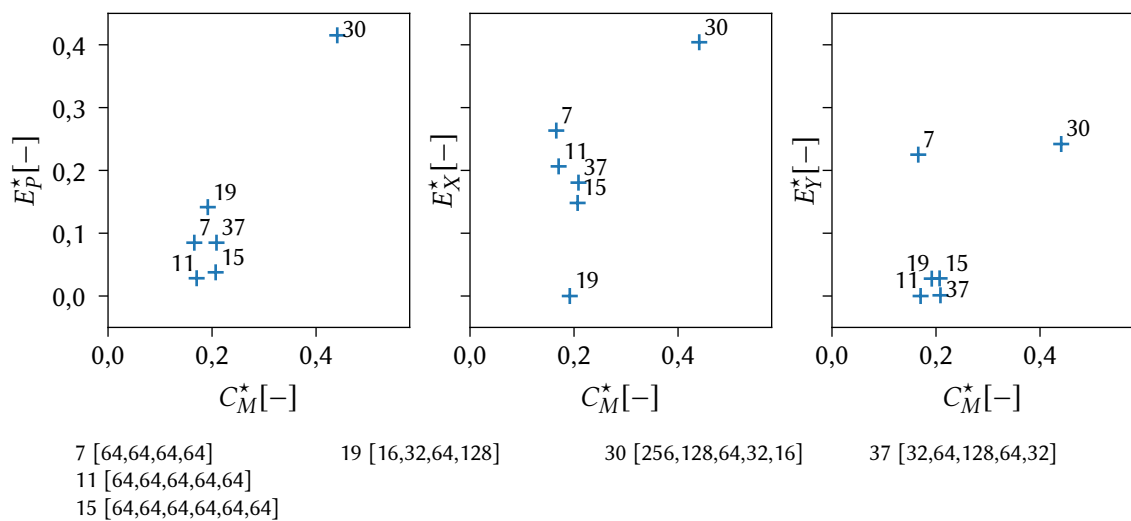


Abbildung 7.15: Darstellung der relativen mittleren Fehler der Validierungsdaten in Abhängigkeit der relativen Modellkomplexität C_M^* für die jeweils besten zuvor dargestellten Modellvarianten.

einander und es zeigt sich keine deutlich überlegene Modellstruktur. Aufgrund des kleinsten Fehlers der Druckfelder wird für die weiteren Analysen die Modellvariante 11 [64,64,64,64,64] weiter verwendet, wobei bei der Untersuchung der weiteren Hyperparameter in den folgenden Abschnitten auch teilweise mehrere der hier dargestellten Modellstrukturen verglichen werden, um eventuelle größere Wechselwirkungen zu erfassen.

Lernrate und Batchgröße

Die beiden Hyperparameter, die Lernrate des Adam-Optimierers l_r (vgl. Abschnitt 5.4.3) und die Batchgröße n_B beeinflussen hauptsächlich die Stabilität sowie die Konvergenzgeschwindigkeit des Trainings und weniger die Anpassungsfähigkeit des Autoencoders. Die maximale Batchgröße ist zudem durch den während des Trainings zur Verfügung stehenden Arbeitsspeicher begrenzt. In Abbildung 7.16 sind die mittleren Fehler des Druckfeldes E_P , der Längs- E_X und der Querkraft E_Y für unterschiedliche Lernraten l_r und Batchgrößen n_B dargestellt. Hierfür ist beispielhaft die Modellvariante mit $n_L = 5$ Schichten und einer einheitlichen Filteranzahl von $n_F = 32$ (Modellvariante [32,32,32,32,32]) ausgewählt. Für alle gezeigten Varianten wird die gleiche Anzahl an Epochen $n_E = 2500$ während des Trainings durchlaufen. Daher ergeben sich weniger Optimierungsschritte des Netzwerkes je größer die Batches sind. Das zeigt sich auch in Abbildung 7.16, die Fehler steigen für größere Batches an. Für kleinere Batchgrößen hingegen nimmt der Mehraufwand (engl. Overhead) zu, was in einem geringfügig höheren Trainingsaufwand resultiert. Für die dargestellten Varianten ist das Training für eine Batchgröße von $n_B = 2$ und der größten Lernrate $l_r = 5 \cdot 10^{-4}$ am effizientesten und werden deshalb für das Trainieren

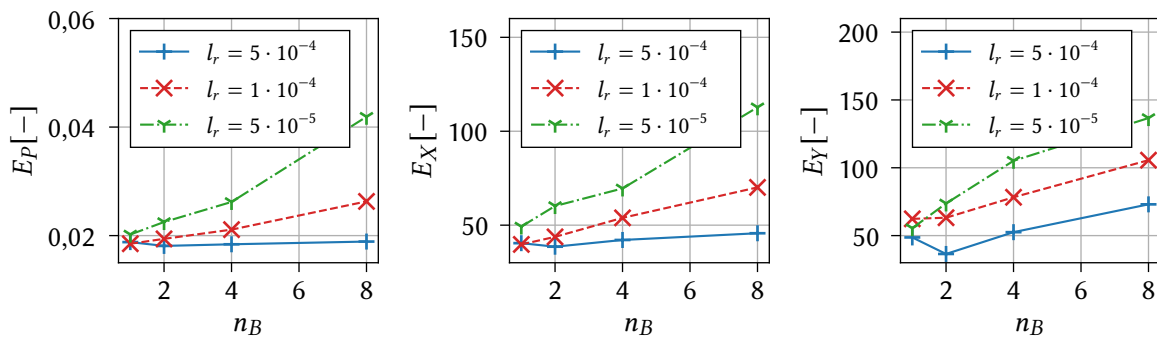


Abbildung 7.16: Vergleich der mittleren Fehler für die Druckfelder E_P sowie die Längs- E_X und Querkräfte E_Y für unterschiedliche Lernraten l_r und Batchgrößen n_B .




Abbildung 7.17: Vergleich der mittleren Fehler der Druckfelder E_P sowie der Längs- E_X und Querkräfte E_Y für drei unterschiedliche Modellvarianten und die beiden Aktivierungsfunktionen *elu* und *tanh*.

der weiteren Modelle verwendet.

Aktivierungsfunktion

Ein weiterer Hyperparameter ist die für die CNN-Schichten angewendete Aktivierungsfunktion ψ . Theoretisch kann für jede Schicht eine andere Aktivierungsfunktion gewählt werden, hier wird der Einfachheit halber für alle Schichten die gleiche Aktivierungsfunktion verwendet. In der Arbeit von Fukami et al. (2021) werden ebenfalls unterschiedliche Aktivierungsfunktionen für CNN-basierte Darstellungen von Strömungsfeldern ausführlich verglichen. Für unterschiedliche Problemstellungen werden in der Arbeit von Fukami et al. (2021) die besten Ergebnisse mit den Aktivierungsfunktionen *elu* und *tanh* erreicht. Diese beiden Varianten werden im Folgenden für den hier betrachteten Anwendungsfall der aerodynamischen Schiffsumströmung verglichen. In Abbildung 7.17 sind die drei mittleren Fehler für die Druckfelder E_P sowie die Kräfte in Längs- E_X und Querrichtung E_Y für jeweils drei unterschiedliche Modellstrukturen und beide Aktivierungsfunktionen dargestellt. Für alle Modellvarianten zeigen die

Fehler für beide Aktivierungsfunktionen die gleiche Tendenz auf. Für die Varianten mit der *elu*-Aktivierungsfunktion ergeben sich in Summe leicht kleinere Fehler.

Für die folgenden Untersuchungen und die finale Modellbildung wird daher die *elu*-Aktivierungsfunktion gewählt.

Anzahl der Faltungsoperationen je Schicht

Optional können innerhalb einer Schicht des Autoencoders mehrere Faltungsoperationen hintereinander durchgeführt werden. Nach der letzten Faltungsoperation einer Schicht erfolgt die Anwendung der Aktivierungsfunktion. Die abschließende Operation jeder Schicht des Autoencoders stellt das Maximum-Pooling zur Reduktion der räumlichen Dimensionen dar. Die zusätzlichen Faltungen erhöhen die Komplexität der jeweiligen Varianten des Autoencoders. Im Vergleich zu den Autoencoder-Varianten mit nur eine Faltungsoperation ($n_C = 1$) steigt der relative Trainingsaufwand für mehrere Faltungsoperationen ($n_C > 1$) geringfügig an.

In Abbildung 7.18 sind die mittleren Fehler der drei betrachteten Größen über der Anzahl der Faltungsoperationen je Schicht n_C und über die relative Modellkomplexität C_M^* aufgetragen. Die relative Modellkomplexität wird mit der maximalen Anzahl an Parametern der hier betrachteten Varianten des Autoencoders gebildet. Dargestellt sind drei unterschiedliche Modellvarianten mit jeweils unterschiedlicher Filteranzahl $n_F \in \{16, 32, 64\}$ je Faltung. Die Anzahl an Schichten ist für alle drei betrachteten Varianten gleich $n_L = 5$. Mit zunehmender Anzahl an Faltungsoperationen n_C steigen die Fehler der Druckfelder und der Kräfte für die Varianten mit der Filteranzahl $n_F = 32$ und $n_F = 64$ an. Für die Filteranzahl $n_F = 16$ verringern sich die Fehler für $n_C = 2$ und $n_C = 3$ im Vergleich zu einer einzelnen Faltungsoperation. Allerdings sind die Fehler im Vergleich zu den Varianten mit $n_F = 32$ und $n_F = 64$ bei ungefähr gleicher Modellkomplexität C_M^* größer. Eine Verwendung mehrere Faltungsoperationen je Netzwerkschicht ist daher, insbesondere auch aufgrund des höheren Trainingsaufwandes nicht sinnvoll, weshalb für die weitere Anwendung nur eine Faltungsoperation je Schicht $n_C = 1$ verwendet wird.

Filterweite der CNN

Ein weiterer Hyperparameter, der die Faltungen direkt beeinflusst ist die Filterweite w_F . Allgemein wird eine Filterweite von $w_F = 3$ in jeder Koordinatenrichtung vorgeschlagen. Für den hier vorliegenden dreidimensionalen Fall ergeben sich daher $3 \cdot 3 \cdot 3 = 27$ Parameter je Filter, deren Werte während des Trainingsprozesses bestimmt werden. Die Komplexität des Modells wird von der gewählten Filterweite beeinflusst. Von der Verwendung von geraden Filterweiten wird generell abgeraten. Der Vorteil ungerader Filterweiten ist, dass die berücksichtigten Punkte symmetrisch um den aktuell betrachteten Punkt in die Filteroperation eingehen und es zu keiner Schiefe bzw. keinen Verzerrungen zwischen den Schichten kommt. Der Vollständigkeit halber wird hier dennoch auch der Fall $w_F = 2$ berücksichtigt.

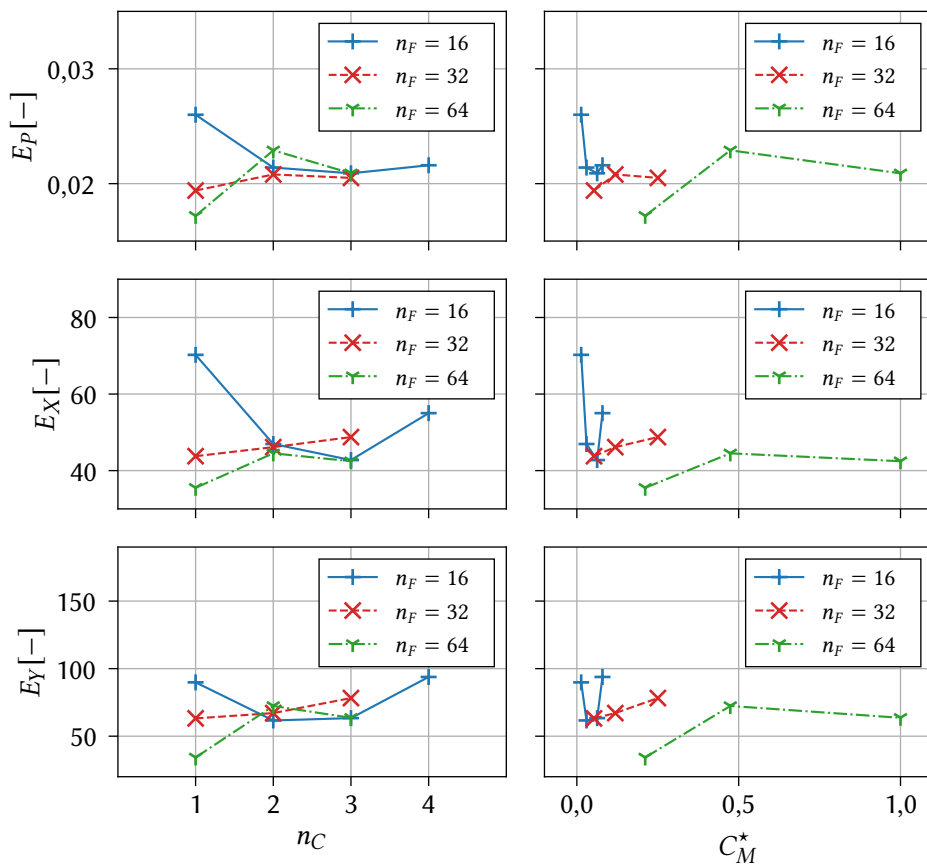


Abbildung 7.18: Darstellung der mittleren Fehler für unterschiedliche Anzahlen an Faltungsoperationen n_C je Autoencoder-Schicht. Verglichen werden der mittlere Fehler der Druckfelder E_P sowie die mittleren Fehler der Kräfte E_X und E_Y , aufgetragen über der Anzahl n_C (links) sowie der relativen Modellkomplexität C_M^* (rechts).

In Abbildung 7.19 werden je vier Filterweiten $w_F \in \{2, 3, 5, 7\}$ für zwei unterschiedliche Anordnungen der CNN-Schichten betrachtet. Die resultierenden mittleren Fehler sind über der Filterweite w_F und der relativen Modellkomplexität C_M^* aufgetragen. Die drei betrachteten mittleren Fehler für die Druckfelder E_P sowie die Längs- E_X und Querkräfte E_Y nehmen mit zunehmender Filterweite leicht ab, die Komplexität der Modellvarianten steigt allerdings stark an, wie aus dem rechten Teil der Abbildung 7.19 ersichtlich ist. Weiterhin zeigt die symmetrische Filterweite große Schwächen.

Durch die Wahl größerer Filterweiten für die Faltungsoperationen wird die Modellkomplexität stark erhöht, bei nur moderater Verbesserung der Anpassungsfähigkeit des Autoencoders. Daher ist die im Weiteren verwendete Filterweite $w_F = 3$.

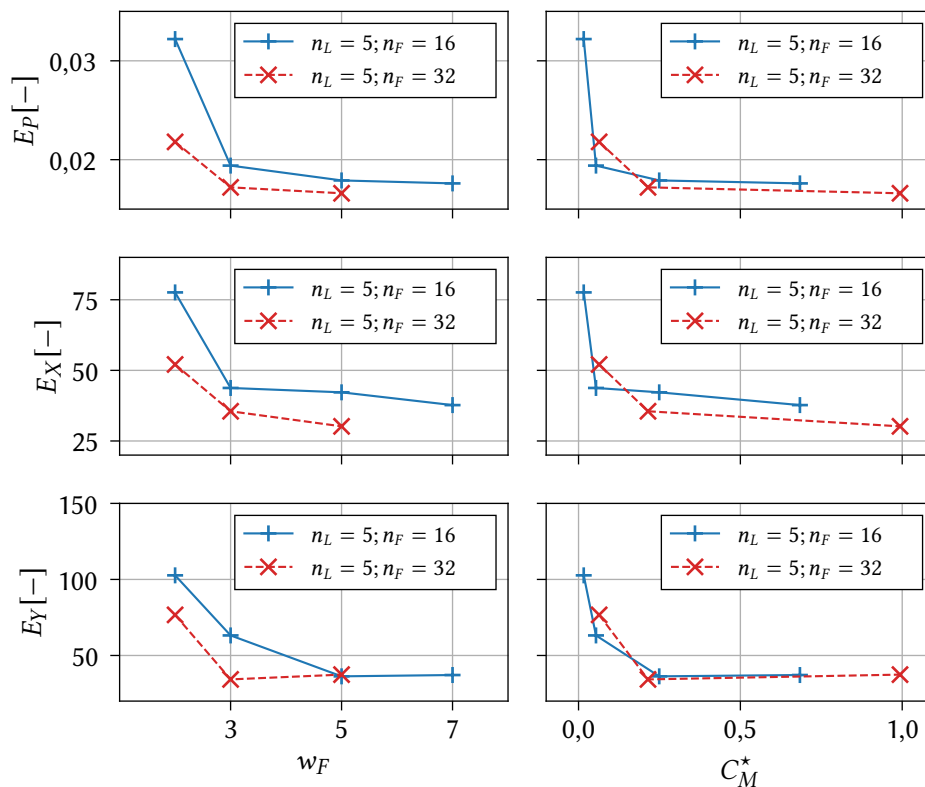


Abbildung 7.19: Darstellung der mittleren Fehler für unterschiedliche Filterweiten w_F . Verglichen werden die mittleren Fehler der Druckfelder E_P sowie die mittleren Fehler der Kräfte E_X und E_Y , aufgetragen über der Filterweite w_F (links) und der relativen Modellkomplexität C_M^* (rechts).

7.3.2 Reduzierte Darstellung der Datensätze

Der wichtigste Hyperparameter der Modellbildung ist die Anzahl der reduzierten Variablen n_R . Dieser entspricht der Anzahl POD-Moden und legt die Reduktion der Datenfelder innerhalb der Dimensionsreduktion fest. Für die finale Beurteilung der CAE-basierten Dimensionsreduktion wird daher die Qualität der Dimensionsreduktion in Abhängigkeit der Anzahl reduzierter Variablen betrachtet und mit der POD-basierten Reduktion verglichen.

Da sich für Datensatz A nur ein moderater Einfluss der meisten Hyperparameter gezeigt hat, wird für Datensatz B lediglich der Einfluss einzelner Hyperparameter dargestellt: es wird die Anzahl der CNN-Schichten und die jeweilige Filteranzahl variiert. Anschließend wird, wie auch für Datensatz A, der Einfluss der Anzahl reduzierter Variablen ermittelt und mit der POD-basierten Methode verglichen.

Datensatz A

Für Datensatz A wird der Einfluss der Anzahl reduzierter Variablen n_R auf die mittleren Fehler analysiert. Die CAE-Modellvariante wird mit $n_L = 5$ Schichten und $n_F = 64$ Filtern je Schicht

[64,64,64,64,64] für unterschiedliche Anzahlen n_R trainiert. Die mittleren Fehler des Druckfeldes und der Lasten werden mit den mittleren Fehlern der POD-basierten Dimensionsreduktion verglichen.

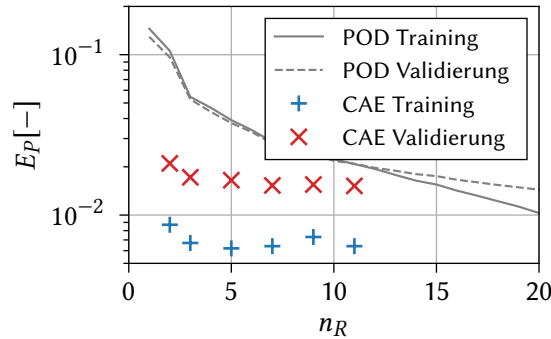


Abbildung 7.20: Vergleich der mittleren Fehler der Druckfelder E_P für die POD- und CAE-basierte Dimensionsreduktion der Trainings- und Validierungsdaten (Datensatz A).

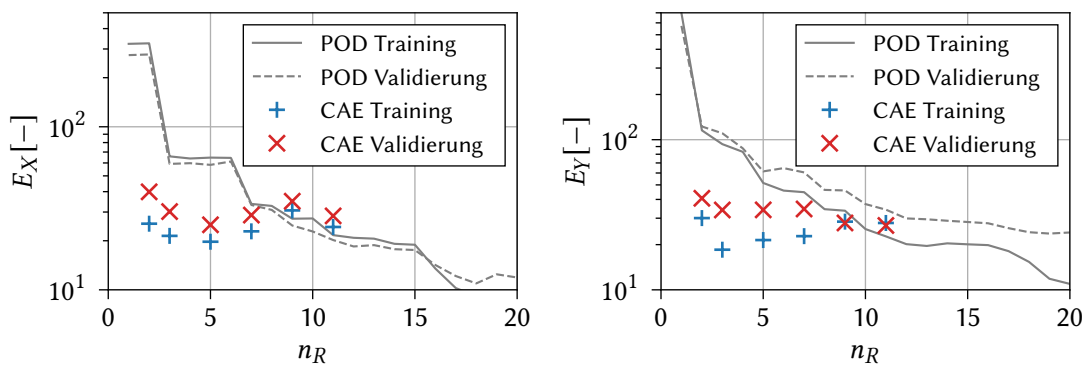


Abbildung 7.21: Vergleich der mittleren Fehler der Kräfte E_X und E_Y für die POD-basierte und CAE-basierte Dimensionsreduktion der Trainings- und Validierungsdaten (Datensatz A).

In Abbildung 7.20 sind die mittleren Fehler der Druckfelder E_P für die POD-basierte und CAE-basierte Dimensionsreduktion über die Anzahl der reduzierten Variablen bzw. berücksichtigten Moden n_R jeweils für die Trainings- und Validierungsdaten aufgetragen. Die mittleren Fehler der Druckfelder liegen dabei für die CAE-basierte Varianten deutlich unter denen der POD-basierten Methode. Die mittleren Fehler der Kräfte E_X und E_Y , welche in Abbildung 7.21 dargestellt sind, sind im Bereich $n_R < 7$ ebenfalls deutlich kleiner und im Bereich $n_R \geq 7$ vergleichbar mit der POD-basierten Methode. Der hier dargestellte Vergleich der mittleren Fehler zeigt, dass aufgrund der Nichtlinearität sich mit der CAE-basierten Modellierung deutlich kompaktere Darstellungen finden lassen. Für $n_R > 5$ verringern sich die mittleren Fehler

der Druckfelder der CAE-Variante in kleinem Maße und die mittleren Fehler der Kräfte steigen teilweise wieder an. Die beste Wahl für die Anzahl reduzierter Variablen für Datensatz A ist $n_R = 5$ und wird für die weitere Modellierung verwendet.

Datensatz B

Für Datensatz B liegt der Fokus der Untersuchung der Hyperparameter auf der Anzahl reduzierter Variablen. Aus der Hyperparameter-Studie zum Datensatz A in Abschnitt 7.3.1 ergibt sich, dass die Modellstruktur den größten Einfluss auf die Qualität der Dimensionsreduktion hat. Im Folgenden wird daher der Einfluss der Anzahl hintereinander angeordneter CNN-Schichten n_L sowie der jeweiligen Anzahl an Filtern n_F je Schicht für Datensatz B analysiert. Abschließend wird der Einfluss der Anzahl reduzierter Variablen n_R dargestellt.

Die Werte der übrigen Parametern entsprechen denen zuvor für den Datensatz A verwendeten Werten, welche in Tabelle 7.1 zusammengefasst sind. Die Anzahl der Epochen des Trainings wird jedoch verringert auf $n_E = 1500$. Durch den deutlich umfangreicheren Datensatz mit 270 anstatt 40 Datenpunkten und die kleinere Batchgröße $n_B = 2$ werden im Vergleich etwa gleich viele Optimierungsläufe ausgeführt wie zuvor für Datensatz A mit $n_E = 10000$. Das Lernen der Parameter ist nach $n_E = 1500$ Epochen für Datensatz B bereits konvergiert.

