

Wissensbasierte Optimierungsstrategien für elektronische Steuergeräte an Common-Rail-Dieselmotoren

vorgelegt von
Diplom-Ingenieur
Tino Naumann
aus Leipzig

Von der Fakultät V - Verkehrs- und Maschinensysteme
der Technischen Universität Berlin
zur Erlangung des akademischen Grades
Doktor der Ingenieurwissenschaften
- Dr.-Ing. -

genehmigte Dissertation

Promotionsausschuss:

Vorsitzender: Prof. Dr.-Ing. Helmut E. Siekmann
Berichter: Prof. Dr.-Ing. Helmut Pucher
Berichter: Prof. Dr. rer. nat. Volker Schindler

Tag der wissenschaftlichen Aussprache: 27.06.2002

Berlin 2002
D83

Vorwort

Diese Arbeit entstand im Rahmen meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Land- und Seeverkehr, Fachgebiet Verbrennungskraftmaschinen, der Technischen Universität Berlin.

Ganz besonderen Dank möchte ich Herrn Prof. Dr.-Ing. H. Pucher für seine fachliche und persönliche Unterstützung bei der Umsetzung dieser Arbeit sowie für die Übernahme des Hauptreferates aussprechen.

Mein Dank gilt Prof. Dr. rer. nat. V. Schindler für die Übernahme des Koreferates sowie Prof. Dr.-Ing. H. Siekmann für seine Bereitschaft zur Übernahme des Vorsitizes im Promotionsausschuss.

Des Weiteren gilt mein Dank Herrn Dipl.-Ing. R. Buck, der als Vorsitzender der AiF/FVV-Arbeitskreise *Dynamische Prozessoptimierung* und *Wissensbasis Dieselmotoren* durch vielfältige Diskussionen und Anregungen zum Gelingen dieser Arbeit beitrug.

Ganz besonders möchte ich meinen ehemaligen Kollegen und Mitarbeitern am Fachgebiet Verbrennungskraftmaschinen danken, die mit ihrer Kooperationsbereitschaft stets für ein angenehmes Arbeitsumfeld gesorgt haben. Herrn Dr.-Ing. M. Bauer danke ich für die hervorragende Zusammenarbeit bei der Durchführung des Forschungsprojektes *Dynamische Prozessoptimierung*. Wesentlich Beiträge zu dieser Arbeit lieferten die Studien- bzw. Diplomarbeiten von Dipl.-Ing. R. Berndt, Dipl.-Ing. M. Rächle, Dipl.-Ing S. Ilic und M. Augsburg, denen ich hiermit ausdrücklich danken möchte.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Optimierung von Motorsteuergeräten im Motorentwicklungsprozess . . .	1
1.2	Stand der Technik	3
2	Zielsetzung	7
3	Softwarestrukturen in elektronischen Motorsteuergeräten	9
3.1	Entwicklungsgeschichte	9
3.2	Regel- und Überwachungssysteme am Common-Rail-Dieselmotor . . .	12
3.2.1	Gemischaufbereitung	12
3.2.2	Diagnosesysteme	16
4	Optimierung des dieselmotorischen Gesamtprozesses	17
4.1	Definition der Prozessoptimierung	17
4.2	Modellmotoren und Versuchsumgebung	18
4.3	Multikriterielle Optimierungsziele und ihre mathematische Beschrei- bung	21
4.3.1	Zielkonflikte bei der dieselmotorischen Prozessoptimierung . .	21
4.3.2	Pareto-optimale Lösungsräume	23
4.3.3	Skalare Zielfunktionen	25
4.4	Stationäre Optimierung an Dieselmotoren	28
4.5	Dynamische Optimierung	30
4.5.1	Dynamischer Motorbetrieb	30
4.5.2	Lokale dynamische Optimierung	36
4.5.3	Globale dynamische Optimierung	37

4.5.4	Kennfelderweiterung zur Identifizierung dynamischer Motorbetriebsphasen	39
4.5.5	Potential der Kennfelderweiterung hinsichtlich einer Aufweichung des Optimierungsproblems	44
4.6	On- und Offline-Optimierung	51
5	Numerische Motormodelle zur Entwicklung und Verifizierung von Optimierungsstrategien	55
5.1	Übersicht	55
5.2	Statistische Versuchsplanung und RSM	57
5.2.1	Faktorielle Versuchspläne	57
5.2.2	Response-Surface-Methode (RSM)	60
5.3	Neuronale Netze als Prozessmodelle	64
5.3.1	Grundlagen	64
5.3.2	Netzarchitekturen	65
5.4	Physikalisch basierte Motorprozess-Simulation	68
5.5	Stationäre Motormodelle für den M47R	70
5.5.1	Polynommodelle auf Basis der statistischen Versuchsplanung	70
5.5.2	Auswahl geeigneter neuronaler Netze	72
6	Numerische Verfahren zur Prozessoptimierung	77
6.1	Klassifizierung	77
6.2	Hill-Climbing-Verfahren	81
6.2.1	Prinzip	81
6.2.2	Gradientenfreie und einfache gradientenbasierte Verfahren	86
6.2.3	Newton- und Quasi-Newton-Verfahren	87
6.2.4	Lösung von Problemen mit Nebenbedingungen durch SQP	89
6.3	Die Goal-Attainment-Methode zur multikriteriellen Optimierung	94
6.4	Methoden zur Optimierung dynamischer Prozessverläufe	95
6.5	Anwendung der Hill-Climbing-Verfahren zur stationären Optimierung	96
7	Wissensbasierter Fuzzy-Optimierungsansatz	101
7.1	Fuzzy-Strategien	101
7.1.1	Fuzzy-Logik	101

7.1.2	Fuzzy-Reglerstrukturen	104
7.1.3	Fuzzy-Diagnose und Fuzzy-Modellierung	106
7.2	Entwurf des Fuzzy-Interpreters zur Prozessoptimierung	107
7.3	Dieselmotoren-Wissensbasis als Grundlage für die Fuzzy-Regelbasis	108
7.3.1	Stationäre Common-Rail-Wissensbasis am Beispiel M47R	108
7.3.2	Anwendung der Wissensbasis auf andere Einspritzkonzepte	118
7.4	Potential des Fuzzy-Optimierers zur stationären Optimierung am Motormodell	119
7.4.1	Fuzzy-Optimierer mit einfacher Regelbasis zur SBPO	119
7.4.2	Fuzzy-Optimierer mit erweiterter Regelbasis	125
7.5	Erweiterung des Fuzzy-Optimierers für dynamische Optimierungsaufgaben	129
8	Automatisierungskonzepte zur wissensbasierten Online-Optimierung	131
8.1	Schnittstellen zu Motorenprüfständen	131
8.2	Online-Optimierungssystem DOMAIN III	133
8.2.1	Online-Systemkonzept	133
8.2.2	Implementierung des wissensbasierten Optimierers	134
9	Zusammenfassung	135

Abbildungsverzeichnis

1.1	Funktionsentwicklung und -optimierung für Motorsteuergeräte entlang des Design-V	2
1.2	Konventionelle Ladedruckregelung	4
3.1	Entwicklung der Parameteranzahl in elektronischen Motorsteuergeräten	11
3.2	Motormanagement für das Bosch Common-Rail-System der 1. Generation	13
3.3	Einfluss der Voreinspritzung auf Druckverlauf, Brennverlauf und Durchbrennfunktion beim M47R	15
4.1	Grundprinzip der schrittweisen Parameteroptimierung	18
4.2	MSR-Stellen am Versuchsmotor OM441 LA	19
4.3	Hardware-Architektur der Prüfstandssteuerung	20
4.4	$PM-NO_x$ -Trade-Off und legislative Grenzwertstufen am Beispiel Nutzfahrzeugemissionen	22
4.5	Lösungsraum für ein 2-dimensionales Minimierungsproblem	24
4.6	Skalare Zielfunktionen für konkave Lösungsräume	27
4.7	Beispiel eines stationären Optimierungslaufes	29
4.8	Verwendeter Testzyklus	30
4.9	Potential der dynamischen Optimierung im Vergleich zur Optimierung bei quasistationärer Betrachtungsweise	31
4.10	Rastervermessung stationärer Betriebspunkte am OM441 LA	32
4.11	Stationär optimierte Führungsgrößen-Kennfelder	33
4.12	Vergleich „lokale“ und „globale“ Optimierung	35
4.13	Rückrechnung der Messwerte auf Führungsgrößen-Stützstellen	36
4.14	Zyklusbewertung mit lokalen und globalen Messgrößen	38

4.15	Ablauf der Kennfeldoptimierung bei globaler Zyklusbewertung (schematisch)	39
4.16	Dynamische Motorbetriebsphasen im stationären Motorkennfeld	40
4.17	Kennfelderweiterung	41
4.18	Einfluss der Wandtemperatur auf den Motorwirkungsgrad	42
4.19	Korrelation zwischen Wandtemperatur und Drehmomentgradienten	43
4.20	Untersuchte Lastrampen	44
4.21	Vergleich realer und simulierter Emissionswerte	45
4.22	Untersuchte EB- und VTG-Sollwertverläufe	46
4.23	Verlauf von NO_x -Emission und Opazität bei Lastgradienten	46
4.24	Kumulierte Emissionen bei positivem Lastgradienten	47
4.25	Kumulierte Emissionen bei negativem Lastgradienten	48
4.26	b_e - NO_x -Trade-Off für die untersuchten Lastrampen	49
4.27	Emissionsverläufe bei verschiedenen VTG-Stellstrategien	50
4.28	Kumulierte Emissionen bei unterschiedlichen VTG-Stellstrategien	51
4.29	Online- und Offline-Optimierung zur Entwicklung von Optimierungsstrategien	52
5.1	Versuchsbasierte Motormodelle	56
5.2	Beispiele für vollständige Versuchspläne	58
5.3	Neuronales Netz mit einer Zwischenschicht und linearem Ausgangs-Neuron (5-9-1-Netz) als Stickoxid-Modell	65
5.4	Beispiele für mögliche Aktivierungsfunktionen	66
5.5	Überschneidung der Basisfunktionen für MLP- und RBF-Netze am Beispiel eines zweidimensionalen Eingangsvektors	67
5.6	Ergebnisse einer dynamischen Simulationsrechnung	69
5.7	Modellfehler und Cox-Box-Diagramm für das NO_x -Modell	71
5.8	Optimierungsraum nach Polynommodell, Betriebspunkt $n = 2250 \text{ min}^{-1}$, $M = 105 \text{ Nm}$	72
5.9	GUI des grafischen Modellierungs- und Visualisierungs-Tools auf MATLAB-Basis	74
5.10	Modellvergleich entlang eines 2-D-Kennfeldschnittes bei $n = 2250 \text{ min}^{-1}$, $M = 80 \text{ Nm}$, $HEB = 0^\circ \text{ KW}$ (rel. zur Serie), $VEM = 2 \text{ mm}^3$	75

6.1	Klassifizierung numerischer Optimierungsstrategien	78
6.2	Fallunterscheidung beim Liniensuchverfahren der kubischen Interpolation	83
6.3	Fallunterscheidung beim Liniensuchverfahren der gemischten Interpolation	85
6.4	Vergleich der Suchverfahren <i>Sukzessive Variation der Variablen</i> und <i>Methode des steilsten Abstiegs</i> für ein 2-dimensionales Optimierungsproblem ohne Beschränkungen	87
6.5	Optimierungstrajektorien von Quasi-Newton- und Goal-Attainment-Verfahren bei SBPO	98
6.6	Differenzenkenfelder ZQBPO-ZQKFO, Quasi-Newton-Verfahren, Startvektor [5 4 800] für alle Kennfeldstützstellen	99
7.1	Unschärfe Darstellung durch linguistische Terme am Beispiel Haupteinspritzbeginn	102
7.2	Abbildung unscharfer Zusammenhänge mittels Fuzzy-Inferenz	104
7.3	Struktur eines Fuzzy-Regelmechanismus	105
7.4	Aufbau des Fuzzy-Optimierungssystems	108
7.5	Schadstoffemissionen bei Variation der Piloteinspritzung im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$	110
7.6	Abhängigkeit des maximalen Zylinderdruckgradienten von der Piloteinspritzung im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$	111
7.7	4-Quadranten-Diagramm der Schadstoffemissionen bei Variation des Raildruckes im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$	112
7.8	$b_e - NO_x$ -Trade-Off bei Variation des Raildruckes im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$	113
7.9	Geräuschentwicklung in Abhängigkeit des Raildruckes im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$	113
7.10	4-Quadranten-Diagramm der Schadstoffemissionen bei Variation der Abgasrückführtrate im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$	114
7.11	4-Quadranten-Diagramm der Schadstoffemissionen bei Variation des Raildruckes im Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$	115
7.12	$b_e - NO_x$ -Trade-Off bei Variation des Raildruckes im Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$	116
7.13	$b_e - NO_x$ -Trade-Off bei Variation des Ladedruckes im Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$	116
7.14	Ein- und Ausgangsgrößen des Fuzzy-Inferenzalgorithmus zur SBPO	119

7.15	Zugehörigkeitsfunktionen der verwendeten unscharfen Ein- und Ausgangsgrößen	120
7.16	Beispiel einer Inferenz-Bildung im Fuzzy-Optimierer	122
7.17	Ausgewählte Regelflächen für den SBPO-Fuzzy-Optimierer	123
7.18	Vergleich der Optimierungsläufe von Hill-Climbing-Verfahren und wissensbasiertem Ansatz im stationären Betriebspunkt	124
7.19	Struktur der Offline-Fuzzy-Optimierung mit Erweiterung zur ZQBPO	125
7.20	Regelflächen des Fuzzy-Interpreters zur Ermittlung lokaler NO_x/PM -Grenzwertvektoren	126
7.21	Pareto-optimale Ergebnisse der globalen Optimierung und dazugehörige optimale Führungsgrößen-Kennfelder für Quasi-Newton-Verfahren und Fuzzy-Optimierer	128
8.1	Standardisierte Schnittstellen für Systeme zur Motorenprüfung	132
8.2	Benutzeroberfläche von DOMAIN III	133
8.3	MATLAB [®] -Schnittstelle des Optimierungssystems	134

Tabellenverzeichnis

3.1	Meilensteine der Entwicklung elektronischer Steuergeräte	10
4.1	Technische Daten der verwendeten Modellmotoren	18
4.2	Vergleich der zyklusspezifischen Ergebnisse bei Verwendung unterschiedlicher Testzyklen mit b_e - und NO_x -optimalen Führungsgrößen-Kennfeldern	35
4.3	Vor- und Nachteile verschiedener Optimierungsansätze	54
5.1	Beispiel einer Matrix der unabhängigen Faktoren eines unvollständigen Versuchsplans	59
5.2	Nicht vermengte Effekte beim unvollständigen Versuchsplan	60
5.3	Parameterraum der Motorvermessung, M47R	70
5.4	Kenngrößen des erstellten Versuchsplans	70
5.5	Kenngrößen der erstellten Polynommodelle	71
5.6	Kenngrößenvergleich aller untersuchten stationären Motormodelle	73
6.1	Mathematische Fallbehandlung bei der kubischen Liniensuche	84
6.2	Mathematische Fallbehandlung bei der gemischten Liniensuche	86
6.3	Auswahl geeigneter Optimierungsverfahren	96
6.4	Optimierungsergebnisse mit Hill-Climbing Verfahren	97
7.1	Linguistische Prozess-Zusammenhänge für den M47R im Teillast-Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$	117
7.2	Linguistische Prozess-Zusammenhänge für den M47R im Volllast-Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$	117
7.3	Vergleich der Ergebnisse des untersuchten Einspritzsystems mit Angaben in der Literatur zu anderen Systemen	118
7.4	Regelbasis des Fuzzy-Interpreters zur SBPO	121

7.5	Zusätzliche Regeln zur Verbesserung des Konvergenzverhaltens des Optimierers	123
7.6	Vergleich der Ergebnisse zwischen Hill-Climbing- und Fuzzy-Optimierung	127

Formelzeichen, Indizes und Abkürzungen

Formelzeichen		
<i>ABHE</i>	$^{\circ}KW$	Ansteuerbeginn Haupteinspritzmenge
<i>ABVE</i>	$^{\circ}KW$	Ansteuerbeginn Voreinspritzmenge
b_e	g/kWh	effektiver spezifischer Kraftstoffverbrauch
c	-	Zentrum der RBF-Neuronen
<i>CO</i>	g/kWh	spezifische CO-Emission
d	-	Anzahl berücksichtigte Prozessgrößen
<i>EB</i>	$^{\circ}KW$ -	Einspritzbeginn (OM441 LA, keine Piloteinspritzung)
F	-	Zielfunktion
F	-	skalare Zielfunktion
G	-	skalare Nebenbedingungs-Funktion
G'	kg/h	Abgasmassenstrom
h	-	relative Häufigkeit
H	-	Hypothese (SVP)
H	-	Hessematrix
<i>HC</i>	g/kWh	spezifische HC-Emission
<i>HEB</i>	$^{\circ}KW$	Haupteinspritzbeginn (= ABHE)
I	-	Identität des Versuchsplans (SVP)
k	-	Reduktionsmaß des unvollständigen Versuchsplans (SVP)
L	-	Lösungstyp des Versuchsplans (SVP)
M	Nm	Motordrehmoment
m	-	Anzahl Nebenbedingungen
m_B	kg	kumulierte Kraftstoffmasse
\dot{m}_B	kg/h	Kraftstoffmassenstrom
n	min^{-1}	Motordrehzahl

n	-	Anzahl Führungsgrößen, Anzahl Versuche (SVP)
NO_x	g/kWh	spezifische Stickoxid-Emission
\mathbf{p}	-	Prozessgrößen-Vektor
\mathbf{pt}	-	Zielgrößen-Vektor
p	-	Anzahl der Faktoren bzw. Vertrauensintervall einer Hypothese (SVP)
p_{me}	bar	effektiver Mitteldruck
p_L	bar	Ladeluftdruck
PM	g/kWh	spezifische Partikelmassen-Emission
p_{zmax}	bar	maximaler Zylinderdruck
p_{Rail}	bar	Raildruck
R^2	-	Bestimmtheitsmaß (SVP)
S	-	empirische Varianz (SVP)
S^2	-	empirische Standardabweichung (SVP)
S	-	Optimierungsdurchlauf
s	-	Anzahl Optimierungsläufe
SA	°KW	Abstand Voreinspritzung-Haupt einspritzung
SZ	-	Schwärzungszahl nach Bosch
u	-	Hilfsvariable
\mathbf{v}	-	Suchrichtung
VEM	mm ³	Voreinspritzmenge
\mathbf{w}	-	Wichtungsfaktor
\mathbf{x}	-	Führungsgrößen-Vektor
$\mathbf{x}^{(i)}$	-	Führungsgrößen-Vektor nach Hauptiteration i
\mathbf{x}_j	-	Führungsgrößen-Vektor nach Liniensuch-Iteration j
y	-	Systemantwort
\hat{y}	-	Modellantwort
γ	-	Schrittweite
δ	-	Varianz
δ^2	-	Standardabweichung
λ	-	Lagrange-Faktor
Λ	-	Lösungsraum
∇	-	Nabla-Operator
Φ	-	Basisfunktion
$\hat{\Theta}$	-	Schätzvektor des Regressionsmodells

$\hat{\theta}$	-	Element des Schätzvektors
Ω	-	Raum zulässiger Führungsgrößen-Vektoren

Indizes und Abkürzungen

<i>(h)</i>		versteckte Schicht (Hidden Layer)
<i>KF</i>		Kennfeld
<i>LOF</i>		lack of fit
<i>M</i>		Modell
<i>(o)</i>		Ausgangs-Schicht (Output Layer)
<i>PE</i>		pure error
<i>RES</i>		residual
<i>rek</i>		rekonstruierte Größe
<i>s</i>		signifikante Faktoren
<i>SVP</i>		Statistische Versuchsplanung
<i>v</i>		Beobachtung einer Faktorkombination
<i>z</i>		Faktorkombination
<i>Zyklus,</i> <i>Zyk</i>		kumulierte Zyklusgröße

Kapitel 1

Einleitung

1.1 Optimierung von Motorsteuergeräten im Motorentwicklungsprozess

Bei der Weiterentwicklung von Verbrennungsmotoren spielt seit jeher der Einsatz moderner Regelungstechnik eine herausragende Rolle. Die Notwendigkeit einer kontinuierlichen Herabsetzung des spezifischen Kraftstoffverbrauchs bei gleichzeitiger Einhaltung ständig schärferer legislativer Emissionsgrenzwerte erzwang eine permanente Verbesserung der regelungstechnischen Strukturen am Verbrennungsmotor. Bestand bei den ersten Verbrennungsmotoren die eingesetzte Regelungstechnik lediglich aus einem mechanischen Fliehkraftregler für die Leerlauf- bzw. Vollastregelung, so gehören heute elektronische Motorsteuergeräte zur Regelung, Steuerung und Überwachung des Einspritzsystems, des Ventiltriebs, der Ladeluftstrecke und im zunehmenden Maße auch der Abgasnachbehandlungssysteme zur notwendigen Standardausrüstung von Verbrennungsmotoren im Fahrzeugeinsatz. Solche komplexen Steuergeräte sind mikroprozessorgesteuert und werden auf Grund ihrer multifunktionalen Eigenschaften auch als Motormanagementsysteme bzw. Engine Control Units (ECU) bezeichnet. Über entsprechende Bussysteme wird der Informationsaustausch mit anderen elektronischen Fahrzeugkomponenten, wie z. B. Getriebesteuergerät (TCU¹) und Steuergerät für den vollelektrischen Ventiltrieb (VCU²) sichergestellt. Derzeitige Entwicklungen sehen zusätzlich ein übergeordnetes Antriebsstrang-Management³ vor, welches das Zusammenspiel der untergeordneten Systeme steuert und überwacht. Eine herausragende Rolle innerhalb dieser vernetzten Struktur nimmt nach wie vor die ECU ein, da sie die Funktionen zur Sicherstellung eines emissionsarmen und dennoch kundentauglichen Betriebs des Verbrennungsmotors über den gesamten Motorlebenszeitraum enthält. Im Rahmen der Motorentwicklung sind sowohl Hard- als auch Softwarestrukturen solcher Motormanagementsysteme fest-

¹Transmission Control Unit

²Valve Control Unit

³z. B. Integrated Power Management nach [73]

zulegen und zu bedaten. Dieser Entwicklungsprozess erfolgt entlang der Design-V-Kurve, die in **Abb. 1.1** exemplarisch für die Funktionsentwicklung in Steuergeräten dargestellt ist. Der Entwicklungsingenieur wird in allen Entwicklungsschritten von leistungsfähigen CAX-Tools unterstützt. Dabei spielt die Simulation des realen Motorverhaltens eine herausragende Rolle. Je nach Anwendungsfall und geforderter Qualität werden dazu einfache, aber echtzeitfähige Modelle mit eher qualitativem Charakter (Kennfeldmodelle, künstliche neuronale Netze [87, 88, 5]) oder sehr genaue physikalische Prozessmodelle, wie PROMO [7], THEMOS [11, 90] oder FIRE [62] eingesetzt, die Ladungswechsel-, Gemischbildungs- und Verbrennungsvorgänge auf Basis von konstruktiven Motordaten schon in einer sehr frühen Phase der Motorentwicklung vorausberechnen können. Funktionen und Regelkreise können somit parallel zur Entwicklung des Motors entstehen, weiterentwickelt und optimiert werden.

Mit den Methoden Model in the Loop (MiL), Software in the Loop (SiL) und Hardware in the Loop (HiL) wird es möglich, die Steuergeräte-Soft- und -Hardware quasi parallel zur mechanischen Motorentwicklung voran zu treiben [47]. Ein zusammenhängender Funktionstest von Motor und Steuergerät am Motorenprüfstand kann dann direkt ohne Aufschubzeit nach Fertigung eines Motor-Prototypen erfolgen.

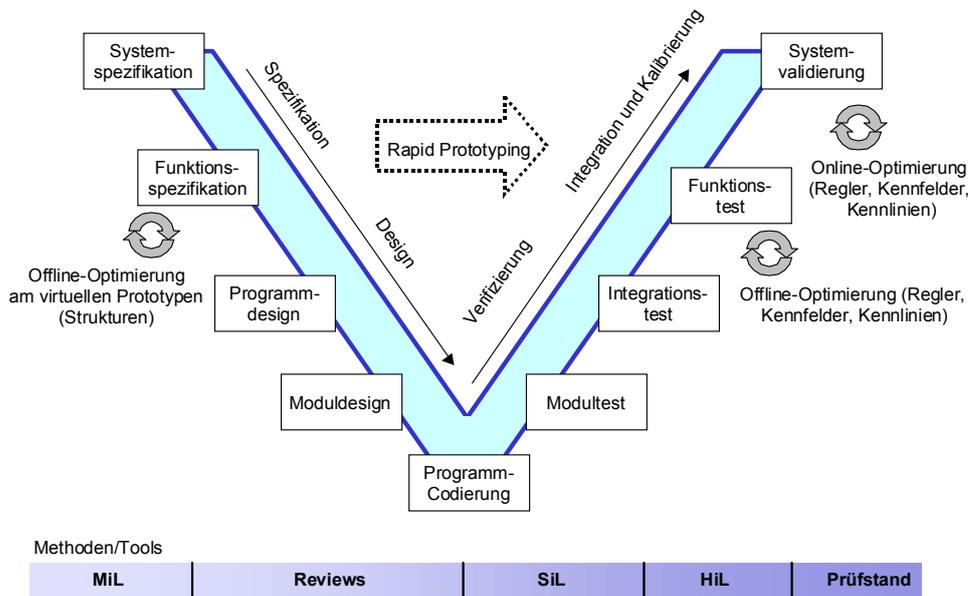


Abb. 1.1 Funktionsentwicklung und -optimierung für Motorsteuergeräte entlang des Design-V, nach [6, 91]

Trotz einer stetigen Verbesserung der Genauigkeit der Simulations-Tools ist es mit heutigen Programmsystemen nicht möglich, das zu erwartende Motoremissionsverhalten, insbesondere die Stickoxid- und Partikelemissionen, hinreichend genau voraus zu berechnen. Aus diesem Grund muss eine Struktur und Parameteroptimierung der verbrennungsbeeinflussenden Steuergerätefunktionen am Motorenprüfstand

oder im realen Fahrzeugeinsatz erfolgen. Zur Bedatung bzw. Optimierung der freien Parameter eines modernen Steuergerätes am Prüfstand (man spricht hier auch von Steuergeräte-Applikation), bedarf es erfahrener Applikationsingenieure, denen motortechnische Zusammenhänge bekannt sind und die bestehende Zielkonflikte in einem vertretbaren Zeitrahmen lösen können.

Auch bei diesem Prozess kann Prüfstandszeit effektiv genutzt werden, indem aus realen Messdaten am Prüfstand Modelle für den prozesstechnischen Einfluss der zu optimierenden Führungsgröße erstellt werden und anhand dieser Modelle die Parameteroptimierung durchgeführt wird. Man spricht dann von einer Offline-Optimierung. In der Praxis muss anschließend das Optimierungsergebnis am Motorenprüfstand überprüft und gegebenenfalls im Rahmen einer Online-Optimierung verbessert werden. Für beide Verfahren, Online- und Offline-Optimierung (vgl. **Abb. 1.1** auf der vorherigen Seite), existieren bereits entsprechende Software-Tools, mit denen sich einfache Applikationsaufgaben automatisieren lassen. Eine vollautomatisierte Bedatung des Steuergerätes ist jedoch auch mit diesen Hilfsmitteln nicht möglich. Einen weiteren Schritt in Richtung einer vollautomatischen Steuergeräte-Applikation stellt ein Optimierungssystem dar, welches auf das Motorwissen des Applikationsingenieurs zurückgreifen kann.

1.2 Stand der Technik

In elektronischen Motormanagementsystemen für Fahrzeuge (ECU, VCU, etc.) werden Führungsgrößen-Kennfelder vorgehalten, aus denen die entsprechenden Regelgrößen, z. B. Einspritzbeginn, Ladedruck, Abgasrückführtrate, interpoliert werden. Als Führungsregler arbeitende PID-Algorithmen sorgen für die Einstellung und Einhaltung der Sollwerte. Eine Adaption der Führungsgrößen im dynamischen Motorbetrieb wird teilweise über so genannte Vorsteuerfunktionen bzw. -kennfelder realisiert, womit der Motorprozess auf die Besonderheiten des dynamischen Betriebs abgestimmt werden kann. **Abb. 1.2** auf der nächsten Seite zeigt exemplarisch die prinzipielle Struktur eines solchen Stell- und Regelmechanismus für den Ladedruck eines Dieselmotors.

Der Entwicklungsingenieur steht nun vor der Aufgabe, sowohl die Stützstellen der Führungsgrößen-Kennfelder als auch die Reglerparameter der nachgeschalteten Führungsregler so aufeinander abzustimmen, dass sich ein stets optimales Prozessverhalten im Sinne einer gegebenen Betriebsstrategie⁴ für den Verbrennungsmotor ergibt, [36]. Ein solches Vorgehen, manuell oder automatisiert durchgeführt, wird üblicherweise als Steuergeräte-Optimierung bzw. -Applikation bezeichnet. Bei der Formulierung des Optimierungsziels müssen heute neben der Forderung nach einer Reduktion von Schadstoffkomponenten im Abgas bei gleichzeitiger Erhöhung des Motorwirkungsgrades beispielsweise auch Grenzwerte für Geräuschemissionen

⁴Betriebsstrategie und Optimierungsziel sind im Allgemeinen identisch, z. B. minimaler Kraftstoffverbrauch bei Einhaltung von Emissionsgrenzwerten in einem gegebenen Testzyklus.

und Fahrbarkeitskriterien Berücksichtigung finden.

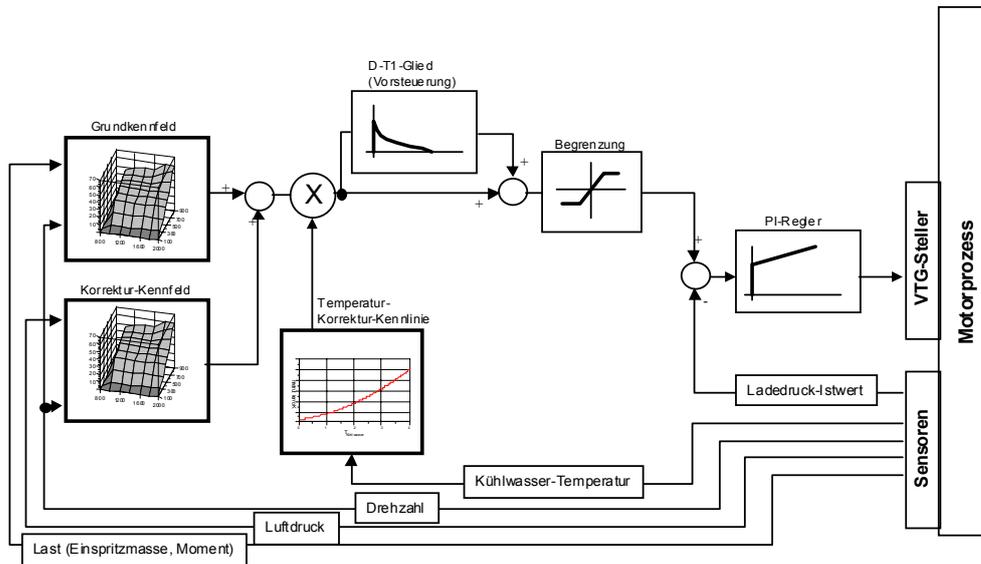


Abb. 1.2 Ladedruckregelung mit Sollwertvorgabe aus Kennfeldern in einer ECU

Auf Grund der erweiterten Parametriermöglichkeiten moderner Einspritzsysteme und der damit verbundenen Komplexität bei der mehrzieligen Optimierung der Steuerdatensätze gewinnen zunehmend automatische Kennfeld-Optimierungssysteme an Bedeutung [17], [13]. Bereits 1992 wurden in [37] Ansätze für ein solches Optimierungssystem vorgestellt. Heute teilen sich die kommerziellen Softwarepakete CA-MEO, als Erweiterung der AVL-Prüfstandsautomatisierung PUMA und das System VEGA der Schenck-Pegasus GmbH den Markt. CAMEO beinhaltet neben der Offline-Kennfeldoptimierung auch Parametrierfunktionen für Regler unter Berücksichtigung physikalischer Streckenmodelle, VEGA kann hingegen auch eine Online-Optimierung am Motorenprüfstand durchführen. Die genannten Systeme verwenden als Optimierungsstrategien Gradientensuchverfahren für die lokale und die globale Optimierung⁵ Bedingt durch die recht unflexible Struktur der verwendeten Algorithmen sind sie zum jetzigen Zeitpunkt nicht in der Lage, komplexe Optimierungsaufgaben befriedigend zu lösen.

In den letzten Jahren wurden zunehmend gänzlich neue Ansätze für die optimale Regelung und Steuerung des Motorbetriebs vorgestellt. Dazu zählen modellbasierte Regler, [25, 28, 33, 38], (dynamische) neuronale Netze, [30], und optimale Mehrgrößenregler, [86]. Diese Methoden betrachteten bisher, losgelöst vom Gesamtprozess, nur Teilaspekte der Optimierung des Gesamtsystems Verbrennungsmotor. Die Berücksichtigung von Emissionsgrenzwerten spielte hierbei eine untergeordnete Rolle. Ziel dieser Untersuchungen war es, die Kennfeldsteuerung durch geschlossene

⁵lokale Optimierung: Optimierung des Parametersatzes für einen stationären Motorbetriebspunkt (definiert durch Drehzahl und Last); Globale Optimierung: Optimierung eines ganzen Bereichs des Motorkennfeldes auf Basis eines globalen Optimierungsziels, meist unter Annahme der Quasi-Stationarität und lokaler Optimierung entlang eines Kennfeldrasters

robuste Regelkreise zu ersetzen und somit den Applikationsaufwand zu verringern. Die Vorteile dieser Ansätze zur nichtlinearen Regelung des turboaufgeladenen Dieselmotors konnten für die Leerlaufregelung in [32] und die Regelung des Ladedruckes in Verbindung mit einer Abgasrückführung in [69, 81, 31] aufgezeigt werden. In [46] werden künstliche neuronale Netze zur selbstadaptiven dynamischen Mengenregelung für den Ottomotor herangezogen. Trotz des erfolgreichen Einsatzes kennfeldfreier Strukturen in Teilbereichen des Motormanagements sprechen grundsätzlich folgende Aspekte für die Beibehaltung der Führungsgrößen-Kennfelder mit anschließender Folgeregelung, die auch die Basis für die hier vorgestellte Arbeit bilden:

- Kennfelder sind übersichtliche Datenstrukturen, die einfach appliziert werden können. Zudem sind die zu erwartenden Verläufe der entsprechenden Stellgrößen leicht abschätzbar.
- Die Regelung von Abgaskomponenten setzt die Verfügbarkeit von zuverlässigen selektiven Gassensoren voraus, deren Einsatz bisher weder für den täglichen Fahrzeugbetrieb ausreichend erprobt noch unter wirtschaftlichen Gesichtspunkten vertretbar ist.
- Die Modellierung des Gesamtsystems Verbrennungsmotor ist eine hochkomplexe Aufgabe. Es existieren heute keine einsetzbaren echtzeitfähigen Modelle, welche das Emissionsverhalten des Motors hinreichend genau abbilden können. Diese wären jedoch für die Übertragung modellbasierter Regelungsalgorithmen auf den Gesamtprozess notwendig.

Anzumerken ist weiterhin, dass auch die in diesem Kapitel genannten nichtlinearen Regelungsalgorithmen hinsichtlich ihrer Struktur und ihrer Parameter optimiert werden müssen. Obwohl sich dafür analytische Verfahren anbieten - ein hinreichend genaues Streckenmodell ist prinzipbedingt vorhanden - können auch die in dieser Arbeit vorgestellten schrittweisen Optimierungsverfahren für eine effiziente Parameteroptimierung Verwendung finden. Das gilt insbesondere dann, wenn eine mathematisch-analytische Lösung des Optimierungsproblems nicht oder nur mit großem Aufwand möglich ist. Auch für die Optimierung von Diagnosestrukturen, wie sie in [39] und [29] vorgestellt wurden, ist der Einsatz der im Verlauf dieser Arbeit aufgezeigten Algorithmen zur Prozessoptimierung denkbar.

Kapitel 2

Zielsetzung

Ziel der hier vorgestellten Arbeit ist die Entwicklung eines Verfahrens zur Optimierung von Führungsgrößen-Kennfeldern aufgeladener Dieselmotoren. Dabei soll im Vergleich zu bisher verwendeten automatischen Kennfeld-Optimierungssystemen eine schnellere und effizientere Online-Optimierung insbesondere von vielparametrischen Einspritzsystemen direkt am dynamischen Motorenprüfstand möglich werden. Zugleich wird gefordert, neben dem stationären auch das dynamische Prozessverhalten in den Optimierungsprozess einzubeziehen.

Motivation für die Suche nach neuen Optimierungsverfahren ist die Tatsache, dass sich mit gradientenbezogenen bzw. gradientenfreien Strategien eine mehrzielige Online-Optimierung vielparametrischer Systeme nicht mehr effizient am Motorenprüfstand durchführen lässt [55]. Mit dem Ansatz eines Fuzzy-basierten Optimierungsalgorithmus sollen deterministische Entscheidungsprozesse und systematisiertes Motorwissen des Prüfstandsingenieurs nachgebildet und mittels Software auch auf eine für den Menschen nicht mehr zu bewältigende Komplexität motortechnischer Optimierungsaufgaben angewendet werden.

Nach einem Überblick zur Geschichte und zum aktuellen Stand der Technik in Motorsteuerungssystemen in Kapitel 3 soll in Kapitel 4 auf mögliche Regelungs- und damit Betriebskonzepte für Verbrennungsmotoren eingegangen werden. Hier sind die Optimierungsziele speziell für Dieselmotoren auf Basis klassischer bzw. neu entwickelter Steuergeräte-Strukturen zu definieren. Bereits erwähnt wurde, dass es zur Entwicklung und zum Test von Optimierungsstrategien geeigneter Motormodelle bedarf, die in der Regel nicht in analytisch-physikalischer Form zu Verfügung stehen. Deshalb wird eine Modellbildung auf Basis vermessener Abhängigkeiten notwendig. In Kapitel 5 sind dazu geeignete Methoden und im Rahmen dieser Arbeit entstandene Software-Tools zu beschreiben. Kapitel 6 soll die Grundlagen der numerischen Optimierungsmethodik zusammenfassen und Grenzen dieser Verfahren aufzeigen. Funktionsweise und Potential des neuartigen wissensbasierten Fuzzy-Optimierers sollen anhand der stationären lokalen Optimierung eines Beispielmotors dargestellt werden. In Kapitel 7 sollen darüber hinaus Ausblicke auf wissensbasierte Algorithmen, die Besonderheiten des dynamischen Motorbetriebs in die Optimierungsstra-

tegie einbeziehen, dargestellt werden.

Kern des neuartigen Optimierungsverfahrens soll eine Wissensbasis bilden, die motortechnische Zusammenhänge in Form von WENN-DANN-Regeln beschreibt. Diese Zusammenhänge unterscheiden sich prinzipbedingt bei unterschiedlichen Motorkonzepten, sodass in dieser Arbeit durchgängig derselbe Modellmotor, ein 4-Zylinder-DI-Dieselmotor mit Common-Rail-Einspritzsystem, betrachtet wird. In der verwendeten Wissensbasis sollen dementsprechend motortechnische Zusammenhänge dieses Motorkonzepts abgebildet werden. Zur Verdeutlichung grundlegender Zusammenhänge sollen darüber hinaus Messdaten eines DI-Nutzfahrzeug-Dieselmotors mit Reihen-Hubschieberpumpe zum Einsatz kommen.

Kapitel 3

Softwarestrukturen in elektronischen Motorsteuergeräten

3.1 Entwicklungsgeschichte

Die Entwicklung von Komponenten zur Regelung von Verbrennungsmotoren begann schon zu einem sehr frühen Zeitpunkt der industriellen Revolution, quasi mit dem Erscheinen der ersten Verbrennungsmotoren. Schon der dritte Versuchsmotor Rudolf Diesels besaß eine Mengenregelung mit Fliehkraftgewichten zur Konstanthaltung der Motorendrehzahl bei sich ändernden Lastbedingungen. Ein Jahr später, 1898, wurde am ersten kommerziellen, von der Firma Maschinenfabrik Augsburg (später MAN) gelieferten Dieselmotor die so genannte Lauster-Saugventilregelung zur Drehzahlstabilisierung eingesetzt [82].

Die früheste Erwähnung von Regelungstechnik an Ottomotoren geht auf das Jahr 1890 zurück. Am ersten Maybach-4-Zylinder-Gasmotor kam ein ebenfalls fliehkraftgeregelter Drosselklappensteller zum Einsatz. Bis Ende der 1960er Jahre wurden die mechanischen Regeleinrichtungen für Fahrzeug-Dieselmotoren um die Funktionen Leerlauf-Drehzahlregelung und Enddrehzahlregelung erweitert [66], [84].

Der Beginn des motorischen Elektronikzeitalters wurde in Deutschland 1967 mit der Ausrüstung des VW 1600 LE mit einer elektronisch gesteuerten Einspritzanlage eingeleitet. Mit der D-Jetronic ließen sich die im Kalifornien-Test festgelegten Abgasgrenzwerte für Ottomotoren deutlich unterbieten [60]. 1973 folgte die L-Jetronic als Weiterentwicklung der D-Jetronic, die wiederum Ende der 70er Jahre mit dem Heißfilmanemometer zur rückwirkungsfreien Luftmassenstrombestimmung (LH-Jetronic) und der Lambdasonde weitere Verbesserungen erfuhr.

Auf Grund der prinzipbedingt höheren Bauteilbelastungen bei Dieselmotoren, insbesondere auch in den Einspritzdüsen, hielten hier elektronisch unterstützte Systeme wesentlich später Einzug. Erst 1988 erfolgte nach dem sporadischen Einsatz von Drive-by-Wire-Systemen in Nutzfahrzeugen der Einsatz von elektronischen Motorsteuergeräten in der PKW-Großserie. **Tab. 3.1** auf der nächsten Seite stellt die

Meilensteine der Steuergeräte-Entwicklung für Otto- und Dieselmotoren gegenüber. Dabei soll nicht unerwähnt bleiben, dass auch voll mechanisch geregelte Systeme, wie die K-Jetronic oder Vergaseranlagen parallel dazu weiterentwickelt wurden.

Tab. 3.1 Meilensteine der Entwicklung elektronischer Steuergeräte

Jahr	Ottomotor	Dieselmotor
1978	Ankündigung des Einsatzes von Mikrocontrollern in Motorsteuergeräten durch LUCAS	
1979	Verbindung von Motor- und Zündungssteuergerät zur Bosch-MOTRONIC, erster serienmäßiger Einsatz von Mikrocontrollern in Motorsteuerungen im 7er BMW ab August 1979	Erste Veröffentlichung zum Thema Elektronische Diesel-Mengenregelung für Reiheneinspritzpumpen und Großmotoren [93, 43]
1984	Einführung der Anti-Klopffregelung durch Renault	
1985	Gesetz zur Ausrüstung aller PKW mit On-Board-Diagnose-Technik (OBD I-Überwachung aller Abgas-relevanten Sensoren und Aktoren) in Kalifornien	Elektronische Motorsteuerung (EMS) von Bosch zur Steuerung mech. Einspritzpumpen über E-Gas und Servomotor zum Einsatz in Bussen und LKWs [40]
1988	Einführung von OBD II (Katalysatorüberwachung durch 2 λ -Sonden, Zündaussetzer-Erkennung, etc.)	Erste Großserie der Digitalen-Diesel-Elektronik (DDE) mit Verteilereinspritzpumpe im BMW 324td (Mengen-/Laufruheregung, AGR, Ladedruckregelung, Spritzbeginnregelung, Diagnosefunktion) [89], Hubschieberpumpe mit Spritzbeginnregelung für LKW
1991	Elektronik der neuen S-Klasse von Mercedes-Benz mit Komfortfunktionen Antischlupfregelung, Tempomat, Zylinderselektive Kraftstoffvorlagerung. CAN-Bus als Kommunikationsstandard zwischen Steuer-, Diagnose- und Getriebesteuergerät	
1993	erstes Steuergerät mit 32-Bit-Prozessor-Architektur, TRIONIC von Saab	
1995	ME 1.0 (Bosch) vereinigt die bis dahin in getrennten Modulen untergebrachten Funktionen On-Board-Diagnose (OBD II), E-Gas und Motorsteuerung und ergänzt sie um weitere Komfortfunktionen. [85]	Bosch-EDC15 in modularer Bauweise für Verteilereinspritzpumpe VP43/44 [4]
1997		Vorstellung des Common-Rail-Systems für PKW-Motoren von DaimlerChrysler mit EDC15C (gesteuerte Piloteinspritzung)[27]
1998	Übergang von der mengen- zur drehmomentbasierten Funktionsstruktur in der ME7 von Bosch. Dadurch konnte ein durchgehender Aufbau aller Antriebssteuerkomponenten auf Basis von Drehmomentanforderungen des Fahrers erzielt werden [51]. Verwendung von Echtzeitbetriebssystemen	Erweiterung der EDC15P für Pumpe-Düse-Systeme (Volkswagen AG) [35]
2000/ 2001	Einsatz von künstlichen neuronalen Netzen und modellbasierten Regelungsstrukturen für Teilfunktionen der Motorsteuerung, Beispiel: BMW-VALVETRONIC [46]	Übergang zur drehmomentbasierten Kennfeldstruktur und Verwendung adaptiver Algorithmen [92]

Die rasante Entwicklung der Komplexität solcher Systeme verdeutlicht **Abb. 3.1**. Waren Ende der 60er Jahre noch 18 Kennlinienwerte ausreichend, so gilt es in

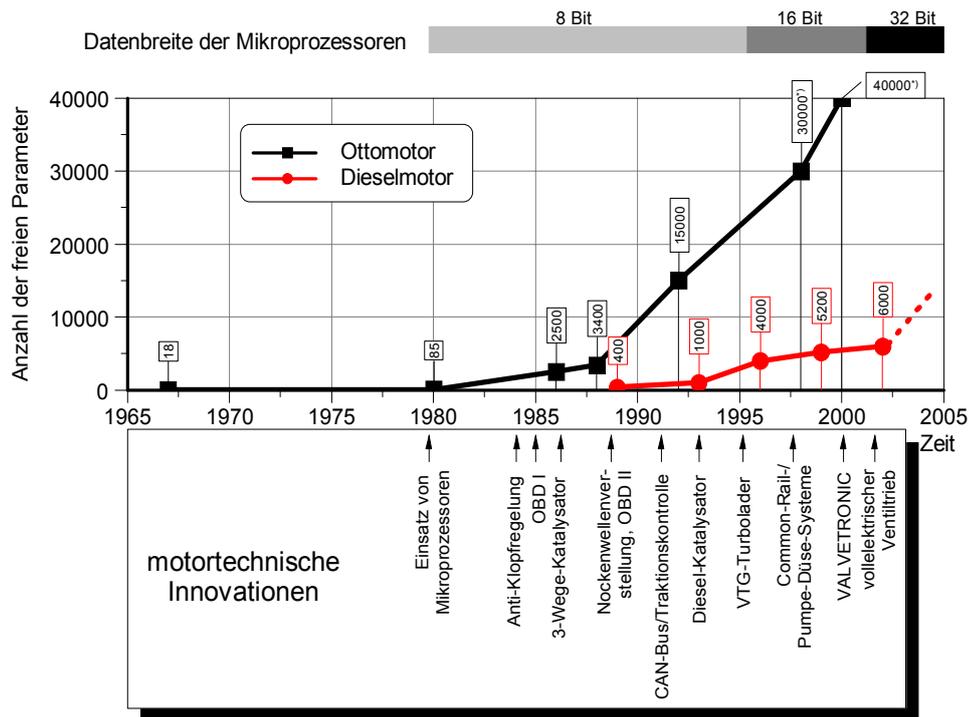


Abb. 3.1 Entwicklung der Parameteranzahl in elektronischen Motorsteuergeräten;
*)Hochrechnung aus [46]

modernen Steuergeräten schon weit über 20.000 Daten zu applizieren. Das entspricht etwa 400 Funktionen und 4000 Labels bei der derzeitigen Generation von Ottomotoren-Steuergeräten (ME9 von Bosch [46]). Um den damit verbundenen Kalibrieraufwand für zukünftige Generationen von Steuergeräten nicht noch weiter zu erhöhen, wird schrittweise dazu übergegangen, über die Jahre gewachsenene, unübersichtliche Funktionsstrukturen zu entflechten und, falls möglich, durch physikalisch motivierte, modellbasierte Ansätze zu ersetzen. Trotz dieser Bemühungen ist nicht damit zu rechnen, dass der Zeitaufwand zur Kalibrierung bzw. Applikation von Steuergeräte-Datensätzen in Zukunft sinken wird, zumal die Einhaltung zukünftiger gesetzlicher Rahmenbedingungen neue Fahrzeugsysteme und die dazugehörigen Regelungsstrukturen fordert (z. B. NO_x -Speicherkatalysator).

In den folgenden Abschnitten sind die dem heutigen Stand der Technik entsprechenden Steuer- und Regelkreise dargestellt. Dabei wird speziell auf das Common-Rail-Einspritzsystem an Dieselmotoren eingegangen, welches auch Gegenstand der Untersuchungen im weiteren Verlauf der Arbeit ist.

3.2 Regel- und Überwachungssysteme am Common-Rail-Dieselmotor

3.2.1 Gemischaufbereitung

Bedingt durch das Prinzip der internen Gemischbildung bei Dieselmotoren, lässt sich die Qualität der Verbrennung durch den Einspritzverlauf sowie durch die Menge, die Zusammensetzung und die kinetische Energie des sich im Zylinder befindlichen Gasgemisches beeinflussen. Ersterer wird wesentlich durch die Art des verwendeten Einspritzsystems bestimmt. Die möglichen Freiheitsgrade bei der Einspritzverlaufsformung unterscheiden sich je nach Typ des verwendeten Systems.

Qualität und Menge der Verbrennungsluft im Zylinder hingegen hängen von der momentanen Abgasrückführrate, dem Ladedruck, der Ladelufttemperatur und dem Restgasgehalt im Zylinder ab. Abgasrückführrate und Ladedruck können zumindestens im stationären Motorbetrieb unabhängig voneinander geregelt werden. Eine vollständige dynamische Entkopplung der Komponenten der Ladeluftstrecke ist jedoch nicht möglich. Ladelufttemperatur und Restgasgehalt lassen sich unter realen Fahrzeugbedingungen im Allgemeinen nicht beeinflussen, sondern werden durch konstruktive und umgebungsspezifische Randbedingungen (Ladeluftkühler, Ventilüberschneidung, Einlassdrall, etc.) bestimmt.

Gegenüber klassischen Einspritzsystemen, wie solche mit Reihen- oder Verteilereinspritzpumpen, weist das Common-Rail-System folgende Vorteile auf:

- Die Einspritzung kann in mehrere Teileinspritzungen zerlegt werden, wodurch eine in weiten Grenzen variable Gestaltung des Einspritzverlaufs möglich wird. Das für die vorliegende Arbeit verwendete System lässt eine Pilot-(Vor-) und eine Haupteinspritzung zu. Zukünftige Systeme werden bis zu 5 Teileinspritzungen erlauben. Damit ist eine gleichzeitige Absenkung des jeweiligen Niveaus von Ruß- und NO_x -Emissionen sowie der Geräuschemissionen möglich, [42, 96, 97].
- Das Pumpenantriebsmoment der Hochdruckpumpe ist geringer als bei konventionellen Verteilereinspritzpumpen, [64].
- Ein Fertigungsverbund mit Ottomotoren ist durch ähnlichen Aggregateaufbau und gleiche Nocken-/Kurbelwellensensorik möglich, [65].
- Der maximale Einspritzdruck (eingestellter Raildruck) liegt schon beim Öffnen der Düsenadel an, was sich positiv auf die Gemischbildung auswirkt.
- Der Einspritzdruck (Raildruck) und damit die benötigte Leistung der Hochdruckpumpe ist im Motorkennfeld frei wählbar.

Mit dem hier verwendeten System lassen sich Raildrücke bis zu 1350 bar realisieren. Modernere Systeme arbeiten inzwischen schon mit Raildrücken bis 1600 bar, womit

die in Pumpe-Düse-Systemen erzielten Druckniveaus (> 2000 bar) jedoch noch nicht erreicht werden. Gründe hierfür liegen in der Dauerdruckbeanspruchung der Injektoren und den daraus folgenden Kavitationsschädigungen im Düsenverbund. In einer weiteren Erhöhung der maximalen Raildrücke ist der größte Entwicklungsbedarf bei Common-Rail-Systemen zu sehen.

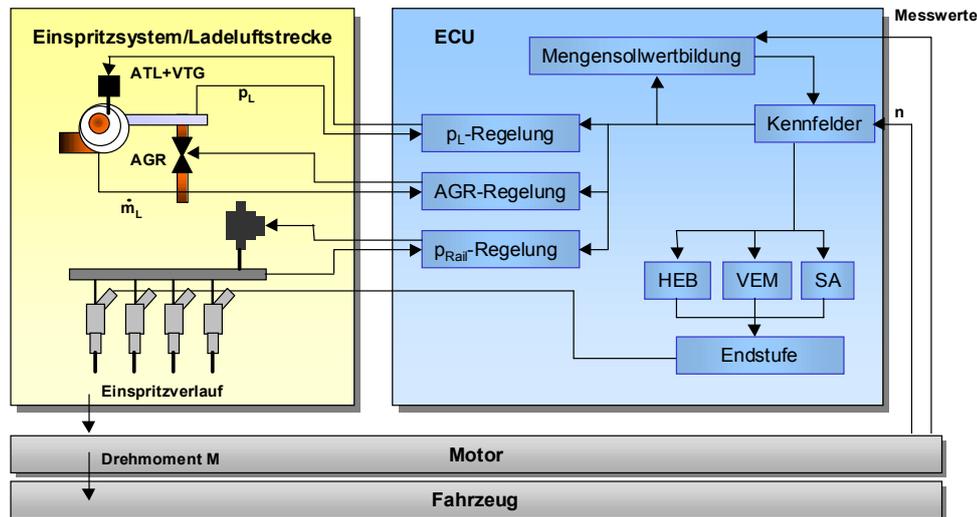


Abb. 3.2 Motormanagement für das Bosch Common-Rail-System der 1. Generation, Quelle: Robert Bosch GmbH

Abb. 3.2 illustriert die durch das Motormanagement beeinflussbaren Parameter des untersuchten Common-Rail-Einspritzsystems. Die Wahl dieser Prozessführungsgrößen bestimmt die Form des Brennverlaufs und darüber das Leistungs- und Emissionsverhalten des Verbrennungsmotors. Im Folgenden sollen die für die Parametrierung der einzelnen Steuer- und Regelkreise maßgeblichen Strukturen beschrieben werden. In kommerziellen Motorsteuergeräten werden diese durch eine Reihe zusätzlicher Algorithmen ergänzt, womit unterschiedlichste Randbedingungen, wie geforderte Notlaufeigenschaften bei Sensorausfall, sich ändernde Umgebungsbedingungen und Sicherheitsanforderungen berücksichtigt werden können.

Einspritzmenge

Über den Pedalwertgeber wird dem Steuergerät der Fahrerwunsch übermittelt und durch das Fahrerwunsch-Kennfeld auf die zu realisierende Einspritzmenge abgebildet. Ein Rauchbegrenzungskennfeld begrenzt die maximal mögliche Einspritzmenge bei gegebenem Ladedruck. Dieses Kennfeld bietet entsprechendes Optimierungspotential im Hinblick auf die Schadstoffemissionen. Über einen für jede Einspritzdüse spezifischen Faktor wird diejenige Ventil-Öffnungsdauer berechnet, die zur Einspritzung der geforderten Menge an Kraftstoff führt.

Ansteuerbeginn der Haupteinspritzung (Haupteinspritzbeginn, HEB)

Der Haupteinspritzbeginn wird zunächst aus einem Grundkennfeld, aufgespannt über Drehzahl und Einspritzmenge¹, interpoliert. Für den Kaltstart werden entsprechende Korrekturkennfelder vorgehalten. Je nachdem, ob der Einspritzverlauf aus Vor- und Haupteinspritzung besteht, oder nur aus einer Haupteinspritzung, werden unterschiedliche HEB-Kennfelder benutzt.

Voreinspritzmenge (VEM)

Die Voreinspritzmenge wird wiederum durch ein Grundkennfeld (Drehzahl-Einspritzmenge) vorgegeben. Die minimale und die maximale VEM werden abhängig vom aktuellen Raildruck begrenzt, um die Funktion des Injektors sicherzustellen. Wird mit einer VEM gearbeitet, ergibt sich die Haupteinspritzmenge (HEM) als Differenz aus begrenzter Fahrerwunschmenge und VEM.

Ansteuerbeginn der Voreinspritzmenge (ABVE), Spritzabstand (SA)

Für diesen Freiheitsgrad existiert ein entsprechendes Kennfeld, in dem abhängig vom Betriebspunkt des Motors der Einspritzzeitpunkt für die Voreinspritzung als Abstand zur Haupteinspritzung in $^{\circ}KW$ abgelegt ist. **Abb. 3.3** zeigt den Einfluss von VEM und SA auf den Brennverlauf exemplarisch für einen Betriebspunkt des Motors M47R. Kleine Voreinspritzmengen (hier 3 mm^3) sind nur bei moderaten Spritzabständen sinnvoll, da sonst die eingebrachte Teilmenge nicht den erwünschten Effekt der Vorverbrennung erzielt. Eine detaillierte Analyse der motortechnischen Zusammenhänge findet sich in Abschnitt 7.3, welcher die Erstellung der Wissensbasis behandelt.

Raildruck (p_{Rail})

Der Raildruck-Sollwert wird aus einem entsprechenden Kennfeld interpoliert und einem geschlossenen Regelkreis als Eingangsgröße zugeführt. Mit Hilfe eines Drucksensors am Rail und eines Absteuerventils in der Hochdruckpumpe wird über diesen Regelkreis der gewünschte Raildruck konstant gehalten.

