



Technische
Universität
Braunschweig

INSTITUT FÜR
mobile Maschinen
und Nutzfahrzeuge



Forschungsberichte

Kerstin Palm

**Einsatzindividuelles, intelligentes
Energiemanagement im hybriden Nutzfahrzeug**

Herausgeber:
Freundes- und Förderkreis des Instituts
für mobile Maschinen und Nutzfahrzeuge e.V.

Shaker Verlag

Einsatzindividuelles, intelligentes Energiemanagement im hybriden Nutzfahrzeug

Von der Fakultät für Maschinenbau
der Technischen Universität Carolo-Wilhelmina zu Braunschweig

zur Erlangung der Würde

einer Doktor-Ingenieurin (Dr.-Ing.)

genehmigte Dissertation

von:	Kerstin Palm, geb. Ritters
geboren in:	Lüneburg
eingereicht am:	26.06.2023
mündliche Prüfung am:	12.01.2024
Vorsitz:	Prof. Dr.-Ing. Roman Henze
Gutachter:	Prof. Dr. Ludger Frerichs Prof. Dr.-Ing. Markus Lienkamp

Forschungsberichte aus dem
Institut für mobile Maschinen und Nutzfahrzeuge

Kerstin Palm

**Einsatzindividuelles, intelligentes Energie-
management im hybriden Nutzfahrzeug**

Shaker Verlag
Düren 2024

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

Zugl.: Braunschweig, Techn. Univ., Diss., 2024

Copyright Shaker Verlag 2024

Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder vollständigen Wiedergabe, der Speicherung in Datenverarbeitungsanlagen und der Übersetzung, vorbehalten.

Printed in Germany.

ISBN 978-3-8440-9400-8

ISSN 2196-7369

Shaker Verlag GmbH • Am Langen Graben 15a • 52353 Düren

Telefon: 02421 / 99 0 11 - 0 • Telefax: 02421 / 99 0 11 - 9

Internet: www.shaker.de • E-Mail: info@shaker.de

Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftliche Mitarbeiterin am Institut für mobile Maschinen und Nutzfahrzeuge der Technischen Universität Braunschweig.

Besonders bedanken möchte ich mich bei meinem Doktorvater Herrn Prof. Dr. Ludger Frerichs, der durch meine Einstellung am Institut, die fortwährende Unterstützung während der Institutszeit und zahlreiche Diskussionen zum Gelingen der Arbeit beigetragen hat. Durch die Möglichkeit, verschiedene Aufgaben im Institut zu übernehmen, hat er auch maßgeblich zu meiner persönlichen Weiterentwicklung beigetragen, wofür ich sehr dankbar bin. Herrn Prof. Dr.-Ing. Markus Lienkamp danke ich für die Übernahme des Koreferats und Prof. Dr.-Ing. Roman Henze für die Übernahme des Vorsitzes der Prüfungskommission.

Bei der SAF-HOLLAND GmbH, insbesondere bei Herrn Olaf Drewes, bedanke ich mich für die gute Zusammenarbeit im gemeinsamen Projekt sowie die Bereitstellung der technischen Daten und Messdaten der Fahrzeuge für meine Dissertation. Ohne diese Grundlagen wären die Untersuchungen in dieser Arbeit nicht möglich gewesen.

Die Zeit am Institut war für mich eine ganz besondere, die ich auf keinen Fall missen möchte. Das liegt in erster Linie an dem einzigartigen Kollegium, welches mich in den gut sechs Jahren dort begleitet hat. Mein Dank gilt daher allen aktuellen und ehemaligen Mitarbeitenden des Instituts, mit denen ich mich austauschen, diskutieren und auch sehr viel lachen konnte. Einige Sprüche werden mir noch lange im Ohr bleiben und mich stets an unsere gemeinsame Zeit erinnern.

