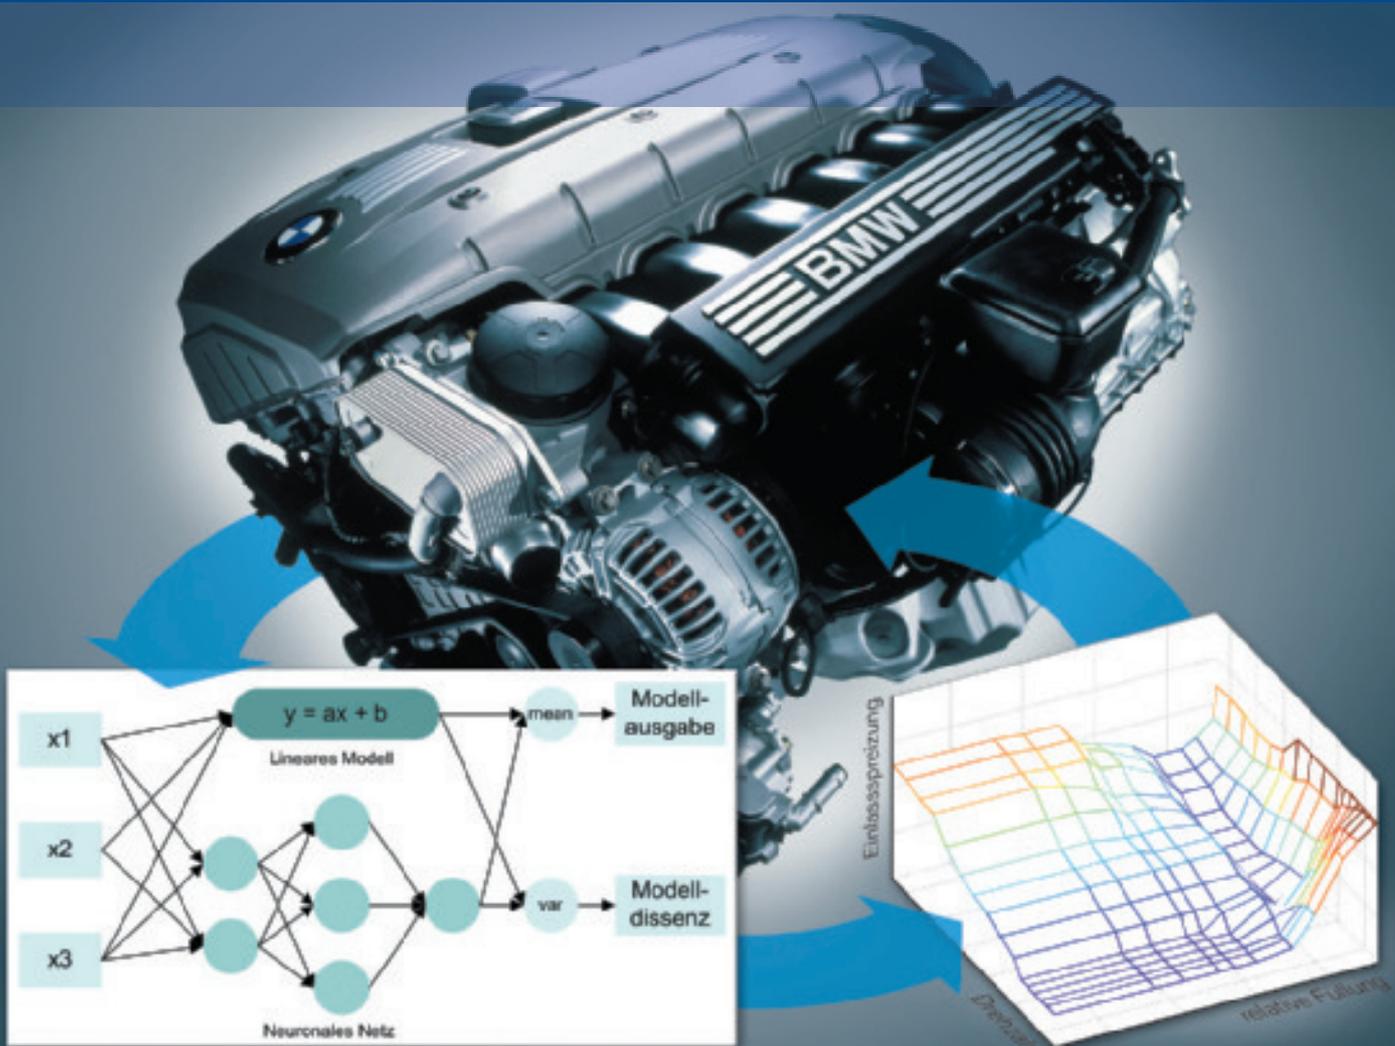


Modellbasierte Online-Optimierung in der Simulation und am Motorenprüfstand

Der vorliegende Artikel beschreibt die Erweiterungen des modellbasierten Optimierungsalgorithmus „mbminimize“, der in einer Zusammenarbeit der Universität Tübingen und der BMW Group für die Online-Optimierung von Verbrennungsmotoren entwickelt wurde. Im Vordergrund dieses Beitrags stehen dabei die Modularisierung der Optimierungsmethoden und die Umsetzung für die Praxis des Prüfstandsbetriebs.



1 Einleitung

Die modellbasierte Optimierung gewann in den letzten Jahren zunehmend an Bedeutung für die Applikation komplexer Motorsteuerungen. Rechnergestützte Verfahren für die Offline-Optimierung haben sich schon seit längerer Zeit bewährt und sind beispielsweise in [1, 2, 3] beschrieben. Fortschritte in der jüngeren Zeit gab es jedoch besonders in der Online-Optimierung. In diesem Bereich sind bekannte Optimierungssysteme wie beispielsweise Cameo [4] oder Vega [5] im Einsatz, aber auch der in [6, 7] präsentierte Algorithmus „mbminimize“ hat seinen Platz in der praktischen Anwendung gefunden.