Ladedruck (p_L)

Zur Regelung des Ladedrucks ist der Versuchsmotor M47R mit einem VTG-Lader ausgerüstet, dessen Turbinenleitapparat elektropneumatisch verstellbar ist. Der aus einem Kennfeld interpolierte Ladedrucksollwert wird sowohl zur Steuerung als auch

¹Die Einspritzmenge wird beim verwendeten Motor als Last-Äquivalent verwendet. Zukünftige Motorsteuergeräte verwenden das Drehmoment, welches in Echtzeit über entsprechende Motormodelle berechnet wird (modellbasierte Struktur).

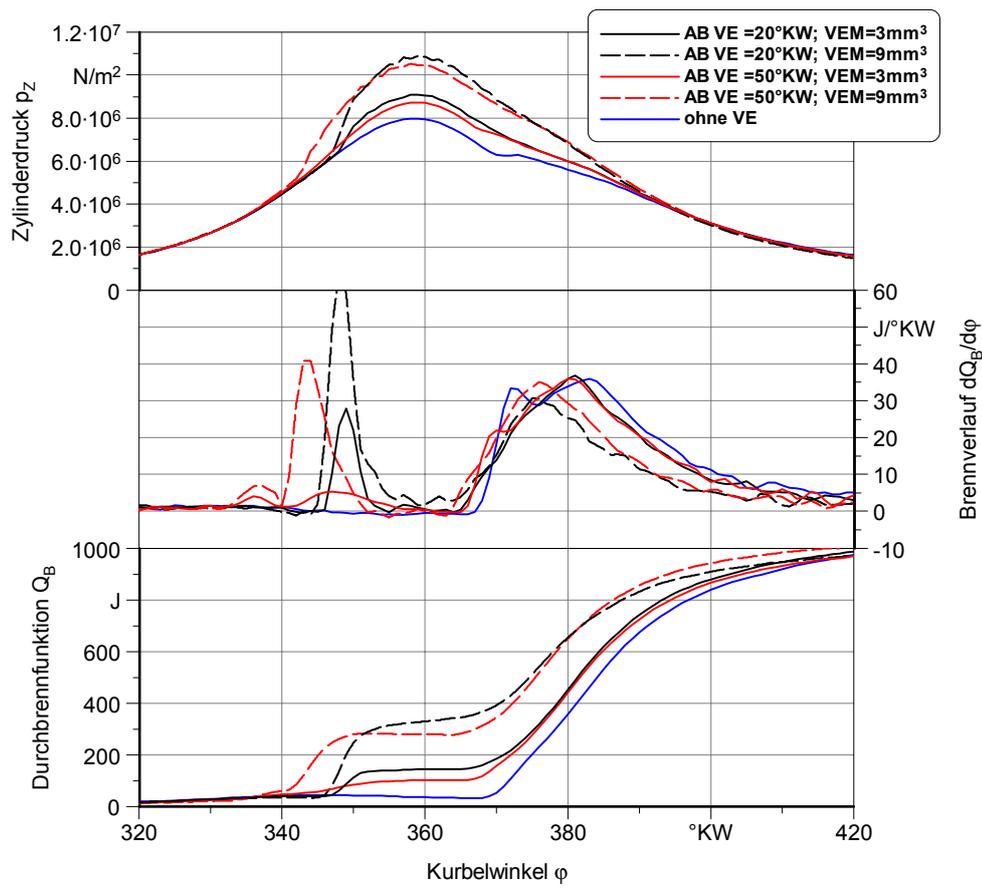


Abb. 3.3 Einfluss der Voreinspritzung auf Druckverlauf, Brennverlauf und Durchbrennfunktion beim M47R ($n = 3000 \text{ min}^{-1}$, $M = 93 \text{ Nm}$, $p_L = 1.66 \text{ bar}$, $p_{\text{Rail}} = 800 \text{ bar}$, keine AGR, $HEB = 2^\circ \text{KW}$)

zur Regelung des Ladedruckes verwendet. Die Steuerung arbeitet, wenn kurze Antwortzeiten des Systems gefordert sind (Beschleunigung) oder wenn eine Regelung des Druckes nicht sinnvoll ist (Leerlauf). Steuerung und Regelung werden überlagert betrieben. Bei der Steuerung wird aus dem Solldruck über ein weiteres Kennfeld direkt das Tastverhältnis zur Ansteuerung des VTG-Leitapparates ermittelt, bei der Regelung wird der Sollwert einem PID-Regler zugeführt.

Abgasrückführrate (AGR)

Da die rückgeführte Abgasmenge nicht direkt gemessen werden kann, wird an ihrer Stelle die Frischluftmasse, die in den Ansaugtrakt des Motors einströmt, geregelt. Diese ist über ein Heißfilmanemometer exakt bestimmbar. Als Stellglied dient ein elektropneumatisches Taktventil, welches die Zumischung des Abgases steuert. Aus einem Kennfeld wird abhängig vom Motorbetriebspunkt die gewünschte Frischluftmasse interpoliert und mittels PID-Regler eingestellt.

Es stehen somit neben den betriebspunktdefinierenden Parametern Drehzahl und

Drehmoment (Einspritzmenge) 6 Freiheitsgrade zur stationären Emissionsabstimmung zur Verfügung, nämlich der Haupteinspritzbeginn, die Voreinspritzmenge, der Spritzabstand, der Raildruck, der Ladedruck und die Abgasrückführrate. Sollen dynamische Effekte bei der Optimierung berücksichtigt werden, kommen weitere Freiheitsgrade, wie z. B. das Rauchbegrenzungskennfeld hinzu.

3.2.2 Diagnosesysteme

Der Gesetzgeber schreibt seit mehreren Jahren auch bestimmte Diagnosefunktionen in Dieselmotoren-Steuergeräten vor, die einen emissionsarmen Fahrzeugbetrieb überwachen und sicherstellen sollen. Dazu zählen im Einzelnen

- Erfassen von Defekten im Oxidations-Katalysator (falls vorhanden),
- Überwachung der Funktionsweise des Partikelfilters (falls vorhanden),
- Überwachung der Funktion der Kraftstoffmengen- und Einspritzzeitpunkt-Regler des Einspritzsystems auf Störungen und Funktionsausfall,
- Überwachung der Ladeluftdruckregelung, der Abgasrückführregelung und der Ladelufttemperatur, inklusive der dazu benötigten Sensoren,
- Überwachung sonstiger Soft- und Hardwarestrukturen, deren Ausfall eine erhöhte Schadstoffemission des Fahrzeugs zur Folge hätte.

Diese im OBDII-Standard und in der EU-Richtlinie 70/220/EWG für Diesel-PKW spezifizierten Diagnosefunktionen tragen zur nachhaltigen Einhaltung der legislativen Emissionsgrenzwerte bei. Eine Berücksichtigung der Diagnose-Algorithmen bei der Prozessoptimierung ist jedoch nicht Gegenstand dieser Arbeit.

Kapitel 4

Optimierung des dieselmotorischen Gesamtprozesses

4.1 Definition der Prozessoptimierung

Die Aufgabe der Prozessoptimierung besteht darin, die beeinflussbaren Parameter oder Eingangsgrößen eines Systems derart zu berechnen, dass unter Berücksichtigung von Beschränkungen aller Art ein dem System zugeordnetes Gütekriterium zu einem Optimum gebracht wird. Die Führungsgrößen des Systems können je nach Aufgabenstellung einen festen Wert annehmen (optimaler stationärer Betriebspunkt), eine zeitveränderliche Kurve ergeben (optimaler Prozessverlauf) oder mehrdimensionale Räume beschreiben (z. B. zeit- und ortsoptimale Steuerung) [34].

Neben der Definition des Prozesses selbst muss mindestens ein Gütekriterium bzw. eine Zielfunktion festgelegt werden, die eine qualitative Aussage über die Prozessgüte in Abhängigkeit der Führungsgrößen macht und deren Optimum der gewünschten optimalen Prozesssituation entspricht.

Liegt ein geschlossenes analytisches Modell des zu optimierenden Systems vor, kann die Berechnung der optimalen Stellgrößen(verläufe) prinzipiell ebenfalls analytisch erfolgen. Bei komplexen technischen Prozessen - dazu zählt auch der Motorprozess - lässt sich ein solches Modell im Allgemeinen nicht finden und die Optimierung muss in einem numerischen Mehrschrittverfahren erfolgen. **Abb. 4.1** auf der nächsten Seite zeigt die Arbeitsweise der schrittweisen Motorprozessoptimierung mit den zu definierenden Randbedingungen. Die Stellglieder und Folgeregler, welche die Einstellung der Führungsgrößen bzw. Führungsgrößenverläufe am Motor realisieren, sind dem zu optimierenden Prozess zugeordnet, obwohl eine Optimierung der entsprechenden Reglerparameter ebenfalls Gegenstand einer Optimierungsaufgabe sein kann.

Ausschlaggebend für die Güte und die Dauer der Optimierung ist die geeignete Wahl

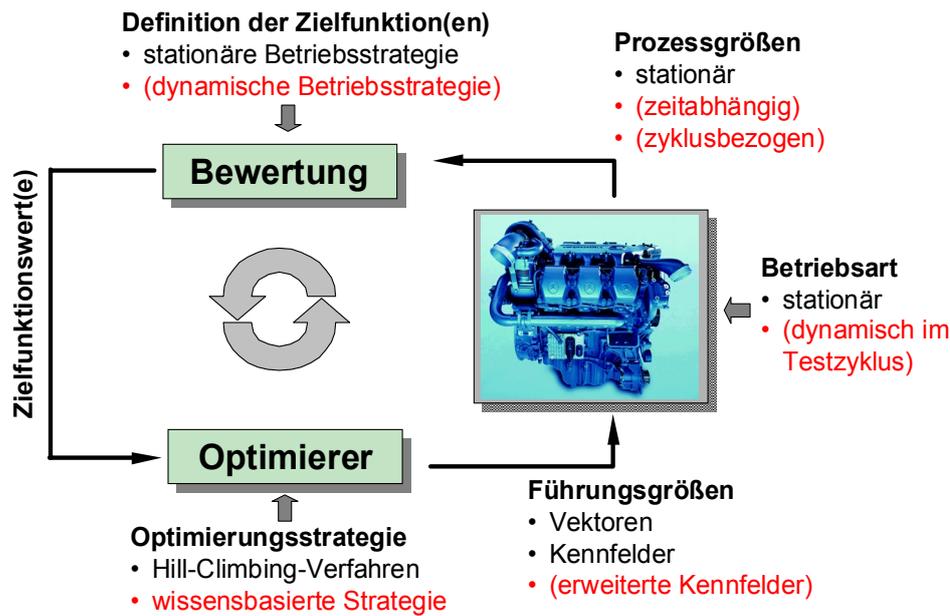


Abb. 4.1 Grundprinzip der schrittweisen Parameteroptimierung (Aussagen in Klammern gelten für die dynamische Optimierung)

des Gütekriteriums bzw. der Zielfunktion(en). Da der mathematische Optimierer nur das Ergebnis dieser Zielfunktion(en) zur Prozessbewertung heranzieht, ergeben sich häufig Optimierungsergebnisse, die nicht das bestmögliche Ergebnis im Sinne der eigentlich angestrebten motortechnischen Betriebsstrategie darstellen, sodass im Allgemeinen weitere zu erfüllende Ungleichungen in Form von Randbedingungen (Constraints) aufgestellt werden müssen.

4.2 Modellmotoren und Versuchsumgebung

Tab. 4.1 Technische Daten der verwendeten Modellmotoren

Hersteller	Daimler Benz	BMW
Typ	OM441LA	M47R
Zylinderanordnung	V6	R4
Nennleistung	243 kW	85 kW
Nenndrehzahl	2100 min ⁻¹	4000 min ⁻¹
Bohrung	128 mm	84 mm
Hub	142 mm	88 mm
Hubvolumen	10600 cm ³	1950 cm ³
Max. Drehmoment	1350 Nm/1200 min ⁻¹	250 Nm/1750 min ⁻¹
Einspritzsystem	Hubschieberpumpe RP 43	Common-Rail-System 1. Generation (Bosch)
AGR	gekühlt	ungekühlt
Aufladesystem	K29/VTG	VNT15//VTG
Verwendungszweck in dieser Arbeit	Grundlagenuntersuchung zur dynamischen Optimierung	Modellerstellung für die wissensbasierte Optimierung

Für die in dieser Arbeit angestellten Versuche wurden zwei verschiedene Versuchsmotoren verwendet, die im Weiteren als Modellmotoren bezeichnet werden sollen. Es handelt sich um die in **Tab. 4.1** näher spezifizierten seriennahen DI-Dieselmotoren. Für die Versuche stand ein hochdynamischer Motorenprüfstand mit Fahrer-/Fahrzeugsimulation¹ zur Verfügung, mit dessen Hilfe es möglich war, vorgegebene Geschwindigkeitsprofile mit einem virtuellen Fahrzeug, in dem der reale Modellmotor arbeitet, nachzufahren.

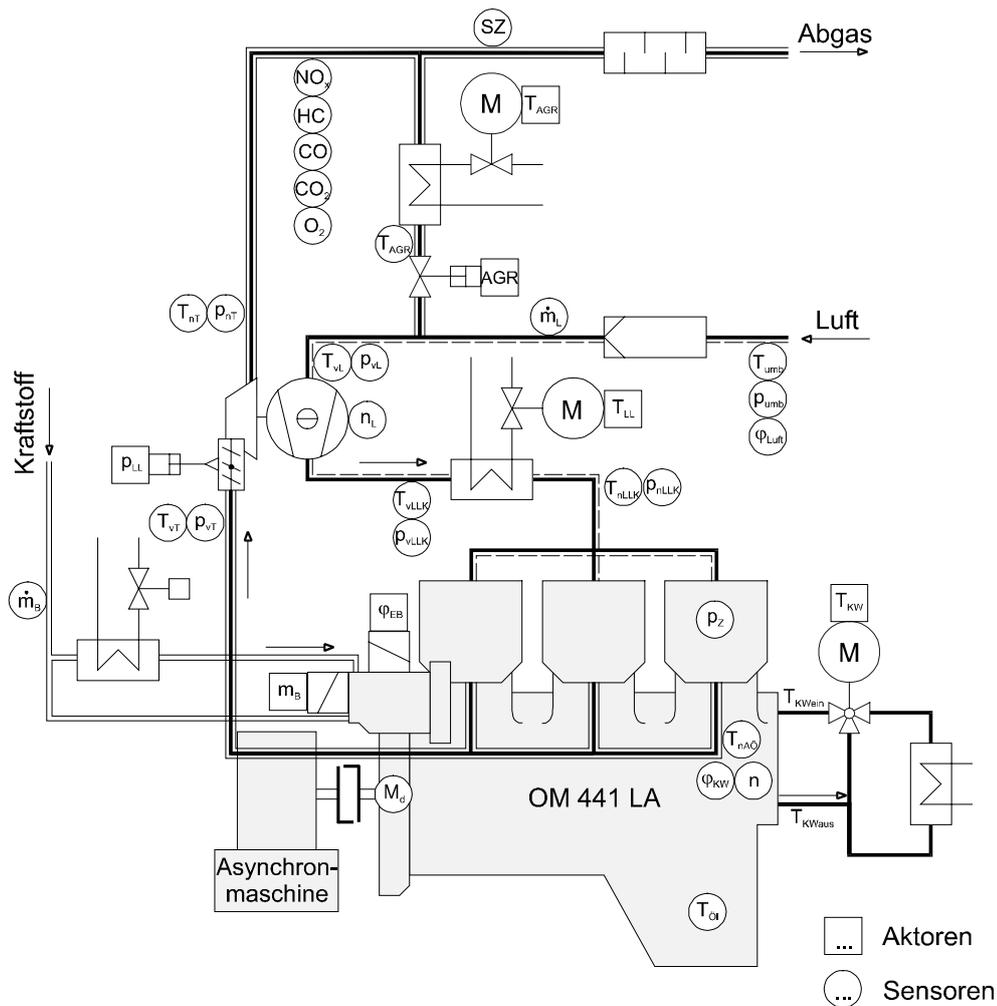


Abb. 4.2 MSR-Stellen am Versuchsmotor OM441 LA

In **Abb. 4.2** ist die verwendete Sensorik und Aktorik des Prüfstandsbaus am Beispiel des Nutzfahrzeug-Modellmotors OM441LA dargestellt. Für den M47R wurden mit Ausnahme der AGR-Kühlung und der Einspritzsystem-spezifischen Aktoren die gleichen MSR-Stellen verwendet.

Die Prüfstandsautomatisierung besteht aus einer *Simatic S5* zur Prüfstandsüberwachung, mehreren Prozessrechnerkarten zur schnellen Datenerfassung und zur

¹Dezentrales Simulations System - DSS

Realisierung schneller Simulations-/Regelroutinen, einem PC-System (*CATS-PC*) als Benutzerschnittstelle und einem Optimierungs-PC, auf dem die zu entwickelnden Optimierungsroutinen implementiert werden sollen. Die Vernetzung der an der Prüfstandsautomatisierung beteiligten Hardwarekomponenten ist in **Abb. 4.3** dargestellt. Es handelt sich um eine dezentrale Architektur, d. h. die Peripherie-Geräte (Sensorik und Aktorik I/O) übernehmen die Messwertdigitalisierung und die Aktorsteuerung dezentral in der Feldebene. Der Datenaustausch basiert auf dem Profibus-DP-Protokoll².

Um für ausgewählte Messgrößen eine Abtastfrequenz von 100 Hz realisieren zu können, musste der DP-Bus auf zwei Bus-Master aufgeteilt werden. Weniger zeitkritische Messungen erfolgen im Zyklustakt der SPS (ca. 50 ms), alle anderen Messgrößen werden direkt vom digitalen Simulationssystem (DSS) mit einer Zeitscheibe von 6 ms erfasst.

Der Datenaustausch zur Prozessvisualisierung und zur PC-Benutzerschnittstelle des Automatisierungssystems erfolgt physikalisch ebenfalls über einen Zweidraht-Bus, als Protokoll wird der Profibus-FDL-Standard³ eingesetzt. Dies erlaubt die asynchrone Datenübertragung zwischen verschiedenen Master-Systemen und dient als Basis für die Erstellung anwendungsspezifischer Protokolle der ISO/OSI-Referenzschicht 7. Dieses Schnittstellenprotokoll wurde auch für die Anbindung des PC-basierten Optimierungssystems an die Prüfstandsautomatisierung gewählt. Der Optimierungs-PC ist dabei an eine separate Industrierechnerkarte (CPU 486) gekoppelt, auf der Echtzeit-Routinen zur schnellen Kennfeldinterpolation ablaufen. Über einen parallelen Rückwandbus im MMC-Rahmen haben die Echtzeit-Programme Zugriff auf alle Mess- und Stellgrößen der SPS bzw. des DSS.

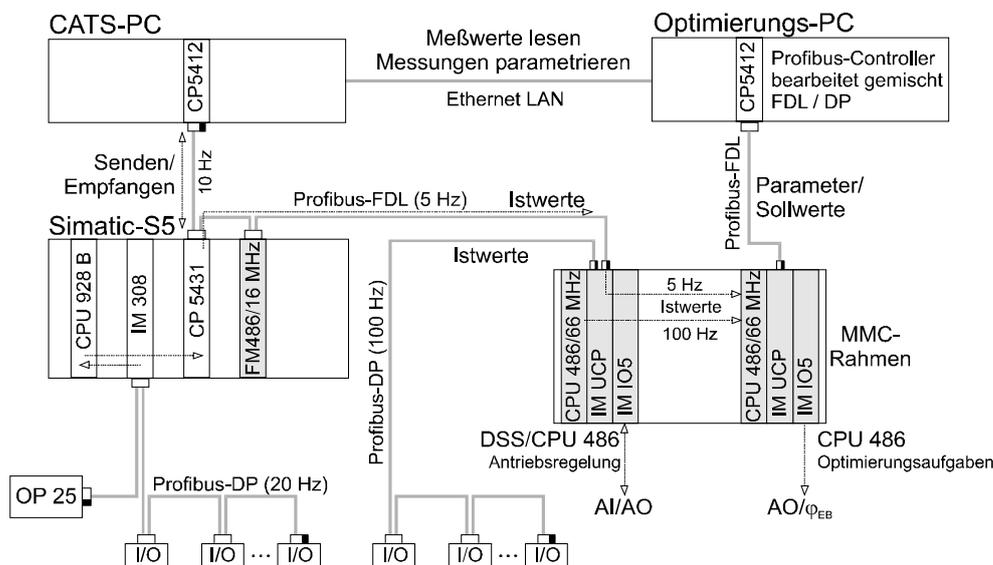


Abb. 4.3 Hardware-Architektur der Prüfstandssteuerung

²Polling an Dezentraler Peripherie, ISO/OSI-Schicht 7 (Gesamtübertragungsrate 1,5 Mbaud).

³Fieldbus Data Link - Protokoll der ISO/OSI-Schicht 2

4.3 Multikriterielle Optimierungsziele und ihre mathematische Beschreibung

4.3.1 Zielkonflikte bei der dieselmotorischen Prozessoptimierung

Bei der Optimierung motortechnischer Prozesse im Allgemeinen und der des Dieselmotors im Speziellen unterscheidet man folgende Aufgaben, denen prinzipiell die gleichen Zielkonflikte zu Grunde liegen.

1. Bei der *stationären Betriebspunkt-Optimierung* - *SBPO* gilt es, den Motorprozess in einem nominellen, d. h. durch Drehzahl und Drehmoment vorgegebenen, *stationären Betriebspunkt* zu optimieren. Dieses Optimierungsproblem liegt insbesondere bei Stationärmotoren und bei der ersten Abstimmung von Fahrzeugmotoren vor⁴.
2. Die *zyklusorientierte quasistationäre Betriebspunkt-Optimierung* - *ZQBPO* geht davon aus, dass ein beliebiger Testzyklus in eine Folge stationärer nomineller Motorbetriebspunkte zerlegt werden kann. Es wird für im Vorfeld entsprechend dem Zyklusverlauf auszuwählende repräsentative Betriebspunkte je eine Zielfunktion festgelegt und nacheinander jeder dieser Betriebspunkte stationär optimiert. Im Anschluss an die Optimierung werden aus den erstellten optimalen Führungsgrößen-Vektoren \mathbf{x}^* optimale Führungsgrößen-Kennfelder $\mathbf{x}_{\mathbf{KF}}^*$ ⁵ erstellt, aus denen dann im Zyklus die Führungsgrößen-Werte interpoliert werden können.
3. Ähnlich wie bei der Aufgabe nach Punkt 2 wird bei der *zyklusorientierten quasistationären Kennfeld-Optimierung* - *ZQKFO* von einer quasistationären Betrachtungsweise ausgegangen. Auch hier müssen im Vorfeld des Optimierungslaufes stationäre Betriebspunkte gewählt werden, die repräsentativ im Zyklus vorkommen. Das Optimierungsziel ist hier jedoch *global*, d. h. alle (gewählten) Kennfeldpunkte werden synchron optimiert und das resultierende Testzyklusergebnis bewertet⁶.
4. Man spricht von einer *zyklusorientierten dynamischen Kennfeld-Optimierung* - *ZDKFO* wenn im Algorithmus nach Punkt 3 zusätzlich dynamische Zusammenhänge des Motorbetriebs berücksichtigt werden⁷.

⁴auch *lokale* stationäre Optimierung

⁵Vektor-Darstellung entsprechend **Gl. 4.18**

⁶Man spricht hierbei auch von einer *globalen* Optimierung im Sinne eines einzigen globalen Optimierungsziels.

⁷Dazu ist in der Regel eine Erweiterung des Definitionsbereichs der Führungsgrößen-Kennfelder um eine dynamische Beschreibungsgröße notwendig (vgl. 4.5.4).

5. Die *dynamische betriebspunktorientierte Optimierung - DBPO*⁸ stellt die universellste und damit auch komplexeste Optimierungsaufgabe dar. Hierbei wird jeder einzelne in einem beliebigen Zyklus durchgeführte (dynamische) Motorbetriebspunkt von seiner Umgebung losgelöst betrachtet und optimiert⁷.

Der bedeutendste Zielkonflikt, der bei der Prozessoptimierung an Dieselmotoren gelöst werden muss, ist das gegenläufige Verhalten von Partikel- und Stickoxidemissionen⁹.

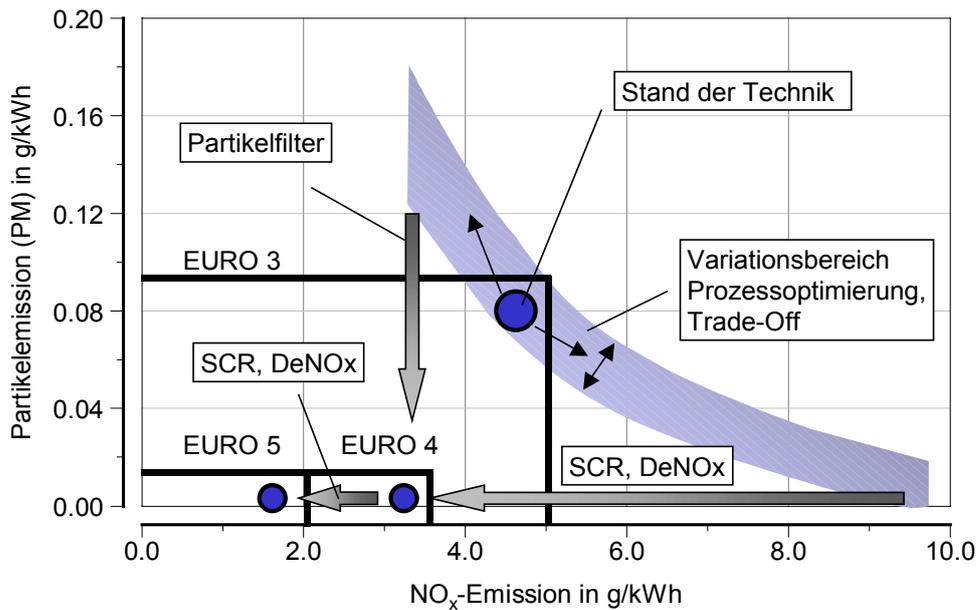


Abb. 4.4 $PM-NO_x$ -Trade-Off und legislative Grenzwertstufen am Beispiel Nutzfahrzeugemissionen (European Steady Cycle, ESC, nach 88/77/EC)

Abb. 4.4 verdeutlicht diese Problematik exemplarisch für den Nutzfahrzeugesektor. Der durch innermotorische Maßnahmen beeinflussbare Bereich der Trade-Off-Funktion bildet den für die Prozessoptimierung nutzbaren *Optimierungsraum*. Obwohl die Grenzwertstufen EURO 4 und EURO 5 allein durch innermotorische Maßnahmen nicht erreicht werden können - der Einsatz von Abgasnachbehandlungssystemen, wie Partikelfilter¹⁰ und NO_x -Katalysatortechnik¹¹, wird zwingend notwendig sein - muss deren Potential durch entsprechende Optimierungswerkzeuge ausgeschöpft werden. Für PKW-Dieselmotoren ist mit einem ähnlichen Szenario zu rechnen, wenn auch mit verzögerter Einführung der Abgasnachbehandlungssysteme.

Weitere Optimierungsziele, die zum Teil mit einander konkurrieren¹² sind:

⁸auch *lokale dynamische* Optimierung

⁹auch als Partikel-Stickoxid-Trade-Off bezeichnet

¹⁰CRT-Filter (Continuous Reduction Trap)[41]

¹¹SCR-Katalysator (Selective Catalytic Reduction) [98] bzw. DeNOx-Speicherkatalysatoren [23]

¹² vgl. pareto-optimale Lösungsräume im folgenden Abschnitt

- minimaler spezifischer Kraftstoffverbrauch im zu optimierenden Stationärpunkt bzw. im Mittel über einen Testzyklus,
- Einhaltung legislativer Grenzwerte für HC -, CO - und CO_2 -Emissionen,
- Einhaltung eines Grenzwertes für den zulässigen Rußstoß bei Motor-/Fahrzeugbeschleunigung,
- minimale Geräuschemissionen,
- Einhaltung von Belastungsgrenzen für Bauteile (z.B. Abgastemperaturen, maximale Zylinderdrücke),
- optimales Fahr-/Beschleunigungsverhalten, [99].

Im Rahmen dieser Arbeit soll im Wesentlichen die gleichzeitige Optimierung der Größen spezifischer Kraftstoffverbrauch, Partikel- und NO_x -Emission untersucht werden. Das sind derzeit die kritischen Zielgrößen beim DI-Dieselmotor, sowohl im Nutzfahrzeug- als auch im PKW-Segment. Kohlenwasserstoff- und Kohlenmonoxid-Emissionen können durch Oxydationskatalysatoren nachhaltig gesenkt werden und bedürfen in der Regel keiner innermotorischen Reduktions-Maßnahmen. Die Einhaltung von bauteilspezifischen Belastungsgrenzen wird bei der Optimierung derart berücksichtigt, dass der Optimierungsraum entsprechenden Einschränkungen unterliegt. Die Zielgrößen Geräuschemission und Fahrverhalten sollen zunächst keine Berücksichtigung finden.

4.3.2 Pareto-optimale Lösungsräume

Zum besseren Verständnis multikriterieller Optimierungsaufgaben soll zunächst das Problem in allgemeiner Form mathematisch formuliert werden (vgl. [95]). Definiert man den Zielfunktionsvektor $\mathbf{F}(\mathbf{x})$ und eine endliche Anzahl von Nebenbedingungen (Constraints) $G_i(\mathbf{x})$, so lässt sich ein Optimierungsproblem durch **Gl. 4.1** darstellen.

$$\begin{aligned}
 & \min_{\mathbf{x} \in \mathfrak{R}^n} \mathbf{F}(\mathbf{x}) \\
 & G_i(\mathbf{x}) = 0 \quad i = 1, \dots, m_e \\
 & G_i(\mathbf{x}) \leq 0 \quad i = m_e + 1, \dots, m \\
 & \mathbf{x}_u \leq \mathbf{x} \leq \mathbf{x}_o
 \end{aligned} \tag{4.1}$$

Handelt es sich bei den Komponenten des Vektors $\mathbf{F}(\mathbf{x})$ um konkurrierende Größen, so existiert keine eindeutige Lösung für dieses Problem. Vielmehr muss das Konzept der Pareto-Optimalität angewendet werden [5]. Eine Lösung des Optimierungsproblems heißt pareto-optimal bzw. nicht-unterlegen, wenn die Verbesserung eines Teilzieles zwangsläufig mit einer Verschlechterung eines anderen Teilzieles einhergeht.

In der englischsprachigen Literatur werden solche Lösungen auch als *noninferior solution*, *efficient solution* oder als *set of admissible solutions* bezeichnet [44]. Der Begriff Pareto-Optimalität stammt aus der ökonomischen Statistik. Betrachtet man einen begrenzten Parameterraum Ω in \mathfrak{R}^n , für den alle Nebenbedingungen $G_i(\mathbf{x})$ erfüllt sind,

$$\begin{aligned} \Omega = \{ \mathbf{x} \in \mathfrak{R}^n \} \quad \text{für} \\ G_i(\mathbf{x}) = 0 \quad i = 1, \dots, m_e \\ G_i(\mathbf{x}) \leq 0 \quad i = m_e + 1, \dots, m \\ \mathbf{x}_u \leq \mathbf{x} \leq \mathbf{x}_o, \end{aligned} \quad (4.2)$$

kann ein korrespondierender Raum Λ für die Zielfunktionswerte festgelegt werden:

$$\Lambda = \{ \mathbf{y} \in \mathfrak{R}^m \} \quad \text{für} \quad \mathbf{y} = \mathbf{F}(\mathbf{x}), \quad \text{wobei} \quad \mathbf{x} \in \Omega. \quad (4.3)$$

Die Transformation von Ω nach Λ übernimmt dabei die Zielfunktion $\mathbf{F}(\mathbf{x})$.

Ein $\mathbf{x}^* \in \Omega$ ist genau dann eine pareto-optimale Lösung des Optimierungsproblems, wenn in der Umgebung von \mathbf{x}^* kein $\Delta \mathbf{x}$ existiert, sodass gilt $(\mathbf{x}^* + \Delta \mathbf{x}) \in \Omega$ und

$$\begin{aligned} F_i(\mathbf{x}^* + \Delta \mathbf{x}) \leq F_i(\mathbf{x}^*) \quad i = 1, \dots, m \\ F_j(\mathbf{x}^* + \Delta \mathbf{x}) \leq F_j(\mathbf{x}^*) \quad j \in \mathfrak{N}. \end{aligned} \quad (4.4)$$

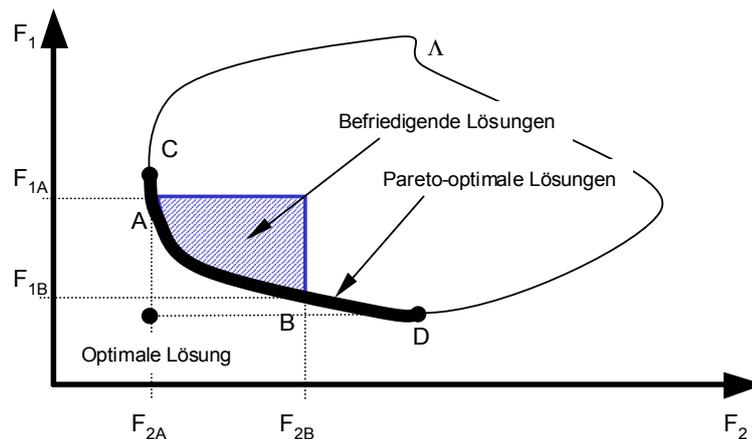


Abb. 4.5 Lösungsraum für ein 2-dimensionales Minimierungsproblem mit pareto-optimalen und befriedigenden Lösungen (nach [5, 44])

Für den zweidimensionalen Fall ist das Problem in **Abb. 4.5** dargestellt. Die optimale Lösung ist auf Grund des durch Nebenbedingungen begrenzten Lösungsraums

Λ nicht realisierbar. Es ist ersichtlich, dass für alle pareto-optimalen Lösungen F entlang der Begrenzung $C - D$ von Λ gilt:

$$F_{1i} < F_{1j} \quad \text{und} \quad F_{2i} > F_{2j} \quad \text{für} \quad i \neq j; \quad i, j \in \{C, D\} \quad (4.5)$$

Der mögliche Lösungsraum für befriedigende Lösungen muss je nach Aufgabenfall festgelegt werden. Es ist nicht zwingend notwendig, dass nur pareto-optimale Lösungen als befriedigend im Sinne des Optimierungsproblems gelten. Lösungsansätze für multikriterielle Probleme werden in den Kapiteln 6 und 7 behandelt.

4.3.3 Skalare Zielfunktionen

Skalare Zielfunktionen sind ein Sonderfall des mit **Gl. 4.1** auf Seite 23 beschriebenen Systems. $F(\mathbf{x})$ ist hier kein Vektor konkurrierender Zielgrößen, sondern eine skalare Größe. Prinzipiell lässt sich jedes multikriterielle Optimierungsproblem mit Nebenbedingungen mehr oder weniger exakt auf ein eindimensionales nebenbedingungsfreies Problem reduzieren. Eine Optimierung kann dann mit schnellen eindimensionalen Algorithmen erfolgen. Allerdings ist die Projektion des Problems auf eine skalare Zielfunktion meist nicht trivial. Insbesondere bei sehr vielen konkurrierenden Parametern und Zielgrößen ist die Findung einer geeigneten skalaren Zielfunktion meist nicht ohne umfangreiche Vorversuche möglich, die wiederum ein ausreichendes a-priori-Wissen über das Systemverhalten erfordern. Je nach genauer Problemstellung kann also mehr Zeit für die Findung von schnell optimierbaren Zielfunktionen oder aber für die Optimierung selbst aufgewendet werden. Im Folgenden sind zwei mögliche Methoden zur Bildung skalarer Zielfunktionen für mehrzielige Optimierungsaufgaben aufgezeigt.

Strategie der gewichteten Summe (Lagrange'sche Multiplikatoren)

Lagrange'sche Multiplikatoren können sowohl zur Behandlung von Nebenbedingungen als auch bei der Vereinigung mehrerer Zielfunktionen zu einer skalaren Funktion eingesetzt werden. Es soll zunächst ein Problem mit einer einzigen Zielfunktion $F_1(x_1)$ und einer einzigen Nebenbedingung $G_1(x_1) = 0$ betrachtet werden. Führt man das Steigungsverhältnis

$$\frac{dF_1/dx_1}{dG_1/dx_1} = \lambda \quad (4.6)$$

ein, so erhält man nach entsprechender Umformung

$$\frac{dF_1}{dx_1} - \lambda \frac{dG_1}{dx_1} = 0. \quad (4.7)$$

Zusammen mit der Nebenbedingung $G_1(x_1) = 0$ kann diese Gleichung als notwendige Bedingung für den Extremwert der erweiterten Zielfunktion

$$\tilde{F}_1(x, \lambda) = F_1(x_1) - \lambda G_1(x_1) \quad (4.8)$$

betrachtet werden. Verallgemeinert lautet das Minimierungsproblem aus **Gl. 4.8**:

$$\min_{\mathbf{x} \in \mathfrak{R}^n} \tilde{\mathbf{F}}(\mathbf{x}, \lambda) = \sum_{i=1}^d w_i F_i(\mathbf{x})^2 - \sum_{j=1}^m \lambda_j G_j(\mathbf{x}) \quad (4.9)$$

Die Methode der Lagrange'schen Multiplikatoren führt in der Regel zu einfacheren Gleichungen als andere Methoden, obwohl zusätzliche Variablen eingeführt werden. Die Lagrange-Faktoren w_i und λ_j der einzelnen Zielfunktionen und Nebenbedingungen können vorgegeben oder bei Verwendung eines entsprechenden Algorithmus ebenfalls geschätzt werden. Handelt es sich bei dem Lösungsvektor \mathbf{x}^* allerdings um eine singuläre Lösung der Gleichung **Gl. 4.9**, führt diese Transformation in Kombination mit klassischen Hill-Climbing-Verfahren (vgl. Kapitel 6) nicht zum Erfolg. Dieser Fall tritt auf, wenn durch die Transformation ein bestehendes Minimum-Problem in ein Sattelpunkt-Problem umgewandelt wird ([26]).

Als ebenfalls problematisch erweist sich die Minimumfindung bei konkaven Lösungsräumen. Für den zweidimensionalen Fall verdeutlicht das **Abb. 4.6 a**. Betrachtet man eine Gerade H mit der Gleichung $\mathbf{w}^T \mathbf{F}(\mathbf{x}) = k$ im Lösungsraum, so kann das zweidimensionale Minimierungsproblem folgendermaßen interpretiert werden: Es ist ein Wert k derart zu finden, dass die Gerade H die Grenze von Λ gerade berührt. Bei nichtkonvexen Λ sind dann jedoch die Lösungen zwischen A und B nicht verfügbar.

ϵ -constrained-Methode

Einige nichtkonvexe Probleme können mit der so genannten ϵ -constrained-Methode erfolgreich behandelt werden. Dabei werden ein primäres Ziel $F_p(\mathbf{x})$ definiert und alle weiteren konkurrierenden Ziele in Form von Ungleichungs-Nebenbedingungen ausgedrückt:

$$\min_{\mathbf{x} \in \Omega} F_p(\mathbf{x}) \quad \text{für} \quad F_i(\mathbf{x}) \leq \epsilon_i \quad ; \quad i = 1, \dots, d \quad i \neq p \quad (4.10)$$

Abb. 4.6 b zeigt die grafische Interpretation für den zweidimensionalen Fall. Um zu verwertbaren Ergebnissen zu gelangen, muss in erster Linie eine geeignete Wahl von ϵ erfolgen. Das ist für komplexe Optimierungsprobleme ohne genaue Kenntnis des Prozesses schwer möglich.

Da es sich bei der Optimierung von Verbrennungsmotoren meist um konvexe Probleme handelt (vgl. Kapitel 5), soll in dieser Arbeit ausschließlich die Methode der

Lagrange'schen Multiplikatoren angewendet werden.

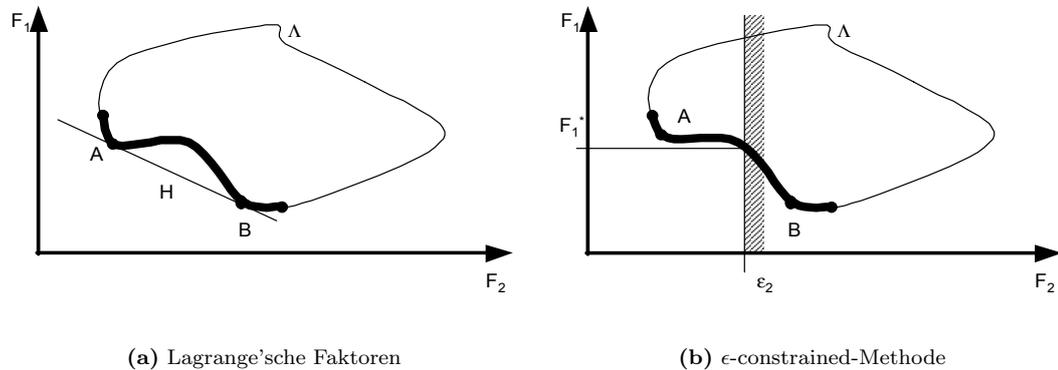


Abb. 4.6 Skalare Zielfunktionen für konkave Lösungsräume

In [45] wird eine speziell für die Optimierung von Nutzfahrzeug-Dieselmotoren formulierte Variante einer skalaren Zielfunktion vorgestellt. Diese Funktion gilt es zu maximieren:

$$\max_{\mathbf{x} \in \mathfrak{R}^n} F(\mathbf{x}) \quad \text{für} \quad F(\mathbf{x}) = \frac{1000}{\left(\frac{NO_x}{NO_{xt}}\right)^2 + \left(\frac{PM}{PM_t}\right)^2 + \frac{b_e}{b_{et}}} \quad (4.11)$$

mit:

$$\begin{aligned} \mathbf{p} &= (NO_x, PM, b_e) && \text{- gemessene Prozessgrößen} \\ \mathbf{p}_t &= (NO_{xt}, PM_t, b_{et}) && \text{- Zielwerte der Prozessgrößen} \end{aligned}$$

Der Ursprung dieser Art der multikriteriellen Zielfunktion liegt im so genannten Goal-Programming, einer Klasse von mehrzieligen Optimierungsverfahren, die vielfältige Lösungsansätze vereint (vgl. dazu [44]). All diesen Methoden gemein ist der Versuch, den zu bewertenden Prozessgrößenvektor \mathbf{p} an einen Zielvektor \mathbf{p}_t anzunähern. Im gezeigten Beispiel sind alle Größen gleich gewichtet.

Ein allgemeingültiger Ansatz für multikriterielle Probleme, der nicht in einer skalaren Optimierung resultiert, und ein darauf zugeschnittener Optimierungsalgorithmus - die Goal-Attainment-Methode - wird in Kapitel 6 vorgestellt und angewendet.

4.4 Stationäre Optimierung an Dieselmotoren

Soll ein Dieselmotor in einem stationären Betriebspunkt optimiert werden, so sind vom Optimierer die möglichen Führungsgrößen, wie z. B. Einspritzbeginn, Ladedruck und Abgasrückführtrate so aufeinander abzustimmen, dass der Motor sich entsprechend einer vom Betreiber frei wählbaren Betriebsstrategie verhält. Eine solche Betriebsstrategie könnte z. B. der minimale Kraftstoffverbrauch bei Einhaltung von vorgegebenen Emissionsgrenzwerten sein. In [11, 74] wurde ausgehend von **Gl. 4.9** für diese Betriebsstrategie folgende skalare Zielfunktion formuliert:

$$F(\mathbf{x}) = b_e(\mathbf{x}) + \lambda_1 G_{NO_x}(\mathbf{x}) + \lambda_2 G_{p_{zmax}}(\mathbf{x}) + \lambda_3 G_{SZ}(\mathbf{x}) \quad (4.12)$$

mit

$$G_p(\mathbf{x}) = \begin{cases} p_i(\mathbf{x}) - p_{ti} & p_{ti} < p_i(\mathbf{x}) \\ 0 & p_{ti} \geq p_i(\mathbf{x}) \end{cases} \quad i = 1, \dots, d \quad (4.13)$$

$p_i(\mathbf{x})$ - gemessene Prozessgröße i
 p_{ti} - Zielwert der Prozessgröße i

Ziel ist die Findung des Minimums dieser Funktion. Die Überschreitung des vorgegebenen NO_x -Grenzwertes p_{tNO_x} wird durch einen entsprechenden Strafterm bewertet und führt je nach Wahl des Lagrange-Faktors λ_1 zu einem mehr oder minder starken Ansteigen der Zielfunktion bei kritischen Führungsgrößenvektoren \mathbf{x} . Analog dazu sind in der beispielhaften Zielfunktion Strafterme für die Überschreitung von Grenzwerten für p_{zmax} und SZ definiert. **Abb. 4.7** auf der nächsten Seite zeigt einen Optimierungslauf bei Verwendung einer Koordinatenstrategie mit variabler Schrittweite und einem Führungsgrößen-Vektor, zusammengesetzt aus Ladedruck und Einspritzbeginn. Die gezeigte Optimierung wurde online am Motorenprüfstand durchgeführt, d. h. die Ausgabe der vom Optimierer erzeugten Führungsgrößen erfolgte direkt an den stationär betriebenen Verbrennungsmotor.

Nachdem jeweils stabile Messwerte für die zu berücksichtigenden Prozessgrößen erreicht wurden, erfolgte eine erneute Berechnung der Zielfunktion und die Generierung neuer Führungsgrößen. Der Optimierungslauf wurde erfolgreich beendet, wenn keine Verbesserung der Zielfunktion mehr auftrat. Mit dieser Methode ist es möglich, den Motorprozess unter stationären Gesichtspunkten im gesamten Betriebsbereich des Motors zu optimieren. Die für ausgewählte stationäre Motorbetriebspunkte ermittelten Führungsgrößenkombinationen können zu Führungsgrößen-Kennfeldern zusammengefasst im Steuergerät des Motors abgelegt werden (**Abb. 4.1** auf Seite 18). Eine solche Vorgehensweise entspricht nach der Definition in Abschnitt 4.3.1 einer *zyklusorientierten quasistationären Betriebspunktoptimierung*.

Bei überwiegend stationär betriebenen Dieselmotoren, wie etwa in stationären Energie-Erzeugungsanlagen oder in seegehenden Schiffen, ergibt sich eine weitere interessante Anwendung der stationären Online-Prozessoptimierung. Das Optimierungsverfahren wird als so genanntes Meta-Managementsystem der eigentli-

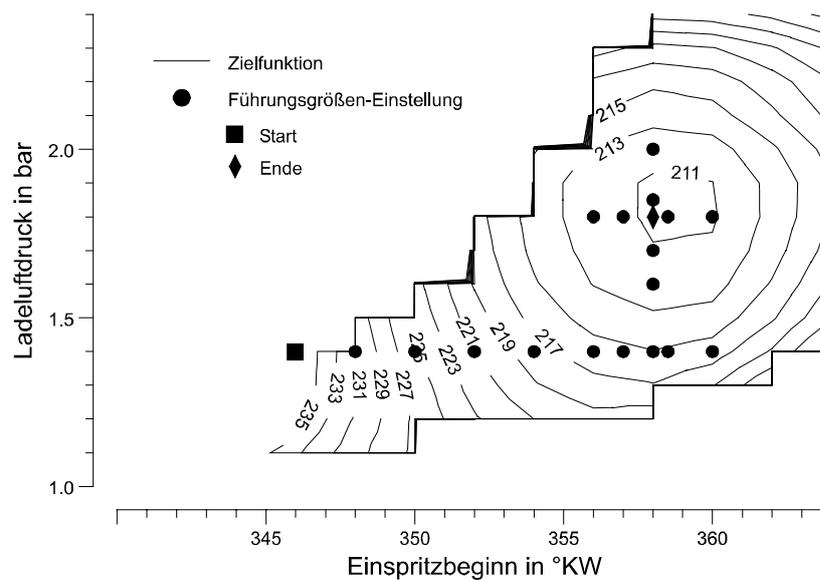


Abb. 4.7 Beispiel eines Optimierungslaufes im stationären Motorbetrieb (Motor OM 441 LA, Betriebspunkt: $n = 2000 \text{min}^{-1}$, $p_{me} = 5 \text{bar}$, Koordinatenstrategie), nach [11]

chen Steuergerätefunktionalität überlagert. Es wird dadurch eine kontinuierliche Nachführung der Führungsgrößen und somit eine optimale Prozessführung im Sinne der gewählten Betriebsstrategie möglich. Alterungsprozesse und Fehlfunktionen einzelner Motorbauteile können in gewissen Grenzen kompensiert werden, [74].

4.5 Dynamische Optimierung

4.5.1 Dynamischer Motorbetrieb

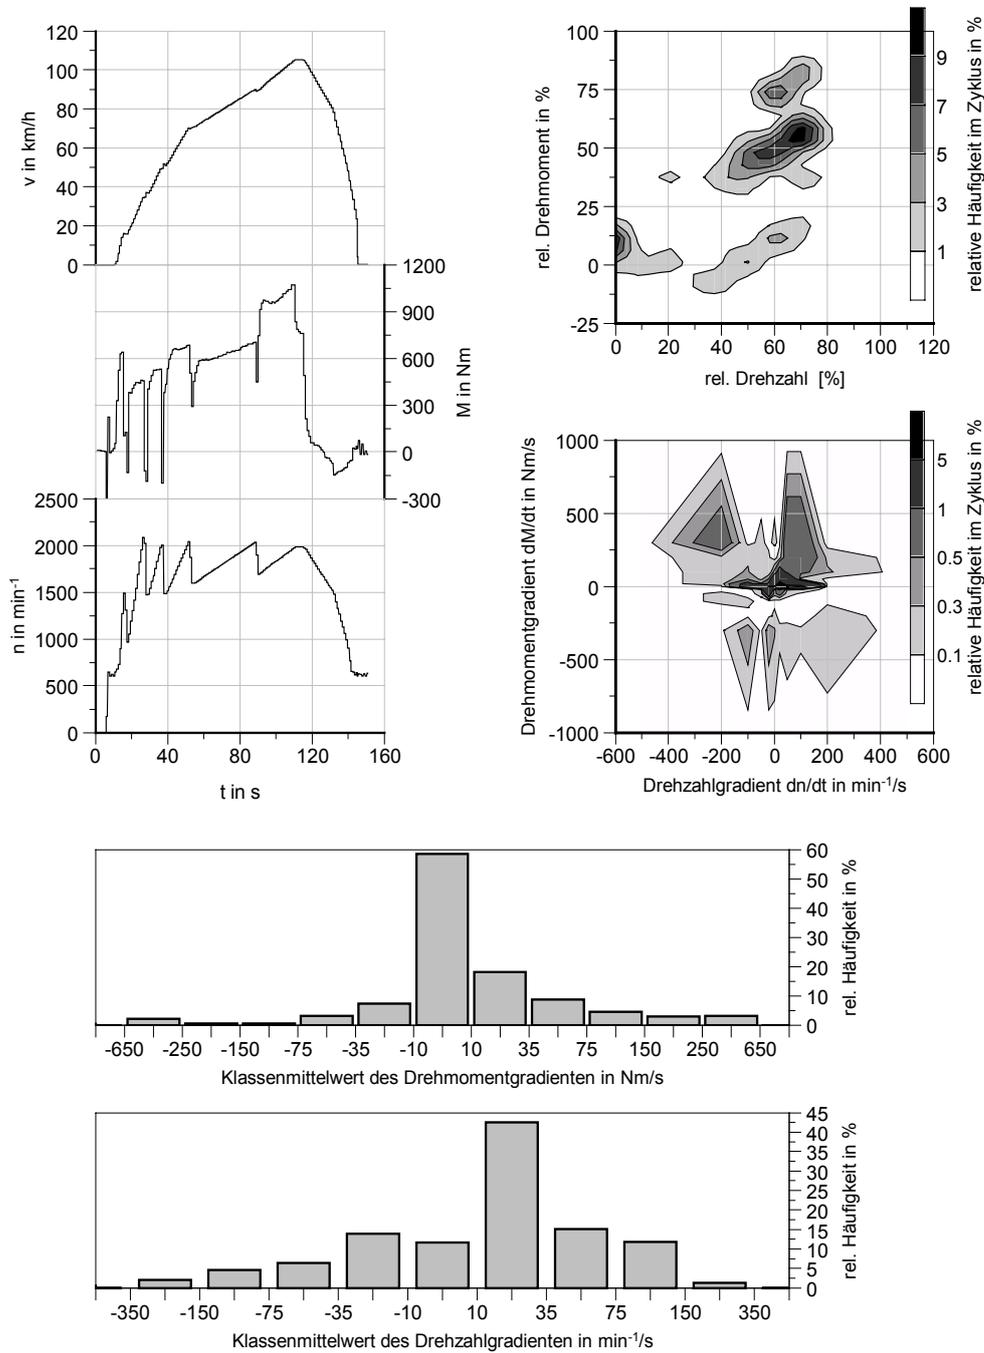


Abb. 4.8 Eigenschaften des verwendeten Testzyklus

Bei einem Fahrzeugmotor liegt im realen Fahrbetrieb praktisch nie ein rein stationärer Motorbetriebszustand vor, auch wenn er zwischenzeitlich in stationären

Betriebspunkten betrieben wird. Gesetzlich vorgeschriebene Testzyklen stellen besondere Fahrprogramme dar, für die gewisse Emissionsgrenzwerte definiert sind. **Abb. 4.8** auf der vorherigen Seite zeigt die Verteilung von Fahrgeschwindigkeit, Drehzahl, Drehmoment und den entsprechenden Gradienten für ein (virtuelles) Nutzfahrzeug mit 12 Tonnen Gesamtmasse und einem 6-Gang-Getriebe, gemessen auf dem dynamischen Motorenprüfstand entlang eines Testzyklus. Die Aufgabe der Prozessoptimierung besteht hier - ähnlich der bei stationären Motorbetriebspunkten - darin, den Motorprozess dahingehend zu optimieren, dass legislativ vorgeschriebene Zyklus-Grenzwerte eingehalten werden und gleichzeitig dem Kundenwunsch nach geringstmöglichem Kraftstoffverbrauch Rechnung getragen wird.

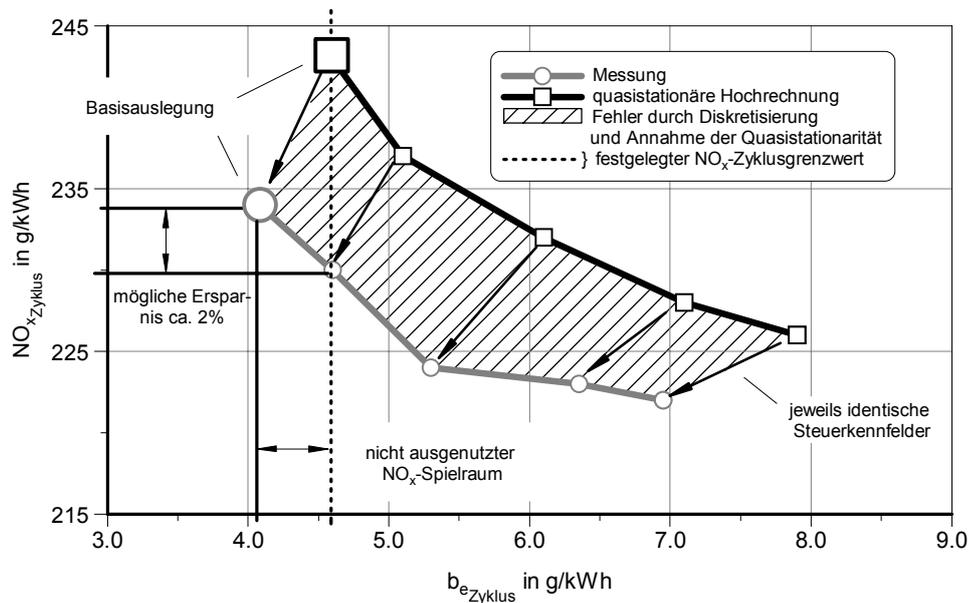


Abb. 4.9 Potential der dynamischen Optimierung im Vergleich zur Optimierung bei quasistationärer Betrachtungsweise im MVEG(EUDC)-Testzyklus

Auf Grund gestiegener Anforderungen an den Fahrzeugbetrieb reicht es im Allgemeinen zur Erfüllung einer solchen Optimierungsaufgabe nicht mehr aus, stationäre Betriebspunkte zu optimieren und aus den so gewonnenen Führungsgrößen-Vektoren entsprechende Kennfelder aufzuspannen, die dann den Motor im dynamischen Betrieb steuern (quasistationäre Betrachtung). Vielmehr muss ein Übergang zur *dynamischen* Optimierung erfolgen.

Differenzen zwischen der quasistationären Hochrechnung stationärer Emissionsmesswerte und experimentellen Zyklusergebnissen wurden schon in [67] und [68] nachgewiesen. **Abb. 4.9** verdeutlicht diese Problematik. Die untere Kurve stellt den gemessenen Zusammenhang zwischen NO_x -Emission und Kraftstoffverbrauch dar, wie er sich beim Durchfahren eines Testzyklus mit unterschiedlichen Führungsgrößen-Kennfeldern für Einspritzbeginn und Ladedruck ergibt (Trade-Off-Kurve).