In den Abbildungen 7.22 und 7.23 sind die mittleren Fehler der Druckfelder und der Kräfte für die unterschiedlichen Modellvarianten aufgetragen. Es werden unterschiedliche Anzahl CNN-Schichten n_L und unterschiedliche Anzahlen an Filtern n_F je Schicht betrachtet. Für alle Varianten beträgt die Anzahl reduzierter Variablen $n_R = 5$.




Abbildung 7.22: Mittlere Fehler der Druckfelder E_P für Variationen der Anzahl der CNN-Schichten n_L und der Anzahl an Filtern n_F je Schicht (Datensatz B).

Für die dargestellten Fehler der Druckfelder ergeben sich für die unterschiedliche Anzahl an CNN-Schichten n_L keine signifikanten Unterschiede und die Wahl einer größeren Anzahl an Filter je Schicht $n_F > 32$ führt ebenfalls nicht zu einer Verringerung der mittleren Fehler der Druckfelder. Für die in Abbildung 7.23 dargestellten Fehler der Kräfte E_X und E_Y haben die

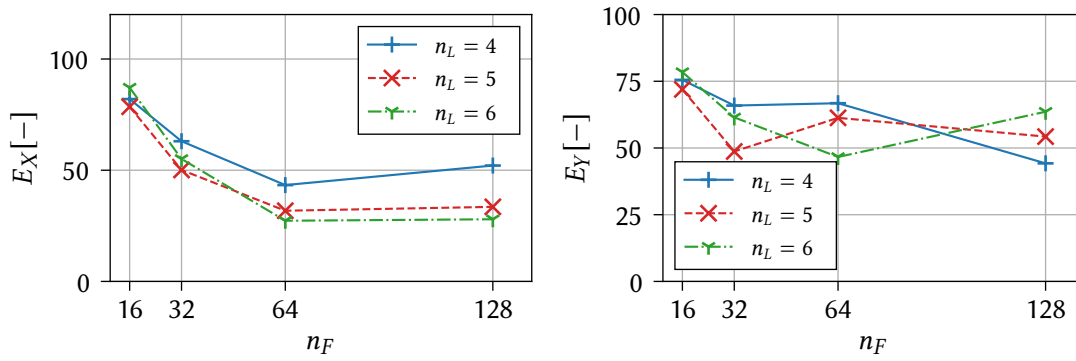


Abbildung 7.23: Mittlere Fehler der Längs- E_X und Querkräfte E_Y für Variationen der Anzahl der CNN-Schichten n_L und der Anzahl an Filtern n_F je Schicht (Datensatz B).

Anzahl der Schichten sowie die Filteranzahl hingegen einen signifikanten Einfluss. Für die Längskräfte ergeben sich die geringsten Fehler für $n_L = 5$ und 6 und eine Filteranzahl von $n_F = 64$. Für den Fehler der Querkräfte E_Y zeigt sich ein stochastischer Zusammenhang der Modellparameter und des mittleren Fehlers, tendenziell nimmt der Fehler für eine größere Filteranzahl ab. Für die weitere Modellierung wird daher die Variante mit $n_L = 5$ Schichten und einer Filteranzahl von $n_F = 64$ gewählt (Modellvariante [64,64,64,64,64]). Dies entspricht der CNN-Struktur, welche bereits für Datensatz A verwendet wird.

Wie bereits zuvor für Datensatz A wird auch für Datensatz B die Qualität der Dimensionsreduktion in Abhängigkeit der Anzahl reduzierter Variablen n_R mit der POD-basierten Modellierung analysiert.




Abbildung 7.24: Vergleich der mittleren Fehler der Druckfelder E_P für die POD-basierte und CAE-basierte Dimensionsreduktion der Trainings- und Validierungsdaten (Datensatz B).

In Abbildung 7.24 sind die mittleren Fehler des Druckfeldes für die Trainings- und Validierungsdaten für die POD- und CAE-basierte Dimensionsreduktion abgebildet. Für den gesamten betrachteten Bereich $n_R < 20$ ist der CAE-basierte Fehler der Validierungsdaten deutlich

geringer als der Fehler der POD-basierten Modellierung. Der CAE-basierte Fehler verringert sich allerdings für größere Anzahlen reduzierter Variablen nur sehr geringfügig im Bereich $n_R > 7$ und wird von der POD-basierten Methode angenähert. In Abbildung 7.25 sind die mitt-




Abbildung 7.25: Vergleich der mittleren Fehler der Kräfte E_X und E_Y für die POD-basierte und CAE-basierte Dimensionsreduktion der Trainings- und Validierungsdaten (Datensatz B).

leren Fehler der Längs- E_X und Querkraften E_Y für beide Methoden und die Trainings- sowie Validierungsdaten aufgetragen. Für die Längskraft zeigen sich im Bereich $5 < n_R < 12$ deutlich geringere Fehler der Validierungsdaten für die CAE-basierte Methode. Im übrigen Bereich und für die Querkraft sind die Fehler der beiden Methoden sehr ähnlich.

Für beide Datensätze A und B zeigt sich, dass $n_R = 5$ eine geeignete Wahl für die Anzahl der reduzierten Variablen ist. Der Vorteil der CAE-basierten Dimensionsreduktion besteht in der kompakteren Darstellung der Daten. Basierend auf einer ca. dreifach geringeren Anzahl reduzierter Variablen im Vergleich zu den zur Rekonstruktion verwendeten Anzahl an POD-Moden lassen sich die Druckfelder mit vergleichbarer Qualität darstellen.

7.4 Validierung des Gesamtmodells

Im Folgenden werden die Modellerstellung und die Ergebnisse des Gesamtmodells für beide Datensätze A und B dargestellt. Aufbauend auf der dimensionsreduzierten Darstellung ist die Regression der Koeffizienten zur Erstellung des Gesamtmodells erforderlich. Die Koeffizienten der POD-basierten Methode werden durch die Projektion der ursprünglichen Druckfelder (gemäß Gleichung (5.4)) bestimmt. Die Koeffizienten der CAE-basierten Methode sind die Ausgabewerte der latenten Schicht des Autoencoders und entsprechen den reduzierten Variablen. Für beide Methoden der Dimensionsreduktion werden unterschiedliche Regressionsmethoden analysiert und der Einfluss der jeweiligen Modellparameter veranschaulicht. Neben der Polynomregression und der Gaußprozess-Regression wird die Regression mit Neuronalen Netzen

verglichen.

Zu Beginn des Abschnittes wird auf die Eigenschaften und Charakteristik der Modellkoeffizienten eingegangen. In den darauf folgenden Abschnitten werden die Parameter der unterschiedlichen Regressionsmethoden beleuchtet und deren Einfluss auf die Modellierung der Datensätze A und B für die POD- und CAE-Reduktion dargestellt. Abschließend werden für beide Datensätze alle Modellvarianten anhand der bisher zurückgehaltenen Testdaten validiert.

7.4.1 Parametrisierung der Koeffizienten

Zur qualitativen Beurteilung des funktionalen Zusammenhangs der Systemparameter und der Koeffizienten sowie der Darstellbarkeit mit Regressionsfunktionen werden die diskreten Verläufe der Koeffizienten bzw. reduzierten Variablen \mathbf{r} in Abhängigkeit der Systemparameter α herangezogen. Für Datensatz A werden zwei Systemparameter, der Winkel der Zuströmung β und die einheitliche Höhe der Containerbeladung h_C berücksichtigt.

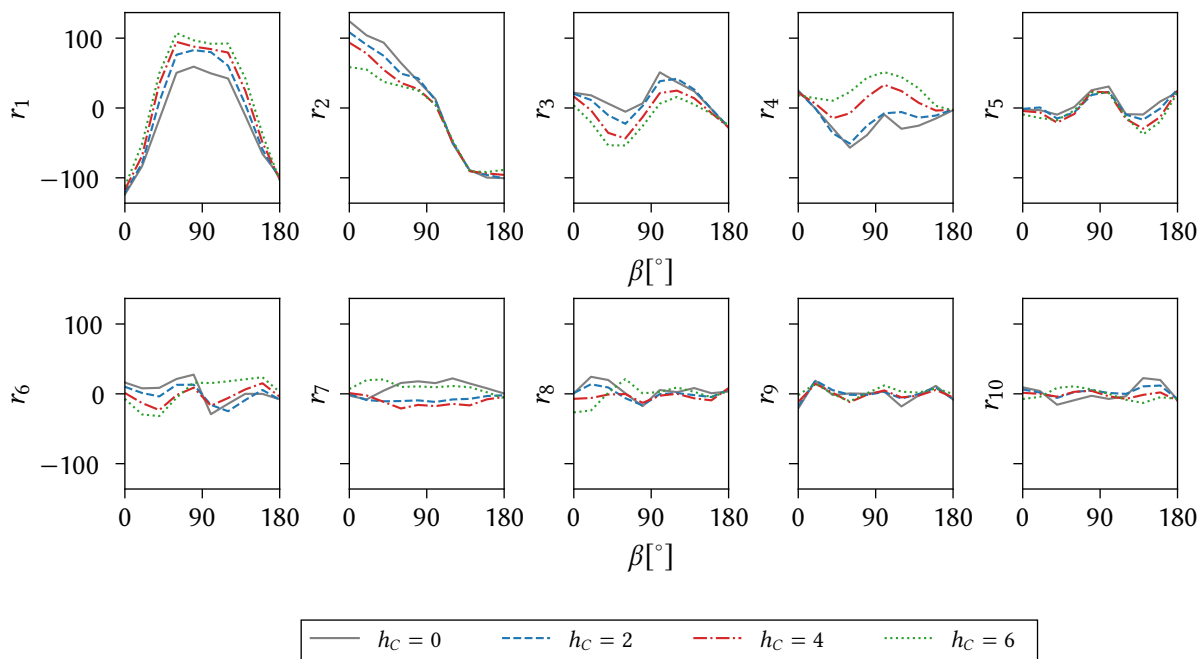


Abbildung 7.26: Verlauf der POD-Koeffizienten für unterschiedliche Beladungshöhen h_C über dem Zuströmwinkel β . Dargestellt sind die ersten zehn Koeffizienten (Trainingsdatensatz A).

Für Trainingsdatensatz A sind in Abbildung 7.26 die qualitativen Verläufe der ersten zehn Koeffizienten r_i basierend auf der POD in Abhängigkeit der beiden Systemparameter β und h_C dargestellt. Für die POD ergibt sich eine Sortierung der Koeffizienten $r_1 - r_{10}$ nach deren Relevanz.

Die Tendenz der diskreten Verläufe zeigt eine gute Darstellbarkeit durch eine Regression für

den funktionalen Zusammenhang, insbesondere für die ersten Koeffizienten $r_1 - r_5$. Zum Vergleich sind in Abbildung 7.27 die diskreten Verläufe der fünf reduzierten Variablen der CAE Dimensionsreduktion ebenfalls in Abhängigkeit der beiden Systemparameter β und h_C dargestellt. Die Struktur des Autoencoders setzt sich aus $n_L = 5$ Schichten mit jeweils $n_F = 64$ Filtern zusammen. Die Anzahl der reduzierten Variablen ist $n_R = 5$. Im Vergleich zeigen diese einen stochastischeren Verlauf auf und sind in Bezug auf die Amplituden nicht hierarchisch gegliedert.

Um den Einfluss des kombinierten Trainings beider Modellierungsschritte auf den Verlauf der reduzierten Variablen darzustellen, sind diese in Abbildung 7.28 für das kombinierte Training dargestellt. Das kombinierte Modell hat die gleichen Hyperparameter ($n_L = 5$; $n_F = 64$; $n_R = 5$) wie das sequenziell trainierte CAE-Modell und der Polynomgrad für den Polynom-basierten Regressionsschritt ist $n_P = 3$.

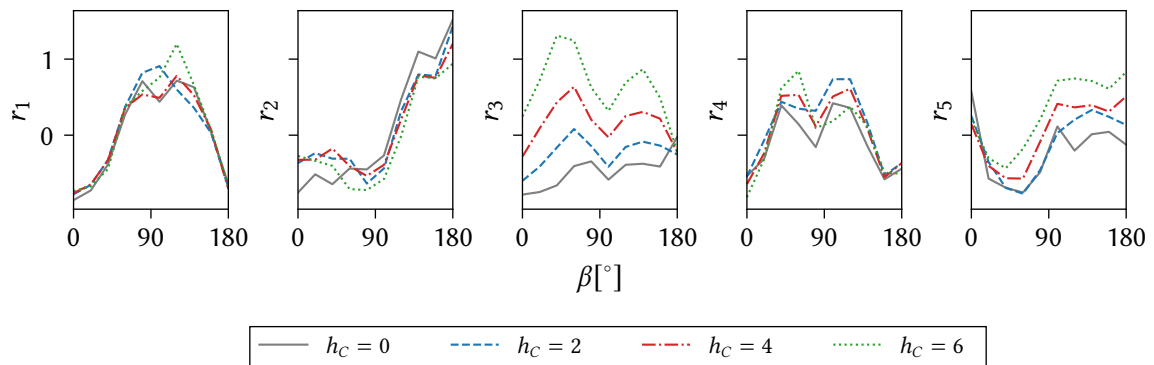


Abbildung 7.27: Verlauf der reduzierten Variablen r_i für unterschiedliche Beladungshöhen h_C über dem Zuströmwinkel β für die CAE Dimensionsreduktion (Trainingsdatensatz A).

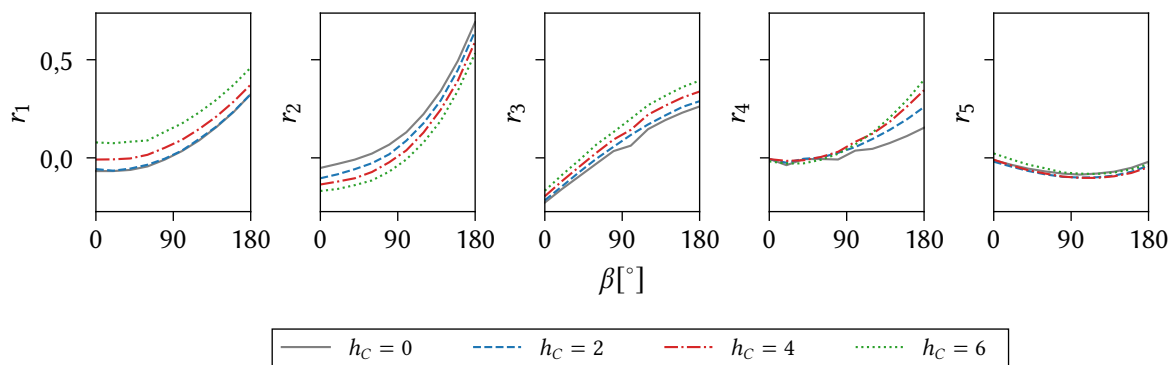


Abbildung 7.28: Verlauf der reduzierten Variablen r_i für unterschiedliche Beladungshöhen h_C über dem Zuströmwinkel β für das kombiniert trainierte CAE-Modell (Trainingsdatensatz A).

Der Vergleich der reduzierten Variablen für das einfache CAE-basierte Dimensionsreduktions-

modell und das kombiniert trainierte Modell zeigt die signifikanten Unterschiede im Verlauf der reduzierten Variablen. Die in Abbildung 7.28 dargestellten reduzierten Variablen folgen mit guter Übereinstimmung einem polynomialen Verlauf und die Regression ist von hoher Güte. Die in Abbildung 7.27 dargestellten reduzierten Variablen der reinen CAE-Dimensionsreduktion hingegen haben einen unregelmäßigen Verlauf und das Abbilden durch eine Regression ist deutlich schwieriger.

Datensatz A: POD-basierte Modellierung

Zunächst wird für Datensatz A und die POD-basierte Modellierung der Einfluss der Parameter für die Polynomregression analysiert. Dazu werden die mittleren Fehler für das Gesamtmodell ausgewertet. Die Anpassungsfähigkeit der Polynomregression wird über den Polynomgrad n_p gesteuert. Außerdem wird der Einfluss der Anzahl der berücksichtigten POD-Moden n_R untersucht. Die mittleren Fehler der rekonstruierten Druckfelder der Validierungsdaten sind in Abbildung 7.29 über dem Polynomgrad n_p für vier unterschiedliche Modellvarianten aufgetragen.




Abbildung 7.29: Mittlere Fehler der Druckfelder E_P für die POD-basierte Dimensionsreduktion und die Polynomregression. Dargestellt wird der Einfluss des Polynomgrades n_p auf die Regression und die Anzahl der berücksichtigten Moden n_R der Dimensionsreduktion (Datensatz A).

Für $n_R \geq 8$ unterscheiden sich die Fehler der Druckfelder für die unterschiedlichen Polynomgrade n_p nur minimal. Die geringsten Fehler treten für die Polynomgrade $n_p = 4$ und $n_p = 6$ auf. Für größere Polynomgrade $n_p > 6$ steigen die Fehler aufgrund der Überanpassung an die Trainingsdaten wieder an. Die mittleren Fehler der resultierenden Kräfte in Längs- E_X und Querrichtung E_Y sind in Abbildung 7.30 dargestellt. Die mittleren Fehler E_X und E_Y unterscheiden sich für $n_R \geq 8$ für alle Polynomgrade nur gering. Die geringsten Fehler der Längskraft treten für $n_p = 8$ und bei der Querkraft für $n_p = 6$ auf. Für das Gesamtmodell basierend auf der POD und der Polynomregression ist der Polynomgrad $n_p = 6$ am besten geeignet. Für




Abbildung 7.30: Mittlere Fehler der Längs- E_X und der Querkraft E_Y für die POD-basierte Dimensionsreduktion und die Polynomregression. Dargestellt wird der Einfluss des Polynomgrades n_p für die Regression und die Anzahl der berücksichtigten Moden n_R für die Dimensionsreduktion (Datensatz A)

Tabelle 7.2: Übersicht der Hyperparameter für die NN-basierte Regression der für den Autoencoder verwendeten Hyperparameter.

Hyperparameter	Formelzeichen	Standardwert
Batch-Größe	n_B	4
Epochen	n_E	30000
Adam-Parameter 1	β_1	0,9
Adam-Parameter 2	β_2	0,999
Adam-Lernrate	l_r	0,001
early-Stop Patience		400
Aktivierungsfunktion	f	elu
Verlustfunktion		MAE

$n_p = 8$ sind die Fehler teils geringer, jedoch nur geringfügig für E_p . Um eine Überanpassung zu vermeiden, wird der niedriger Polynomgrad $n_p = 6$ gewählt.

Die Regression basierend auf Neuronalen Netzen wird ebenfalls für unterschiedliche Varianten des Neuronalen Netzes und unterschiedliche Anzahlen an Moden durchgeführt.

Die Grundstruktur des Neuronalen Netzes besteht aus der Eingabeschicht, der versteckten Schichten und der Ausgabeschicht. Die Eingabeschicht besteht aus zwei Knoten für die beiden Eingabe-Systemparameter $\alpha = (\beta, h_C)$. Darauf folgen die versteckten Schichten, deren genaue Struktur im Weiteren betrachtet wird und eine Ausgabeschicht, deren Anzahl an Knoten der Anzahl berücksichtigter Moden n_R entspricht. Die übrigen Hyperparameter des Neuronalen Netzes werden nicht variiert und sind in Tabelle 7.2 zusammengefasst.

Für die Struktur der versteckten Schichten werden vier unterschiedliche Varianten betrachtet. Drei Varianten mit jeweils $n_L = 2$ Schichten und eine Variante mit $n_L = 3$ Schichten. Die Anzahl




Abbildung 7.31: Mittlere Fehler der Druckfelder E_P für die POD-basierte Dimensionsreduktion und die NN-basierte Regression (Datensatz A). Dargestellt wird der Einfluss der Netzstruktur und die Anzahl der berücksichtigten Moden n_R der Dimensionsreduktion.

der Knoten je Schicht wird variiert. Die Bezeichnung der Modellvarianten (z.B. [4,4]) gibt die Anzahl der Knoten (je 4) und die Anzahl der Schichten (2) wieder. Die mittleren Fehler der Druckfelder E_P und die mittleren Fehler der beiden Kräfte E_X und E_Y sind für die verschiedenen Modellvarianten in den Abbildungen 7.31 und 7.32 dargestellt. Für eine Knotenanzahl der versteckten Schichten, welche kleiner als die Anzahl der berücksichtigten Moden und damit der Anzahl der Knoten der Ausgabeschicht ist, ergeben sich relativ große Fehler. Für die übrigen Varianten mit mindestens 20 Knoten je Schicht liegen die Verläufe der drei betrachteten Fehler nah beieinander. Durch den Vergleich der unterschiedlichen Varianten zeigt sich, dass zwei Schichten mit je 20 Knoten ausreichend für die Modellierung der Regression sind. Werden für die Dimensionsreduktion $n_R > 10$ POD-Moden berücksichtigt, verringert sich der mittlere Fehler der Druckfelder geringfügig, während die mittleren Fehler der beiden Kräfte E_X und E_Y nicht weiter abnehmen.

Für die Regression basierend auf Gaußprozessen wird eine Variante mit einem quadratisch exponentiellen Kernel (RBF) (nach Gleichung (6.12)) und jeweils einem Längenmaß für die Eingabedaten (Systemparameter) verwendet. In den Abbildungen 7.33 und 7.34 werden die mittleren Fehler der Druckfelder E_P und der Kräfte E_X und E_Y für die drei unterschiedlichen Regressionsmethoden verglichen. Die mittleren Fehler sind jeweils über die Anzahl der berücksichtigten POD-Moden aufgetragen. Zusätzlich sind die Fehler für die reine Dimensionsreduktion (POD basiert) abgebildet. Für die dargestellten Varianten mit Polynomregression ist der Polynomgrad $n_p = 6$. Für die Gaußprozess Regression wird der RBF-Kernel angewendet. Für die Regression basierend auf einem Neuronalen Netz werden zwei versteckte Schichten mit jeweils 20 Knoten (Modellvariante [20,20]) verwendet.

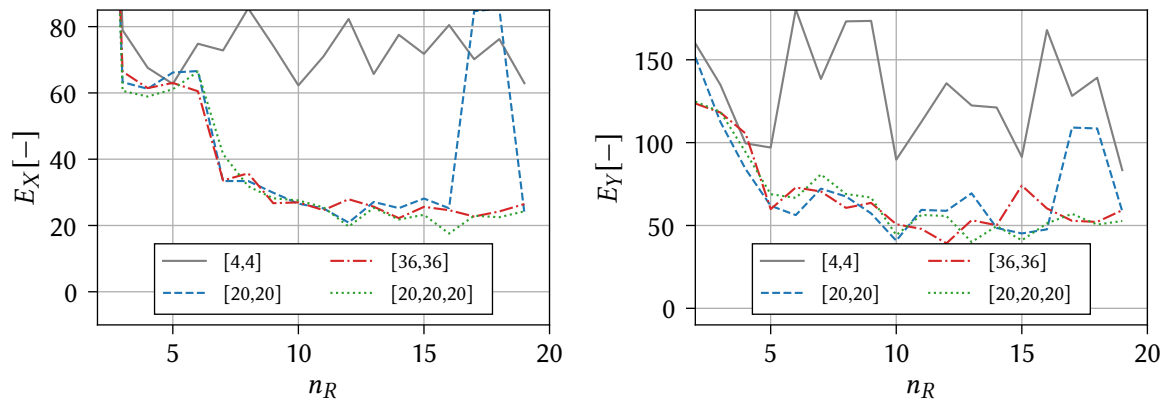


Abbildung 7.32: Mittlere Fehler der Längs- E_X und der Querkräfte E_Y für die POD-basierte Dimensionsreduktion und die NN-basierte Regression (Datensatz A). Dargestellt wird der Einfluss der Netzstruktur und die Anzahl der berücksichtigten Moden n_R der Dimensionsreduktion.




