TECHNISCHE UNIVERSITÄT MÜNCHEN
Lehrstuhl für Regelungstechnik

Versuchsplanung und Methoden zur Identifikation zeitkontinuierlicher Zustandsraummodelle am Beispiel des Verbrennungsmotors

Dipl.-Ing. Univ. Michael Deflorian

Vollständiger Abdruck der von der Fakultät für Maschinenwesen der Technischen Universität München zur Erlangung des akademischen Grades eines Doktor-Ingenieurs genehmigten Dissertation.

Vorsitzender:	Univ.-Prof. Dr.-Ing. Hartmut Spliethoff
Prüfer der Dissertation:	1. Univ.-Prof. Dr.-Ing. habil. Boris Lohmann
	2. Univ.-Prof. Dr.-Ing. Georg Wachtmeister

Die Dissertation wurde am 07.09.2011 bei der Technischen Universität München eingereicht und durch die Fakultät für Maschinenwesen am 01.12.2011 angenommen.

Berichte aus der Automatisierungstechnik

Michael Deflorian

Versuchsplanung und Methoden zur Identifikation zeitkontinuierlicher Zustandsraummodelle am Beispiel des Verbrennungsmotors

Shaker Verlag
Aachen 2012

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.: München, Techn. Univ., Diss., 2011

Copyright Shaker Verlag 2012
Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder vollständigen Wiedergabe, der Speicherung in Datenverarbeitungsanlagen und der Übersetzung, vorbehalten.

Printed in Germany.

ISBN 978-3-8440-0824-1
ISSN 0945-4659

Shaker Verlag GmbH • Postfach 101818 • 52018 Aachen
Telefon: 02407 / 95 96 - 0 • Telefax: 02407 / 95 96 - 9
Internet: www.shaker.de • E-Mail: info@shaker.de

Kurzfassung

Diese Arbeit beschreibt neue Methoden der Online-Versuchsplanung und Online-Identifikation dynamischer Zusammenhänge am Verbrennungsmotorenprüfstand. Diese Methoden sollen die Steuergeräteapplikation bei der Modellierung und Optimierung dynamischer Vorgänge unterstützen. Die Ergebnisse der Arbeit fließen in den modellbasierten Online-Optimierungsalgorithmus ein, welcher zur Optimierung des Stationärverhaltens des Verbrennungsmotors verwendet wird, und ermöglichen diesen zukünftig auch zur Optimierung des Instationärverhaltens einzusetzen.

Die wesentlichen Neuerungen dieser Arbeit betreffen die modellbasierte Online-Versuchsplanung und Online-Modellbildung. Die vorgestellten Methoden der Online-Versuchsplanung ermöglichen es unter Berücksichtigung von Einschränkungen an die Ein- und Ausgänge mit möglichst wenigen Messungen einen maximalen Informationsgewinn aus diesen zu ziehen und die Versuchsplanung hinsichtlich des späteren Einsatzzwecks der Modelle zu optimieren. Die Methoden der Online-Modellbildung ermöglichen die Identifikation eingangs-/zustandsstabiler zeitkontinuierlicher Zustandsraummodelle unter Verwendung von Neuronalen Netzen, die mittels Runge-Kutta Methoden zeitdiskretisiert werden. Es kann gezeigt werden, dass sowohl die Methoden der Online-Versuchsplanung als auch die der Online-Modellbildung zu einer Verbesserung der erzielten Modellgüte führen und den bisher am Verbrennungsmotorenprüfstand eingesetzten Methoden der Versuchsplanung und Identifikation dynamischer Modelle überlegen sind. Die Versuchsplanung und Modellbildung eignet sich auch für den konventionellen Offline-Betrieb.

Anhand von zwei Beispielen wird die Anwendbarkeit der entwickelten Methoden am Verbrennungsmotorenprüfstand gezeigt.

Abstract

This thesis describes methods to calculate online design of experiments and to identify online the dynamic behaviour of combustion engines. These methods are developed to support the electronic control unit calibration in terms of modelling and optimizing the dynamics of the combustion engine. The results are used to extend an existing model-based online optimization algorithm, which is used to optimize the steady state behaviour of the combustion engine, such that this algorithm can also be used to optimize the transient behaviour of the combustion engine.

