In der Rubrik **[FORSCHUNG.KOMPAKT]** stellen wir aktuelle Forschungsergebnisse übersichtlich und frei zugänglich dar, die eine wissenschaftliche Begutachtung (»Peer Review«) durchlaufen haben. Die Originalfassung dieses Artikels wurde veröffentlicht unter **Moradi, M. H., Heinz, A., Wagner, U., & Koch, T. (2022). Modeling the emissions of a gasoline engine during high-transient operation using machine learning approaches. International Journal of Engine Research, 23(10), 1708–1716.**, und kann unter der nebenstehenden Adresse abgerufen werden.

https://doi.org/10.5445/IR/1000135485 (Open Access Postprint)

[FORSCHUNG.KOMPAKT]

Alexander Heinz*

Modellierung der Emissionen eines Benzinmotors während hochdynamischen Betriebs durch maschinelles Lernen

Um einen Verbrennungsmotor hinsichtlich Emissionen und Effizienz zu optimieren, benötigt man Modelle, die wechselhaften (»transienten«) Betrieb realistisch und echtzeitfähig abbilden. In dieser Arbeit zeigen wir, wie und weshalb Verfahren der künstlichen Intelligenz – genauer gesagt des maschinellen Lernens – genutzt werden können, um die NO_x- und HC-Rohemissionen (vor Abgasnachbehandlung) bei einem Sechszylinder-Ottomotor vorherzusagen. Die Verfahren sollen das Verhalten eines Motors »erlernen«, um es dann in Simulationen realistischer wiedergeben zu können – insbesondere für realistischen, wechselhaften Betrieb des Motors.

→ **Kontakt**

* Karlsruher Institut für Technologie (KIT), Institut für Kolbenmaschinen (IFKM), **alexander.heinz2@kit.edu**

In der Motorenforschung sowie in der Fahrzeugindustrie wird seit Jahrzehnten anhand von immer schärfer werdenden Emissionsvorgaben an der Verbesserung des Schadstoffausstoßes von Fahrzeugen und Motoren geforscht und entwickelt. Der hier besprochene Journalbeitrag beschäftigt sich mit der Modellierung dieser Schadstoffemissionen in Realfahrmanövern. Neben einer kurzen Zusammenfassung des Beitrags werden die wichtigsten Konzepte rund um den hier vorgestellten Ansatz erklärt.

Warum überhaupt Modellierung von Emissionen – und was sind eigentlich Realfahremissionen?

In der Vergangenheit wurden Fahrzeuge ausschließlich auf Rollenprüfständen unter sehr genau eingeschränkten Umgebungsbedingungen zertifiziert. Dies ist im Grunde auch heute so. Es wird ein Geschwindigkeitsprofil – der WLTC-Fahrzyklus[1] – vorgegeben und das Fahrzeug wird so in einem genau bekannten Geschwindigkeitsbereich bewegt. Es ist also insbesondere aus der Sicht des Motors bekannt, welche Betriebsbereiche abgefahren werden und damit besonders wichtig für Verbrauch und Emissionen sind. Der Fahrzyklus soll dabei einen breiten Betriebsbereich abdecken, ist aber verglichen mit Aufzeichnungen von realem Fahrverhalten teilweise nicht dynamisch genug.

1 Worldwide harmonized Light-duty vehicles Test Cycles

In der aktuellen Gesetzgebung gibt es darüber hinaus zusätzlich Straßentests. In diesen RDE-Tests[2] wird das Fahrzeug im normalen Straßenverkehr bewegt und die Emissionen mittels eines portablen Emissionsmessgeräts (PEMS) untersucht. Dabei werden breite Randbedingungen an die Umgebung und die Strecke zugelassen. Ein Fahrzeug muss also in verschiedensten Betriebszuständen die Emissionsgrenzwerte einhalten. Dabei muss eine Mindest- und eine Maximaldynamik – also Beschleunigung – eingehalten werden, damit die Tests nicht zu »sanft« oder aggressiv gefahren werden.

In der Motorenforschung ist die Abbildung des ersten Tests am Motorenprüfstand vergleichsweise einfach und wird schon länger umgesetzt. Für die Abbildung des RDE-Tests haben die Autoren einen Engine-in-the-Loop-Ansatz verfolgt. Dabei wird mittels verschiedener Modelle für das Fahrzeug (inklusive Kupplung und Getriebe, die Umgebung – also Straße, Geschwindigkeitsbegrenzungen, Ampeln – und den Fahrer) der Motor »virtuell eingebaut«. Dadurch lassen sich auch komplexe Fahrsituationen realitätsnah untersuchen.