Abbildung 7.33: Vergleich der mittleren Fehler der Druckfelder E_P für unterschiedliche Methoden der Regression in Abhängigkeit der Anzahl berücksichtigter POD-Moden n_R (Datensatz A). Vergleichend ist der Fehler des Dimensionsreduktionsschrittes (POD) dargestellt.




Abbildung 7.34: Vergleich der mittleren Fehler für die Längs- E_X und Querkräfte E_Y für unterschiedliche Methoden der Regression in Abhängigkeit der Anzahl berücksichtigter POD-Moden n_R (Datensatz A). Vergleichend ist der Fehler des Dimensionsreduktionsschrittes (POD) dargestellt.

Für den mittleren Fehler der Druckfelder E_P und $n_R < 5$ stimmen die Werte der Fehler für alle dargestellten Modellvarianten überein. Für mehr berücksichtigte POD-Moden $n_R > 7$ zeigen sich deutlichere Unterschiede zwischen der reinen POD-basierten Reduktion und den drei Gesamtmodellen mit unterschiedlichen Regressionsmethoden. Die geringsten Fehler ergeben sich für die Varianten mit Gaußprozess-basierter Regression, die größten Fehler für die Polynomregression. Für die mittleren Fehler der Längskräfte E_X sind für $n_R < 15$ die Fehler der reinen Dimensionsreduktion und die des Gesamtmodells mit Gaußprozess-basierter Regression und NN-Regression vergleichbar, die für die Polynomregression etwas größer. Für die mittleren Fehler der Querkräfte sind die reine POD und die Gaußprozess- und Polynom-basierte Regressionen für $n_R < 15$ ebenfalls vergleichbar. Der Fehler E_Y der NN-basierten Regression ist etwas größer. Für die drei betrachteten Fehler ergeben sich die geringsten Werte für das Gesamtmodell mit Gaußprozess-basierter Regression. Da sich die Fehler der beiden Kräfte für $n_R > 12$ nur geringfügig verringern, wird für alle Varianten der Regression $n_R = 12$ für die Gesamtmodellierung gewählt.

Datensatz A: CAE-basierte Modellierung

Für das CAE-basierte Modell wird ebenfalls der Einfluss der Regressionsparameter auf die Performance des Gesamtmodells analysiert. Die Dimensionsreduktion basiert auf einem CAE mit $n_L = 5$ CNN-Schichten und jeweils $n_F = 64$ Filtern. Die Anzahl der reduzierten Variablen ist $n_R = 5$.

In Abbildung 7.35 sind die drei mittleren Fehler der Druckfelder E_P und der beiden Kräfte E_X und E_Y für das Gesamtmodell mit Polynomregression dargestellt. Für die Abhängigkeit der Fehler vom verwendeten Polynomgrad n_p zeigt sich eine ähnliche Tendenz, wie zuvor bereits bei




Abbildung 7.35: Vergleich der mittleren Fehler für die Druckfelder E_p , die Längs- E_x und Querkräfte E_y für das CAE-basierte Gesamtmodell mit Polynomregression für verschiedene Polynomgrade n_p (Datensatz A)

den POD-basierten Modellen, vgl. Abbildungen 7.29 und 7.30. Die geringsten mittleren Fehler der Druckfelder E_p finden sich für $n_p = 6$ und $n_p = 8$. Der geringste Fehler der Längskräfte E_x tritt für $n_p = 8$ auf und bei der Querkraft E_y für $n_p = 6$. Insgesamt sind die hier dargestellten Fehler für die CAE-basierte Variante leicht größer als für das POD-basierte Verfahren. Um die Überanpassung der Polynomregression zu vermeiden, wird auch hier der Polynomgrad $n_p = 6$ für das finale Gesamtmodell gewählt.

Auch für die CAE-basierte Dimensionsreduktion wird der Regressionsschritt basierend auf einem kleinen Neuronalen Netz durchgeführt. Das CAE-Modell für die Dimensionsreduktion entspricht der zuvor gezeigten Modellvariante mit den Parametern in Tabelle 7.2. In Abbildung 7.36 sind die mittleren Fehler für unterschiedliche NN-Strukturen dargestellt. Die grundsätzliche Struktur des Netzes entspricht dem im zuvor bereits beschriebenen POD-Ansatz benutzten Netz: die Eingabeschicht besteht aus zwei Knoten für die beiden Systemparameter α , die versteckten Schichten werden entsprechend variiert und die Ausgabeschicht besteht aus fünf Knoten für die $n_R = 5$ reduzierten Variablen. Insgesamt werden neun unterschiedliche NN-Modellvarianten betrachtet. Für alle drei berücksichtigten mittleren Fehler ergeben sich die geringsten Werte für die NN-Variante 6 mit 3 versteckten Schichten und jeweils 36 Knoten ([36,36,36]). Diese Variante wird für weitere CAE-basierte Modellierungen mit NN-Regression der Koeffizienten berücksichtigt.

Für die kombiniert trainierten CAE-Modelle wird ebenfalls der Einfluss der verwendeten Polynomgrade n_p untersucht. Hier werden drei unterschiedliche CAE-Modellvarianten mit unterschiedlicher Anzahl an CNN-Schichten $n_L \in \{4,5,6\}$ verglichen. Die Anzahl an Filtern je Schicht beträgt für alle Varianten $n_F = 64$. Die Anzahl der reduzierten Variablen ist für alle Varianten mit $n_F = 5$ gleich. Für die Gewichtung der einzelnen Teile der Zielfunktion in Gleichung




Abbildung 7.36: Vergleich der mittleren Fehler der Druckfelder E_p , der Längs- E_x und Querkräfte E_y für das CAE-basierte Gesamtmodell mit NN-basierter Regression für verschiedene NN-Strukturen (Datensatz A).

(6.20) werden die Werte $\lambda_1 = 0,72$, $\lambda_2 = 0,18$ und $\lambda_3 = 0,1$ verwendet. Kleinere Änderungen der Werte haben nur einen geringen Einfluss auf den Trainingsprozess des kombinierten Modells. Der Einfluss des Polynomgrades auf die Fehler des kombiniert trainierten Gesamtmodells ist in den Abbildungen 7.37 und 7.38 aufgetragen.




Abbildung 7.37: Darstellung des Einflusses des Polynomgrades n_p für die Regression des kombiniert gelernten Modells auf die mittleren Fehler der Druckfelder E_p (Datensatz A).

Eine signifikante Wechselwirkung zwischen der Struktur des CAE-Teils und des Polynomgrades des Regressionsschrittes besteht nicht. Im Falle von $n_L = 4$ CNN-Schichten ergeben sich deutlich größere Fehler als für die beiden Varianten mit 5 bzw. 6 Schichten. Für die CAE-Varianten mit $n_L = 5$ und $n_L = 6$ zeigen sich kaum Unterschiede in Bezug auf die Fehler. Daher wird die einfachere Modellierungsvariante mit nur $n_L = 5$ Schichten bevorzugt. Die Fehler für die Kräfte E_x und E_y sind für den Polynomgrad $n_p = 3$ am geringsten. Die mittleren Fehler

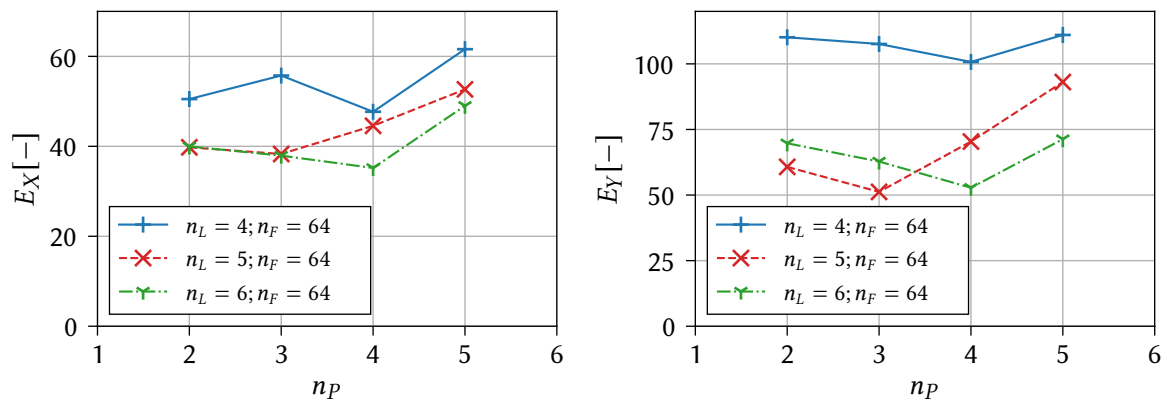


Abbildung 7.38: Darstellung des Einflusses des Polynomgrades n_p für die Regression des kombiniert gelernten Modells auf die mittleren Fehler der Längs- E_X und Querkräfte E_Y (Datensatz A)

der Druckfelder sind für $n_p = 2$ und $n_p = 3$ ähnlich groß. Daher wird für die das kombiniert trainierte Modell $n_p = 3$ gewählt. Für die Gaußprozess-Regression wird ein quadratisch exponentieller Kernel (RBF) verwendet.

Datensatz B: POD-basierte Modellierung

Für Datensatz B mit POD-basierter Dimensionsreduktion wird ebenfalls der Einfluss der Parameter der verschiedenen Regressionsmethoden analysiert. Der Polynomgrad der Polynomregression sowie die NN-Struktur werden variiert und jeweils ausgewertet. Zunächst wird der Einfluss des Polynomgrades n_p und der Anzahl berücksichtigter POD-Moden n_R auf die Rekonstruktion der Druckfelder und der Kräfte gezeigt.

Die mittleren Fehler der Druckfelder E_P sind in Abbildung 7.39 für eine unterschiedliche Anzahl von Moden n_R über dem Polynomgrad n_p aufgetragen.

Die Kurven für die unterschiedlichen Anzahl von POD-Moden verlaufen nahezu parallel. Die geringsten Fehler ergeben sich für die Polynomgrade $n_p = 4$ und $n_p = 6$. Die Berücksichtigung von mehr als $n_R = 12$ POD-Moden führt nicht zu einer Verringerung der Fehler.

In Abbildung 7.40 sind die mittleren Fehler der Längs- E_X und Querkräfte E_Y für unterschiedliche Anzahlen berücksichtigter POD-Moden n_R , und unterschiedliche Polynomgrade n_p dargestellt. Erneut verlaufen die Kurven nahezu parallel und die mittleren Fehler der Längskräfte sind für $n_p = 4$ und für die Querkräfte für $n_p = 6$ am geringsten. Für größere Polynomgrade $n_p > 6$ steigt der Fehler aufgrund der Überanpassung an. Wie auch beim Fehler der Druckfelder verringert sich der Fehler nicht signifikant, wenn mehr als $n_R = 12$ POD-Moden für die Modellierung berücksichtigt werden. Da sich für keinen Fehler signifikante Reduktionen für $n_p > 4$ ergeben und Überanpassung zu vermeiden ist, wird für die weitere Modellierung der Polynomgrad $n_p = 4$ gewählt.




Abbildung 7.39: Mittlere Fehler der Druckfelder E_P für die POD-basierte Dimensionsreduktion und die Polynomregression (Datensatz B). Dargestellt ist der Einfluss des Polynomgrades n_P auf die Regression und die Anzahl der berücksichtigten Moden n_R der Dimensionsreduktion.

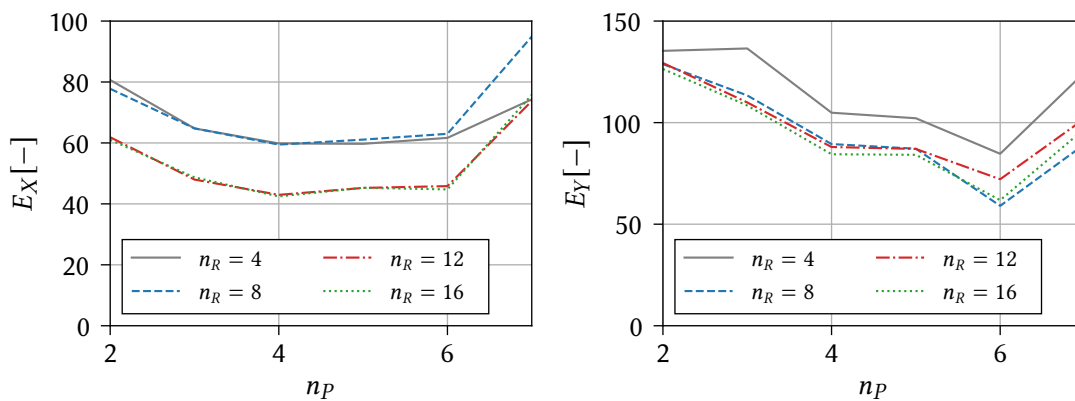


Abbildung 7.40: Mittlere Fehler der Längs- E_X und Querkräfte E_Y für die POD-basierte Dimensionsreduktion und die Polynomregression (Datensatz B). Dargestellt ist der Einfluss des Polynomgrades n_P auf die Regression und die Anzahl der berücksichtigten Moden n_R der Dimensionsreduktion.

Für die Regression mit Neuronalen Netzen werden für den Datensatz B unterschiedliche Netzstrukturen in Kombination mit der POD-basierten Reduktion getestet. Die Anzahl der für die Rekonstruktion verwendeten POD-Moden n_R wird ebenfalls variiert. Die Eingabeschicht besteht in diesem Fall entsprechend der Anzahl an Systemparametern des Datensatzes B $n_\alpha = 4$ aus vier Knoten. Die übrigen Parameter stimmen mit den zuvor in Tabelle 7.2 aufgeführten Daten überein.




Abbildung 7.41: Mittlere Fehler der Druckfelder E_P für die POD-basierte Dimensionsreduktion und die NN-basierte Regression (Datensatz B). Dargestellt ist der Einfluss der Netzstruktur und die Anzahl der berücksichtigten Moden n_R der Dimensionsreduktion.

In Abbildung 7.41 sind die mittleren Fehler der Druckfelder für vier unterschiedliche NN-Strukturen über der Anzahl berücksichtigter POD-Moden n_R dargestellt. Für die Variante mit zwei versteckten Schichten und jeweils vier Knoten sind die Fehler für $n_R > 4$ signifikant größer als für die übrigen drei Varianten, für welche die Fehler vergleichbar sind. Für die Fehler der Längs- und Querkräfte in Abbildung 7.42 zeigt sich für $n_R > 10$ keine klare Tendenz zur Abhängigkeit der Fehler von der Anzahl berücksichtigten POD-Moden. Die Werte der Fehler schwanken stochastisch. Für die weitere Modellierung wird die Variante mit $n_L = 2$ Schichten und je $n_K = 12$ Knoten gewählt, da eine Erhöhung der Modellkomplexität nicht zu geringeren Modellierungsfehlern führt.

Um die drei unterschiedlichen Regressionsmethoden für das POD-basierte Gesamtmodell für Validierungsdatensatz B direkt miteinander zu vergleichen, sind die mittleren Fehler der Druckfelder und der Kräfte in Abhängigkeit der Anzahl POD-Moden n_R in den Abbildungen 7.43 und 7.44 dargestellt. Zusätzlich sind die Fehler der reinen Dimensionsreduktion abgebildet.

Der Polynomgrad der Polynomregression ist $n_p = 4$, für die NN-Regression wird eine Netzstruktur mit $n_L = 2$ versteckten Schichten und jeweils $n_K = 12$ Knoten benutzt. Für die

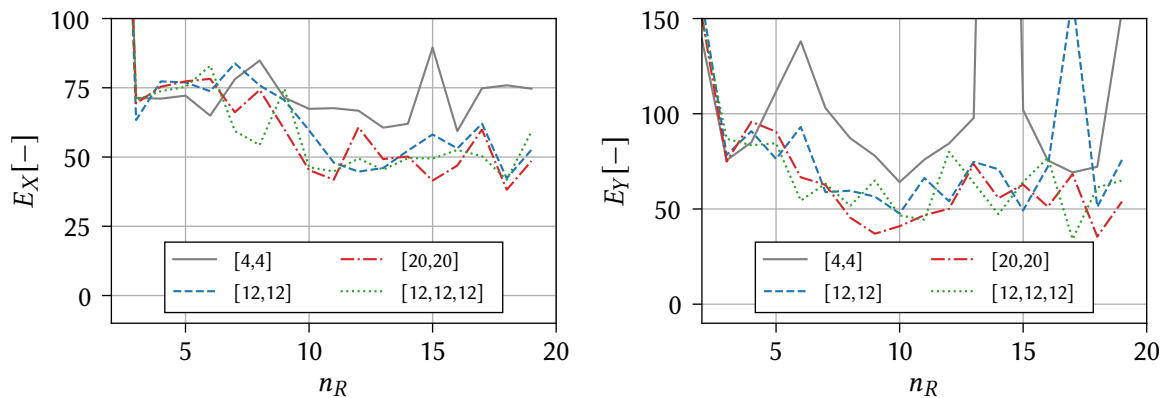


Abbildung 7.42: Mittlere Fehler der Längs- E_X und Querkräfte E_Y für die POD-basierte Dimensionsreduktion und die NN-basierte Regression (Datensatz B). Dargestellt ist der Einfluss der Netzstruktur und die Anzahl der berücksichtigten Moden n_R der Dimensionsreduktion.

Gaußprozess-Regression wird der RBF-Kernel verwendet. Für den RBF-Kernel wird für jeden Systemparameter ein eigenes Längenmaß als optimierter Modellparameter verwendet. Für die NN und Gaußprozess-basierten Regressionsmethoden sind die mittleren Fehler der Druckfelder E_P für $n_R < 12$ auf gleichem Niveau. Die Abweichungen in den Druckfeldern für die Modellierung mit Polynomregression sind hingegen signifikant größer. Für die mittleren Fehler der Kräfte E_X und E_Y sind die Fehler für die Gaußprozess-Regression am geringsten. Die mittleren Fehler der Querkräfte sind für die Polynomregression am größten.

Beim Vergleich der unterschiedlichen POD-basierten Modellvarianten für Datensatz B mit den mittleren Fehlern des Datensatzes A in den Abbildungen 7.33 und 7.34, sind für Datensatz B die Fehler vergleichsweise größer. Die Differenz zur reinen Dimensionsreduktion ist für Datensatz A geringer als für Datensatz B. Die Regression der Koeffizienten für die Modellbildung des Datensatzes B ist komplexer, was auf die höhere Anzahl an Systemparametern n_α zurückzuführen ist.

Datensatz B: CAE-basierte Modellierung

Für Datensatz B und die CAE-basierte Dimensionsreduktion wird ebenfalls der Einfluss der unterschiedlichen Modellparameter der Regressionsmethoden analysiert. Die Dimensionsreduktion basiert für alle Varianten auf der CAE-Struktur mit $n_L = 5$ Schichten und jeweils $n_F = 64$ Filtern. Der Standardwert der reduzierten Variablen ist $n_R = 5$, wobei dieser für einige Modellvarianten ebenfalls variiert wird, um eventuell existierende signifikante Wechselwirkungen zwischen den Varianten zu erkennen.

Zunächst wird der Einfluss der Polynomgrade n_P für zwei unterschiedlich Werte $n_R = 5$ und $n_R = 7$ untersucht. In Abbildung 7.45 sind die mittleren Fehler der Druckfelder E_P und der




Abbildung 7.43: Vergleich der mittleren Fehler der Druckfelder E_P für unterschiedliche Methoden der Regression in Abhängigkeit der Anzahl berücksichtigter POD-Moden n_R (Datensatz B). Vergleichend ist der Fehler des Dimensionsreduktionsschrittes (POD) dargestellt.

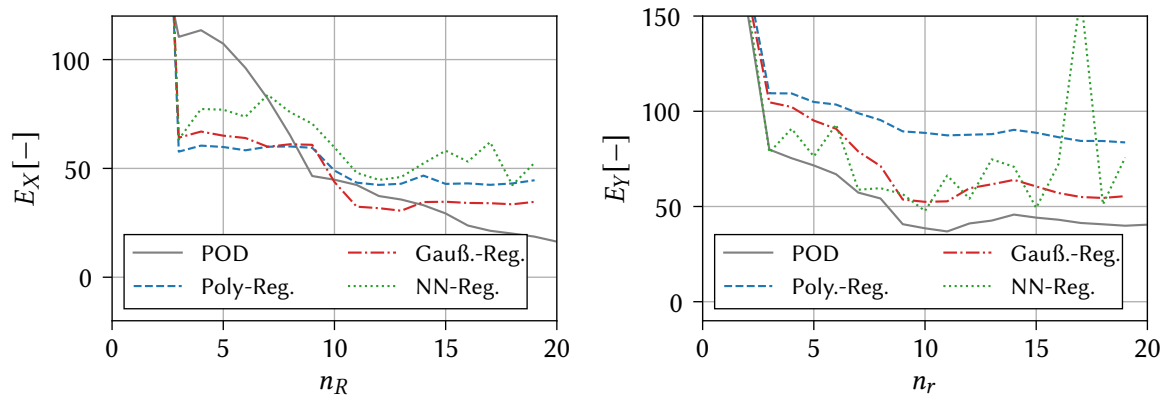


Abbildung 7.44: Vergleich der mittleren Fehler für die Längs- E_X und Querkräfte E_Y für unterschiedliche Methoden der Regression in Abhängigkeit der Anzahl berücksichtigter POD-Moden n_R (Datensatz B). Vergleichend ist der Fehler des Dimensionsreduktionsschrittes (POD) dargestellt.




Abbildung 7.45: Einfluss des Polynomgrades n_p auf die Fehler der Druckfelder und der Kräfte des CAE-basierten Modells mit unterschiedlicherer Anzahl reduzierter Variablen $n_R = 5$ und $n_R = 7$ (Datensatz B).

beiden Kräfte E_X und E_Y über dem Polynomgrad n_p aufgetragen. Für die mittleren Fehler der Druckfelder E_p und der Querkräfte E_Y liefert die Variante mit weniger reduzierten Variablen $n_R = 5$ bessere Ergebnisse, da eine höhere Anzahl reduzierter Variablen teilweise zu Koeffizienten führt, deren Abhängigkeit von den Systemparametern schwieriger darstellbar ist.

Für die beiden Kräfte sind die Fehler für den Polynomgrad $n_p = 4$ am geringsten, für die Druckfelder hingegen für $n_p = 6$. Um eine Überanpassung zu vermeiden, wird für die weitere Modellierung $n_R = 5$ und der Polynomgrad $n_p = 4$ gewählt.




Abbildung 7.46: Einfluss der NN-Struktur für die Regression basierend auf dem CAE-Modell auf die Fehler der Druckfelder E_p und der Kräfte E_X, E_Y (Datensatz B).

Für die NN-Regression der Koeffizienten wird ausschließlich der Fall $n_R = 5$ betrachtet. Für die Struktur des NN werden in Abbildung 7.46 die mittleren Fehler der Druckfelder und der Kräfte für neun unterschiedliche NN-Varianten dargestellt. Die größten Fehler ergeben sich für die Varianten 1,4 und 7 mit $n_K = 4$ Knoten je Schicht, unabhängig von der Anzahl verdeckter

Schichten. Die geringsten Fehler für die Fehler der Kräfte E_X und E_Y ergeben sich für die Variante mit $n_L = 2$ Schichten und jeweils $n_K = 36$ Knoten (Modellvariante 3 [36,36]). Für diese Variante ist auch der Fehler der Druckfelder E_P vergleichsweise gering. Diese Variante wird daher für die weitere Modellierung des Gesamtmodells gewählt.