The thesis introduces new model-based online designs of experiments and online-identification algorithms. The model-based online design of experiments allows gathering maximum information with minimum measurements, to consider constraints on the inputs and outputs and to optimize the design of experiment in respect to the indented use of the models. The online-identification enables to identify continuous time, input-to-state stable state-space models using neural networks, which are disretized by Runge-Rutta methods. It is possible to show, that the proposed online design of experiment and the online identification lead to better model quality and are superior to state of the art methods.

Two examples show the application of the proposed methods at the testbed.

Vorwort

Die Arbeit entstand während meiner Zeit als Doktorand im Bereich „Entwicklung Versuchsmethoden“ der BMW Group in München in Zusammenarbeit mit dem Lehrstuhl für Regelungstechnik der Technischen Universität München.

An dieser Stelle möchte ich mich bei Prof. Dr.-Ing. Lohmann, Dr.-Ing. Michael Buhl und Dr.-Ing. Florian Klöpper für die fachliche Betreuung und wertvollen Diskussionen während der Entstehung dieser Arbeit bedanken. Zudem danke ich den Studenten Martin Ronis, Susanne Zaglauer und Matthias Moll für ihren Einsatz und Unterstützung.

Besonderer Dank gilt meiner Familie und vor allem auch meiner Freundin für die fortwährende Unterstützung und Geduld!

München, August 2011 Michael Deflorian

Inhaltsverzeichnis

1 Einleitung **1**
1.1 Einführung in die Aufgabenstellung und Motivation 1
1.2 Stand der Technik in der Applikation 3
1.2.1 Messdatenbasierte Optimierung 4
1.2.2 Modellbasierte Optimierung 5
1.2.3 Messdatenerfassung 7
1.3 Ziele der Arbeit 9
1.4 Aufbau der Arbeit 11

2 Grundlagen der Modellbildung **12**
2.1 Darstellung der Dynamik 14
2.1.1 Modell-Konfiguration 14
2.1.2 Zeitdiskrete Modelle 15
2.1.3 Zeitkontinuierliche Modelle 18
2.1.4 Wahl der Abtastzeit 19
2.1.5 Diskussion im Sinne der Aufgabenstellung 20
2.2 Bias-Varianz Dilemma 21
2.2.1 Early Stopping 23
2.2.2 Regularisierungsverfahren 23
2.2.3 Modellkomitees 24
2.3 Modellbildungsverfahren 25
2.3.1 Parametrische Modelle 25
2.3.2 Nicht-Parametrische Modelle 25
2.3.3 Kostenfunktionen 26
2.3.4 Diskussion im Sinne der Aufgabenstellung 26

3 Stand der Technik: Versuchsplanung **27**
3.1 Anregungssignale für dynamische Systeme 27
3.2 Versuchsplanung: modellfreie und modellbasierte Verfahren 29
3.3 Versuchsplanung: Offline-Verfahren 31
3.3.1 Maxmin Latin Hypercube Verteilung 31
3.3.2 Fisher-Information basierte Verteilung 31
3.4 Versuchsplanung: Online-Verfahren 33
3.4.1 Query by Committee 33
3.4.2 Sequentielles Fisher-Information basiertes Design 34
3.5 Limitbehandlung 34
3.6 Diskussion im Sinne der Aufgabenstellung 35

4 Stand der Technik: Identifikation dynamischer nichtlinearer Systeme 36
4.1 Neuronale Netze . . . 37
4.1.1 Zeitdiskrete Neuronale Netze . . . 37
4.1.2 Parameterschätzung . . . 38
4.1.3 Regularisierung . . . 39
4.1.4 Bifurkation und Stabilität . . . 40
4.2 Lokal lineare Modelle . . . 43
4.2.1 Aufbau des Takagi-Sugeno Fuzzy Modells . . . 43
4.2.2 LOLIMOT . . . 45
4.2.3 Hinging Hyperplanes . . . 45
4.2.4 Lokale Neuro-Fuzzy Modelle . . . 46
4.3 Diskussion im Sinne der Aufgabenstellung . . . 46