Während die beiden bisherigen Beiträge zum Algorithmus „mbminimize“ seine Funktionsweise aus theoretischen Überlegungen heraus beschreiben, steht im vorliegenden Artikel die praktische Anwendung im Vordergrund. Diese beinhaltet den Einsatz des Algorithmus im Prüfstandsbetrieb, ist aber nicht auf diesen beschränkt. Der Bogen vom Entwurf zur Praxis wird über die Simulation gespannt, in der grundlegende Überlegungen an Testfunktionen geprüft werden können. Dabei wird für die Realisierung am Prüfstand besonders auf die Effizienz des Optimierungsverfahrens geachtet, auf die neue Verfahren stets einen Schwerpunkt setzen, um auch bei steigender Problemgröße weiterhin den Echtzeitanforderungen des Online-Betriebs gerecht zu werden [8, 9].

2 Anforderungen an die Online-Optimierung

Der in Kooperation von Universität Tübingen und BMW Group entwickelte Algorithmus „mbminimize“ wird zur Kennfeldoptimierung eingesetzt und ist besonders für die in [5] genannte Vollraasterabstimmung geeignet. Dabei sollen für jeden Betriebspunkt Kombinationen der Verstellgrößen gefunden werden, die optimal hinsichtlich einer gegebenen Zielfunktion sind, beispielsweise für den spezifischen Kraftstoffverbrauch. Für den praktischen Einsatz sind dabei unter anderem folgende Punkte wichtig, auf die der vorliegende Artikel über den Algorithmus „mbminimize“ eingeht:

- Flexibilität und Modularität ist zukunftsweisend für einen Optimierungsalgorithmus, der nicht nur am Prüfstand, sondern auch in der Simulation eingesetzt werden kann, um kostbare Ressourcen zu sparen. Gute Wartbarkeit und einfache Aktualisierbarkeit einzelner Kom-

ponenten erleichtern die zeitgemäße Weiterentwicklung des Algorithmus.

- Bei der Auswertung sind nicht nur die Optima des Modells interessant, sondern auch ein Maß für die Modellsicherheit im gegebenen Suchraum. Beide Größen spielen im Verlauf der Online-Optimierung eine wichtige Rolle.
- Prüfstandszeit ist wertvoll und zudem begrenzt verfügbar. Daher sind möglichst wenige benötigte Messungen sowie kurze Rechenzeiten während des Prüfstandsbetriebs zu erreichen.

Das Verfahren in seiner ursprünglichen Form und der theoretische Hintergrund sind in [10] beschrieben. Zur Modellbildung wird bei „mbminimize“ ein Komitee aus neuronalen Netzen und LLR-Modellen verwendet, wobei bei den zuletzt genannten linear parametrisierten Modellen die Modellausgabe eine Linearkombination aus nichtlinearen Basisfunktionen ist. Neuronale Netze haben sich in der modellbasierten Optimierung schon lange bewährt, wie zum Beispiel in [2] und [11] dargestellt wird.

3 Konzept von „mbminimize“

3.1 Modularisierung

Ein Aspekt der Weiterentwicklung von „mbminimize“ ist die Modularisierung. Der Algorithmus war stark auf die Anwendung am Motorenprüfstand ausgerichtet, so dass zum Beispiel eine Einbindung von Simulationsumgebungen aufwändig war. Als vorteilhaft erwies es sich, die Prüfstand-spezifische Limitbehandlung, die in „mbminimize“ selbst integriert war, stattdessen auf der Prüf-

Die Autoren



Dipl.-Inf.
Alexander Sung
ist wissenschaftlicher Angestellter am Lehrstuhl für Rechnerarchitektur der Universität Tübingen.



Florian Klöpfer M. Sc.
ist Doktorand und Methodeningenieur im Bereich Antriebsentwicklung der BMW Group in München.



Dr.-Ing.
Alexander Mitterer
ist verantwortlich für die Methodenentwicklung im Bereich Antriebsentwicklung der BMW Group in München.



Prof. Dr.-Ing.
Georg Wachtmeister
leitet den Lehrstuhl für Verbrennungskraftmaschinen der Technischen Universität München.



Prof. Dr. Andreas Zell
leitet den Lehrstuhl für Rechnerarchitektur der Universität Tübingen.

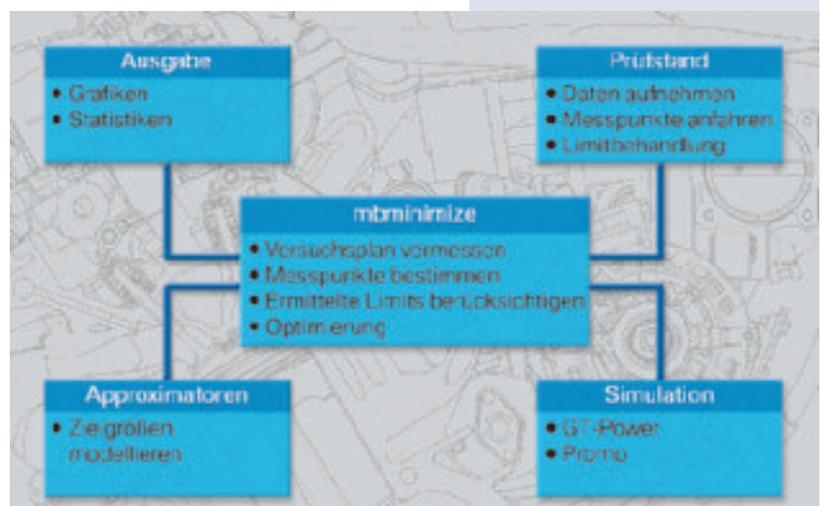


Bild 1: Komponenten von „mbminimize“ nach der Modularisierung

Figure 1: Components of “mbminimize” after modularisation

standsseite durchzuführen. Auch wurde die ursprünglich in „mbminimize“ eingebettete Modellgenerierung aus dem Kern des Algorithmus heraus getrennt, und es wurde somit ermöglicht, das Modell-Komitee für andere Anwendungen zu verwenden.