In mehreren Forschungsprojekten wurden diese Modelle aufgebaut und validiert. Da RDE-Tests ca. 90 min lang sind, stellen diese Tests am Motorenprüfstand viel investierte Zeit dar. Man möchte also lieber weniger Tests mit einem hohen Informationsgehalt erzeugen.

Um dieses Ziel zu erreichen werden Modelle für das Emissionsverhalten des Motors erstellt. Dafür werden konventionell die erwünschten Werte in Abhängigkeit von Steuergrößen des Motors ermittelt. Wenn es gelingt, ein gutes Modell für den Motor zu erstellen, dann kann mit dem Modell der Betrieb des Motors optimiert werden, ohne dass der Prüfstand betrieben werden muss. Es gibt für die Art der Modelle verschiedene Ansätze, die von einfachen Geraden- oder Parabelgleichungen bis hin zu komplexen mathematischen Ansätzen reichen. In den letzten Jahren haben sich »Künstliche Neuronale Netze« (KNN) als sehr vielseitig erwiesen, also eine Methode der Künstlichen Intelligenz (KI) und des maschinellen Lernens (ML).

Die Autoren wollen mit ihrer Untersuchung die folgenden Fragen beantworten:

- Lassen sich direkt aus simulierten RDE-Fahrten die nötigen Modelle für Emissionen gewinnen? Die Alternative hierzu wären zusätzliche kürzere Versuchsläufe, die die Datenbasis für die Modellbildung erweitern müssten.
- Sind maschinelle Lernverfahren, wie KNN, für die über die Zeit sehr komplexen Zusammenhänge zwischen Fahrzeug-/ Motorzustand und Rohemissionen geeignet?
- Und wenn ja: Welche Art dieser Verfahren?

2 Real Driving Emissions

Tabelle 5: Technische Motordaten

Typ	Benzindirekteinspritzung
Zylinder	R6
Hubraum	2979 cm^3
Kompression	10.2:1
Injektorposition	zentral
Ventilsteuerzeiten	variabel
Ansaugsystem	Abgasturbolader
Leistung	225 kW bei 5800 rpm
Drehmoemnt	400 Nm bei 1200–5000 rpm
Emissionsklasse	Euro V
Treibstoff	Super E5

Inhalt des Papers

Im folgenden sollen die einzelnen Abschnitte des Papers kurz besprochen werden. Der Inhalt wird dabei in kompakter Form umschrieben. Auf eine Wort-zu-Wort-Übersetzung wird bewusst verzichtet.

Experiment und Ergebnisse der Prüfstandsexperimente

Wie bereits erwähnt kam ein Engine-in-the-loop-Ansatz zum Einsatz. Schematisch ist der Versuchsaufbau in Abb. 1 dargestellt. Dabei wurden die gasförmigen Emissionen mittels verschiedener Analysatoren kontinuierlich erfasst. Wichtig für diese Untersuchung sind dabei Stickoxid- (NO_x) und unverbrannte Kohlenwasserstoff- (HC) Emissionen. Dabei wird das zu untersuchende Abgas vor der Abgasnachbehandlung entnommen. Damit ist das Abgas nicht »gereinigt« und es können die direkten Emissionen des Motors untersucht werden. Bei dem Ottomotor handelt es sich um einen Reihensechszylinder mit Direkteinspritzung und Abgasturboaufladung. Einige Daten finden sich in Tab. 5. Dabei wird möglichst ein seriennahes Motorsteuergerät verwendet. Dies führt dann dazu, dass sich der Motor im Experiment so verhält wie der gleiche Motor eingebaut im Fahrzeug auf der Straße.

Mit diesem Versuchsaufbau wurden Versuche auf drei virtuellen Strecken durchgeführt. Diese Strecken bilden reale Straßen im Umfeld von Karlsruhe, Heilbronn und Stuttgart ab. Dabei sind sowohl die Verläufe als auch die Beschilderung und Ampeln be-