Die hierbei verwendeten Führungsgrößen-Kennfelder wurden zuvor für diesen Testzyklus stationär optimiert. Dazu wurde der Testzyklus zunächst entsprechend ihrer

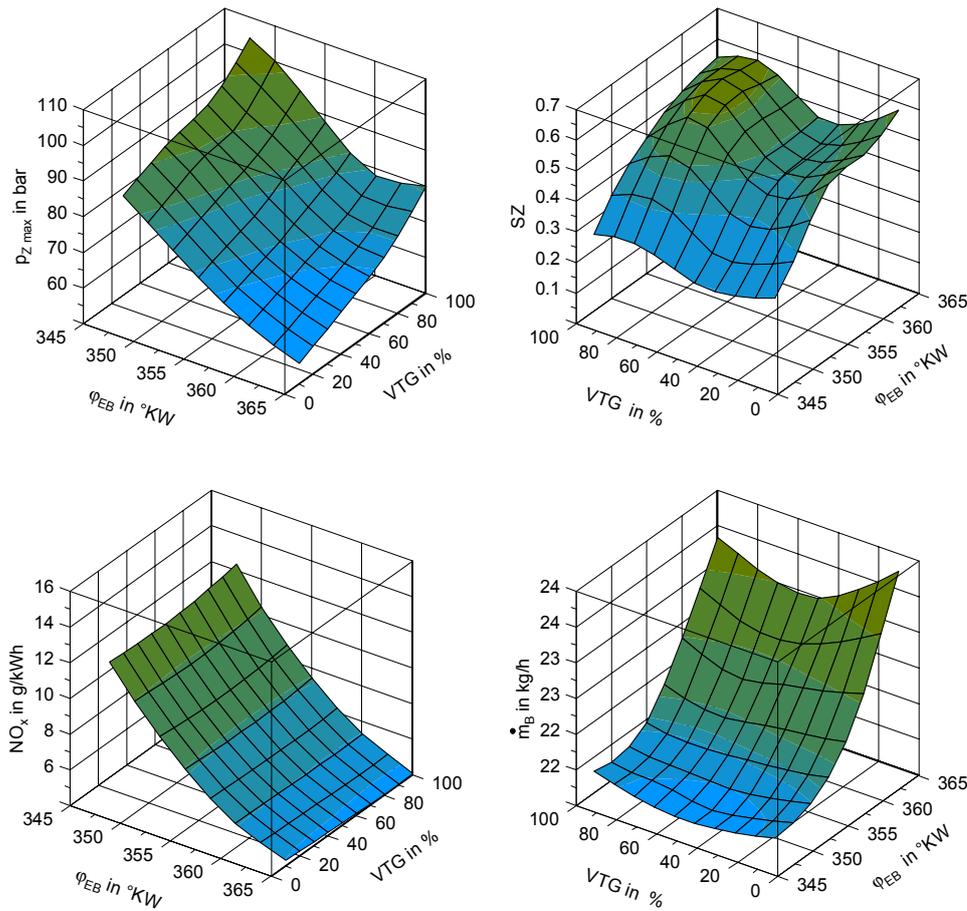


Abb. 4.10 Rastervermessung des Betriebspunktes 8: $n = 1575 \text{ min}^{-1}$, $p_{me} = 7 \text{ bar}$ für Variation von EB und Ladedruck

Häufigkeitsverteilung (siehe **Abb. 4.8**) in 15 repräsentative stationäre Betriebspunkte zerlegt und der Versuchsmotor in diesen unter Variation der Führungsgrößen rastermäßig¹³ vermessen. **Abb. 4.10** zeigt das Ergebnis dieser Vermessung für einen der 15 repräsentativen Motorbetriebspunkte. Mit den relativen Häufigkeiten h_i des den entsprechenden Betriebspunkten zugeordneten Motorbetriebsbereiches (Klasse) im Gesamtzyklus und der Vorgabe eines NO_x -Grenzwertes für den Gesamtzyklus $NO_{xZyklus_t}$ konnte nun für jeden Betriebspunkt ein lokaler NO_x -Grenzwert NO_{xti} festgelegt werden. Unter Berücksichtigung der relativen Häufigkeit des Betriebspunktes im Zyklus wurden die einzelnen NO_x -Grenzwerte über

$$\frac{\sum_{i=1}^{i=15} NO_{xi} h_i P_i}{\bar{P}_{Zyklus}} = NO_{xZyklus} \quad (4.14)$$

berechnet. Eine unterschiedliche Bewertung der einzelnen Betriebspunkte bezüglich ihrer NO_x -Emissionen führte bei diesem Motor zu nur unwesentlich anderen optimalen Führungsgrößen-Kennfeldern als bei einem Ansatz $NO_{xti} = NO_{xtj}$. Mit

¹³Das Rastergitter wird mit jeweils 6 nicht äquidistanten Zwischenwerten im jeweiligen Verstellbereich gebildet.

der Einführung von zusätzlichen Grenzwerten für die Schwärzungszahl und den maximalen Zylinderdruck in jedem repräsentativen Betriebspunkt wurde mit einem Suchverfahren (vollständige Enumeration) aus den Ergebnissen der Rastervermessung jeweils die optimale Motoreinstellung gefunden.

Als Zielfunktion diente **Gl. 4.12**, wobei die gewählten Bewertungsfaktoren der Lagrange-Terme von $\lambda_i = 10000$ erwartungsgemäß zu einer rechnerisch exakten Einhaltung der vorgegebenen Grenzwerte führte (starke Bestrafung bei Überschreitung der Vorgaben). Aus den so gewonnenen optimalen Führungsgrößenvektoren wurden Führungsgrößen-Kennfelder aufgestellt, die den Versuchsmotor dann beim Durchfahren des Testzyklus steuern.

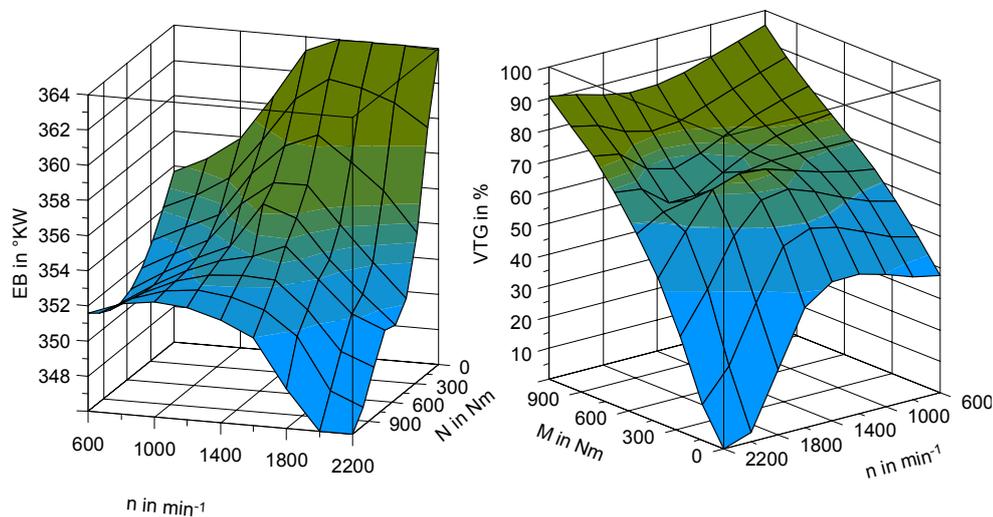


Abb. 4.11 b_e -optimale Führungsgrößen-Kennfelder für VTG und EB bei globalem NO_x -Grenzwert $NO_{xZyklus_t} = 7g/kWh$, $SZ_t < 1$ und $p_{z_{max_t}} < 130bar$

Abb. 4.11 zeigt die so entstandenen Führungsgrößen-Kennfelder für Einspritzbeginn EB und VTG-Stellung. Auf eine Regelung des Ladedruckes wurde bewusst verzichtet, da sie aufgrund des nichtlinearen Streckenmodells der Ladeluftstrecke nur als sehr langsam ausgelegt werden konnte. Um schnelle Reaktionszeiten des VTG-Laders gewährleisten zu können, ist die Überlagerung mit einer Steuerungskomponente unabdingbar, welche in dynamischen Motorbetriebsphasen dann auch den Hauptanteil des Stellgrößenverlaufs ausmacht. Es erwies sich deshalb als hinreichend, auf die Ladedruckregelung ganz zu verzichten und nur eine Regelstrecke für die VTG-Stellung zu implementieren.

Die Stützstellen der berechneten Trade-Off-Kurve (quasistationäre Hochrechnung)

in **Abb. 4.9** auf Seite 31 ergeben sich mit **Gl. 4.15** und **Gl. 4.16**.

$$NO_{x_{Zyklus}} = \frac{\sum_{i=1}^{i=15} NO_{x_i} h_i P_i}{\bar{P}_{Zyklus}} \quad (4.15)$$

$$b_{e_{Zyklus}} = \frac{\sum_{i=1}^{i=15} b_{e_i} h_i P_i}{\bar{P}_{Zyklus}}, \quad (4.16)$$

mit $i =$ Nummer des repräsentativen Betriebspunktes.

Die aus der quasistationären Berechnungsweise hervorgehende Kurve liegt deutlich oberhalb der gemessenen, d.h. der ursprünglich für die Optimierung angesetzte NO_x -Grenzwert für den Testzyklus wird im realen Motorversuch deutlich unterschritten und das zur Verfügung stehende Einsparungspotential für den Kraftstoffverbrauch nicht ausgeschöpft. Im vorliegenden Beispiel ergibt sich ein ungenutztes Einsparungspotential für den Kraftstoffverbrauch von ca. 2 %.

Dafür gibt es im Wesentlichen zwei Ursachen:

1. Fehler durch die Diskretisierung des Testzyklus (hier 15 Betriebspunkte) und Klassierung
2. Fehler durch Vernachlässigung dynamischer Effekte, insbesondere bei der Emissionsentstehung

Der Diskretisierungsfehler kann verringert werden, indem die Trade-Off-Kurve nicht nach **Gl. (4.15)** und **Gl. (4.16)** berechnet wird, sondern durch Interpolation der rastervermessenen Motorkennfelder entlang des Testzyklus erfolgt. Dieses Verfahren führt zwar zu einer Annäherung der rechnerischen Stützstellen an die gemessenen Werte, setzt jedoch zur Einhaltung der vorgegebenen Zyklusgrenzwerte voraus, dass nach jedem Suchschritt des Optimierungsverfahrens ein kompletter Interpolationslauf (Zykluslauf) durchgeführt und das Ergebnis entsprechend bewertet wird. Es handelt sich dann um eine *zyklusorientierte quasistationäre Kennfeldoptimierung*. Ein solcher Algorithmus benötigt ein Vielfaches der Rechenzeit des ZQBPO und hat weiterhin den Nachteil, dass es sich um eine quasistationäre Betrachtungsweise handelt und dynamische Effekte nicht berücksichtigt werden können.

Einen anderen Nachteil des Einsatzes stationär optimierter Kennfelder mit klassischer Drehzahl-Last-Definition zeigt **Tab. 4.2**.

Im zweiten Teil des neuen europäischen Fahrzyklus (EUDC)¹⁴ mit seinen langen Stationärphasen bilden sich die der Kennfeldoptimierung zu Grunde gelegten betriebsstrategiespezifischen Effekte heraus. Die Verbrauchswerte liegen bei Verwendung von zuvor stationär für minimalen Kraftstoffverbrauch unter Einhaltung eines NO_x -Grenzwertes optimierter Führungsgrößen-Kennfelder¹⁵ niedriger als bei Verwendung von Kennfeldern, die für minimale NO_x -Emissionen bei Einhaltung einer

¹⁴Extra Urban Driving Cycle

¹⁵ b_e -optimale Betriebsstrategie

Tab. 4.2 Vergleich der zyklusspezifischen Ergebnisse bei Verwendung unterschiedlicher Testzyklen mit b_e - und NO_x -optimalen Führungsgrößen-Kennfeldern

Zyklus	Strategie	$b_{e\text{ Zyklus}}$	$NO_{x\text{ Zyklus}}$	Differenz $b_{e\text{ Zyklus}}^a$	Differenz $NO_{x\text{ Zyklus}}^b$
Modellzyklus ^c	b_e -optimal	316,6 g/km	7,03 g/km	-0,25 %	0,6 %
	NO_x -optimal	317,4 g/km	7,07 g/km		
MVEG(EUDC)	b_e -optimal	282,5 g/km	6,59 g/km	-3,4 %	-19,8 %
	NO_x -optimal	292,2 g/km	5,50 g/km		

^abezogen auf NO_x -optimale Strategie

^bbezogen auf b_e -optimale Strategie

^cvgl. **Abb. 4.8**

Kraftstoffverbrauchsgrenze¹⁶ optimiert wurden. Anders stellt sich das bei dem recht dynamischen Modellzyklus entsprechend **Abb. 4.8** dar. Hier ist nur ein marginaler Unterschied in den Zyklussummenwerten zu erkennen. Die erzielten Ergebnisse sprechen für eine testzyklusspezifische Optimierung unter Berücksichtigung dynamischer Motorbetriebsphasen (ZDKFO), da offensichtlich eine starke Abhängigkeit der betriebsstrategie-optimalen Kennfelder von den Testzykluseigenschaften besteht.

Zusammenfassend lässt sich feststellen, dass stationäre Optimierungsverfahren angewendet auf die Aufgabe der Erfüllung eines (gesetzlich) vorgeschriebenen Testzyklus nur eine Orientierungshilfe darstellen können. Eine Feinabstimmung der Motorsteuerung ist in jedem Falle notwendig, ob direkt im Fahrzeug auf dem Rollenprüfstand oder auf dem dynamischen Motorenprüfstand.

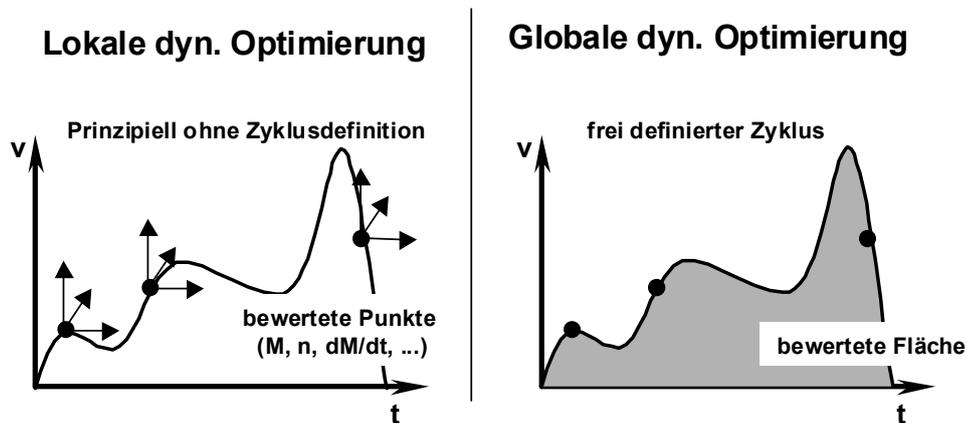


Abb. 4.12 „Lokale“ und „globale“ Optimierung des dynamischen Motorbetriebs

Zwei völlig unterschiedliche Herangehensweisen können zur Optimierung des dynamischen Motorbetriebs genutzt werden. In **Abb. 4.12** sind diese beiden Verfahren gegenübergestellt.

¹⁶ NO_x -optimale Betriebsstrategie

4.5.2 Lokale dynamische Optimierung

Bei der so genannten *lokalen* Optimierung wird davon ausgegangen, dass sich der Motorprozess zu jedem Zeitpunkt im Testzyklus bezüglich seiner (dynamischen) Betriebswerte eindeutig beschreiben lässt (dynamischer Betriebspunkt). Die Betriebspunktdefinition muss dazu neben den im stationären Fall ausreichenden Größen Motordrehzahl und -last zusätzliche Parameter beinhalten, die die momentane Dynamik des Prozesses beschreiben¹⁷. Erreicht der Prozess während des Zyklusdurchlaufs einen bestimmten so definierten Betriebspunkt, kann der Optimierer, ausgehend von den Ergebnissen vorangegangener Optimierungsschritte in diesem Betriebspunkt, einen neuen Führungsgrößenvektor, der nur für diesen dynamischen Betriebspunkt Gültigkeit hat, generieren. Bis zum wiederholten Erreichen des Betriebspunktes werden die Daten in einer Datenbank abgelegt, sodass in der Zwischenzeit andere Betriebspunkte optimiert werden können. Idealerweise gibt es also für jeden im Testzyklus durchfahrenen dynamischen Betriebspunkt genau einen Optimierungsprozess nach **Abb. 4.1**. Alle diese Prozesse laufen parallel ab.

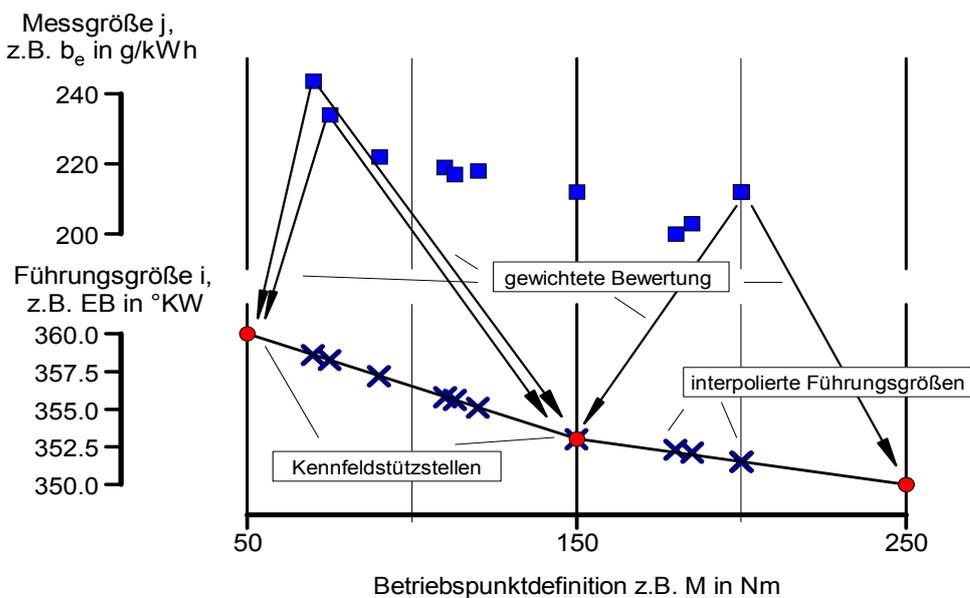


Abb. 4.13 Rückrechnung der Messwerte auf Führungsgrößen-Stützstellen

Praktisch kann jedoch nur eine bestimmte Stützstelle im Führungsgrößen-Kennfeld optimiert werden. Die Anzahl der parallel ablaufenden Optimierungsprozesse ist auf die Anzahl der Kennfeldstützstellen begrenzt. Ausgehend von einem Basis-Kennfeld¹⁸ für jede Führungsgröße sind die Kennfeldstützstellen während des Zykluslaufs einer ständigen Veränderung unterworfen, je nach dem, welcher dynamische Betriebspunkt gerade durchlaufen wird. Ein optimales Ergebnis für alle Kennfeldbe-

¹⁷Eine solche Betriebspunktdefinition kann z. B. die Gradienten für n und M enthalten

¹⁸Die Kennfelddefinition muss mit der Definition des dynamischen Betriebspunktes übereinstimmen (erweiterte Dimensionalität).

reiche lässt sich nur dann erzielen, wenn jeder Betriebspunkt oft genug angefahren wird. Das kann unter Umständen nur durch mehrmaliges Wiederholen des Zyklusdurchlaufs erreicht werden. Vorteilhaft bei dieser Methode ist, dass sie als Online-Verfahren in das Seriensteuergerät des Fahrzeugs implementiert werden und so den Motorprozess kontinuierlich optimieren kann.

Folgende gravierende Unzulänglichkeiten sprechen jedoch gegen die Anwendung der *lokalen* Optimierung:

- Jedem dynamischen Betriebspunkt muss ein momentaner Messwert-Datensatz zugeordnet werden. Sowohl die Messtechnik für Schadstoff-Emissionen als auch für den momentanen Kraftstoffverbrauch lässt das, auf Grund systembedingter Gerätedynamiken, nicht zu (vgl. Kapitel 4).
- Die aktuellen Führungsgrößen werden aus Führungsgrößen-Kennfeldern interpoliert. Es besteht nun bei der Optimierung die Aufgabe, die momentanen Messwerte und die aus dem Optimierungsschritt resultierende Führungsgrößen-Variation einer oder mehreren Kennfeldstützstellen zuzuordnen. **Abb. 4.13** verdeutlicht diese Problematik vereinfacht in der Ebene. Man erkennt, dass die parallel für mehrere Betriebspunkte ablaufenden Optimierungsprozesse zur Bewertung an einer einzigen Stützstelle führen. Die kontinuierliche Veränderung der Kennfeld-Stützstellen durch konkurrierende Optimierungsprozesse lässt sich kaum in einer Optimierungs-Methodik berücksichtigen und würde zu einem enormen Aufwand in der Datenhaltung führen.
- Die Randbedingungen des Motorprozesses können sich kurzfristig ändern (z. B. nach dem Kaltstart). Das müsste durch das Optimierungssystem berücksichtigt werden, um einer ständigen Anpassung der Kennfelder auf nur kurzzeitig vorhandene Randbedingungen entgegenzuwirken. Auch hieraus ergibt sich ein nicht zu vertretender Aufwand in der Datenhaltung.

4.5.3 Globale dynamische Optimierung

Eine Ausschöpfung der zur Verfügung stehenden Potentiale mit vertretbarem Aufwand kann mit dem Ansatz einer *zyklusorientierten dynamischen Optimierung* (DKFO) erreicht werden. Der in **Abb. 4.1** auf Seite 18 dargestellte Algorithmus bleibt dabei prinzipiell erhalten. Es werden jedoch nicht einzelne, stationäre Betriebspunkte untersucht, sondern es wird das *globale* Ergebnis eines Testzyklus-Durchlaufs zur Prozessbewertung herangezogen (vgl. **Abb. 4.12** auf Seite 35). Ein wesentlicher Unterschied zur ZQKFO liegt damit in der tatsächlichen dynamischen Vermessung der Auswirkungen einer Führungsgrößenänderung im Zuge eines Optimierungsschrittes.

Die Zielfunktion setzt sich bei dieser Aufgabe aus über den Zyklus kumulierten Messwerten (z. B. zyklusspezifische NO_x -Emission, Kraftstoffverbrauch) und Straf-Kennfeldern, in denen „lokale“ Grenzwertüberschreitungen in bestimmten Betriebsbereichen dargestellt sind, zusammen. **Abb. 4.14** auf der nächsten Seite verdeutlicht

die unterschiedlichen Bewertungsgrößen. Den Straf-Kennfeldern liegt dabei die gleiche Definition wie den Führungsgrößen-Kennfeldern zu Grunde, sodass die Grenzwertüberschreitungen auf die zu optimierenden Kennfeldstützstellen gewichtet werden können. Auf Grund der Tatsache, dass diese Kennfelder Aussagen über Ereignisse im *Verlauf* des Testzyklus liefern, werden sie als Modalmatrizen bezeichnet. Mit dieser Bewertungsmethode können unterschiedlichste globale und lokale Beschränkungen in einer einzigen skalaren Zielfunktion berücksichtigt werden:

$$F(\mathbf{x}_{\mathbf{KF}}) = b_{eZyk}(\mathbf{x}_{\mathbf{KF}}) + \lambda_1 G_{NO_x Zyk}(\mathbf{x}_{\mathbf{KF}}) + \lambda_2 G_{p_{zmax} Zyk}(\mathbf{x}_{\mathbf{KF}}) + \lambda_3 G_{SZ Zyk}(\mathbf{x}_{\mathbf{KF}}) \quad (4.17)$$

mit

$$G_{pZyk}(\mathbf{x}_{\mathbf{KF}}) = \begin{cases} p_{iZyk}(\mathbf{x}_{\mathbf{KF}}) - p_{tiZyk} & p_{tiZyk} < p_{i(\mathbf{x}_{\mathbf{KF}})Zyk} ; \\ 0 & p_{tiZyk} \geq p_{i(\mathbf{x}_{\mathbf{KF}})Zyk} \end{cases} \quad (4.18)$$

$$i = 1, \dots, d;$$

$$\mathbf{x}_{\mathbf{KF}} = (x_1^{S_0}, \dots, x_m^{S_0}, x_1^{S_j}, \dots, x_m^{S_j}, x_1^{S_s}, \dots, x_m^{S_s}).$$

- $p_{iZyk}(\mathbf{x}_{\mathbf{KF}})$ Zyklus-kummulierte Prozessgröße i
 p_{tiZyk} - Zyklus-Zielwert der Prozessgröße i
 S_j - Kennfeld-Stützstelle j

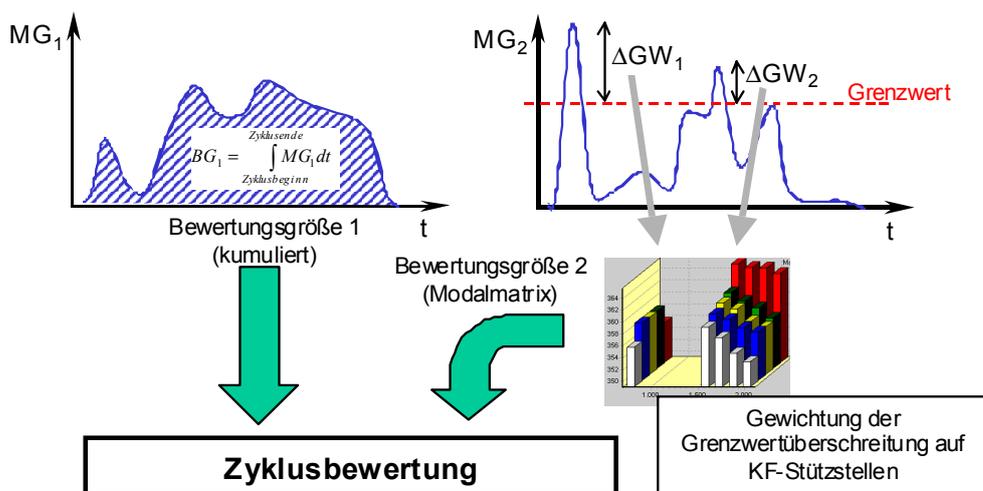


Abb. 4.14 Zyklusbewertung mit lokalen und globalen Messgrößen (MG - Messgröße, ΔGW - Grenzwertüberschreitung)

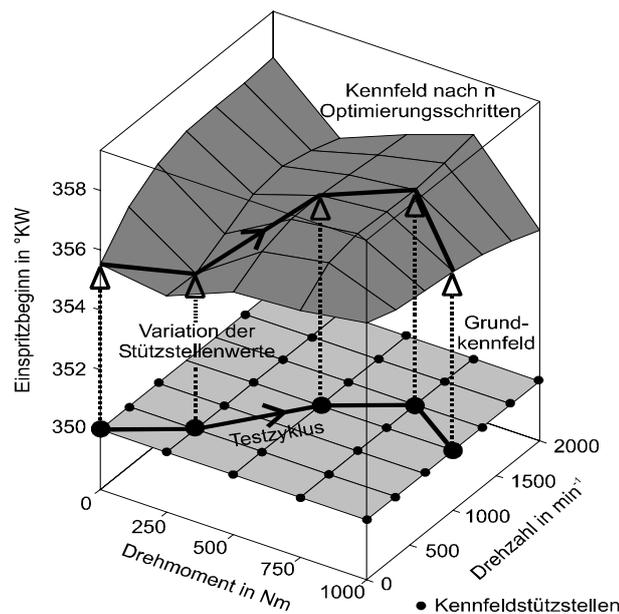


Abb. 4.15 Ablauf der Kennfeldoptimierung bei globaler Zyklusbewertung (schematisch)

Im Optimierer müssen anschließend vollständige Führungsgrößen-Kennfelder für den nächsten Optimierungsschritt generiert werden. Dieser Prozess wird solange fortgesetzt, bis ein Abbruchkriterium erfüllt, das Optimierungsergebnis also erreicht ist.¹⁹ Es steht dann ein Satz optimierter Führungsgrößen-Kennfelder zur Verfügung (siehe **Abb. 4.15**), der in das Steuergerät implementiert werden kann und der den Motorprozess optimal führt, sofern ein für den späteren Fahrzeugeinsatz repräsentativer Testzyklus zu Grunde gelegen hatte.

4.5.4 Kennfelderweiterung zur Identifizierung dynamischer Motorbetriebsphasen

Wie bereits erwähnt, definieren sich die Führungsgrößen-Kennfelder in Motorsteuergeräten im Allgemeinen über die Motordrehzahl und einen Lastparameter. Die daraus interpolierten Führungsgrößen-Vektoren sind deshalb unabhängig davon, ob ein Betriebspunkt im stationären Motorbetrieb oder beim Durchlaufen einer Beschleunigungs- bzw. Verzögerungsrampe im Testzyklus durchfahren wird. Die momentane Dynamik des Motorbetriebes kann bei klassischer Kennfelddefinition nur über zusätzliche Funktionen oder über die Abstimmung der Reglerparameter in den Folgereglern berücksichtigt werden. Im Folgenden sollen zwei Ansätze vorgestellt werden, mit denen diese Problematik umgangen werden kann, nämlich das

¹⁹Der Testzyklus-Durchlauf wird entsprechend oft wiederholt, wobei für konstante Randbedingungen zu sorgen ist. Es ist deshalb der dynamische Motorenprüfstand dem Fahrzeug-Rollenprüfstand vorzuziehen, zumal sich für diesen auch die Installation der Messtechnik wesentlich einfacher gestaltet.

Kennfeld-Clustering und die *Kennfelderweiterung*.

Kennfeld-Clustering

In **Abb. 4.16** sind sowohl die Fahrwiderstandskurven der einzelnen Gänge im stationären Motorbetrieb für eine Fahrzeugbewegung in der Ebene als auch ausgewählte nominelle Betriebspunkte, die in dynamischen Testzyklen auftreten, in das stationäre Motorkennfeld des M47R eingetragen. Der stationäre Motorbetrieb ist auf einen relativ kleinen Kennfeldbereich unterhalb der Fahrwiderstandskurve des 5. Ganges beschränkt. Schon in den Beschleunigungsphasen des MVEG-Zyklus wird dieser Bereich verlassen. Die Volllastbeschleunigung markiert ein Gebiet, nahe der Volllastkurve. Es scheint praktikabel, das Kennfeld in Bereiche aufzuteilen, in denen im Fahrzeugbetrieb unterschiedliche Beschleunigungs-/Verzögerungswerte zu erwarten sind, und diese *Cluster* nach unterschiedlichen Zielvorgaben zu optimieren. Im einfachsten Fall also das Gebiet unterhalb der höchsten Fahrwiderstandslinie für die SBPO und das Gebiet oberhalb dieser Kurve für ZDKFO bzw. DKFO. So wird es möglich, trotz zweidimensionaler Definition der Führungsgrößen-Kennfelder Einsparungspotentiale sowohl im stationären als auch im dynamischen Motorbetrieb zu nutzen. Auf Grund der anderen Betriebssituation bei Dieselmotoren in mobilen Maschinen kann dieser Ansatz auf diese jedoch nicht übernommen werden und muss auf Fahrzeugmotoren beschränkt bleiben.

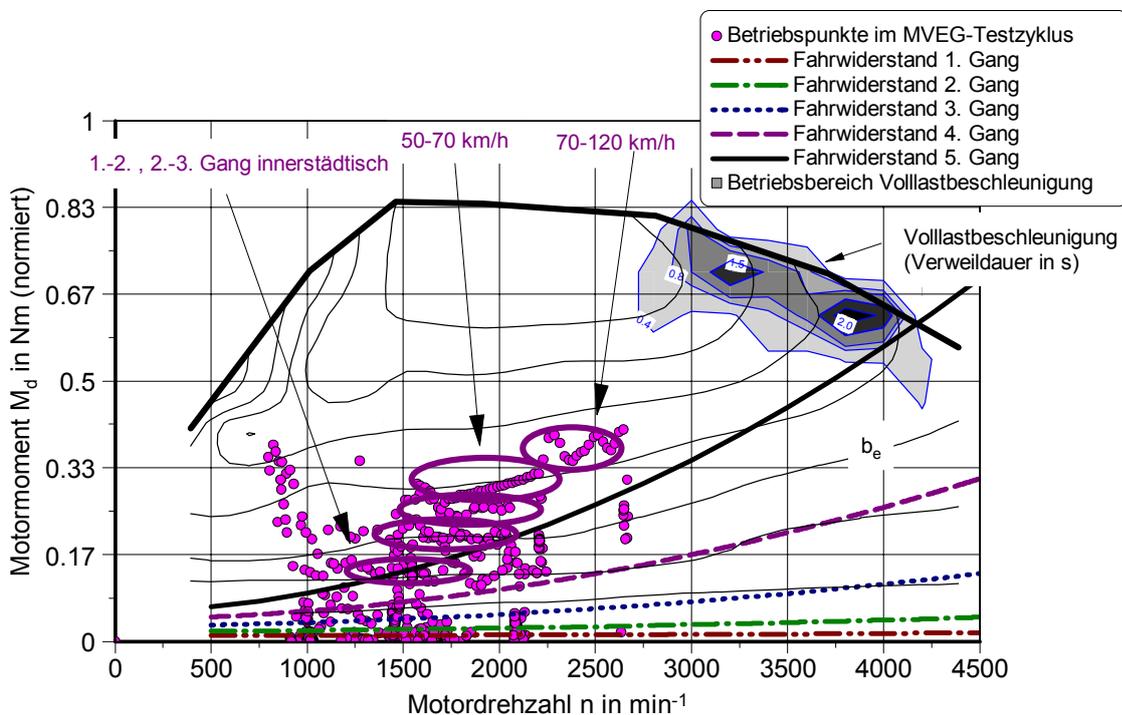


Abb. 4.16 Dynamische Motorbetriebsphasen im stationären Motorkennfeld am Beispiel eines 4-Zylinder-DI-Common-Rail-Motors

Kennfelderweiterung durch Drehmomentgradient

Bei Beibehaltung der klassischen Kennfelddefinition könnte auch beim Einsatz des Kennfeld-Clustering für einen Testzyklus genau ein optimaler Satz Führungsgrößen-Kennfelder gefunden werden. Weicht der praktische Motorbetrieb im Fahrzeugeinsatz von dieser Zyklusdefinition ab - das ist im Allgemeinen der Fall -, ist ein optimaler Motorbetrieb jedoch nicht mehr gegeben. Insbesondere stehen dann auch für stationäre Betriebspunkte ausserhalb des stationären Kennfeld-Clusters, z. B. bei längeren Bergfahrten, keine optimalen Führungseinstellungen mehr zur Verfügung.

Dies schafft jedoch der nachfolgend beschriebene Ansatz, der mit einer zusätzlichen Kennfelddimension - einer dynamischen Beschreibungsgröße - arbeitet. Bewährt hat sich dafür der Gradient des Motordrehmoments, da dieser gut mit dynamischen Effekten wie Rußstoß und Ladedruckaufbau korreliert. Man erhält dadurch eine zusätzliche Abhängigkeit des Basiskennfeldes klassischer Definition vom dynamischen Verhalten des Motorprozesses:

$$\mathbf{p} = (EB, VTG, AGR) = f(M, n, dM/dt) \quad (4.19)$$

Wie in **Abb. 4.17** dargestellt ist, erweitert sich dadurch außerdem der Optimierungsraum in Richtung des gewünschten Prozessverhaltens. Ein Nachweis dafür wird in Abschnitt 4.5.5 erbracht. Den Ausgangspunkt für einen Optimierungslauf stellt nun ein zuvor unter stationären Gesichtspunkten optimiertes Kennfeld (für $dM/dt = 0$) dar, welches für Drehmomentgradienten $dM/dt \neq 0$ durch die Optimierungsstrategie modifiziert wird.

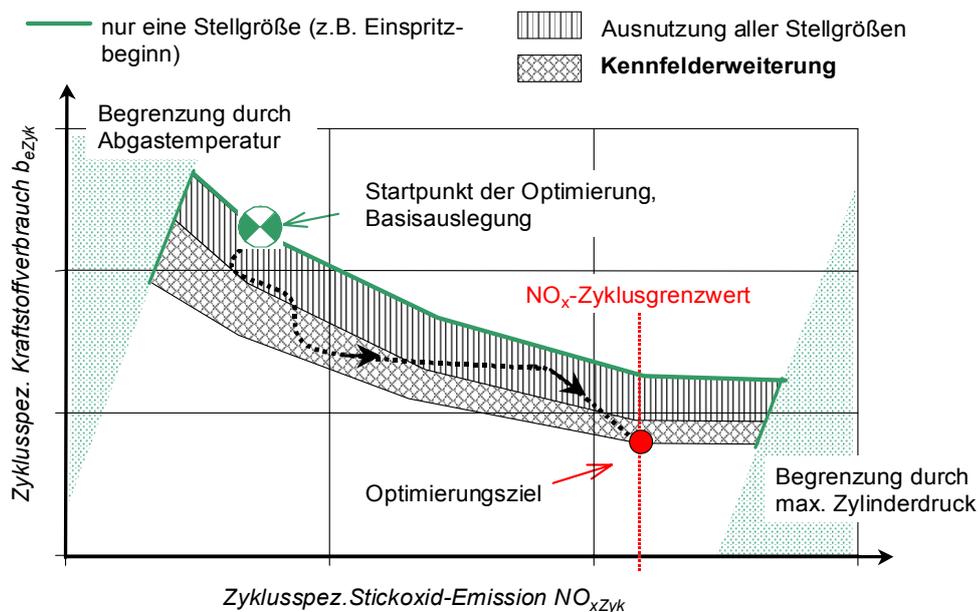


Abb. 4.17 Erweiterung des Optimierungsraumes durch zusätzliche Kennfelddimension

Spätestens hier wird die Komplexität der Optimierungsaufgabe deutlich, die, insbesondere bei wachsender Anzahl von variierbaren Motorparametern (Führungsgrößen-Kennfeldern), nicht mehr mit den aus der stationären Optimierung bekannten stochastischen und deterministischen Optimierungsstrategien gelöst werden kann. Der Ansatz der Kennfelderweiterung eignet sich ob der wenig vernetzten Software-Strukturen im Steuergerät eher für Nutzfahrzeugmotoren als für die auch heute schon sehr komplexen PKW-Applikationen.

Kennfelderweiterung durch Wandtemperatur

Neben dem Drehmomentgradienten wurde auch eine repräsentative Wandtemperatur als mögliche dynamische Beschreibungsgröße erwogen. Motivation dafür war die Tatsache, dass die brennraumseitigen Zylinderwandtemperaturen sowohl Einfluss auf den Verbrennungsprozess haben als auch Informationen über die „Vorgeschichte“ eines Prozesszustandes liefern. Erfolgte z. B. eine Beschleunigung auf einen bestimmten nominellen Betriebspunkt aus einem Niedriglast-Betriebspunkt, liegen die Zylinderwandtemperaturen unterhalb derer, die sich bei Verzögerung aus einem Hochlast-Betriebspunkt heraus ergeben.

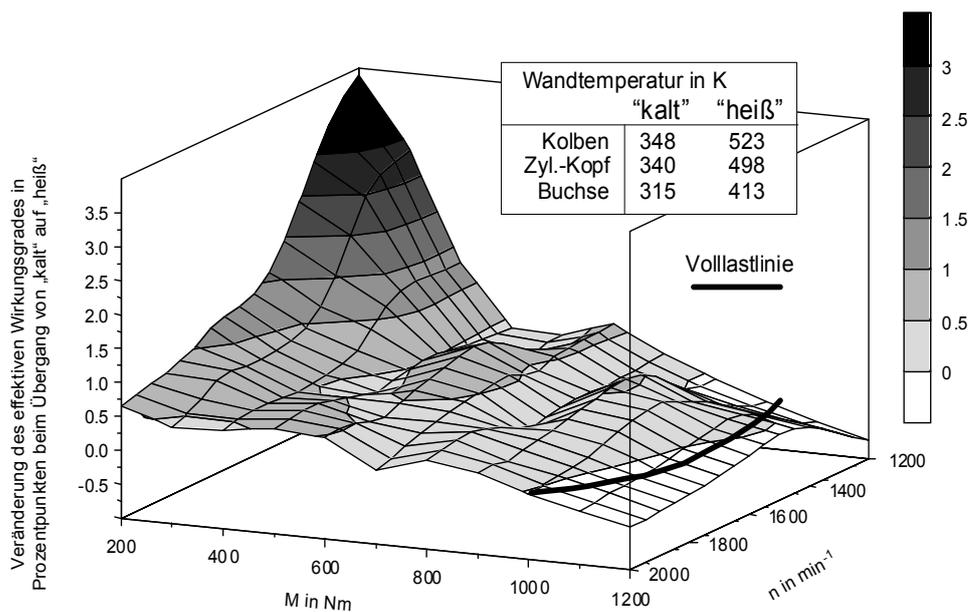
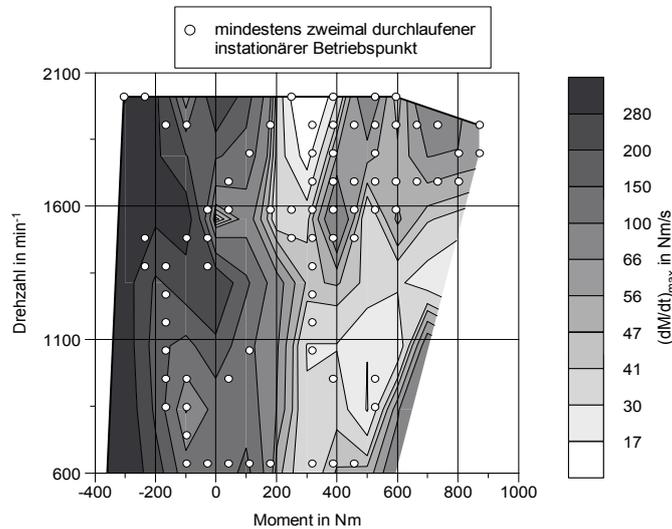


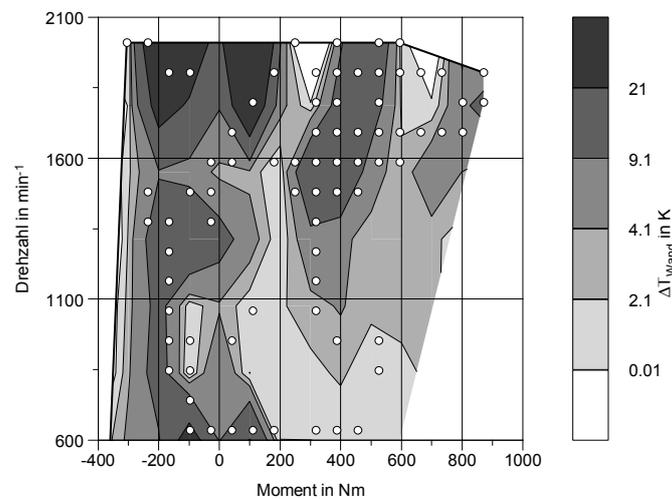
Abb. 4.18 Einfluss der Zylinderwandtemperatur auf den Motorwirkungsgrad am Modellmotor OM441 LA, nach [61]

Der Einfluss der Zylinderwandtemperaturen auf den effektiven Motorwirkungsgrad ist in **Abb. 4.18** dargestellt. Im testzyklusrelevanten mittleren Last- und Drehzahlbereich ist nur ein äußerst geringer Einfluss von 0.5 bis 1 Prozentpunkt auszumachen. Im unteren Last-/Drehzahlbereich des Motorkennfeldes ist eine Differenz im Kraftstoffverbrauch zwischen den extrem möglichen Temperaturniveaus von max. 3.5

Prozentpunkten zu erwarten. Diese Berechnungen machen deutlich, dass ein wandtemperaturabhängiges Führungsgrößenkennfeld aus optimierungstechnischer Sicht sinnvoll ist.



(a) Maximale Differenz des Drehmomentgradienten im Motorkennfeld beim Durchfahren des Modellzyklus



(b) Maximale Differenz der Zylinderkopftemperatur im Motorkennfeld beim Durchfahren des Modellzyklus

Abb. 4.19 Korrelation zwischen Wandtemperatur und Drehmomentgradienten im Modellzyklus (OM441LA)

Inwieweit das Temperatursignal an einer repräsentativen Stelle im Brennraum²⁰ auch mit anderen Effekten korreliert, zeigt **Abb. 4.19**. In **Abb. 4.19(a)** ist die

²⁰Für die hier dargestellten Untersuchungen wurde ein brennraumwandnah in den Zylinderkopf eingebrachtes dünnes NiCr/Ni-Thermoelement mit geringer Ansprechzeit verwendet.

maximale im Testzyklus auftretende Differenz des Drehmomentgradienten über dem Motorkennfeld dargestellt. Die weißen Punkte markieren dabei die zur Berechnung dieses Klassierungs-Kennfeldes benutzten Stützstellen. Jede der Stützstellen wurde im Zyklus mindestens zweimal durchfahren.

Analog dazu sind in **Abb. 4.19(b)** die maximal auftretenden Wandtemperaturdifferenzen an diesen Stützstellen eingetragen. Es ist eine deutliche Korrelation zwischen den beiden Größen Zylinderwandtemperatur und Drehmomentgradient auszumachen, was ebenfalls für eine alternative Verwendung der Wandtemperatur als dynamische Prozessbeschreibunggröße spricht. Hohe Gradientendifferenzen haben hohe Temperaturdifferenzen zur Folge. Dagegen spricht der Fakt, dass ein zusätzliches Messsignal ins Steuergerät geführt werden müsste, während der Drehmomentgradient numerisch aus einem im Steuergerät bereits vorhandenen Lastsignal (momentane Einspritzmenge oder Drehmoment) gebildet werden kann.

4.5.5 Potential der Kennfelderweiterung hinsichtlich einer Aufweichung des Optimierungsproblems

Im Folgenden soll anhand von Experimentalergebnissen dargestellt werden, welches Potential die Kennfelderweiterung um den Parameter Drehmomentgradient im Vergleich zu statischen Kennfeldstrukturen aufweist. Es wurde am Beispiel des Nutzfahrzeugmotors OM441 LA untersucht, wie das erweiterte Einspritzbeginn-Kennfeld für den dynamischen Motorbetrieb dahingehend optimiert werden kann, dass der Trade-Off zwischen Kraftstoffverbrauch und NO_x -Emission in einem gegebenen Testzyklus mit Beschleunigungs- und Verzögerungsanteilen minimiert wird.

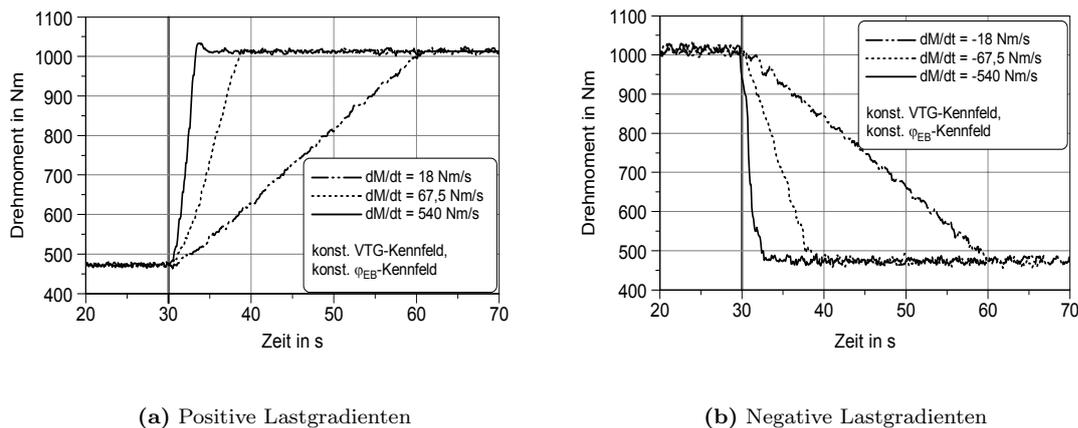


Abb. 4.20 Untersuchte Last(Drehmoment-)gradienten bei $n = 1875 \text{min}^{-1}$

Dazu wurden zunächst Lastrampen mit positiven bzw. negativen Drehmomentgradienten bei konstanter Drehzahl an diesem 6-Zylinder-Nfz-Dieselmotor mit VTG-Lader gefahren (**Abb. 4.20**). Als Führungsgrößen-Kennfelder kam hierbei ein Satz

stationär optimierter Einspritzbeginn- und VTG-Sollwertkennfelder (ohne Kennfelderweiterung) zum Einsatz. In **Abb. 4.21** ist der Vergleich zwischen dynamischer Messung und der Interpolation aus stationär vermessenen Betriebspunkten dargestellt. Deutlich zu erkennen sind die Zunahme des Einbruchs in der NO_x -Kurve und die wachsende Überhöhung der Opazität mit steigendem Lastgradienten. Als Hauptursache dafür sind der verzögerte Ladedruckaufbau und die voneinander abweichenden Verläufe der thermischen Zustandsgrößen zu nennen. Diese Zusammenhänge können durch die quasistationäre Betrachtungsweise nicht abgebildet werden.

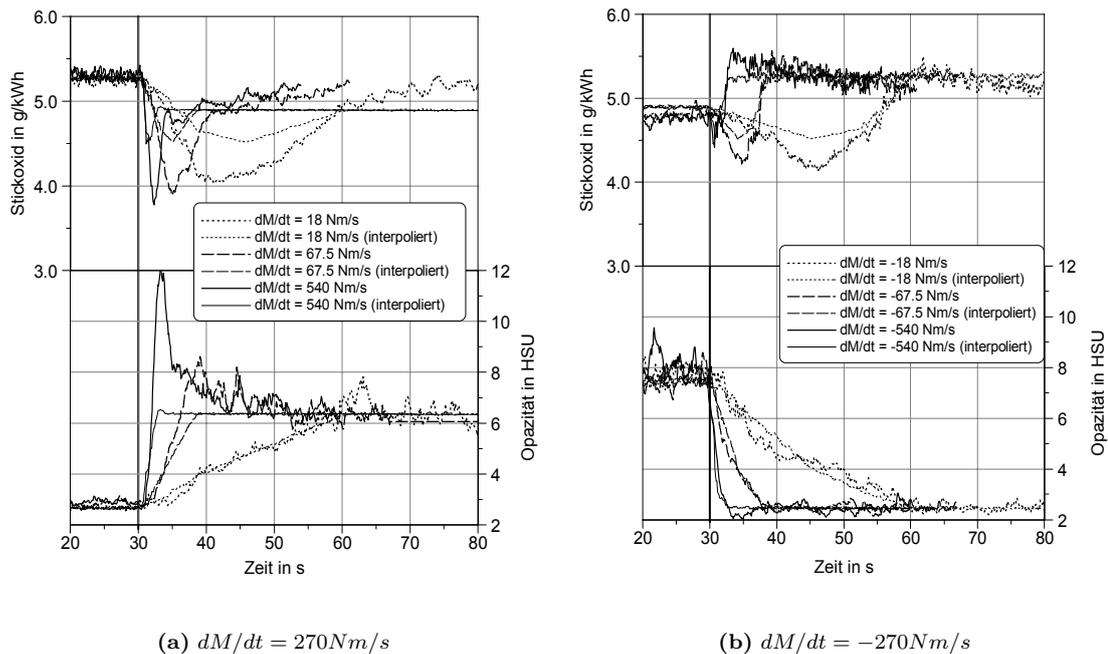


Abb. 4.21 Vergleich realer und quasistationär simulierter NO_x - und Opazitätsverläufe, „Rampenstart“ bei 30s

Da sich die dynamischen Effekte am stärksten bei betragsmäßig sehr hohen Lastgradienten ausprägen, wurden für die systematische Untersuchung der Einflussmöglichkeiten der Kennfelderweiterung Lastrampen mit $dM/dt = \pm 270 Nm/s$ herausgegriffen. Dieser Wert tritt auch im Modellzyklus²¹ noch relativ häufig auf. Das Führungsgrößen-Kennfeld für den Einspritzbeginn wird nun um die Dimension Drehmomentgradient erweitert, sodass **Gl. 4.19** gilt.

Erweitertes EB-Kennfeld

Abb. 4.22 zeigt die untersuchten Einspritzbeginnvorgaben (Rampenstart bei 30 s, Rampenlänge 2 s). Die Auswertung der Ergebnisse zeigt, dass auch für die Optimierung in dynamischen Testläufen - analog zur stationären Motorabstimmung - prinzipielle Zielkonflikte gelöst werden müssen.

²¹vgl. **Abb. 4.8** auf Seite 30

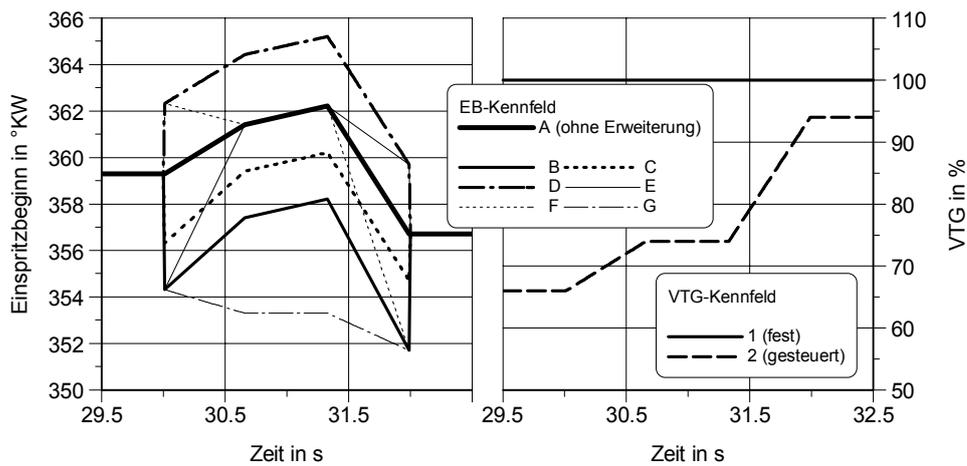
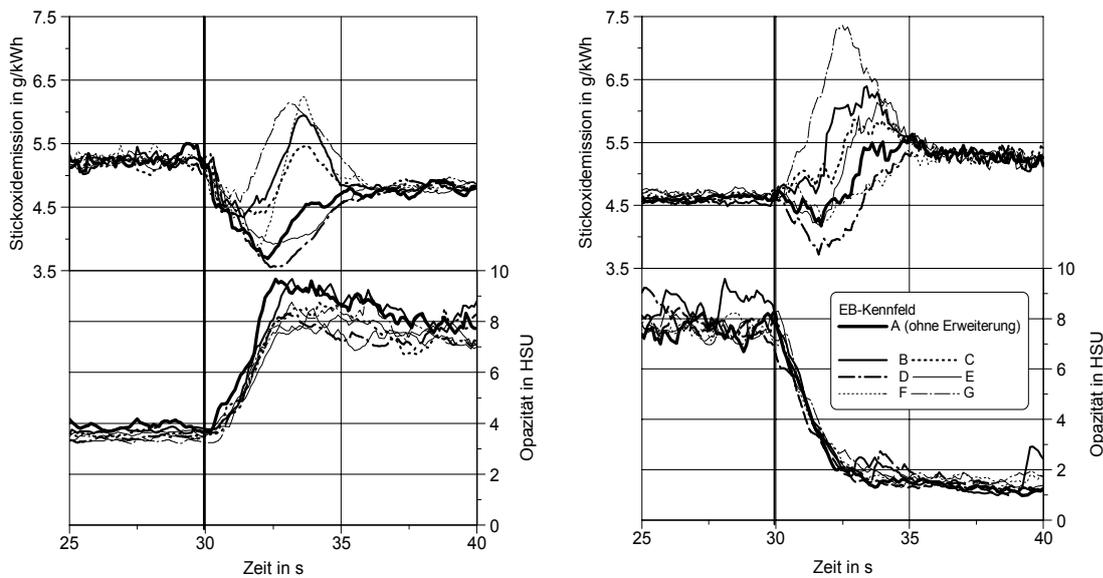


Abb. 4.22 Sollwertverlauf für verschiedene Einspritzbeginn- (A-G) und VTG-Kennfelder (1-2)



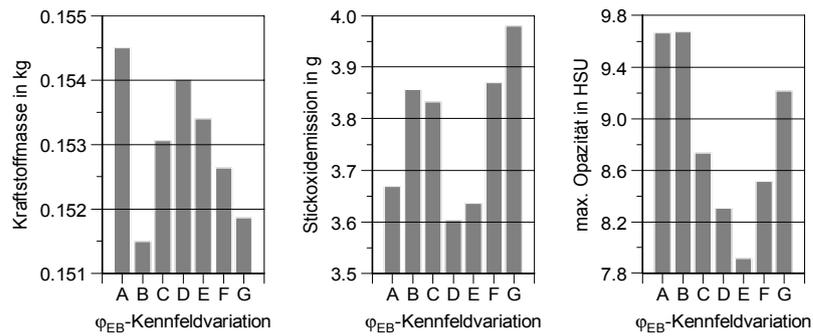
(a) VTG fest auf 100% (Variante 1)

(b) VTG aus Kennfeld gesteuert (Variante 2)

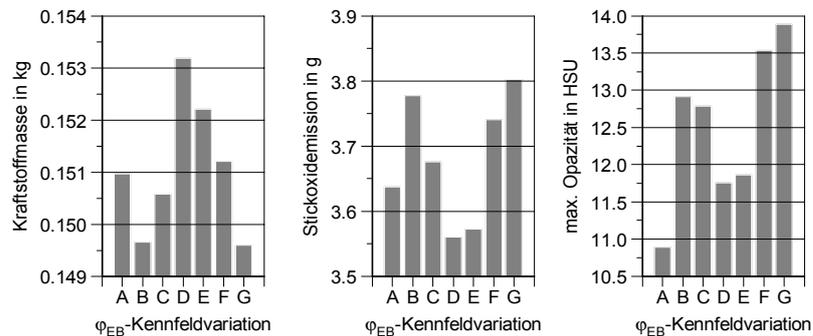
Abb. 4.23 Verlauf von NO_x -Emission und Opazität bei $n = 1875 \text{ min}^{-1}$ und $dM/dt = 270 \text{ Nm/s}$ bzw. $dM/dt = -270 \text{ Nm/s}$ unter EB-Kennfeldvariation (A-G)

Alle Rampen-Versuche wurden jeweils nach zwei verschiedenen VTG-Steuerstrategien durchgeführt, einmal mit dem konstanten engsten Turbinenquerschnitt (100%)²², das andere Mal mit einer gesteuerten VTG aus einem stationär optimierten nichterweiterten Kennfeld.