Bild 1 zeigt die Struktur von „mbminimize“ nach der Modularisierung. Die einzelnen Teilaufgaben sind getrennt und einfach ersichtlich. Das Grundgerüst des Algorithmus besteht aus der Initialisierung, Messdatenauswertung, Phasenplanung und Bestimmung der Messpunkte. Über Schnittstellen damit verknüpft sind die Messverfahren, Modelle und graphischen Ausgaben. Für eine genaue Beschreibung der einzelnen Komponenten des Algorithmus wird hier auf die früheren Artikel [6, 7] verwiesen.

Die Verstellstrategie der Eingangsgrößen zur Anfahrt des nächsten Messpunkts wurde auf das Prüfstand-Automatensystem übertragen, das einen Messpunkt über die synchrone Verstellung aller Variationsgrößen erreicht. Zeitgleich kann das System die Limitüberwachung durchführen, welche ebenfalls aus „mbminimize“ ausgegliedert wurde. Vorteile dieser Vorgehensweise sind:

- schnelles Einstellen der Messpunkte bei kleiner Zielgrößenanregung, wodurch ein schnelleres Einregeln von Zündwinkel und Abgastemperatur durch die Prüfstand-Regelsysteme möglich wird
- Datenauswertung im Prüfstand-Automatensystem und nicht in Matlab, somit eine schnellere Erkennung von Limitverletzungen dank leistungsfähiger Schnittstelle auf Prüfstandsseite
- mögliche Änderungen der Variations- und Limitstrategie im Online-Betrieb.

3.2 Modellierung mehrerer Zielgrößen

Charakteristisch für die in „mbminimize“ verwendeten Komitees ist das QBC-Kriterium (Query by Committee), von dem **Bild 2** eine exemplarische Ausgabe zeigt. Das QBC-Kriterium liefert die größten Werte an den Stellen, wo die Einzelmodelle des Komitees am meisten voneinander abweichen. Der Ausdruck Query bezeichnet dabei die Entscheidungsfindung zur Bestimmung des nächsten Messpunktes anhand der vorliegenden Modelle.

Über das Query-Kriterium erfolgt die Auswahl der nächsten Messpunkte anhand der Modelle. Bisher wurde dieses nur für die primäre, zu optimierende Zielgröße angewendet. Weitere sekundäre Zielgrößen werden anhand der Messpunkte modelliert. Das Query-Kriterium ergibt sich am Punkt x dabei zu Gl. (1).

$$q(x) = q_{QBC}(x) \cdot \varphi \cdot \Theta(x) \tag{1}$$

$q_{QBC}(x)$ ist die Varianz des Modellsystems am Punkt x. φ ist der Faktor, der den Einfluss der Zielgröße auf das Query-Kriterium abbildet. Der Konfidenzterm Θ sorgt schließ-

lich dafür, dass in den Bereichen, die bereits vermessen wurden, keine neuen Messpunkte bestimmt werden. Die Erfahrung zeigt, dass im Rahmen der Parameteropti-

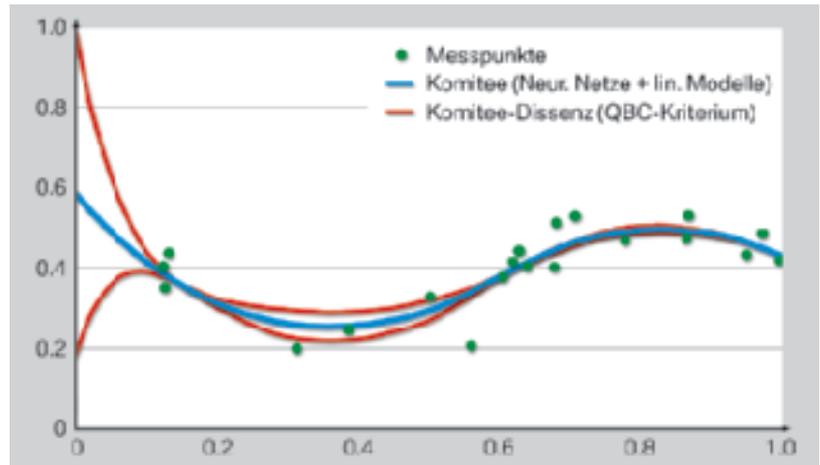


Bild 2: Modellausgabe eines Komitees aus neuronalen Netzen und linearer Regression – das QBC-Kriterium (Modellunsicherheit) liefert die größten Werte an den Stellen, wo die Einzelmodelle am meisten voneinander abweichen

Figure 2: Model output of a committee of neural networks and linear regression – the QBC criterion (model uncertainty) supplies the largest values to the points where the individual models diverge most

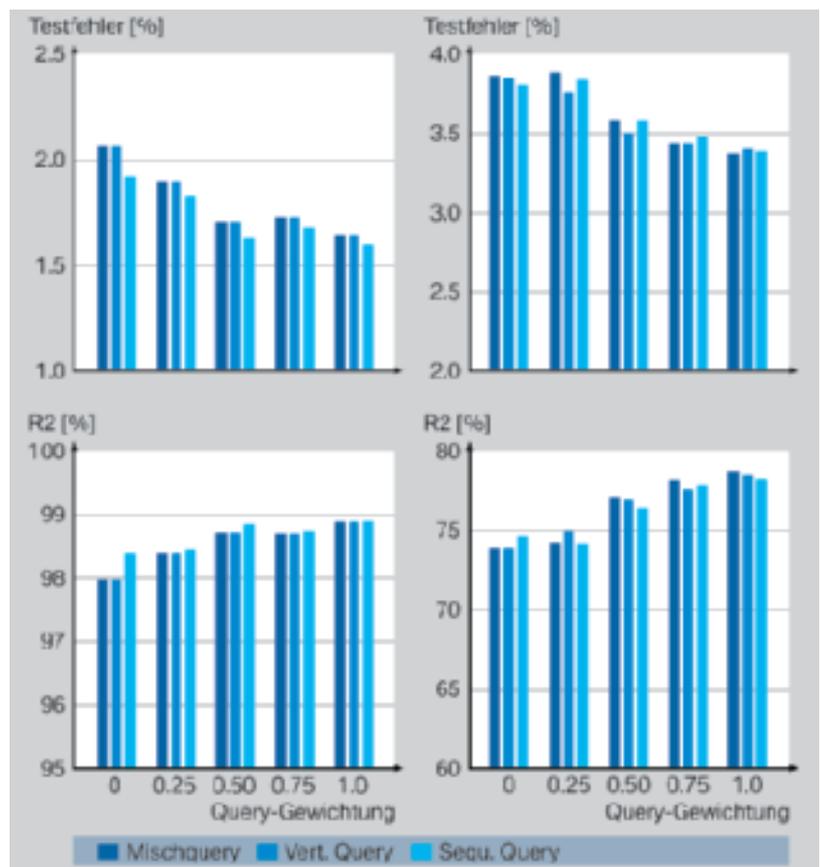


Bild 3: Testfehler (oben) und Bestimmtheitsmaß (unten) als Kennwerte für die Modellqualität der Zielgröße 1 (links) und 2 (rechts) für unterschiedliche Gewichtungsfaktoren