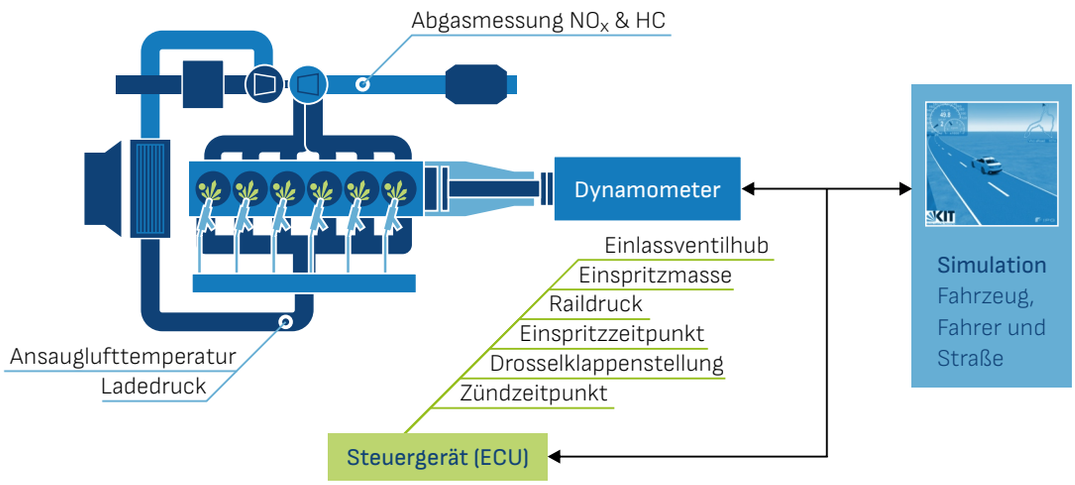


Abb. 1: Experimentalsetup als Verbindung von Motor, Steuergerät und Simulation

rücksichtigt. Bei den Tests wurden allerdings nicht alle Randbedingungen für RDE-Straßentests eingehalten:

- Der Motor wurde künstlich auf einer konstanten Temperatur im Kühlmittel von 85° C gehalten. Dies hatte den Grund, dass die Untersuchung vergleichbar zu anderen Tests am Prüfstand sein sollte. Der Nachteil ist, dass in der Realität insbesondere kalte Motorzustände direkt nach Motorstart die meisten Herausforderungen für Emissionsoptimierung beinhalten.
- Es wurden ausschließlich Rohemissionen entnommen. Bei Straßentests werden hingegen die Emissionen erst nach der Abgasreinigung entnommen.
- Der Dynamikparameter $va_{pos,95}$ wurde überschritten. Das bedeutet, dass die Tests deutlich dynamischer sind, und damit ein breiterer Betriebsbereich des Motors abgedeckt wird. Dies ist wichtig, damit für die Modellgenerierung eine möglichst breite Datenbasis zur Verfügung steht.

Die Datenbasis besteht aus neun Läufen. Jede Strecke wurde mit drei verschiedenen Fahrerkonfigurationen gefahren. Die virtuellen Fahrer unterscheiden sich hauptsächlich bezüglich maximaler Beschleunigung und Schaltverhalten. Die Daten zum Training des KNN wurden ausschließlich aus diesen Versuchsläufen generiert.

Abb. 2 zeigt im Beispiel, wie dynamisch die Daten der Prüfläufe sind. Das Schaltverhalten und damit die Motordrehzahlgrenze wird durch die Fahrerparametrierung sowie die Fahrpedalstellungsgrenze gesteuert. Wie aus diesem Beispiel ersichtlich wird, führen die Fahrereingaben und der simulierte Straßenverlauf zu stark transienten Lastanforderungen und Motordrehzahlen. Da kein Verkehr simuliert wurde, wird die resultierende simulierte Fahrzeuggeschwindigkeit durch das Tempolimit und die Querbeschleunigungsgrenzen für Kurvengeschwindigkeiten bestimmt. Spitzenwerte der HC-Emissionen treten häufig bei Lastwechseln von einer höheren zu einer niedrigeren Last auf.

Bei der genaueren Auswertung der Fahrdynamik stellt sich heraus, dass jeweils der aggressivste Fahrer über der erlaubten Dynamik liegt. Tab. 6 zeigt eine Übersicht über Fahrzeuggeschwindigkeit und Dynamikbereich der verwendeten RDE-Läufe. Die Fahrerkonfigurationen führen zu dynamischen Parametern, die unter dem Grenzwert (»niedriger«), nahe dem Grenzwert (»mittel«) und über dem Grenzwert (»höher«) der Verordnung liegen.

Die verwendeten Ansätze des maschinellen Lernens

In diesem Paper wurden verschiedene Ansätze untersucht. Sie unterscheiden sich vor allem in der Topologie der Netze. Herauszuheben hier der »Long Short-Term Memory«-Ansatz (LSTM, dt.: langes Kurzzeitgedächtnis). Dieser unterscheidet sich von Ansätzen mit KNN vor allem in der Möglichkeit, dass bei der Bestimmung der momentanen Emissionen auch Zeitschritte in der Vergangenheit berücksichtigt werden können. Damit ist er vielversprechend für die Analyse der transienten Prüfläufe. Eine genauere Beschreibung der Ansätze findet sich in der Originalveröffentlichung.