²²Zur Kennzeichnung der Verstellposition des VTG-Leitapparates wurde in dieser Arbeit der



(a) VTG fest auf 100% (Variante 1)



(b) VTG aus Kennfeld gesteuert (Variante 2)

Abb. 4.24 Kumulierte Messwerte für NO_x -Emission, Opazität und Kraftstoffverbrauch bei $n = 1875 \text{ min}^{-1}$ und $dM/dt = 270 \text{ Nm/s}$ unter EB-Kennfeldvariation (A-G)

Aus den Signalverläufen in **Abb. 4.23** und den dazugehörigen Zyklussummenwerten entsprechend **Abb. 4.24** lassen sich folgende Zielkonflikte ableiten:

1. Die Änderungen der Summenwerte für die entstehende Stickoxidmasse und den Kraftstoffverbrauch verhalten sich bei allen gewählten Kennfeldbelegungen gegenläufig. Es war nicht möglich, ausgehend von der Basiskonfiguration, beide Zielgrößen gleichzeitig abzusenken.
2. Entgegen dem aus Stationärversuchen bekannten Zusammenhang zwischen NO_x -Emission und Schwärzungszahl verändern sich die Höhe des Rußstoßes und der Betrag der Stickoxidmasse nicht prinzipiell gegenläufig zueinander. Es entsteht jedoch auch hier ein Zielkonflikt im Sinne der gewünschten Betriebsstrategie, in der Art, dass zumindest bei gesteuertem VTG-Kennfeld für eine Absenkung des Kraftstoffverbrauchs ein etwas größerer Rußstoß in Kauf genommen werden muss.

prozentuale Verstellweg des elektropneumatischen VTG-Aktors benutzt. 100% entspricht dabei dem kleinstmöglichen und 0% dem größtmöglichen Anströmquerschnitt der Turbine

3. Bei geschlossener VTG besteht ein NO_x -Opazitäts-Trade-Off.

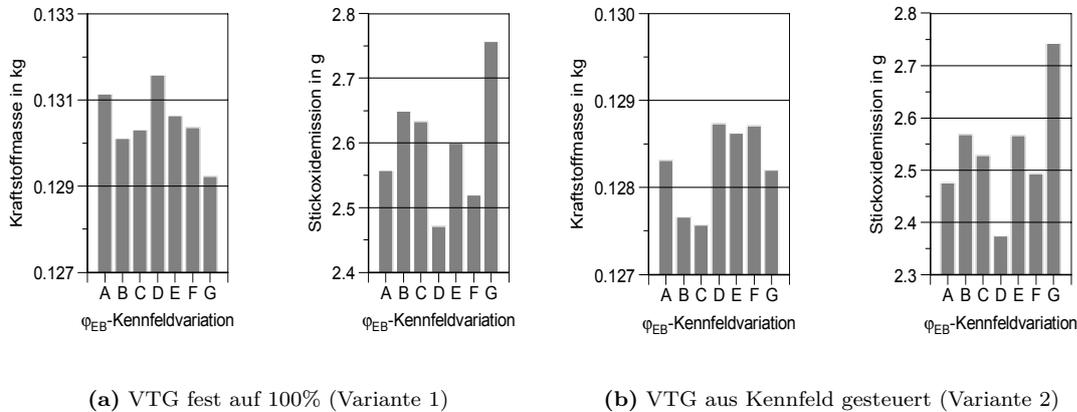


Abb. 4.25 Kumulierte Messwerte für NO_x -Emission, Opazität und Kraftstoffverbrauch bei $n = 1875 \text{min}^{-1}$ und $dM/dt = -270 \text{Nm/s}$ unter EB-Kennfeldvariation (A-G)

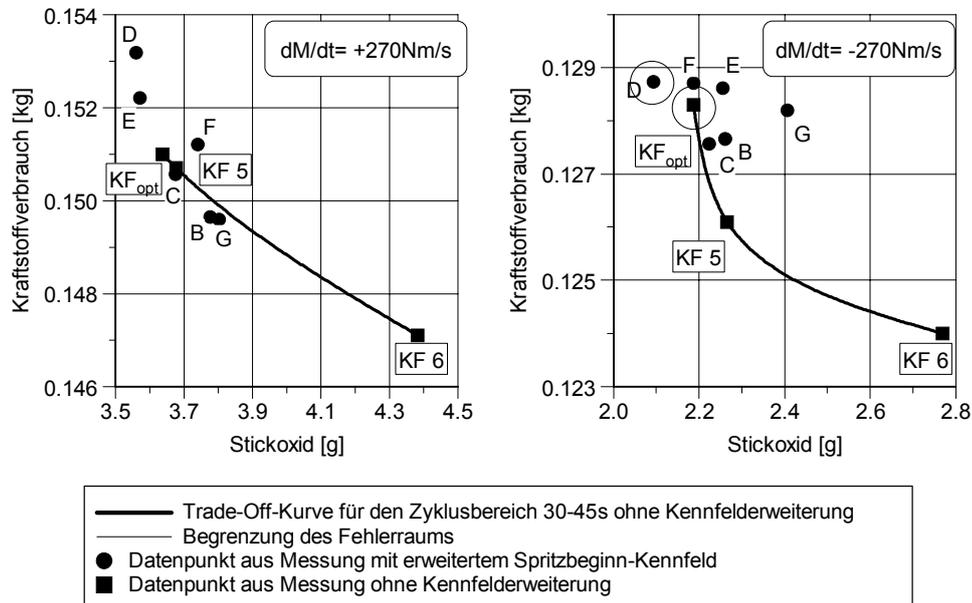
Die Ergebnisse der Versuche mit negativen Lastgradienten (**Abb. 4.25** und **Abb. 4.26** auf der nächsten Seite) lassen sich wie folgt zusammenfassen:

1. Es besteht auch hier der Zielkonflikt zwischen Kraftstoffverbrauch und NO_x -Emission
2. Da bei negativem Lastgradienten erwartungsgemäß kein Rußstoß auftritt, ist die Betrachtung der max. Opazitätswerte gegenstandslos.

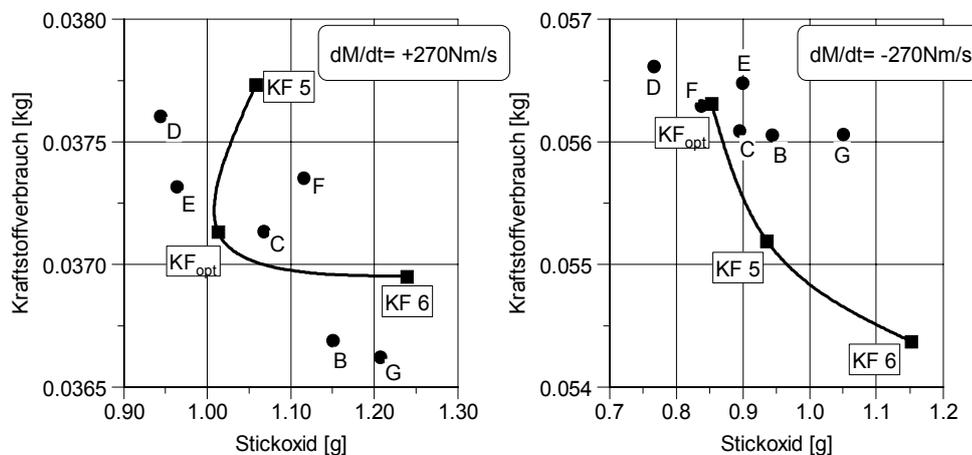
Es bleibt nun die Frage zu beantworten, ob sich durch die in erweiterten Führungsgrößen-Kennfeldern abgebildeten Verstellstrategien die Zielfunktion weiter minimieren lässt, als das bei konventioneller Kennfelddimensionierung möglich war. Zur Beantwortung dieser Frage sind die Ergebnisse beider Versuchsreihen zusammen mit der Trade-Off-Kurve dargestellt, welche sich aus den Messwerten bei Verwendung stationärer Last-Drehzahl-Sollwertkennfelder ergibt (**Abb. 4.26**).

Es ist ersichtlich, dass die Kennfelder B und G bei positivem Lastgradienten hinsichtlich des Optimierungsziels günstigere Zyklussummenwerte liefern (**Abb. 4.26(links)**), als das bei konventioneller Kennfelddimensionierung möglich wäre. Betrachtet man einen kleineren Zyklusauschnitt von 30s - 35s (im Bild unten), so ist dieser Effekt noch deutlicher sichtbar. Die Steuerungsstrategie ist demnach um so günstiger, je näher der zugehörige Messwertpunkt am Koordinatenursprung liegt. In der Darstellung für den negativen Lastgradienten (rechts) ist keine Verbesserung der Zyklusergebnisse im Vergleich zur konventionellen Kennfeldsteuerung zu erkennen. Die Messwertpunkte aller untersuchten Verstellstrategien liegen oberhalb der sich konventionell ergebenden Trade-Off-Kurve. Diese wird aus Versuchen mit den in

rechteckiger Umrandung bezeichneten Steuerkennfeldern aus stationärer Optimierung gebildet²³.



(a) Zeitausschnitt 30s-45s



(b) Zeitausschnitt 30s-35s

Abb. 4.26 Kumulierte Emissionen für die untersuchten Lastrampen bei unterschiedlichen Spritzbeginn-Steuerstrategien

Anhand der Darstellungen wird außerdem deutlich, dass sich die mit konventioneller Kennfelddimensionierung ergebende Optimierungs-(oder Trade-Off-)Linie zu einem Optimierungsraum erweitert, in dem sich die Messpunkte bei erweiterter Kennfeld-

²³Es handelt sich hierbei um diejenigen Führungsgrößen-Kennfelder, die zu der in **Abb. 4.9** dargestellten Untersuchung herangezogen wurden.

definition verteilen. Hier wird nochmals die Komplexität der Optimierungsaufgabe deutlich, die schon in Abschnitt 4.5.4 angedeutet wurde.

Einbeziehung des VTG-Kennfeldes

Soll der maximale Rußstoß weiter abgesenkt werden, als das durch Variation des Einspritzbeginns möglich ist, müssen die Möglichkeiten der VTG-Verstellung ausgenutzt werden. **Abb. 4.27** und **Abb. 4.28** zeigen das mögliche Potential auf. Eine Absenkung des Rußstoßes ist bei positivem Lastgradienten in gewissen Grenzen möglich, es bleibt jedoch der NO_x -Ruß-Zielkonflikt bestehen, d. h. ein kleinerer Rußstoß geht mit der Erhöhung der NO_x -Emission einher.

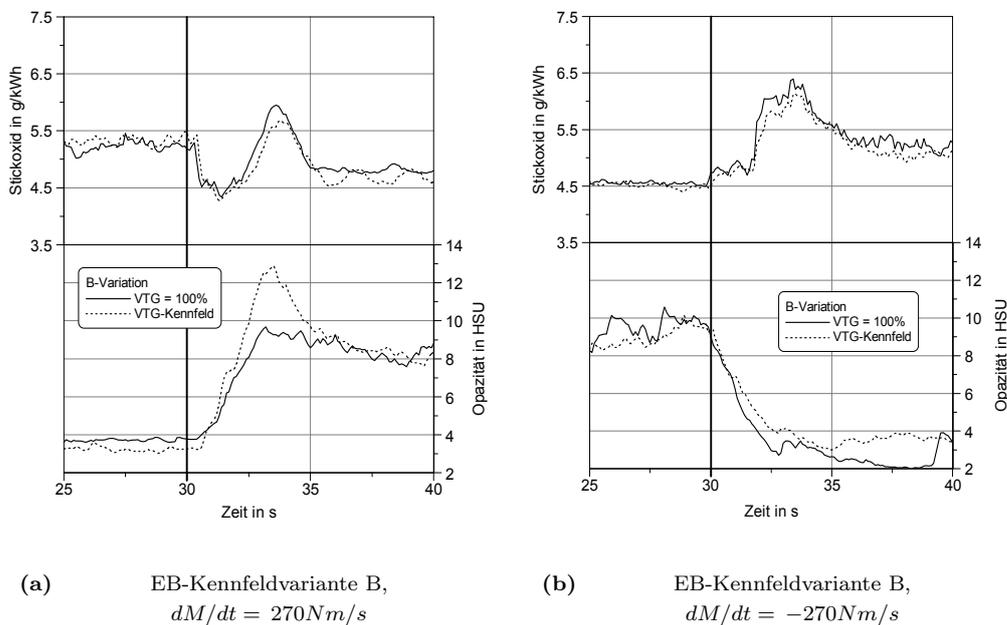


Abb. 4.27 Emissionsverläufe bei verschiedenen VTG-Stellstrategien und konstantem Einspritzbeginn-Kennfeld ($n = 1875 min^{-1}$, EB-Kennfeldvariation B)

Der in **Abb. 4.26** auf der vorherigen Seite eingezeichnete Fehlerraum ergab sich aus entsprechenden Vorversuchen. Man erkennt, dass alle herausgearbeiteten Effekte an ihrer Nachweisgrenze liegen. Das tatsächliche Einsparungspotential in einem aus stationären und dynamischen Betriebsphasen bestehenden Testzyklus hängt maßgeblich von der Anzahl und dem Instationärgrad der dynamischen Zyklusanteile ab. Aussagen hierzu können nach Abschluss noch laufender Forschungsarbeiten gemacht werden. Wegen des höheren Betriebsdrehzahlbereiches wird für schnelllaufende PKW-Dieselmotoren ein größeres Optimierungspotential erwartet.

Aus den dargestellten Ergebnissen lassen sich folgende Regeln für die Formulierung einer dynamischen Optimierungsstrategie ableiten:

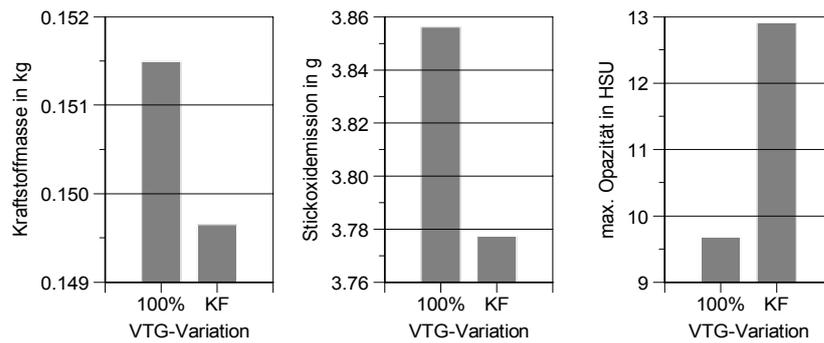


Abb. 4.28 Kumulierte Emissionen bei unterschiedlichen VTG-Stellstrategien ($dM/dt = 270 Nm/s, n = 1875 min^{-1}$)

1. Stehen als Ausgangsbasis stationär optimierte Last-Drehzahl-Kennfelder (d. h. bei $dM/dt=0$) zur Verfügung, sind die Einspritzbeginn-Sollwerte mit zunehmendem Lastgradienten (in erster Näherung durch eine lineare Funktion) in Richtung „früh“ zu verschieben.
2. Diese Aufgabe kann am einfachsten durch eine Koordinatenstrategie realisiert werden.
3. Mit Früherlegen des Einspritzbeginns gemäß 1. erhält man damit gleichzeitig eine gewisse Absenkung des maximalen Rußstoßes.
4. Soll eine noch größere Rußstoßabsenkung erfolgen, ist diese nur durch eine gleichzeitige Erhöhung des Ladedrucks, also die Adaption der VTG-Steuerkennfelder (engere Turbine), realisierbar.

Die dargestellten Regeln bilden eine erste wissensbasierte Optimierungstrategie. Auf die mathematische Umsetzung solcher wissensbasierten Ansätze in entsprechenden Optimierungssystemen wird in Kapitel 7 eingegangen.

4.6 On- und Offline-Optimierung

Der Vorgang der Kennfeldoptimierung für Motorsteuergeräte ist heute nicht mehr nur ein eigenständiger Aufgabenbereich am Ende der Motor-Designkette, sondern er erfordert vielmehr eine frühzeitige Integration in den Motor-Entwicklungsprozess. Nur so kann ein hohes Maß an a-priori-Wissen über den Motorprozess bei der Erstellung automatisierter adaptiver Optimierungsalgorithmen genutzt werden. Prinzipiell kann man zwischen Online- und Offline-Optimierung unterscheiden, **Abb. 4.29**.

Voraussetzung für beide Methoden ist eine Optimierungsstrategie, die im Vorfeld anhand geeigneter (Teil-)Modelle des Motorprozesses erprobt und verifiziert wurde. Beim Offline-Verfahren wird zur eigentlichen Optimierung ein Motormodell genutzt, welches je nach Ziel der Optimierung gegebenenfalls auch das dynamische Motorverhalten quantitativ abbilden muss. Wie bereits erwähnt, sind solche Modelle in der

Regel sehr rechenintensiv (thermodynamische Kreisprozessrechnung) und insbesondere bei der Abbildung von Emissionswerten noch von unzureichender Genauigkeit, sodass eine Offline-Optimierung nur zur prinzipiellen Erprobung der Strategie dienen kann.

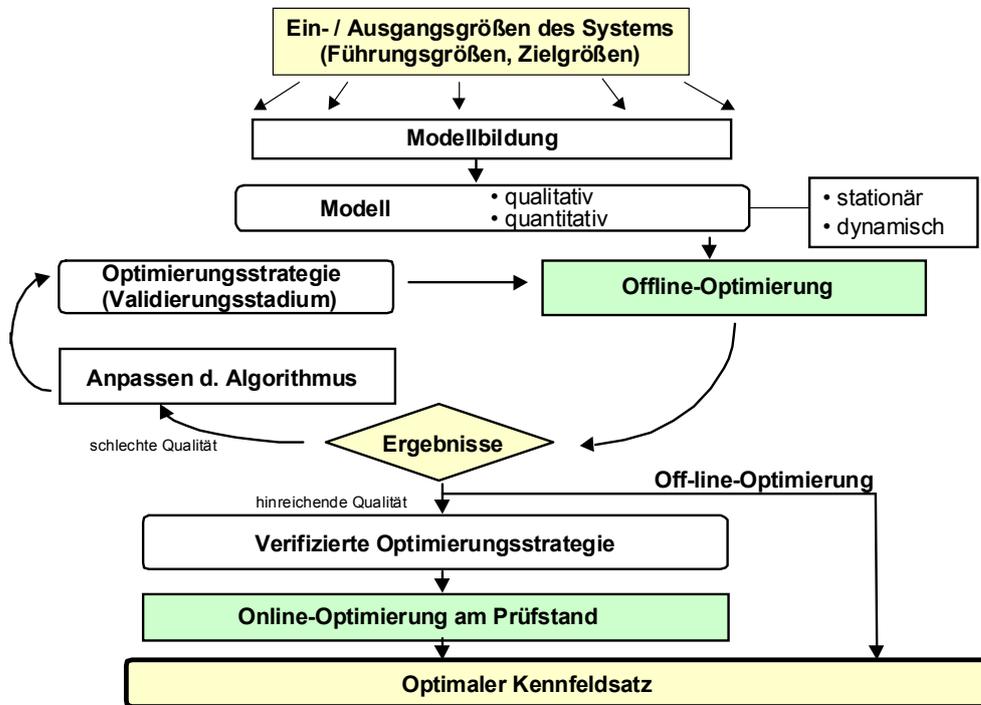


Abb. 4.29 Online- und Offline-Optimierung zur Entwicklung von Optimierungsstrategien

Die Unzulänglichkeiten bei der quantitativen Modellbildung sprechen für eine Online-Optimierung der Führungsgrößen-Kennfelder. Dabei wird eine am qualitativen Prozessmodell verifizierte Optimierungsstrategie zur direkten Optimierung am Motorenprüfstand verwendet. Geeignet hierfür sind Strategien, die mit wenigen Iterationen - bei der Online-Optimierung erfordert jede Iteration eine Neuvermessung des Motorbetriebspunktes bzw. -kennfeldes - zu einer akzeptablen Lösung des Problems führen. Die zur Strategieverifizierung verwendeten numerischen Prozessmodelle müssen zumindest qualitativ die signifikanten Prozesszusammenhänge abbilden. In Kapitel 5 ist die Herangehensweise bei der Modellerstellung am Beispiel des Modellmotors M47R dargestellt.

Tab. 4.3 fasst die Vor- und Nachteile der möglichen Optimierungsansätze an Verbrennungsmotoren zusammen. Darüber hinaus können den beiden letzten Spalten die für jede Optimierungsvariante gleichzeitig zu berücksichtigenden Parameter und die für eine Kennfeldoptimierung benötigte Anzahl von Optimierungsläufen entnommen werden. Es wird hierbei davon ausgegangen, dass alle Führungsgrößen-Kennfelder die gleichen Stützstellen benutzen und der Zyklus bei quasistationärer Betrachtungsweise auch auf diese klassiert ist. Bei den kennfeldbezogenen Verfahren

ZQKFO und DKFO wird jeweils nur ein einziger Optimierungslauf benötigt, um ein komplettes Kennfeld zu erhalten. Dafür ist ein Vielfaches an Optimierungsparemtern im Vergleich zu den stationären/quasistationären Verfahren ZQBPO und DBPO zu berücksichtigen, was die Optimierungszeiten überproportional ansteigen lässt.

Nach Abwägung aller Vor- und Nachteile scheint beim derzeitigen Stand der Technik die Verwendung der Varianten ZQKFO und DKFO sinnvoll. Im Gegensatz zur Offline-Optimierung werden bei der Online-Optimierung jedoch äußerst effiziente Strategien benötigt, um einen vertretbaren Aufwand an Prüfstandszeit erzielen zu können.

Tab. 4.3 Vor- und Nachteile verschiedener Optimierungsansätze und benötigte Parameter- und Optimierungs-Anzahl für eine Kennfeldoptimierung (m - Anzahl Führungsgrößen, S_n - Anzahl Kennfeld-Stützpunkte)

	Vorteile	Nachteile	Anzahl Optimierungen	Anzahl Parameter
Offline-Optimierung	<ul style="list-style-type: none"> • geringer Zeitaufwand • keine Zusatzkosten durch Prüfstandsbetrieb • viele Iterationen erlaubt 	<ul style="list-style-type: none"> • ungenaues Optimierungsergebnis • Berücksichtigung von Dynamik schwierig • quantitatives Modell notwendig 	-	-
Online-Optimierung	<ul style="list-style-type: none"> • Optimierungsergebnis direkt in Steuergerät übertragbar • kein quantitatives Modell erforderlich • Optimierungsstrategie auf andere Motoren vom gleichen Typ übertragbar 	<ul style="list-style-type: none"> • nur sinnvoll bei wenigen Iterationen - effiziente Strategie • zur Strategieentwicklung a-priori-Wissen notwendig • Anbindung des Optimierers an Prüfstand notwendig 	-	-
SBPO/ZQBPO	<ul style="list-style-type: none"> • wenige Optimierungs-Parameter • geringe Fehler in der Betriebspunkt-Optimierung • klassische Optimierungsalgorithmen verwendbar • schnelle Online-Optimierung möglich 	<ul style="list-style-type: none"> • Dynamik wird nicht berücksichtigt (Quasistationarität) • Optimierungsergebnisse nur bedingt auf Fahrzeug übertragbar • lokale Grenzwerte p_{t_i} müssen im Vorfeld festgelegt werden 	S_n	m
ZQKFO	<ul style="list-style-type: none"> • bessere Annäherung an das globale Optimum durch variable Betriebspunktgewichtung • klassische Optimierungsalgorithmen bedingt verwendbar 	<ul style="list-style-type: none"> • Dynamik wird nicht berücksichtigt (Quasistationarität) • Optimierungsergebnisse nur bedingt auf Fahrzeug übertragbar 	1	$S_n \cdot m$
DBPO	<ul style="list-style-type: none"> • Dynamik wird bei der Optimierung berücksichtigt • zyklusunabhängig • als Online-Algorithmus im Fahrzeug einsetzbar 	<ul style="list-style-type: none"> • Kennfelderweiterung erforderlich • erfordert genaue dynamische Modelle zur Offline-Optimierung • schwer lösbares Zuordnungsproblem (vgl. Abb. 4.13) • für Kennfeldsteuerungen praktisch nicht umsetzbar 	S_n	m
DKFO	<ul style="list-style-type: none"> • Dynamik wird bei der Optimierung berücksichtigt • Kennfelderweiterung nicht zwingend erforderlich • Optimierungsergebnisse auf Fahrzeug übertragbar 	<ul style="list-style-type: none"> • viele Optimierungsparameter • klassische Optimierungsverfahren nur bedingt einsetzbar • erfordert genaue dynamische Modelle zur Offline-Optimierung • ohne Kennfelderweiterung zyklusspezifisch 	1	$S_n \cdot m$

Kapitel 5

Numerische Motormodelle zur Entwicklung und Verifizierung von Optimierungsstrategien

5.1 Übersicht

Voraussetzung für die Entwicklung und Erprobung aufgabenspezifischer Optimierungsstrategien ist die Verfügbarkeit möglichst umfassender qualitativer Motormodelle. **Abb. 5.1** zeigt eine Übersicht über mögliche Varianten der Modellierung von Verbrennungsmotoren, die auf den Ergebnissen messtechnischer Versuchsreihen basieren.

In den letzten Jahren hat sich zur effizienten Gestaltung von Versuchen die Verwendung D-optimaler Versuchspläne im Zusammenhang mit der Response-Surface-Methode durchgesetzt, [3, 16, 18, 63, 83]. Die D-Optimalität der Anordnung der gewählten Versuchspunkte im möglichen Versuchsraum führt zu einer Minimierung der zu erwartenden Modellfehler bei Kenntnis der im Vorfeld festgelegten Modellordnung. Unvollständige optimale Versuchspläne beinhalten nur diejenigen Versuchspunkte, die zur Parametrierung eines polynomischen Ansatzes notwendig sind, zuzüglich einer frei wählbaren Anzahl von Versuchen zur statistischen Validierung des Modells. Für die Modellierung von verbrennungsmotorischen Zusammenhängen haben sich quadratische Mehrfaktoransätze bewährt [53, 80, 12]. Auch Ansätze erster Ordnung wurden für spezielle Probleme erfolgreich eingesetzt, [45].

Neben der Abbildung des Motorverhaltens über Polynomansätze besteht des Weiteren die Möglichkeit, neuronale Netze als nichtlineare Motormodelle einzusetzen. Das bringt insbesondere dann Vorteile, wenn mehr als die zur Bestimmung des quadratischen Polynomansatzes benötigten Messpunkte zur Verfügung stehen und die gewählte Modellordnung nicht ausreicht bzw. ein stark nichtlineares Prozessverhalten modelliert werden soll. Auch dynamische Zusammenhänge lassen sich mit neuronalen Netzen abbilden (z. B. mit LOLIMOT-Netzen [57]).

Blockpläne sind nur zur Analyse von nichtstetigen Einflussfaktoren sinnvoll und sollen hier nicht weiter betrachtet werden.

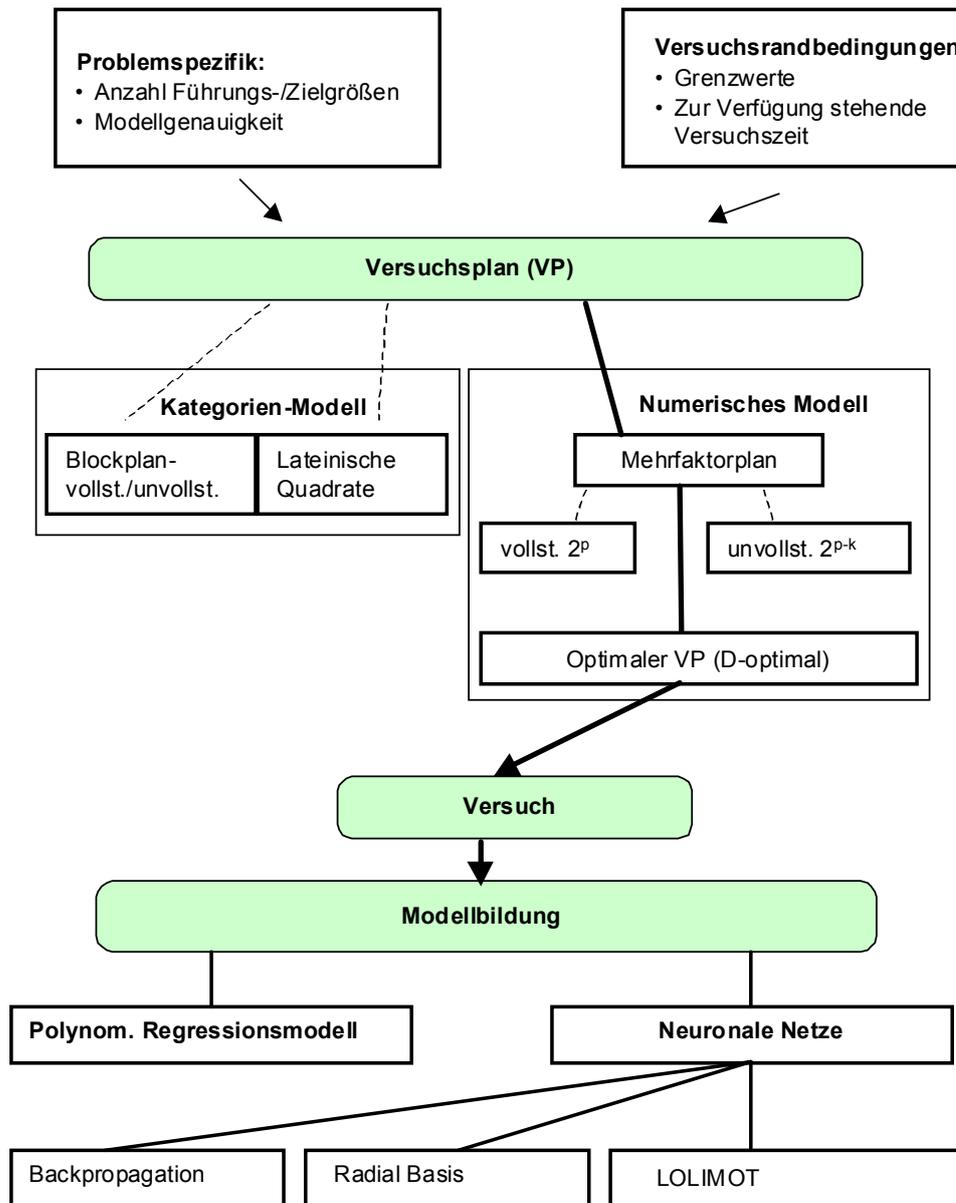


Abb. 5.1 Versuchsbasierte Motormodelle

Neben den versuchsbasierten Modellen existieren eine Reihe von physikalisch-analytischen Modellen zur motorischen Prozesssimulation, die in der Regel mit halbempirischen und iterativ/numerischen Ansätzen kombiniert werden. Die Eignung solcher rechenintensiven Modelle zur Vorausberechnung von Motorleistung, Kraftstoffverbrauch und Ansprechverhalten wurde vielfach nachgewiesen, [11, 15]. Soll allerdings das Emissionsverhalten von Motoren nachgebildet werden, versagen diese Modelle, da hierzu geeignete Ansätze fehlen. Deshalb ist die Motorprozesssimulation im Rahmen dieser Arbeit nur zu einzelnen Parameterstudien verwendet worden.

5.2 Statistische Versuchsplanung und RSM

5.2.1 Faktorielle Versuchspläne

Um mit möglichst wenigen Versuchen zu einem geeigneten Prozessmodell zu gelangen, müssen Versuche geplant werden. Methoden der mathematischen Statistik können effizient zur Planung technischer Versuche eingesetzt werden und gestatten es trotz gleichzeitiger Variation mehrerer Prozessvariablen, systematische Modellaussagen zu erhalten. In dieser Arbeit sollen ausschließlich faktorielle Versuchspläne behandelt werden, also Pläne, die sich zur Analyse quantitativer Zusammenhänge bei der Variation von Prozesseingangsgrößen, hier Faktoren genannt, eignen. An einen Versuchsplan werden folgende Anforderungen gestellt, [83]:

- Eine Abschätzung der Koeffizienten Θ eines Polynoms des gewünschten Grades muss möglich sein;
- das Modellpolynom muss die gemessenen Werte approximieren können;
- das Polynom muss auf Präzision und Adäquatheit hin überprüfbar sein;
- geringe Anzahl an Versuchspunkten;
- Möglichkeit der Blockbildung;
- Erweiterbarkeit.

Vollständige faktorielle Versuchspläne

Ein Versuchsplan heißt vollständig, wenn alle möglichen Faktorstufen-Kombinationen vermessen werden. Eine Faktorstufe ist ein skalarer Wert eines Faktors. Prinzipiell können für einen Versuchsplan für jeden Faktor beliebig viele nicht äquidistante Faktorstufen gewählt werden. Dieses Vorgehen entspricht der bekannten Rastervermessung. Um den Versuchsaufwand so gering wie möglich zu halten, hat sich jedoch die Wahl von 2 oder 3 Stufen pro Faktor an den Grenzen bzw. in der Mitte des Verstellbereiches bewährt. Solche Versuchspläne sind vom Typ 2^p bzw. 3^p , wobei p der Anzahl der untersuchten Faktoren entspricht. Zur vollständigen Untersuchung eines 3-stufigen Prozesses mit 5 Faktoren müssen demnach $3^5 = 243$ Versuche durchgeführt werden. Pläne vom Typ 2^p werden auch als Faktorenpläne erster Ordnung bezeichnet. Mit den damit gefundenen Versuchsergebnissen lassen sich die Parameter eines Regressionspolynoms 1. Ordnung eindeutig schätzen.

Für die Schätzung eines Regressionsmodells 2. Ordnung (vgl. Abschnitt **Regressi-on**) reichen die Versuchspunkte des vollständigen Plans 1. Ordnung nicht aus und es müssen zusätzliche Versuchspunkte generiert werden. Die Einführung so genann-

ter Stern- bzw. Zentralpunkte führt zu orthogonalen¹, drehbaren² Zentralplänen, die sich sehr gut zur Parameterschätzung eignen. In **Abb. 5.2** ist jeweils ein Beispiel für einen Plan erster und zweiter Ordnung mit den dazugehörigen normierten Planmatrizen³ angegeben.

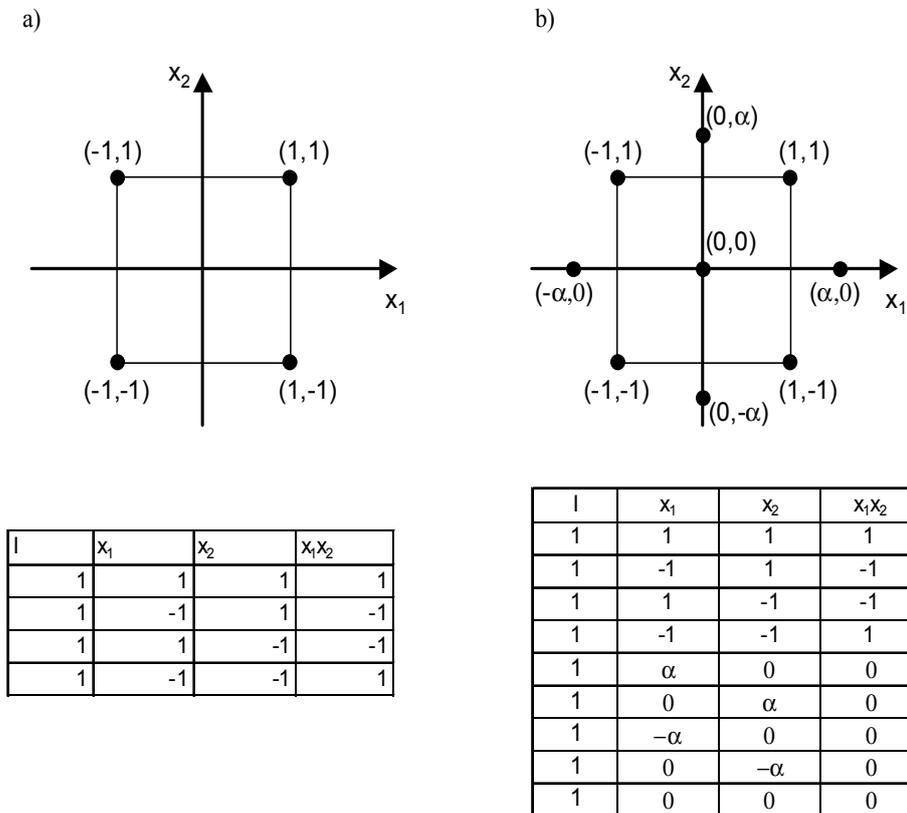


Abb. 5.2 Beispiele für vollständige Versuchspläne, a) Typ 2^2 , b) zentraler zusammengesetzter Plan 2. Ordnung auf Basis des 2^2 -Plans

Unvollständige faktorielle Versuchspläne

Eine Reduktion des Versuchsaufwandes wird dadurch erreicht, dass bestimmte Faktorkombinationen des vollständigen Versuchsplans nicht vermessen werden. Das ist möglich, wenn a-priori-Informationen darüber vorliegen, dass bestimmte Faktorwechselwirkungen nicht signifikant sind und die entsprechenden Modellparameter deshalb nicht geschätzt werden müssen. Da in der Praxis der Modellansatz fast immer weniger zu schätzende Parameter hat, als Faktorkombinationen möglich sind, werden hier vorrangig unvollständige Versuchspläne, auch Teilfaktorpläne genannt,

¹ Die Orthogonalität eines Versuchsplans wird durch den Variance Inflation Factor (VIF) beschrieben. $VIF = 1$ steht für einen rein orthogonalen Plan. Für $VIF's > 10$ sind die Faktoren zu stark korreliert.

² Drehbare (rotationssymmetrische) Versuchspläne haben die geringstmögliche Varianz der Schätzparameter zur Folge.

³ Die Faktorstufen werden auf das Intervall $\{-1, 1\}$ bezogen.

Tab. 5.1 Beispiel einer Matrix der unabhängigen Faktoren eines unvollständigen Versuchsplans

Planmatrix					Matrix der unabhängigen Faktoren							
	x_1	x_2	x_3	x_4	I $x_1x_2x_3x_4$	x_1	x_2	x_1x_2 x_3x_4	x_3	x_1x_3 x_2x_4	x_2x_3 x_1x_4	x_4 $x_1x_2x_3$
1	-1	-1	-1	-1	+1	-1	-1	+1	-1	+1	+1	-1
2	+1	-1	-1	+1	+1	+1	-1	-1	-1	-1	+1	+1
3	-1	+1	-1	+1	+1	-1	+1	-1	-1	+1	-1	+1
4	+1	+1	-1	-1	+1	+1	+1	+1	-1	-1	-1	-1
5	-1	-1	+1	+1	+1	-1	-1	+1	+1	-1	-1	+1
6	+1	-1	+1	-1	+1	+1	-1	-1	+1	+1	-1	-1
7	-1	+1	+1	-1	+1	-1	+1	-1	+1	-1	+1	-1
8	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1

aufgestellt. Die Bezeichnung des Plans lautet dann 2^{p-k} bzw. 3^{p-k} . In der Literatur werden verschiedene Ansätze beschrieben, solche Pläne aufzustellen, [83, 16]. Darauf aufbauende Software-Tools stellen sicher, dass insbesondere bei Versuchsplänen 2. Ordnung die genannten Anforderungen bezüglich Orthogonalität und Drehbarkeit erfüllt sind.

Unabhängige Faktoren und Lösungstyp des Versuchsplans

Liegt die Planmatrix eines Versuchsplans in normierter Form vor, so kann ermittelt werden, ob mit den im Versuchsplan geforderten Faktorkombinationen alle Effekte unabhängig beobachtbar sind. Für einen vollständigen Versuchsplan ist das immer der Fall, bei unvollständigen Versuchsplänen können jedoch Vermengungen der Effekte auftreten, die durch eine Modellschätzung nicht mehr abgebildet werden.

Am Beispiel aus **Tab. 5.1** sei dies erläutert. Wechselwirkungsfaktoren werden in der Matrix der unabhängigen Faktoren durch einfache Produktbildung der normierten Stufen der an der Wechselwirkung beteiligten Faktoren gebildet. Man erkennt nun, dass unter anderem die Spalten x_1x_2 und x_3x_4 in der Matrix identisch sind, also beide Mischeffekte nicht getrennt von einander untersucht werden. Es gilt in diesem Fall $x_1x_2 = x_3x_4$ und damit ist eine unvermengte Schätzung der Polynomkoeffizienten für das Modell nicht möglich. Es müssen weitere Versuche zum Versuchsplan hinzugefügt werden, um dies zu ermöglichen. Ist einer der beiden Effekte nicht signifikant, spricht man von einem hinreichenden Versuchsplan.

Das Maß der Effekt-Vermengung eines Versuchsplans wird durch seinen Lösungstyp beschrieben, der in römischen Ziffern angegeben wird (z. B. 2_{IV}^{4-1} -Typ in **Tab. 5.1**). Der Lösungstyp L ist durch die Anzahl der Faktoren der kleinsten mit der Identität I des Versuchsplans vermengten Faktorkombination gegeben (definierende Beziehung I). Im Fall des Beispielsversuchsplans gilt $I = x_1x_2x_3x_4$, was einem Lösungstyp VI entspricht. In **Tab. 5.2** ist zusammengefasst, welche Effekte je nach Lösungstyp

Tab. 5.2 Nicht vermengte Effekte (HE, 2WW, 3WW, 4WW) bei den Lösungstypen III-V unvollständiger Versuchspläne, nach [83]

L	getrennt berechenbar	werden vernachlässigt	vermengt
III	HE	2WW und höhere	HE mit 2WW
IV	HE	3WW und höhere	HE mit 3WW, 2WW mit 2WW
V	HE, 2WW	3WW und höhere	HE mit 4WW, 2WW mit 3WW

unabhängig geschätzt werden können.

Mit einem Versuchsplan vom Lösungstyp III lassen sich demnach keine Wechselwirkungen zwischen 2 Faktoren (2WW) mehr beobachten. Diese müssen zur getrennten Berechnung der Haupteffekte (HE) vernachlässigt werden.

Für eine unvermengte Schätzung der Parameter eines quadratischen Regressionsansatzes reichen 2 Faktorstufen nicht mehr aus, vielmehr muss hierfür ein Versuchsplan vom Typ 3^{p-k} in Form eines erweiterten 2^{p-k} -Plans zur Anwendung kommen, [3].

5.2.2 Response-Surface-Methode (RSM)

Die Response-Surface-Methode wurde im Jahre 1951 von Box und Wilson formuliert, um Herstellungsprozesse der chemischen Industrie zu modellieren und zu optimieren. Ziel des Verfahrens ist die Erstellung eines optimalen Regressionspolynoms, welches die Systemantwort in Abhängigkeit der Prozessparameter beschreibt. Mit statistischen Methoden werden nichtsignifikante Anteile des Regressionspolynoms eliminiert und der Modellfehler abgeschätzt.

Die Methodik kann prinzipiell zur Modellbildung aller derjenigen technischen Prozesse angewendet werden, die ein statisches, also zeitinvariantes Verhalten aufweisen. Die Anregung des Prozesses erfolgt durch Variation der p Prozessparameter - der Faktoren - in einer durch den Versuchsplan festgelegten Reihenfolge und Größe. Bezüglich der Modellierung von verbrennungsmotorischen Zusammenhängen entspricht das einer statistisch fundierten Betriebspunktvermessung des Motors. Die Systemantwort (Response Surface) kann grafisch als Fläche im $p + 1$ -dimensionalen Raum interpretiert werden.

Als Versuchspläne lassen sich alle vollständigen bzw. unvollständigen Pläne verwenden. Um mit einer geringen Versuchsanzahl zu einem adäquaten Modell zu gelangen, sollte ein Versuchsplan folgende Eigenschaften aufweisen,:

1. Orthogonalität (geringer VIF),
2. unvermengte signifikante Faktoren,
3. gute D- und G-Effizienz (vgl. Abschnitt **Optimale Versuchspläne**).

Mächtige Software-Tools unterstützen heute den Anwender bei der Aufstellung solcher Versuchsablaufpläne. In Abschnitt 5.5 wird ein solcher Versuchsplan im Rahmen der RSM angewendet.

Regression

Mittels Least-Square-Methoden werden unter Verwendung von z Systemantworten $y_i(\mathbf{x})$ die Koeffizienten $\hat{\theta}_1, \dots, \hat{\theta}_z$ eines noch zu definierenden Polynomansatzes geschätzt, sodass der mittlere quadratische Modellfehler $\sum_{i=1}^z e_i^2(\mathbf{x})$ mit $e_i(\mathbf{x}) = \hat{y}_i(\mathbf{x}) - y_i(\mathbf{x})$ ⁴ minimal wird. Wurden insgesamt n Versuche im Versuchsplan definiert, können die restlichen $n - z$ Faktorkombinationen für die Modellfehler- und Signifikanzanalyse benutzt werden.

Als Polynomansätze haben sich bewährt:

1. Modelle erster Ordnung

$$\hat{\mathbf{y}}(\mathbf{x}) = \hat{\theta}_0 + \hat{\theta}_1 x_1 + \dots + \hat{\theta}_p x_p;$$

2. Modelle erster Ordnung mit Wechselwirkung

$$\hat{\mathbf{y}}(\mathbf{x}) = \hat{\theta}_0 + \sum_{i=1}^p \hat{\theta}_i x_i + \sum_{i,j=1;i < j}^p \hat{\theta}_{ij} x_{ij};$$

3. Modelle zweiter Ordnung

$$\hat{\mathbf{y}}(\mathbf{x}) = \hat{\theta}_0 + \sum_{i=1}^p \hat{\theta}_i x_i + \sum_{i=1}^p \hat{\theta}_{ii} x_{ii}^2 + \sum_{i,j=1;i < j}^p \hat{\theta}_{ij} x_{ij}.$$

Algorithmen zur Regression sind in ausreichender Zahl bekannt und z. B. in [18, 95] zu finden. In [18] wird vorgeschlagen, zunächst mit einem für den Modellansatz erster Ordnung ausreichenden Versuchsplan zu beginnen und dann im näher zu untersuchenden Parameterraum einen Ansatz zweiter Ordnung zu verfolgen, um die Modellgenauigkeit zu verfeinern. Für die Modellbildung in dieser Arbeit wird ein Modell zweiter Ordnung gewählt. Als Parameterschätzverfahren kommt der Gauss-Newton-Algorithmus zum Einsatz.

Residualanalyse

Die Anpassungsgüte des Modellpolynoms wird durch die Standardabweichung der Residuen⁵ $\sigma_{RES} = \sqrt{E[S_{RES}^2]}$ von ihrem Mittelwert 0 beschrieben. Der Vorhersagefehler des Modells liegt bei $3 * \sigma_{RES}$ (mit einer Wahrscheinlichkeit von 99,9%).

⁴ $\hat{y}_i(\mathbf{x})$ ist die Schätzung des Polynommodells für den Parametervektor \mathbf{x}

⁵Die Residuen entsprechen $e_i(\mathbf{x}) = \hat{y}_i(\mathbf{x}) - y_i(\mathbf{x})$.

Signifikanzanalyse

Bei der Signifikanzanalyse wird getestet, ob eine Übereinstimmung der Varianz σ_z^2 der Stichproben mit der Faktorkombination z^6 bezogen auf die Regressionsfunktion mit der Varianz σ_{RES}^2 des Modellfehlers zu verzeichnen ist, also ob die Auswirkungen der Faktorkombination z auf die Modellfunktion signifikant sind. Dazu wird in einem F-Test die Gültigkeit der Hypothese $H_z^0 : \hat{\theta}_z = 0$ untersucht. Wird diese verworfen, bedeutet das, es liegt in der Faktorkombination z ein signifikanter Anteil der Regressionsfunktion vor. Anderenfalls ist die Faktorkombination nicht signifikant und muss im Polynom nicht berücksichtigt werden. Unter der Annahme, dass bei Stichprobenexperimenten für die Varianzen die Erwartungswerte der empirischen Varianzen $E[S_z^2]$ und $E[S_E^2]$ eingesetzt werden können, [14], wird für jeden Term $\hat{\theta}_z$ der Regressionsfunktion der Hypothesentest formuliert zu:

$$\text{Verwerfe } H_z^0 \text{ für } \frac{S_z^2}{S_{RES}^2} > F_{\alpha;1,r}. \quad (5.1)$$

Hierbei ist r die Anzahl der Freiheitsgrade zur Bestimmung der Varianz des Modellfehlers, die als Auswirkung der Messungenauigkeit interpretiert werden kann. Da jede Faktorkombination bei dem in **Gl. 5.1** angenommenen orthogonalen 2-stufigen Design nur die zwei möglichen kodierten Level -1 und $+1$ annehmen kann (vgl. Einflussplan), wird dem F-Test der Freiheitsgrad 1 für die Varianzbestimmung des Faktoreinflusses übergeben. Bei mehrstufigen Designs ergibt sich hier ein entsprechend höherer Wert.

In der Praxis liefert die statistische Auswertesoftware meist einen so genannten p_{SIG} -Wert, der für jede Faktorkombination angibt, wie groß das Vertrauensintervall für die Verwerfung der F-Test-Hypothese ist. Bei Werten von $p_{SIG} < 0.05$ geht man von einer Signifikanz der Faktorkombination aus. Stellt man über die Varianzanalyse fest, dass ein bestimmter Faktor nicht signifikant ist, so wird dieser aus der Regressionsfunktion entfernt und die Regression so lange wiederholt, bis nur noch n_s signifikante Faktorkombinationen in der Funktion enthalten sind.

Adäquatheitstest

Steht das Modellpolynom fest, so muss mit einem Adäquatheitstest⁷ geprüft werden, ob es sich bei der mathematischen Beschreibung um ein adäquates Modell unter Berücksichtigung der Messunsicherheiten handelt.

Geht man von n_s signifikanten Faktorkombinationen aus, so lässt sich für jeden dieser Faktoren $\hat{\theta}_v$ eine Varianz σ_{E-v}^2 der n_v Beobachtungen dieser Faktorkombination feststellen. Diese Varianz ist sozusagen der Messfehler bei einer bestimmten Faktor-

⁶Für z können beliebige Faktorkombinationen eingesetzt werden, die in Regressionsmodellen auftreten, z. B. A , AB , ABC , \dots

⁷Dieser Test ist auch als Lack-of-Fit-Test bekannt.

kombination. Aus den n_s möglichen Einzelvarianzen lässt sich dann die empirische Varianz des Grundfehlers S_{PE}^2 ⁸ zu

$$S_{PE}^2 = \sum_{v=1}^{n_s} (n_v - 1) \sigma_{E-z}^2 / (n - n_s) \quad (5.2)$$

berechnen. Für die empirische Varianz des Modellfehlers⁹ S_{LOF}^2 folgt dann mit S_{RES} :

$$S_{LOF}^2 = (S_{RES}^2 r - S_{PE}^2 (n - n_s)) / (n_s - p - 1). \quad (5.3)$$

Die mittels F-Test zu überprüfende Nullhypothese lautet somit $H_{LOF}^0 : \sigma_{LOF}^2 = \sigma_{PE}^2$:

$$\text{Verwerfe } H_{LOF}^0 \text{ für } \frac{S_{LOF}^2}{S_{PE}^2} > F_{\alpha; n_s - p - 1, n - n_s}. \quad (5.4)$$

In Analogie zur Signifikanzanalyse wird zur Überprüfung der Modelladäquatheit wiederum ein entsprechender p_{LOF} -Faktor herangezogen, der größer als 0.05 sein muss, damit die Hypothese verworfen wird. In diesem Fall kann von einem Modell ausgegangen werden, dass die Realität mit all ihren Signifikanzen im untersuchten Modellraum gut wiedergibt.

Optimale Versuchspläne

Ziel der optimalen Versuchsplanung ist es, eine optimale Versuchsanzahl und bei gegebener Versuchsanzahl die optimale Allokation der Versuchspunkte zu finden. Ein Versuchsplan ist optimal, wenn er die Wirkungsfläche (Response Surface) mit höchster Präzision zu schätzen gestattet, [83].

Ein D-optimaler Versuchsplan liefert die größtmögliche Präzision der Schätzkoeffizienten. Wählt man einen Versuchsplan, der zu einer Minimierung der maximalen Varianz des Prognosewertes führen soll, so heißt der Plan G-optimal. Bei A-optimalen Versuchsplänen ist die mittlere Varianz der Koeffizientenschätzung minimal. Es gibt des Weiteren noch E-, I- und C-optimale Pläne.

Einen D-optimalen Plan - das ist die für technische Fragestellungen wichtigste Struktur - kann man mathematisch als genau denjenigen Versuchsplan interpretieren, für den das Volumen des Streuungsellipsoids des Schätzvektors $\hat{\Theta}$ minimal ist. Das entspricht einer Minimierung der Kovarianzmatrix $B_{\hat{\Theta}}$. Eine Herleitung dazu ist in [3] angegeben.

Die Erstellung optimaler Versuchspläne ist mathematisch sehr aufwändig und bei Fehlen notwendiger a-priori-Information zum Teil nicht lösbar. Software-Tools bieten Unterstützung bei der Findung von entsprechenden Näherungslösungen.

⁸mean square of pure error

⁹sum of squares for lack of fit

Um exakte optimale Pläne umzusetzen, müssen viele Realisierungen der einzelnen Faktorkombinationen durchgeführt werden. In der Praxis wird deshalb ein Effizienzkriterium eingeführt, das den mit n Versuchen erreichbaren Anteil des Optimalzustandes charakterisiert. Aus der Literatur geht hervor, dass Versuchspläne mit einer G- bzw. D-Effizienz von mehr als 50% praktisch optimal sind. Das ist für die meisten orthogonalen Teilfaktorpläne erfüllt. Eine weitere Optimierung des Versuchsplans in Richtung D- bzw. G-Optimalität ist deshalb meist nicht erforderlich, [83].

5.3 Neuronale Netze als Prozessmodelle

5.3.1 Grundlagen

Neuronale Netze bilden die Informationsverarbeitung biologischer Nervensysteme in Form eines abstrahierten Modells ab. Sie können beliebige nichtlineare Transformationen von gegebenen Eingangsdaten auf die Netzausgänge anhand entsprechender Trainingsdatensätze erlernen. Sie sind damit universelle Approximatoren für das statische und dynamische Prozessverhalten und stellen eine Alternative zu den Polynomansätzen dar.

Jedes neuronale Netz ist, angelehnt an das biologische Vorbild, aus vernetzten Neuronen-Elementen aufgebaut. Jedes Neuron wiederum beinhaltet eine so genannte Basisfunktion Φ_i , die einen Eingangsvektor auf einen skalaren Ausgangswert projiziert. Diese Basisfunktion besteht aus einer Überföhrungsfunktion, die die Elemente des Eingangsvektors \mathbf{x} auf eine skalare Zwischengröße z abbildet (Wichtung) und einer sich anschließenden Aktivierungsfunktion. **Abb. 5.3** verdeutlicht die Funktion eines Neurons beispielhaft in einem mehrschichtigen Netzverbund.

Im Kontext der Modellbildung kann eine allgemeine Approximationsfunktion für neuronale Netze mit einer verdeckten Schicht und einer linearen Ausgangsschicht aufgestellt werden, welches einen Eingangsvektor \mathbf{x} auf eine skalare Ausgangsgröße \hat{y} abbildet [58]:

$$\hat{y}(\mathbf{x}) = \sum_{i=0}^M w_i^{(o)} \Phi_i(\mathbf{x}, \mathbf{w}_i^{(h)}). \quad (5.5)$$

Dabei sind $\mathbf{w}_i^{(h)}$ der Wichtungsvektor in der verdeckten und $\mathbf{w}^{(o)}$ der Wichtungsvektor in der Ausgangsschicht.

Die Lernfähigkeit ist ein herausragendes Merkmal neuronaler Netze. Über entsprechende Trainingsalgorithmen wird eine Anpassung des Netzverhaltens an den zu Grunde liegenden Prozess erreicht. Dazu sind die Gewichtsvektoren in den einzelnen Neuronen und in der Ausgangsschicht mit geeigneten Verfahren so zu schätzen, dass eine größtmögliche Übereinstimmung der Modellantwort mit der realen Systemantwort gegeben ist.

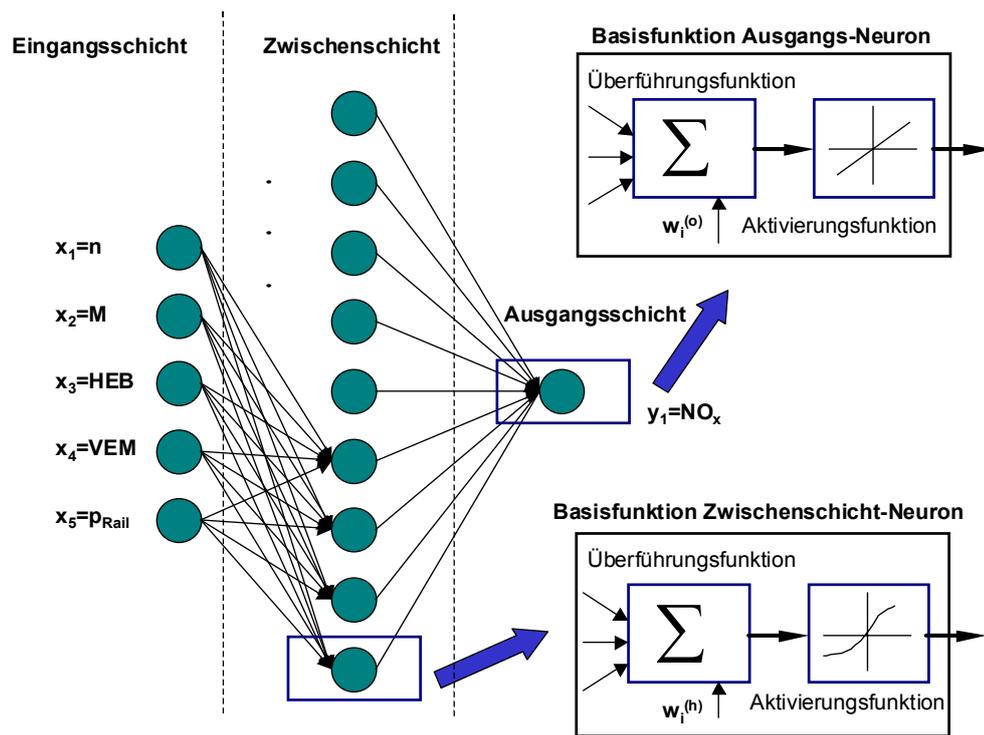


Abb. 5.3 Neuronales Netz mit einer Zwischenschicht und linearem Ausgangs-Neuron (5-9-1-Netz) als Stickoxid-Modell

Unabhängig von der gewählten Basisfunktion ist \hat{y} linear in den Gewichten $w_i^{(o)}$ der Ausgangsschicht, was eine Schätzung derselben mit einem Least-Square-Verfahren erlaubt. Um mit **Gl. 5.5** eine nichtlineare Modellapproximation zu erreichen, müssen die Aktivierungsfunktionen der einzelnen Neuronen nichtlinear sein. Die Schätzung der Elemente von $\mathbf{w}_i^{(h)}$ erfolgt deshalb zweckmäßiger Weise mit nichtlinearen Optimierungsverfahren (vgl. Kapitel 6). Bei Radial-Basis-Netzen werden die Wichtungsfaktoren der verdeckten Schicht in geschickter Weise vorgelegt, sodass nur eine lineare Optimierung erfolgen muss.