Für Datensatz B wird ebenfalls der Einfluss des verwendeten Polynomgrades n_P für das kombiniert gelernte Modell analysiert. Es werden zwei unterschiedliche Strukturen mit $n_L = 5$ oder $n_L = 6$ CNN-Schichten und zwei unterschiedliche Anzahlen reduzierter Variablen $n_R = 5$ und $n_R = 7$ betrachtet. Für die Varianten mit $n_L = 6$ werden die Polynomgrade $n_P = 2$ und $n_P = 3$ berücksichtigt. Die Anzahl der Filter je CNN-Schicht beträgt dabei für alle Varianten $n_F = 64$. Die Werte der Gewichte der Zielfunktion sind unverändert $\lambda_1 = 0,72$, $\lambda_2 = 0,18$ und $\lambda_3 = 0,1$.




Abbildung 7.47: Einfluss des Polynomgrades n_P für die Regression der kombiniert gelernten Modelle auf die mittleren Fehler der Druckfelder E_P (Datensatz B).

Die mittleren Fehler der Druckfelder E_P und der Längs- E_X und Querkräfte E_Y sind in den Abbildungen 7.47 und 7.48 dargestellt. Die mittleren Fehler der Druckfelder stimmen für die Varianten mit $n_L = 5$ und $n_L = 6$ jeweils überein. Für $n_R = 5$ sind die Werte der Fehler für $n_P = 2$ und $n_P = 3$ nahezu identisch. Für die mittleren Fehler der Kräfte in Längs- und Quer- richtung sind für alle Modellvarianten die Fehler für den Polynomgrad $n_P = 2$ am geringsten. Bei einer weitere Reduzierung des Polynomgrades $n_P = 1$, was einer linearen Modellierung entspricht, sind die mittleren Fehler der Druckfelder und der Kräfte deutlich größer, weshalb sie hier nicht berücksichtigt wird. Für das kombiniert trainierte Gesamtmodell für Datensatz B wird die Modellvariante mit $n_L = 5$ und $n_R = 5$ und der Polynomgrad $n_P = 2$ final gewählt.

Eine Wahl von höheren Polynomgraden führt zu einer höheren Anpassungsfähigkeit des Polynom-basierten Regressionsmodells. Eine zu hohe Anpassungsfähigkeit führt dabei zu einer Überanpassung an die Trainingsdaten. Der Einfluss jedes einzelnen Koeffizienten ξ_i der Polynomregression ist unterschiedlich stark und für sehr kleine Werte näherungsweise ver-

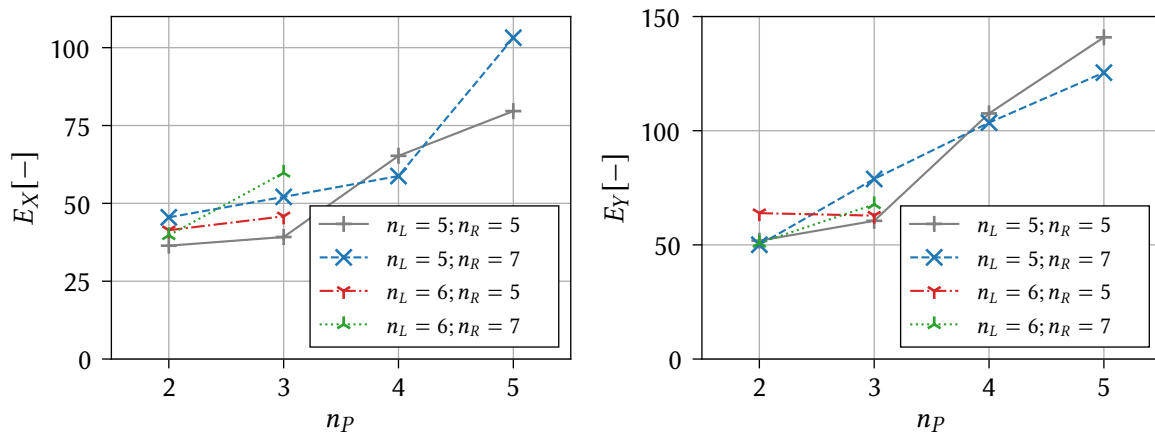


Abbildung 7.48: Einfluss des Polynomgrades n_p für die Regression der kombiniert gelernten Modelle auf die mittleren Fehler der Längs- E_X und Querkräfte E_Y (Datensatz B).

nachlässigbar. Zusätzlich ist das Ziel der Modellierung ein möglichst einfaches Modell mit nur wenigen Parametern zu erstellen. Eine Möglichkeit für die kombiniert gelernten Modelle ein möglichst kompaktes Modell für die Regression zu erreichen, besteht in der Grenzwert-basiertes Deaktivierung einzelner Polynomkoeffizienten ξ_j .

Wenn einzelne Koeffizienten kleine Werte während des Trainings annehmen, werden diese vollständig deaktiviert: wenn $\xi_j < (t^* \cdot \bar{\xi})$ dann $\xi_j = 0$. Dabei beschreibt t^* den relativen Grenzwert der Deaktivierung. Zunächst wird das Modell für 500 Epochen mit vollständigen Polynomkoeffizienten trainiert, bevor alle 50 Epochen ein Unterschreiten des Grenzwertes überprüft wird und die entsprechenden Koeffizienten deaktiviert werden. Für die drei unterschiedlichen Polynomgrade $n_p \in \{2,3,4\}$ wird der Einfluss der Deaktivierung der Polynomkoeffizienten für unterschiedliche relative Grenzwerte t^* analysiert. In Abbildung 7.49 ist die relative Anzahl final aktiver Polynomkoeffizienten n_ξ^* und die mittleren Fehler der Druckfelder E_p über dem relativen Grenzwert t^* aufgetragen.

Für die größten berücksichtigten Werte für $t^* = 0,5$ sind noch ungefähr die Hälfte der Polynomkoeffizienten aktiv $n_\xi^* \approx 0,5$. Die Fehler der Druckfelder sind für kleinere Polynomgrade nahezu konstant und steigen mit zunehmendem Grenzwert leicht an. Für die Modellierung mit dem Polynomgrad $n_p = 4$ führt die Grenzwert-basierte Deaktivierung der Koeffizienten zu geringeren Fehlern in den Druckfeldern. Allerdings ist für diese Variante dennoch der Fehler deutlich größer als für die kleineren Polynomgrade ($n_p = 2$ und $n_p = 3$).

In Abbildung 7.50 sind die zugehörigen Metriken der aerodynamischen Kräfte E_X und E_Y für die unterschiedliche Modellvarianten mit Grenzwert-basierter Deaktivierung dargestellt. Hier zeigt sich für alle dargestellten Modellvarianten keine eindeutige Tendenz und es resultiert somit kein Vorteil aus der Deaktivierung der Polynomkoeffizienten. Die Grenzwert-basierte Deaktivierung der Polynomkoeffizienten wird daher nicht für die weitere Modellierung ange-




Abbildung 7.49: Relative Anzahl der aktiven Polynomkoeffizienten n_{ξ}^* und mittleren Fehler der Druckfelder E_p für unterschiedliche relative Grenzwerte t^* und Polynomgrade n_p (Datensatz B).

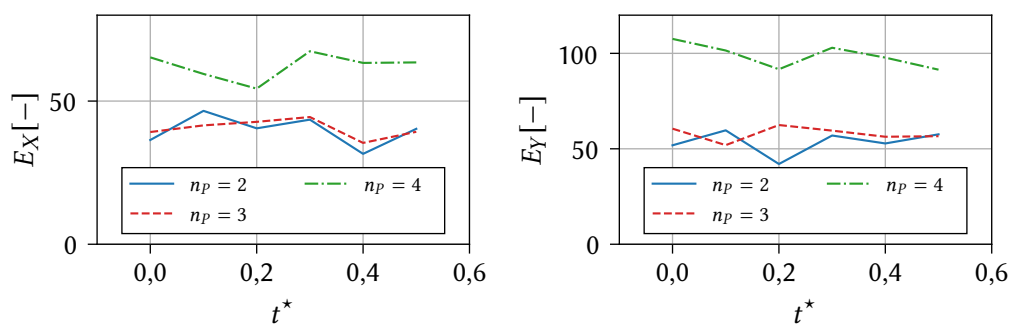


Abbildung 7.50: Mittlere Fehler der Längs- E_X und Querkräfte E_Y für unterschiedliche relative Grenzwerte t^* und Polynomgrade n_p (Datensatz B).

wendet. Für andere Anwendungen der Methode oder andere Problemstellungen ist ein Vorteil der Deaktivierung denkbar.

7.4.2 Gesamtmodell Datensatz A

Bei der Beurteilung der Vorhersagequalität des Gesamtmodells liegt der Fokus auf den Kräften in Längs- und Querrichtung, welche aus den rekonstruierten Druckfeldern resultieren. Zunächst werden die Kräfte der Testdaten des Datensatzes A betrachtet. Der Testdatensatz besteht aus zwei Beladungskonfigurationen, für welche mittels der datenbasierten Modelle die kontinuierlichen Kraftverläufe bestimmt werden.

Die Referenzdaten basieren auf den Druckfeldern der Ergebnisse der numerischen Simulationen. Die Druckfelder werden zunächst auf das reguläre Metagitter interpoliert und die resultierenden Kräfte auf diesem Metagitter bestimmt. Deshalb werden die aus der Interpolation auf das Metagitter resultierenden Fehler hier nicht weiter berücksichtigt, sondern nur die direkten Fehler innerhalb der datenbasierten Modellierung.

Um einen qualitativen Eindruck der Ergebnisse zu vermitteln, sind in Abbildung 7.51 die Kraftverläufe in Längs- c_X und Querrichtung c_Y über dem Windwinkel β für die POD-basierten Modellvarianten aufgetragen. Es werden die Längs- und Querkraften für die zwei unterschiedlichen Beladungskonfigurationen $h_c = 1$ und $h_c = 5$ im schiffsfesten Koordinatensystem betrachtet. Für die Modellierung werden $n_R = 12$ POD-Moden verwendet. Die Polynomregression der zugehörigen Koeffizienten basiert auf dem Polynomgrad $n_P = 6$. Für die Gaußprozess-Regression wird der RBF-Kernel eingesetzt und für die NN-Regression werden $n_L = 2$ Schichten mit jeweils $n_K = 20$ Knoten verwendet.

Durch den Vergleich der Kraftverläufe für die unterschiedlichen Modellvarianten wird deutlich, dass durch die Polynomregression der Verlauf der Kräfte, insbesondere für die Längskräfte, nur stark vereinfacht rekonstruiert wird. Die beiden auf Neuronalen Netzen und dem Gaußprozess basierenden Modellvarianten zeigen eine vergleichbare Qualität. Die hier gezeigten Kräfte basieren auf den Druckfeldern, welche für ausgewählte Windwinkel im Anhang A beispielhaft abgebildet sind.

Die dimensionslosen Kraftverläufe c_X und c_Y der CAE-basierten Dimensionsreduktion sind in Abbildung 7.52 über dem Windwinkel β dargestellt. Die Dimensionsreduktion berücksichtigt dabei $n_R = 5$ reduzierte Variablen. Die CNN-Struktur besteht aus $n_L = 5$ CNN-Schichten mit jeweils $n_F = 64$ Filtern. Für den Regressionsschritt wird bei der Polynomregression der Grad $n_P = 6$ angewendet, für die NN-Regression $n_L = 3$ Schichten mit je $n_K = 36$ Knoten und für das kombinierte Modell der Polynomgrad $n_P = 3$. Die Übereinstimmung der dargestellten Modellvarianten mit den Vergleichsdaten ist sehr gut, lediglich für das Modell mit Polynomregression

treten deutlichere Abweichungen zu den Referenzdaten auf. Für die beiden Beladungskonfigurationen der Testdaten sowie jeweils zwei ausgewählte Windwinkel β werden die zugehörigen rekonstruierten Druckfelder in Anhang A vergleichend dargestellt.

Neben den Kraftverläufen werden zusätzlich die mittleren Fehler der Druckfelder E_P sowie der Längs- E_X und Querkraft E_Y in Tabelle 7.3 für alle Modellvarianten zusammengefasst. Dies ermöglicht die quantitative Beurteilung der unterschiedlichen Varianten der Dimensionsreduktion und der Regression.

Der kleinste mittlere Fehler der Druckfelder E_P ergibt sich für das kombiniert trainierte Modell und das CAE-basierte Modell mit NN-Regression. Die größten Abweichungen in den Druckfeldern zeigen sich für die Varianten mit Polynomregression für beide Methoden der Dimensionsreduktion. Für die dargestellten mittleren Abweichungen der Kraftbeiwerte E_X und E_Y liegen alle Modellvarianten in einem ähnlichen Bereich, wobei ebenfalls für die Polynomregression die größten Fehler auftreten.

Tabelle 7.3: Übersicht der mittleren absoluten Fehler für die Druckfelder sowie die Kräfte für die unterschiedlichen Modellvarianten (Datensatz A). Die angegebenen Abweichungen beziehen sich auf die Modellvariante mit dem jeweils geringsten Fehler.

Modellvariante	$E_P[-]$	Abw. [%]	$E_X[-]$	Abw. [%]	$E_Y[-]$	Abw. [%]
POD + Polynomreg. ($n_p = 6$)	0,0311	48,1	34,65	88,3	57,31	31,9
POD + Gauß-Reg.	0,0246	17,1	18,40	0,0	43,44	0,0
POD + NN-Reg. ($n_L = 2; n_K = 20$)	0,0279	32,9	25,86	40,5	52,09	19,9
CAE + Polynomreg. ($n_p = 6$)	0,0270	28,6	37,50	103,8	64,72	49,0
CAE + Gauß-Reg.	0,0214	1,9	25,65	39,4	43,67	0,5
CAE + NN-Reg. ($n_L = 3; n_K = 36$)	0,0213	1,4	27,51	49,5	46,65	7,4
CAE kombiniertes Mod. ($n_p = 3$)	0,0210	0,0	28,94	57,3	53,20	22,5

7.4.3 Gesamtmodell Datensatz B

Wie bereits zuvor für Datensatz A wird im Folgenden für Datensatz B die Vorhersagequalität der unterschiedlichen Modellvarianten ausgewertet. Der Testdatensatz B besteht aus drei unterschiedlichen, zufällig ausgewählten Beladungskonfigurationen. Für zwei beispielhafte Winkel β sind in Anhang B die mittels der unterschiedlichen Modellvarianten rekonstruierten Druckfelder vergleichend dargestellt.

Zunächst werden die Verläufe der dimensionslosen Kraftbeiwerte über dem Windwinkel für die drei Beladungskonfigurationen betrachtet. In den Abbildungen 7.53 und 7.54 sind die Vorhersagen der POD-basierten Modellvarianten abgebildet. Für die Erstellung der Modelle werden für alle Varianten $n_R = 12$ POD-Moden verwendet. Der Polynomgrad der Regression ist $n_p = 4$,

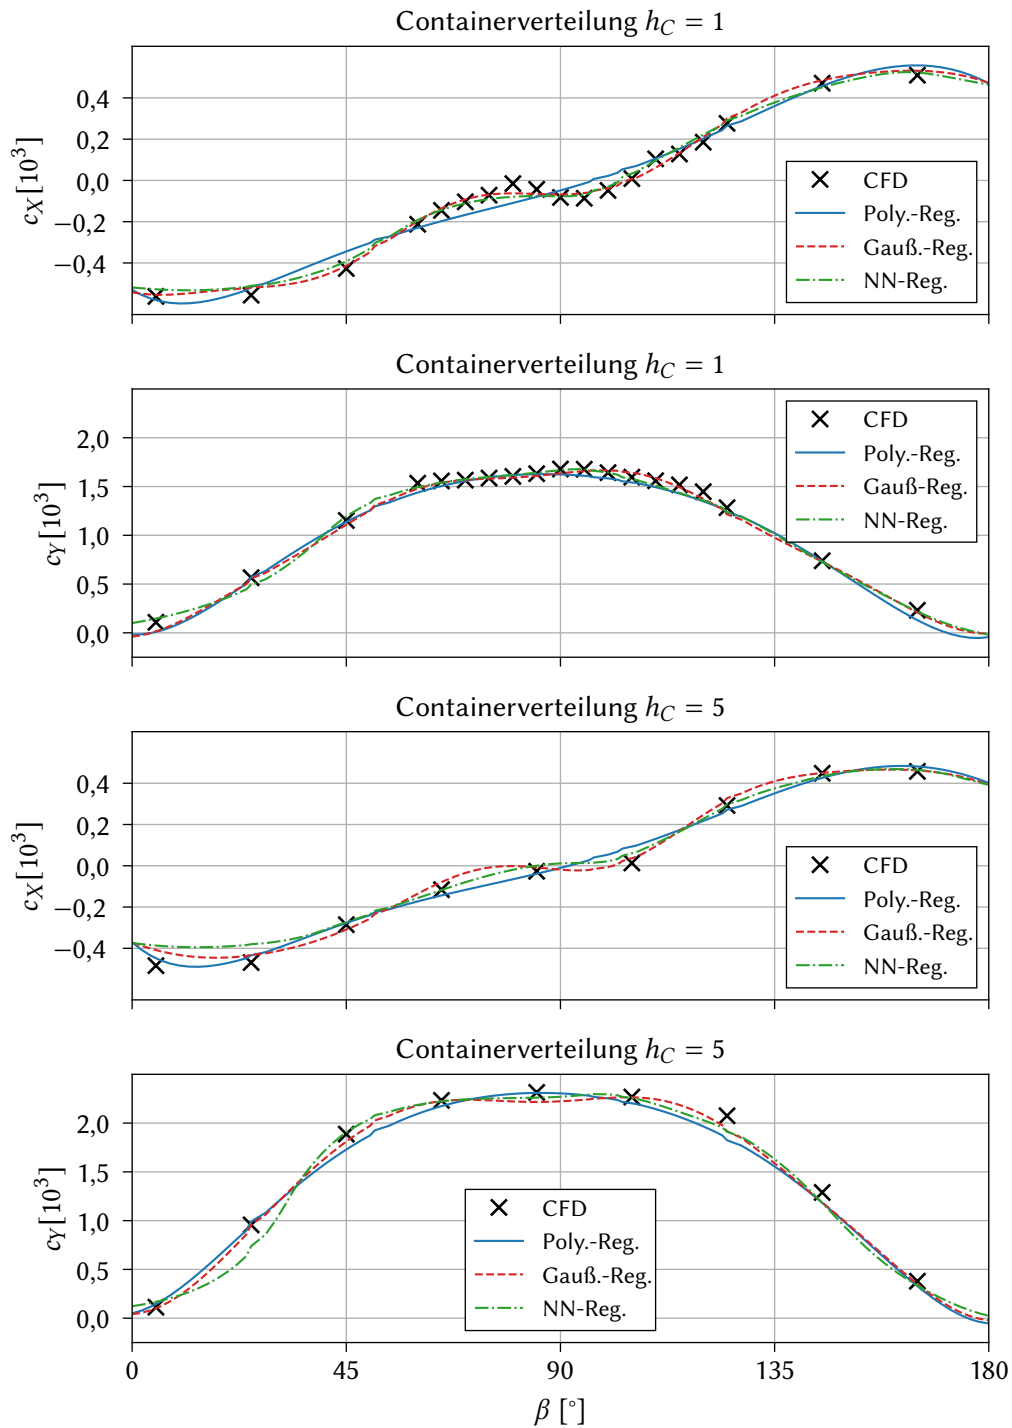


Abbildung 7.51: Verlauf der dimensionslosen Kraftbeiwerte in Längs- c_x und Querrichtung c_y der POD-basierten Modellvarianten ($n_R = 12$) für die zwei unterschiedliche Beladungskonfigurationen der Testdaten A. Verglichen werden die unterschiedlichen Regressionsmethoden: Polynomregression, Gaußprozess-Regression und NN-Regression.

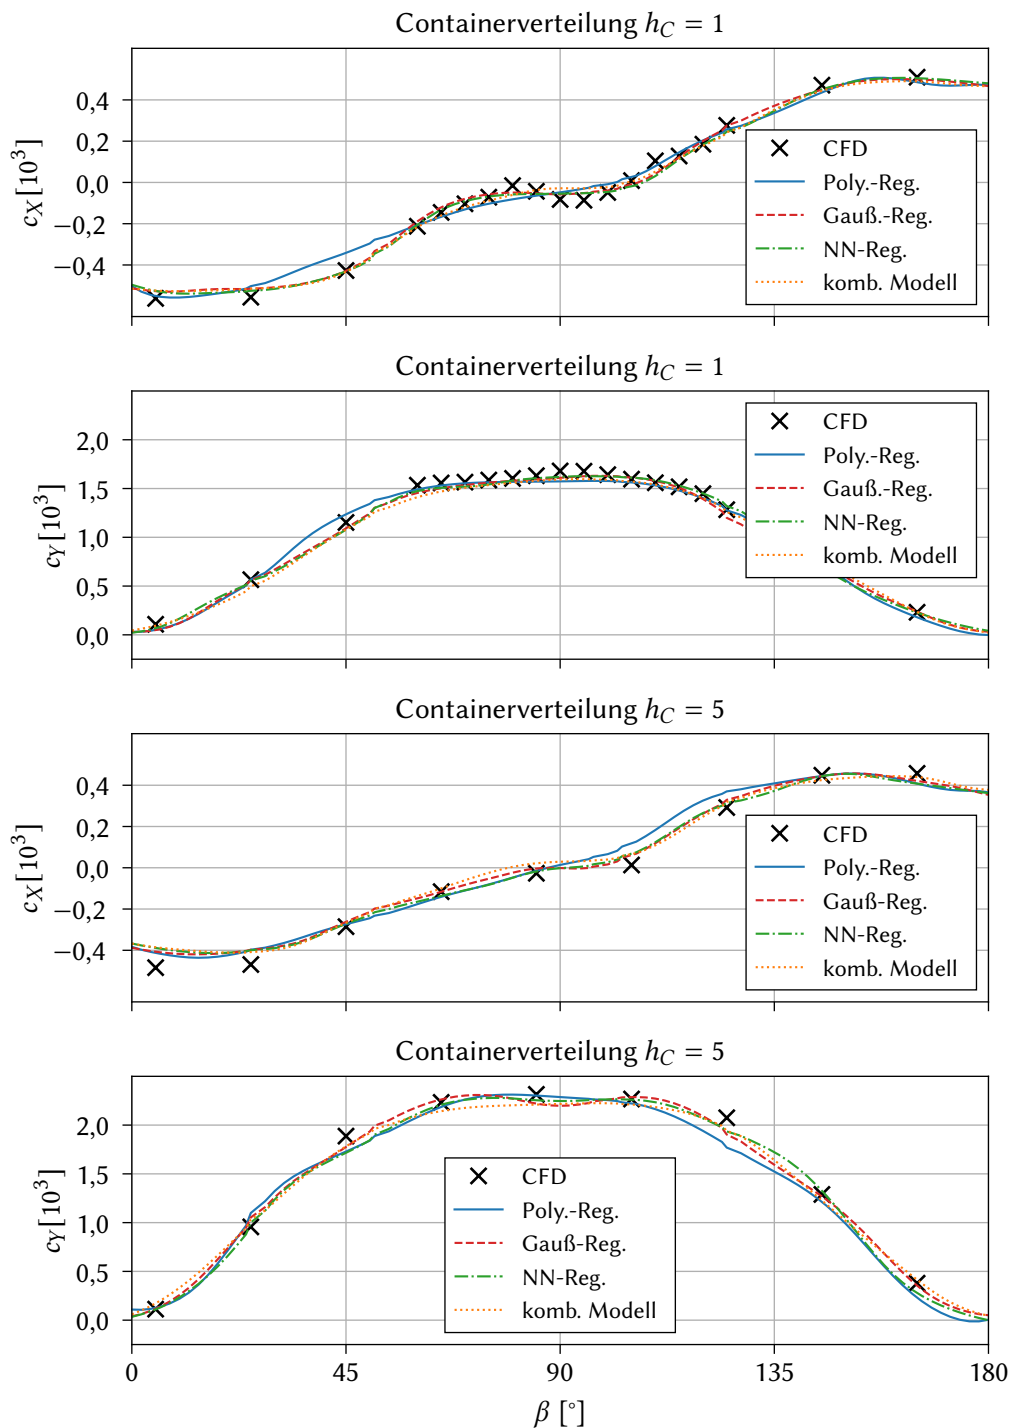


Abbildung 7.52: Verlauf der dimensionslosen Kraftbeiwerte in Längs- c_X und Querrichtung c_Y der CAE-basierten Modellvarianten ($n_R = 5$) für die zwei unterschiedliche Beladungskonfigurationen der Testdaten A. Verglichen werden die unterschiedlichen Regressionsmethoden: Polynomregression, Gaußprozess-Regression, NN-Regression und das kombiniert gelernte Modell.

das NN besteht aus $n_L = 2$ Schichten mit jeweils $n_K = 12$ Knoten und für die Gaußprozess-Regression wird der RBF-Kernel verwendet. Für die Modellvariante mit Polynomregression zeigen sich deutliche Abweichungen der Kraftverläufe von den Referenzdaten. Die Modellvarianten mit Gaußprozess und NN-Regression stimmen gut mit den Vergleichsdaten überein. Dennoch zeigen sich teils kleinere Abweichungen von den Referenzdaten, insbesondere für die Verläufe der Querkraftkoeffizienten c_Y .