5 Online-Versuchsplanung und Identifikation dynamischer Zusammenhänge 48
5.1 Anforderungen . . . 48
5.2 Identifikation von Runge-Kutta Neuronalen Netzen . . . 49
5.2.1 Problemformulierung . . . 51
5.2.2 Struktur der Runge-Kutta Neuronalen Netze . . . 52
5.2.3 Berechnung der Jakobi-Matrix . . . 54
5.2.4 Gradientenberechnung der Kostenfunktion . . . 56
5.2.5 Stabilität . . . 57
5.2.6 Wahl des expliziten Runge-Kutta Verfahrens . . . 59
5.2.7 Initialisierung . . . 60
5.2.8 Einschränkungen der Runge-Kutta Neuronalen Netze . . . 60
5.2.9 Vorteile der Runge-Kutta Neuronalen Netze . . . 61
5.3 Modellkomitee . . . 62
5.4 Versuchsplanung . . . 64
5.4.1 Parametrisches Anregungssignal . . . 64
5.4.2 Offline-Versuchsplanung für dynamische Systeme . . . 66
5.4.3 Online-Versuchspläne für dynamische Systeme . . . 67
5.4.4 Aufgabenbezogene Modifikationen . . . 69
5.5 Simulative Evaluierung: Versuchsplanung und Modellbildung . . . 71
5.5.1 Modellbildung . . . 71
5.5.2 Online-Versuchsplanung . . . 82
5.6 Diskussion im Sinne der Aufgabenstellung . . . 84

6 Online-Identifikation am Motorprüfstand 85
6.1 Implementierung und Heuristiken . . . 85
6.1.1 Phasenplanung . . . 85
6.1.2 Verstellstrategie und Limitbehandlung . . . 87
6.1.3 Totzeiten, Ausreißer und unterschiedliche Zielgrößendynamik . . . 90
6.2 Evaluierung im Prüfstandsbetrieb . . . 92
6.2.1 Kennfelddokumentation . . . 92
6.2.2 Prüfstandsreglerentwurf . . . 94
6.3 Einschränkungen und Ausblick . . . 97

7 Zusammenfassung und Ausblick **99**

A Wahrscheinlichkeitstheorie **103**
A.1 Wahrscheinlichkeitsverteilungen 103
A.1.1 Wahrscheinlichkeitsdichtefunktion 103
A.1.2 Likelihood-Funktion 104
A.2 Fisher-Information 104

B Levenberg-Marquardt Algorithmus **107**

C Definitionen **111**
C.1 Totale Ableitung 111
C.2 Matrix- und Vektoreigenschaften 111
C.3 Fehlermaße 114

D Stabilitätsanalyse **115**
D.1 Stabilitätsanalyse zeitdiskreter Systeme 116
D.2 Stabilitätsanalyse zeitkontinuierlicher Systeme 117
D.2.1 Zusammenhang zwischen ISS und Stabilität nach Lyapunov 117
D.2.2 Zusammenhang ISS und Ein-/Ausgangsstabilität 119
D.3 Stabilität von Runge-Kutta Verfahren 119
D.4 Stabilität von Runge-Kutta Neuronalen Netzen 121
D.4.1 B-ISS expliziter Runge-Kutta Methoden 121
D.4.2 Stabilitätsnebenbedingungen an die Gewichte des Runge-Kutta Neuronalen Netzes 130

E Benchmarksystem **136**

Notation

Abkürzungen

APRBS	Amplitudenmoduliertes Pseudo Randomisiertes Binäres Signal
DoE	Design of Experiment
FIM	Fisher-Informationsmatrix
LHC	Latin HyperCube
LM	Levenberg-Marquardt
LOLIMOT	Local Linear Model Tree
MLP	Multi Layer Perceptron
NARX	Nonlinear AutoRegressive with eXogenous input
NMSE	Normalized Mean Square Error
NMAE	Normalized Mean Absolute Error
NOE	Nonlinear Output Error
QbC	Query by Committee
RBF	Radial Basis Function
RK	Runge-Kutta
RKNN	Runge-Kutta Neuronales Netz
SNR	Signal to Noise Ratio
TS	Takagi-Sugeno
ZDNN	Zeitdiskretes Neuronales Netz

Symbole

N_x	Anzahl an Zuständen
N_R	Anzahl an Regressoren
N_I	Anzahl an Eingängen
N_O	Anzahl an Ausgängen
N_N	Anzahl an Neuronen in der versteckten Schicht
N_p	Anzahl an Parametern
u	Eingang
$x, \hat{x}$	System- / Modellzustand
$y, \hat{y}$	System- / Modellausgang
θ	Modellgewichte / -parameter
φ	Regressor
η	Messrauschen
e	Abweichung zwischen Modell- und Systemausgang
t_s	Abtastrate
h_{rk}	Runge-Kutta Schrittweite