5.3.2 Netzarchitekturen

Die in Technikanwendungen verbreitetsten Netztopologien sind so genannte *Multi-Layer-Perceptron-Netze* und *Radial-Basis-Netze*. Diese unterscheiden sich grundlegend in ihrer Basisfunktion und damit auch in ihrem Transformations-Verhalten. **Abb. 5.4** zeigt mögliche Aktivierungsfunktionen für beide Netztypen, deren Übertragungsverhalten für einen zweidimensionalen Eingangsvektor und skalaren Netz- ausgang in **Abb. 5.5** illustriert ist.

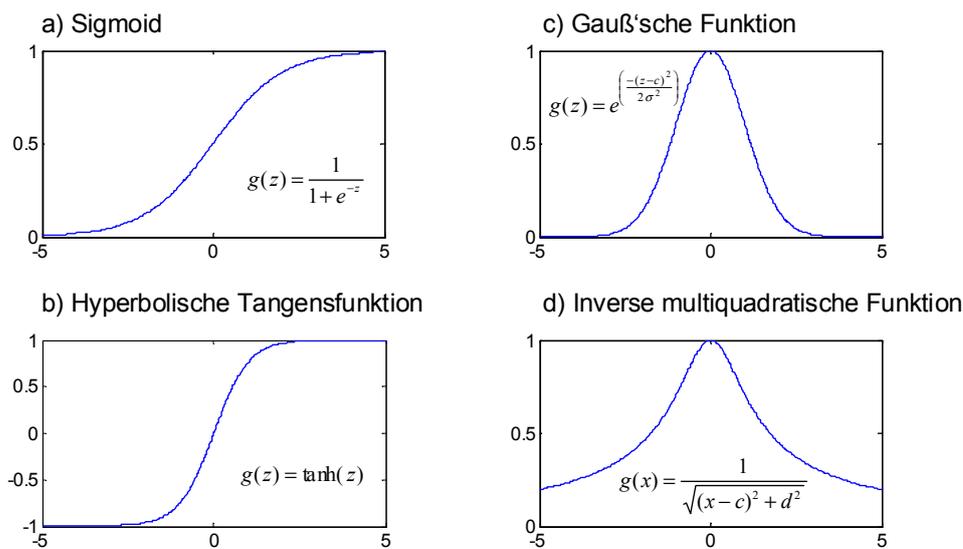


Abb. 5.4 Beispiele für mögliche Aktivierungsfunktionen, a),b) - MLP; c),d) - RBF

Multi-Layer-Perceptron (MLP)

Mehrschichtige Perceptronen verwenden folgenden Basisfunktionstyp

$$\Phi_i(\mathbf{x}, \mathbf{w}_i^{(h)}) = g(\mathbf{w}_i^{(h)T} \mathbf{x}), \quad (5.6)$$

wobei für g eine Aktivierungsfunktion mit Sättigungscharakter zu wählen ist. Durch eine Projektion des Eingangsvektors auf den Gewichtsvektor in Form des Skalarprodukts $\mathbf{w}_i^{(h)T} \mathbf{x}$ wird das n-dimensionale Eingangsproblem auf die Berechnung eines skalaren Aktivierungsfunktionals reduziert. Bei der Optimierung der Gewichte $\mathbf{w}_i^{(h)}$ im Rahmen einer Lernprozedur werden demnach optimale Projektionsrichtungen ermittelt. Die Basisfunktionen der MLP's sind global. MLP's führen zu einer Dimensionsreduzierung und eignen sich insbesondere für vieldimensionale Probleme.

Da die Gewichte der verdeckten Schicht technisch schwer interpretierbar sind, erfolgt die Initialisierung des Netzes meist zufällig. In Verbindung mit der sich anschließenden nichtlinearen Optimierung ist der Lernprozess insgesamt sehr zeitaufwändig. Als Optimierungsverfahren wird in den hier betrachteten MLP-Netzen ein Gradienten-Suchverfahren eingesetzt, welches zur Ermittlung der besten Suchrichtung hin zum minimalen Modellfehler die Netzantwort des vorangegangenen Schrittes benötigt. Dieses Lernverfahren wird deshalb als Backpropagation-Methode und entsprechende MLP's auch als Backpropagation-Netzwerke bezeichnet.

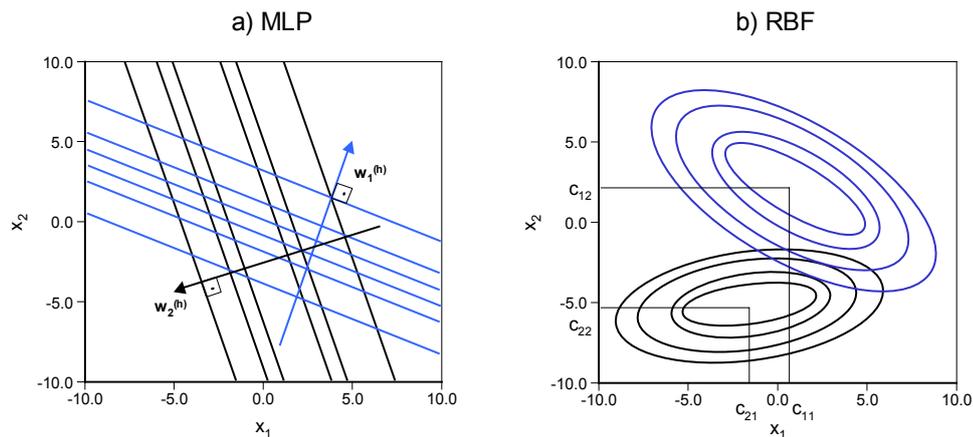


Abb. 5.5 Überschneidung der Basisfunktionen für MLP- und RBF-Netze am Beispiel eines zweidimensionalen Eingangsvektors

Radial-Basis-(Funktions-)Netze (RBF)

Radial-Basis-Netze stellen auf Grund ihrer schnelleren Lernalgorithmen eine Alternative insbesondere für mitteldimensionale Probleme dar. Es gilt die Basisfunktion

$$\Phi_i(\mathbf{x}, \mathbf{w}_i^{(h)}) = g(\|x - c_i\|_{\Sigma_i}). \quad (5.7)$$

Dabei sind $\|x - c_i\|_{\Sigma_i}$ die jeweilige Abstandsnorm und c_i die Zentren der Basisfunktionen. In RBF-Netzen wird jedes Neuron durch sein Zentrum c_i charakterisiert. Durch entsprechende Wahl der Varianzmatrix Σ_i zur Bestimmung des Abstandsnormals können sowohl elliptisch-achsenorthogonale als auch echte radiale RBFs erzeugt werden, die Elemente des Wichtungsvektors $\mathbf{w}_i^{(h)}$ können als Varianzen der Glockenkurven interpretiert werden, [57]. Jede Basisfunktion hat dabei die Dimensionalität des Eingangsraumes. Da alle Bereiche, in denen Messdaten vorliegen, mit mindestens einer Basisfunktion abgedeckt werden müssen, steigt die Komplexität des Netzes mit steigender Dimensionalität des Problems stark an. Vorteilhaft bei RBF-Netzen ist die geometrische Interpretierbarkeit der Basisfunktionen.

Die Zentren der Basisfunktionen und die Varianz-Matrizen müssen so gewählt werden, dass keine Unter- bzw. Überbestimmtheit des Netzes auftritt. In der Regel werden so viele Basisfunktionen wie Messdatensätze angesetzt und die Varianzen mit einer Nächster-Nachbar-Methode¹⁰ abgeschätzt.

Sonderformen

Neben den näher erläuterten Topologien existieren noch ein Menge anderer Netz-Strukturen, die meist eine Mischform aus neuronalen Netzen und anderen mathematischen Abstraktionsformen, wie z. B. Fuzzy-Logik bestehen. Neuro-Fuzzy-Netze

¹⁰Schnittpunkt benachbarter Glockenkurven bei $y = 0.5$

zum Beispiel verwenden Basisfunktionen, die eine Konjunktion (Und-Verknüpfung in der Fuzzy-Mengenlehre) von Zugehörigkeitsfunktionen darstellen. In der Nomenklatur der neuronalen Netze entsprechen die Zugehörigkeitsfunktionen den Aktivierungsfunktionen. Die Basisfunktionen der Neuro-Fuzzy-Netze sind noch besser interpretierbar als RBF-Netze, allerdings steigt auch der Implementierungsaufwand an.

Weiterhin existieren spezielle Netztypen für Clustering- und Diagnoseaufgaben (Hopfield-, Kohonen-Architektur, Adaptive Resonanztheorie, [10]) sowie teillinearisierte Ansätze, zu denen auch das LOLIMOT¹¹-Netz zählt. Das Prinzip von LOLIMOT baut auf einem RBF-Netz auf und basiert auf der Idee, eine nichtlineare Funktion durch eine Überlagerung stückweise linearer Funktionen zu approximieren, [56].

Obwohl in dieser Arbeit neuronale Netze ausschließlich zur Modellierung statischer Zusammenhänge benutzt werden, soll nicht unerwähnt bleiben, dass sich diese Strukturen auch zur Modellbildung dynamischer Prozesse eignen. Dazu werden dem Eingangsraum des Netzes eine oder mehrere Ableitungen der zu berücksichtigenden Prozessparameter zugefügt (externe Dynamik) oder Basisfunktionen mit Dynamikanteil verwendet (interne Dynamik).

5.4 Physikalisch basierte Motorprozess-Simulation

Für Grundlagenuntersuchungen hinsichtlich der dynamischen Prozessoptimierung am OM441 LA wurde im Rahmen dieser Arbeit auch ein physikalisches Prozessmodell mit teilweise halbempirischen Ansätzen eingesetzt. Das nulldimensionale Modellierungstool THEMOS ist in der Lage, auf Basis eines gegebenen Brennverlaufs Aussagen über die zu erwartende Motorleistung und die Ladungswechselvorgänge zu machen.

Das Gaswechsel-Leitungssystem wird nach der Füll- und Entleer-Methode berechnet. Die Parameter des Zylinderprozesses können alternativ durch die schrittweise reale Prozessrechnung oder durch Interpolation eines mehrdimensionalen Kennfeldes, [90], ermittelt werden.

Eine Anwendung dieses Simulators zeigt **Abb. 5.6** auf der nächsten Seite. Mittels der realen Kreisprozessrechnung wurden hier die Auswirkungen eines Lastsprunges auf die NO_x -Emission und den Kraftstoffverbrauch untersucht (**Abb. 5.6(a)**). Das Ergebnis deckt sich qualitativ hervorragend mit den gemessenen NO_x -Verläufen in Kapitel 4.

Im Diagramm **Abb. 5.6(b)** ist der Vergleich zwischen der Berechnung der erwarteten NO_x -Emission durch Interpolation stationärer Messwerte und dem entsprechen-

¹¹Local Linear Model Tree

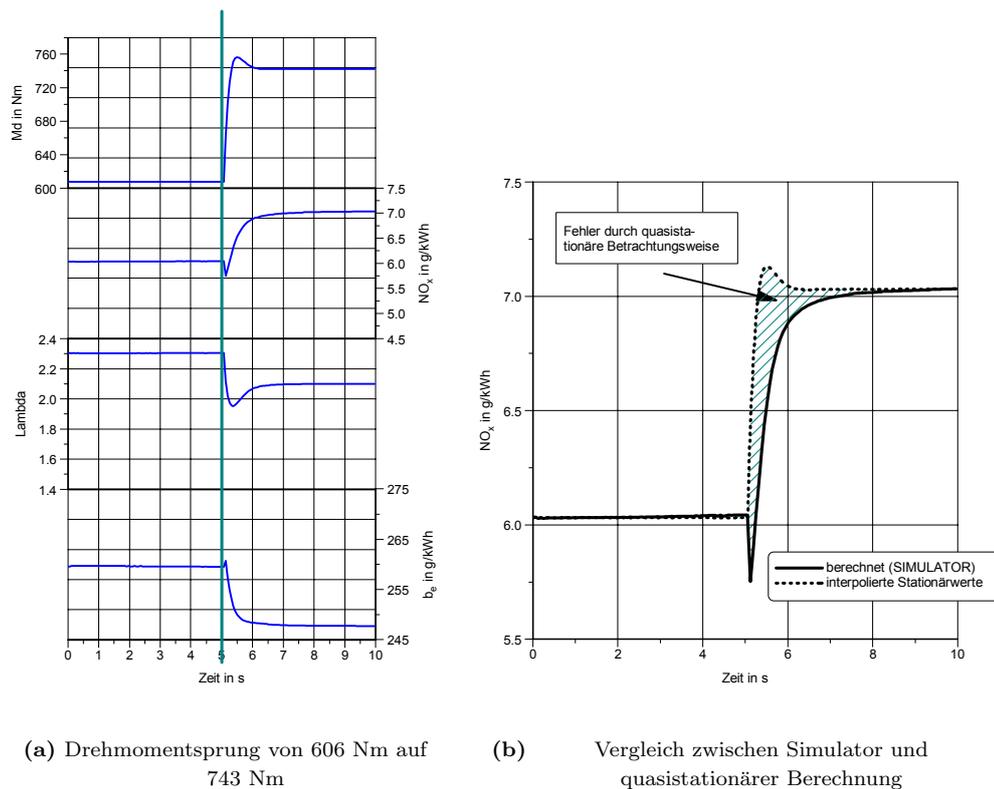


Abb. 5.6 Ergebnisse einer dynamischen Simulationsrechnung mit VTG-Turbolader-Modell

den Simulator-Ergebnis dargestellt. Die in Abschnitt 4.5.1 erläuterte Problematik der quasistationären Betrachtungsweise wird hier noch einmal verdeutlicht. Der Simulator kann jedoch gegenüber Polynom- und Neuronalen-Netz-Ansätzen nur dann Vorteile liefern, wenn er, wie im gezeigten Beispiel, mit der zeitaufwändigen realen Kreisprozessrechnung arbeitet und dabei ein dynamisches Turboladermodell zum Einsatz kommt. Ein solches Modell muss die instationären Interaktionsvorgänge zwischen Lader, Zylinder, Gaswechselleitungen und Turbine abbilden. Die Emissionsberechnungen wurden mit einem quasidimensionalen 2-Zonen-Modell durchgeführt, welches in [24] beschrieben ist.

Für die Simulation der im dynamischen Betrieb auftretenden Rußemissionen existieren bislang nur sehr aufwändige bzw. qualitativ ungenügende Ansätze, maßgeblich auf der Basis von Untersuchungen an vorgemischten Flammen [70]. Das als Ergebnis einer Untersuchung speziell zur Rußoxidation in Dieselmotoren entstandene phänomenologische Modell (vgl. [71], [79]) eignet sich aufgrund qualitativer Mängel bei der Berechnung der Restrußmasse in seiner jetzigen Form nicht für eine programmtechnische Umsetzung, sodass, insgesamt betrachtet, auf eine versuchsbasierte Modellierung des Motorprozesses nicht verzichtet werden kann.

5.5 Stationäre Motormodelle für den M47R

5.5.1 Polynommodelle auf Basis der statistischen Versuchsplanung

Zum Test der Strategien für die stationäre Prozessoptimierung sollte ein Modell erstellt werden, welches die Prozessgrößen spezifischer Kraftstoffverbrauch b_e , Stickoxidemission NO_x und Partikelmasse PM in Abhängigkeit der Führungsgrößen n , M , HEB , VEM und p_{Rail} abbildet. Die Grenzen des Parameterraums veranschaulicht **Tab. 5.3**. Der dabei berücksichtigte Motorbetriebsbereich deckt einen großen Teil der Beschleunigungsphasen des MVEG-Testzyklus ab (**Abb. 4.16** auf Seite 40) und ist zugleich klein genug, um allzu große Nichtlinearitäten im Prozessverhalten ausschließen zu können. Damit eignet sich das Modell auch zur quasistationären Untersuchung dynamischer Motorbetriebsphasen.

Tab. 5.3 Parameterraum der Motorvermessung, M47R

Parameter/Faktor	n	M	HEB (relativ zur Serieneinstellung)	VEM	p_{Rail}
Variationsbereich	2000–2500 min^{-1}	30 – 150 Nm	–5 – +5 $^{\circ}KW$	0 – 4 mm^3	400 – 800 bar

Der optimierte Versuchsplan für die 5 Parameter mit jeweils 3 Faktorstufen bestand aus insgesamt 51 Versuchen, wobei 30 zur Schätzung der Modellgüte herangezogen werden konnten. Ausgehend von einem quadratischen Regressionsansatz entstanden nach Entfernen der nichtsignifikanten Faktorkombinationen die in **Tab. 5.5** zusammengefassten Polynommodelle. Sowohl die Kenngrößen des Versuchsplans in **Tab. 5.4** als auch die der Regressionsmodelle weisen auf eine sehr hohe Modellgüte hin. Der mittlere p_{SIG} -Wert liegt für alle 3 Polynome unter 0.001, d. h. es besteht nur eine Restwahrscheinlichkeit von unter 0.1%, dass das Modell entsprechende nichtsignifikante Effekte beinhaltet. Ähnliches gilt für den Adäquatheits-Test, obwohl die Wahrscheinlichkeit der Unterbestimmtheit des Modells größer ist.

Tab. 5.4 Kenngrößen des erstellten Versuchsplans bei Annahme eines quadratischen Polynomansatzes

Kenngröße	Freiheitsgrade zur Schätzung von PE	Freiheitsgrade zur Schätzung von LOF bzw. RES	VIF (Orthogonalität)	D-Effizienz	G-Effizienz
Wert	4	26	< 1,4	60,6%	62,0%
Grenzwert	> 3	> 4	< 10	> 50%	> 50%

Für die Funktionen zur Berechnung von b_e bzw. PM wurde eine entsprechende Abszissentransformation nach der Box-Cox-Methode, [18], durchgeführt, um eine

Gleichverteilung der Schätzwerte in ihren Grenzen zu erreichen. Damit verbesserten sich die statistischen Gütemerkmale der Modelle. Bei der Box-Cox-Methode wird der Transformations-Exponent λ in der Art iterativ bestimmt, dass eine minimale Residuen-Varianz S_{RES}^2 für das Modell zu erwarten ist. Die Transformationsregel lautet:

$$\begin{aligned}\hat{y} &\Rightarrow (\hat{y})^\lambda, & \lambda \neq 0; \\ \hat{y} &\Rightarrow \ln(\hat{y}), & \lambda = 0.\end{aligned}\quad (5.8)$$

Tab. 5.5 Kenngrößen der erstellten Polynommodelle

Prozessgröße	NO_x	PM	b_e	Grenzwert
Ansatz	$\begin{aligned}NO_x = & 0,803 - \\ & 0,012M - 0,085HEB + \\ & 0,103VEM + \\ & 0,003p_{Rail} + 1e^{-4}M^2 + \\ & 0,0126HEB^2 + \\ & 0,1306VEM^2 - \\ & 0,0034M \cdot VEM + \\ & 0,32e^{-4}HEB \cdot p_{Rail}\end{aligned}$	$\begin{aligned}\ln(PM) = & -7,15 - \\ & 0,0015n + 0,0057M + \\ & 0,00627HEB + \\ & 1,18VEM - \\ & 9,4e^{-4}p_{Rail} - \\ & 4,9e^{-4}n \cdot VEM - \\ & 0,0012M \cdot HEB + \\ & 6,3e^{-5}M \cdot p_{Rail}\end{aligned}$	$\begin{aligned}(b_e)^{-1,76} = & \\ & 3,34e^{-5} - 2,11e^{-8}n - \\ & 7,56e^{-7}M + \\ & 1,53e^{-6}HEB + \\ & 2,39e^{-6}VEM + \\ & 1,41e^{-8}p_{Rail} - \\ & 3,63e^{-9}M^2 - \\ & 6,41e^{-11}p_{Rail}^2 + \\ & 2,36e^{-11}n \cdot p_{Rail} - \\ & 1,61e^{-8}M \cdot VEM + \\ & 3,23e^{-10}M \cdot p_{Rail} - \\ & 2,46e^{-7}HEB \cdot VEM\end{aligned}$	
PLOF	0,175	0,021	0,0176	> 0,01
mittleres PSIG	< 0,001	< 0,001	< 0,001	< 0,01
SRES	0,49	0,45	$2,83e^{-6}$	

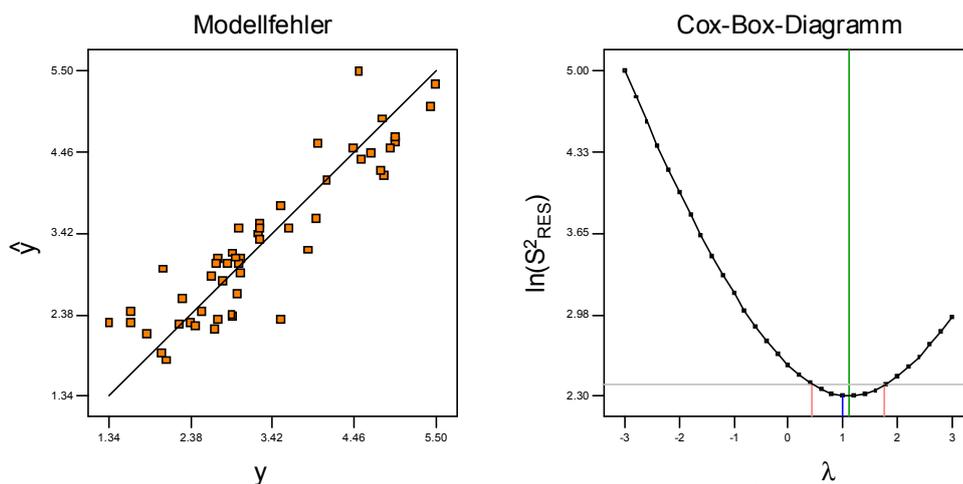


Abb. 5.7 Modellfehler und Cox-Box-Diagramm für das NO_x -Modell

Beim NO_x -Modell (**Abb. 5.7**) liegt das optimale λ bei 1, in der Mitte des 95%-Vertrauensbereiches für das Varianz-Minimum. Damit muss keine Transformation

für diese Größe erfolgen. In Analogie ergab sich für das Polynom zur Berechnung der Partikelmasse PM ein Transformationsexponent von $\lambda = 0$, was einem natürlichen Logarithmus gleichkommt, und für das b_e -Polynom ein Exponent $\lambda = -1,76$.

Das Ergebnis der Modellbildung über Polynommodelle zeigt **Abb. 5.8** im Kontext des Optimierungsproblems für einen stationären Betriebspunkt. Durch Einzeichnen der b_e -Isolinien in die Schnittebenen des durch die Parameter HEB , VEM und p_{Rail} aufgespannten b_e -Raumes kann das Optimierungsziel grafisch interpretiert werden. Angenommen, das Ziel der Optimierung bestünde primär in einer Minimierung des spezifischen Kraftstoffverbrauchs, so wäre entsprechend der Darstellung die obere rechte Ecke $[5^\circ KW, 0 mm^3, 800 bar]$ zu wählen. Beachtet man jedoch zusätzlich die Iso-Grenzflächen für die Stickoxid- und die Partikelemissionen¹², so wird das globale Optimum im hier als Zielgebiet bezeichneten Bereich zu suchen sein.

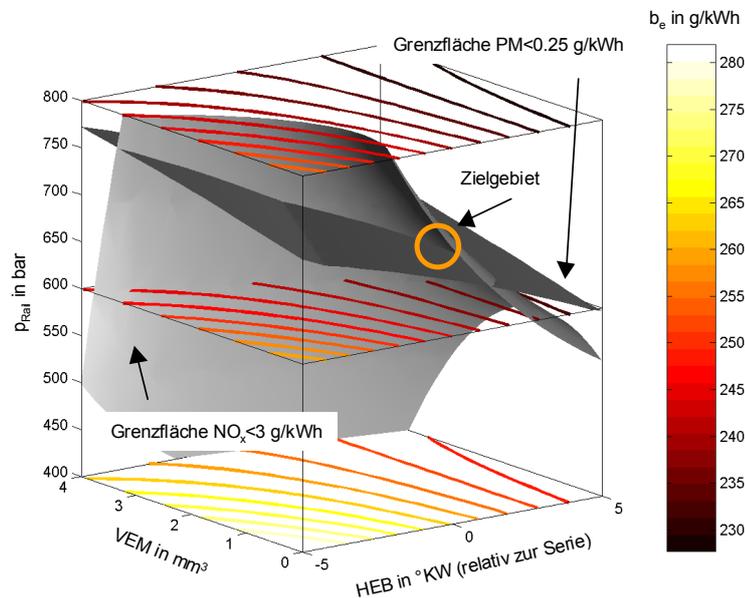


Abb. 5.8 Optimierungsraum nach Polynommodell, stationärer Betriebspunkt $n = 2250 \text{ min}^{-1}$, $M = 105 \text{ Nm}$

5.5.2 Auswahl geeigneter neuronaler Netze

Neben den beschriebenen Polynommodellen sollten auch künstliche neuronale Netze auf ihre Eignung zur Modellbildung hin untersucht werden. Als Datenbasis zum Anlernen der Netze dienten die aus der statistischen Versuchsplanung gewonnenen Datensätze. Um den Lernprozess zu verkürzen, wurden die Eingangsdaten jeweils auf das Intervall $[0 \cdot \dots \cdot 1]$ normiert. In **Tab. 5.6** sind die zur Modellerstellung benötigten Iterationen und die erreichten Modellgenauigkeiten für eine MLP- und eine RBF-Netzstruktur im Vergleich zu den Polynomansätzen zusammengestellt. In der Klasse

¹²Die eingezeichneten Grenzwerte wurden auf Basis der in der Regelung 220/70/EWG, Stufe EURO III festgesetzten Grenzwerte durch Umrechnung auf arbeitsbezogene Größen ermittelt

Tab. 5.6 Kenngrößenvergleich aller untersuchten stationären Motormodelle

		Polynom	RBF-Netz	MLP-Netz
Struktur	NO_x	$Poly^2$, LSQ-Regression	51 Eingangsneuronen, 3 Ausgangsneuronen	5-10-1-Netz (tansig/tansig/lin) ^a , Trainingsmethode: variable learning rate ^b
	PM	$\ln(Poly^2)$, LSQ-Regression	siehe NO_x	siehe NO_x
	b_e	$(Poly^2)^{-1,76}$, LSQ-Regression	siehe NO_x	siehe NO_x
Anzahl Iterationen	kumuliert	ca, 600	51	ca, 16000
Modellfehler	NO_x	0,47 g/kWh	0	0,47 g/kWh
	PM	0,03 g/kWh	0	0,03 g/kWh
	b_e	21,5 g/kWh	0	20 g/kWh

^aAktivierungsfunktionen der verschiedenen Layer: tansig - hyperbolische Tangensfunktion, lin - lineare Funktion

^bvgl. [94]

der MLP-Netze stellte sich eine Netz-Topologie, bestehend aus 3 Schichten mit 10 Neuronen in der Zwischenschicht, als günstigster Kompromiss zwischen Konvergenzverhalten und Modellgüte heraus.

Es ist zu erkennen, dass die RBF-Struktur ein exaktes Abbild der Lerndaten liefert. Die Zentren der Basisfunktionen wurden im Training an die Eingangspunkte angepasst. Der Anlernvorgang ist mit 51 Iterationen sehr kurz. Die gewählte Basisfunktion¹³ verspricht auch in den Interpolationsgebieten eine hohe Modellgüte.

Das MLP-Netz benötigt hingegen 16000 Iterationen bis zur Konvergenz. Als Abbruchkriterium galt hierbei ein maximal zulässiger Modellfehler, der dem des Polynommodells entspricht. Es gelang nicht, das Konvergenzverhalten des MLP-Netzes durch die Wahl anderer Netztopologien (mehrere Zwischenschichten, größere Neuronenanzahl) weiter zu verbessern.

Zur Visualisierung des Interpolationsverhaltens der aufgestellten Modelle wurde auf Basis der mathematischen Programmiersprache *MATLAB*[®] ein Software-Tool erstellt. Damit ist es möglich, in den Neuronalen-Netz-Modellen unerwünschte Nicht-linearitäten zu lokalisieren und damit den Einsatzbereich der verschiedenen Modellvarianten zu spezifizieren. **Abb. 5.9** zeigt beispielhaft die Differenzendarstellung von Polynommodell und RBF-Netz für einen $[HEB, VEM, p_{Rail}]$ -Eingangsvektor im n/M -Kennfeld. Die Belegung des Eingangsvektors kann über Schieberegler variiert werden, sodass eine interaktive Darstellung des gesamten Modellierungsbereichs möglich ist.

Trotz gleicher Datenbasis weisen unterschiedliche Modellansätze deutliche Differenzen in ihrer Abbildungsgenauigkeit auf, qualitativ kann jedoch zumindest im dar-

¹³Entsprechend Abschnitt 5.3.1 wurde als Basisfunktion eine Gauß'sche Glockenkurve gewählt.

gestellten Fall von einer recht guten Übereinstimmung der verschiedenen Modelle ausgegangen werden.

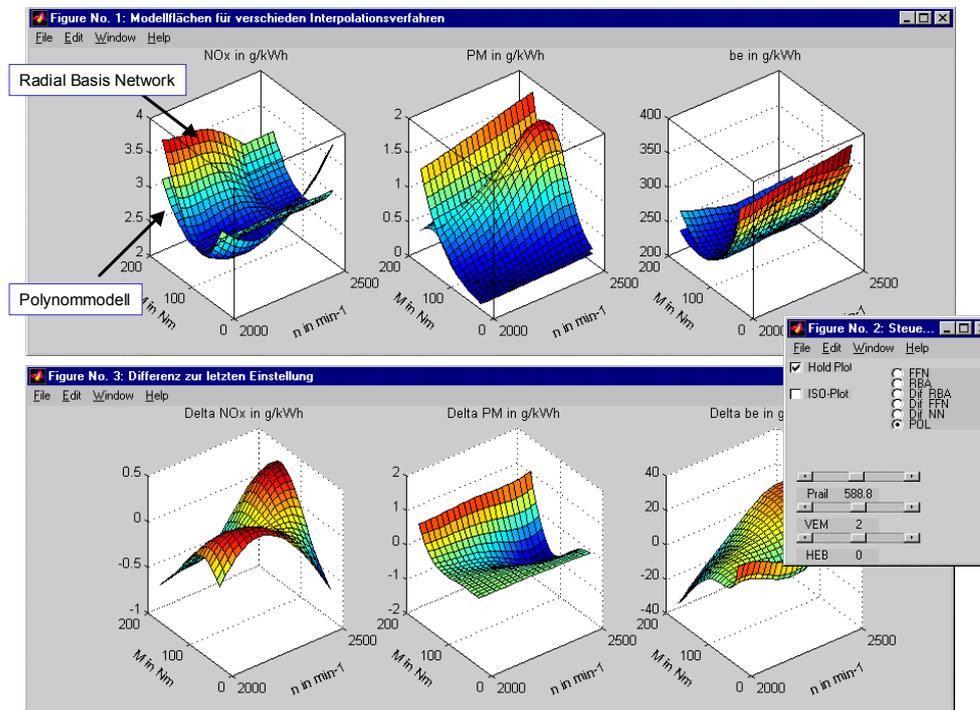


Abb. 5.9 GUI des grafischen Modellierungs- und Visualisierungs-Tools auf MATLAB-Basis am Beispiel der Modelldifferenz zwischen Polynomansatz und RBF-Netz

Die Problematik der unterschiedlichen Modellfehler verdeutlicht **Abb. 5.10** aus einer anderen Perspektive. Dargestellt sind die Interpolations-Graphen der untersuchten Modelle entlang einer p_{Rail} -Variation. Entlang dieses Schnittes lagen keine Lerndaten für die Modelle vor, sodass die Grafik ein reines Interpolationsergebnis darstellt. Mit Hilfe einer Validierungsmessung sollte die Interpolationsgüte der verschiedenen Modellvarianten überprüft werden. Man erkennt, dass das MLP-Netz als qualitatives Prozessmodell ungeeignet ist. In [52] wird dieser Nachteil gegenüber dem statistischen Polynomansatz anhand eines anderen motortechnischen Beispiels bestätigt. Auch in [1] konnten bei der Modellierung des stationären Emissionsverhaltens eines Verbrennungsmotors mittels MLP-Netzen im Interpolationsbereich nur wenig befriedigende Modellgenauigkeiten erzielt werden ($R^2 < 0.8$). Ursache hierfür ist die unzureichende Interpolationsgüte von MLP-Netzwerken bei ungenügender Lerndatenanzahl.

Der quadratische Polynomansatz und das RBF-Netz bilden die tatsächlichen Zusammenhänge deutlich besser ab.

Da sich durch weitere Versuche mit verkürzten MLP-Topologien (geringer Neuronenzahl) keine weitere Verbesserung der Modellqualität ergab, wurde für die Optimierungsaufgaben in dieser Arbeit der quadratische Polynomansatz entsprechend

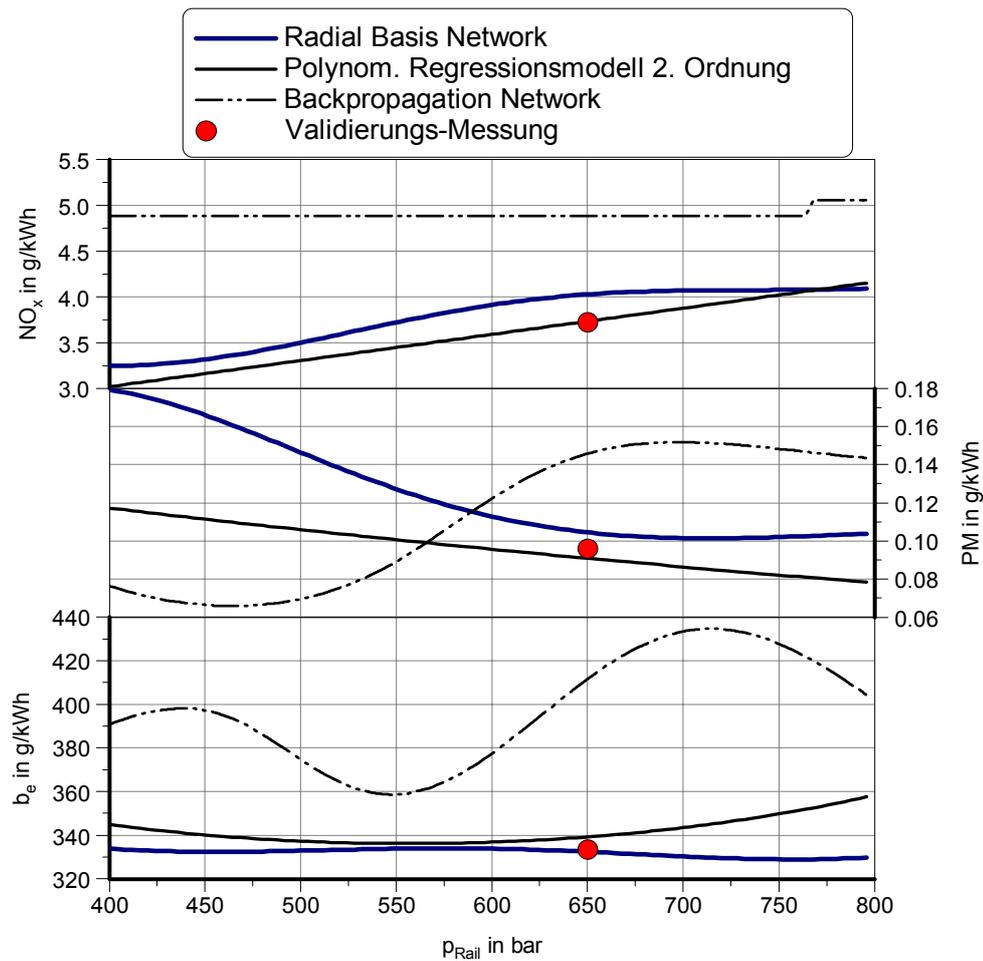


Abb. 5.10 Modellvergleich entlang eines 2-D-Kennfeldschnittes bei $n = 2250 \text{ min}^{-1}$, $M = 80 \text{ Nm}$, $HEB = 0^\circ \text{KW}$ (rel. zur Serie), $VEM = 2 \text{ mm}^3$

Tab. 5.6 als Prozessmodell ausgewählt. Dieses 5-dimensionale Modell eignete sich nicht zuletzt wegen seiner einfachen mathematischen Umsetzbarkeit am besten zum Test verschiedener Optimierungsstrategien.

Kapitel 6

Numerische Verfahren zur Prozessoptimierung

6.1 Klassifizierung

In der Literatur lassen sich in ihrer Betrachtungsweise verschiedene Ansätze für eine Klassifizierung von Optimierungsverfahren finden. Am Beispiel von mehrdimensionalen Optimierungsproblemen mit Nebenbedingungen soll zunächst eine Übersicht der verschiedenen Verfahren gegeben werden. Ansätze für multikriterielle und dynamische Optimierungsprobleme werden in den folgenden Abschnitten erläutert.

Es wird zunächst zwischen analytischen und numerischen Verfahren unterschieden [34]. Bei den analytischen Verfahren müssen der zu optimierende Prozess und die dazugehörige Zielfunktion in Form eines analytischen physikalisch-mathematischen Modells vorliegen, welches die Abhängigkeiten des Prozessverhaltens von den Prozessführungsgrößen (Parametern) darstellt. Weitere Bedingung ist das Vorliegen der ersten und zweiten Ableitung dieser Zielfunktion in analytischer Form. Durch Nullsetzen der ersten Ableitung der Zielfunktion können so die Prozessoptima bestimmt und über die zweite Ableitung Aussagen über die Art der Optima getroffen werden. Da ein geschlossenes analytisches und differenzierbares Modell insbesondere für die meisten technischen Prozesse mit Nebenbedingungen nicht verfügbar ist, finden zur Optimierung in der Regel numerische Verfahren Verwendung, die das Optimum nach einer endlichen Anzahl von Optimierungsschritten finden. Eine Übersicht zu den verschiedenen numerischen Verfahren gibt **Abb. 6.1**.

Ein weiteres Klassifizierungsmerkmal ist die jeweilige Art der Zielfunktion und der Nebenbedingungsfunktionen. Man spricht von einem linearen Optimierungsproblem, wenn sowohl die Zielfunktion $F(\mathbf{x})$ als auch die Nebenbedingungsfunktionen $G_i(\mathbf{x})$ linear von den Führungsgrößen abhängen. Lineare Optimierungsprobleme sind dadurch charakterisiert, dass lokales und globales Optimum aufeinander fallen und der zulässige Optimierungsraum Λ endlich viele Randpunkte besitzt, von denen in einem das Optimum liegt. Solche Aufgaben werden zumeist mit dem *Simplex-Verfahren*

nach Dantzig gelöst. Dieses stellt ein sequentielles Verfahren dar, bei dem, ausgehend von einem Eckpunkt des durch Zielfunktion und Nebenbedingungen aufgespannten n -dimensionalen Simplex, als nächster ein benachbarter Eckpunkt bestimmt wird, der zu einem Zuwachs¹ der Zielfunktion führt [26].

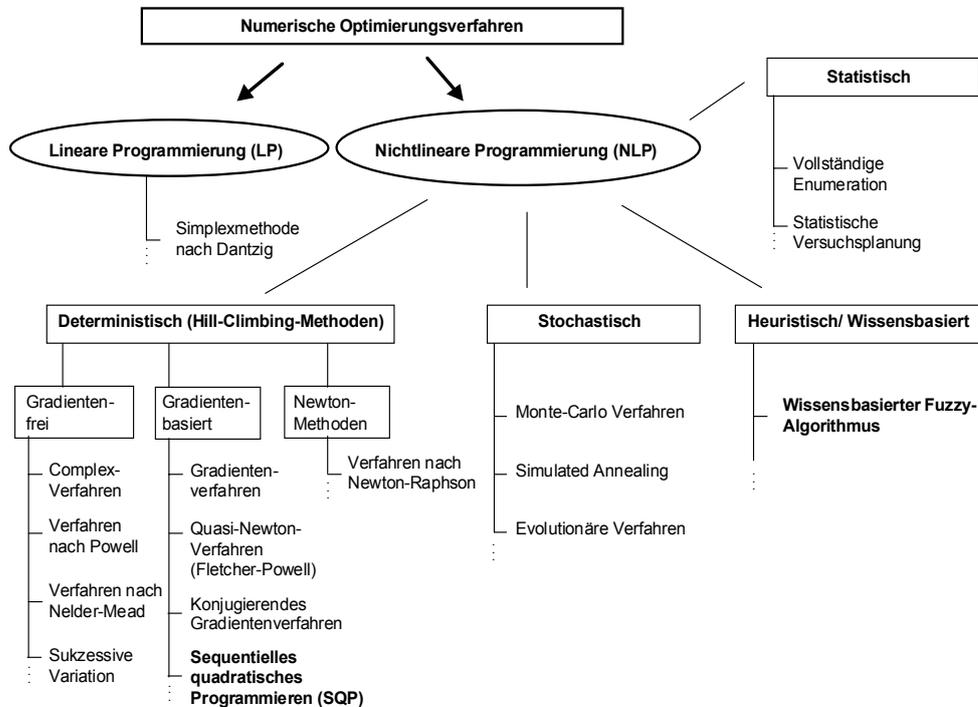


Abb. 6.1 Klassifizierung numerischer Optimierungsstrategien, fettgedruckte Strategien werden in dieser Arbeit angewendet

Verfahren der linearen Programmierung (LP) werden vor allem im Gebiet des Operation Research behandelt [5]. Wie viele technische Aufgabenstellungen ist auch die Motorprozessoptimierung nichtlinear und bedarf anderer Lösungsansätze. Da bei nichtlinearen Prozessen in der Regel mehrere lokale Optima vorliegen, gibt es für solche Problemstellungen - im Gegensatz zur linearen Programmierung - keinen allgemeingültigen Lösungsansatz. Nichtlineare Programmierungsmethoden müssen immer dann angewendet werden, wenn entweder die Zielfunktion oder die Nebenbedingungen nichtlinear von den Prozess-Führungsgrößen abhängen. Ein Sonderfall des nichtlinearen Programmierens (NLP) ist der als quadratisches Optimieren (QP) bekannte Ansatz, der für Aufgabenstellungen mit quadratischer Zielfunktion und linearen Nebenbedingungen entwickelt wurde [95].

Die Verfahren des nichtlinearen Programmierens gliedern sich in deterministische, statistische, stochastische und heuristische Ansätze. Die am weitesten verbreitete Gruppe ist die der deterministischen Verfahren. Sie werden auch als Hill-Climbing-Verfahren bezeichnet, da im 3-dimensionalen Raum das Optimum einer Zielfunkti-

¹gilt für Maximumprobleme

on auch als Berggipfel interpretiert werden kann. Man unterscheidet hier gradientenfreie, gradientenbasierte und Newton-Verfahren. Die gradientenfreien Verfahren zeichnen sich dadurch aus, dass sie zur Bestimmung von Suchrichtung und Suchschrittweite innerhalb eines Optimierungsschrittes nur die Zielfunktionswerte $F(\mathbf{x})$ benötigen. Sie werden deshalb auch als Suchverfahren bezeichnet. Gradientenverfahren, zu denen beispielsweise die *Methode des steilsten Abstiegs*, die *Gradientenmethode* und die hinsichtlich der benötigten Schrittzahl optimierten Verfahren nach *Fletcher-Powell* und *Fletcher-Reeves* zählen, benötigen zusätzlich zum Funktionswert der Zielfunktion noch deren Ableitung $\nabla F(\mathbf{x})$, die Newton-Verfahren darüber hinaus noch die zweite Ableitung $\nabla^2 F(\mathbf{x})$ in Form der Hesse-Matrix \mathbf{H} . Die Such- und Gradientenmethoden schreiten bei großen Abständen zum Optimum gut voran, wobei sich die Suchgeschwindigkeit in der Nähe des Optimums stark verringert oder die Suche gar scheitert². Hier liegt der Vorteil der Newton-Methoden, die in der Nähe des Optimums sehr gut konvergieren. Nachteilig wirkt sich hier aus, dass für jeden Suchpunkt $\mathbf{x}^{(i)}$ zusätzlich zum n -dimensionalen Gradienten $\nabla F(\mathbf{x})^{(i)}$ auch noch die $n \times n$ -Matrix $\nabla^2 F(\mathbf{x})^{(i)}$ und deren Inverse berechnet werden müssen. Einen Kompromiss stellen die Quasi-Newton-Methoden dar, bei denen die Hesse-Matrix nicht direkt berechnet, sondern aus den Werten für $\nabla F(\mathbf{x})^{(i)}$ geschätzt wird. Bei sehr hoher Dimensionalität des Optimierungsproblems - die Motorprozess-Optimierung ist ein solches Problem - stellen die genannten Nachteile unüberwindbare Hindernisse, insbesondere für eine effiziente Online-Optimierung dar. Da die Hill-Climbing-Methoden für die Offline-Optimierung des Motorprozesses in dieser Arbeit verwendet wurden, ist ihr mathematischer Hintergrund im nächsten Abschnitt detaillierter beschrieben.

Statistische Verfahren untersuchen den gesamten Optimierungsraum in einer Art und Weise, die es erlaubt, die Lage des Optimums mit einer berechenbaren Toleranz zu schätzen. In Kapitel 5 wurde bereits die Anwendung unvollständiger faktoriellen Versuchspläne im Rahmen der *Response Surface Method (RSM)* diskutiert. Im Gegensatz zur heute in der Motorenentwicklung weit verbreiteten *Methode der vollständigen Enumeration* - also der vollständigen Rastervermessung im Rahmen eines Full Factorial Design -, gelingt es mit so genannten Teilfaktorplänen (Fractional Factorial Design), die für einen Versuch benötigte Anzahl von Parameterkombinationen drastisch zu reduzieren. Entsprechende Regressionsmodelle, die auf den Messungen des Versuchsplans basieren und das signifikante Prozessverhalten beschreiben, gestatten eine einfache Findung des Optimums. Nachteilig bei den statistischen Methoden ist die Tatsache, dass mittels Versuchen gefundene Modelle in der Regel nicht auf andere Prozesse übertragbar sind und somit der Optimierung stets ein problemspezifischer Versuch vorausgehen muss, der alle signifikanten Prozesszusammenhänge beschreibt. Bei vieldimensionalen Systemen ist das ein nicht unerheblicher Aufwand.

Mit den stochastischen Zufallsverfahren, beispielsweise den *Monte-Carlo-Methoden*, wird der Optimierungsraum durch eine stochastische Erregung mit Führungsgrößen-

²Insbesondere in langen Schluchten und Tälern in der Zielfunktion.

Vektoren untersucht³. Über entsprechende Varianzanalysen lassen sich Signifikanzen und stochastische Anteile im Prozessverhalten herausarbeiten und gesuchte Optima in Analogie zu den statistischen Prozessen abschätzen. Die experimentelle Systemidentifikation mit Parameterschätzverfahren lässt sich ebenfalls den stochastischen Verfahren zuordnen [21].

Ein modernes Monte-Carlo-Verfahren ist die Methode des Simulated Annealing. Prinzip dieses Verfahrens liegt in der mathematischen Analogie zu einem physikalischen Prozess, der Erstarrung von flüssigem Metall. Bekanntermaßen nimmt ein Partikel beim Erstarren in einer Schmelze zwar in einem kurzen Zeitraum zufällig den Zustand höherer potentieller Energie an. Je kälter die Schmelze wird, desto geringer wird jedoch auch die Chance für das Partikel, auf ein höheres Energieniveau zu springen. Nur wenn die Partikeltemperatur langsam gesenkt wird, endet der Energiezustand des Partikels im globalen Minimum. Im Kontext der Optimierung ist das Partikel ein Punkt im Optimierungsraum und seine potentielle Energie die Zielfunktion. Das Simulated-Annealing-Verfahren eignet sich somit zum Auffinden von globalen Minima in komplexen Prozessen mit mehreren lokalen Optima, [57].

Evolutionäre Algorithmen sind eine weitere Unterklasse der stochastischen Optimierungsverfahren und nutzen die aus der natürlichen Evolution bekannten Mechanismen. Die Vektoren im Parameterraum, also die Führungsgrößen-Vektoren, werden durch Individuen repräsentiert, die wiederum zu Populationen zusammengefasst werden, auf denen evolutionäre Operationen, wie Mutation, Selektion und Rekombination entsprechend einer zu definierenden Fitnessfunktion ausgeführt sind. Diese Funktion entspricht der Zielfunktion. Man unterscheidet prinzipiell genetische Algorithmen und Evolutionsstrategien, [5].

Die stochastischen Optimierungsverfahren haben geringere Anforderungen an die Zielfunktion, sind konvergenzsicher und können auch bei hochdimensionalen Aufgabenstellungen globale Optima auffinden. Allerdings ist die benötigte Versuchsanzahl auf Grund ihres nichtdeterministischen Vorgehens meist sehr groß, was sie für eine Online-Optimierung moderner Verbrennungsmotoren mit vielen Parametern nicht uneingeschränkt geeignet erscheinen lässt. In [74, 75, 76, 77] wurden evolutionäre Verfahren für die Motorprozessoptimierung angewendet und für ein 3-dimensionales Optimierungsproblem gute Ergebnisse erzielt.

Die heuristischen und damit auf Expertenwissen basierenden Optimierungsverfahren stellen eine vielversprechende Methodik zur vielparametrischen Online-Optimierung zur Verfügung. Hierbei werden bekannte prozesstechnische Zusammenhänge für die Formulierung des Optimierungsalgorithmus direkt genutzt. In Kapitel 7 wird ein wissensbasierter Ansatz mit Fuzzy-Interpreter vorgestellt und dessen Potential für die Online-Optimierung aufgezeigt. Nachteilig bei heuristischen Verfahren sind das erforderliche hohe Maß an a-priori-Wissen, welches zunächst für den Prozess erarbeitet werden muss, und die relative Unexaktheit bei der Formulierung des Optimums. Ist eine sehr präzise Bestimmung des Prozessoptimums notwendig, kann die Näherungslösung des heuristischen Algorithmus als Eingangsvektor für ein deterministi-

³Man erhält somit einen stochastischen Prozess.

ches Verfahren genutzt werden. Für Problemstellungen der Kennfeldoptimierung an Verbrennungsmotoren reicht die Genauigkeit der heuristischen Verfahren jedoch in der Regel aus.

6.2 Hill-Climbing-Verfahren

6.2.1 Prinzip

Hill-Climbing-Strategien, die speziell für mehrzielige Problemstellungen mit Nebenbedingungen im Laufe der letzten Jahrzehnte ständigen Verbesserungen unterzogen wurden, stellen sozusagen State-Of-The-Art-Werkzeuge für die Lösung mannigfaltiger technischer Optimierungsprobleme dar. Sie sollen deshalb als Basis für die Potentialabschätzung des in Kapitel 7 vorgestellten neuartigen wissensbasierten Optimierungsansatzes dienen. Auf die mathematischen Grundlagen, insbesondere die des SQP- und Goal-Attainment-Algorithmus, soll deshalb in den folgenden Abschnitten näher eingegangen werden.

Bei den deterministischen Optimierungsverfahren läuft die Ermittlung eines neuen, besseren Parametervektors $\mathbf{x}^{(i+1)}$ im Parameterraum zweistufig ab. Zunächst wird abhängig vom eingesetzten Algorithmus die Suchrichtung $\mathbf{v}^{(i)}$ ermittelt und dann mit einem zumeist linearen Liniensuchverfahren das Optimum entlang der Suchrichtung ermittelt. Nach [26] gilt für den unbeschränkten Fall folgender allgemeiner Iterationsansatz für das Liniensuchverfahren:

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \gamma^{(i)*} \mathbf{v}^{(i)} \quad (6.1)$$

mit

$$F(\mathbf{x}^{(i)} + \gamma^{(i)*} \mathbf{v}^{(i)}) = \mathbf{Min} \quad (6.2)$$

Zur Bestimmung des Optimums entlang der Suchrichtung werden lineare Suchmethoden (Fibonacci, Goldener Schnitt) oder interpolierende Polynomansätze verwendet. Folgende schnelle Interpolationsalgorithmen haben sich in Kombination mit den Algorithmen zur Bestimmung der Suchrichtung bewährt. Zur Unterscheidung zu den Hauptiterationsschritten $^{(i)}$ werden die Iterationen des Liniensuchverfahrens mit $_j$ bezeichnet. Falls nur eine Iteration notwendig ist (reine Interpolation, $j = 1$), wird γ^* direkt berechnet.

Quadratische Interpolation

Ausgehend von der quadratischen Gleichung

$$s_q(\gamma) = a\gamma^2 + b\gamma + c \quad (6.3)$$

gilt für die optimale Suchschrittweite γ^*

$$\gamma^* = \frac{-b}{2a}. \quad (6.4)$$

Die Funktionsparameter a und b können mit Kenntnis dreier Gradienten oder dreier Funktionswerte entlang der Suchgeraden gefunden werden. Betrachtet man den ein-dimensionalen Fall, gilt für ein Parametertripel $\{x_1, x_2, x_3\}$ mit den dazugehörigen Zielfunktionswerten $\{f(x_1), f(x_2), f(x_3)\}$, dass der entsprechend einer quadratischen Interpolation vermutete optimale Parameterwert bei

$$x^{(i+1)} = 1/2 \frac{\alpha_{23}f(x_1) + \alpha_{31}f(x_2) + \alpha_{12}f(x_3)}{\beta_{23}f(x_1) + \beta_{31}f(x_2) + \beta_{12}f(x_3)}. \quad (6.5)$$

liegt. Dabei gilt:

$$\begin{aligned} \alpha_{ij} &= x_i^2 - x_j^2 \\ \beta_{ij} &= x_i - x_j. \end{aligned}$$

Für x_1 wird in der Regel $x^{(i)}$ eingesetzt ($\gamma = 0$). Mit dem Initialschritt γ_0 kann dann $x_2 = x^{(i)} + \gamma_0 * \mathbf{v}$ bestimmt werden. Für x_3 ist ein geeigneter Zwischenpunkt zu wählen.

Kubische Interpolation

Das Verfahren der kubischen Interpolation ist hilfreich, wenn neben den reinen Zielfunktions-Werten auch Gradienteninformationen verfügbar sind, zumal dann nur die Information von zwei Parametervektoren benötigt werden. Aus dem Ansatz

$$s_c(\gamma) = a\gamma^3 + b\gamma^2 + c\gamma + d \quad (6.6)$$

folgt für die Bestimmung der lokalen Extrema

$$3a\gamma^{*2} + 2b\gamma^* + c = 0. \quad (6.7)$$

Mit **Gl. 6.1** folgt in Analogie zu **Gl. 6.5**:

$$x^{(i+1)} = x_2 - (x_2 - x_1) \frac{\nabla f(x_2) + \alpha_2 - \alpha_1}{\nabla f(x_2) + \nabla f(x_1) + 2\alpha_2}, \quad (6.8)$$

mit

$$\alpha_1 = \nabla F(x_1) + \nabla f(x_2) - 3 \frac{\nabla f(x_1) - f(x_2)}{x_1 - x_2}$$

$$\alpha_2 = (\alpha_1^2 - \nabla f(x_1) \nabla f(x_2))^{1/2}.$$

Dieses Verfahren wird in der Literatur auch als Hermite'sche Interpolation bezeichnet, [26].

Insbesondere bei stark nichtlinearen Zielfunktionen kann mit einer einzigen Interpolation das Minimum entlang der Suchgeraden meist nicht getroffen werden. Vielmehr müssen auch hier numerische Iterationsverfahren genutzt werden, die wiederum fall-spezifisch, ausgehend vom letzten Iterationsschritt der Liniensuche, \mathbf{x}_j , zum nächstbesseren Funktionswert \mathbf{x}_{j+1} gelangen. **Abb. 6.2** verdeutlicht grafisch die möglichen Fälle bei der kubischen Interpolation. Das nach k Iterationen gefundene optimale γ_k^* entspricht dann $\gamma^{(i)*}$ aus **Gl. 6.1**. Folgende Vereinbarungen sollen in **Abb. 6.2** gelten:

- Der linke Punkt in den einzelnen Graphen repräsentiert $\mathbf{x}^{(i)} = \mathbf{x}_0$.
- Der Gradient $\nabla F(\mathbf{x}_0)^T \mathbf{v}$ ist der Anstieg in diesem Punkt. Dieser ist stets negativ.
- Der rechte Punkt ist der Punkt \mathbf{x}_j , der nach einem Schritt $\gamma_j \mathbf{v}$ erreicht wurde (ausgenommen Fall 3).
- Der mittlere Punkt entspricht dem interpolierten Minimum bei einer Schrittweite von γ_{j+1} ausgehend von \mathbf{x}_0 .