Für die Modellvarianten mit CAE-basierter Dimensionsreduktion werden $n_r = 5$ reduzierte Variablen verwendet. Die CNN-Struktur besteht aus $n_L = 5$ CNN-Schichten mit jeweils $n_F = 64$ Filtern. Somit stimmt die Struktur des CAEs mit der für Datensatz A verwendeten Struktur überein. Für die Polynomregression ist der Polynomgrad $n_P = 4$. Das NN für die Regression besteht aus $n_L = 2$ Schichten und jeweils $n_K = 36$ Knoten und für das kombiniert gelernte Modell ist der Polynomgrad $n_P = 2$.

Die resultierenden Verläufe der dimensionslosen Kraftbeiwerte für die drei betrachteten Belastungskonfigurationen sind in den Abbildungen 7.55 und 7.56 über dem Winkel β dargestellt. Für alle vier getesteten Modellvarianten zeigt sich eine gute Übereinstimmung mit den Referenzdaten.

Für Datensatz B sind die mittleren Fehler der Druckfelder E_P , und der dimensionslosen Kraftbeiwerte in Längs- E_X und Querrichtung E_Y für die unterschiedlichen Modellvarianten in Tabelle 7.4 zusammengefasst. Der mittlere Fehler der Druckfelder ist hierbei für das kombiniert trainierte CAE-basierte Modell am geringsten. Insgesamt sind die mittleren Fehler der Druckfelder für die CAE-basierten Modelle geringfügig kleiner im Vergleich zu den POD-basierten Varianten. Für beide Varianten der Dimensionsreduktion zeigen sich die größten Fehler im Druckfeld in Kombination mit der Polynomregression. Bei den mittleren Fehlern der Längskräfte und Querkräfte zeigt sich ebenfalls eine bessere Vorhersage der CAE-basierten Modellvarianten, wobei sich für das kombinierte Modell und die Gaußprozess-Regression ähnlich große Fehler ergeben.

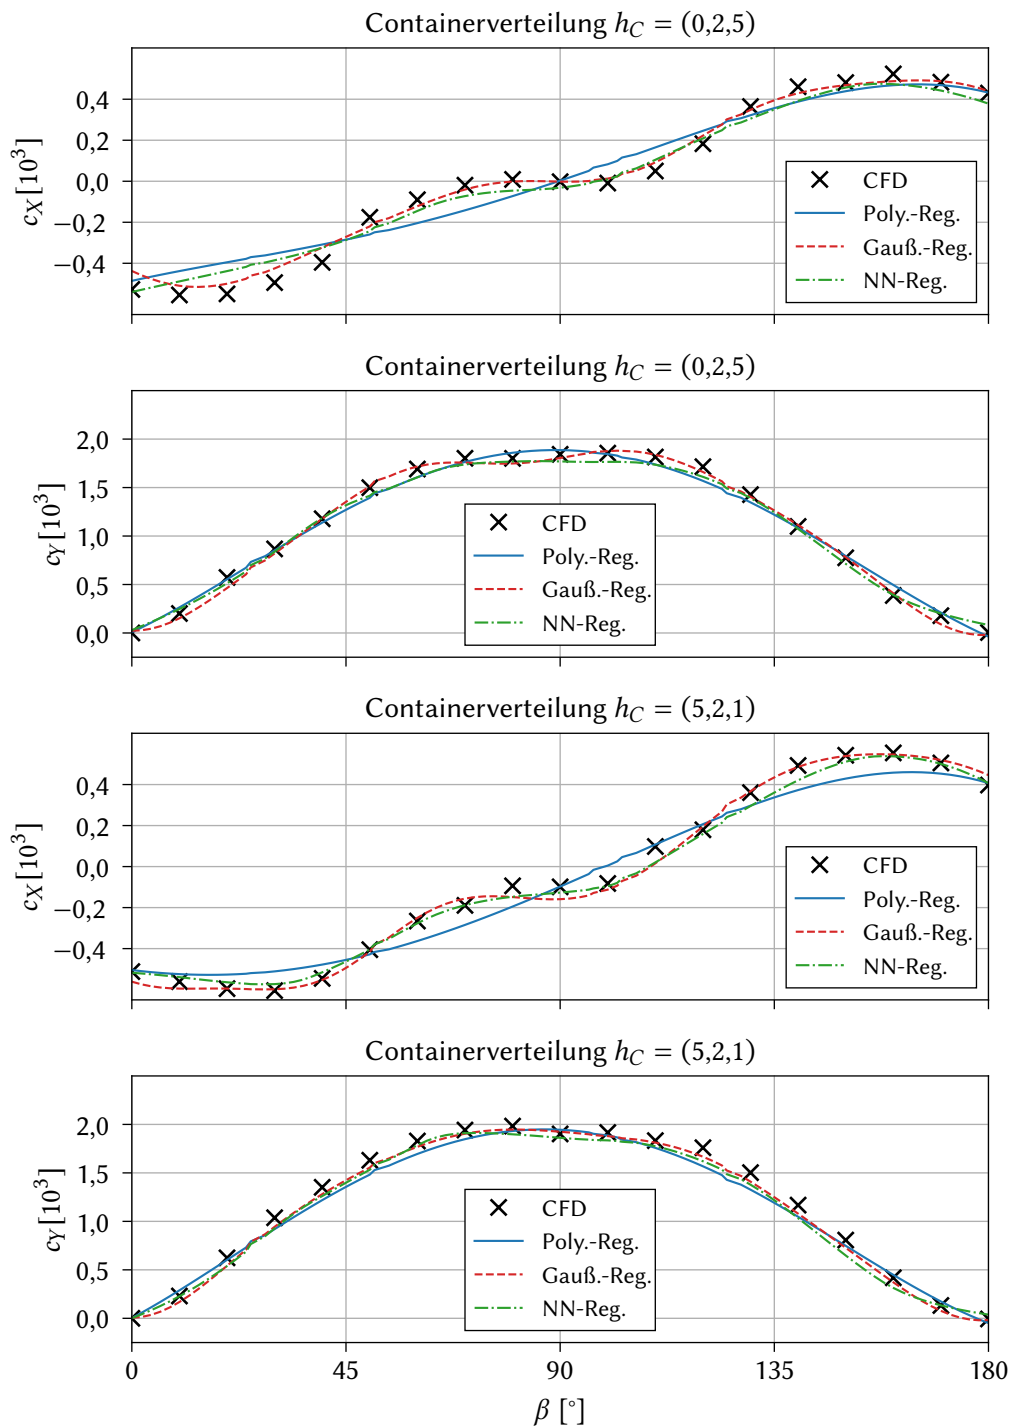


Abbildung 7.53: Verlauf der dimensionslosen Kraftbeiwerte in Längs- c_X und Querrichtung c_Y für die POD-basierten Modellvarianten ($n_R = 12$) für die zwei Beladungskonfigurationen $h_C = (0,2,5)$ und $h_C = (5,2,1)$ der Testdaten B. Verglichen werden die unterschiedlichen Regressionsmethoden: Polynomregression, Gaußprozess-Regression und NN-Regression.

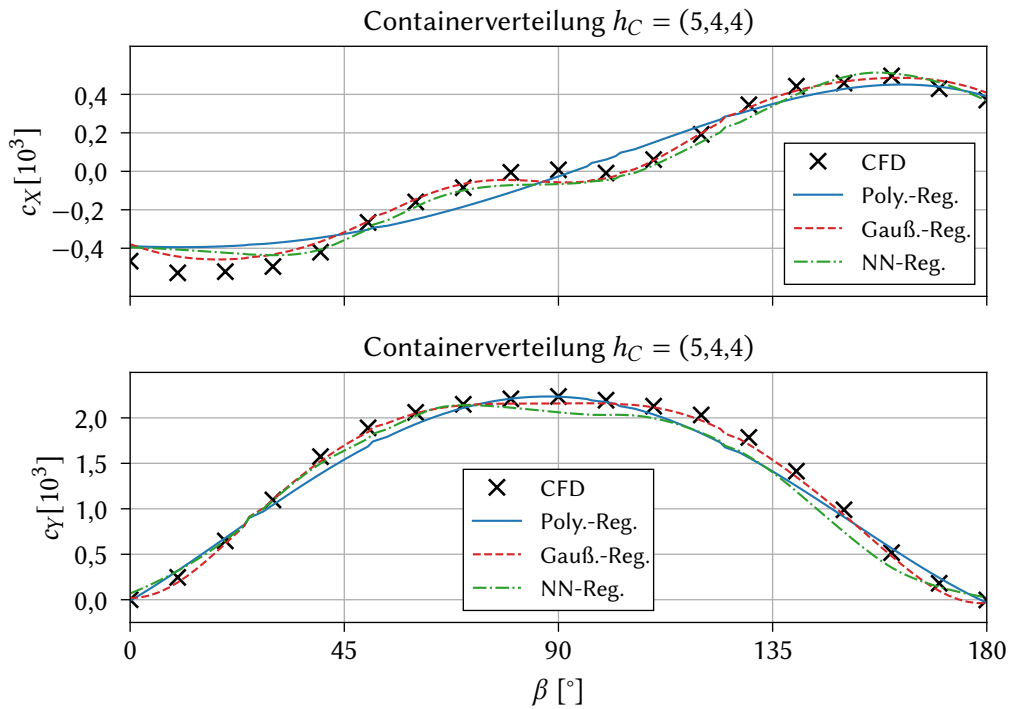


Abbildung 7.54: Verlauf der dimensionslosen Kraftbeiwerte in Längs- c_X und Querrichtung c_Y für die POD-basierten Modellvarianten ($n_R = 12$) für die dritte Beladungskonfigurationen $h_C = (5,4,4)$ der Testdaten B. Verglichen werden die unterschiedlichen Regressionsmethoden: Polynomregression, Gaußprozess-Regression und NN-Regression.

Tabelle 7.4: Übersicht der mittleren Fehler für die Druckfelder sowie die Kräfte für die unterschiedlichen Modellvarianten (Datensatz B). Die angegebenen Abweichungen beziehen sich auf die Modellvariante mit dem jeweils geringsten Fehler.

Modellvariante	$E_P[-]$	Abw. [%]	$E_X[-]$	Abw. [%]	$E_Y[-]$	Abw. [%]
POD + Polynomreg. ($n_P = 4$)	0,0386	79,5	68,56	120,9	74,45	130,6
POD + Gauß-Reg.	0,0275	27,9	31,88	2,7	45,48	40,9
POD + NN-Reg. ($n_L = 2; n_K = 12$)	0,0303	40,9	42,15	35,8	79,94	147,6
CAE + Polynomreg. ($n_P = 4$)	0,0281	30,7	36,85	18,8	50,70	57,1
CAE + Gauß-Reg.	0,0216	0,5	31,74	2,3	49,33	52,8
CAE + NN-Reg. ($n_L = 2; n_K = 36$)	0,0229	6,5	31,03	0,0	49,65	53,8
CAE kombiniertes Mod. ($n_P = 2$)	0,0215	0,0	33,19	7,0	32,28	0,0

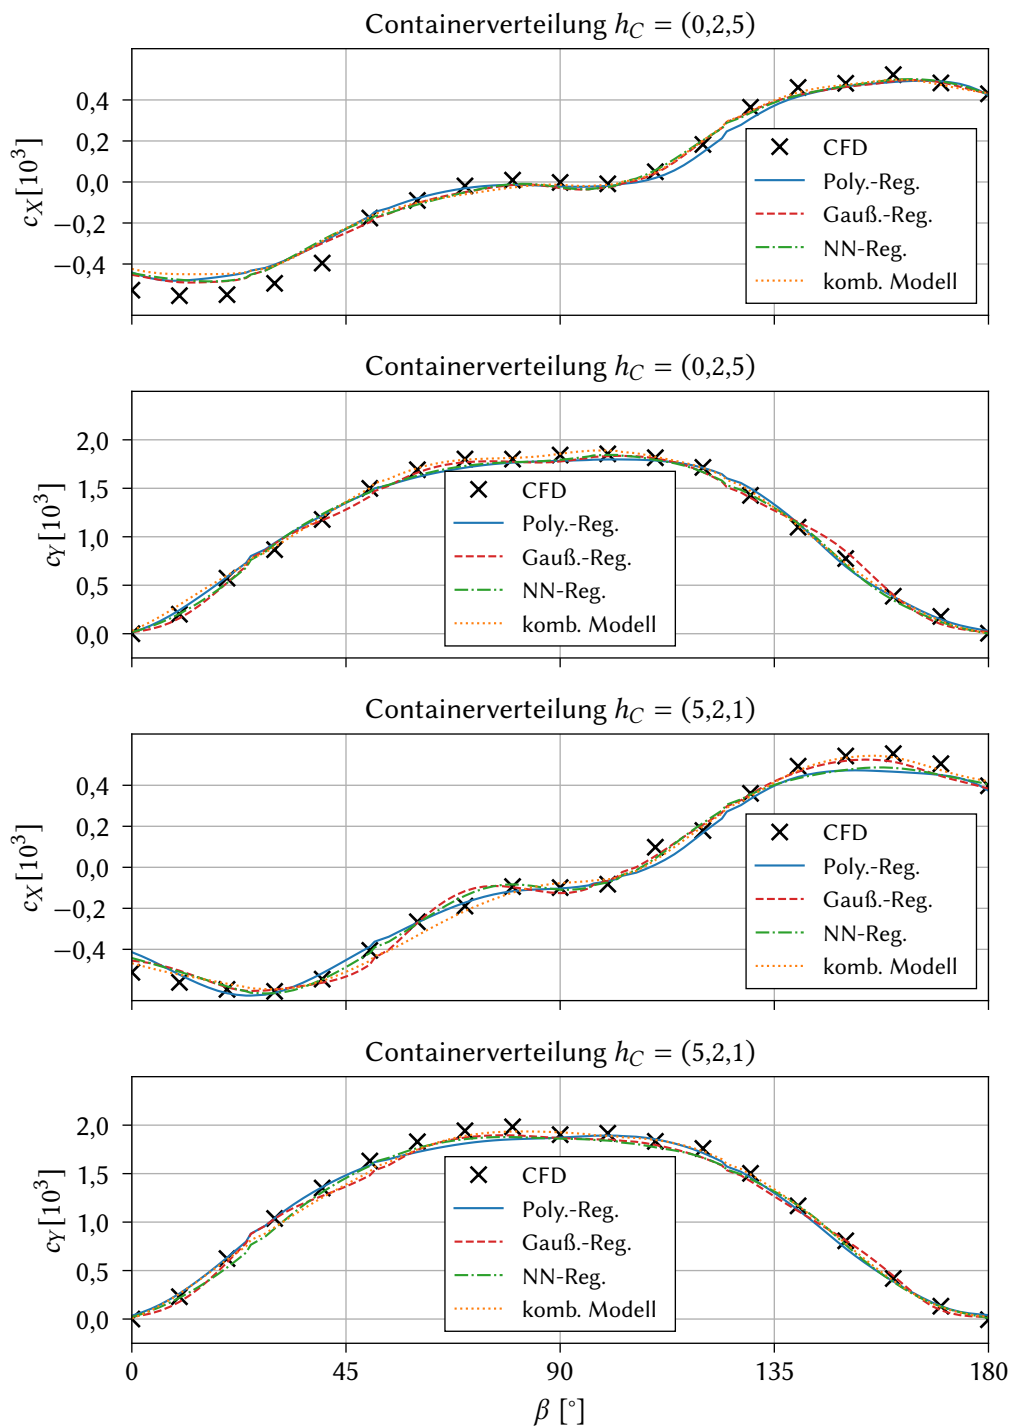


Abbildung 7.55: Verlauf der dimensionslosen Kraftbeiwerte in Längs- c_x und Querrichtung c_y für die CAE-basierten Modellvarianten ($n_R = 5$) für die zwei Beladungskonfigurationen $h_C = (0,2,5)$ und $h_C = (5,2,1)$ der Testdaten B. Verglichen werden die unterschiedlichen Regressionsmethoden: Polynomregression, Gaußprozess-Regression und NN-Regression und das kombiniert gelernte Modell.

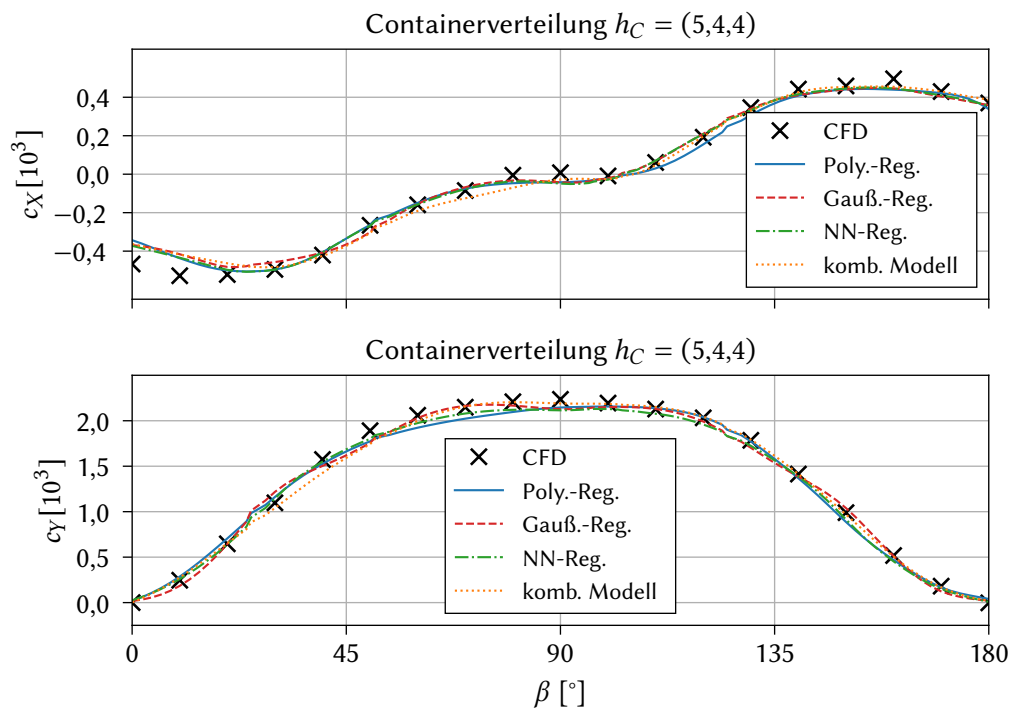


Abbildung 7.56: Verlauf der dimensionslosen Kraftbeiwerte in Längs- c_x und Querrichtung c_y für die CAE-basierten Modellvarianten ($n_R = 5$) für die dritte Beladungskonfigurationen $h_c = (5,4,4)$ der Testdaten B. Verglichen werden die unterschiedlichen Regressionsmethoden: Polynomregression, Gaußprozess-Regression, NN-Regression und das kombiniert gelernte Modell.

7.5 Bewertung der Methodik und der Ergebnisse

Für die Dimensionsreduktion basierend auf der POD- und der CAE-Methode lassen sich nahezu gleichwertige Surrogatmodelle bilden, wobei sich für die CAE-basierten Gesamtmodelle insbesondere für den geometrisch und strömungstechnisch komplexeren Datensatz B leichte Vorteile ergeben. Die CAE-basierte Reduktion ist im Vergleich zur POD deutlich kompakter. Für den vorliegenden Anwendungsfall werden $n_R = 5$ reduzierte Variablen und $n_R = 12$ POD-Moden für die Modellierung beider Datensätze verwendet. Der Vergleich der rekonstruierten Druckfelder aus POD- und CAE-basierter Dimensionsreduktion zeigt, dass die Abweichungen zu den realen Daten nahezu ausschließlich in den gleichen Bereichen auftreten. Dies deutet darauf hin, dass die auftretenden Fehler aus den fehlenden Informationen in der Datenbasis und nicht aus der Modellierungsmethode resultieren. Durch Verwendung von umfangreicheren Datensätzen wird folglich eine weitere Reduzierung der Abweichungen erwartet.

Die Dimensionsreduktion der CAE-Methode wird stark von den verwendeten Hyperparametern beeinflusst. Die einflussreichsten Hyperparameter sind, neben der Anzahl der verwendeten reduzierten Variablen, die Anzahl der CNN-Schichten sowie die jeweilige Filteranzahl der Schichten. In vergleichbaren Arbeiten anderer Autoren werden jeweils unterschiedliche CNN-Strukturen verwendet. Der Vergleich unterschiedlicher CNN-Strukturen in der vorliegenden Arbeit zeigt, dass die Details der Struktur nur einen moderaten Einfluss auf die Ergebnisse haben. Die Verwendung etablierter Methoden, wie des Adam-Optimierers und des Maximum-Poolings innerhalb der CNN-Schichten haben sich in dieser Arbeit als zielführend erwiesen.

Zur Darstellung des funktionalen Zusammenhangs der Koeffizienten mit den Systemparametern, werden im Rahmen dieser Arbeit drei unterschiedliche Methoden zur Regression eingesetzt. Die Surrogatmodelle, bei welchen die Regression mittels Polynomen erstellt wird, zeigen die größten Abweichungen zu den Referenzdaten auf. Die Vorhersagequalität der Surrogatmodelle mit Polynomregression hängt unter anderem vom Datensatz und der gewählten Methode der Dimensionsreduktion ab. Für den komplexeren Beladungsdatensatz B sind die Abweichungen der prognostizierten Verläufe der Kräfte bei Verwendung der POD-basierten Reduktion sehr groß. Für die CAE-basierte Reduktion und Polynomregression hingegen ist die Vorhersage vergleichbar mit den übrigen Modellvarianten. Die Qualität der Modellierung ist sehr sensitiv für den Polynomgrad: für zu geringe Polynomgrade ist die Anpassungsfähigkeit zu gering und zu große Polynomgrade resultieren in einer raschen Überanpassung an die Trainingsdaten.

Die NN-Regression und die Regression basierend auf Gaußprozessen führen zu einer sehr guten und vergleichbaren Vorhersagequalität. Die Hyperparameter der NN-Regression sind deutlich umfangreicher. Insbesondere die Struktur des Netzes hat einen großen Einfluss auf

die Ergebnisse. Bei der Gaußprozess-Regression können die freien Parameter hingegen direkt bestimmt werden und die Modellerstellung ist vergleichsweise einfach.