Figure 3: Test error (top) and degree of certainty (bottom) as characteristics of the model quality of target value 1 (left) and 2 (right) for different weighting factors

mierung Zielgrößen mit unterschiedlicher Komplexität existieren. Daher ist es sinnvoll, diese differenziert zu behandeln. Die Online-Optimierung bietet dabei die Möglichkeit, Schwächen in der Modellbildungsphase frühzeitig zu erkennen und entsprechend darauf zu reagieren.

Um das Query-Kriterium auf mehrere sekundäre Zielgrößen zu erweitern, bieten sich mehrere Alternativen an. Das Mischquery verrechnet die Varianzausgaben der unterschiedlichen Zielgrößen zu einem Gesamtkriterium, Gl. (2).

$$q_{gr}(x) = \left(\underbrace{q_{BC,1}(x)}_{\text{primäre Zielgröße}} \cdot \varphi \cdot w_1 + \sum_{i=2}^n \underbrace{q_{BC,i}(x)}_{\text{sekundäre Zielgrößen}} \cdot w_i \right) \cdot \Theta$$

Gl. (2)

mit $\sum_{i=1}^n w_i = 1$

Die Query-Gewichtung w_i legt hierbei den Einfluss des Einzelkriteriums i auf das Gesamtkriterium fest. Ein weiterer Ansatz ist das verteilte Query. Hierbei variiert die zu optimierende Zielgröße während eines Programmdurchlaufs mehrfach. Es wird stets nur eine Zielgröße zu jedem Zeitpunkt betrachtet, für die das Query-Kriterium gemäß Gl. (1) ausgewertet wird. Beim sequentiellen Query werden entsprechend der parametrisierten Zielgrößen mehrere Durchläufe nacheinander für je eine Zielgröße durchgeführt. Für die zwei zuletzt genannten Verfahren legt der Faktor w_i die Aufteilung der Messpunkte auf die einzelnen Zielgrößen fest.

Die Untersuchungen werden exemplarisch mit Referenzmodellen für zwei Zielgrößen durchgeführt, welche anhand von Prüfstandsdaten erstellt wurden. Zielgröße 1 beschreibt dabei als „gutmütige“ Funktion den spezifischen Kraftstoffverbrauch, Zielgröße 2 den relativ komplexen und damit schwierig zu modellierenden Verlauf der Varianz des indizierten Mitteldrucks des Motors. Beide Zielgrößen spannen einen fünfdimensionalen Variationsraum auf.

Bild 3 zeigt die Ergebnisse dieser Untersuchungen. Deutlich zu erkennen ist zunächst, dass Zielgröße 1 (links) stets besser modelliert wurde als Zielgröße 2 (rechts), auch wenn während der Optimierung das Query-Kriterium der zweiten Zielgröße bevorzugt verwendet wurde (Query-Gewichtung $< 0,5$ für Zielgröße 1 und Query-Gewichtung $> 0,5$ für Zielgröße 2). Bei der leicht zu modellierenden Zielgröße 1 erzielen alle vorgestellten Varianten des Query-Kriteriums ein sehr hohes Bestimmtheitsmaß, wobei das sequentielle Query aufgrund der separaten Betrachtung beider Zielgrößen zum Teil ein noch etwas besseres Ergebnis erreicht. So

mit hat der Anwender die Möglichkeit, die Zielsetzung je nach Anwendung zu spezifizieren und den erwünschten Einfluss der einzelnen Zielgrößen auf das Optimierungsziel zu parametrieren.

3.3 Analyse verschiedener Optimierungsstrategien

Im Zuge der Parameteroptimierung eines Verbrennungsmotors besteht die Aufgabe meistens darin, für einen bestimmten Betriebsbereich des Motors entsprechende Kennfelder zu erstellen. Das bedeutet, an verschiedenen festgelegten Betriebspunkten des Motors optimale Einstellungen der Variationsparameter zu finden. Damit stellt sich die Frage nach einer sinnvollen Optimierungsstrategie für diese Aufgabenstellung.

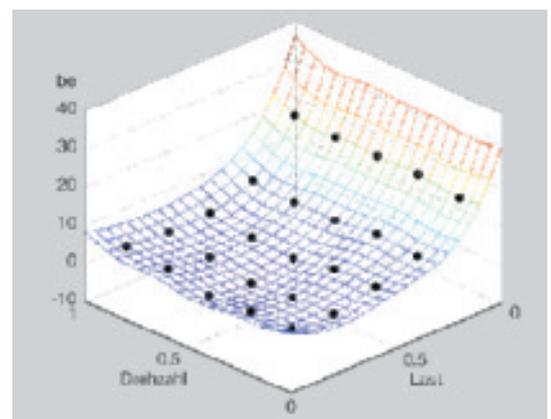
Die intuitivste und heute immer noch gebräuchliche Vorgehensweise ist die lokale Optimierung an den jeweiligen Betriebspunkten. Hierbei wird das Optimierungsproblem entsprechend in einzelne Teilprobleme für jeden Betriebspunkt separiert. Im Rahmen der modellbasierten Optimierung ist die Anzahl der Eingangsparameter des Modells gleich der Anzahl der Variationsparameter n_{VP} . Einen anderen Weg beschreibt die globale Optimierung. Hierbei werden die Betriebspunktgrößen Drehzahl und Last als normale Modellparameter betrachtet. Die Anzahl der Eingangsparameter des Modells ist hier um die Betriebspunktdimensionen n_{BP} erweitert. Eine Möglichkeit besteht darin, die Versuchspunkte auf die vorgegebenen Betriebspunkte zu verteilen. Die Alternative besteht in der freien Auswahl der Betriebspunktgrößen analog zu den Variationsparametern. Es stehen damit drei verschiedene Optimierungsansätze zur Verfügung: ein lokaler Ansatz sowie zwei globale mit und ohne festgelegte Betriebspunkte.