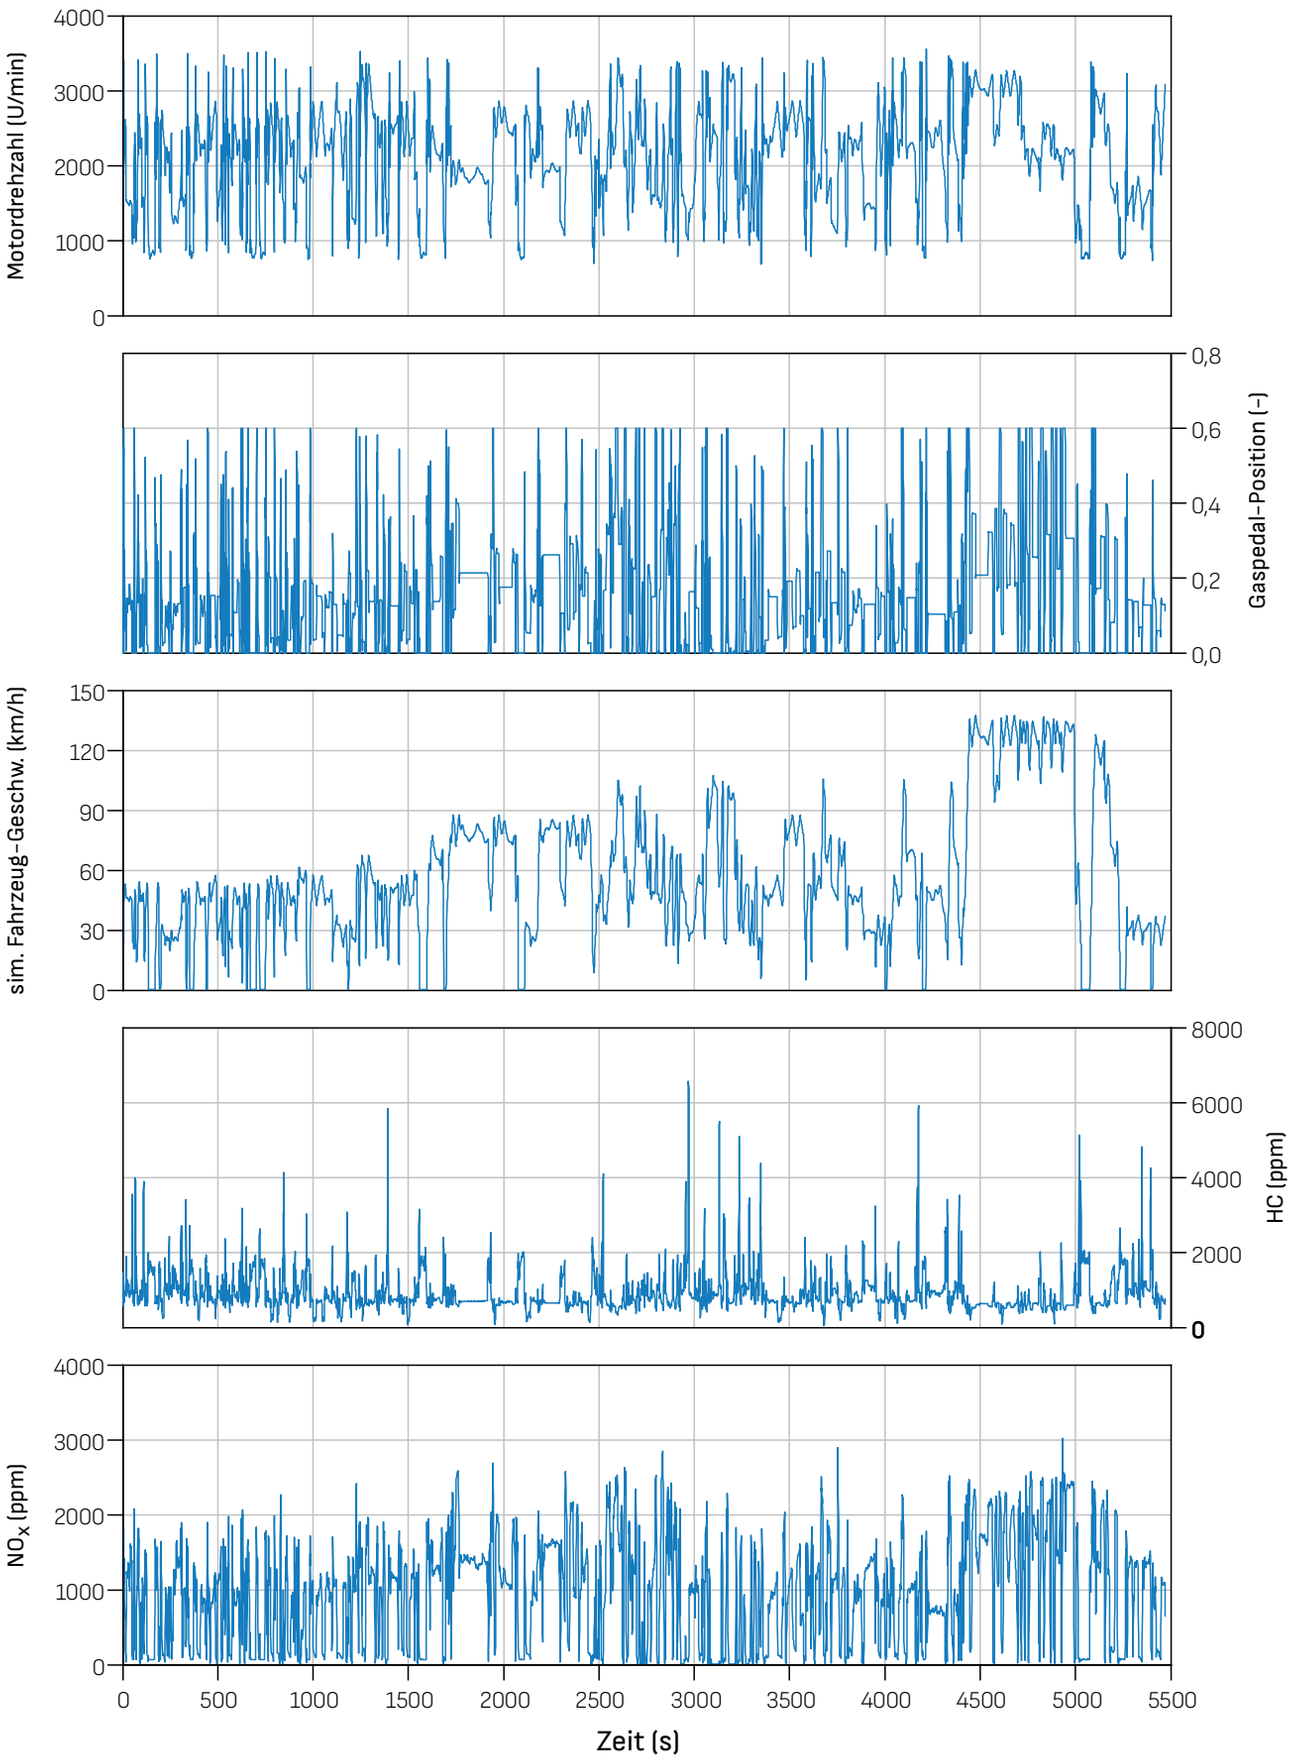


Abb. 2: Beispielhafte experimentelle Daten einer simulierten RDE-Fahrt

Tabelle 6: Fahrzeuggeschwindigkeit und Dynamikbereich der verwendeten RDE-Fahrten

	Fahrer-Dynamik	Bereich urban	ländlich	Autobahn
v_{mean} [km/h]	niedriger	35,9—38,4	74,7—75,5	115—119
	mittel	35,2—35,9	74,4—75,4	115—118
	höher	32,7—34,3	74,0—76,3	116—119
$va_{pos,95}$ [m^2/s^3]	niedriger	15,7—17,4	19,3—22,4	18,2—20,7
	mittel	18,1—19,9	23,3—31,6	24,6—33,9
	höher	21,6—25,6	26,1—34,4	33,1—36,7

Eingangsparameter

Wie bereits erwähnt, sind die Ausgangsparameter bei der Modellierung dieser Studie NO_x und HC jeweils in der Einheit ppm. Zunächst wurden zehn Parameter ausgewählt, die als Input für die Entwicklung der Modelle dienen sollten. Da die lokalen Bedingungen im Zylinder, die vor allem für die Emissionsbildung wichtig sind, nicht bekannt sind, wurden mehrere externe Parameter für den Modellierungsansatz gewählt. Sie sind im Folgenden zusammen mit ihrem Einfluss auf die Verhältnisse im Zylinder aufgeführt:

- *Eingespritzte Kraftstoffmasse* (mg pro Hub): Kraftstoffgemisch, Last und Spitzendruck im Zylinder
- *Drosselklappenstellung* (%), *Einlassventilhub* (mm): Last, Kraftstoffgemisch, Strömung im Zylinder
- *Motordrehzahl* (1/min): Strömung im Zylinder
- *Ladedruck* (mbar): maximaler Druck im Zylinder
- *Ladedruck* (MPa), *Einspritzzeitpunkt* (Grad Kurbelwelle vor oberem Totpunkt): Gemischbildung, Homogenisierung
- *Ansauglufttemperatur* (°C): Klopfverhalten
- *Zündzeitpunkt* (Grad Kurbelwelle v.ZOT): Verbrennungseigenschaften einschließlich Höchstdruck
- *Volumetrischer Wirkungsgrad* (-): zusätzlicher, optionaler Lastparameter