Mein größter Dank gilt meiner Familie. Meine Eltern und mein Bruder haben mich schon in jungen Jahren geprägt und mein Interesse an der Technik geweckt und gefördert. Im Studium und während der Zeit am Institut war ich in der Heimat jederzeit Willkommen und habe diese Möglichkeit auch sehr gern genutzt, um den Uni-Alltag für ein paar Tage zu vergessen. Mein Mann Sebastian hat mich während der Erstellung der Arbeit motiviert, mich aber auch zu nötigen Pausen ermutigt. Er hat sich meinen Frust und meine Freude angehört und war mir so stets eine große Hilfe. Dafür danke ich ihm von ganzem Herzen. Unsere Tochter Ella, die zum Zeitpunkt der Finalisierung der Arbeit gerade unterwegs war, hat mir die letzte Motivation für die Fertigstellung geliefert und bereichert nun unser Leben. Ich freue mich sehr, nach dem Abschluss der Promotion nun mehr Zeit für meine kleine Familie zu haben und blicke voller Vorfreude in unsere gemeinsame Zukunft.

Kurzfassung

Hybridfahrzeuge können insbesondere im Schwerlastverkehr dazu beitragen, die seitens der EU vorgegebenen Ziele zur CO₂-Flottenreduktion zu erreichen. Aufgrund des Kompromisses zwischen Emissionsreduktion bei weiterhin hoher Reichweite ist eine große Kundenakzeptanz solcher Fahrzeuge zu erwarten. Um das Potential der Hybridantriebe möglichst weit ausnutzen zu können, sind geeignete, intelligente Energiemanagementstrategien erforderlich. Heute werden hierfür meist regelbasierte oder lokal optimierende Verfahren verwendet. In der Wissenschaft gibt es jedoch auch erste Ansätze, die auf Maschinellen Lernverfahren beruhen. Solche Lernverfahren zeigen in anderen Anwendungen bereits hervorragende Ergebnisse, sodass ihr Potential auch für das Energiemanagement im Hybridfahrzeug untersucht werden sollte. Neben der Wahl des Algorithmus und seiner Parametrierung haben die verwendeten Trainingsdaten einen wesentlichen Einfluss auf die erlernten Strategien. In den bisher veröffentlichten Ansätzen werden einzelne aufgezeichnete Messfahrten, deren Repräsentativität zu hinterfragen ist, oder standardisierte Fahrprofile verwendet, die wiederum sehr allgemein gehalten sind und vom tatsächlichen Fahrzeugeinsatz abweichen können. Methoden zur Erzeugung einsatzindividueller, synthetischer Fahrprofile sind vorhanden, wurden bisher aber nicht als Trainingsdaten verwendet.

In der vorliegenden Arbeit wird deshalb untersucht, ob einsatzindividuelle, synthetische Fahrprofile in Simulationsmodellen für das Training solcher Maschineller Lernverfahren zum Energiemanagement geeignet sind und welche Vorteile sich gegenüber einem Training mit standardisierten Profilen ergeben. Als Beispielanwendung wird ein hybrider Kühltatzug betrachtet, der aus einer konventionellen Zugmaschine und einem elektrifizierten Kühltatzugauflieger besteht. Es werden zwei Varianten hinsichtlich der vorhandenen Ladeinfrastruktur betrachtet. Aus einer Literaturrecherche heraus wird der TD3-Algorithmus als Lernverfahren gewählt. Für die Erzeugung der einsatzindividuellen synthetischen Fahrprofile aus einer vorliegenden Messdatenbasis wird eine bestehende Methode adaptiert. Das Training erfolgt einerseits mit den einsatzindividuellen und andererseits mit standardisierten Profilen. Als weitere Varianten werden mittels der Dynamischen Programmierung global optimierte Lösungen sowie daraus abgeleitete regelbasierte Steuerstrategien betrachtet. Außerdem wird zur Abschätzung des Kraftstoffesparpotentials ein konventionelles Fahrzeug simuliert. Die verschiedenen Steuerstrategien werden hinsichtlich ihres Gesamtkraftstoffverbrauchs und der Betriebskosten verglichen.

Es zeigt sich, dass die einsatzindividuell trainierten Reinforcement Learning-Agenten zum Energiemanagement sowohl hinsichtlich des Kraftstoffverbrauchs wie auch der Betriebskosten deutlich bessere Ergebnisse liefern als die standardisiert trainierten. Von der optimierten Lösung weichen die einsatzindividuellen Agenten um etwa 2 % ab. Gegenüber der konventionellen Fahrt können ohne Ladeinfrastruktur etwa 6 % Kraftstoff eingespart werden, mit Infrastruktur durchschnittlich 13 %. Die regelbasierten Strategien liefern noch bessere Ergebnisse, sie sind jedoch schlechter auf andere Streckenlängen und elektrische Systeme übertragbar.