Das kombinierte Training der Dimensionsreduktion und des Regressionsschrittes ist für die Surrogatmodellierung vorteilhaft. Die mittels der kombiniert trainierten Gesamtmodelle prognostizierten Druckfelder und Kraftverläufe weisen die geringsten Abweichungen zu den Referenzdaten auf. Die Polynom-basierte Modellierung der Regression der Koeffizienten führt zu einer besseren Interpretierbarkeit der Modellierung. Für die Modellierung sind vergleichsweise geringe Polynomgrade ausreichend und die Regression wird durch wenige Modellparameter vollständig beschrieben. Dadurch wird auch das vorhandene Anpassungspotential des CAE deutlich. Die Anwendung höherer Polynomgrade kombiniert mit der Deaktivierung einzelner Terme innerhalb der Polynomregression führt zu keinen Vorteilen im Vergleich zur vollständigen Berücksichtigung aller Terme niedriger Polynomgrade. Der Nachteil der kombinierten im Vergleich zur sequenziellen Modellierung ist der komplexere Trainingsprozess, da sich die Zielfunktion aus mehreren Termen zusammensetzt und diese jeweils gewichtet werden müssen.

Die beiden verwendeten Datensätze A und B unterschieden sich im Umfang und der Varianz der jeweiligen Datenbasis. Die Druckfelder des Datensatzes B enthalten mehr Varianz, was durch den Vergleich der POD-basierten Dimensionsreduktion für Datensatz A und B verdeutlicht wird. Der Umfang von Datensatz B ist ferner deutlich größer als der Umfang des Datensatzes A. Dies ist für eine datenbasierte Modellierung vorteilhaft. Beim Vergleich der Vorhersagequalität der unterschiedlichen Modelle für die beiden Datensätze A und B zeigt sich, dass für Datensatz A die POD- und CAE-basierten Modelle eine ähnliche Qualität liefern. Beim Datensatz B hingegen dominieren die CAE-basierten Modelle in der Qualität der Bestimmung der Druckfelder deutlich, was auf die komplexere Struktur der Datenfelder und die doppelte Anzahl an Systemparametern ($n_{\alpha_B} = 4$, $n_{\alpha_A} = 2$) zurückzuführen ist.

In vergleichbaren Arbeiten werden Methoden der datenbasierten Modellierung ausschließlich für strömungsmechanische Problemstellungen mit geringer Komplexität und kleinen Reynoldszahlen betrachtet. Im Rahmen der vorliegenden Arbeit wird eine datenbasierte Methodik zu Modellierung der komplexen aerodynamischen Umströmung von Überwasserschiffen in der Großausführung mit beachtlich hoher Reynoldszahl entwickelt und angewendet. Eine Herausforderung dabei ist die variable Verteilung der Containerstapel an Deck und die daraus resultierende unterschiedliche Ausdehnung der Fluidfelder. Die vorgestellte Extrapolation der Druckfelder innerhalb der Bereiche der Containerstapel, um eine einheitliche Ausdehnung der Eingabefelder der Modellierung zu erreichen, hat sich dabei als sehr praktikabel erwiesen. Für die Auswertung der Druckfelder werden die extrapolierten Bereiche hingegen nicht benötigt.

Für die Bewertung der unterschiedlichen Modellierungsschritte und der Gesamtmodelle werden neben den prognostizierten Druckfeldern ebenfalls die auf Basis der Druckfelder bestimmten Kräfte in Längs- und Querrichtung ausgewertet und verglichen. Dabei korrelieren die Fehler der Kräfte nur bedingt mit denen der Druckfelder. Letztere sind dreidimensionale Felddaten und erstrecken sich über einen sehr viel größeren Bereich als der kraftrelevante Nahbereich des Überwasserschiffes. Die Auswertung der Kräfte basiert nur auf einem geringen Teil der Punkte des Metagitters in direkter Nähe zur Oberfläche der Geometrie. Da in diesem Bereich teils große Extremwerte des Druckes mit lokaler Ausdehnung auftreten, können größere Abweichungen des Druckfeldes nur weniger Metagitterpunkte bereits einen signifikanten Einfluss auf die Bestimmung der resultierenden Kräfte haben. Insbesondere die Rekonstruktion von Extremwerten ist dabei mittels der eingesetzten datenbasierten Methoden herausfordernd. Beim Vergleichen unterschiedlicher Modelle oder Hyperparameter zeigt sich daher häufig für die Fehler der Druckfelder eine klare Tendenz, während dies für die Fehler der Kräfte nicht der Fall ist. Dies ist unter anderem auf den oszillierenden Verlauf der Metriken, bedingt durch das stochastische Gradientenabstiegsverfahren, während des Trainingsprozesses zurückzuführen.

8 Zusammenfassung

In der vorliegenden Arbeit werden Surrogatmodelle zur Vorhersage der aerodynamischen Umströmung von Überwasserschiffen entwickelt. Neben Messungen im Windkanal werden umfangreiche numerische Simulationen für ein Containerfeederschiff beschrieben. Die Datenfelder der numerischen Simulationen dienen als Basis für die datenbasierte Surrogatmodellierung.

Im Einklang mit vergleichbaren Arbeiten zeigen die Windkanalversuche einen signifikanten Einfluss der Containerverteilung an Deck auf die aerodynamische Umströmung und somit auf die aerodynamischen Kräfte. Die Strömung ist geprägt von starker Ablösung an den Kanten der Schiffsaufbauten und der Containerladung.

Die Versuche im Windkanal dienen als Grundlage zur Validierung der eingesetzten numerischen Methoden. Der Vergleich der teilweise skalenauflösenden Turbulenzmodellierung mit der einfacheren RANS-basierten Turbulenzmodellierung zeigt die deutlichen Vorteile der hybriden, skalenauflösenden Turbulenzmodellierung. Die Analyse der Zweipunktkorrelationen für unterschiedliche Gitterauflösungen ergibt, dass auch für vergleichsweise grobe Gitterauflösungen eine genaue Bestimmung der Strömungsfelder möglich ist. Die großskaligen dominanten Wirbel innerhalb der Ablösegebiete werden ausreichend aufgelöst. Durch die relativ grobe räumliche Auflösung ist auch die zeitliche Auflösung vergleichsweise gering und der Aufwand der hybriden Turbulenzmodellierung im Vergleich zur RANS-Methode ist dadurch nur moderat größer. Auf Basis der vorgestellten Simulationsmethoden ist die genaue und präzise Vorhersage der Strömungsfelder und der aerodynamischen Kräfte möglich. Im Vergleich zu Arbeiten mit RANS-basierter Modellierung ist die Übereinstimmung mit den Messungen im Windkanal signifikant besser.

Die Druckfelder der Simulationen für unterschiedliche Systemparameter bilden die Grundlage der datenbasierten Surrogatmodellierung. Durch die Vorbereitung der Datenfelder im Bereich der Containerstapel durch Extrapolation der Druckfelder, wird die Modellierung der Felder mit ursprünglich unterschiedlicher räumlicher Ausdehnung vereinheitlicht. Die im Rahmen dieser Arbeit entwickelte Methodik ist robust und effizient für unterschiedliche Strömungsfelder anwendbar.

Die Dimensionsreduktion der Datenbasis ist der erste Schritt der Modellbildung. Dabei wird

der Umfang der Daten reduziert und die Daten werden mittels Koeffizienten bzw. reduzierten Variablen dargestellt. Für die Dimensionsreduktion werden die POD-Methode und die CAE-Methode verglichen. Durch die Nichtlinearität der CAE-Methode sind deutlich kompaktere Darstellungen der Daten möglich. Im zweiten Schritt der Modellbildung wird der funktionale Zusammenhang der Koeffizienten und der Systemparameter des Datensatzes modelliert. Dafür werden drei unterschiedliche Regressionsmethoden eingesetzt und analysiert: Polynomregression, Gaußprozess-Regression und NN-Regression. Für alle drei Regressionsmethoden lassen sich vergleichbare Surrogatmodelle bilden. Für beide Schritte der Modellierung wird der Einfluss verschiedener Hyperparameter auf die Modellbildung dargestellt. Die meisten Parameter haben dabei einen moderaten Einfluss auf die Modellerstellung. Der einflussreichste und wichtigste Hyperparameter ist die Auswahl der berücksichtigten POD-Moden bzw. die Anzahl der reduzierten Variablen. Durch diese Parameter wird der Grad der Dimensionsreduktion gesteuert.

In vergleichbaren Arbeiten werden meist nur die Fehler der rekonstruierten Druckfelder berücksichtigt. In der vorliegenden Arbeit hingegen werden die aus dem Druckfeld abgeleiteten Kräfte bestimmt und analysiert. Die Auswertung der Kräfte für die unterschiedlichen Varianten der Gesamtmodellierung zeigt eine sehr gute Übereinstimmung mit den Referenzdaten.

A Druckfelder Datensatz A

Für Datensatz A werden die mittels der unterschiedlichen Modellvarianten rekonstruierten Druckfelder in den Abbildungen A.1 - A.4 betrachtet. Für die Testdatensätze mit zwei unterschiedlichen Beladungskonfigurationen $h_C = 1$ und $h_C = 5$ werden jeweils die beiden Windwinkel $\beta = 5^\circ$ und $\beta = 45^\circ$ exemplarisch ausgewählt und dargestellt. Die Darstellung der Druckfelder erfolgt in dimensionsloser Form in der Längsebene mittschiffs. Die verwendeten Parameter der Modellvarianten sind in Tabelle A.1 zusammengefasst. Neben dem CFD-Referenzdruckfeld sind die durch die sieben unterschiedlichen Modellvarianten bestimmten Druckfelder abgebildet. Zusätzlich wird die Abweichung des jeweiligen Druckfeldes vom Referenzdruckfeld in der rechten Spalte der Abbildung vergleichend dargestellt.

Die Abweichungen der prognostizierten Druckfelder treten für alle betrachteten Modellvarianten an den gleichen räumlichen Stellen auf. Für die POD-basierten Modellvarianten sind die Abweichungen größer als für die CAE-basierten Modellvarianten.

Tabelle A.1: Übersicht der Modellparameter der sieben unterschiedlichen Modellvarianten für Datensatz A.

Modellvariante	Dimensionsreduktion	Regression der Koeffizienten
POD Poly.-Reg.	POD $n_R = 12$	$n_p = 6$
POD Gauß.-Reg.		RBF-Kernel
POD NN-Reg.		2 Schichten je 20 Knoten
CAE Poly.-Reg.	CAE $n_R = 5$	$n_p = 6$
CAE Gauß.-Reg.		RBF-Kernel
CAE NN-Reg.		3 Schichten je 36 Knoten
CAE komb.		kombiniertes Modell $n_p = 3$

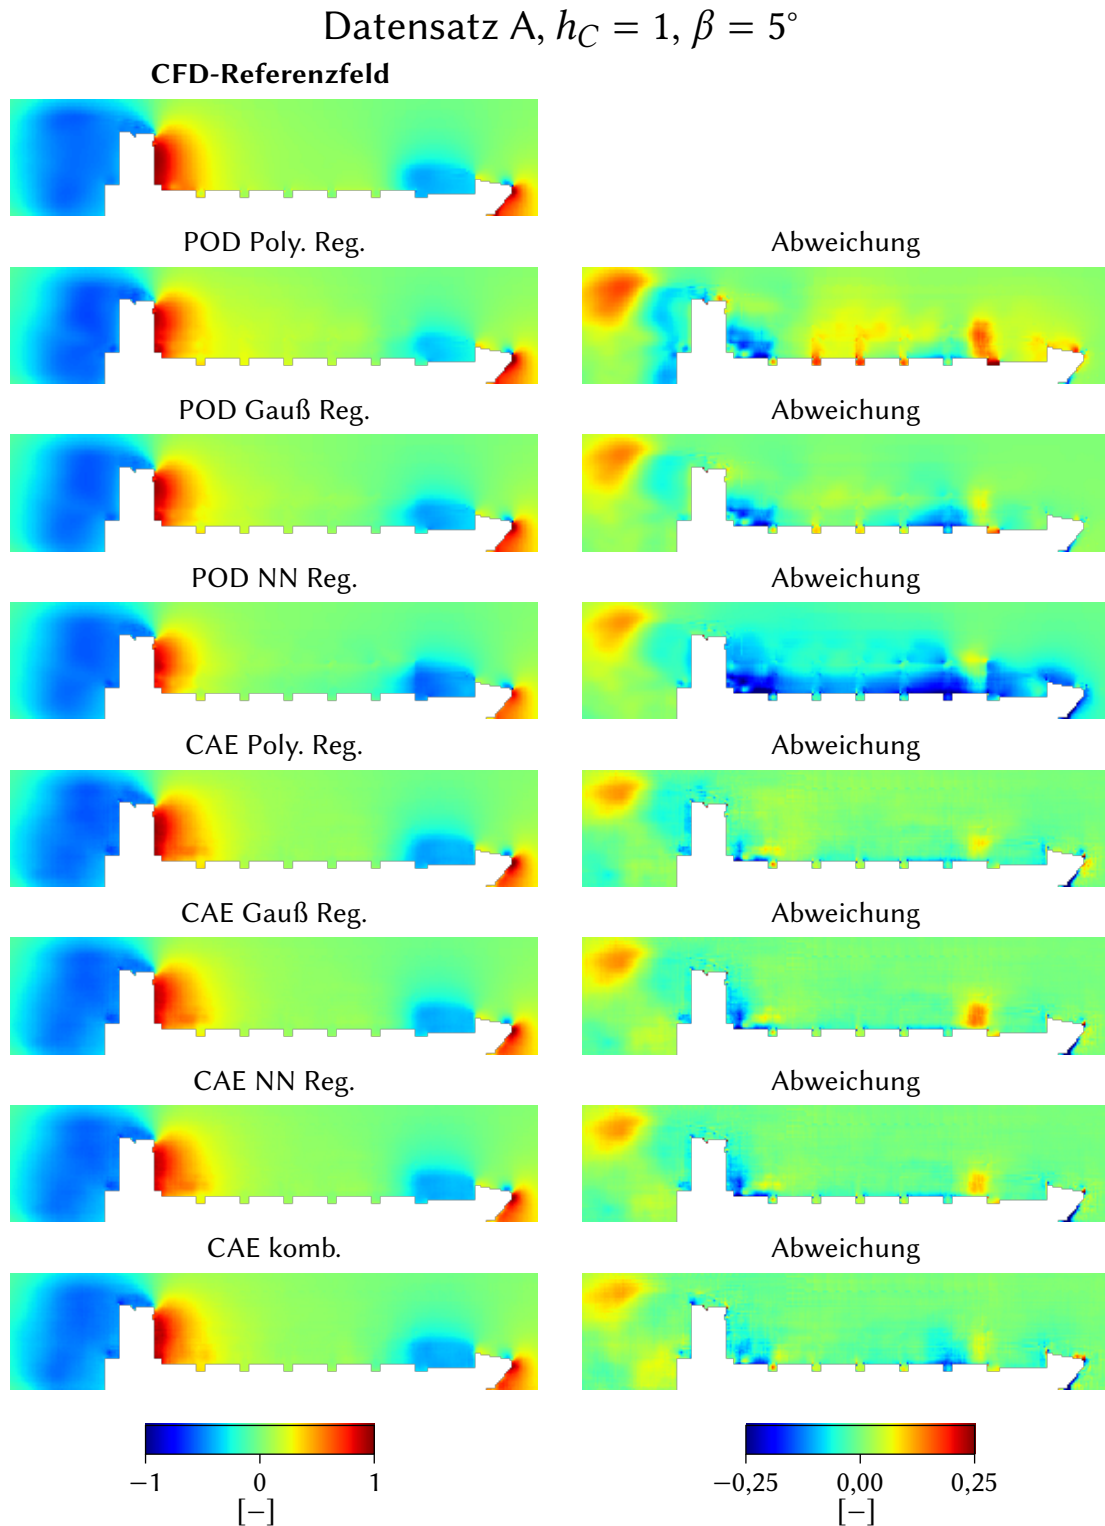


Abbildung A.1: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = 1$ und einen Windwinkel $\beta = 5^\circ$ für Datensatz A.

Datensatz A, $h_C = 1$, $\beta = 45^\circ$

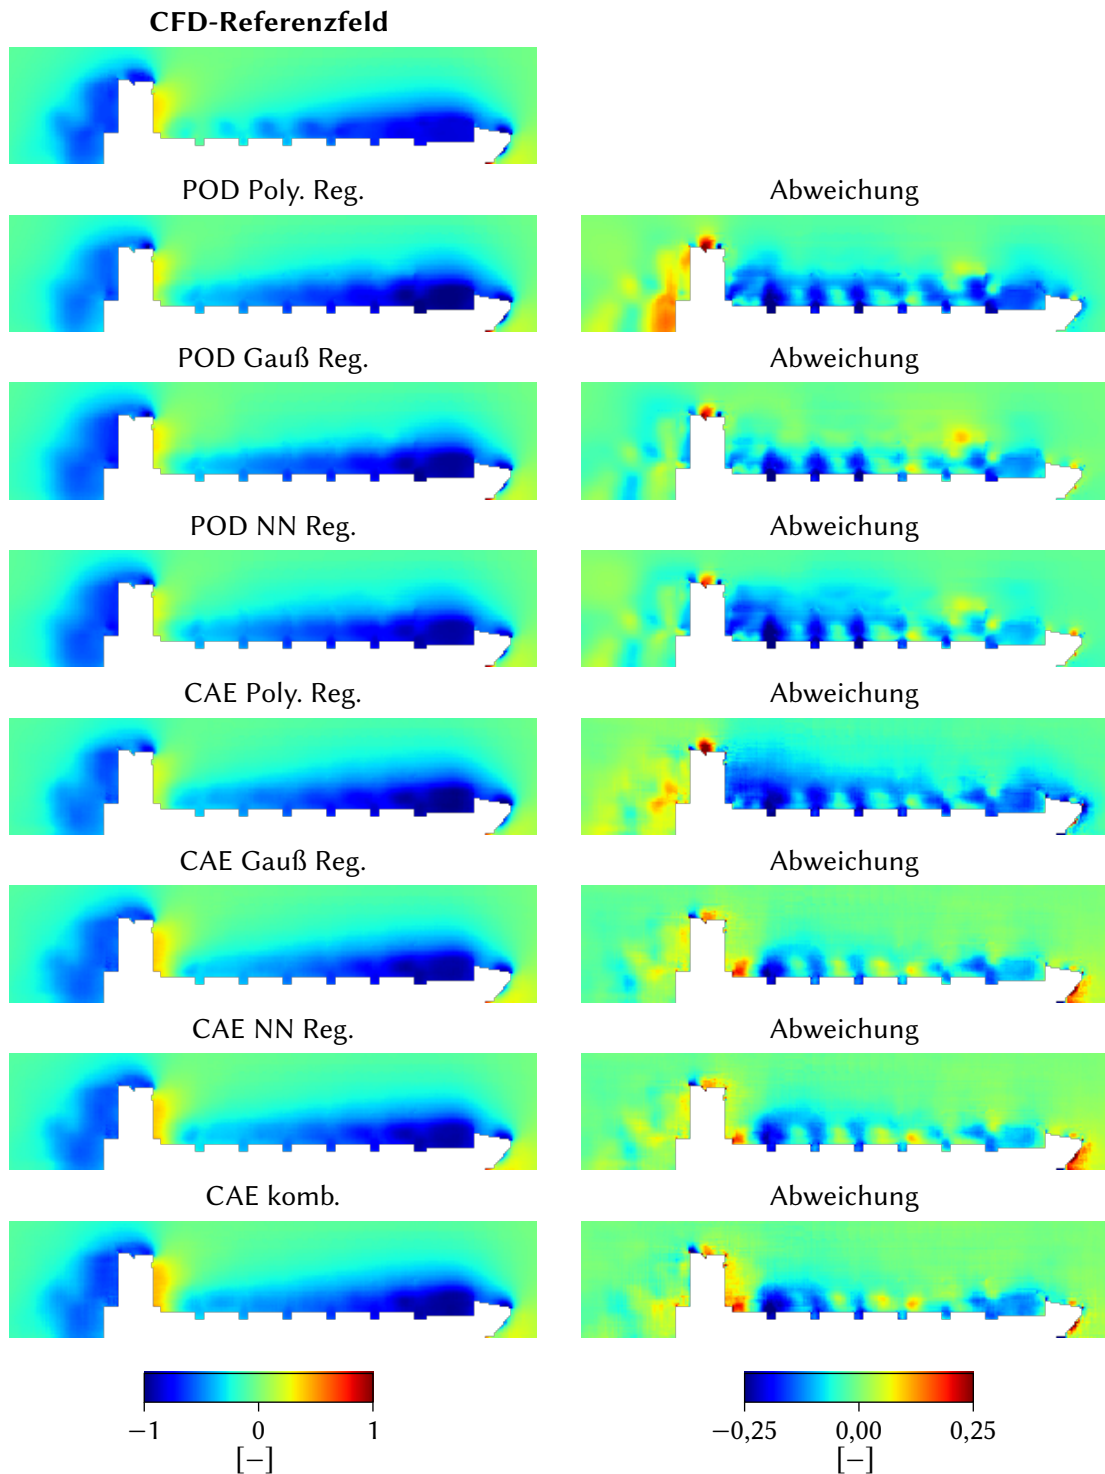


Abbildung A.2: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = 1$ und einen Windwinkel $\beta = 45^\circ$ für Datensatz A.