Für diese Untersuchung wird folgendes Szenario festgelegt: Ziel ist die Optimierung einer simulierten Verbrauchsfunktion an 25 Betriebspunkten. Die Funktion besitzt insgesamt $n_{Dim} = 4$ Eingangsdimensionen, somit $n_{BP} = 2$ Betriebspunktdimensionen und $n_{VP} = 2$ weitere Variationsparameter. Der Funktionsverlauf ist dem Verbrauchverhalten eines Verbrennungsmotors nachempfunden. Diese zeichnet sich durch einen dominanten Einfluss des zweiten Parameters aus, **Bild 4**.

Während des Prüfstandsbetriebs ergeben sich noch weitere Herausforderungen, welche das Optimierungsergebnis beeinflussen und in der Simulation behandelt werden sollen:

- Die Betriebspunkte werden am Prüfstand über entsprechende Regelsysteme eingestellt. Insbesondere die exakte Einstellung kleiner Lasten gestaltet sich aufgrund der Laufunruhe des Motors als schwierig. In dieser Untersuchung werden die Betriebspunktgrößen in mehreren Versuchen mit einem normalverteilten Rauschen mit maximal dreiprozentiger Standardabweichung versehen.
- Messungen der Zielgröße unterliegen einer gewissen Messunsicherheit. Die Zielgröße sowie die beiden restlichen Betriebspunktgrößen werden entsprechend mit einem einprozentigen Rauschen versehen. Interessant ist die Verifikationsrate der jeweiligen Optima an den einzelnen Betriebspunkten, **Bild 5**. Diese wird anhand der von „mbminimize“ ermittelten Modelloptima und der Referenzfunktion über mehrere unabhängige Versuche ermittelt. Sind die Betriebspunktgrößen unverrauscht (links), so ergeben sich für alle drei Optimierungsstrategien in weiten Bereichen Verifikationsraten von nahezu 100 %, mit leichten Nachteilen für die globale, betriebspunktlose Optimierung. Bei einem dreiprozentigen Rauschen der Betriebspunktgrößen (rechts) sin-

Bild 4: Verbrauchsfunktion mit den zu optimierenden Betriebspunkten über der Betriebs-ebene – dominant ist der Einfluss der Last als Variationsparameter, insbesondere im niedrigen Betriebsbereich
Figure 4: Fuel consumption function with the operating points to be optimised, over the operating plane – the influence of load as a variation parameter is dominant, particularly in the low operating range



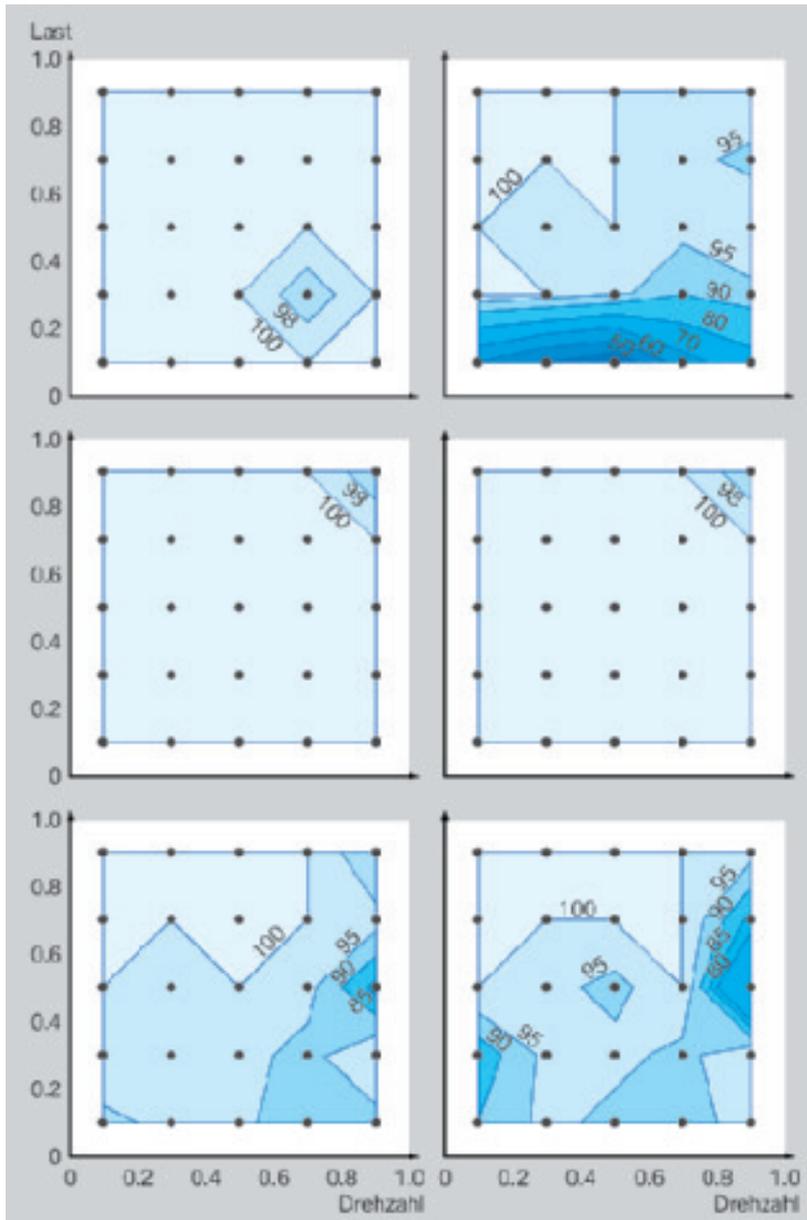


Bild 5: Verifikationsrate der Optima im Betriebsbereich bei unverrauschten Betriebspunktgrößen (links) und bei dreiprozentigem Rauschen der Betriebspunktgrößen (rechts) für die lokale (oben) beziehungsweise globale Optimierung mit und ohne festgelegte Betriebspunkte (Mitte und unten)

Figure 5: Verification rate of optimums in the operating range for noise-free operating point variables (left) and 3 % noise for operating point variables (right) for local (top) and global optimisation with and without defined operating points (centre and bottom)

ken die Verifikationsraten bei der lokalen Optimierung stellenweise unter 50 %. Die globale Vorgehensweise ist dort wesentlich robuster, die Verifikationsraten ändern sich deutlich weniger stark. Die globale Optimierung mit festgelegten Betriebspunkten zeigt hier das beste Ergebnis.