Abstract

Hybrid vehicles can contribute to achieve the EU's CO₂ fleet reduction targets, especially in heavy-duty transport. Due to the trade-off between emission reduction and maintaining a high range, a high level of customer acceptance is to be expected. In order to exploit the potential of hybrid drives as much as possible, suitable, intelligent energy management strategies are required. Today, rule-based or locally optimising methods are mostly used for this purpose. In science, however, there are also initial approaches based on machine learning methods. Such learning methods already show excellent results in other applications, so that their potential should also be investigated for energy management in hybrid vehicles. In addition to the choice of algorithm and its parameterisation, the training data used has a significant influence on the strategies learned. In the approaches published so far, individual recorded test drives, the representativeness of which must be questioned, or standardised driving profiles are used, which in turn are very general and can deviate from actual vehicle use. Methods for generating mission-specific, synthetic driving profiles are available, but have not yet been used as training data.

This thesis therefore investigates whether mission-specific, synthetic driving profiles in simulation models are suitable for training such machine learning methods for energy management and which advantages arise compared to training with standardised profiles. As example application, a hybrid refrigerated truck-trailer combination consisting of a conventional truck and an electrified refrigerated semitrailer is considered. Two variants are examined with regard to the existing charging infrastructure. Based on a literature research, the TD3 algorithm is chosen as the learning method. An existing method is adapted for the generation of individual synthetic driving profiles from an available measurement database. The training is carried out on the one hand with the individual profiles and on the other hand with standardised profiles. As further variants, by dynamic programming globally optimised solutions and rule-based control strategies derived from them are considered. In addition, a conventional vehicle is simulated to estimate the fuel saving potential. The different control strategies are compared with regard to their overall fuel consumption and operating costs.

It can be seen that the mission-specific trained reinforcement learning agents for energy management deliver significantly better results than the standardised trained ones, both in terms of fuel consumption and operating costs. The mission-specific agents deviate from the optimised solution by about 2 %. Compared to conventional driving, fuel savings of about 6 % can be achieved without charging infrastructure, and an average of 13 % with infrastructure. The rule-based strategies deliver even better results, but they are less transferable to other route lengths and electric systems.

Inhaltsverzeichnis

Formelzeichen	XI
Abkürzungen	XV
1 Einleitung	1
2 Grundlagen und Stand der Technik	4
2.1 Hybride Fahrzeugantriebe	4
2.1.1 Definition und Einteilung hybrider Fahrzeugantriebe	4
2.1.2 Hybrid angetriebene Lkw und elektrifizierte Trailer	7
2.2 Synthetische Fahrprofile	9
2.2.1 Standardisierte Zyklen	10
2.2.2 Methoden zur Erzeugung einsatzindividueller Zyklen	14
2.2.3 Methode von Kattenberg	18
2.3 Optimierungsverfahren für Steuerungs- und Regelungsprobleme	21
2.3.1 Definition und Bellman'sches Optimalitätsprinzip	21
2.3.2 Dynamische Programmierung	23
2.3.3 Maschinelles Lernen	24
2.4 Energiemanagement in hybriden Fahrzeugen	32
2.4.1 Regelbasierte Strategien	33
2.4.2 Optimierende Strategien	34
2.4.3 Strategien basierend auf Maschinellern Lernen	36
2.4.4 Trainingsdaten der Reinforcement Learning-Ansätze	40
3 Zielsetzung der Arbeit	42
4 Modelle und Daten	47
4.1 Betrachtetes Fahrzeug	47
4.2 Simulationsmodelle	49
4.3 Messdatenbasis	52
5 Einsatzindividuelle Fahrprofile und Energiemanagementstrategien	54
5.1 Repräsentative, einsatzindividuelle Fahrprofile	54
5.1.1 Auswahl und Aufbereitung von Validierungszyklen	54
5.1.2 Erweiterung der Methode von Kattenberg	55
5.1.3 Erzeugung von Informationen zum Fahrzeugeinsatz	59
5.1.4 Erzeugte Einsatzprofile	63