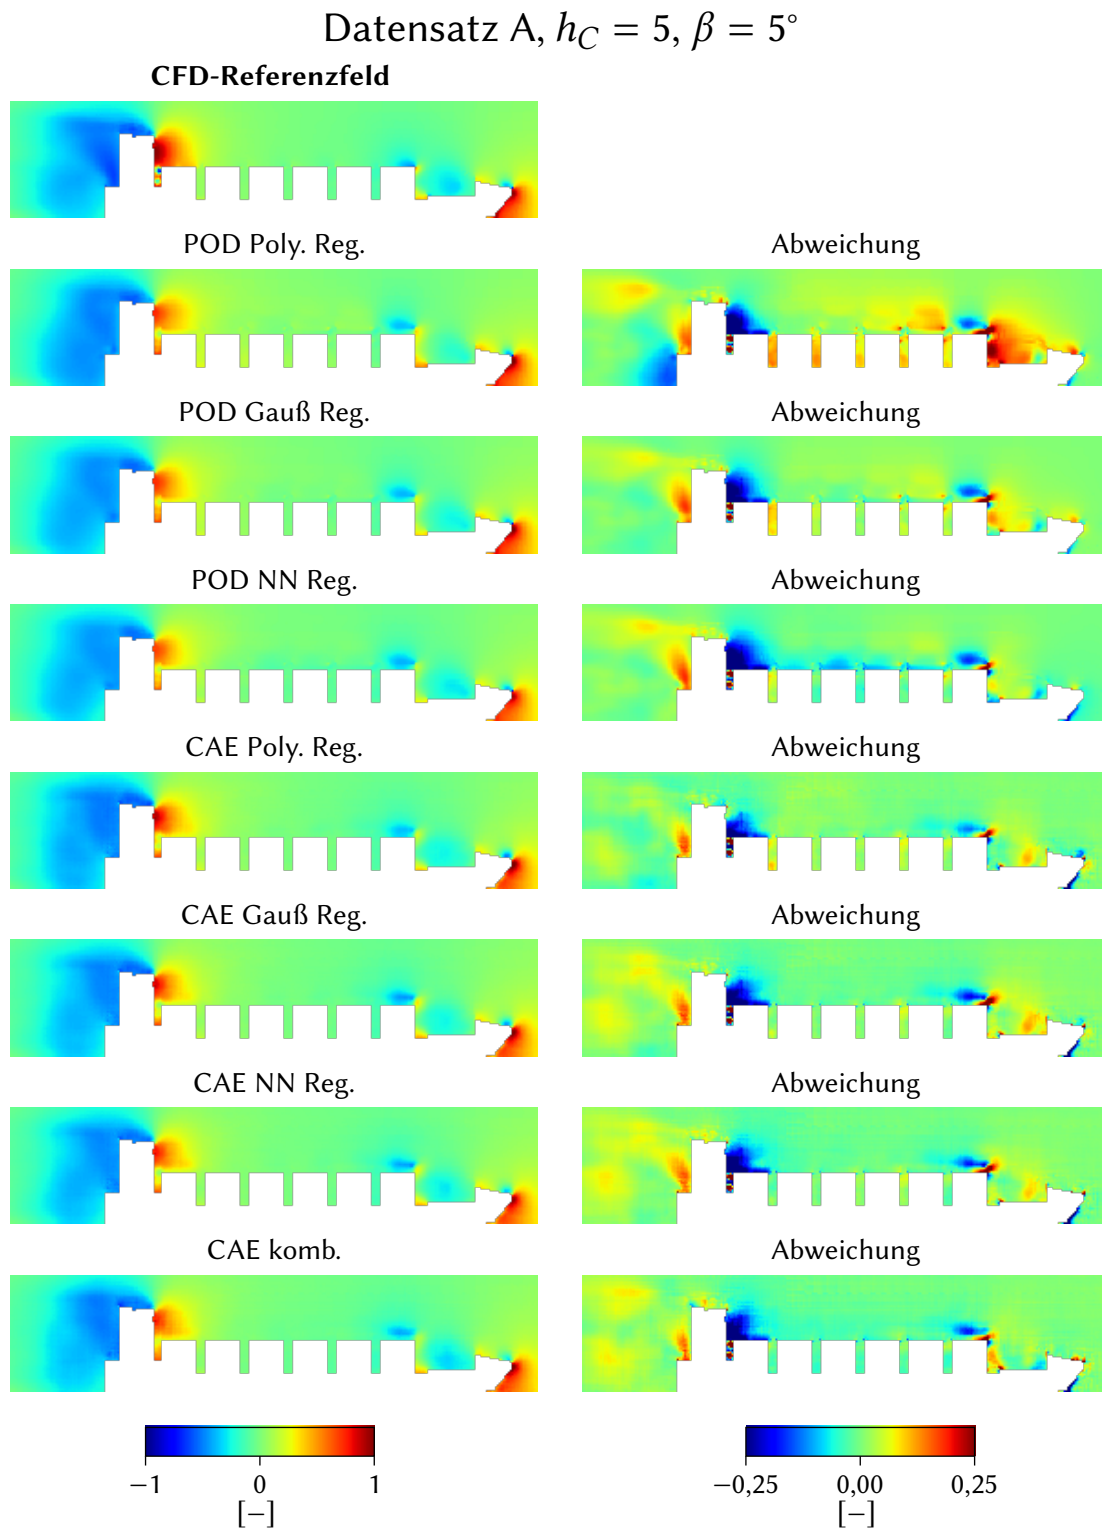


Abbildung A.3: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = 5$ und einen Windwinkel $\beta = 5^\circ$ für Datensatz A.

Datensatz A, $h_C = 5$, $\beta = 45^\circ$

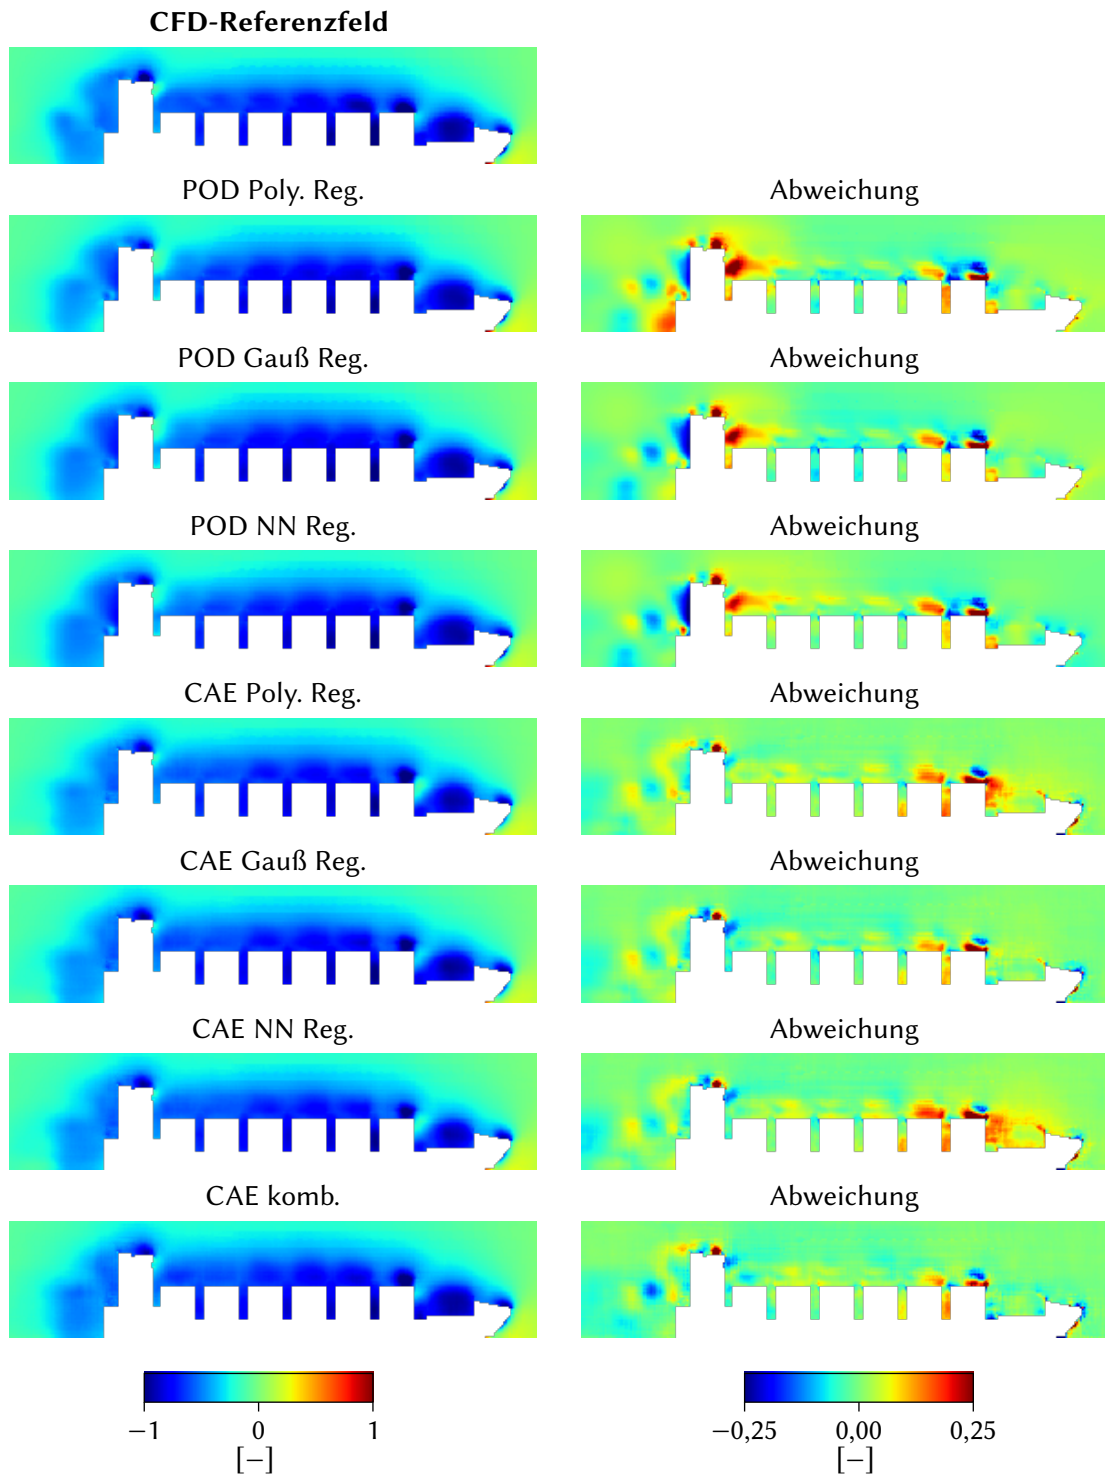


Abbildung A.4: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = 5$ und einen Windwinkel $\beta = 45^\circ$ für Datensatz A.

B Druckfelder Datensatz B

In den Abbildungen B.1 - B.6 erfolgt ein Überblick über die rekonstruierten dimensionslosen Druckfelder der Testdaten des Datensatzes B. Betrachtet und dargestellt sind jeweils drei unterschiedliche Beladungskonfigurationen $h_C = (0,2,5)$, $h_C = (5,2,1)$ und $h_C = (5,4,4)$ für zwei unterschiedliche Winkel $\beta = 0^\circ$ und $\beta = 50^\circ$. Die Darstellung des Druckes erfolgt in dimensionsloser Form in der Längsebene mittschiffs. Die verwendeten Parameter der Modellvarianten sind in Tabelle B.1 zusammengefasst. Neben dem CFD-Referenzdruckfeld sind die durch die sieben Modellvarianten prognostizierten Druckfelder abgebildet. In der rechten Spalte der Abbildung sind die Abweichungen der jeweiligen Modellvarianten vom CFD-Referenzfeld dargestellt.

Die größeren Abweichungen der Druckfelder treten für die POD-basierten Modellvarianten auf. Die Unterschiede zwischen den einzelnen Regressionsmethoden sind nur geringfügig, wobei die größten Abweichungen jeweils für die Modellvarianten mit Polynomregression auftreten.

Tabelle B.1: Übersicht der Modellparameter der sieben unterschiedlichen Modellvarianten für Datensatz B.

Modellvariante	Dimensionsreduktion	Regression der Koeffizienten
POD Poly.-Reg.	POD $n_R = 12$	$n_p = 4$
POD Gauß.-Reg.		RBF-Kernel
POD NN-Reg.		2 Schichten je 12 Knoten
CAE Poly.-Reg.	CAE $n_R = 5$	$n_p = 4$
CAE Gauß.-Reg.		RBF-Kernel
CAE NN-Reg.		2 Schichten je 36 Knoten
CAE komb.		kombiniertes Modell $n_p = 2$

Datensatz B, $h_C = (0,2,5)$, $\beta = 50^\circ$

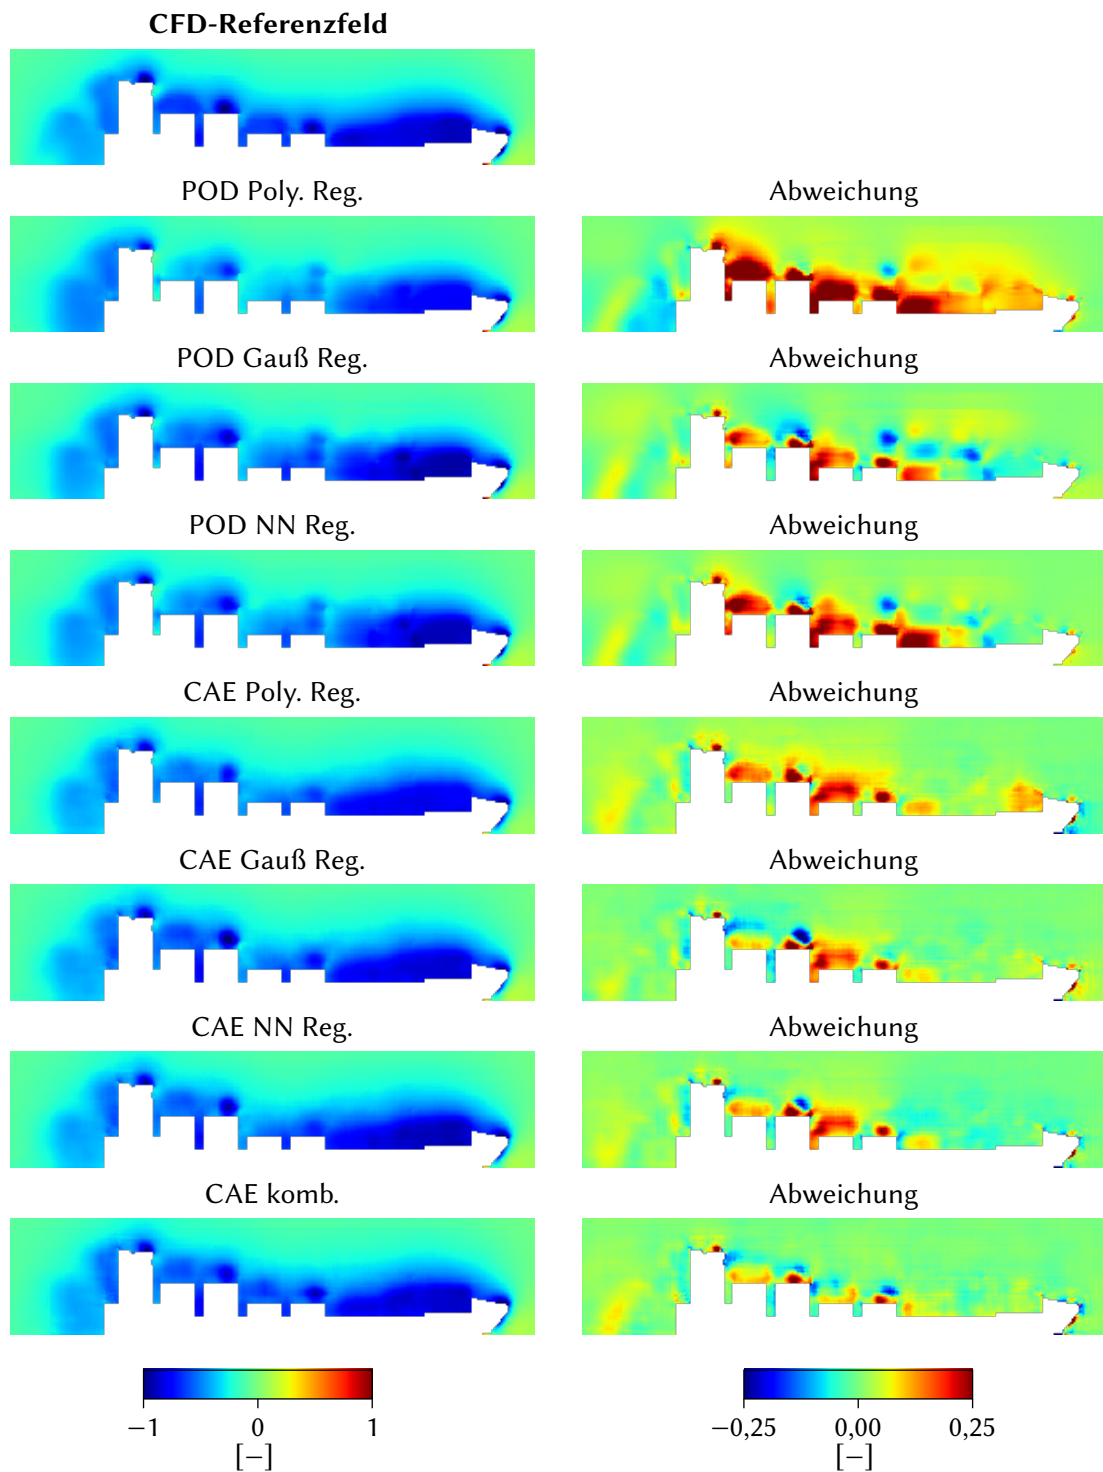


Abbildung B.2: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = (0,2,5)$ und einen Windwinkel $\beta = 50^\circ$ für Datensatz B.

Datensatz B, $h_C = (5,2,1)$, $\beta = 50^\circ$

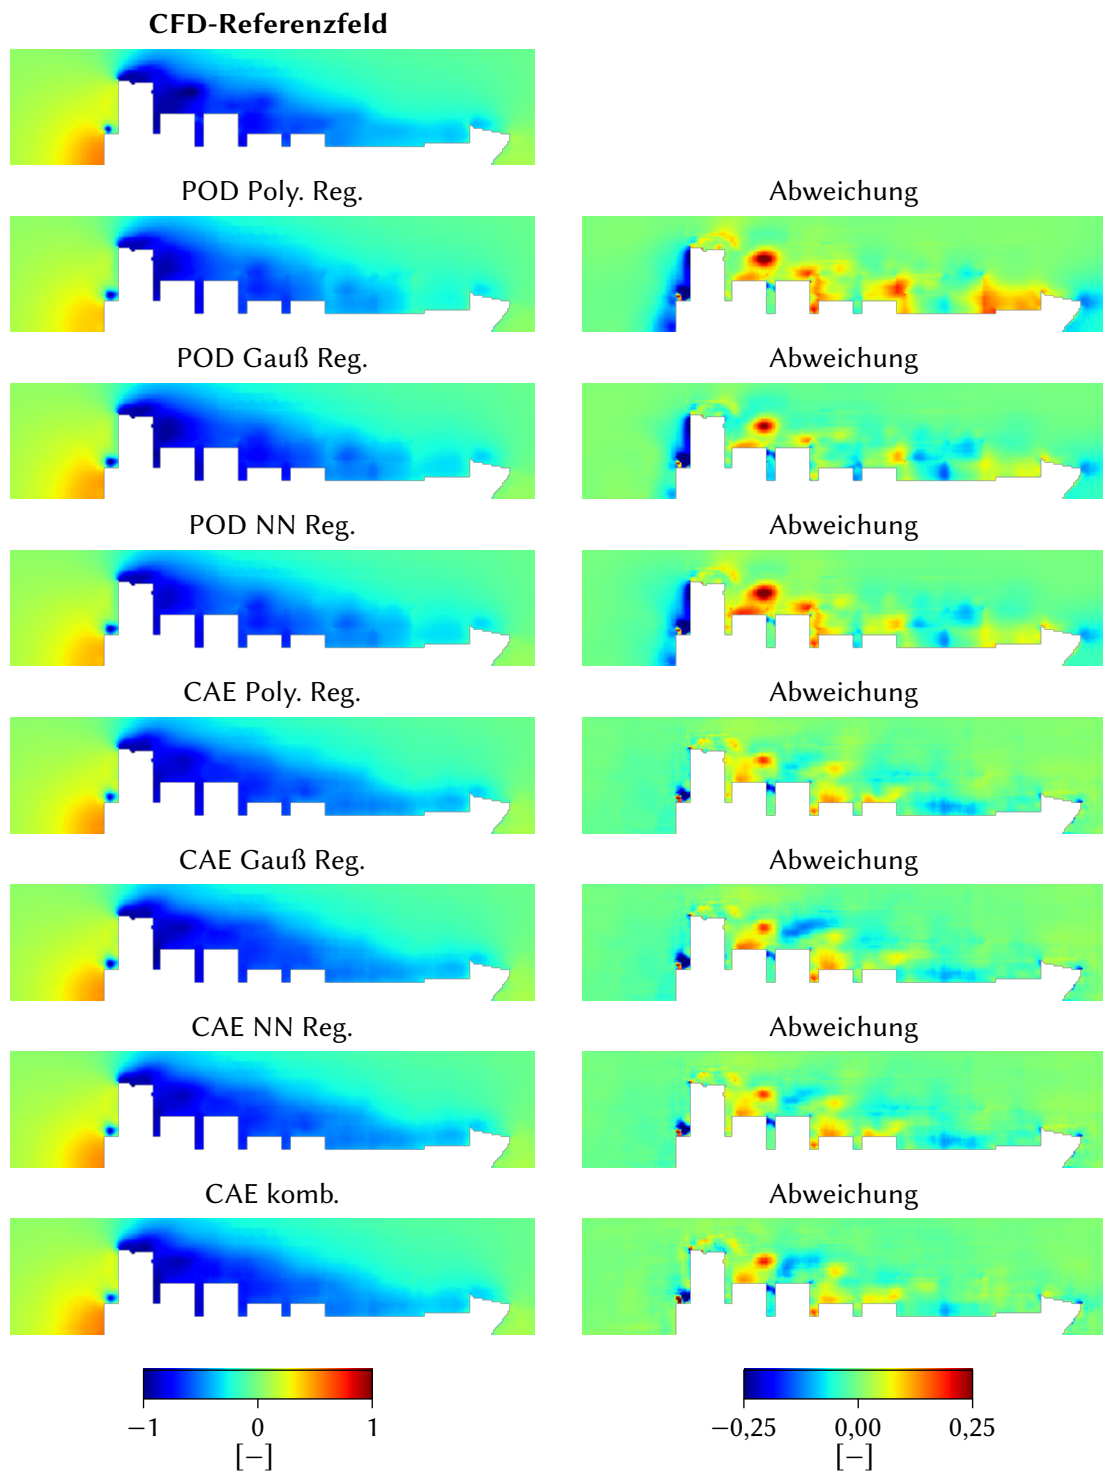


Abbildung B.4: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = (5,2,1)$ und einen Windwinkel $\beta = 50^\circ$ für Datensatz B.