Die **Tabelle** zeigt relevante Kenngrößen in Abhängigkeit der Optimierungsstrategie und des Rauschens der Betriebspunktgrößen. Die Anzahl der Messpunkte steigt bei

der lokalen Optimierungsstrategie mit zunehmendem Rauschen deutlich an. Trotz dieser zusätzlichen Informationen nimmt die Generalisierungsfähigkeit des Modells deutlich ab, erkennbar an den ansteigenden Fehlerwerten beziehungsweise dem abfallenden Bestimmtheitsmaß.

Die beiden globalen Optimierungsstrategien benötigen deutlich weniger Messungen. Dies ist dadurch erklärbar, dass durch den globalen Modellansatz Nachbarschaftsbe-

ziehungen ausgenutzt werden. Die Modellqualität ist gemäß den Fehlerkennwerten sehr robust gegenüber Rauschen. Für die globale Optimierung ohne Betriebspunkte ergibt sich eine signifikant bessere globale Modellqualität als für die Variante mit festgelegten Betriebspunkten. Die Ursache liegt in der gleichmäßigeren Verteilung der Messungen, die sich nicht nur auf die festgelegten Betriebspunkte beschränken. Im Gegenzug erweist sich die globale Optimierung mit Betriebspunkten bei der Auswertung an letzteren als überlegen.

Als Ergebnis dieser Untersuchung ist festzuhalten, dass die lokale Optimierung für die Untersuchung einzelner Betriebspunkte bei korrekter Einstellung der Last oder in der Simulation, wo Ungenauigkeiten in der Lasteinstellung vernachlässigbar sind, geeignet ist. Die Optimierung ganzer Betriebsbereiche mit dieser Methode benötigt zu viele Messungen, was manchmal aufgrund des Versuchsprogramms jedoch nicht zu umgehen ist. Ein Beispiel dafür ist die in Abschnitt 4 vorgestellte Volllastoptimierung.

Die globale Optimierung ist gut geeignet zur Optimierung von Betriebsbereichen. Beim Verfahren mit Betriebspunkten ist die Modellqualität an den Betriebspunkten sehr gut; die betriebspunktlose Optimierung ist sehr gut für die globale Regression geeignet. Die erste Variante ist sinnvoll zur Kennfeldoptimierung an festen Stützstellen, letztere bei kontinuierlicher Auswertung des Modells.

4 Anwendungsbeispiele

In diesem Abschnitt werden zwei ausgewählte Anwendungen aus Simulation und Prüfstandsbetrieb vorgestellt. Damit soll die Vielseitigkeit des „mbminimize“-Algorithmus in der Antriebsentwicklung demonstriert werden.

Die optimale Ausführung von Sauganlagen und Ventiltrieb ist entscheidend zur Erzielung der gewünschten Drehmoment-beziehungswise Leistungscharakteristik von Saugmotoren. Für diese Aufgabenstellung kommen in der frühen Entwicklungsphase rechnergestützte Simulationswerkzeuge (CFD) zum Einsatz, die Vorausberechnungen mit einer guten Genauigkeit ermöglichen. Durch neue Entwicklungen hinsichtlich des Ventiltriebs und der Sauganlage nimmt die Anzahl der Freiheitsgrade stark zu. Konventionelle Methoden der Parameteroptimierung stoßen hierbei an ihre Grenzen. Diese Anwendung der Online-Optimierung hat daher zum Ziel, eine zeitsparende Grobauslegung der Sauganlage

gengeometrie durchzuführen. Das Optimierungsproblem wird dabei aufgeteilt: Im Drehzahlbereich von 3000 bis 5000/min steht das Erreichen maximalen Drehmoments im Vordergrund, für den Drehzahlbereich von 5000 bis 7500/min ist die maximale Leistung entscheidend. Als Optimierungsstrategie kommt die globale Optimierung ohne feste Betriebspunkte zum Einsatz, da das Modell kontinuierlich ausgewertet wird. Im Unterschied zu den Untersuchungen in Abschnitt 3.3 liegt bei der Volllastoptimierung mit der Drehzahl nur eine Betriebspunktdimension vor. Die Anzahl der Variationsparameter ergibt sich mit Saugrohrlänge (SRL) und -durchmesser (SRD), Einlassventilhub (EVH) und -öffnungsdauer (EVD) sowie Auslassventilhub (AVH) zu $n_{vp} = 5$. Mit der Drehzahl als Betriebspunktdimension ergibt sich daraus ein sechsdimensionaler Variationsraum.

Die Ergebnisse sind hier in Form von Nomogrammen dargestellt, aus denen die Saugrohrgeometrie ermittelt werden kann. Zur deren Erstellung werden für unterschiedliche Saugrohrgeometrien (SRL, SRD) und konstante Werte für EVD, EVH und AVH das maximale Drehmoment beziehungsweise die maximale Leistung mit der

dazugehörenden Drehzahl anhand der Modelle bestimmt. In den Nomogrammen ist jeweils ein Beispiel zur Auswertung eingezeichnet: Um ein maximales Drehmoment bei niedrigen Drehzahlen zu erreichen, sind relativ lange Saugrohre kleinen Durchmessers erforderlich, **Bild 6**. Soll maximale Leistung erzielt werden, ist die Auswahl kurzer Saugrohre großen Durchmessers sinnvoll, **Bild 7**. Bei anderen Drehmomentbeziehungsweise Leistungswerten kann entsprechend analog vorgegangen werden. Da das Systemverhalten des Motors in Form von Modellen vorliegt, können diese sehr flexibel vielseitig ausgewertet werden. Beispielsweise lassen sich auch (offline) Zielwertuntersuchungen durchführen.