5.2	Energiemanagement mittels Reinforcement Learning	64
5.2.1	Wahl des Algorithmus	65
5.2.2	Bestimmung der Hyperparameter	67
5.2.3	Festlegung von Beobachtungen und Belohnung	70
5.2.4	Restriktionen	72
5.2.5	Training	73
5.3	Dynamische Programmierung als Benchmark	75
5.3.1	Aktionsraum, Zustandsraum und Kostenfunktion	75
5.3.2	Schrittweitenbestimmung	77
5.4	Entwicklung regelbasierter Betriebsstrategien	79
5.4.1	Ohne Ladeinfrastruktur	80
5.4.2	Mit Ladeinfrastruktur	81
6	Simulationsergebnisse und Diskussion	83
6.1	Evaluation des Reinforcement Learning-Ansatzes	83
6.1.1	Lernverhalten	84
6.1.2	Auswahl von Agenten	85
6.1.3	Ergebnisse für Trainingsdaten	88
6.2	Bewertungsmethode	94
6.3	Ergebnisse der Validierungsfahrten	96
6.3.1	Ohne Ladeinfrastruktur	96
6.3.2	Mit Ladeinfrastruktur	103
6.4	Übertragbarkeit auf Varianten	109
6.4.1	Variation der Beladung	109
6.4.2	Variation der Streckenlänge	112
6.4.3	Variation des elektrischen Systems	113
7	Fazit und praktischer Nutzen	119
8	Zusammenfassung und Ausblick	123
	Quellenverzeichnis	125
	Anhang	i

Formelzeichen

Zeichen	Einheit	Bedeutung
a	m/s^2	Beschleunigung
a	-	Aktivität eines Neurons
a	-	Parameter der Gamma-Funktion
a_t	div.	Vom Agenten gewählte Aktion zum Zeitpunkt t
A	div.	Aktionsraum
b	-	Parameter der Gamma-Dichtefunktion
b_{ij}	-	Bias-Wert des Neurons Nr. j in der Schicht Nr. i in Neuronalen Netzen
B_{KA}	-	Betriebsweise des Kühlaggregats (elektrisch, dieselmotorisch)
C_t	div.	Kostenfunktion zur Bewertung einer Aktion
E	-	Erwartungswertoperator
$E_{Bat,max}$	kWh	Maximale Batteriekapazität
E_{ext}	kWh	Energiemenge, die der Batterie durch externes Laden zugefügt wurde
$g(z)$	-	Aktivierungsfunktion in einem Neuronalen Netz in Abhängigkeit vom Zwischenwert z
$h(a)$	-	Ausgabefunktion in einem Neuronalen Netz in Abhängigkeit von der Aktivität a des Neurons
$J(u)$	div.	Kostenfunktion in Abhängigkeit der Stellgröße u
k_{Diesel}	€/l	Kosten für Dieselkraftstoff
k_{el}	€/kWh	Kosten für elektrische Energie
k_{KA}	s/l	Gewichtungsfaktor für den Kraftstoffverbrauch des Kühlaggregats
$k_{personal}$	€/h	Kosten für Personal
k_{SOC}	-	Gewichtungsfaktor für die Abweichung des aktuellen SOC vom Referenz-SOC