Zunächst wurden diese Parameter statistisch untersucht, um festzustellen, ob überhaupt ein Zusammenhang zwischen den Parametern und den jeweiligen Emissionen besteht. Das Ergebnis lässt sich anhand von Sperman- und Pearson-Parametern bewerten. Die Ergebnisse zeigen eine signifikante lineare und nicht-lineare Korrelation zwischen Eingangs- und Ausgangsparametern. Dies bestätigt die Tatsache, dass die ausgewählten Eingangsparameter eine entscheidende Rolle bei der Bestimmung und Vorhersage der NO_x- und HC-Emissionen spielen. Grundsätzlich sind die gewählten Eingangsparameter also geeignet.

Datenvorbereitung

In einem ersten Schritt wurden die Daten aus verschiedenen Messsystemen synchronisiert. Danach wurden 20% der Daten nach dem Zufallsprinzip entnommen, um sie für den Test der entwickelten Modelle zu verwenden. Mit den verbleibenden Daten wurden die Modelle trainiert. Diese Datenproben sollten die gesamten Änderungsbereiche der Eingangsparameter abdecken, um eine ganzheitliche Prüfung der Modelle in allen Bereichen der Änderungsbereiche durchführen zu können. In Abb. 3 ist zu erkennen, dass die Testmuster (blau markiert) eine geeignete Abdeckung für die Änderungsbereiche der Eingangsparameter darstellen.

Ergebnis der Modellbildung

In der Originalpublikation wird an dieser Stelle detailliert auf statistische Kennwerte zur Modellgüte eingegangen. Das Ergebnis lässt sich folgendermaßen zusammenfassen:

- Das LSTM ist sehr gut geeignet um die Emissionen abzubilden. Im Falle der HC-Vorhersage hat das LSTM-Modell die besten Ergebnisse.
- Es lässt sich feststellen, dass die entwickelten KNN-Modelle nicht genau genug sind, insbesondere bei der Vorhersage der HC-Emissionen.
- Bei Ottomotoren und transientem Betrieb durch Lastwechsel können hohe HC-Emissionsspitzen auftreten, die auf die Verzögerung der Gemischregelung zurückzuführen sind.
  - Die Vorhersage dieser Spitzenwerte ist mit KNN-Modellen nicht möglich (Abb. 4a).
  - Einen großen Vorteil bietet dagegen das LSTM-Modell, das die Informationen aus der vorangegangenen Zeitreihe nutzen kann.