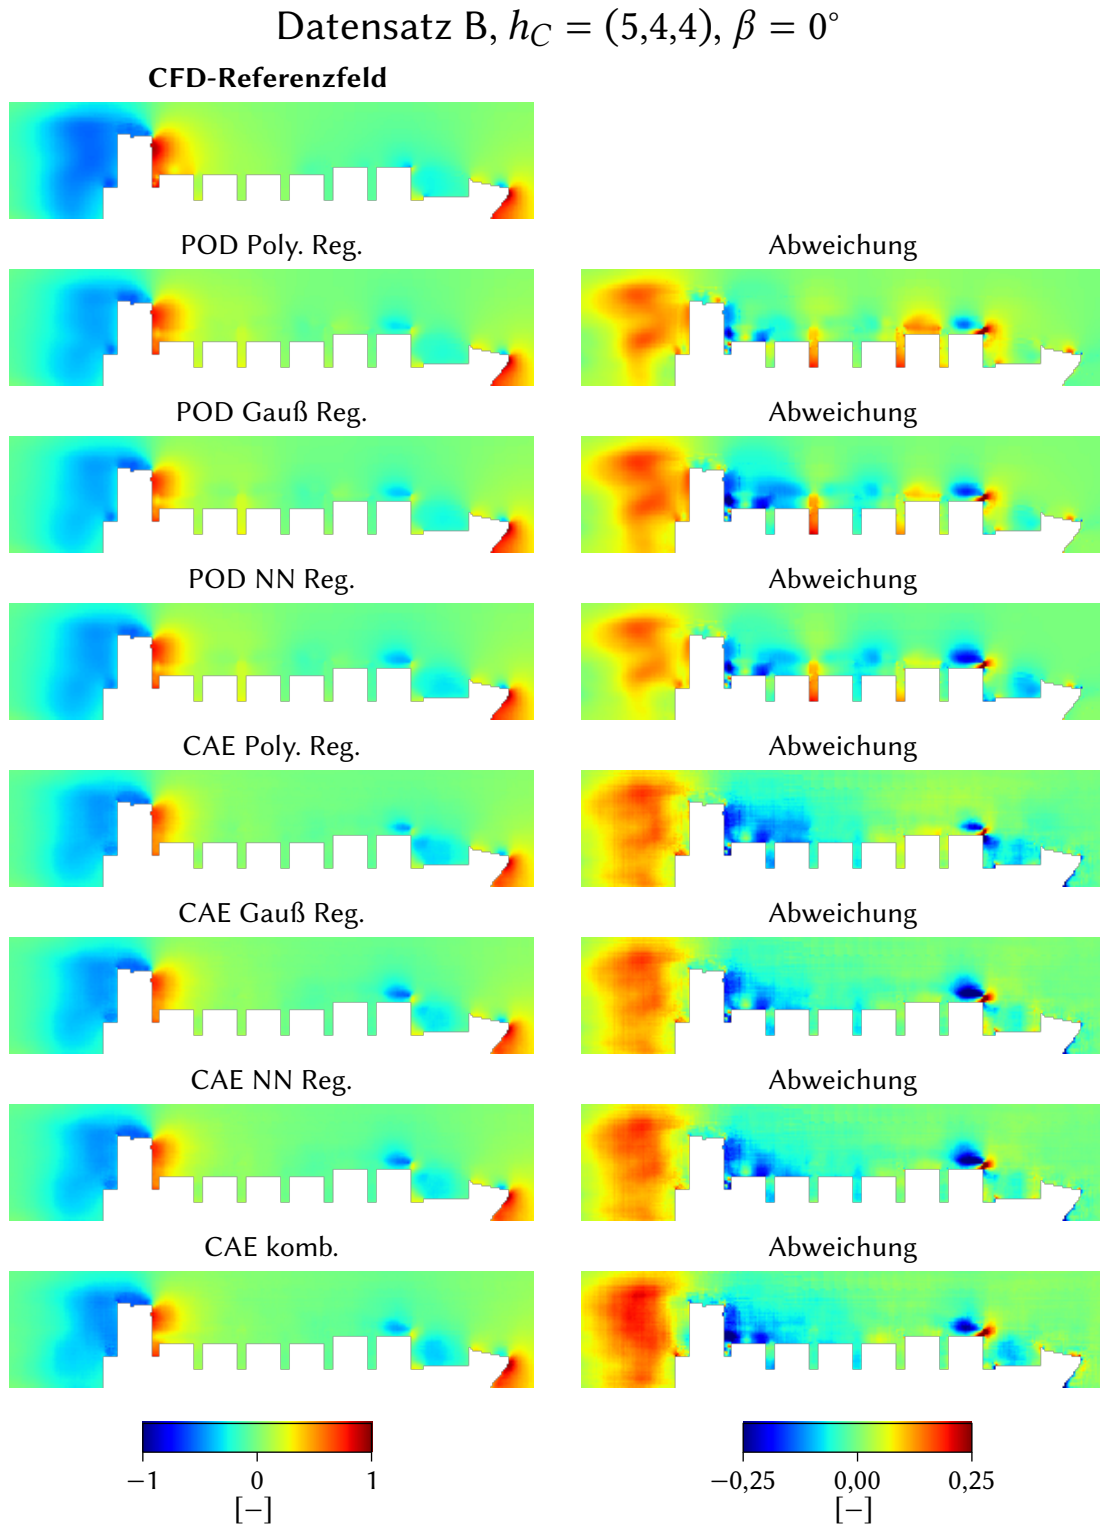


Abbildung B.5: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = (5,4,4)$ und einen Windwinkel $\beta = 0^\circ$ für Datensatz B.

Datensatz B, $h_C = (5,4,4)$, $\beta = 50^\circ$

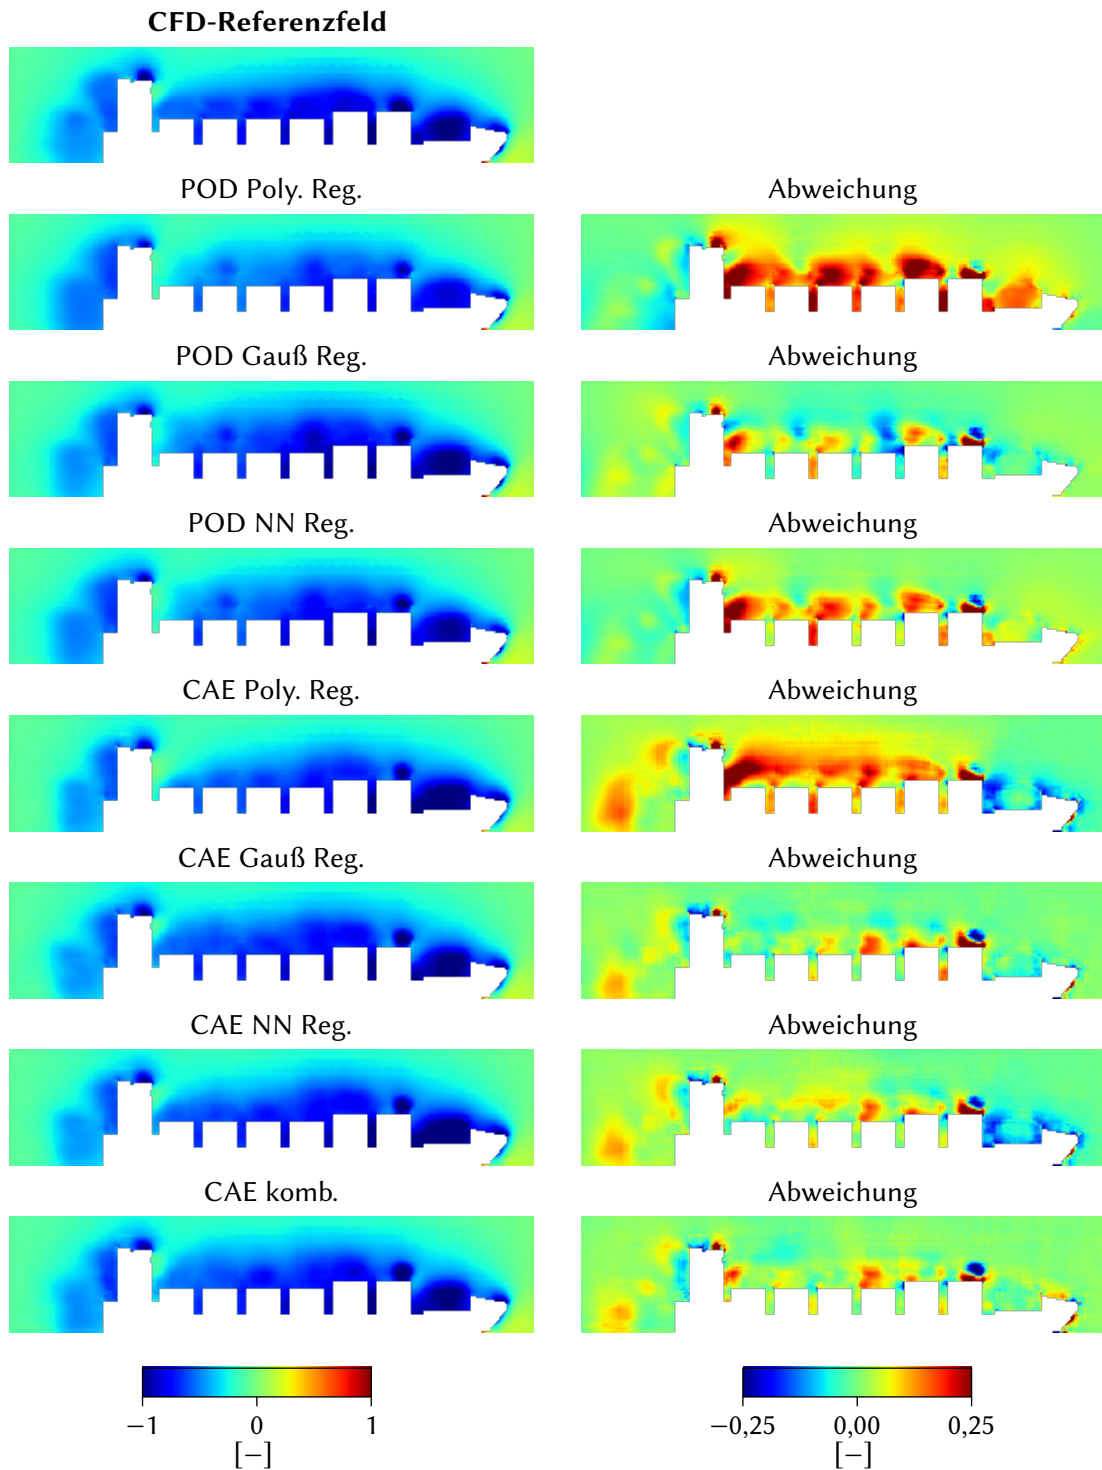


Abbildung B.6: Vergleich der dimensionslosen Druckfelder in Längsrichtung mittschiffs für einen Beladungsfall $h_C = (5,4,4)$ und einen Windwinkel $\beta = 50^\circ$ für Datensatz B.

Literaturverzeichnis

- C. C. Aggarwal. *Neural networks and deep learning: A textbook*. Springer, New York, 2019.
- L. Agostini. Exploration and prediction of fluid dynamical systems using auto-encoder technology. *Physics of Fluids*, 32(6):067103, 2020. doi: 10.1063/5.0012906.
- I. M. V. Andersen. Wind loads on post-panamax container ship. *Ocean Engineering*, 58:115–134, 2013. doi: 10.1016/j.oceaneng.2012.10.008.
- P. Baldi und K. Hornik. Neural networks and principal component analysis: Learning from examples without local minima. *Neural Networks*, 2(1):53–58, 1989. doi: 10.1016/0893-6080(89)90014-2.
- P. Benner, S. Gugercin, und K. Willcox. A survey of projection-based model reduction methods for parametric dynamical systems. *SIAM Review*, 57(4):483–531, 2015. doi: 10.1137/130932715.
- W. Blendermann. *Die Windkräfte am Schiff*, volume Nr. 467 of *Bericht / Institut für Schiffbau der Universität Hamburg*. Inst. für Schiffbau, Hamburg, 1986.
- W. Blendermann. *Wind loading of ships: Collected data from wind tunnel tests in uniform flow*, volume Nr. 574 of *Bericht / Institut für Schiffbau der Universität Hamburg*. Inst. für Schiffbau, Hamburg, 1996.
- W. Blendermann. *Messung der Windlast an zwei Containerschiffen in realem Ladezustand im Windkanal*, volume Nr. 586 of *Bericht / Institut für Schiffbau der Universität Hamburg*. Inst. für Schiffbau, Hamburg, 1997.
- S. L. Brunton und N. Kutz. *Data-driven science and engineering: Machine learning, dynamical systems, and control*. Cambridge University Press, Cambridge, 2019.
- S. L. Brunton, B. R. Noack, und P. Koumoutsakos. Machine learning for fluid mechanics. *Annual Review of Fluid Mechanics*, 52(1):477–508, 2020. doi: 10.1146/annurev-fluid-010719-060214.
- K. Champion, B. Lusch, J. N. Kutz, und S. L. Brunton. Data-driven discovery of coordinates and governing equations. *Proceedings of the National Academy of Sciences of the United States of America*, 116(45):22445–22451, 2019. doi: 10.1073/pnas.1906995116.

- D.-A. Clevert, T. Unterthiner, und S. Hochreiter. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs), 2015.
- B Colvert, M. Alsalman, und E. Kanso. Classifying vortex wakes using neural networks. *Bioinspiration & Biomimetics*, 13(2):025003, 2018. doi: 10.1088/1748-3190/aaa787.
- L. Davidson. Large Eddy Simulations: How to evaluate resolution. *International Journal of Heat and Fluid Flow*, 30(5):1016–1025, 2009.
- H. Eckelmann. *Einführung in die Strömungsmesstechnik*. Leitfäden der angewandten Mathematik und Mechanik. Teubner, Stuttgart, 1997.
- J. H. Ferziger und M. Perić. *Numerische Strömungsmechanik*. Springer, Berlin, 2008.
- R. G. J. Flay. A twisted flow wind tunnel for testing yacht sails. *Journal of Wind Engineering and Industrial Aerodynamics*, 63(1-3):171–182, 1996. doi: 10.1016/S0167-6105(96)00080-3.
- J. S. Forrest und I. Owen. An investigation of ship airwakes using Detached-Eddy Simulation. *Computers & Fluids*, 39(4):656–673, 2010. doi: 10.1016/j.compfluid.2009.11.002.
- J. S. Forrest, C. H. Kaaria, und I. Owen. Evaluating ship superstructure aerodynamics for maritime helicopter operations through CFD and flight simulation. *The Aeronautical Journal*, 120(1232):1578–1603, 2016. doi: 10.1017/aer.2016.76.
- J. Fröhlich und D. von Terzi. Hybrid LES/RANS methods for the simulation of turbulent flows. *Progress in Aerospace Sciences*, 44(5):349–377, 2008.
- K. Fukami, K. Hasegawa, T. Nakamura, M. Morimoto, und K. Fukagata. Model Order Reduction with Neural Networks: Application to Laminar and Turbulent Flows. *SN Computer Science*, 2(6), 2021. doi: 10.1007/s42979-021-00867-3.
- M. Ghalandari, A. Ziamolki, A. Mosavi, S. Shamshirband, K.-W. Chau, und S. Bornassi. Aeromechanical optimization of first row compressor test stand blades using a hybrid machine learning model of genetic algorithm, artificial neural networks and design of experiments. *Engineering Applications of Computational Fluid Mechanics*, 13(1):892–904, 2019. doi: 10.1080/19942060.2019.1649196.
- I. Goodfellow, Y. Bengio, und A. Courville. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- M. S. Gritskevich, A. V. Garbaruk, J. Schütze, und F. R. Menter. Development of DDES and IDDES Formulations for the $k-\omega$ Shear Stress Transport Model. *Flow, Turbulence and Combustion*, 88(3):431–449, 2012. doi: 10.1007/s10494-011-9378-4.

- M. R. Haddara und C. Guedes Soares. Wind loads on marine structures. *Marine Structures*, 12 (3):199–209, 1999. doi: 10.1016/S0951-8339(99)00023-4.
- K. Hasegawa, K. Fukami, T. Murata, und K. Fukagata. Machine-learning-based reduced-order modeling for unsteady flows around bluff bodies of various shapes. *Theoretical and Computational Fluid Dynamics*, 34(4):367–383, 2020. doi: 10.1007/s00162-020-00528-w.
- K. Hornik, M. Stinchcombe, und H. White. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5):359–366, 1989. doi: 10.1016/0893-6080(89)90020-8.
- W.-H. Hucho. *Aerodynamik der stumpfen Körper: Physikalische Grundlagen und Anwendungen in der Praxis*. Vieweg+Teubner Verlag, Wiesbaden, 2., vollständig überarbeitete und erweiterte auflage edition, 2012. doi: 10.1007/978-3-8348-8243-1.
- IMO. Fourth IMO GHG study 2020. Technical report, International Maritime Organization, 2021.
- H.P.A.H. Irwin. The design of spires for wind simulation. *Journal of Wind Engineering and Industrial Aerodynamics*, 7(3):361–366, 1981. ISSN 01676105. doi: 10.1016/0167-6105(81)90058-1.
- W. D. Janssen, B. Blocken, und H. J. van Wijhe. CFD simulations of wind loads on a container ship: Validation and impact of geometrical simplifications. *Journal of Wind Engineering and Industrial Aerodynamics*, 166:106–116, 2017. doi: 10.1016/j.jweia.2017.03.015.
- W.P Jones und B.E Launder. The prediction of laminarization with a two-equation model of turbulence. *International Journal of Heat and Mass Transfer*, 15(2):301–314, 1972. doi: 10.1016/0017-9310(72)90076-2.
- G. Karypsis und V. Kumar. *Unstructured Graph Partitioning and Sparse Matrix Ordering System, Version 2.0*. 1995.
- D. P. Kingma und J. Ba. Adam: A method for stochastic optimization. *CoRR*, abs/1412.6980, 2015.
- A. Kolmogorov. The Local Structure of Turbulence in Incompressible Viscous Fluid for Very Large Reynolds’ Numbers. *Doklady Akademiia Nauk SSSR*, (30):301–305, 1941.
- A. Koop, B. Rossin, und G. Vaz. Predicting Wind Loads on Typical Offshore Vessels Using CFD. In *Volume 5: Ocean Engineering; CFD and VIV*, pages 731–742. American Society of Mechanical Engineers, 2012. doi: 10.1115/OMAE2012-83449.

- B. P. Leonard. A stable and accurate convective modelling procedure based on quadratic upstream interpolation. *Computer Methods in Applied Mechanics and Engineering*, 19(1):59–98, 1979. doi: 10.1016/0045-7825(79)90034-3.
- A. Lozano-Durán und J. Jiménez. Effect of the computational domain on direct simulations of turbulent channels up to $Re_\tau = 4200$. *Physics of Fluids*, 26(1):011702, 2014. doi: 10.1063/1.4862918.
- J. L. Lumley. The structure of inhomogeneous turbulent flows. *Atmospheric Turbulence and Radio Wave Propagation*, pages 166–177, 1967.
- H. V. Ly und H. T. Tran. Modeling and control of physical processes using proper orthogonal decomposition. *Mathematical and Computer Modelling*, 33(1-3):223–236, 2001. doi: 10.1016/S0895-7177(00)00240-5.
- L. Mainini und K. Willcox. Surrogate modeling approach to support real-time structural assessment and decision making. *AIAA Journal*, 53(6):1612–1626, 2015. doi: 10.2514/1.J053464.
- R. Martinuzzi und C. Tropea. The Flow Around Surface-Mounted, Prismatic Obstacles Placed in a Fully Developed Channel Flow (Data Bank Contribution). *Journal of Fluids Engineering*, 115(1):85–92, 1993. doi: 10.1115/1.2910118.
- F. R. Menter. Two-equation eddy-viscosity turbulence models for engineering applications. *AIAA Journal*, 32(8):1598–1605, 1994. doi: 10.2514/3.12149.
- F. R. Menter, M. Kuntz, R. Langtry, Y. Nagano, M. J. Tummers, und K. Hanjalic. Ten years of industrial experience with the sst turbulence model, 4th.; internal symposium, turbulence, heat and mass transfer. In *4th.; Internal Symposium, Turbulence, heat and mass transfer*, volume 4, pages 625–632, New York, 2003. Begell House,.
- M. Milano und P. Koumoutsakos. Neural network modeling for near wall turbulent flow. *Journal of Computational Physics*, 182(1):1–26, 2002. doi: 10.1006/jcph.2002.7146.
- C. Mockett. *A Comprehensive Study of Detached Eddy Simulation*. Universitätsverlag der TU Berlin, 2009. ISBN 9783798321601.
- R. B. Mora. Experimental investigation of the flow on a simple frigate shape (SFS). *TheScientificWorldJournal*, 2014:818132, 2014. doi: 10.1155/2014/818132.
- T. Murata, K. Fukami, und K. Fukagata. Nonlinear mode decomposition with convolutional neural networks for fluid dynamics. *Journal of Fluid Mechanics*, 882, 2020. doi: 10.1017/jfm.2019.822.

- N. Omata und S. Shirayama. A novel method of low-dimensional representation for temporal behavior of flow fields using deep autoencoder. *AIP Advances*, 9(1):015006, 2019. doi: 10.1063/1.5067313.
- S. B. Pope. *Turbulent flows*. Cambridge University Press, Cambridge and New York, 2000.
- J. Prpić-Oršić, M. Valčić, und Z. Čarija. A Hybrid Wind Load Estimation Method for Container Ship Based on Computational Fluid Dynamics and Neural Networks. *Journal of Marine Science and Engineering*, 8(7):539, 2020. doi: 10.3390/jmse8070539.
- M. Raffel, C.E. Willert, S.T. Wereley, und J. Kompenhans. *Particle Image Velocimetry: A Practical Guide*. Experimental Fluid Mechanics. Springer International Publishing, Cham, second edition edition, 2007. ISBN 978-3-540-72308-0.
- C. E. Rasmussen und C. K. I. Williams. *Gaussian processes for machine learning*. MIT, Cambridge, 2006.
- O. Reynolds. IV. On the dynamical theory of incompressible viscous fluids and the determination of the criterion. *Philosophical Transactions of the Royal Society of London. (A.)*, 186: 123–164, 1895.
- A. Ricci, W. D. Janssen, H. J. van Wijhe, und B. Blocken. CFD simulation of wind forces on ships in ports: Case study for the Rotterdam Cruise Terminal. *Journal of Wind Engineering and Industrial Aerodynamics*, 205:104315, 2020. doi: 10.1016/j.jweia.2020.104315.
- D. E. Rumelhart, G. E. Hinton, und R. J. Williams. Learning representations by back-propagating errors. *Nature*, 323(6088):533–536, 1986. doi: 10.1038/323533a0.
- T. Rung. *Entwicklung anisotroper Wirbelzähigkeitsbeziehungen mit Hilfe von Projektionstechniken*. PhD thesis, Technische Universität Berlin, Berlin, 2000.
- T. Rung. *Vorlesungsmanuskript: Numerische Methoden der Thermofluidodynamik 2 (CFD2)*. Institut für Fluidodynamik und Schiffstheorie, Technische Universität Hamburg-Harburg, 2008.
- T. Rung, K. Wöckner, M. Manzke, J. Brunswig, C. Ulrich, und A. Stück. Challenges and perspectives for maritime CFD applications. *Jahrbuch der Schiffbautechnischen Gesellschaft*, (103):127–139, 2009.
- L. Sirovich. Turbulence and the dynamics of coherent structures. III. dynamics and scaling. *Quarterly of Applied Mathematics*, 45(3):583–590, 1987. doi: 10.1090/qam/910464.
- J. Smagorinsky. General circulation experiments with the primitive equations. *Monthly Weather Review*, 91(3):99–164, 1963.

- P. Spalart und S. Allmaras. A one-equation turbulence model for aerodynamic flows. In *30th Aerospace Sciences Meeting and Exhibit*. American Institute of Aeronautics and Astronautics, 1992. doi: 10.2514/6.1992-439.
- P. Spalart und C. Strelets. *Young-Person's Guide to Detached-Eddy Simulation Grids*. 2001.
- P. R. Spalart, W.-H. Jou, M. Strelets, und S. R. Allmaras. Comments on the feasibility of les for wings, and on a hybrid rans/les approach. 1997.
- P. R. Spalart, S. Deck, M. L. Shur, K. D. Squires, M. Kh. Strelets, und A. Travin. A New Version of Detached-eddy Simulation, Resistant to Ambiguous Grid Densities. *Theoretical and Computational Fluid Dynamics*, 20(3):181–195, 2006. doi: 10.1007/s00162-006-0015-0.
- R. Swischuk, L. Mainini, B. Peherstorfer, und K. Willcox. Projection-based model reduction: Formulations for physics-based machine learning. *Computers & Fluids*, 179:704–717, 2019. doi: 10.1016/j.compfluid.2018.07.021.
- K. Taira, S. L. Brunton, S. T. M. Dawson, C. W. Rowley, T. Colonius, B. J. McKeon, O. T. Schmidt, S. Gordeyev, V. Theofilis, und L. S. Ukeiley. Modal analysis of fluid flows: An overview. *AIAA Journal*, 55(12):4013–4041, 2017. doi: 10.2514/1.J056060.
- F. Tillig und J. W. Ringsberg. Design, operation and analysis of wind-assisted cargo ships. *Ocean Engineering*, 211:107603, 2020. doi: 10.1016/j.oceaneng.2020.107603.
- S. Walton, O. Hassan, und K. Morgan. Reduced order modelling for unsteady fluid flow using proper orthogonal decomposition and radial basis functions. *Applied Mathematical Modelling*, 37(20-21):8930–8945, 2013. doi: 10.1016/j.apm.2013.04.025.
- D. C. Wilcox. Reassessment of the scale-determining equation for advanced turbulence models. *AIAA Journal*, 26(11):1299–1310, 1988. doi: 10.2514/3.10041.
- A. D. Wnek und C. Guedes Soares. CFD assessment of the wind loads on an LNG carrier and floating platform models. *Ocean Engineering*, 97:30–36, 2015. doi: 10.1016/j.oceaneng.2015.01.004.