Zeichen	Einheit	Bedeutung
k_{ZM}	s/l	Gewichtungsfaktor für den Kraftstoffverbrauch der Zugmaschine
K_{DP}	l	Kostenfunktion in der Dynamischen Programmierung
K_{ges}	€	Kostenfunktion zur Bewertung der Energiemanagementstrategien
$\dot{m}_{\text{äq,Bat}}(t)$	kg/s	Äquivalenter Kraftstoffmassenstrom der aktuellen Batterieleistung zum Zeitpunkt t
$\dot{m}_{\text{Kraftstoff}}(t)$	kg/s	Kraftstoffmassenstrom zum Zeitpunkt t
$M_{\text{Dauer}}(n)$	Nm	Dauermoment der E-Maschine in Abhängigkeit der Drehzahl n
$M_{EM,Ist}$	Nm	Istmoment der E-Maschine
$M_{EM,Soll}$	Nm	Sollmoment der E-Maschine
M_{Ist}	Nm	Istmoment
M_{Soll}	Nm	Sollmoment
n	1/s	Drehzahl
p	- ; %	Fahrbahnsteigung
$P_{a_t, s_t \rightarrow s_{t+1}}$	-	Wahrscheinlichkeit, dass bei Ausführen der Aktion a_t ausgehend vom Zustand s_t tatsächlich der Folgezustand s_{t+1} erreicht wird
$P_{max,alt}$	kW	Maximale Leistung der standardmäßig betrachteten E-Maschine
$P_{max,neu}$	kW	Maximale Leistung einer neu betrachteten E-Maschine
$Q(s, a)$	-	Aktionswert, Funktion zur Bewertung der Wahl einer Aktion a im Zustand s
r	-	Belohnung, Reward
s	m	Strecke, Streckenpunkt
s_{max}	m	Gesamtstreckenlänge
s_t	div.	Zustand eines Systems zum Zeitpunkt t
\mathbf{S}	div.	Zustandsraum
SOC	- ; %	State of Charge, Ladezustand der Batterie

Zeichen	Einheit	Bedeutung
SOC_{end}	- ; %	Ladezustand der Batterie am Ende der Fahrt
SOC_{ref}	- ; %	Referenzwert für den Ladezustand der Batterie
t	s	Zeitpunkt
$t_{Event,0}$	s	Stillstandszeit
$t_{Event,0,max}$	s	Maximale Stillstandszeit der Fahrprofils
t_{Fahrt}	s	Fahrzeit (ohne Stillstand)
t_{ges}	s	Gesamtfahrzeit
$t_{ges,norm}$	-	Auf Ergebnisse der Dynamischen Programmierung normierte Fahrzeit
$u(t)$	div.	Stellgröße eines Reglers zum Zeitpunkt t
$u^*(t)$	div.	Optimaler zeitlicher Verlauf der Stellgröße eines Reglers
$v, v(s)$	m/s	Fahrgeschwindigkeit (am Streckenpunkt s)
$v_{D,ges}$	-	Auf Ergebnisse der Dynamischen Programmierung normierter Gesamtdieserverbrauch
v_{el}	-	Auf Ergebnisse der Dynamischen Programmierung normierter elektrischer Energiebedarf
v_{Ist}	m/s	Istgeschwindigkeit
v_{Soll}	m/s	Sollgeschwindigkeit
v_{ZM}	-	Auf Ergebnisse der Dynamischen Programmierung normierter Kraftstoffverbrauch der Zugmaschine
$V(s), V_t$	-	Zustandswert, Funktion zur Bewertung des Systemzustands s zum Zeitpunkt t
V_{el}	kWh	Elektrischer Gesamtenergiebedarf
V_{KA}	l	Gesamtkraftstoffverbrauch des Kühlaggregats
\dot{V}_{KA}	l/s	Kraftstoffverbrauch (Volumenstrom) des Kühlaggregats
V_{ZM}	l	Gesamtkraftstoffverbrauch der Zugmaschine
\dot{V}_{ZM}	l/s	Kraftstoffverbrauch (Volumenstrom) der Zugmaschine

Zeichen	Einheit	Bedeutung
$w_{(i-1)jk}$	-	Gewicht beim Übergang von Schicht Nr. $i - 1$ zu Schicht Nr. i für das Neuron Nr. j und den Eingabewert Nr. k in Neuronalen Netzen
$x_{(i-1)k}$	-	Eingabewert Nr. k aus Schicht Nr. $i - 1$ in Schicht Nr. i
y_{ij}	-	Ausgabewert des Neurons Nr. j in der Schicht Nr. i in Neuronalen Netzen
z_{ij}	-	Zwischenwert bei der Berechnung des Ausgabewerts eines Neurons Nr. j in der Schicht Nr. i in Neuronalen Netzen
γ	-	Diskontierungsfaktor, schwächt Einfluss zukünftiger Belohnungen ab
$\Gamma(a)$	-	Gamma-Funktion, abhängig vom Parameter a
ΔSOC	- ; %	Differenz zwischen dem Ladezustand der Batterie zu Beginn der Fahrt und zum Ende der Fahrt
λ	s^2/m^2	Äquivalenzfaktor zur Gewichtung des elektrischen Energiebedarfs aus der Batterie gegenüber dem Kraftstoffverbrauch
λ	-	Faktor bei der Berechnung des Eignungsfaktors im TD(λ)-Verfahren
$\pi(s)$	-	Policy, Strategie zur Wahl einer Aktion abhängig vom aktuellen Systemzustand s