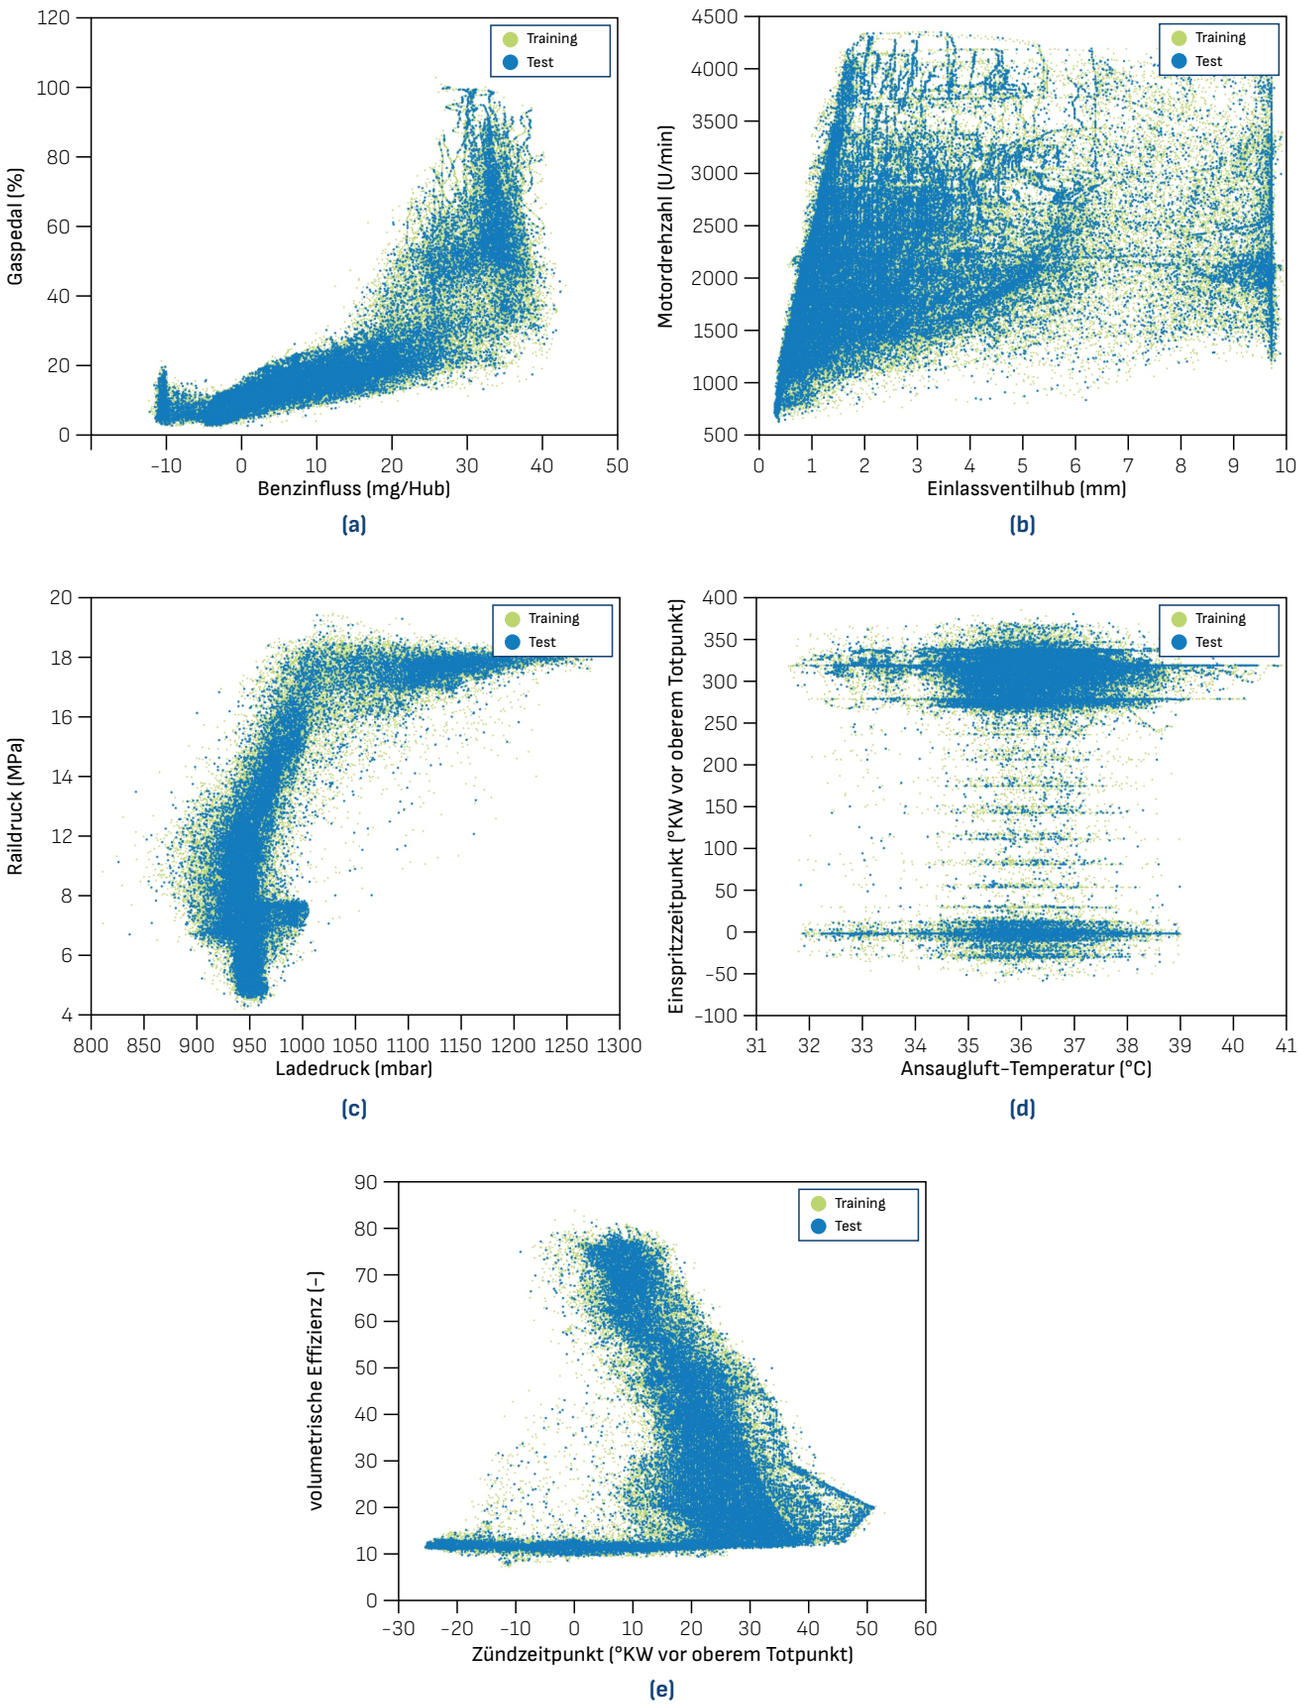
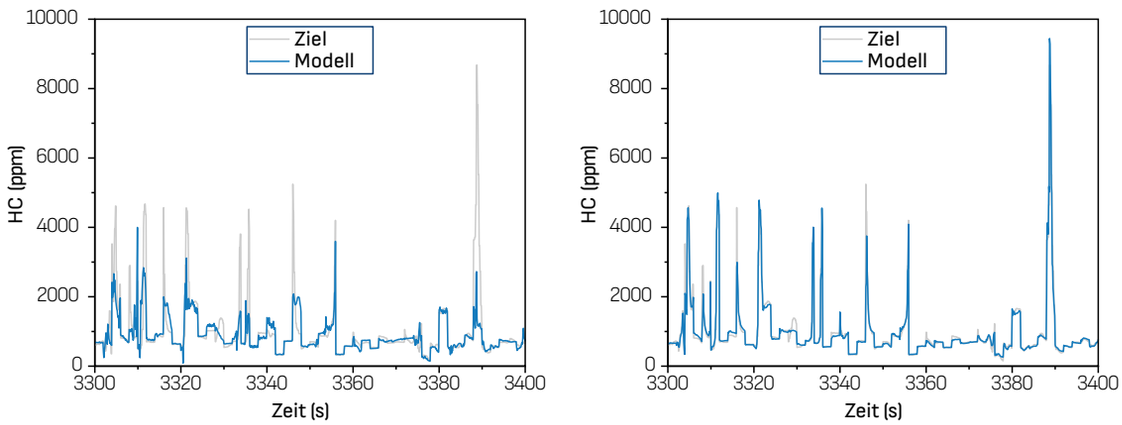