Eine Prüfstandsanwendung stellt die Volllastoptimierung dar. Ziel ist es, das Drehmoment für ein vorgegebenes Drehzahlraaster zu maximieren. Die Anzahl der Variationsparameter beträgt mit den Spreizungen für Ein- und Auslassventil sowie dem Einlassventilhub $n_{vp} = 3$. Zündzeitpunkt und Luftverhältnis werden durch Regelsysteme am Prüfstand optimal hinsichtlich der Klopf- und Abgastemperaturgrenze eingestellt. Zudem ist die Berücksichtigung verschiedener Nebenbedin-

gungen erforderlich. Dazu zählen unter anderem die stetige Auslegung der Kennlinie für den Ventilhub, sowie die Vermeidung zu großer Gradienten in den Spreizungskennfeldern.

Zur Lösung dieser Aufgabe kommt die lokale Optimierung zum Einsatz. Aufgrund starker Inhomogenitäten der Füllung, verursacht durch Umschaltungen des Schaltsaugrohrs, ist eine globale Optimierungsstrategie, welche die Drehzahl als zusätzliche Variationsgröße mit einschließt, problematisch. Die Verbesserung des Drehmomentverlaufs gegenüber dem vorher bereits guten Applikationsstand zeigt **Bild 8**. Insbesondere im niedrigen Drehzahlbereich bei 2000/min konnte eine Verbesserung erzielt werden.

5 Zusammenfassung und Ausblick

In diesem Beitrag wurde beschrieben, aus welchem Hintergrund heraus und auf welche Weise die Neuerungen in „mbminimize“ umgesetzt wurden. Hauptmerkmale dabei sind die Modularisierung des Algorithmus sowie die Modellierung mehrerer Zielgrößen. Anwendungsbeispiele

Tabelle: Relevante Kenngrößen

Table: Relevant characteristics variables

Rauschen	0	0,5	1	2	3
lokale Optimierung					
Anzahl Messungen/Betriebspunkt	23	24	25	26	27
Anzahl Messungen gesamt	607	620	646	681	707
mittlerer Testfehler an den Betriebspunkten [%]	0,7	0,7	0,8	1,1	1,4
maximaler Testfehler an den Betriebspunkten [%]	1	1	1,4	2,4	3,2
Bestimmtheitsmaß an den Betriebspunkten [%]	95	94	92	87	81
globale Optimierung mit Betriebspunkten					
Anzahl Messungen/Betriebspunkt	9				
Anzahl Messungen gesamt	195	195	195	195	196
mittlerer Testfehler an den Betriebspunkten [%]	0,9	0,9	0,9	0,9	0,9
maximaler Testfehler an den Betriebspunkten [%]	1,2	1,3	1,3	1,2	1,2
Bestimmtheitsmaß an den Betriebspunkten [%]	93	93	93	93	92
mittlerer Testfehler global [%]	2,5	2,4	2,3	2	1,9
Bestimmtheitsmaß global [%]	97	97	98	98	98
globale Optimierung ohne Betriebspunkte					
Anzahl Messungen/Betriebspunkt	-				
Anzahl Messungen gesamt	195	195	195	195	195
mittlerer Testfehler an den Betriebspunkten [%]	1,1	1,2	1,1	1,2	1,2
maximaler Testfehler an den Betriebspunkten [%]	2,2	2,7	2,2	2,6	2,4
Bestimmtheitsmaß an den Betriebspunkten [%]	91	90	91	91	90
mittlerer Testfehler global [%]	1,2	1,2	1,2	1,2	1,3
Bestimmtheitsmaß global [%]	99	99	99	99	99

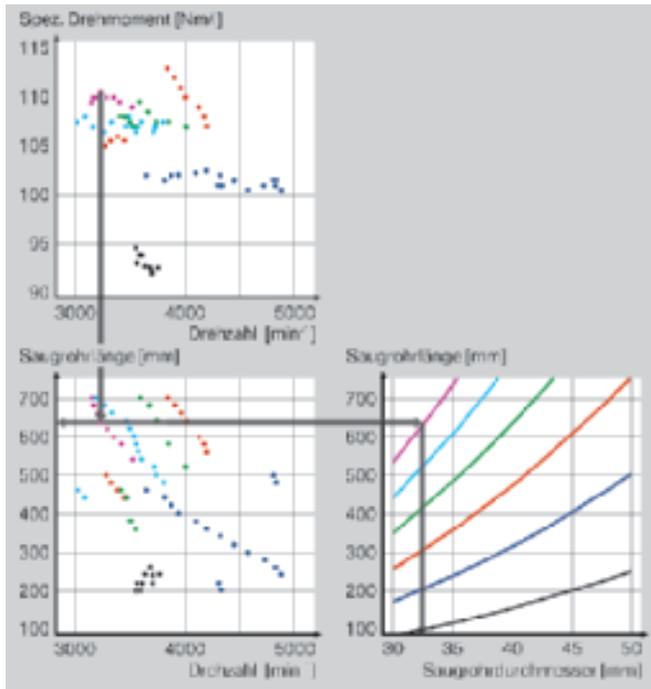


Bild 6: Nomogramm für das maximale Drehmoment. Für ein bestimmtes Drehmoment lassen sich Drehzahl, Saugrohrlänge- und Durchmesser bestimmen
Figure 6: Nomogram for maximum torque. The engine speed, intake manifold length and intake manifold diameter can be determined for a particular torque