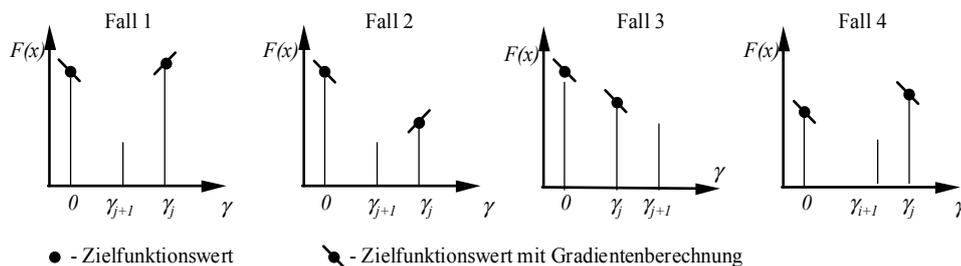


Abb. 6.2 Fallunterscheidung beim Liniensuchverfahren der kubischen Interpolation

Folgende Vorgehensweise bei der Liniensuche wurde für die im Rahmen dieser Arbeit verwendeten Hill-Climbing-Verfahren ausgewählt. Jedem Iterationsschritt $j + 1$ gehen eine Funktions- und eine Gradientenberechnung an der Position \mathbf{x}_j voraus. Da diese beiden Werte für den Startiterationsschritt $\mathbf{x}^{(i)} = \mathbf{x}_0$ ebenfalls bekannt sind,

kann je nach Auftreten der Fälle 1-4 eine neue Iterationsschrittweite γ_{j+1} berechnet werden, die zum Punkt

$$\mathbf{x}_{j+1} = \mathbf{x}^{(i)} + \gamma_{j+1} * \mathbf{v}^{(i)} \quad (6.9)$$

führt. Erfüllt dieser Punkt die Bedingung

$$\mathbf{x}_{j+1} < \mathbf{x}^{(i)}, \quad (6.10)$$

und gilt weiterhin $\mathbf{q}_j^T \mathbf{s}_j > 0^4$, so wird \mathbf{x}_{j+1} als neuer Ausgangspunkt $\mathbf{x}^{(i+1)}$ für ein Update der Suchrichtung \mathbf{v} betrachtet und ein neues Liniensuchverfahren initiiert. Gilt $\mathbf{q}_j^T \mathbf{s}_j \leq 0$, so wird die kubische Interpolation solange fortgesetzt, bis $\nabla F(\mathbf{x}_j)^T \mathbf{v}$ so klein wird, dass man ein positives $\mathbf{q}_j^T \mathbf{s}_j$ erhält. Dieser Fakt muss in den Fällen 2 und 3 beachtet werden.

Tab. 6.1 Mathematische Fallbehandlung bei der kubischen Liniensuche

	Beschreibung ^a	neuer Linien-Suchschritt	Update \mathbf{v}
Fall 1	$F(\mathbf{x}_j) > F(\mathbf{x}_0), \nabla F(\mathbf{x}_j)^T \mathbf{v} > 0$	$\gamma_{j+1} = \begin{cases} \gamma_c/2 & \text{für } \gamma_j < 0.1 \\ \gamma_c & \end{cases}$	
Fall 2	$F(\mathbf{x}_j) \leq F(\mathbf{x}_0), \nabla F(\mathbf{x}_j)^T \mathbf{v} \geq 0, \mathbf{q}_j^T \mathbf{s}_j \geq 0$		$\gamma_{j+1} = \min\{1, \gamma_c\}$
	$F(\mathbf{x}_j) \leq F(\mathbf{x}_0), \nabla F(\mathbf{x}_j)^T \mathbf{v} \leq 0, \mathbf{q}_j^T \mathbf{s}_j < 0$	$\gamma_{j+1} = 0.9\gamma_c$	
Fall 3	$F(\mathbf{x}_j) < F(\mathbf{x}_0), \nabla F(\mathbf{x}_j)^T \mathbf{v} < 0, \mathbf{q}_j^T \mathbf{s}_j \geq 0$		$\gamma_{j+1} = \min\{2, p, 1.2\gamma_c\}^b$
	$F(\mathbf{x}_j) < F(\mathbf{x}_0), \nabla F(\mathbf{x}_j)^T \mathbf{v} < 0, \mathbf{q}_j^T \mathbf{s}_j < 0$	$\gamma_{j+1} = \min\{2, \max\{1.5, \gamma_j\}, \gamma_c\}$	
Fall 4	$F(\mathbf{x}_j) \geq F(\mathbf{x}_0), \nabla F(\mathbf{x}_j)^T \mathbf{v} \leq 0, \mathbf{q}_j^T \mathbf{s}_j \geq 0$		$\gamma_{j+1} = \min\{\gamma_c, \gamma_j/2\}$

$$^a \mathbf{s}_j = \mathbf{x}_j - \mathbf{x}_0, \mathbf{q}_j = \nabla F(\mathbf{x}_j) - \nabla F(\mathbf{x}_0)$$

$$^b p = 1 + \mathbf{q}_j^T \mathbf{s}_j - \nabla F(\mathbf{x}_j)^T \mathbf{v} + \min\{0, \gamma_j\}$$

Für den Fall, dass eine kubische Interpolation einen Wert $\gamma_c < 0$ liefert, wird die neue Schrittweite γ_{j+1} auf den Wert $2\gamma_j$ gesetzt. Verschiedene Untersuchungen zur Robustheit des Algorithmus haben gezeigt, dass auch mit negativen Schritten unter Umständen eine Reduktion von $F(\mathbf{x})$ möglich ist. Angewendet wird dieses

⁴Die Notwendigkeit dieser Bedingung wird bei der Beschreibung der Quasi-Newton-Verfahren deutlich.

Verfahren, indem bei Unterschreiten einer Schwelle für γ_j^5 die Funktionszuweisung

$$\gamma_{j+1} = -\gamma_j/2 \quad (6.11)$$

durchgeführt wird. Damit kann auch bei Fehlen der exakten analytischen Ableitung eine hohe Genauigkeit des Iterationsalgorithmus gewährleistet werden [95].

Gemischte Quadratisch/Kubische Interpolation

Wie bereits erwähnt, werden für die Hermite'sche Interpolation genau 4 Funktionswerte oder entsprechende Gradienten in beliebiger Kombination benötigt. Wegen seiner Allgemeingültigkeit ist dieses Verfahren dem der quadratischen Interpolation prinzipiell vorzuziehen. Zu Beginn des Liniensuchverfahrens stehen jedoch noch nicht genügend Informationen für dieses Verfahren zur Verfügung, die das Optimum sinnvoll eingrenzen lassen. Darüber hinaus bedeutet die numerische Berechnung von Gradienten immer den Verbrauch von Rechenzeit. Deshalb wird bei modernen Optimierungsverfahren eine Kombination aus quadratischer und kubischer Interpolation angewendet. **Abb. 6.3** zeigt die zu unterscheidenden Fälle. Dabei ist in Analogie zu **Abb. 6.2** der linke Punkt charakterisiert durch den Funktionswert $F(\mathbf{x}^{(i)}) = F(\mathbf{x}_0)$ und den Gradienten $\nabla F(\mathbf{x}^{(i)}) = \nabla F(\mathbf{x}_0)$ vom vergangenen Update des Suchvektors \mathbf{v} . Alle anderen Punkte repräsentieren Iterationsschritte j des Liniensuchverfahrens.

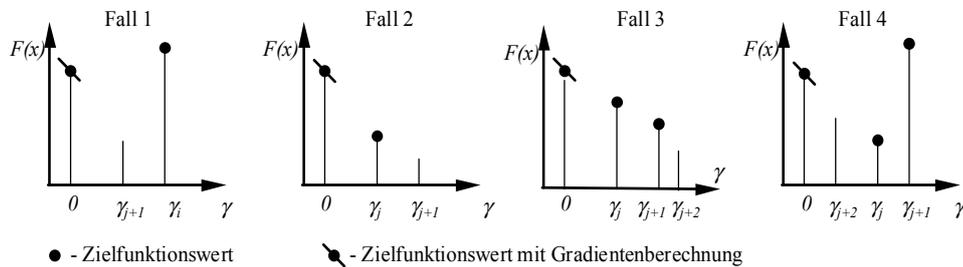


Abb. 6.3 Fallunterscheidung beim Liniensuchverfahren der gemischten Interpolation

γ_q und γ_c entsprechen der optimalen Schrittweite nach quadratischer bzw. kubischer Interpolation/Extrapolation. Die Fälle 1 und 2 benutzen die quadratische Interpolation mit zwei Funktionswerten und einem Gradienten, um einen dritten Punkt zu ermitteln, der das Optimum einschließt. Misslingt dieser Versuch, wird entsprechend Fall 3 und 4 versucht, die Schrittweite γ sukzessive so lange zu verändern, bis eine kubische Interpolation zu einem $F(\mathbf{x}_{j+k})$ führt, das **Gl. 6.11** genügt. Gelingt auch das nicht, wird ein Update von \mathbf{v} an demjenigen Punkt ausgeführt, der als derjenige mit dem niedrigsten Funktionswert zur vorangegangenen kubischen Interpolation herangezogen wurde. Neben den fallspezifischen Iterationsregeln nach **Tab. 6.2** gel-

⁵üblicherweise liegt diese Schwelle bei 10^{-8}

ten für eine weitere Reduzierung der Schrittweite bzw. zum Update der Suchrichtung die Richtlinien entsprechend **Tab. 6.1**.

Tab. 6.2 Mathematische Fallbehandlung bei der gemischten Liniensuche

	Beschreibung	neuer Linien-Suchschritt mit \mathbf{v}
Fall 1	$F(\mathbf{x}_j) \geq F(\mathbf{x}_0)$	$\gamma_{j+1} = \gamma_q$
Fall 2	$F(\mathbf{x}_j) < F(\mathbf{x}_0)$	$\gamma_{j+1} = 1.2\gamma_q$
Fall 3	$F(\mathbf{x}_{j+1}) < F(\mathbf{x}_0)$	$\gamma_{j+2} = \max\{1.2\gamma_q, 2\gamma_{j+1}\}$
Fall 4	$F(\mathbf{x}_{j+1}) > F(\mathbf{x}_0)$	$\gamma_{j+1} = \gamma_c$

Je nach verwendetem Hill-Climbing-Verfahren werden unterschiedliche Methoden zum Update der Suchrichtung verwendet. Die einfachste Suchmethode ist die der sukzessiven Variation der Variablen. Aufbauend auf diesem Verfahren soll die Newton-Raphson-Methode als Vertreter der Newton-Verfahren und abschließend das am weitesten entwickelte Gradientenverfahren nach der Methode des sequentiellen quadratischen Programmierens behandelt werden.

6.2.2 Gradientenfreie und einfache gradientenbasierte Verfahren

Bekanntester Vertreter dieser Gruppe ist das *Verfahren der sukzessiven Variation der Variablen*, auch als *Koordinatenstrategie* bezeichnet. Hierbei werden die Führungsgrößen des Prozesses (Variablen) x_1, x_2, \dots, x_n der Reihe nach einzeln so lange verändert, bis jeweils das Minimum (Maximum) der Zielfunktion gefunden ist. Die Suchrichtung $\mathbf{v}^{(i)}$ stimmt dabei mit den Einheitsvektoren $\mathbf{e}^{(i)}$ des von den Führungsgrößen aufgespannten Koordinatensystems überein. Sind alle Koordinatenrichtungen einmal abgesucht, wird die Suchrichtung wieder auf den ersten Einheitsvektor gesetzt und so weiter. Die Beschreibungsgleichung für einen Optimierungsschritt lautet damit

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \gamma^{(i)*} * \mathbf{e}^{(i)}. \quad (6.12)$$

Ausgehend von einem beliebigen Startpunkt $\mathbf{x}^{(1)}$ wird der Iterationszyklus solange fortgesetzt, bis ein bestimmtes Abbruchkriterium erfüllt ist. Mit Ausnahme der Hermite'schen Interpolation können für die Liniensuche die in Abschnitt 6.1 genannten Such- und Optimierungsverfahren angewendet werden⁶.

⁶Die Hermite'sche Interpolation ist ungeeignet, da diese Ableitungen der Zielfunktion benötigt, deren Berechnung für das eigentliche Optimierungsverfahren nicht erforderlich ist.

Nachteilig bei der Methode der sukzessiven Variation der Variablen ist, dass die Suchrichtungen durch die Wahl des Koordinatensystems festgelegt sind. Mit der *Methode des steilsten Abstiegs* wird dieses Problem umgangen. Als Suchrichtung wird hier jeweils die dem Gradienten $\nabla F(\mathbf{x}^{(i)})$ entgegengesetzte Richtung verwendet. **Gl. 6.1** wird dann zu

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} - \gamma^{(i)*} * \nabla F(\mathbf{x}^{(i)}) \quad (6.13)$$

In **Abb. 6.4** sind für ein zweidimensionales Optimierungsproblem exemplarisch jeweils ein Optimierungslauf mit der Methode der sukzessiven Variation der Variablen und dem Verfahren des steilsten Abstiegs dargestellt. Bei beiden Methoden bilden zwei aufeinander folgende Suchrichtungen stets ein orthogonales System, was der Grund für die relativ große Anzahl benötigter Iterationen insbesondere bei sehr flachen Zielfunktionen ist.

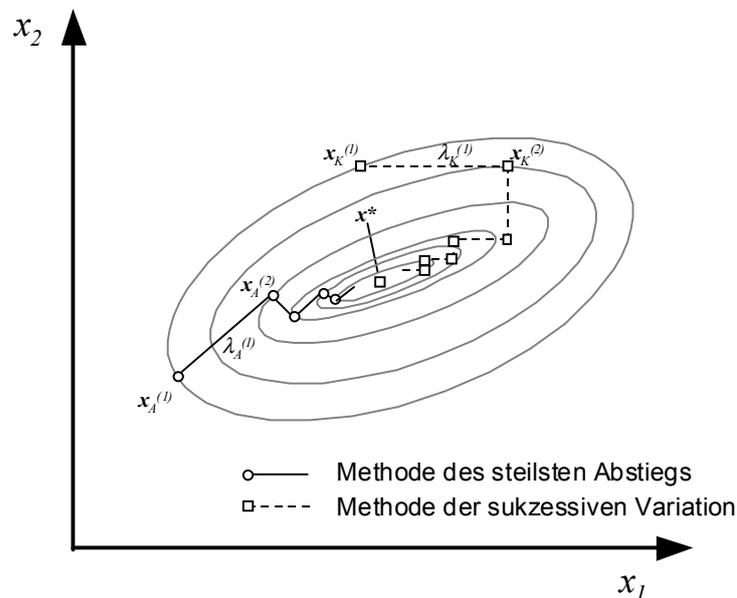


Abb. 6.4 Vergleich der Suchverfahren *Sukzessive Variation der Variablen* (Koordinatenstrategie, K) und *Methode des steilsten Abstiegs*, A für ein 2-dimensionales Optimierungsproblem ohne Beschränkungen

Durch weitere Verbesserungen der Update-Methoden für die Suchrichtung gelang es, mit recht einfachen Mitteln leistungsfähige Suchstrategien zu entwickeln. Dazu zählen die *Methode der konjugierten Gradienten*, die *Methode nach Rosenbrock*, die *Methode nach Hooke-Jeeves* und das *Powell-Verfahren* (vgl. hierzu [26]).

6.2.3 Newton- und Quasi-Newton-Verfahren

Newton- und Quasi-Newton-Methoden beruhen auf dem Prinzip, bei jeder Hauptiteration eine quadratische Näherung des tatsächlichen Verlaufs der Zielfunktion auf ihr

Minimum hin zu untersuchen. Wie in Kapitel 5 gezeigt wurde, lassen sich verbrennungsmotorische Zusammenhänge sehr gut mittels quadratischer Polynomansätze approximieren, sodass sich die Newton-Verfahren für die hier untersuchten Optimierungsprobleme besonders eignen. Es wird folgendes quadratisches Optimierungsproblem formuliert:

$$\min_{\mathbf{x} \in \mathfrak{R}^n} \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x} + \mathbf{c}^T \mathbf{x} + b. \quad (6.14)$$

Dabei sind \mathbf{H} die stets positive definite und symmetrische Hesse-Matrix, \mathbf{c} ein konstanter Vektor und b eine Konstante. Bestimmt man die erste Ableitung dieser Gleichung, folgt für den optimalen Führungsgrößenvektor \mathbf{x}^* des Hauptiterationsschrittes ⁽ⁱ⁾

$$\nabla F(\mathbf{x}^*) = \mathbf{H} \mathbf{x}^* + \mathbf{c} = 0 \quad (6.15)$$

woraus

$$\mathbf{x}^* = -\mathbf{H}^{-1} \mathbf{c} \quad (6.16)$$

abgeleitet werden kann.

Im Gegensatz zu Quasi-Newton-Methoden wird zum Beispiel beim Newton-Raphson-Verfahren die Hesse-Matrix direkt berechnet. Es muss demnach nur der unbekannte Vektor \mathbf{c} mit Hilfe eines Liniensuchverfahrens bestimmt werden.

Quasi-Newton-Methoden vermeiden die numerische Berechnung von Gradienten und die rechenintensive Invertierung der Hesse-Matrix, indem sie \mathbf{H} auf Basis der Hesse-Matrix des letzten Iterationsschrittes approximieren. Aus den verschiedenen bekannten Update-Methoden für die Hesse-Matrizen hat sich das Verfahren nach Broyden, Fletcher, Goldfarb und Shannon (BFGS-Methode)⁷ als praktikabelstes herauskristallisiert. Die Update-Formel lautet

$$\mathbf{H}^{(i+1)} = \mathbf{H}^{(i)} + \frac{\mathbf{q}^{(i)} \mathbf{q}^{(i)T}}{\mathbf{q}^{(i)T} \mathbf{s}^{(i)}} - \frac{\mathbf{H}^{(i)T} \mathbf{s}^{(i)T} \mathbf{s}^{(i)} \mathbf{H}^{(i)}}{\mathbf{s}^{(i)T} \mathbf{H}^{(i)} \mathbf{s}^{(i)}}, \quad (6.17)$$

mit

$$\begin{aligned} \mathbf{s}^{(i)} &= \mathbf{x}^{(i+1)} - \mathbf{x}^{(i)} \\ \mathbf{q}^{(i)} &= \nabla F(\mathbf{x}^{(i+1)}) - \nabla F(\mathbf{x}^{(i)}). \end{aligned}$$

Der Algorithmus basiert auf der Annahme, dass für jede quadratische Zielfunktion ein Optimum von \mathbf{H} und damit ein Optimum innerhalb des aktuellen Hauptiterationsschrittes (**Gl. 6.16**) mit einer begrenzten Anzahl von linearen Suchschritten

⁷ auch Fletcher-Powell-Verfahren

bestimmbar ist. Dazu werden so genannte A-konjugierte Suchrichtungen, ähnlich den konjugierenden Gradientenverfahren aufgebaut, [26].

Als Startmatrix \mathbf{H}_0 kann prinzipiell jede positiv finite Matrix gewählt werden, vorzugsweise die Einheitsmatrix \mathbf{I} . Für die Approximation der inversen Hesse-Matrix sind ebenfalls Näherungsverfahren, wie das nach Davidson, Powell und Fletcher, [20], bekannt. Nach jeder Hauptiteration wird beim Quasi-Newton-Verfahren ein Liniensuchalgorithmus entlang der Suchrichtung

$$\mathbf{v}^{(i)} = -\mathbf{H}^{(i)-1}\nabla F(\mathbf{x}^{(i)}) \quad (6.18)$$

durchgeführt. Zum Einsatz kommt hier das gemischte quadratisch/kubische Interpolationsverfahren entsprechend Abschnitt 6.2.2. Um zu gewährleisten, dass die Suchrichtung \mathbf{v} immer in absteigender Richtung verläuft, muss \mathbf{H} nach jedem Update positiv definit sein. Das wird dadurch erreicht, dass \mathbf{H} zunächst positiv definit initialisiert wird und sodann der Term $\mathbf{q}^{(i)T}\mathbf{s}^{(i)}$ immer positiv bleibt. Durch Umstellen von **Gl. 6.18** erhält man mit Hilfe von **Gl. 6.1**

$$\mathbf{q}^{(i)T}\mathbf{s}^{(i)} = \gamma^{(i)}(\nabla F(\mathbf{x}^{(i+1)})^T\mathbf{v}^{(i)} - \nabla F(\mathbf{x}^{(i)})^T\mathbf{v}^{(i)}) \quad (6.19)$$

Es kann immer ein positiver Term $\mathbf{q}^{(i)T}\mathbf{s}^{(i)}$ garantiert werden, wenn nur die Schrittweite $\gamma^{(i)}$ klein genug gewählt wird, sodass $-\nabla F(\mathbf{x}^{(i+1)})^T\mathbf{v}^{(i)} < -\nabla F(\mathbf{x}^{(i)})^T\mathbf{v}^{(i)}$. Da $-\nabla F(\mathbf{x}^{(i)})^T\mathbf{v}^{(i)}$ und $\gamma^{(i)}$ stets positiv sind, folgt dann auch für den gesamten Term ein positives Ergebnis.

6.2.4 Lösung von Problemen mit Nebenbedingungen durch SQP

Bisher wurden nur Optimierungsmethoden für Probleme ohne Nebenbedingungen untersucht, wobei herausgestellt wurde, dass Quasi-Newton-Verfahren den günstigsten Kompromiss aus benötigter Rechenzeit und Qualität der Optimierung darstellen.

Die erste und einfachste Möglichkeit der Berücksichtigung von Nebenbedingungen besteht darin, die unbeschränkte Zielfunktion $\mathbf{F}(\mathbf{x})$ durch die in Abschnitt 4.4, **Gl. 4.6**, dargestellte Lagrange'sche Zielfunktion zu ersetzen und mit den beschriebenen Hill-Climbing-Verfahren zu optimieren. Die Lagrange-Terme werden dann auch als so genannte Straf-Terme bezeichnet, [5].

Ein effizienterer Lösungsansatz wird durch direkte Lösung der so genannten Kuhn-Tucker-Gleichungen erzielt. Auf Basis der allgemeingültigen Darstellung des Optimierungsproblems nach **Gl. 4.1** auf Seite 23 kann folgender Lagrange-Ansatz formuliert werden, der auch als Kuhn-Tucker-Ansatz bezeichnet wird, [95].

$$\begin{aligned}
\nabla F(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* \nabla G_i(\mathbf{x}^*) &= 0 \\
\nabla G_i(\mathbf{x}) &= 0 \quad i = 1, \dots, m_e \\
\lambda_i^* &\leq 0 \quad i = m_e + 1, \dots, m
\end{aligned} \tag{6.20}$$

Die erste Gleichung beschreibt den Ausgleich der Gradienten im Optimalpunkt. Dazu müssen die Lagrange-Faktoren λ_i vom Optimierungsalgorithmus geschätzt werden. Die beiden unteren Gleichungen drücken aus, dass für inaktive Nebenbedingungen die Lagrange-Faktoren verschwinden müssen. Sind sowohl $F(\mathbf{x})$ als auch die Nebenbedingungen $G_i(\mathbf{x})$ konvexe Funktionen - das ist bei den hier betrachteten Problemen der Fall -, so ist dieses Gleichungssystem notwendige und hinreichende Bedingung für die Existenz eines globalen Optimums. Der Einsatz von Quasi-Newton-Methoden zur Lösung dieses Problems garantiert lineare Konvergenz und wird als *Sequentielles Quadratisches Programmieren*, (SQP) bezeichnet, da in jeder Hauptiteration ein QP-Subproblem zu lösen ist.

Das quadratische Subproblem wird ausgehend von **Gl. 6.20** und **Gl. 6.14** wie folgt definiert.

$$\begin{aligned}
\min_{\mathbf{v} \in \mathfrak{R}^n} \quad & \frac{1}{2} \mathbf{v}^T \mathbf{H}^{(i)} \mathbf{v} + \nabla F(\mathbf{x}^{(i)})^T \mathbf{v} \\
\nabla G_i(\mathbf{x}^{(i)})^T \mathbf{v} + G_i(\mathbf{x}^{(i)}) &= 0 \quad i = 1, \dots, m_e \\
\nabla G_i(\mathbf{x}^{(i)})^T \mathbf{v} + G_i(\mathbf{x}^{(i)}) &\leq 0 \quad i = m_e + 1, \dots, m
\end{aligned} \tag{6.21}$$

Ein neues Iterations-Zwischenergebnis kann dann über

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \gamma^{(i)} \mathbf{v}^{(i)} \tag{6.22}$$

gebildet werden, wobei zur Bestimmung von $\gamma^{(i)}$ die bereits beschriebene gemischte Liniensuch-Strategie herangezogen wird. Für die im Rahmen dieser Arbeit angestellten Untersuchungen diente ein SQP-Verfahren als Basis, dessen Hauptiterationen in den drei Schritten

- Update der Hesse-Matrix $\mathbf{H}^{(i)}$,
- Finden einer lokalen QP-Lösung $\mathbf{v}^{(i)}$ und
- Liniensuche zur Bestimmung eines optimalen $\gamma^{(i)}$

ablaufen. Diese Schritte sind im Folgenden näher erläutert.

Update der Hesse-Matrix

Mit den geschätzten Lagrange-Faktoren der letzten Iterationsstufe wird ein auf der BFGS-Methode (Gl. 6.17) basierendes Update der Hesse-Matrix durchgeführt:

$$\begin{aligned} \mathbf{H}^{(i+1)} &= \mathbf{H}^{(i)} + \frac{\mathbf{q}^{(i)}\mathbf{q}^{(i)T}}{\mathbf{q}^{(i)\mathbf{s}^{(i)}}} - \frac{\mathbf{H}^{(i)T}\mathbf{H}^{(i)}}{\mathbf{s}^{(i)T}\mathbf{H}^{(i)}\mathbf{s}^{(i)}} \\ \mathbf{s}^{(i)} &= \mathbf{x}^{(i+1)} - \mathbf{x}^{(i)} \\ \mathbf{q}^{(i)} &= \nabla F(\mathbf{x}^{(i+1)}) + \sum_{j=1}^n \lambda_j \nabla G_j(\mathbf{x}^{(i+1)}) - \nabla \left(F(\mathbf{x}^{(i)}) + \sum_{j=1}^n \lambda_j \nabla G_j(\mathbf{x}^{(i)}) \right) \end{aligned} \quad (6.23)$$

Sollte ein negativer Term $\mathbf{s}^{(i)T}\mathbf{q}^{(i)}$ auftreten, wird der Vektor $\mathbf{q}^{(i)}$ solange entsprechend einer Element-für-Element-Methode verändert, bis ein positiver Wert erreicht werden kann. Das geschieht in einem zweistufigen Verfahren. Zunächst wird das kleinste Element des Vektors solange halbiert, bis der Term $\mathbf{s}^{(i)T}\mathbf{q}^{(i)}$ größer oder gleich 10^{-5} wird. Gelingt das nicht, wird in einem zweiten Schritt folgende Modifikation des Vektors $\mathbf{q}^{(i)}$ vorgenommen.

$$\mathbf{q}^{(i)} = \mathbf{q}^{(i)} + u\mathbf{w} \quad (6.24)$$

wobei gilt

$$w_j = \nabla G_j(\mathbf{x}^{(i+1)})G_j(\mathbf{x}^{(i+1)}) - \nabla G_j(\mathbf{x}^{(i)})G_j(\mathbf{x}^{(i+1)}) \quad \text{für} \\ q_j^{(i)}u < 0 \quad \text{und} \quad q_j^{(i)}s_j^{(i)} < 0, \quad (j = 1, \dots, m)$$

$$w_j = 0, \quad \text{für alle anderen Fälle.} \quad (6.25)$$

j wird sukzessive erhöht, bis das Ziel $\mathbf{s}^{(i)T}\mathbf{q}^{(i)} > 0$ erreicht ist. Normalerweise reicht der Ansatz der ersten Modifizierungsstufe für die hier behandelten Probleme aus. Stufe 2 muss nur bei stark nichtlinearen Problemen, insbesondere bei stark nichtlinearen Nebenbedingungen angewendet werden.

Lösung des QP-Problems

Nachdem die Hesse-Matrix erfolgreich modifiziert wurde, kann das eigentliche lokale QP-Problem gelöst werden. Mit der $m \times n$ -Matrix \mathbf{A}^8 folgt aus Gl. 6.21

⁸ \mathbf{A}_i bezieht sich auf die i -te Reihe der Matrix \mathbf{A}

$$\begin{aligned}
\min_{\mathbf{v} \in \mathfrak{R}^n} \quad & \frac{1}{2} \mathbf{v}^T \mathbf{H} \mathbf{v} + \nabla F(\mathbf{X})^T \mathbf{v} \\
& \mathbf{A}_i^T \mathbf{v} = b_i \quad i = 1, \dots, m_e \\
& \mathbf{A}_i^T \mathbf{v} \leq b_i \quad i = m_e + 1, \dots, m
\end{aligned} \tag{6.26}$$

Nach Gill, [22], wird wiederum eine zweistufige Prozedur zur Lösung des QP-Problems (**Gl. 6.26**) herangezogen. Basis für die Bestimmung einer gültigen Suchrichtung $\tilde{\mathbf{v}}^9$ ist die Matrix $\tilde{\mathbf{A}}$, die diejenigen Randbedingungen enthält, die gerade aktiv sind, d. h., die den Suchraum im aktuellen Haupt-Iterationsschritt begrenzen. Das Verfahren wird deshalb auch als Active-Set-Verfahren bezeichnet.

Der mögliche Unterraum, in dem $\tilde{\mathbf{v}}$ liegen kann, ohne die aktiven Grenzen zu verletzen, wird durch die Basis \mathbf{Z} aufgespannt, deren Spalten orthogonal auf den Richtungsvektoren der aktiven Randbedingungen, also den Reihen j in $\tilde{\mathbf{A}}$ stehen¹⁰. Daraus folgt, dass eine Suchrichtung, die eine Linearkombination der Spalten von \mathbf{Z} darstellt, die Bedingung nach einer Einhaltung der aktiven Grenzen erfüllt. \mathbf{Z} beinhaltet nur die Spalten, die zu noch nicht aktiven Randbedingungen gehören. Damit wird sichergestellt, dass bereits erreichte Grenzen zunächst nicht wieder verlassen werden.

Eine neue zulässige Suchrichtung stellt nun eine beliebige Linearkombination aus den Spalten von \mathbf{Z} dar, also

$$\tilde{\mathbf{v}} = \mathbf{Z} \mathbf{p}, \tag{6.27}$$

für einen beliebigen Vektor \mathbf{p} . Setzt man diesen Zusammenhang in die zu minimierende Zielfunktion des QP-Subproblems (**Gl. 6.26**) ein und differenziert diese nach \mathbf{p} , so ergibt sich für den optimalen Vektor \mathbf{p}^*

$$\mathbf{Z}^T \mathbf{H} \mathbf{Z} \mathbf{p}^* = -\mathbf{Z}^T \nabla F(\mathbf{x}). \tag{6.28}$$

Mit **Gl. 6.27** ist nun die Berechnung der vorerst optimalen Suchrichtung $\tilde{\mathbf{v}}^*$ möglich. $\tilde{\mathbf{v}}^*$ muss in einer zweiten Phase auf seine Eignung für das sich anschließende Liniensuchverfahren geprüft werden. Falls Nebenbedingungen verletzt werden, ist eine neue Iteration zur Bestimmung von $\tilde{\mathbf{v}}^*$ mit einer modifizierten Matrix $\tilde{\mathbf{A}}$ durchzuführen.

Dazu wird ein Suchschritt der Form

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \gamma^{(i)} \tilde{\mathbf{v}}^* \tag{6.29}$$

⁹Zur Unterscheidung von der Suchrichtung \mathbf{v} , die das Ergebnis des QP-Subproblems ist, wurden die Zwischenergebnisse innerhalb des QP-Algorithmus mit $\tilde{\mathbf{v}}$ bezeichnet.

¹⁰In diesem Fall gilt, dass $\tilde{\mathbf{A}} \mathbf{Z}$ eine $n \times n$ -Matrix ist, deren Elemente über der Diagonalen verschwinden, also $\tilde{\mathbf{A}} \mathbf{Z} = \begin{bmatrix} 0 \\ R \end{bmatrix}$. Das wird durch einen speziellen Algorithmus zur orthogonalen Dreiecks-Dekomposition erreicht, [95], der hier nicht näher erläutert werden soll.

mit $\gamma^{(i)} = 1$. durchgeführt. Sind alle Nebenbedingungen erfüllt, so ist die Lösung $\tilde{\mathbf{v}}^*$ des QP-Problems der Suchvektor für das Liniensuchverfahren \mathbf{v} . Wird eine Nebenbedingung bei diesem Schritt verletzt, so ist schrittweise die zuerst verletzte Nebenbedingung in die Active-Set-Matrix $\tilde{\mathbf{A}}$ aufzunehmen und eine neue Lösung des QP-Problems entsprechend **Gl. 6.26-6.29** zu bilden. Für den Fall, dass alle Nebenbedingungen aktiv werden, wird der Lagrange-Vektor λ in der Art geschätzt, dass

$$\tilde{\mathbf{A}}^T \lambda = \nabla F(\mathbf{x}^{(i)}) \quad (6.30)$$

erfüllt ist¹¹.

Liniensuche

Um alle Nebenbedingungen bei der Liniensuche berücksichtigen zu können, wird eine modifizierte Zielfunktion Ψ als Ersatz im Optimierungsgesetz nach **Gl. 6.1** angesetzt:

$$\Psi(\mathbf{x}) = F(\mathbf{x}) + \sum_{j=1}^{m_e} r_j G_j(\mathbf{x}) + \sum_{j=m_e+1}^m r_j \max\{0, G_j(\mathbf{x})\}, \quad (6.31)$$

Für die Straf-Faktoren r_j gilt das Iterationsgesetz

$$r_j = r_j^{(i+1)} = \max_j \left\{ \lambda_j, \frac{1}{2}(r_j^{(i)} + \lambda_j) \right\}, \quad j = 1, \dots, m. \quad (6.32)$$

Damit werden auch die im letzten Iterationsschritt noch aktiven Randbedingungen berücksichtigt. Eine Initialisierung der Straf-Faktoren erfolgt über

$$r_j = \frac{\|\nabla F(\mathbf{x})\|}{\|\nabla G_j(\mathbf{x})\|}. \quad (6.33)$$

¹¹Sind alle Elemente in λ positiv, so ist $\tilde{\mathbf{v}}^*$ die optimale Lösung des folgenden QP-Problems, andernfalls werden die negativen Elemente in λ gelöscht und eine neue QP-Iteration gestartet.

6.3 Die Goal-Attainment-Methode zur multikriteriellen Optimierung

Beim Goal-Attainment-Verfahren werden sowohl für die eigentlich zu minimierende skalare Zielfunktion $F(\mathbf{x})$ als auch für die Nebenbedingungen $G_j(\mathbf{x})$ ¹² Zielwerte (Goals) definiert, die im Zielwertvektor

$$\mathbf{F}^* = \{F_1^*, F_2^*, \dots, F_m^*\}$$

zusammengefasst werden. Analog dazu wird ein Zielfunktionsvektor

$$\mathbf{F}(\mathbf{x}) = \{F_1(\mathbf{x}), F_2(\mathbf{x}), \dots, F_m(\mathbf{x})\}$$

definiert. Die Optimierungsaufgabe beschreibt dann **Gl. 6.34**.

$$\begin{aligned} \min_{\lambda \in \mathfrak{R}, \mathbf{x} \in \Omega} \quad & \lambda, \text{ sodass gilt} \\ F_j(\mathbf{x}) - w_j \lambda & \leq F_j^*, \quad j = 1, \dots, m. \end{aligned} \quad (6.34)$$

Über den Wichtungsvektor \mathbf{w} können die einzelnen Ziele unterschiedlich gewichtet werden. Eine intuitive Umsetzung der Optimierungsaufgabe wird damit ermöglicht. Die mathematische Definition eines Gleichungssystems, bestehend aus Zielfunktion und Nebenbedingungen, kann entfallen. Gilt $\mathbf{w} = 0$, so wird versucht, alle Ziele exakt einzuhalten. Wie der Ziel- und der Wichtungsvektor konkret für die Optimierung des dieselmotorischen Prozesses belegt werden müssen, ist im nächsten Kapitel beschrieben.

Zur mathematischen Lösung des Goal-Attainment-Problems kommt ebenfalls der im vorangegangenen Abschnitt vorgestellten SQP-Algorithmus zum Einsatz. In Anlehnung an die Lösung so genannter Minimax-Probleme mit SQP soll als Zielfunktion für die Liniensuche folgender Ausdruck gewählt werden.

$$\Psi = \sum_{j=1}^m \begin{cases} r_j \max\{0, F_j(\mathbf{x}) - w_j \lambda - F_j^*\} & \text{für } w_i = 0 \\ \max_j \Lambda_j, & i = 1, \dots, m \text{ alle anderen Fälle} \end{cases} \quad (6.35)$$

Dabei gelten

$$\Lambda_j = \frac{F_j(\mathbf{x}) - F_j^*}{w_j} \quad (6.36)$$

¹²Im Sinne einer einheitlichen Darstellung werden beim Goal-Attainment-Verfahren auch die Nebenbedingungen $G_j(\mathbf{x})$ als skalare Zielgrößen $F_j(\mathbf{x})$ definiert.

und **Gl. 6.32** zur Berechnung der Straf-Terme. Das Update der Hesse-Matrix und die Lösung des QP-Subproblems erfolgt nach der in Abschnitt 6.2.3 beschriebenen Vorgehensweise.

6.4 Methoden zur Optimierung dynamischer Prozessverläufe

Vier prinzipiell unterschiedliche Ansätze werden in der Literatur zur numerischen Optimierung von dynamischen Prozessen bzw. Kurvenverläufen genannt.

1. **Analytische Verfahren (Variationsrechnung, Maximumprinzip von Pontryagin, Hamilton'sche Methode), [34]**

Diese Verfahren liefern allgemeingültige Lösungen und stellen geringe Anforderungen an die Rechnerleistung. Allerdings muss eine analytische Lösung des Problems vorausgehen, was zum Teil einen hohen mathematischen Aufwand bedeutet und für die hier betrachteten Probleme kaum möglich ist.

2. **Dynamische Programmierung, [26]**

Dieses Verfahren arbeitet iterativ, indem in einer Stufenstruktur die Änderungen in Vorgängerstufen bei der Optimierung der Nachfolgerstufen berücksichtigt werden. Diese Klasse von Optimierungsmethoden setzt eine Stufenstruktur des Problems voraus, die eher bei Entscheidungsprozessen als bei kontinuierlichen technischen Problemen gegeben ist.

3. **Optimale Funktions-Parametrisierung, [57]**

Diese Methodenklasse optimiert die Parameter einer gegebenen Systemübertragungsfunktion, deren Struktur bekannt sein und mit dem tatsächlichen Systemverhalten abgeglichen werden muss. Als Zielfunktion dient in der Regel ein gegebenes Gütefunktional, welches die kumulierte Differenz zwischen Ist- und Sollwertverlauf beschreibt. Die Least-Square-Methoden der experimentellen Systemanalyse im Zusammenhang mit einer Systemanregung durch PRBS- bzw. APRBS-Signale, [87, 88], sind praktische Anwendungsfälle der Funktions-Parametrisierung, die spezielle Formen der beschriebenen SQP-Algorithmen darstellen. Nachteilig ist hierbei, dass eine Funktionsstruktur (Übertragungsverhalten) bekannt sein muss.

4. **Dynamische Kennfeldoptimierung, [55, 78]**

Ebenfalls mit SQP-Algorithmen werden bei dieser Vorgehensweise anstatt der Parameter einer Übertragungsfunktion die Kennfeldstützstellen von Steuerkennfeldern, die das Systemverhalten beschreiben, optimiert. Als Zielfunktion ist ein entsprechendes Gütefunktional zu generieren, welches die erzielte kumulierte Prozess-Performance beschreibt. Ansätze dafür wurden in Kapitel 4 gegeben. Da die Anzahl der zu optimierenden Kennfeldstützstellen höher ist als die Parameteranzahl in vergleichbaren Übertragungsfunktionen, ist diese

Methode zwar universeller, stellt aber auch höhere Ansprüche an die Rechen-
technik als die Methodenklasse 3.

6.5 Anwendung der Hill-Climbing-Verfahren zur stationären Optimierung

Zur Optimierung des dieselmotorischen Gesamtprozesses unter stationären Gesichtspunkten wurden die in **Tab. 6.3** zusammengefassten Verfahren ausgewählt. Diese sollen als Basis für die Untersuchung der Leistungsfähigkeit des in Kapitel 7 vorgestellten Fuzzy-Algorithmus dienen. Auf Grund der hohen Anforderungen des nicht-linearen vielparametrischen Optimierungsproblems an den zu selektierenden Algorithmus kamen nur SQP-Verfahren in Frage.

Tab. 6.3 Auswahl geeigneter Optimierungsverfahren

Aufgabe (nach Tab. 4.3)	Verfahren	Vor-/Nachteile
SBPO/Offline	Quasi-Newton-Methode mit NB (SQP), Goal-Attainment-Verfahren (SQP)	exakt, schnell bei bis zu 6 Parametern
ZQBPO/Offline	Quasi-Newton-Methode mit NB (SQP), Goal-Attainment-Verfahren (SQP)	exakt, langsam (viele Iterationen)
ZQKFO/Offline	Quasi-Newton-Methode mit NB (SQP), Goal-Attainment-Verfahren (SQP)	Konvergenzprobleme, sehr langsam (viele Parameter)

Die globale Optimierung vollständiger Führungsgrößen-Kennfelder mit $6 \times 6 = 36$ Stützstellen wurde nach zwei verschiedenen Methoden durchgeführt. Ihre Umsetzung erfolgte am Polynommodell aus Abschnitt 5.5.

1. ZQBPO für jeden lokalen n/M -Betriebspunkt bei Verwendung jeweils gleicher NO_x - und PM -Grenzwerte als Nebenbedingung. Das entspricht 36 SBPO mit je 3 Freiheitsgraden.
2. Erstellung eines globalen Parametervektors mit $3 \times 36 = 108$ Freiheitsgraden und Optimierung der gewichteten Ziel- und Nebenbedingungen entsprechend **Gl. 6.20** (Quasi-Newton-Verfahren), **Gl. 6.34** (Goal-Attainment-Verfahren) und **Gl. 6.37** (globale quasistationäre Ziel- und Nebenbedingungsfunktionen). Das entspricht der Lösung des ZQKFO-Optimierungsproblems.

Bei der globalen Optimierung wurde von einer Gleichverteilung der im realen Motorbetrieb auftretenden stationären Betriebspunkte im Motorkennfeld ausgegangen.

Tab. 6.4 Optimierungsergebnisse mit Hill-Climbing Verfahren

Aufgabe/Verfahren		Quasi-Newton-Verfahren	Goal-Attainment-Methode
SBPO von <i>HEB</i> , <i>VEM</i> und <i>p_{Rail}</i> für einen nominellen Betriebspunkt (exemplarisch $n = 2250 \text{ min}^{-1}$, $M = 105 \text{ Nm}$)	b_e	233,7 g/kWh	233,4 g/kWh
	NO_x	3,00 g/kWh	3,00 g/kWh
	PM	0,25 g/kWh	0,25 g/kWh
	Iterationen	100	122
ZQBPO für <i>HEB</i> -, <i>VEM</i> - und <i>p_{Rail}</i> -Führungsgrößen-Kennfelder mit je 36 n/M -Kennfeld-Stützstellen)	$b_{eZyklus}$	246,3 g/kWh	246,6 g/kWh
	$NO_{xZyklus}$	3,00 g/kWh	3,00 g/kWh
	PM_{Zyklus}	0,189 g/kWh	0,183 g/kWh
	Iterationen	3025	3603
ZQKFO für <i>HEB</i> -, <i>VEM</i> - und <i>p_{Rail}</i> -Führungsgrößen-Kennfelder mit je 36 n/M -Kennfeld-Stützstellen)	$b_{eZyklus}$	245,9 – 253,7 g/kWh	244,4 – 244,6 g/kWh
	$NO_{xZyklus}$	3,00 g/kWh	3,00 g/kWh
	PM_{Zyklus}	0,25 g/kWh	0,298 – 0,295 g/kWh
	Iterationen	4516 – 10011	18200 – 24400

Mit $h_i = 1/36$ folgt mit **Gl. 4.15-4.16** für die Zielfunktions- und Nebenbedingungs- werte

$$F = b_{eZyklus} = \frac{\sum_{i=1}^{i=36} b_e(\mathbf{x}_i)P(\mathbf{x}_i)}{\sum_{i=1}^{i=36} P(\mathbf{x}_i)},$$

$$G_{NO_x} = NO_{xZyklus} = \frac{\sum_{i=1}^{i=36} NO_x(\mathbf{x}_i)P(\mathbf{x}_i)}{\sum_{i=1}^{i=36} P(\mathbf{x}_i)},$$

$$G_{PM} = PM_{xZyklus} = \frac{\sum_{i=1}^{i=36} PM(\mathbf{x}_i)P(\mathbf{x}_i)}{\sum_{i=1}^{i=36} P(\mathbf{x}_i)}, \quad (6.37)$$

mit $i = \text{Nummer der Kennfeldstützstelle}$.

Das Goal-Attainment-Verfahren arbeitet mit dem Zielvektor $[b_e^* \ NO_x^* \ PM^*] = [200 \ 3 \ 0,25]$ und dem Wichtungsvektor $\mathbf{w} = [0,98 \ 0,0001 \ 0,0001]$.

Die Optimierungsergebnisse sind in **Tab. 6.4** zusammengefasst. Sowohl das Quasi-Newton- als auch das Goal-Attainment-Verfahren eignen sich bezüglich der erreichbaren Optimierungsqualität sehr gut für die stationäre Betriebspunktoptimierung SBPO. Unabhängig vom gewählten Startpunkt der Optimierung erreichen beide Verfahren nach ca. 100 Funktionsberechnungen, also nach 100 Messungen auf dem Prüfstand bei einer alternativen Online-Optimierung, das globale Optimum. **Abb. 6.5** illustriert verschiedene Optimierungsläufe im aus Abschnitt 5.5 bekannten Optimierungsraum¹³. Dargestellt sind nur die Hauptiterationen des jeweiligen SQP-

¹³Hier ohne Grenzwert-Isoliächen dargestellt.

Algorithmus. Die Trajektorien beider Verfahren verlaufen bei gleichem Startpunkt fast gleich, sodass keinem der beiden Verfahren ein eindeutiger Vorteil zugesprochen werden kann.

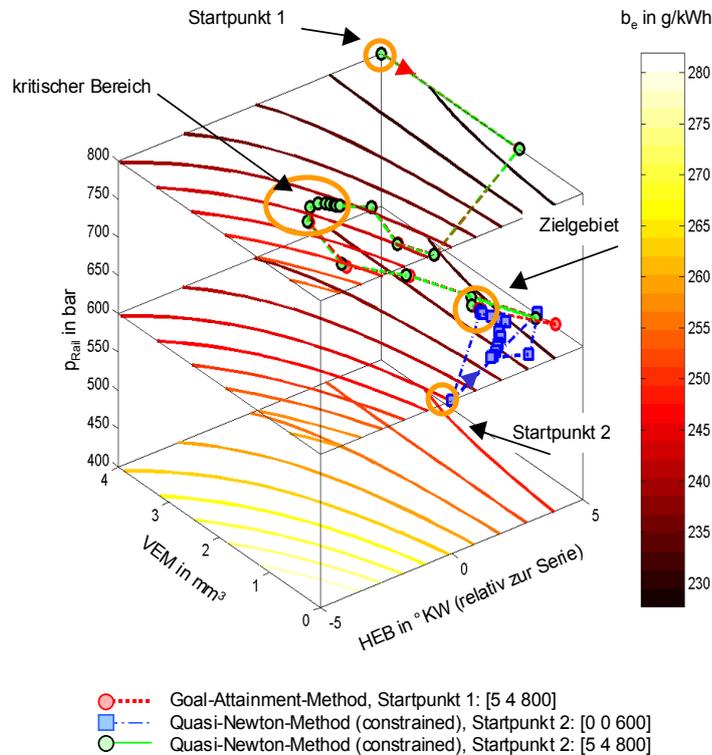


Abb. 6.5 Optimierungstrajektorien von Quasi-Newton- und Goal-Attainment-Verfahren bei SBPO ($n = 2250 \text{ min}^{-1}$, $p_{me} = 6.77 \text{ bar}$)

Eine weitere Verringerung der benötigten Iterationen gelang nicht, da eine Aufweichung der Abbruchkriterien¹⁴ den Algorithmus dazu veranlasst, schon im Bereich sehr flacher Zielfunktionsverläufe in der Nähe der NO_x -Grenzfläche das Optimum zu vermuten. In **Abb. 6.5** ist dieses numerische Schein-Minimum als kritischer Bereich markiert. Wie erwartet, erfordern die numerischen Hill-Climbing-Verfahren kleine Schrittweiten und damit viele Iterationen in nichtlinearen Bereichen der Zielfunktion.

Bei der Kennfeld-Optimierung (ZQBPO und ZQKFO) wird dieser Nachteil zum unüberwindlichen Hindernis im Falle einer angestrebten Online-Optimierung. Je nach Verfahren und Startkennfeld benötigen die Hill-Climbing-Algorithmen zwischen 3000 und 25000 Iterationen für eine komplette Kennfeldoptimierung. Das entspricht bei einer durchschnittlichen Messzeit von 200 s pro Iteration einer Prüfstand-Nutzungsdauer von 160 – 1400 Stunden zur Erzeugung eines optimalen Kennfelddatensatzes.

¹⁴Als Abbruchkriterium wurde unter Anderem die Differenz der Zielfunktionswerte zweier aufeinander folgender Iterationen auf 0.1 g/kWh festgesetzt. Die Erhöhung dieses Wertes würde ein früheres Abbrechen des Algorithmus bewirken.

Die ZQBPO ist dabei erwartungsgemäß schneller als die ZQKFO, was auf die Dimensionalität des Optimierungsproblems zurückzuführen ist (vgl. **Tab. 4.3** auf Seite 54). Der dargestellte Ergebnisbereich für b_e und PM bei der ZQBPO resultiert aus unterschiedlichen Startkennfeldern. Ein absolutes Optimum lässt sich bei dieser Komplexität offensichtlich nicht mehr eingrenzen. Das Goal-Attainment-Verfahren erreicht im Rahmen der ZQKFO trotz sehr vieler Optimierungsschritte nicht die geforderte Qualität im Abbruchpunkt. Der Grenzwert für die Partikelemissionen wurde in nicht unerheblichem Maße verletzt ($0.29 \text{ g/kWh} > 0.25 \text{ g/kWh}$).

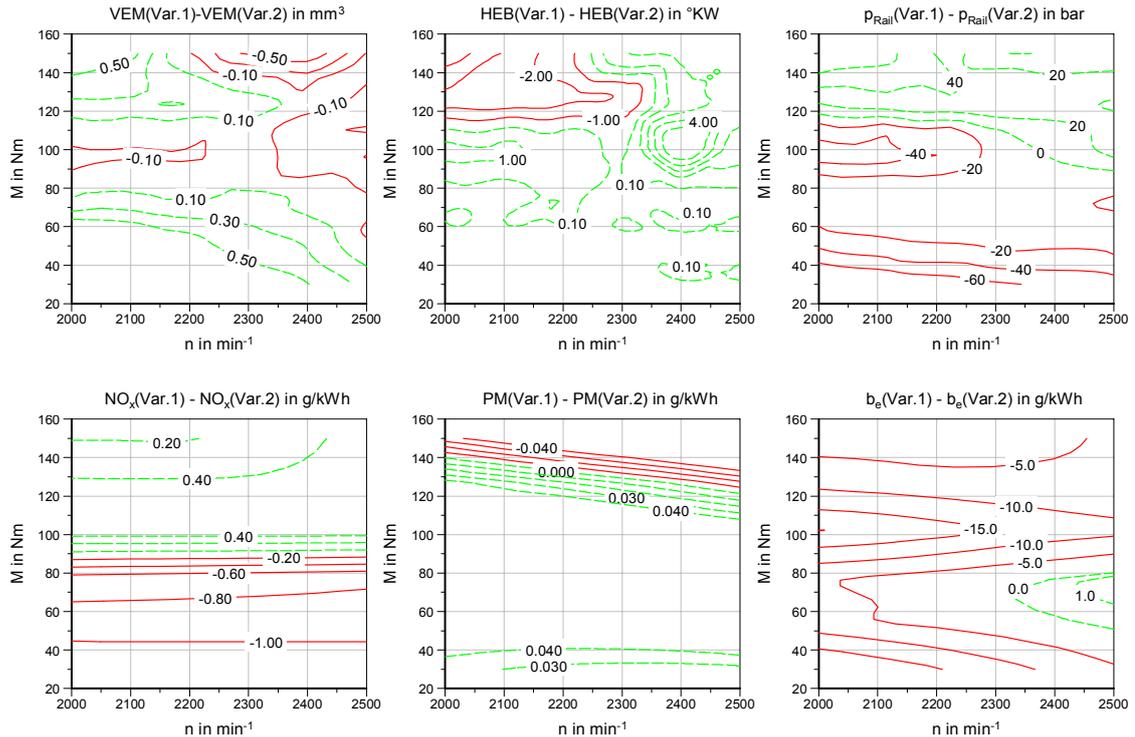


Abb. 6.6 Differenzenkennfelder ZQBPO-ZQKFO, Quasi-Newton-Verfahren, Startvektor [5 4 800] für alle Kennfeldstützstellen

Die Differenzenkennfelder in **Abb. 6.6** machen deutlich, dass trotz unterschiedlicher Optimierungsergebnisse \mathbf{x}_{KF} das gleiche qualitative Modellmotorverhalten erzielt werden kann. Die Unterschiede im gewichteten $b_{e,zyklus}$ nach **Gl. 6.37** auf Seite 97 liegen unter 0.2 % und damit deutlich unterhalb der Messunsicherheit am Motorenprüfstand. Es handelt sich hierbei offensichtlich um pareto-optimale Ergebnisse.

Aus den mit klassischen Hill-Climbing-Verfahren gewonnenen Erkenntnissen heraus entstand die Motivation, ein Verfahren zu entwickeln, welches mit wesentlich weniger Iterationen qualitativ gleichwertige Ergebnisse erzielt.

Kapitel 7

Wissensbasierter Fuzzy-Optimierungsansatz

7.1 Fuzzy-Strategien

7.1.1 Fuzzy-Logik

Die Fuzzy-Theorie stellt ein Mengen-Konzept dar, welches näher am menschlichen Denken orientiert ist als die klassische Mengenlehre. Komplexe, nichtlineare Zusammenhänge lassen sich über eine Abstraktion qualitativer Prozessmerkmale vorteilhaft beschreiben. Fuzzy-Logik wurde ursprünglich von Lofti A. Zadeh im Jahre 1965 formuliert. Sie ist eine Verallgemeinerung der mehrwertigen Logik.

In der klassischen Mengenlehre ist eine Variable x entweder ein Element oder kein Element einer definierten Menge. Die mit x assoziierte Zugehörigkeitsmenge ist demnach diskreter Natur. Bei Fuzzy-Mengen geht man von einem Grad der Zugehörigkeit für jedes Element der Menge aus. Dieser Zugehörigkeitsgrad einer Variablen x zur Menge M wird durch die Zugehörigkeitsfunktion $\mu_A(x)$ beschrieben. Vereinfachend normiert man den Wertebereich dieser Zugehörigkeitsfunktion auf das Intervall $[0, 1]$. Die Definition einer Fuzzy-Menge A ergibt sich damit nach [10] zu

$$\begin{aligned} A &= \{x, \mu_A(x) \mid x \in \mathfrak{X}\} \\ A(x) &: \mathfrak{X} \Rightarrow [0, 1]. \end{aligned} \tag{7.1}$$

Jede Prozessgröße kann durch eine oder durch eine Überlagerung mehrerer solcher Fuzzy-Mengen abgebildet werden. Die Prozessgröße wird im Kontext der Fuzzy-Logik als *linguistische Variable* und ihre sie repräsentierenden Fuzzy-Mengen als *linguistische Terme* bezeichnet. In **Abb. 7.1** sind beispielhaft für die Prozessgröße Haupteinspritzbeginn (HEB) mögliche Zugehörigkeitsfunktionen für die linguistischen Terme *früh*, *null* und *spät* dargestellt. Prozesssituationen können nun in Form

von Aussagen über den Prozess beschrieben werden. Beispielsweise entspricht einem Haupteinspritzbeginn von $+1.25 \text{ }^\circ\text{KW}^1$ die linguistische Aussage

Der Haupteinspritzbeginn ist zu 50% *früh* UND zu 50% *null*.

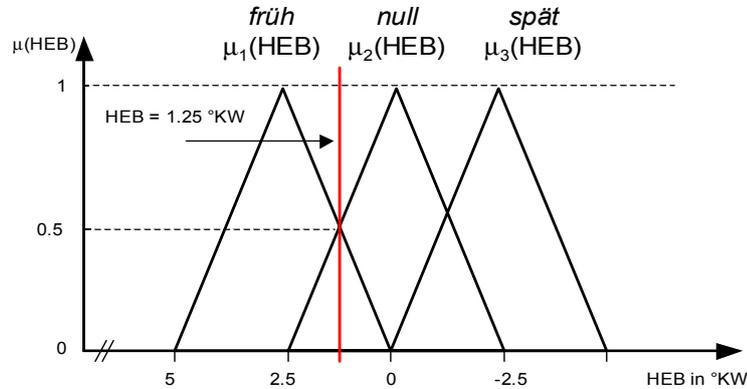


Abb. 7.1 Unscharfe Darstellung durch linguistische Terme am Beispiel Haupteinspritzbeginn

Es handelt sich hierbei um eine verknüpfte Aussage. Der logische Operator *UND* ist wiederum eine Formalisierung umgangssprachlicher Konzepte. Die Operatoren der Fuzzy-Algebra sind prinzipiell von denen der booleschen Algebra abgeleitet. Die mathematischen Umsetzungen der wichtigsten Fuzzy-Operatoren sind im Folgenden zusammengestellt².