Abb. 3: Darstellung der Trainings- und Testdaten für alle Eingabeparameter



(a) KNN **(b)** LSTM

Abb. 4: Gemessene (Ziel) und laut Modell vorhergesagte Emissionen mit (a) KNN-Modell; (b) LSTM-Modell

Wie in Abb. 4b beschrieben, wurden die HC-Spitzen von der LSTM-Methode erkannt und korrekt vorhergesagt.

Zusammenfassung und Ausblick

Die Modellierung der HC- und NO_x-Rohemissionen für einen Sechszylinder-Ottomotor wurde mit Methoden des maschinellen Lernens durchgeführt. Nach bestem Wissen der Autoren haben die Modelle eine der höchsten Genauigkeiten unter den bisher entwickelten maschinellen Lernmodellen für die Emissionsvorhersage bei hochtransientem Betrieb. Darüber hinaus hat das KNN-Modell nach den Ergebnissen eine Schwäche bei der Vorhersage von HC.

Der Grund dafür ist die sehr hohe HC-Spitze, die bei einem Ottomotor bei Lastwechseln auftreten kann. In diesem Fall bietet das LSTM-Modell, das Daten aus früheren Zeitschritten verwendet, Vorteile hinsichtlich der Genauigkeit.

Ein wichtiger Vorteil dieser Modelle ist die Bewertung von Abgasnachbehandlungssystemen während der Fahrt auf der Straße. Die Modellierung der Rohemissionen könnte auf dem Prüfstand durchgeführt werden (wie in dieser Studie) und die trainierten Modelle im RDE-Fahrbetrieb eingesetzt werden. Durch den Vergleich der vorhergesagten Rohemissionen aus den entwickelten Modellen mit den gemessenen Auspuffemissionen aus dem PEMS-Messsystem könnte eine aussagekräftige Bewertung der Effizienz von Abgasnachbehandlungssystemen unter realen Fahrbedingungen gewonnen werden.

Darüber hinaus wäre der Einsatz von KNN im modellbasierten Reinforcement Learning (RL) von Bedeutung. KNN können verwendet werden, um dem RL-Agenten Echtzeitinformationen zu liefern. RL könnte in verschiedenen Anwendungen eingesetzt werden, zum Beispiel bei der Optimierung der Leistungsverteilung und vergleichbaren Zwecken. ■

Literaturverweise

Moradi, Mohammad Hossein, Alexander Heinz, Uwe Wagner und Thomas Koch (2022). »Modeling the emissions of a gasoline engine during high-transient operation using machine learning approaches«. In: *International Journal of Engine Research* 23.10, S. 1708–1716. DOI: 10.1177/14680874211032381.