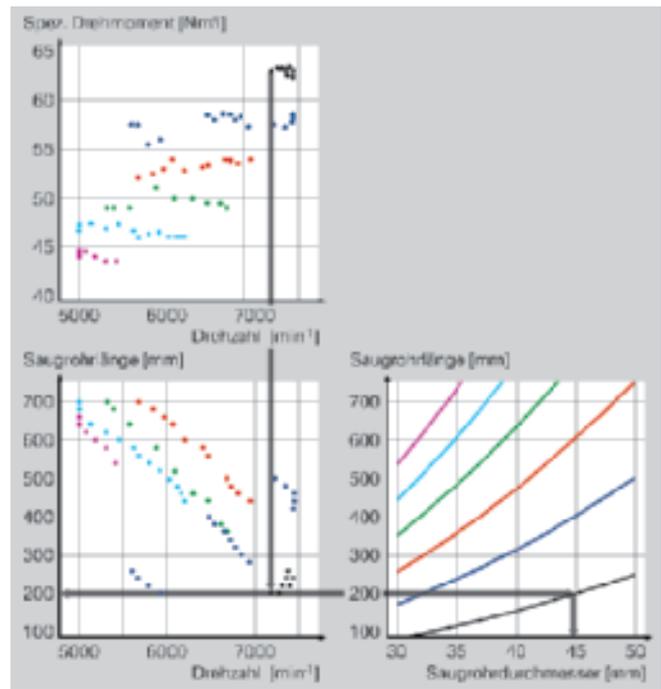


Bild 7: Nomogramm für die maximale spezifische Leistung
Figure 7: Nomogram for maximum specific output

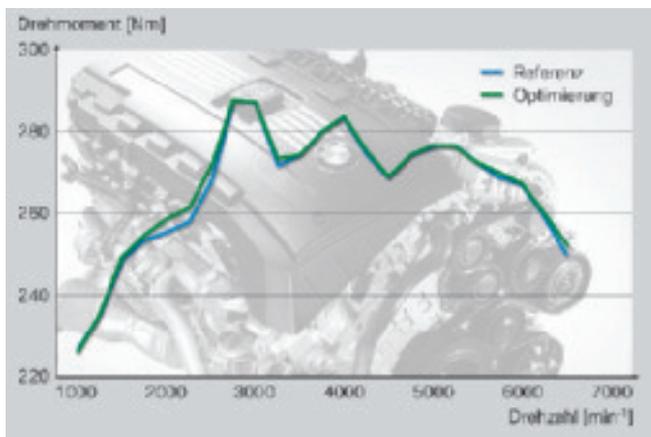


Bild 8: Volllastkurven für das Drehmoment; insbesondere im unteren Drehzahlbereich kann durch die Optimierung eine Verbesserung gegenüber dem bereits guten Referenzstand erzielt werden
Figure 8: Full-load curves for torque; particularly at lower engine speeds, optimisation yields improvements compared with the already good reference status

- [7] Knödler, K.; Poland, J.; Fleischhauer, T.; Mitterer, A.; Ullmann, S.; Zell, A.: Modellbasierte Online-Optimierung moderner Verbrennungsmotoren – Teil 2: Grenzen des fahrbaren Suchraums. In: MTZ 64 (2003), Nr. 6
- [8] Fischer M.; Röpk, K.: Effiziente Applikation von Motorsteuerungsfunktionen für Ottomotoren. In: MTZ 61 (2000), Nr. 9
- [9] Knödler, K.; Poland, J.; Zell, A.: Memetic algorithms for combinatorial optimization problems in the calibration of modern combustion engines. In: B. Langdon et al., editor, Proceedings of the Genetic and Evolutionary Computation Conference (GECCO), pp. 687, 2002
- [10] Poland, J.: Modellgestützte und Evolutionäre Optimierungsverfahren für die Motorentwicklung. Dissertation Universität Tübingen. Logos Verlag Berlin, ISBN 3-8325-0015-4, 2002
- [11] Isermann, R.; Hafner, M.; Müller, N.; Schüler, M.: Der Einsatz neuronaler Netze zur Modellierung, Steuerung und Regelung von Verbrennungsmotoren. 3. Stuttgarter Symposium Kraftfahrwesen und Verbrennungsmotoren, 23.-25. Februar 1999

sowohl aus der Simulation als auch aus der Praxis des Prüfstandsbetriebs stellen exemplarisch dar, wie der Algorithmus eingesetzt wird. In zukünftigen Projekten wird „mbminimize“ vielseitig eingesetzt werden und für weitere Optimierungsaufgaben zur Anwendung kommen.

Literaturhinweise

- [1] Hafner, M.; Schüler, M.; Isermann, R.: Einsatz schneller neuronaler Netze zur modellbasierten Optimierung von Verbrennungsmotoren – Teil 2: Stationäre und dynamische Optimierung von Verbrauch und Emissionen. In: MTZ 61 (2000), Nr. 11
- [2] Mitterer, A.: Optimierung vielparametrischer Systeme in der Kfz-Antriebsentwicklung. Dissertation, Technische

- Universität München. VDI Fortschritt-Berichte, Reihe 12 Nr. 434. Düsseldorf: VDI Verlag, 2000
- [3] Schüler, M.; Hafner, M.; Isermann, R.: Einsatz schneller neuronaler Netze zur modellbasierten Optimierung von Verbrennungsmotoren – Teil 1: Modellbildung des Motor- und Abgasverhaltens. In: MTZ 61 (2000), Nr. 10
- [4] Gschweilt, K.; Pfluegl, H.; Fortuna, T.; Leithgoeb, R.: Steigerung der Effizienz in der modellbasierten Motorenapplikation durch die neue Cameo-Online-DoE-Toolbox. In: ATZ 103 (2001), Nr. 7 und 8
- [5] Bredenbeck, J.: Statistische Versuchsplanung für die Online-Optimierung von Verbrennungsmotoren. In: MTZ 60 (1999), Nr. 11
- [6] Poland, J.; Knödler, K.; Fleischhauer, T.; Mitterer, A.; Ullmann, S.; Zell, A.: Modellbasierte Online-Optimierung moderner Verbrennungsmotoren – Teil 1: Aktives Lernen. In: MTZ 64 (2003), Nr. 5

For an English version of this article, see **MTZ worldwide**. For information on subscriptions, just call us or send an E-mail or fax.



MTZ Vieweg Verlag Postfach 1546 D-65173 Wiesbaden
 Tel. +49 5241 80-1988 | E-mail: vieweg@abo-service.info