Vereinigung (UND)

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} \quad \forall x \in \mathfrak{X} \quad (7.2)$$

Durchschnitt (ODER)

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} \quad \forall x \in \mathfrak{X} \quad (7.3)$$

Komplement (NICHT)

$$\mu_{\bar{A}} = 1 - \mu_A(x) \quad \forall x \in \mathfrak{X} \quad (7.4)$$

Entsprechend den Definitionen der booleschen Logik sind auch für die Fuzzy-Logik algebraische Gesetze wie Assoziativität, Kommutativität, etc. definiert, [72].

Stehen mehrere unscharfe Mengen in Beziehung zueinander, werden zu deren Beschreibung so genannte Fuzzy-Relationen benötigt. Mit zwei Fuzzy-Mengen, die über \mathfrak{X} bzw. \mathfrak{Y} definiert sind, gilt für die Relation R

¹Ein skalarer Wert wird als *Fuzzy-Singleton* bezeichnet.

²Bei den Darstellungen handelt es sich um die von Zadeh vorgeschlagenen Operatoren. Es existieren noch weitere Vorschläge, die in dieser Arbeit jedoch keine Verwendung finden (vgl. hierzu [72]).

$$R = \{(x, y) \mid \mu_R(x, y)\} \quad x, y \in \mathfrak{X} \times \mathfrak{Y} \quad (7.5)$$

$$\mu_R(x, y) : \mathfrak{X} \times \mathfrak{Y} \Rightarrow [0, 1].$$

Relationen zwischen Fuzzy-Mengen können auch verkettet werden. Es seien die Relationen R_{xy} und S_{yz} gegeben. Die Verkettung $R \circ S$ stellt dann eine unscharfe Relation zwischen x und z gemäß

$$R \circ S : \mu_{R \circ S} = \max_{\forall y \in \mathfrak{Y}} [\min\{\mu_R(x, y), \mu_S(y, z)\}] \quad (7.6)$$

her. Diese Relation wird auch als *max-min-Relation* bezeichnet³.

Umgangssprachlich formulierte WENN-DANN-Regeln können mittels Fuzzy-Logik als verkettete *max-min-Relation* zwischen Fuzzy-Mengen dargestellt werden. Für einen Prozess mit den skalaren Führungsgrößen x_1, x_2 , der Prozessgröße y und einer den Prozess beschreibenden Regel der Form

WENN $x_1 = A_1$ UND $x_2 = A_2$ DANN $y = B$

kann ausgehend von **Gl. 7.6** folgende als Zadeh'sche Zuordnungsregel bekannte Funktion zur Bestimmung der Zugehörigkeitsfunktion des linguistischen Ausgangsterms B' aufgestellt werden:

$$B = A \circ R \quad (7.7)$$

$$\mu_{B'}(y) = \max_{y \in \mathfrak{Y}} [\min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2), \mu_R(x, y)\}].$$

Zur Bestimmung der Relation R in **Gl. 7.7** sind wiederum verschiedene Möglichkeiten gegeben. Am weitesten verbreitet ist die Mamdani-Relation R_M mit der Gleichung

$$\mu_{R_M}(x, y) = \min\{\mu_A(x), \mu_B(y)\}. \quad (7.8)$$

Mit dieser Beziehung wird **Gl. 7.7** zu

$$\begin{aligned} \mu_{B'}(y) &= \max_{y \in \mathfrak{Y}} [\min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2), \mu_{A_1}(x), \mu_{A_2}(x), \mu_B(y)\}]. \\ &= \min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2), \mu_B(y)\}. \end{aligned} \quad (7.9)$$

Diese Relation wird auch als *Implikations-Inferenz* bezeichnet. **Abb. 7.2** illustriert die Implikation am Beispiel zweier Regeln.

³Auch für die Verkettung zweier Relationen sind weitere mathematische Repräsentationen, z. B. die *max-prod-Verkettung* bekannt, [10].

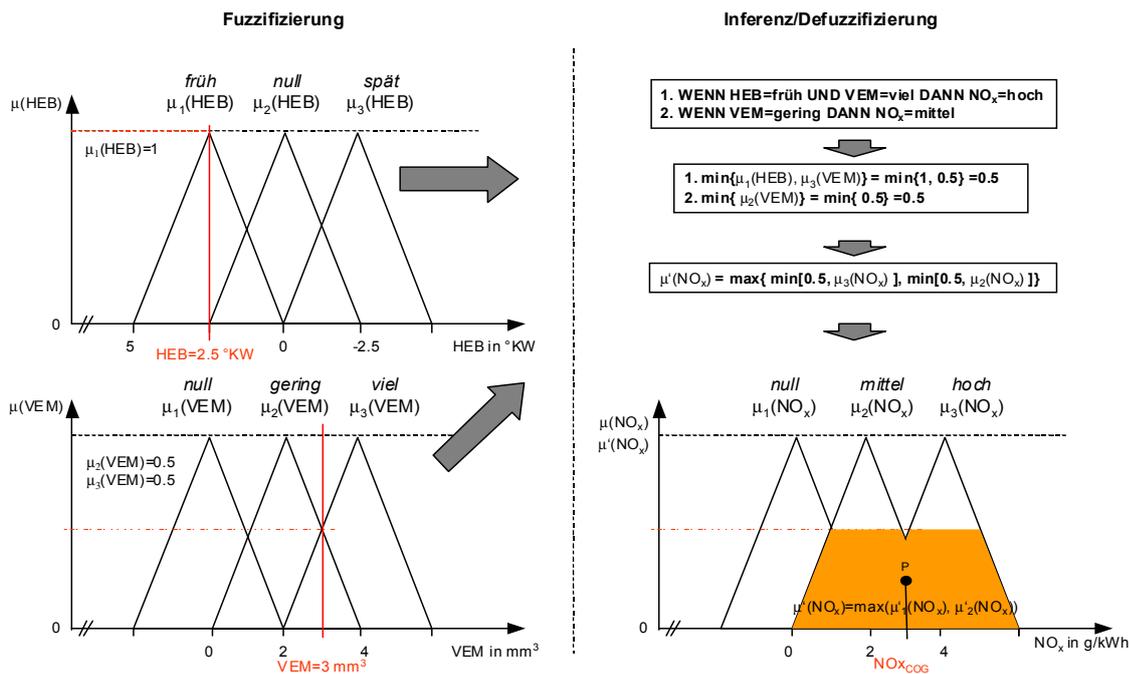


Abb. 7.2 Abbildung unscharfer Zusammenhänge mittels Fuzzy-Inferenz

7.1.2 Fuzzy-Reglerstrukturen

Fuzzy-Strukturen werden überwiegend im Bereich der Regelungstechnik eingesetzt. Insbesondere bei der Regelung stark nichtlinearer Prozesse verspricht der linguistische Ansatz einen schnellen und qualitativ guten Reglerentwurf. Den Aufbau eines Fuzzy-Reglers zeigt **Abb. 7.3**. Man unterscheidet innerhalb der Reglerstruktur vier Teilmechanismen.

Fuzzifizierung

Unter Fuzzifizierung versteht man die Eingangskodierung der zu überwachenden Prozessgrößen, die den Grad der Regleraktivierung bestimmen. Diese Messwerte liegen zumeist als scharfe Werte vor und können als Fuzzy-Singletons betrachtet werden. Geht man von einer einfachen Überlappung der Zugehörigkeitsterme entsprechend **Abb. 7.1** aus, so erhält man maximal zwei Zugehörigkeitswerte pro Prozessgrößen-Singleton.

Auch unscharfe Eingangsgrößen können auf linguistische Terme von Fuzzy-Variablen abgebildet werden⁴. In der Praxis wird dann das Maximum der Schnittmenge als Fuzzifizierungs-Wert verwendet. Diese Arbeit behandelt ausschließlichscharfe Reglereingangsgrößen.

⁴Unschärfe Eingangsgrößen werden z. B. zur Darstellung von Messunsicherheiten verwendet.

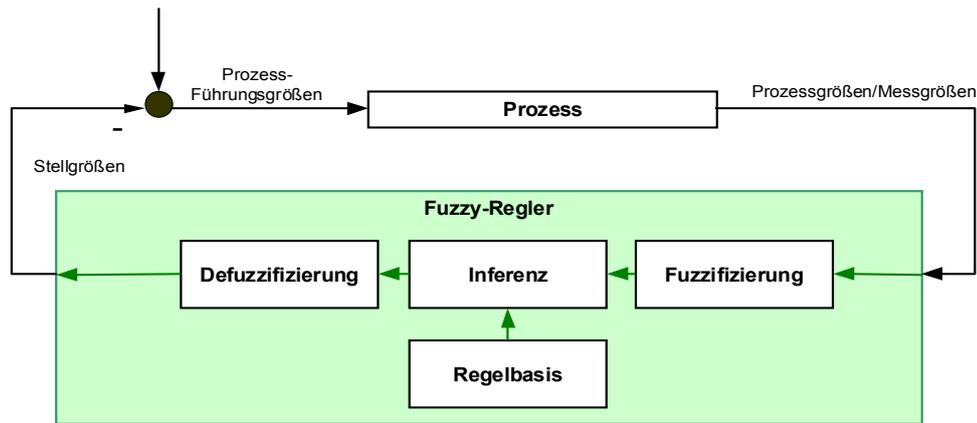


Abb. 7.3 Struktur eines Fuzzy-Regelmechanismus

Regelbasis

Durch die Regelbasis wird die Regelungsstrategie in Form intuitiv verständlicher WENN-Prämisse-DANN-Konsequenz-Regeln abgebildet. Jede Regel stellt einen logischen Zusammenhang zwischen einer bzw. mehrerer Eingangs- und einer Ausgangsgröße unter Verwendung der definierten linguistischen Zugehörigkeitsterme her. Die Prämisse kann eine atomare oder eine zusammengesetzte Aussage sein, die Konsequenz ist immer eine atomare Aussage, [72]. Durchschnitts-, Vereinigungs- und Komplement-Operatoren dienen zur Verknüpfung der linguistischen Eingangsterme. Die Regeln der Regelbasis werden mit Hilfe von Expertenwissen aufgestellt. Der Fuzzy-Ansatz kommt demnach einem Wissenserwerb durch Expertenbefragung gleich.

Fuzzy-Inferenz

Als Inferenz bezeichnet man die Abbildung der fuzzifizierten Eingangswerte auf linguistische Ausgangsterme unter Verwendung eines Inferenzmechanismus. Obwohl auch Inferenzmaschinen existieren, die ohne explizite Regelbasis arbeiten, [10], sollen im Folgenden nur regelbasierte Inferenz-Algorithmen betrachtet werden. Die Fuzzy-Inferenz bezeichnet man auch als *approximatives Schließen*.

In Abschnitt 7.1.1 wurde bereits die Implikations-Inferenz unter Verwendung der Zadeh'schen Zuordnungsregel und der Mamdani-Relation beschrieben, **Gl. 7.7-7.9**, die auch als Mamdani-Inferenz bekannt ist. Zu den regelbasierten Schließmethoden zählen des Weiteren die Gödel-, die Larsen-(max-prod-), die Wu2-, [100], und die Tsukamoto-Inferenz, [10]. All diese Algorithmen stellen eine Erweiterung des *modus ponens* zum Schlussfolgern in der klassischen Logik dar, [8, 19]. Man erhält einen Zugehörigkeitswert zur Konklusion der jeweils aktiven Regel. Die Schlussfolgerung ist bei diesen Inferenz-Verfahren wiederum ein unscharfer Wert.

Bei der Tagaki-Sugeno-Inferenzmethode liegt der Konsequenzteil der Regeln nicht in

Form von unscharfen Mengen vor, sondern ist über vorgegebene analytische Funktionen direkt in Abhängigkeit der unscharfen Prämissen berechenbar. Die Tagaki-Sugeno-Methode eignet sich auf Grund ihrer großen Anzahl frei bestimmbarer Parameter (Parameter der Schließfunktionen) besonders gut zur Funktionsapproximation in Verbindung mit automatisierten Lernverfahren. Sie wurde als Strategie zum Reglerentwurf entwickelt, [10, 8]. Eine direkte intuitive Umsetzung von regelbasiertem Expertenwissen ist jedoch mit dieser Methode nicht mehr möglich, da zusätzliche funktionelle Zusammenhänge formuliert werden müssen.

Defuzzifizierung

Die Umwandlung unscharfer in scharfe Konklusionswerte heißt Defuzzifizierung. Scharfe Ausgangswerte sind zur Steuerung von Stellgliedern unbedingte Voraussetzung. Während bei der Tagaki-Sugeno-Inferenz scharfe Ausgangsgrößen direkt berechnet werden, muss bei der Mamdani-Inferenz eine entsprechende Transformation erfolgen. In der Literatur sind unter anderem die max-, die Mittelwert-max, die Tsukamoto- und die Flächenschwerpunktmethod beschrieben. Die numerisch aufwändigste, aber der Theorie des approximativen Schließens am nächsten kommende ist die Flächenschwerpunkt-Defuzzifizierung (COG-center of gravity). Sie wird in der Praxis am häufigsten und auch im Rahmen dieser Arbeit verwendet.

Der Abszissenwert y_{COG} des Flächenschwerpunktes P der aktivierten linguistischen Terme einer Ausgangsvariablen y wird wie folgt berechnet:

$$y_{COG} = \frac{\int_{\mathfrak{Y}} \mu_B(y)ydy}{\int_{\mathfrak{Y}} \mu_B(y)dy}. \quad (7.10)$$

Dieses Vorgehen wurde bereits im Beispiel der **Abb. 7.2** angewendet. Prinzipbedingt ist es mit der Schwerpunktmethod nicht möglich, die durch die Begrenzung der Zugehörigkeitsfunktion gegebenen Abszissen-Randwerte zu erreichen. Diese Beschränkung des Stellbereichs kann durch eine fiktive Erweiterung der Zugehörigkeitsfunktionen behoben werden. Werden die Terme der linguistischen Ausgangsvariablen durch gleichschenkelige Dreiecke dargestellt, so kann die Berechnung des Schwerpunktes in der Art vereinfacht werden, dass eine Mittelwertbildung der Einzelschwerpunkte aller aktiven Dreiecke erfolgt.

7.1.3 Fuzzy-Diagnose und Fuzzy-Modellierung

Neben der Anwendung von Fuzzy-Strukturen in Regelungssystemen kann das Konzept der kognitiven Nachbildung komplexer systematischer Zusammenhänge auch zur Systemdiagnose und -überwachung bzw. zur gezielten Problembehandlung eingesetzt werden, [49]. So sind beispielsweise in [72] übergeordnete Überwachungs-, Steuerungs- und Adaptionsalgorithmen einer Kläranlagen-Regelung mittels Fuzzy-Logik realisiert. Der prinzipielle Aufbau des Fuzzy-Reglers aus **Abb. 7.3** blieb dabei

erhalten, nur die Ein- und Ausgangsvariablen des Fuzzy-Systems wurden problem-spezifisch angepasst.

Darüber hinaus eignen sich Fuzzy-Strukturen zum Einsatz als Vorsteuerorgan in hochgradig nichtlinearen Regelkreisen, [9], und zur stationären bzw. dynamischen Systemmodellierung. In so genannten Neuro-Fuzzy-Systemen ist unter Verwendung der Trainingsmethoden für künstliche neuronale Netze eine automatische Adaption von Fuzzy-Modellen möglich.

Die Regelbasis solcher Fuzzy-Algorithmen fußt wiederum auf Expertenwissen, welches prozessbezogen erarbeitet werden muss. Speziell zur Umsetzung von Expertenwissen zur Modellbildung wurde in [19] das Verfahren der *Regelbasierten Interpolation (RIP)* vorgestellt. Ausgehend von linguistischem Expertenwissen in Form von Produktionsregeln wird der gesamte mögliche Parameterraum auf die Prozessvariablen abgebildet. Da dies nur an durch die Regelbasis definierten Stützstellen möglich ist, produzieren nachgeschaltete Interpolationsalgorithmen ähnlich der RSM (Abschnitt 5.2) ein vollständiges numerisches Prozessmodell.

Fuzzy-Algorithmen eignen sich hervorragend als allgemeingültige wissensbasierte Approximatoren in unterschiedlichsten Problemstellungen, für die eine analytische Behandlung zu aufwändig bzw. gar nicht möglich ist. Die Anwendung von Fuzzy-Logik zur Prozessoptimierung kann auf Grund des reichlich zur Verfügung stehenden Expertenwissens als sehr aussichtsreich eingeschätzt werden.

7.2 Entwurf des Fuzzy-Interpreters zur Prozessoptimierung

Abb. 7.4 zeigt die prinzipielle Struktur eines wissensbasierten Fuzzy-Optimierers. Der in **Abb. 4.1** auf Seite 18 dargestellte Optimierungskreislauf, bestehend aus Prozess bzw. Prozessmodell, Prozessbewertung und Optimierer ist hier ebenso wiederzuerkennen wie der Fuzzy-Regler-Block aus **Abb. 7.3** auf Seite 105.

Der Fuzzy-Inferenzblock bildet dabei die aktuellen Prozess(bewertungs)-Größen auf neue Führungsgrößen-Datensätze ab. Er übernimmt sowohl die Prozessbewertung als auch die eigentliche Optimierung. Eine Motorwissensbasis dient als Abbild des Motor-Expertenwissens. Die in der Regelbasis enthaltenen Zusammenhänge dienen als Grundlage für die Regelbasis des Fuzzy-Inferenzalgorithmus. Auf Grund der linguistischen Methodik des dargestellten Systems ist es möglich, neben den aktuellen Prozessgrößen auch Kenndaten des dem Versuch zu Grunde gelegten Testzyklus in die Optimierung einfließen zu lassen.

Mit dem dargestellten Verfahren lassen sich prinzipiell auch Reglerparameter, Vorsteuerfunktionen und Diagnosestrukturen in Motorsteuergeräten optimieren. In einer so genannten Kennfeld-Datenbank können Optimierungsläufe abgespeichert und damit in nachfolgenden Optimierungsläufen Vorhersagen für zielführende Optimierungsschritte getroffen werden. Somit sind Auto-Adaptionsmöglichkeiten auf Ba-

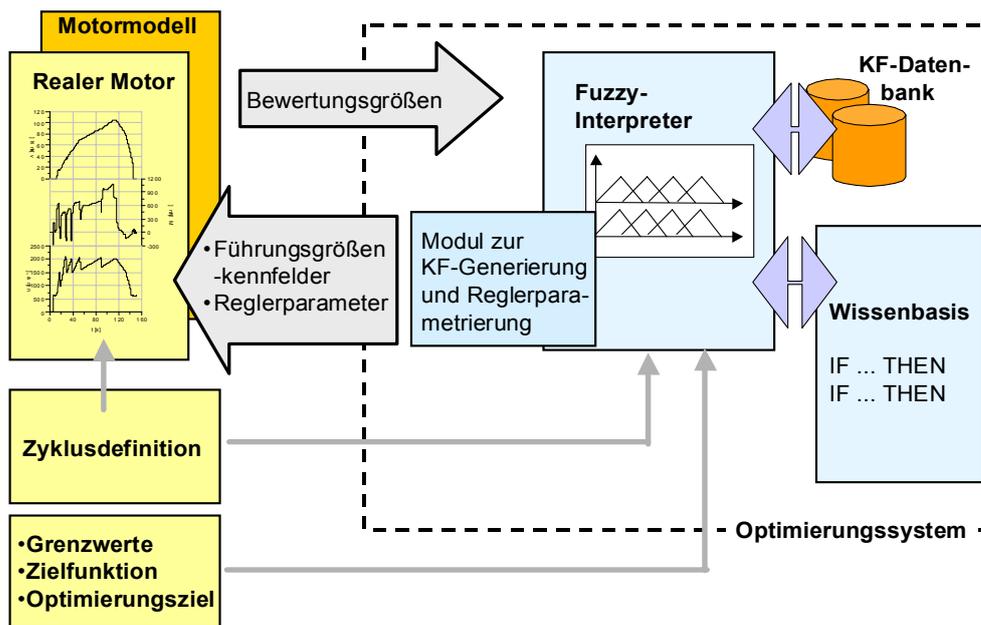


Abb. 7.4 Aufbau des Fuzzy-Optimierungssystems

sis von nachvollziehbaren Trainingsdaten für das Optimierungssystem gegeben. Die Optimierung mit Lerndateien aus bereits aufgenommenen Optimierungsdatensätzen wurde bereits in [5] am Beispiel der Offline-Voroptimierung von DI-Dieselmotoren erfolgreich angewandt.

In den folgenden Abschnitten soll die Vorgehensweise zur Definition der linguistischen Ein- und Ausgangsterme für die in Abschnitt 5.5 erarbeitete Optimierungsaufgabe erläutert werden.

7.3 Dieselmotoren-Wissensbasis als Grundlage für die Fuzzy-Regelbasis

7.3.1 Stationäre Common-Rail-Wissensbasis am Beispiel M47R

In den Abschnitten 4.5.5 und 5.5 wurden bereits Ansätze zur Formulierung linguistischer Regeln über das Motorprozessverhalten vorgestellt. Um ein umfassendes Regelwerk erstellen zu können, sind darüber hinaus systematische Untersuchungen anzustellen, die das Prozessverhalten im gesamten Parameterbereich abdecken. Mit den Methoden der statistischen Versuchsplanung besteht die Möglichkeit, einen einzigen Versuchsplan für den gesamten möglichen Versuchsraum aufzustellen. Eine Rastervermessung einzelner Zusammenhänge bietet jedoch den Vorteil, dass die Ergebnisse besser nachvollziehbar und einzelne Messfehler erkennbar bleiben. Offensichtlich nichtsignifikante Effekte können durch Zusatzuntersuchungen bestätigt

und entsprechende linguistische Zusammenhänge später eliminiert werden.

Am Beispiel ausgewählter systematischer Versuchsreihen soll die Erstellung der linguistischen Wissensbasis für den M47R erläutert werden. Im Vorfeld der eigentlichen Vermessung fand eine Vermessung repräsentativer stationärer Motorbetriebspunkte statt. Folgende Kriterien sollten die ausgewählten Betriebspunkte erfüllen:

- hohe relative Häufigkeit des jeweiligen zum Betriebspunkt gehörigen Betriebsbereichs im Testzyklus (MVEG) bzw. im realen Fahrbetrieb (d. h. auch Vollast-Bereich),
- möglichst viele Parameter müssen in einem weiten Verstellbereich variierbar sein (Vermeidung von physikalisch nicht sinnvollen Führungsgrößen-Kombinationen),
- dynamische Betriebsphasen sollten durch die gewählten Betriebspunkte bei quasistationärer Betrachtungsweise teilweise abgedeckt werden, um später Vergleiche zwischen stationären und dynamischen Prozesszusammenhängen ziehen zu können.

Basierend auf diesen Forderungen wurden je ein Betriebspunkt der unteren und der mittleren Teillast ($n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ bzw. $n = 3000 \text{ min}^{-1}$, $p_{me} = 6 \text{ bar}$) und ein Betriebspunkt in Vollastnähe ($n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$) ausgewählt (vgl. hierzu auch **Abb. 4.16** auf Seite 40). Sinnvolle Einstellwerte für Haupteinspritzbeginne konnten anhand entsprechender Voruntersuchungen ermittelt werden. Die vermessenen Zusammenhänge sind allgemein bekannt und finden sich in der jeweils ersten Zeile der **Tabellen 7.1 und 7.2** auf Seite 117.

Zunächst war das Emissionsverhalten des Motors in Abhängigkeit von Zeitpunkt und Menge der Piloteinspritzung Gegenstand der Untersuchung. **Abb. 7.5** stellt diese Zusammenhänge für den unteren Teillastbetriebspunkt dar. Zum Vergleich sind auch diejenigen Werte eingetragen, die sich ohne Piloteinspritzung ergeben. Es ist ersichtlich, dass bei konstanter Voreinspritzmenge die NO_x - und Partikelemissionen mit größerem Spritzabstand SA fast ausnahmslos fallen und die HC- bzw. CO-Emissionen steigen. Die Ursache hierfür ist in der Gemischaufbereitung zu suchen. Während für die Erhöhung der HC-Emissionen die Zunahme der Kraftstoffanlagerungen, insbesondere durch das Auftreffen des Einspritzstrahls auf den Kolbenmuldenrand, verantwortlich gemacht werden kann, ist für die Erhöhung der CO-Werte die geringe Zylindertemperatur während der Piloteinspritzung entscheidend. Es kommt zu langsameren Vorreaktionen und damit zu einer schlechteren Gemischaufbereitung.

Die Partikel-Emission steigt mit früherer Piloteinspritzung an, weil der Zündverzug der Haupteinspritzung entsprechend vergrößert wird und sich damit ungünstige Oxidationsbedingungen für den Ruß ergeben. Die Spitzentemperatur im Zylinder erhöht sich durch die schlagartige Verbrennung bei sehr frühen Piloteinspritzungen soweit, dass es zu entsprechend erhöhten NO_x -Emissionen kommt.

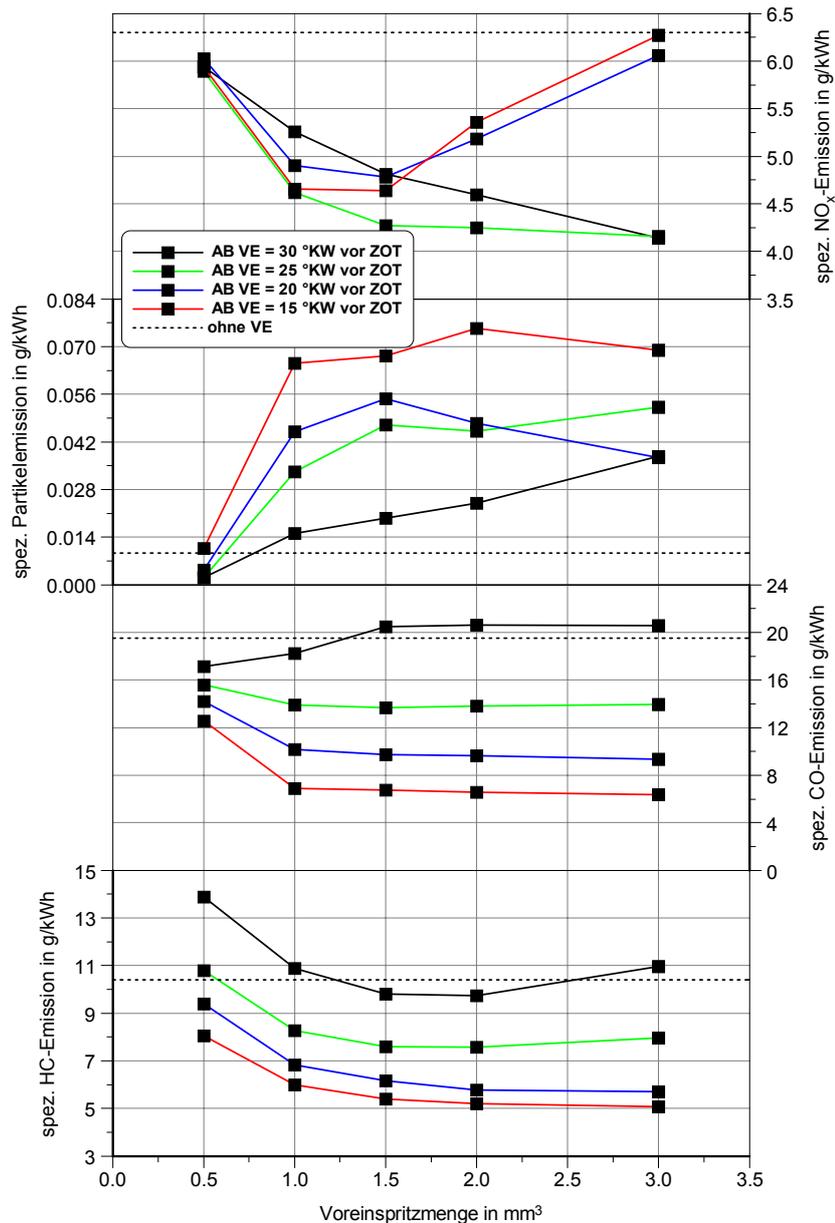


Abb. 7.5 Schadstoffemissionen bei Variation der Piloteinspritzung im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ ($p_{Rail} = 500 \text{ bar}$, $p_L = 1.04 \text{ bar}$, $AGR = 0 \%$, $ABHE = 4 \text{ °KW}$)

Für kurze Spritzabstände steigt die Stickoxid-Emission bei erhöhter Voreinspritzmenge an, womit der bei Dieselmotoren bekannte NO_x - PM -Trade-Off bestätigt wird. Das resultiert aus der Zünd-OT-nahen Verbrennung der Pilotmenge. Bei hohen Pilotmengen kann die zweigeteilte Verbrennung sogar als eine einzige Verbrennung mit einem zum HEB (ABHE) vorgelagerten Einspritzbeginn aufgefasst werden. Das Emissionsverhalten entspricht in diesem Fall demjenigen bei einer Frühverschiebung des HEB. Dass hierbei auch die Oxidation von Ruß begünstigt wird, zeigen die entsprechenden Partikelmassenverläufe. Der Einsatz der Voreinspritzung zur

Senkung von NO_x -Emissionen ist nur bei Wahl der geeigneten Mengen/Abstands-Kombination möglich. In diesem Fall ist jedoch mit einer deutlichen Erhöhung der Partikelemissionen zu rechnen. Wie Versuche bei mittlerer und oberer Teillast gezeigt haben, ist die Piloteinspritzung ab einer gewissen Gesamteinspritzmenge überhaupt nicht mehr in der Lage, Stickoxide zu reduzieren. Ihr Einsatz ist dann nur noch zur Senkung des Geräuschpegels der Verbrennung sinnvoll.

Brenn- und Temperaturverläufe, die durch thermodynamische Analyse des Zylinderdruckverlaufs gewonnen wurden, halfen bei der Interpretation der Messergebnisse (vgl. **Abb. 3.3** auf Seite 15). Durch Berechnung der Gradienten des Zylinderdruckverlaufs war es des Weiteren möglich, systematische Aussagen über das Geräuschverhalten des Motors zu treffen. **Abb. 7.6** verdeutlicht diesen Zusammenhang. Eine genügend große Voreinspritzmenge führt zu einer signifikanten Verringerung des Geräuschpegels, wobei zur weiteren Absenkung der Geräuschemission geringe Spritzabstände vorzuziehen sind (hier $15^\circ KW$). Größere Spritzabstände führen durch den Entzug von Verdampfungswärme zu einer größeren Abkühlung des Verbrennungsraumes, als das bei späten Voreinspritzungen der Fall ist. Im ersten Fall verbrennt die Pilotmenge tatsächlich erst zum Zeitpunkt der Entflammung der Haupteinspritzmenge. Damit wird der Zündverzug der Haupteinspritzmenge unter Umständen sogar leicht vergrößert, was wiederum zu laueren Verbrennungsgeräuschen führt, [54].

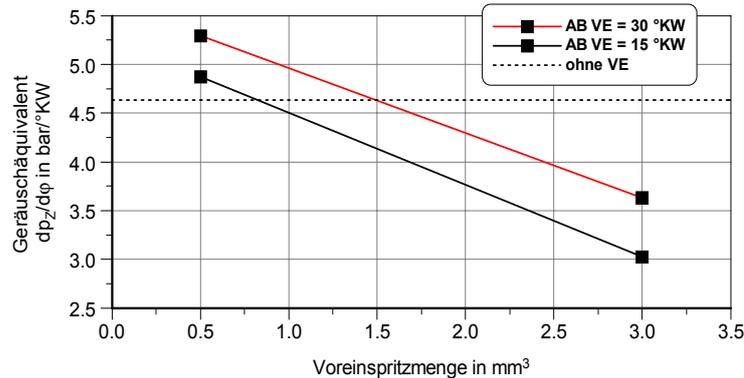


Abb. 7.6 Abhängigkeit des maximalen Zylinderdruckgradienten von der Piloteinspritzung im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ ($p_{Rail} = 500 \text{ bar}$, $p_L = 1.04 \text{ bar}$, $AGR = 0 \%$, $ABHE = 7^\circ KW$)

Einen weiteren wichtigen Bestandteil der Dieselmotoren-Wissensbasis sollte die Klassifizierung der Auswirkungen einer Raildruck-Änderung bilden. **Abb. 7.7** zeigt die 4-Quadranten-Darstellung des Emissionsverhaltens bei Raildruckvariation, ebenfalls für den $p_{me} = 2 \text{ bar}$ -Betriebspunkt. In dieser Darstellungsart lassen sich die motortechnischen Zusammenhänge und vor allen Dingen vorhandene Zielkonflikte übersichtlich visualisieren. Ziel einer optimalen Parameterwahl ist es, solche Parameterkombinationen zu finden, die Emissionswerte so nah wie möglich am jeweiligen Koordinatenursprung oder zumindest in zulässigen Bereichen⁵ zur Folge haben.

⁵Das Einzeichnen legislativer Grenzwerte in das 4-Quadranten-Diagramm führt zu *zulässigen*

Deutlich zu erkennen ist wiederum der NO_x - PM -Trade-Off, der am geringsten für den Fall keiner Piloteinspritzung ausgeprägt ist. Bei kleinen Raildrücken ist eine Voreinspritzung mit einer starken Erhöhung des Partikelaustrages verbunden. Hohe Raildrücke hingegen minimieren den Einfluss der Piloteinspritzung auf die Partikelemission, allerdings steigt die NO_x -Emission auf ein unverträgliches Niveau. Für die weniger problematischen CO- und HC-Emissionen sind bei Verwendung einer Voreinspritzung kleinere und ohne Voreinspritzung größere Raildrücke erforderlich, um deren Grenzwerte einzuhalten.

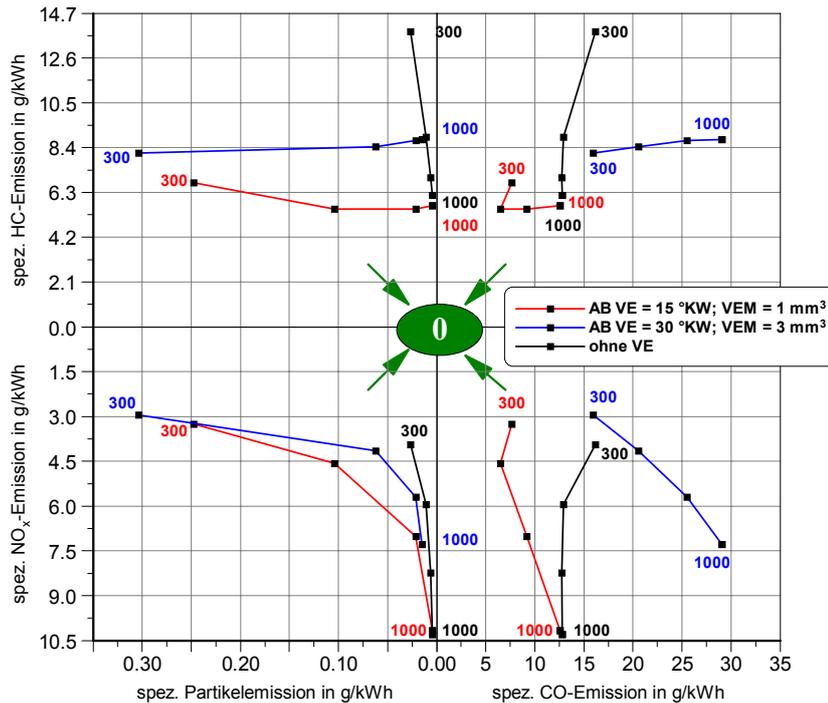


Abb. 7.7 4-Quadranten-Diagramm der Schadstoffemissionen bei Variation des Raildruckes im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ ($p_L = 1.04 \text{ bar}$, $AGR = 0 \%$, $ABHE = 4 \text{ °KW}$)

Der Verlauf des spezifischen Kraftstoffverbrauches und der b_e - NO_x -Trade-Off sind in **Abb. 7.8** dargestellt. Es ist erkennbar, dass b_e bei Erhöhung des Raildruckes unabhängig von den Parametern der Piloteinspritzung zunächst abfällt und danach wieder ansteigt. Der zunächst zu verzeichnende Wirkungsgradgewinn ist mit der besseren Kraftstoff-Zerstäubungsgüte und der damit verbundenen Qualitätsverbesserung in der Gemischaufbereitung zu erklären. Ab einem Raildruck von ca. $p_{Rail} = 550 \text{ bar}$ überschreitet der zusätzliche Leistungsbedarf der Kraftstoff-Hochdruckpumpe den möglichen Zugewinn durch eine qualitativ bessere Verbrennung. Der wirkungsgradoptimale Raildruck liegt demnach in einem Bereich zwischen 500 und 750 bar.

Die Verläufe der Kurven im NO_x - b_e -Diagramm sind ebenfalls mit dem bestehenden Rechtecken, von denen jeweils ein Eckpunkt im Koordinatenursprung liegt.

Zielkonflikt aus Pumpenantriebsleistung und erzielbarem Wirkungsgradgewinn zu erklären. Im oberen Raildruckbereich verlaufen sowohl Stickoxid-Emission als auch spez. Kraftstoffverbrauch ansteigend. Dieser Bereich ist bei der Abstimmung des Parameters Raildruck zu vermeiden.

Auch bei der Darstellung des geräuschäquivalenten Zylinderdruckgradienten in **Abb. 7.9** lassen sich die negativen Auswirkungen zu hoher Raildrücke im Teillastbetrieb erkennen. Das Verbrennungsgeräusch steigt mit wachsendem Raildruck stark an, wobei die Werte bei Verwendung einer Piloteinspritzung deutlich günstiger ausfallen als ohne.

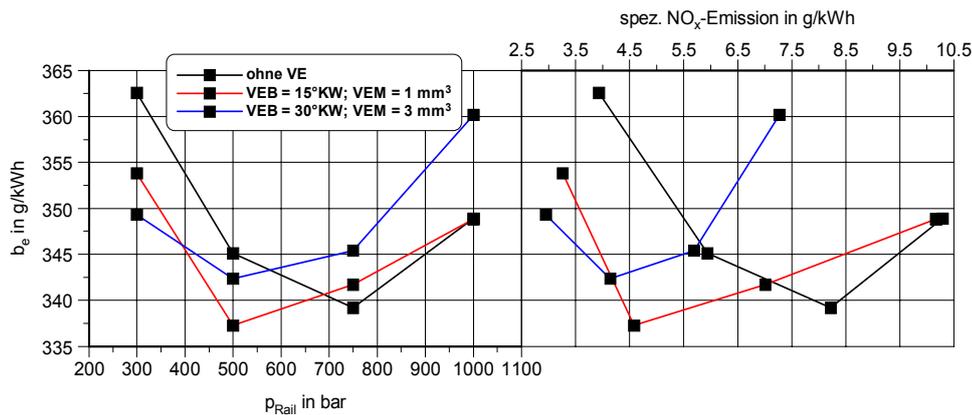


Abb. 7.8 $b_e - NO_x$ -Trade-Off bei Variation des Raildruckes im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ ($p_L = 1.04 \text{ bar}$, $AGR = 0 \%$, $ABHE = 4 \text{ °KW}$)

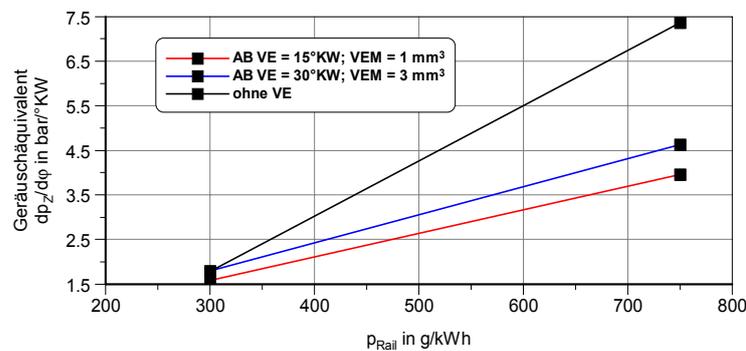


Abb. 7.9 Geräuschentwicklung in Abhängigkeit des Raildruckes im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ ($p_{\text{Rail}} = 500 \text{ bar}$, $p_L = 1.04 \text{ bar}$, $AGR = 0 \%$, $ABHE = 4 \text{ °KW}$)

Die Auswirkungen einer Abgasrückführung auf das Emissionsverhalten im exemplarischen Betriebspunkt der unteren Teillast sind in **Abb. 7.10** dargestellt. Es existiert neben dem Zielkonflikt zwischen Partikelmasse und NO_x -Emission offensichtlich auch ein $HC-PM$ -Trade-Off. Die Zuführung von heißem Abgas bewirkt

eine Verringerung der Kraftstoff-Wandanlagerungen und damit eine Verringerung der HC -Emissionen. Durch restgasbedingten Sauerstoffmangel kann jedoch nur eine unvollständige Rußoxidation stattfinden. Ein Früherlegen der Piloteinspritzung in Verbindung mit einer größeren Pilotmenge verbessert den NO_x - PM -Zielkonflikt merklich, auch wenn dabei die HC -Emissionen durch verstärkte Wandanlagerungen des Kraftstoffes ansteigen. Es sind daher mittlere AGR-Raten anzustreben.

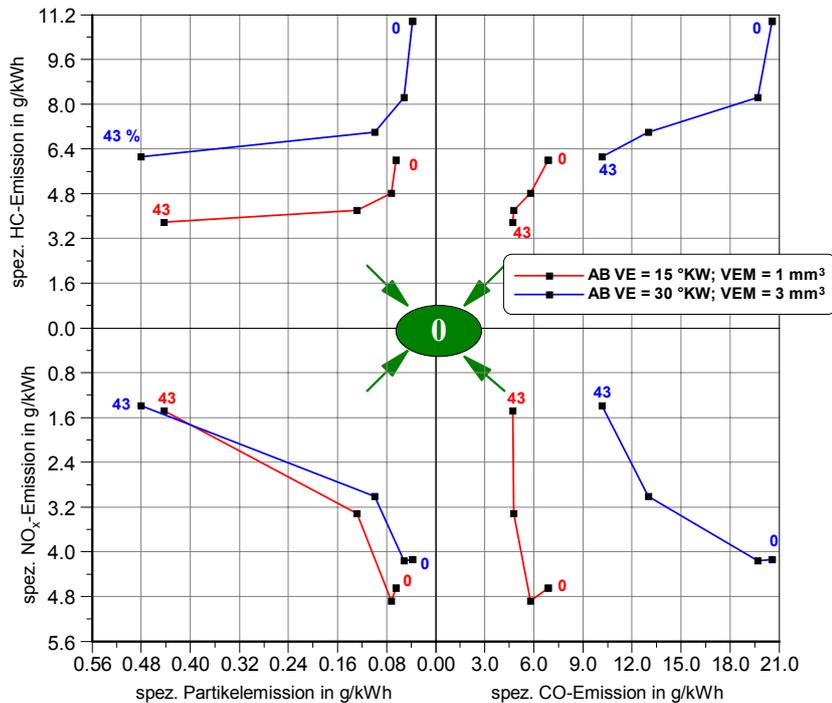


Abb. 7.10 4-Quadranten-Diagramm der Schadstoffemissionen bei Variation der Abgasrückführrate im Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ ($p_{Rail} = 500 \text{ bar}$, $p_L = 1.04 \text{ bar}$, $ABHE = 4 \text{ °KW}$)

Betrachtet man die Ergebnisse für den dritten untersuchten Betriebspunkt genauer, so lässt sich feststellen, dass im Vollastfall etwas andere Zusammenhänge gelten. Das 4-Quadranten-Diagramm in **Abb. 7.11** zeigt die Auswirkungen einer Variation des Raildruckes auf das Emissionsverhalten im Vollastpunkt.

Der NO_x - PM -Zielkonflikt bleibt bestehen, obwohl hier im Gegensatz zum Teillastfall kleine Piloteinspritzmengen bei moderaten Spritzabständen Vorteile gegenüber andern Einspritzverläufen bieten. Zwischen den HC - und CO -Emissionen lässt sich in **Abb. 7.11** ebenfalls ein Zielkonflikt feststellen, der so im Teillast-Betriebspunkt nicht vorlag.

Auch der Verlauf des spezifischen Kraftstoffverbrauchs (**Abb. 7.12**) weist im Vollastfall eine andere Abhängigkeit vom Raildruck auf als das im Teillast-Betriebspunkt der Fall war. Mit steigenden Raildrücken kommt es zu einer deutlichen Wirkungsgradverbesserung bei allen untersuchten Varianten für die Piloteinspritzung. Die erhöhte Pumpenantriebsleistung bei steigenden Drücken fällt hier offensichtlich we-

niger stark ins Gewicht. Anzumerken ist weiterhin, dass Raildrücke unter 1100 bar im Vollastbetrieb nicht mehr realisiert werden konnten. Wie durch Extrapolation der Kurven im dritten Quadranten der **Abb. 7.11** hin zu kleineren Raildrücken ersichtlich ist, ist dann mit unverträglich hohen Partikelemissionen zu rechnen.

Zur Sicherstellung eines ausreichenden Verbrennungs-Luftverhältnisses λ ist in Vollast-Betriebspunkten bekanntlich keine Abgasrückführung mehr möglich. Vielmehr spielt hier der Ladeluftdruck p_L und die davon abhängige Frischluftmenge im Zylinder für die Qualität der Verbrennung eine herausragende Rolle. Die Ergebnisse der Untersuchung entsprechender motortechnischer Zusammenhänge ist exemplarisch in **Abb. 7.13** dargestellt.

Der Wirkungsgrad des verwendeten VTG-Turboladers verschlechtert sich bei Erhöhung des Ladedrucksollwertes offensichtlich so stark, dass die wachsenden Abgasgedrücke zu einer merklichen Verringerung des Motorgesamtwirkungsgrades führen. Verständlich ist auch das gleichzeitige Ansteigen der NO_x -Emissionen, bedingt durch höhere Prozess-Spitzentemperaturen bei höheren Ladedrücken. Prinzipiell lässt sich jedoch kein Quereinfluss von Piloteinspritzparametern und Ladedruck feststellen.

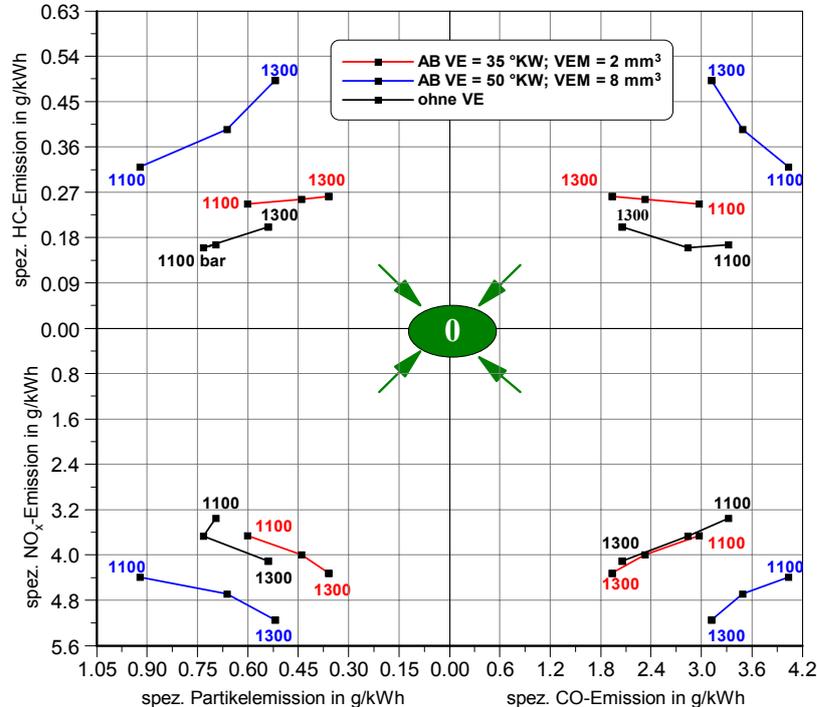


Abb. 7.11 4-Quadranten-Diagramm der Schadstoffemissionen bei Variation des Raildruckes im Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$ ($p_L = 2.00 \text{ bar}$, $AGR = 0 \%$, $ABHE = 12 \text{ °KW}$)

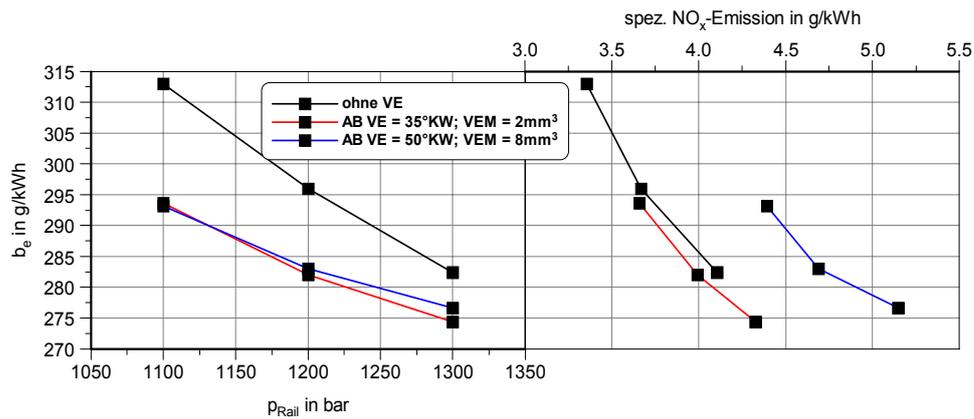


Abb. 7.12 $b_e - NO_x$ -Trade-Off bei Variation des Raildruckes im Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$ ($p_L = 2.00 \text{ bar}$, $AGR = 0 \%$, $ABHE = 12^\circ \text{KW}$)

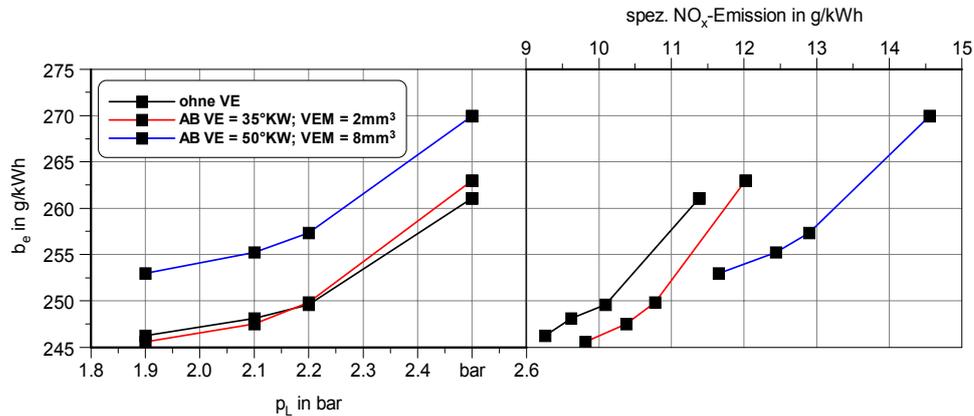


Abb. 7.13 $b_e - NO_x$ -Trade-Off bei Variation des Ladedruckes im Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$ ($p_{Rail} = 1350 \text{ bar}$, $AGR = 0 \%$, $ABHE = 12^\circ \text{KW}$)

Die Ergebnisse aller angestellten Versuche können nun in so genannten linguistischen Tabellen zusammengefasst werden. Für den M47R wurde jeweils für jeden der drei untersuchten Betriebspunkte eine Tabelle erstellt, aus der alle signifikanten Zusammenhänge abgelesen werden können.

Tab. 7.1 zeigt die Ergebnisse der Untersuchungen im Teillast-Betriebspunkt. Als Prämissen finden die Größen Haupteinspritzbeginn ($ABHE$), Spritzabstand (SA), Voreinspritzmenge (VEM), Raildruck (p_{Rail}) und Abgasrückführtrate (AGR) Verwendung. Eine weitere Unterteilung wurde durch die getrennte Untersuchung der letztgenannten Variablen bei jeweils zwei verschiedenen Haupteinspritzbeginnen vorgenommen. Für die Auswertung der Volllastergebnisse wurde anstelle des Parameters AGR der Ladeluftdruck p_L untersucht. *Rot* dargestellte Schlussfolgerungen signalisieren einen Anstieg der entsprechenden Prozessgröße, *grüne* Ergebnisse deuten

auf eine Absenkung des Wertes hin. Ausgehend von der ersten Zeile der **Tab. 7.1** kann zum Beispiel folgender Zusammenhang formuliert werden:

Eine Erhöhung (Früherlegung) des Haupteinspritzbeginns führt zu einer Erhöhung der NO_x -Emission und des Geräuschpegels sowie zu einer Absenkung von Partikel-, CO- und HC-Emissionen.

Tab. 7.1 Linguistische Prozess-Zusammenhänge für den M47R im Teillast-Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$

varierte Größen		Auswirkungen auf Emissionen und Kraftstoffverbrauch					
ABHE=4°KW vor ZOT	ABHE	NO_x	PM	CO	HC	b_e	G
	VEM	$\text{NO}_x \rightarrow \text{NO}_x$ für SA	PM \rightarrow PM für SA	CO für SA	HC \rightarrow HC für SA	b_e	G
	SA	NO_x für SA	PM für SA	CO für SA	HC für SA		
ABHE=7°KW vor ZOT	VEM	$\text{NO}_x \rightarrow \text{NO}_x$ für SA	PM \rightarrow PM für SA	CO für SA	HC für SA	b_e für SA	G
	SA	NO_x für SA	PM für SA	CO für SA	HC für SA	b_e für SA	
	SA	NO_x	PM	CO	HC	b_e	G
ABHE=4°KW vor ZOT	p _{Rail}	NO_x	PM	CO für SA/VEM	HC für SA/VEM	$b_e \rightarrow b_c$	G
				CO für SA/VEM	HC für SA/VEM		
ABHE=7°KW vor ZOT	p _{Rail}	NO_x	PM	CO	HC für SA/VEM	$b_e \rightarrow b_c$	G
					HC für SA/VEM		
ABHE=4°KW vor ZOT	AGR	NO_x	PM	CO	HC	b_e	G
ABHE=7°KW vor ZOT	AGR	NO_x	PM	CO	HC	b_e	G

Tab. 7.2 Linguistische Prozess-Zusammenhänge für den M47R im Vollast-Betriebspunkt $n = 4000 \text{ min}^{-1}$, $p_{me} = 10 \text{ bar}$

varierte Größen		Auswirkungen auf Schadstoffemissionen und Kraftstoffverbrauch					
ABHE =12°KW vor ZOT	ABHE	NO_x	PM	CO	HC	b_e	
	VEM	NO_x	PM	CO für SA	HC für SA	$b_e \rightarrow b_c$	
	SA	NO_x	PM für VEM	CO	HC für VEM	b_e für VEM	
ABHE =21°KW vor ZOT	VEM	NO_x	PM	CO	HC	b_e	
	SA	NO_x	PM	CO	HC	b_e für VEM	
						b_e für VEM	
ABHE =12°KW vor ZOT	p _{Rail}	NO_x	PM	CO	HC	b_e	
ABHE =21°KW vor ZOT	p _{Rail}	NO_x	PM	CO	HC	b_e	
ABHE =12°KW vor ZOT	p _L	NO_x	PM \rightarrow PM	CO \rightarrow CO für SA/VEM	HC \rightarrow HC	$b_e \rightarrow b_c$	
				CO \rightarrow CO für SA/VEM			
ABHE =21°KW vor ZOT	p _L	NO_x	PM für SA/VEM	CO für SA/VEM	HC für SA/VEM	b_e	
			PM \rightarrow PM für SA/VEM	CO \rightarrow CO für SA/VEM	HC für SA/VEM		

In **Tab. 7.2** sind die Ergebnisse der Vollast-Untersuchungen zusammengefasst. Grau unterlegt sind diejenigen Schlussfolgerungen, die sich von denen der Teillast-Untersuchungen unterscheiden. Eine Übereinstimmung ist nur in ca. 50% aller dargestellten Fälle zu verzeichnen. Betriebspunktspezifische Regeln müssen vom wissensbasierten Optimierer in jedem Fall berücksichtigt werden. Der Übersichtlichkeit halber sind die Ergebnisse des zweiten Teillast-Betriebspunktes nicht dargestellt. Sie entsprechen in weiten Bereichen denen des Betriebspunktes $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$.

7.3.2 Anwendung der Wissensbasis auf andere Einspritzkonzepte

Einen Vergleich der linguistischen Zusammenhänge für den Versuchsmotor M47R mit aus der Literatur bekannten Zusammenhängen für andere Motor/Einspritzsystem-Kombinationen ist in **Tab. 7.3** dargestellt. Anhand dieser Tabelle lassen sich erste Aussagen treffen, ob es sich bei den gefundenen Regeln um für direkteinspritzende Dieselmotoren allgemeingültige Zusammenhänge handelt oder nicht.

In [48] wurden Parametervariationen an einem Pumpe-Düse-Einspritzsystem mit einem hubraumgleichen Konkurrenztriebwerk durchgeführt. Aus dem untersuchten Betriebspunktspektrum wurde ein Teillastpunkt ausgewählt, der dem in dieser Arbeit untersuchten Betriebspunkt $n = 2000 \text{ min}^{-1}$, $p_{me} = 2 \text{ bar}$ ähnlich ist. Die grau hinterlegten Felder zeigen an, dass es insbesondere bei Variation des Spritzabstandes große Unterschiede in den zu erwartenden Prozessantworten gibt. Als Gründe für die sich unterscheidenden Ergebnisse können der unterschiedliche Einspritzdruckverlauf und unterschiedliche geometrische Einspritzdüsenparameter genannt werden. Zur Erweiterung der Wissensbasis um Zusammenhänge bei Pumpe-Düse-Systemen sind in jedem Fall weitere Versuchsreihen nötig.