Abkürzungen

A2N	Average-to-Neighbour Strategy
ADEME	Französischer Bus-Fahrzyklus
ANFIS	Adaptive Neuro-Fuzzy Inference System
ARTEMIS	Assessment and Reliability of Transport Emission Models and Inventory Systems
CAN	Controller Area Network
CHTC	Commercial Vehicle Test Cycle
CHTC-B	Chinese Heavy-Duty Commercial Vehicle Test Cycle for City Bus and Coach
CHTC-HT	Chinese Heavy-Duty Commercial Vehicle Test Cycle for Heavy Trucks
CLTC	China Light-Duty Vehicle Test Cycle
DDPG	Deep Deterministic Policy Gradient
DIN	Deutsches Institut für Normung
DNN	Deep Neural Network
DP	Dynamische Programmierung
DQN	Deep-Q-Networks
DRIVE	Dedicated Road Infrastructure for Vehicle Safety in Europe
ECMS	Equivalent Consumption Minimisation Strategy
E-Maschine	Elektromaschine
EPA	Environmental Protection Agency
ESC	European Steady-State Cycle
ETC-Prüfung	Europäische Prüfung mit instationärem Fahrzyklus
EU	Europäische Union
FIGE	Forschungsinstitut für Geräusche und Erschütterungen
FTP	Federal Test Procedure
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
HD-UDDS	Heavy-Duty Urban Dynamometer Driving Schedule
HV	Hochvolt
HWFET	Highway Fuel Economy Driving Schedule
IM240	Insection & Maintenance Driving Cycle
IZF	Informationen zum Fahrzeugeinsatz
J10	10-Mode-Zyklus
J10-15	10-15-Mode-Zyklus

J11	11-Mode-Zyklus
J4	4-Mode-Zyklus
JC08	Transienter japanischer Fahrzyklus
JE05	Japanischer Fahrzyklus für Lkw
KA	Kühlaggregat
LA-4	Alternativer Name für den UDDS Fahrzyklus
MODEM	Modelling of Emissions and Fuel Consumption in Urban Areas
MPC	Model Predictive Control (Modellprädiktive Regelung)
MuJoCo	Multi-Joint dynamics with Contact
NEFZ	Neuer Europäischer Fahrzyklus
NN	Neuronale Netze
NND	Narrow Normal Distribution
NYCC	New York City Cycle
OSM	OpenStreetMap
PG	Policy Gradient
Pkw	Personenkraftwagen
PPO	Proximal Policy Optimization
R2T	Recurrent-to-Terminal Strategy
ReLU	Rectified-Linear-Units (Aktivierungsfunktion)
RL	Reinforcement Learning (Bestärkendes Lernen)
S2T	Sum-to-Terminal Strategy
SAFD	Speed acceleration frequency distribution
SAPD	Speed acceleration probability distribution
SC03	Fahrzyklus mit Berücksichtigung des Leistungsbedarfs einer Klimaanlage
SD3	Softmax Deep Double Deterministic Policy Gradient
SOC	State of Charge
SOH	State of Health
SORT	Standardised On-Road Test Cycles
TD	Temporal Difference
TD3	Twin Delayed Deep Deterministic Policy Gradient Algorithm
TPM	Transition Probability Matrix
UDDS	Urban Dynamometer Driving Schedule
UN	United Nations
UNECE	United Nations Economic Commission for Europe
US06	Fahrzyklus mit aggressivem Fahrverhalten
USA	United States of America

VECTO	Vehicle Energy Consumption calculation Tool
VKM	Verbrennungskraftmaschine
WLTC	Worldwide harmonized Light vehicles Test Cycles
WLTP	Worldwide harmonized Light vehicles Test Procedure
zGG	zulässiges Gesamtgewicht
ZM	Zugmaschine