Tab. 7.3 Vergleich der Ergebnisse des untersuchten Einspritzsystems mit Angaben in der Literatur zu anderen Systemen

Parameter	Common-Rail-System					Pumpe-Düse-System				
AB HE	NO _x	PM	CO	HC	b _e	NO _x	PM	CO	HC	b _e
VEM	NO _x → NO _x	PM → PM	CO	HC	b _e	NO _x	PM	CO	HC	b _e
SA	NO _x	PM	CO	HC	b _e	NO _x	PM	CO	HC	b _e
AGR	NO _x	PM	CO	HC	b _e	NO _x	PM	CO	HC	b _e

Parameter	Vergleich der Auswirkungen bei verschiedenen CR-Systemen					
VEM	NO _x für SA	PM für SA	CO für SA	HC für SA	b _e für SA	G
	NO _x für SA	PM für SA	CO für SA	HC für SA	b _e für SA	
SA	NO _x / NO _x	PM	CO	HC	b _e	G

Die Frage nach der Allgemeingültigkeit der aufgestellten Wissensbasis für Common-Rail-Einspritzsysteme kann nicht abschließend beantwortet werden, da als Vergleichsinformationen nur unvollständige Datensätze zur Verfügung standen. In [59] wurden ausschließlich die Auswirkungen der Variation von Parametern der Piloteinspritzung untersucht. Die Ergebnisse des Vergleichs der beiden CR-Systeme sind, soweit möglich, ebenfalls in **Tab. 7.3** zusammengefasst. Nur hinsichtlich des NO_x -Emissionsverhaltens ergibt sich ein Unterschied zwischen dem in dieser Arbeit und dem in [59] untersuchten System. Es ist deshalb davon auszugehen, dass die erstellte Wissensbasis eine Allgemeingültigkeit für alle Common-Rail-Systeme in Verbindung mit Motoren der gleichen Hubraumklasse besitzt.

7.4 Potential des Fuzzy-Optimierers zur stationären Optimierung am Motormodell

7.4.1 Fuzzy-Optimierer mit einfacher Regelbasis zur SBPO

Als Validierungsaufgabe für den wissensbasierten Fuzzy-Algorithmus soll wiederum die bereits in Abschnitt 6.5 mit den Hill-Climbing-Verfahren durchgeführte Offline-Optimierung am Modell des M47R dienen.

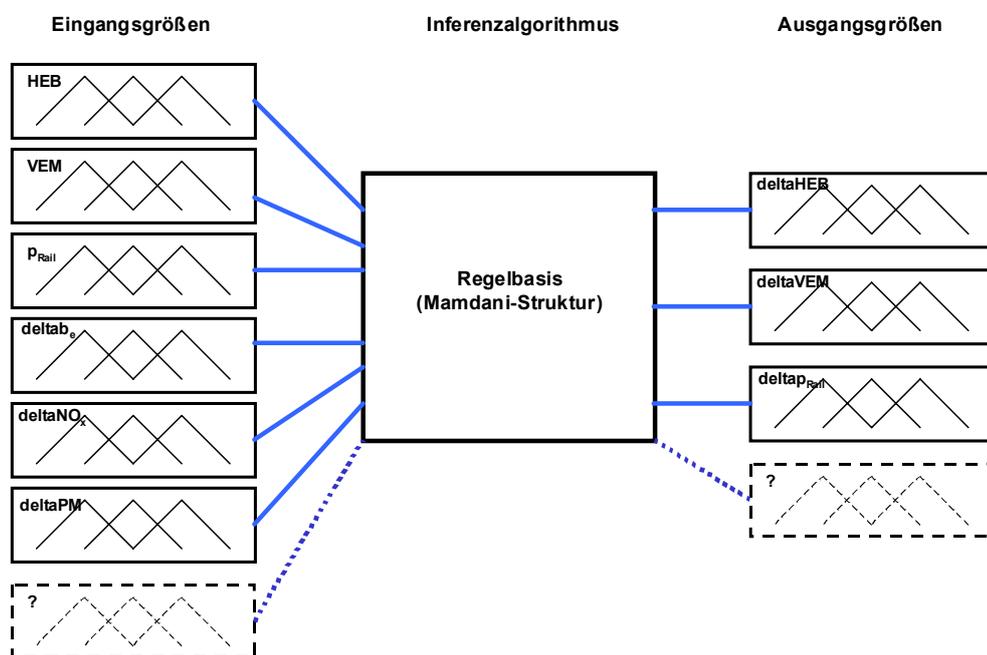


Abb. 7.14 Ein- und Ausgangsgrößen des Fuzzy-Inferenzalgorithmus zur SBPO

Entsprechend der in Abschnitt 7.2 vorgestellten allgemeinen Struktur des Fuzzy-Optimierers wurde zunächst ein Fuzzy-System zur stationären Betriebspunktoptimierung (SBPO) entworfen. Die definierten Ein- und Ausgangsgrößen des Inter-

preters zeigt **Abb. 7.14**. Neben den aktuellen Einstellungen für HEB , VEM und p_{Rail} werden dem Inferenzalgorithmus zusätzlich die letzte Änderung des spezifischen Kraftstoffverbrauchs $delta tab_e$ sowie jeweils ein Abstandsmaß zur Charakterisierung der aktuellen Grenzwertüber- bzw. -unterschreitung für NO_x und PM übergeben. Dabei gilt $delta NO_x = NO_x - G_{NO_x}$ bzw. $delta PM = PM - G_{PM}$. Die beiden Grenzwerte werden bei dieser Version des Optimierers für jeden Betriebspunkt getrennt vorgegeben.

Als Ausgangsgrößen liefert der Algorithmus unscharfe Werte für die im jeweiligen Optimierungsschritt umzusetzenden Änderungen der Führungsgrößen $delta HEB$, $delta VEM$ und $delta p_{Rail}$. Diese werden zu dem im letzten Optimierungsschritt gültigen Führungsgrößenvektor addiert. Mit dem so gebildeten neuen Führungsgrößen-Datensatz erfolgt dann eine erneute Berechnung (bzw. Vermessung) des Prozessverhaltens, auf deren Basis ein weiterer Optimierungsschritt stattfinden kann. Als Abbruchkriterium dient die Bedingung $delta tab_e = 0$, vorausgesetzt, dass keine Emissions-Grenzwerte verletzt sind. Wenn keine Verbesserung des spezifischen Kraftstoffverbrauchs mehr erzielt werden kann, gilt die Optimierung als abgeschlossen.

Zyklus- bzw. Drehzahl-/Drehmoment-Informationen werden von der beschriebenen Inferenz-Struktur nicht berücksichtigt. Die stationären Optimierungsaufgaben erfordern diese Daten prinzipiell nicht. Es ist jedoch möglich, zusätzliche Prozessdaten als Eingangsgrößen des Optimierers zu definieren, um, falls nötig, qualitativ bessere Ergebnisse zu erzielen. Diese Option ist in **Abb. 7.14** durch gestrichelte Ein- und Ausgangs-Symbole angedeutet.

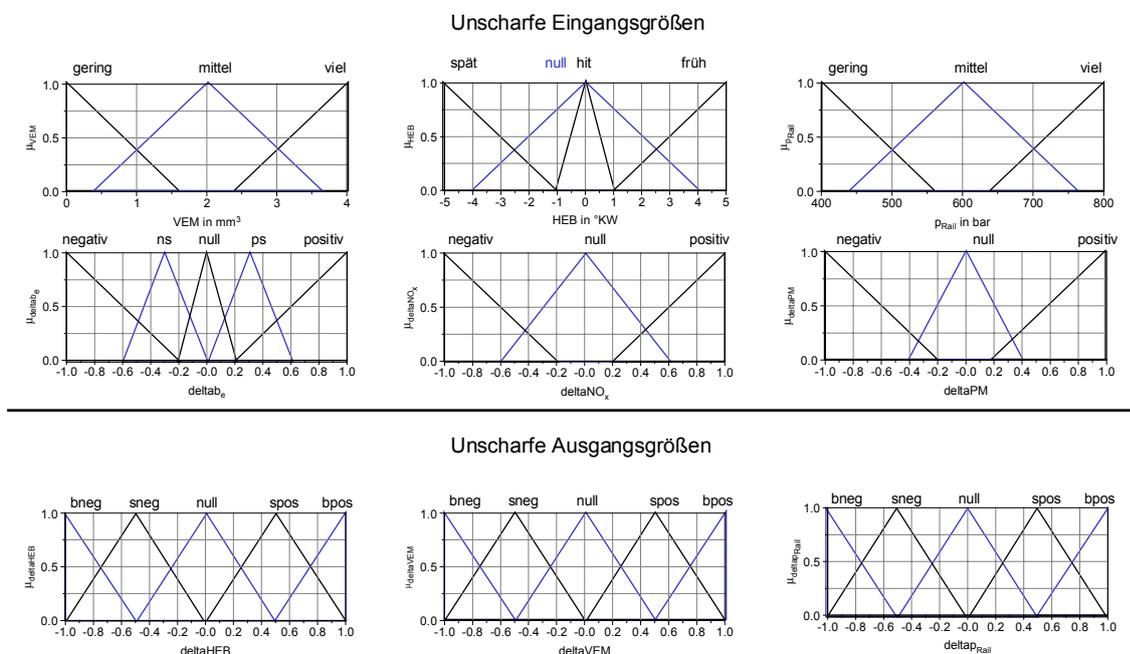


Abb. 7.15 Zugehörigkeitsfunktionen der verwendeten unscharfen Ein- und Ausgangsgrößen

Abb. 7.15 illustriert die zur Fuzzifizierung und Defuzzifizierung verwendeten Zugehörigkeitsfunktionen der jeweiligen Ein- und Ausgangsgrößen. Bis auf die Größen HEB , VEM und p_{Rail} handelt es sich bei allen Ein- bzw. Ausgangssignalen um normierte Größen (Definitionsbereich $[-1, 1]$). Folgende Normierungsgesetze gelten für das in Abschnitt 6.5 definierte Optimierungsproblem

$$\begin{aligned}
 \text{deltab}_e &= 10 \times (b_e - b_e^0), \\
 \text{deltaNO}_x &= 5 \times (NO_x - G_{NO_x}), \\
 \text{deltaPM} &= 10 \times (PM - G_{PM}), \\
 HEB &= HEB^0 + 0.5 \times \text{deltaHEB}, \\
 VEM &= VEM^0 + 1 \times \text{deltaVEM}, \\
 p_{Rail} &= p_{Rail}^0 + 100 \times \text{deltaHEB}.
 \end{aligned} \tag{7.11}$$

Die mit ⁰ indexierten Größen sind entsprechende Werte aus dem vorangegangenen Optimierungsschritt. Grenzwertüberwachungsalgorithmen verhindern undefinierte Zustände ausserhalb des Intervalls $[-1, 1]$.

Tab. 7.4 Regelbasis des Fuzzy-Interpreters zur SBPO

Regel	Linguistischer Ausdruck	Wichtigkeit
1	IF $\text{deltaNO}_x = \text{positiv}$ THEN $\text{deltaHEB} = \text{bneg}$, $\text{deltaVEM} = \text{bneg}$, $\text{deltap}_{Rail} = \text{bneg}$	1
2	IF $\text{deltaNO}_x = \text{negativ}$ THEN $\text{deltaHEB} = \text{bpos}$	1
3	IF $PM = \text{null}$ THEN $\text{deltap}_{Rail} = \text{null}$	1
4	IF $p_{Rail} = \text{viel}$ AND $\text{deltaPM} = \text{positiv}$ THEN $\text{deltap}_{Rail} = \text{negativ}$	1
5	IF $HEB = \text{spät}$ AND $VEM \neq \text{viel}$ AND $\text{deltab}_e \neq \text{positiv}$ AND $\text{deltaNO}_x = \text{negativ}$ AND $\text{deltaPM} \neq \text{positiv}$ THEN $\text{deltaVEM} = \text{bpos}$	1
6	IF $HEB = \text{spät}$ AND $VEM = \text{mittel}$ AND $\text{deltab}_e \neq \text{positiv}$ AND $\text{deltaNO}_x = \text{negativ}$ AND $\text{deltaPM} \neq \text{positiv}$ THEN $\text{deltaVEM} = \text{null}$	1
7	IF $HEB = \text{spät}$ AND $VEM = \text{viel}$ AND $\text{deltab}_e = \text{positiv}$ AND $\text{deltaNO}_x = \text{negativ}$ AND $\text{deltaPM} \neq \text{positiv}$ THEN $\text{deltaVEM} = \text{bneg}$	1
8	IF $p_{Rail} \neq \text{viel}$ AND $\text{deltaPM} = \text{positiv}$ THEN $\text{deltap}_{Rail} = \text{bpos}$	1
9	IF $\text{deltaPM} = \text{positiv}$ THEN $\text{deltaHEB} = \text{bpos}$, $\text{deltaVEM} = \text{null}$	1
10	IF $\text{deltaNO}_x = \text{null}$ AND $\text{deltaPM} = \text{negativ}$ THEN $\text{deltaHEB} = \text{null}$, $\text{deltaVEM} = \text{null}$, $\text{deltap}_{Rail} = \text{sneg}$	1
11	IF $\text{deltab}_e = \text{negativ}$ AND $\text{deltaNO}_x = \text{null}$ AND $\text{deltaPM} = \text{null}$ THEN $\text{deltaHEB} = \text{spos}$, $\text{deltaVEM} = \text{null}$, $\text{deltap}_{Rail} = \text{null}$	1
12	IF $HEB \neq \text{spät}$ AND $VEM = \text{gering}$ AND $\text{deltab}_e \neq \text{positiv}$ AND $\text{deltaNO}_x \neq \text{positiv}$ AND $\text{deltaPM} \neq \text{positiv}$ THEN $\text{deltaVEM} = \text{bpos}$	0.4
13	IF $HEB \neq \text{spät}$ AND $VEM \neq \text{gering}$ AND $\text{deltab}_e \neq \text{positiv}$ AND $\text{deltaNO}_x \neq \text{positiv}$ AND $\text{deltaPM} \neq \text{positiv}$ THEN $\text{deltaVEM} = \text{spos}$	0.4

Das zur Inferenzbildung verwendete Regelwerk ist in **Tab. 7.4** zusammengefasst.

Die zunächst definierten 13 Regeln ließen sich direkt aus der in Abschnitt 7.3 aufgestellten Wissensbasis zum Modellmotor ableiten. Dabei wurden nur die zur Erfüllung der stationären Optimierungsaufgabe notwendigen Zusammenhänge berücksichtigt. Der jeweilige Wichtungsfaktor gibt dabei an, wie stark die Prämissen der einzelnen Regeln bei der Bildung des linguistischen Ausgangsterms in **Gl. 7.9** eingehen. Das Ergebniss der *min*-Bildung wird vor der *max*-Operation mit dem entsprechenden Wichtungsfaktor multipliziert. Als Definitionsbereich der Wichtungsfaktoren gilt das Intervall $[0, 1]$.

Beispielhaft ist in **Abb. 7.16** der Vorgang des approximativen Schließens dargestellt. Sowohl NO_x - als auch PM -Grenzwert sind dabei noch überschritten, auch wenn offensichtlich eine der Abbruchbedingungen ($\delta_{ab_e} = 0$) bereits erfüllt ist. Eine weitere Änderung des Führungsgrößen-Vektors ist deshalb notwendig. Im gezeigten Beispiel erfolgt als Ergebnis der Interpretation der linguistischen Regeln eine Absenkung des Raildruckes um $\delta_{ap_{Rail}} = 11,7 \text{ bar}$, eine Spätverschiebung des Einspritzbeginnes um $\delta_{HEB} = 0,38 \text{ }^\circ KW$ und eine Erhöhung der Voreinspritzmenge um $\delta_{VEM} = 0,207 \text{ mm}^3$. Anhand der Grafik ist erkennbar, dass beim gewählten Eingangsvektor ausschließlich die Regeln 1, 3 und 12 zur Aktivierung der linguistischen Ausgangsterme beitragen. Man spricht dabei auch von *feuernden* Regeln. Alle anderen Regeln sind auf Grund der *UND*-Verknüpfung teilweise nicht erfüllter Voraussetzungen inaktiv, auch wenn Teile der Prämisse erfüllt sind.

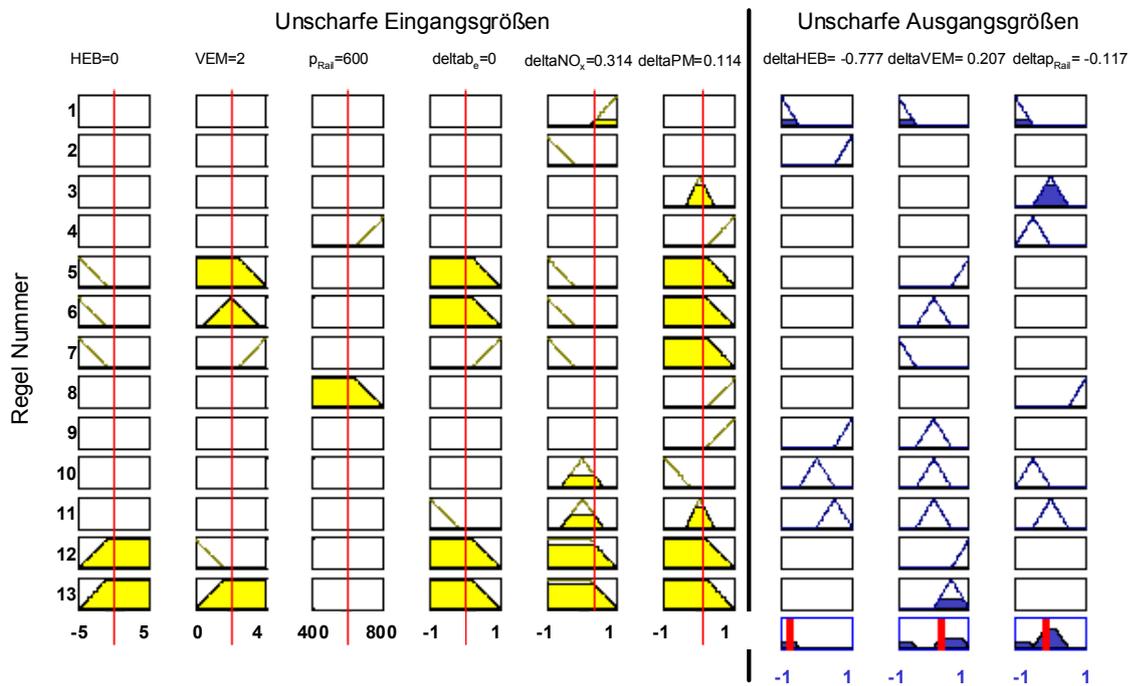


Abb. 7.16 Beispiel einer Inferenz-Bildung im Fuzzy-Optimierer

Erste Versuche mit diesem Regelwerk machten deutlich, dass insbesondere zur Vereinheitlichung des Konvergenzverhaltens bei unterschiedlichen Startpunkten der

Optimierung weitere Regeln in die Regelbasis aufgenommen werden müssen. Die Einführung des linguistischen Terms *hit* als unscharfen Wert der Grenzwertabweichung der Stickoxidemissionen⁶ und der Neudefinition der Regeln 10 und 11 führte zu einer deutlich besseren Annäherung des gefundenen Optimums an die vorgegebenen Grenzwerte. Die neu hinzu gekommenen Regeln 14 und 15 verbesserten die Konvergenz bei bereits unterschrittenen Grenzwerten für NO_x und PM .

Tab. 7.5 Zusätzliche Regeln zur Verbesserung des Konvergenzverhaltens des Optimierers

Regel	Linguistischer Ausdruck	Wichtigkeit
10	IF $\Delta NO_x = hit$ AND $\Delta PM = negativ$ THEN $\Delta HEB = null$, $\Delta VEM = null$, $\Delta p_{Rail} = neg$	1
11	IF $\Delta tab_e = negativ$ AND $\Delta NO_x = hit$ AND $\Delta PM = null$ THEN $\Delta HEB = spos$, $\Delta VEM = null$, $\Delta p_{Rail} = null$	1
14	IF $\Delta tab_e = negativ$ THEN $\Delta HEB = spos$, $\Delta VEM = null$, $\Delta p_{Rail} = spos$	1
15	IF $\Delta tab_e = ns$ THEN $\Delta HEB = spos$, $\Delta VEM = null$, $\Delta p_{Rail} = spos$	0.5

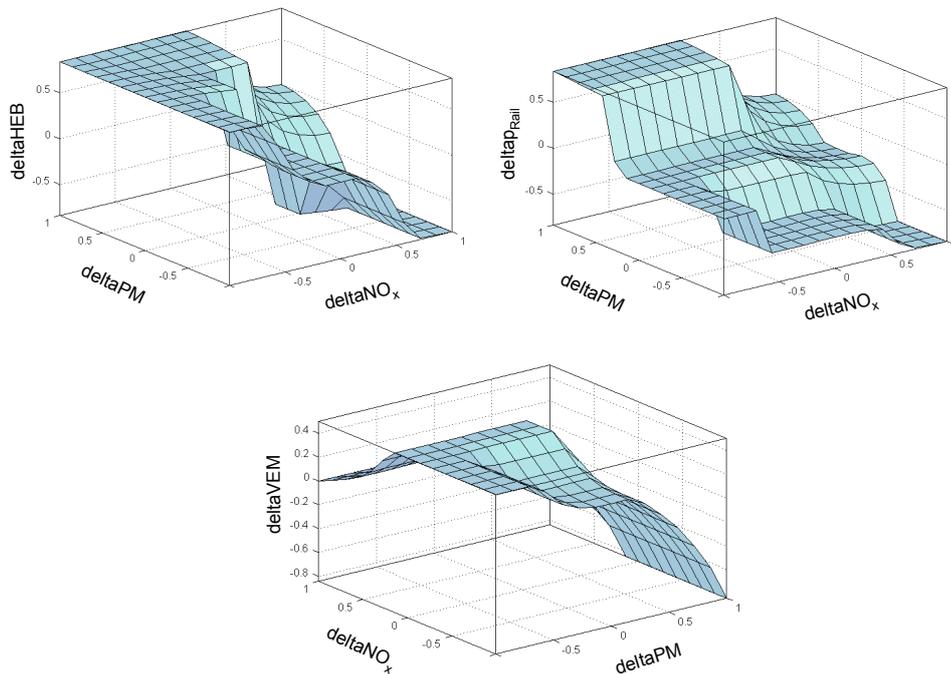


Abb. 7.17 Ausgewählte Regelflächen für den SBPO-Fuzzy-Optimierer, $HEB = 0 \text{ } ^\circ KW$, $VEM = 2 \text{ } mm^3$, $p_{Rail} = 600 \text{ } bar$, $\Delta tab_e = 0$

Über eine grafische Darstellung des Übertragungsverhaltens des Fuzzy-Optimierers,

⁶vgl. **Abb. 7.15** auf Seite 120

die so genannten Regelflächen, lässt sich die Antwortreaktion des Systems bei Variation der Eingangsgrößen nachvollziehen. In **Abb. 7.17** sind für die drei Ausgangsgrößen die Regelflächen in Abhängigkeit der grenzwertbezogenen NO_x - und PM -Emissionen dargestellt. Alle anderen Eingangsgrößen sind bei dieser Untersuchung konstant.

Es lässt sich z. B. für den Fall einer drastischen Überschreitung des NO_x -Grenzwertes ($\Delta NO_x = 1$) bei gleichzeitiger Unterschreitung des Partikelgrenzwertes ($\Delta PM = -1$) qualitativ der Verstellschritt $HEB=früher$, $VEM=kleiner$, $p_{Rail}=kleiner$ ableiten. Die Verstellschrittweiten sind dabei um so größer, je größer die jeweiligen Abstände zu den aktuellen Grenzwerten ausfallen.

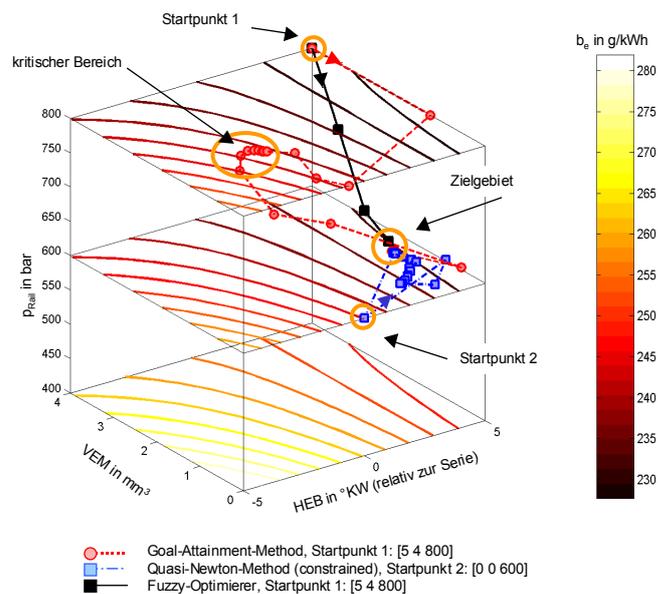


Abb. 7.18 Vergleich der Optimierungsläufe von Hill-Climbing-Verfahren und wissensbasiertem Ansatz im stationären Betriebspunkt ($n = 2250 \text{ min}^{-1}$, $p_{me} = 6.77 \text{ bar}$)

Einen beispielhaften Optimierungslauf des wissensbasierten Fuzzy-Optimierers zeigt **Abb. 7.18**. Zum Vergleich wurden nochmals zwei Optimierungsläufe mit Hill-Climbing-Verfahren eingetragen. Man erkennt, dass der Fuzzy-Optimierer deutlich schneller zum Optimum findet. Auch eine Verringerung der Schrittweite in der Nähe der Grenzwert-Isoflächen, wie sie bei den Hill-Climbing-Verfahren auftrat (vgl. **Abb. 6.5** auf Seite 98), ist hier nicht zu erkennen. Im gesamten modellierten Kennfeldbereich gelang es, unabhängig von der Wahl des Optimierungs-Startpunktes eine Verminderung der für den jeweiligen Optimierungslauf benötigten Berechnungen (entspricht Versuchen im Online-Verfahren) um den Faktor 10 zu erzielen. Im Beispiel werden anstatt $70\text{-}122^7$ Berechnungen nur 7 Modellrechnungen benötigt, um das Optimum zu erreichen. Wie **Tab. 7.6** (Zeile SBPO) zeigt, ist die Qualität des erreichten Abbruchpunktes nicht schlechter als die des absoluten Optimums, welches

⁷ja nach Verfahren und Startpunkt

die Hill-Climbing-Verfahren fanden. Prinzipbedingt variieren die Fuzzy-Ergebnisse bei unterschiedlichen Startpunkten etwas. Die teilweise Überschreitung der Emissionsgrenzwerte kann als unkritisch angesehen werden.

7.4.2 Fuzzy-Optimierer mit erweiterter Regelbasis

Zur zyklusbezogenen quasistationären Optimierung (ZQBPO) kann prinzipiell der gleiche Fuzzy-Mechanismus wie zur SBPO Verwendung finden. Allerdings muss im Vorfeld eine geeignete Auswahl repräsentativer Betriebspunkte mit ihren Wichtungsfaktoren und eine Festlegung entsprechender NO_x/PM -Grenzwertkombinationen für diese repräsentativen Betriebspunkte erfolgen.

Eine gleichzeitige Variation aller Stützpunkte der Führungsgrößen-Kennfelder, wie sie bei der ZQKFO in Abschnitt 6.5 durchgeführt wurde, ist bei Anwendung des wissensbasierten Ansatzes nicht sinnvoll. Eine heuristische Kennfeldoptimierung beinhaltet stets die Zusammenfassung geeigneter Kennfeldabschnitte zu Clustern und die anschließende getrennte Variation der entsprechenden Parametersätze. Eine sinnvolle linguistische Darstellung von Regeln zur parallelen Optimierung aller Kennfeldstützstellen kann nicht gefunden werden. Es wurde deshalb ein Ansatz gewählt, der die Effizienz der ZQBPO mit dem Freiheitsgrad-Vorteil der ZQKFO verbindet.

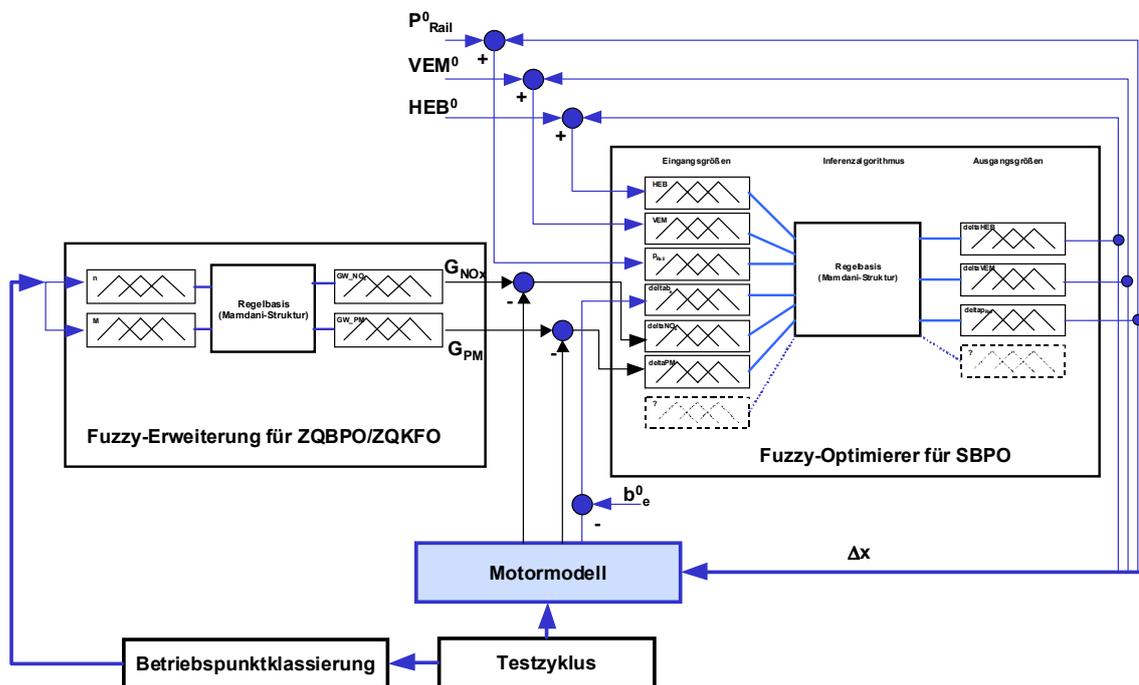


Abb. 7.19 Struktur der Offline Fuzzy-Optimierung mit Erweiterung zur ZQBPO

In Abb. 7.19 ist die erweiterte Struktur des Fuzzy-Mechanismus für die globale Kennfeldoptimierung dargestellt. Ein dem bereits bekannten SBPO-Interpreter vorgeschalteter Fuzzy-Algorithmus ermittelt in Anhängigkeit des quasistationären

Betriebspunktes die aktuellen Grenzwerte für Stickoxide und Partikel. Es erfolgt dann eine stationäre Optimierung des entsprechenden Betriebspunktes hinsichtlich des somit lokal definierten Optimierungsziels (minimaler Kraftstoffverbrauch bei Einhaltung der lokalen Emissionsgrenzwerte).

Der vorgeschaltete Fuzzy-Algorithmus muss die lokalen Grenzwerte unter Berücksichtigung des globalen Optimierungsziels vorgeben⁸.

Die sich bei den verwendeten Regeln ergebenden Regelflächen für die Fuzzy-Erweiterung sind in der **Abb. 7.20** dargestellt. Es wurde versucht, ein Verhalten zu modellieren, welches die tatsächlichen Spielräume der Emissionsabstimmung in den verschiedenen Motorkennfeldbereichen wiedergibt. Entsprechende Vermessungen des gesamten Motorkennfelds dienen dazu als Vorlage. So besteht zum Beispiel die Möglichkeit, in Bereichen geringer Last und niedriger Drehzahl wesentlich geringere Grenzwerte für die NO_x -Emission festzulegen und dafür im Bereich hoher Lasten und hoher Drehzahlen Grenzwert erhöhungen zuzulassen. So würde auch ein Applikationsingenieur bei der Kennfeldoptimierung verfahren. Voraussetzung für diese Annahme ist, wie bereits in Abschnitt 6.5 postuliert, dass alle Kennfeldbereiche mit gleicher Häufigkeit durchfahren werden (vgl. **Gl. 6.37** auf Seite 97).

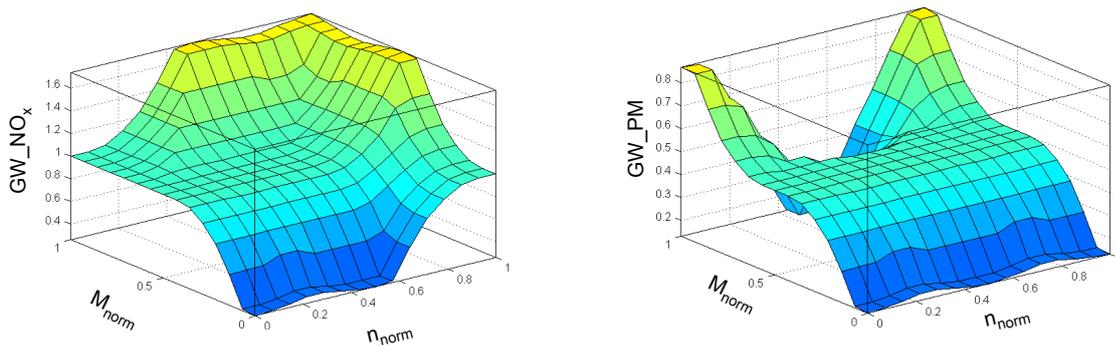


Abb. 7.20 Regelflächen des Fuzzy-Interpreters zur Ermittlung lokaler NO_x/PM -Grenzwertvektoren

Eine Adaption des Algorithmus zur schrittweisen Anpassung der lokalen Grenzwerte an die Zielvorgaben der globalen Optimierungsaufgabe war im hier dargestellten Entwicklungsstadium nicht vorgesehen. Vielmehr sollte untersucht werden, inwieweit das globale Ziel durch Verwendung intuitiver Mechanismen bei der Vorgabe der lokalen Grenzwerte eingehalten werden kann.

Als Vergleich dienen die Ergebnisse in Abschnitt 6.5. In **Tab. 7.6** sind die Ergebnisse der globalen Kennfeldoptimierung zusammengefasst. Mit deutlich weniger Iterationen (Faktor 4-12) erreicht der Fuzzy-Algorithmus ein den Hill-Climbing-Verfahren qualitativ gleichwertiges Optimierungsergebnis. Lediglich ein um 1% erhöhter Kraftstoffverbrauch ist als Nachteil festzustellen. Obwohl aus der Regelfläche für die Vor-

⁸Die Einhaltung des globalen Ziels kann zumindest für die Emissionswerte anhand von **Gl. 6.37** überprüft werden.

Tab. 7.6 Vergleich der Ergebnisse zwischen Hill-Climbing- und Fuzzy-Optimierung

Aufgabe/Verfahren	Quasi-Newton-Verfahren	Fuzzy-Optimierer	
SBPO von <i>HEB</i> , <i>VEM</i> und <i>p_{Rail}</i> für einen nominellen Betriebspunkt (exemplarisch $n = 2250 \text{ min}^{-1}$, $M = 105 \text{ Nm}$)	b_e	233; 7 g/kWh	230,4 – 232,2 g/kWh
	NO_x	3,00 g/kWh	3,00 – 3,01 g/kWh
	PM	0,25 g/kWh	0,25 – 0,26 g/kWh
	Iterationen	100	7
ZQBPO für <i>HEB</i> -, <i>VEM</i> - und <i>p_{Rail}</i> -Führungsgrößen-Kennfelder mit je 36 n/M -Kennfeld-Stützstellen)	$b_{e \text{ Zyklus}}$	246,3 g/kWh	248,9 g/kWh
	$NO_x \text{ Zyklus}$	3,00 g/kWh	3,04 g/kWh
	$PM \text{ Zyklus}$	0,189 g/kWh	0,20 g/kWh
	Iterationen	3025	733
ZQKFO für <i>HEB</i> -, <i>VEM</i> - und <i>p_{Rail}</i> -Führungsgrößen-Kennfelder mit je 36 n/M -Kennfeld-Stützstellen)	$b_{e \text{ Zyklus}}$	245,9 – 253,7 g/kWh	-
	$NO_x \text{ Zyklus}$	3,00 g/kWh	-
	$PM \text{ Zyklus}$	0,25 g/kWh	-
	Iterationen	4516 – 10011	-

gabe der NO_x -Grenzwerte entsprechend **Abb. 7.20** hervorgeht, dass bezogen auf den gesamten modellierten Kennfeldbereich wesentlich mehr Grenzwertüberhöhungen als Abschwächungen vorgenommen werden, wird der globale NO_x -Grenzwert ebenfalls nur um 1% überschritten.

Da es sich beim verwendeten Fuzzy-Ansatz um eine Kombination aus ZQBPO und ZQKFO handelt, ist ein Vergleich mit beiden Vorgehensweisen bei der klassischen Optimierung möglich.

Für variable Startkennfelder ergibt sich auch beim Fuzzy-Ansatz eine Streuung in den Ergebnissen. Da diese schon bei der SBPO als unerheblich eingestuft wurden, konnte bei der globalen Optimierung auf eine tiefere Untersuchung dieser Problematik verzichtet werden. Die im Ergebnis der Fuzzy-Optimierung stehenden Führungsgrößen-Kennfelder stimmen trotz gleicher globaler Ergebnisse lokal mit denen der Hill-Climbing-Verfahren nicht überein. Dieses Phänomen wurde bereits beim Vergleich zwischen den Ergebnissen der ZQBPO und der ZQKFO im Abschnitt 6.5 als Pareto-Optimalität im Sinne des globalen Optimierungsziels beschrieben.

Abb. 7.21 zeigt im direkten Vergleich die Ergebnisse der Fuzzy- und der Quasi-Newton-Optimierung (ZQBPO) im modellierten Parameterraum. Die jeweiligen Ergebnis-Kennfelder der Fuzzy-Optimierung sind dabei netzartig, die Ergebnisse der Quasi-Newton-Optimierung als durchgezogene Flächen dargestellt. Betrachtet man die quasistationären Ergebnis-Kennfelder für NO_x bzw. PM , so findet man in deren geometrischen Form (Fuzzy) die lokalen Grenzwert-Vorgaben entsprechend den Regelflächen in **Abb. 7.20** wieder. Die Ergebnisse der Quasi-Newton-Optimierung hingegen bewegen sich ausschließlich auf bzw. unter den Ebenen der für alle Betriebspunkte gleichsam gültigen Grenzwerte. Die optimalen Führungsgrößen-Kennfelder der Fuzzy-Optimierung verlaufen auf Grund der stützstellenspezifischen Grenzwertvorgaben insgesamt stetiger als die der Quasi-Newton-Optimierung. Das ist ein wei-

terer Vorteil des wissensbasierten Verfahrens. Eine nachträgliche Kennfeldglättung kann in den meisten Fällen entfallen.

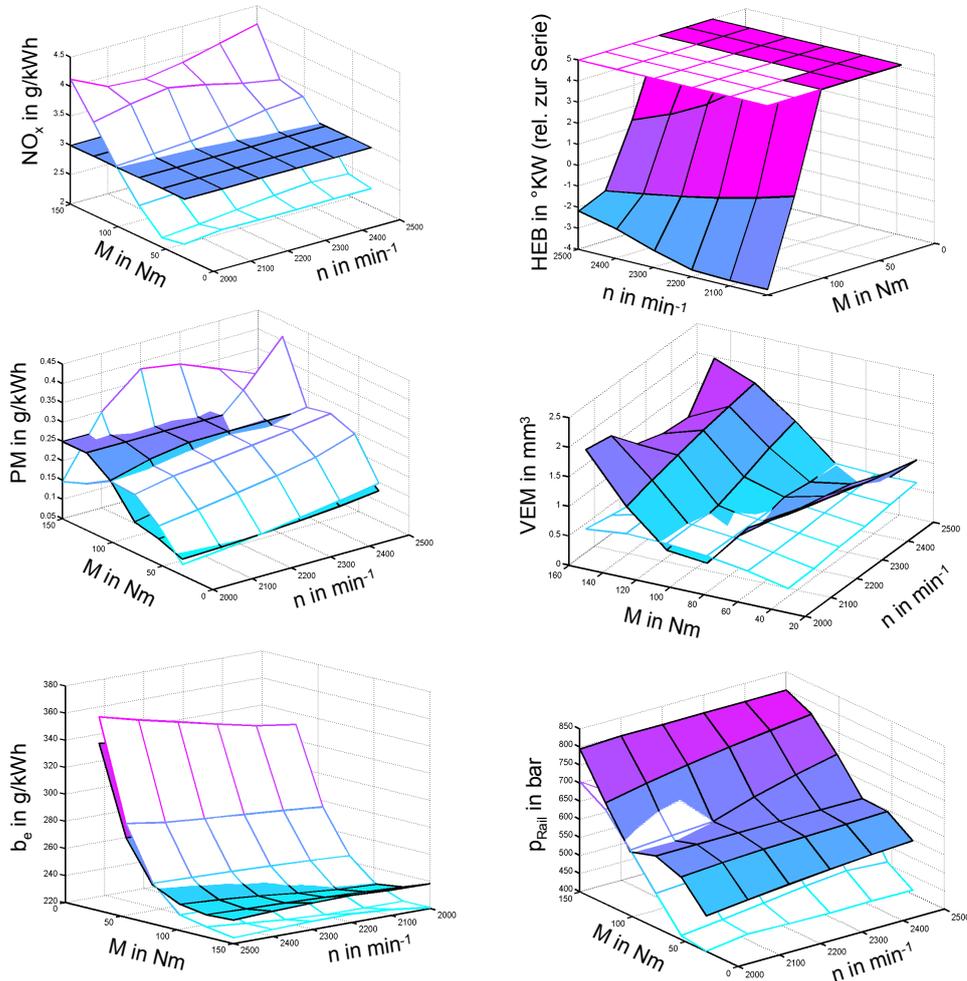


Abb. 7.21 Pareto-optimale Ergebnisse der globalen Optimierung (ZQBPO, links) und dazugehörige optimale Führungsgrößen-Kennfelder (rechts) für Quasi-Newton-Verfahren (Fläche, $b_{eZyklus} = 246.3 \text{ g/kWh}$) und Fuzzy-Optimierer (Gitter, $b_{eZyklus} = 248.9 \text{ g/kWh}$)

Zusammenfassend können die Ergebnisse mit dem wissensbasierten Fuzzy-Optimierer folgendermaßen charakterisiert werden:

- Der Fuzzy-Ansatz erlaubt eine regelbasierte Definition des Optimierungs-Verhaltens, die intuitiv aus bereits vorhandenem Expertenwissen über den Prozess abgeleitet werden kann.
- Die jeweiligen Regelbasen müssen nur die zur Lösung des speziellen Optimierungsproblems benötigten Regeln enthalten.

- Anhand eines komplexen Optimierungsbeispiels konnte nachgewiesen werden, dass der Fuzzy-Optimierer sowohl für die lokale stationäre als auch für die globale quasistationäre Kennfeldoptimierung eine um den Faktor 4-10 kleinere Anzahl an Funktionsberechnungen, respektive Motorvermessungen im Falle der Online-Optimierung, benötigt als klassische Hill-Climbing-Verfahren.
- Der hier vorgestellte wissensbasierte Fuzzy-Algorithmus eignet sich damit insbesondere zur Online-Prozessoptimierung von Verbrennungsmotoren am Motorenprüfstand.

7.5 Erweiterung des Fuzzy-Optimierers für dynamische Optimierungsaufgaben

In Abschnitt 4.5 wurden verschiedene Ansätze zur mathematischen Interpretation und Lösung dynamischer Optimierungsprobleme an Verbrennungsmotoren vorgestellt. Dazu zählen das Kennfeld-Clustering und die Kennfelderweiterung. Unabhängig davon, welche der beiden Methoden im konkreten Anwendungsfall zum Einsatz kommt, müssen entsprechende linguistische Zusammenhänge des dynamischen Motorprozesses bekannt sein und diese über die Fuzzy-Regelbasis dem Algorithmus zugänglich gemacht werden.

Grundlage dafür bildet wiederum die Motorenwissensbasis, die um dynamische Aspekte erweitert werden muss. Im Rahmen dieser Arbeit sind dazu erste Versuchsreihen durchgeführt worden. Um spezielle dynamische Besonderheiten des Motorbetriebs bezüglich seiner Emissionsentwicklung herausarbeiten zu können, wurde ähnlich dem in Abschnitt 5.2 beschriebenen Vorgehen zur stationären Prozessoptimierung ein D-optimaler Versuchsplan entwickelt. Ein Motorversuch bestand dabei aus mehreren hintereinander am dynamischen Motorenprüfstand gefahrenen Drehzahlrampen unter Einhaltung eines konstanten Drehmoments. Eine Analyse des realen Fahrzeugbetriebs hinsichtlich seiner Beschleunigungscharakteristika führte zu diesem Ansatz. Entsprechende motortechnische Zusammenhänge bei Verwendung von Drehmomentrampen wurden bereits in Abschnitt 4.5.4 dargestellt. Die Rampenparameter Steilheit dn/dt und Drehmoment M stellen Faktoren des Versuchsplans und damit Parameter des zu findenden Modells dar. Folgende Parametervariationen wurden im Rahmen des Versuchsplans untersucht:

1. dn/dt im Intervall $[50 \text{ min}^{-1} \text{ s}^{-1}, 400 \text{ min}^{-1} \text{ s}^{-1}]$
2. M im Intervall $[50 \text{ Nm}, 180 \text{ Nm}]$
3. HEB im Intervall $[-5^\circ \text{ KW}, +5^\circ \text{ KW}]$ (relativ zur Serie)
4. VEM im Intervall $[0 \text{ mm}^3, 4 \text{ mm}^3]$
5. p_{Rail} im Intervall $[400 \text{ bar}, 800 \text{ bar}]$

Bei den Versuchen handelt es sich nicht um stationäre Betriebspunkte, sondern um zeitabhängige Verläufe. Die Zielgrößen NO_x - bzw. Partikelemissionen und b_e stellen somit zyklusspezifische Größen dar und werden durch Integration der entsprechenden Verläufe gebildet. Zur Verringerung des relativen Messfehlers wird die Rampe eines jeden Versuches 5 mal hintereinander gefahren. Während jedes dynamischen Versuchs erfolgt die Ausgabe der HEB - , VEM - und p_{Rail} -Parameterwerte entsprechend den Parametervorgaben. In den Phasen zwischen den Rampen eines jeden Versuchs ($dn/dt = 0$, stationär, intransient) gelten hingegen die Serieneinstellungen der Führungsgrößen-Kennfelder. Damit werden tatsächlich nur die signifikanten Einflüsse der Führungsgrößenänderungen auf die dynamischen Betriebsphasen herausgearbeitet.

Über die Bildung entsprechender Polynommodelle und einen Vergleich zwischen quasistationärem und dynamischem Modellansatz können aus diesen Messdaten linguistische Regeln für das dynamische Motorprozessverhalten abgeleitet werden. Diese Untersuchungen sind Gegenstand derzeitiger Forschungsprojekte und werden an dieser Stelle nicht weiter ausgeführt.

Als Struktur für einen entsprechenden Fuzzy-Optimierer zur dynamischen Kennfeldoptimierung eignet sich ebenfalls der in **Abb.7.19** vorgestellte Ansatz. Lediglich der Block *Fuzzy-Erweiterung* müsste für den Fall der Verwendung erweiterter Führungsgrößen-Kennfelder um dynamische Eingangsgrößen ergänzt werden (z. B. dn/dt). Insbesondere dann, wenn die Analyse der dynamischen Versuche völlig neue Zusammenhänge ergibt, ist auch eine Erweiterung der linguistischen Variablen und Terme des Haupt-Inferenzblocks notwendig.

Kapitel 8

Automatisierungskonzepte zur wissensbasierten Online-Optimierung

8.1 Schnittstellen zu Motorenprüfständen

Unter dem Druck ständig wachsender Anforderungen an die Prüfgenauigkeit und die Prüfmethodik sind Motorenprüfstände in den letzten Jahren zu komplexen, vernetzten elektronischen Systemen weiterentwickelt worden. Der Benutzer agiert mittels umfangreicher Softwaresysteme mit verschiedenster mikroprozessorgesteuerter Mess- und Steuerungstechnik. Um die Entwicklung und die Kompatibilität zukünftiger Systeme verschiedener Hersteller zu erleichtern, bemüht sich die ASAM-Vereinigung (Association for Standardisation of Automation and Measurement Systems) um eine Standardisierung entsprechender Schnittstellen zwischen den Teilsystemen der Prüfstandsautomatisierung, [2].

Abb. 8.1 verdeutlicht die bis heute vorliegenden Schnittstellenstandards. Unter ASAM-ACI¹ ist die Schnittstelle zwischen dem Prüfstands-Automatisierungssystem und einem übergeordneten Optimierungssystem definiert. Auf einer hochsprachigen Protokollebene tauschen Optimierer und Prüfstand aufbereitete Messdaten und Führungsgrößen(-Kennfelder) bzw. Prüfdaten aus. Das Optimierungssystem bearbeitet in dieser Konzeption ausschließlich die zur Optimierung notwendigen Algorithmen. Die Datenübergabe zum Motorsteuergerät und zur Prüfstands-Hardware übernimmt das Prüfstandsautomatisierungssystem über die Schnittstellen ASAM-MCD² bzw. ASAM-GDI³. Auch eine direkte Kommunikation zwischen Optimierungssystem und Motorsteuergerät über ASAM-MCD ist denkbar, falls entsprechende Features vom Automatisierungssystem nicht zur Verfügung gestellt werden

¹Automatic Calibration Interface

²Measurement Calibration and Diagnostics

³Generic Device Interface

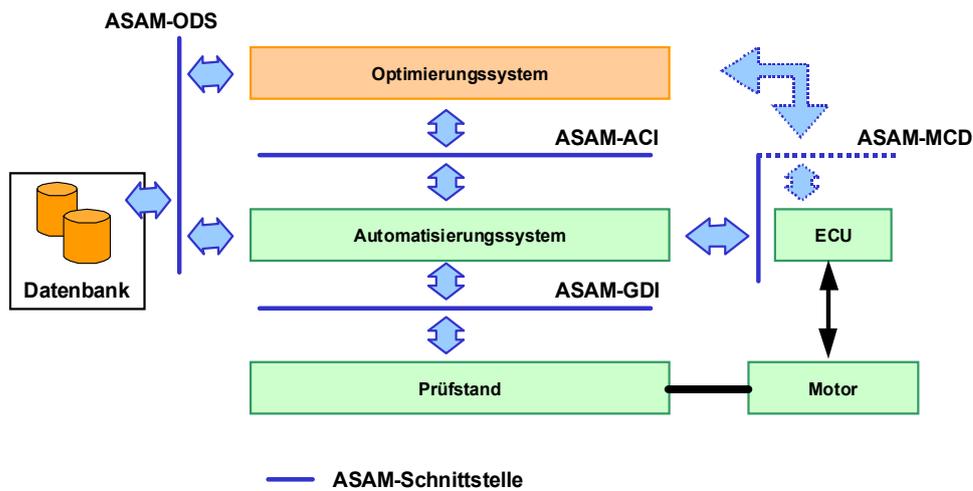


Abb. 8.1 Standardisierte Schnittstellen für Systeme zur Motorenprüfung

oder spezielle Funktionen im Steuergerät direkt angesprochen werden sollen⁴.

Mit ASAM-ODS⁵ steht für die Software-Komponenten am Motorenprüfstand eine gemeinsame Schnittstelle zu Datenbanken zur Verfügung, auf die sowohl in einer Versuchs- als auch in einer Simulationsumgebung zugegriffen werden kann. Der in Abschnitt 7.2 beschriebene Datenbankzugriff auf bereits durchgeführte Optimierungsläufe könnte z. B. mittels ASAM-ODS realisiert werden.

Alle ASAM-Protokoll-Standards sind am oberen Ende der Kommunikationshierarchie des ISO/OSI-Referenzmodells angeordnet. Ihre physikalische Realisierung ist über verschiedene Medien möglich. Ebenso ist ihre Verwendung als Erweiterung allgemeingültiger Protokollstandards⁶ denkbar. Das an der TU Berlin, Fachgebiet Verbrennungskraftmaschinen entwickelte Optimierungssystem DOMAIN III⁷ ist ein offenes Software-Tool, welches entsprechend der ASAM-ACI Spezifikation ausgelegt wurde. Da die genaue Definition des Protokollaufbaus zum Zeitpunkt der Erstellung des Systems noch nicht vorlag, wurde zunächst ein proprietäres Protokoll umgesetzt, welches sich jedoch leicht an zukünftige Standards anpassen lässt.

⁴Viele kommerzielle System nutzen den so genannten ASAP-Standard zur Kommunikation zwischen Steuergerät und übergeordneten Systemen, [50]. Diese Definition gilt als Vorgänger von ASAM-MCD.

⁵Offline Data Services

⁶Das Profibus-FDL-Protokoll zum Beispiel ist ein gängiges Industrie-Protokoll in der ISO/OSI-Ebene 2

⁷Diesel Engine Operation Management Aided by Information Technology

8.2 Online-Optimierungssystem DOMAIN III

8.2.1 Online-Systemkonzept

Im Rahmen eines an der Forschungsstelle unter Mitwirkung des Verfassers bearbeiteten FVV-Forschungsprojektes wurde das Software-Tool DOMAIN III als Online-Optimierer für Diesel-Motor-Steuergeräte konzipiert, [78]. Neben klassischen Suchverfahren kamen zur Optimierung Algorithmen nach einer Evolutionsstrategie zum Einsatz.

Die Benutzeroberfläche von DOMAIN III ist *WINDOWS*[®]-typisch aufgebaut, **Abb. 8.2**, sodass die Systemfunktionalität flexibel über Menüs und Auswahldialoge gesteuert werden kann.

Die Messwerte der Motorprozessgrößen und deren Bewertung für unterschiedliche Testzyklusdurchläufe lassen sich tabellarisch und in zweidimensionalen Zeitverlaufdiagrammen darstellen (rechts im Bild). Die Stützstellen der Führungsgrößen-Kennfelder, die als Ergebnis der Optimierung generiert werden, können in Tabellen und in dreidimensionalen Kennfeldgraphen dargestellt werden (links im Bild).

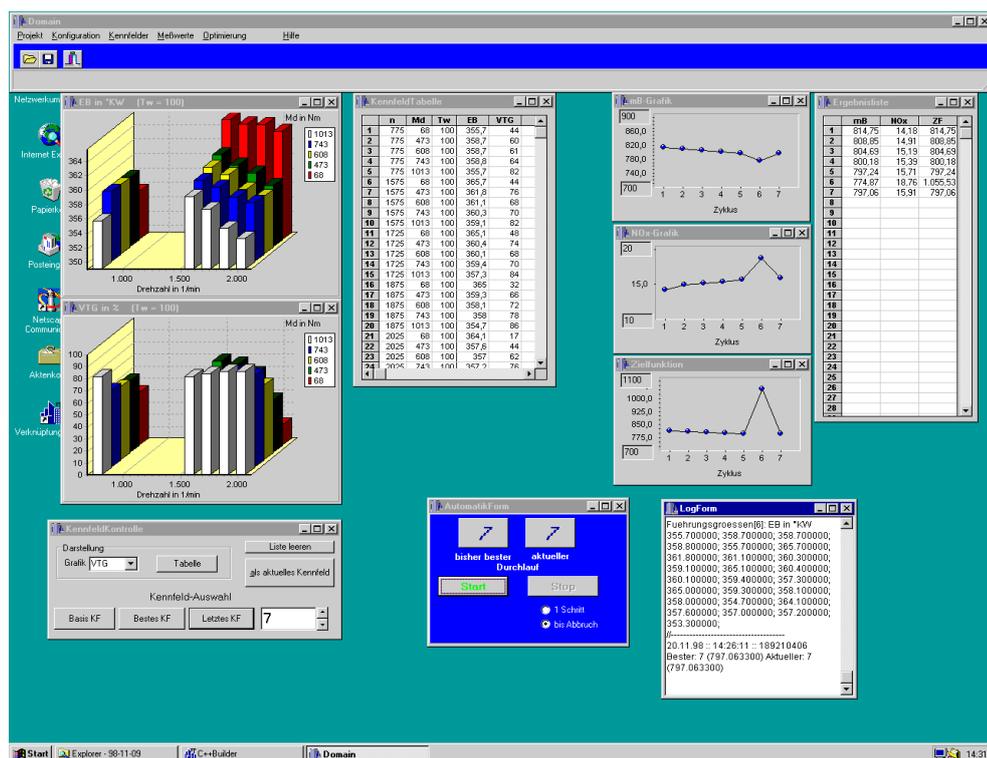


Abb. 8.2 Benutzeroberfläche von DOMAIN III

Unterstützt werden sowohl konventionelle 3-dimensionale Kennfeldstrukturen als auch die in Abschnitt 4.5.4 vorgestellten erweiterten Kennfelder. Im letzteren Fall muss eine direkte Kommunikation mit dem Motorsteuergerät erfolgen, da solche

Strukturen im Allgemeinen nicht durch das Prüfstandsautomatisierungssystem unterstützt werden. Im automatisierten Systembetrieb wird die Optimierung bis zur Erfüllung eines Abbruchkriteriums durchgeführt, das beispielsweise durch die maximale Anzahl von Optimierungszyklen oder die minimale weitere Verbesserung der Zielfunktion definiert ist.

Neben dem automatisierten Systembetrieb ist auch ein interaktiver, manueller Betrieb möglich, in dem der Benutzer das Führungsgrößenkennfeld direkt beeinflussen kann und so mit seinem Expertenwissen günstige Startbedingungen setzen oder die Ergebnisse des Systems verifizieren kann.

8.2.2 Implementierung des wissensbasierten Optimierers

Zur Schaffung einer höheren Systemflexibilität von DOMAIN III wurde eine Schnittstelle zu MATLAB/SIMULINK[®] realisiert (**Abb. 8.3**). Durch die externe Funktionalität des MATLAB-Pakets lassen sich leistungsfähige Optimierungsalgorithmen auf einfache Weise über die Benutzung von Optimierungsskripten implementieren. Eine effiziente und zügige Implementierung der in dieser Arbeit vorgestellten wissensbasierten Fuzzy-Algorithmen in DOMAIN III ist somit gegeben.

Über die realisierte Schnittstelle hat MATLAB[®] vollen Zugriff auf die DOMAIN-Datensätze, sodass auch eine Visualisierung komplexer Datensätze einfach über die MATLAB[®]-Grafikbibliothek zu realisieren ist.

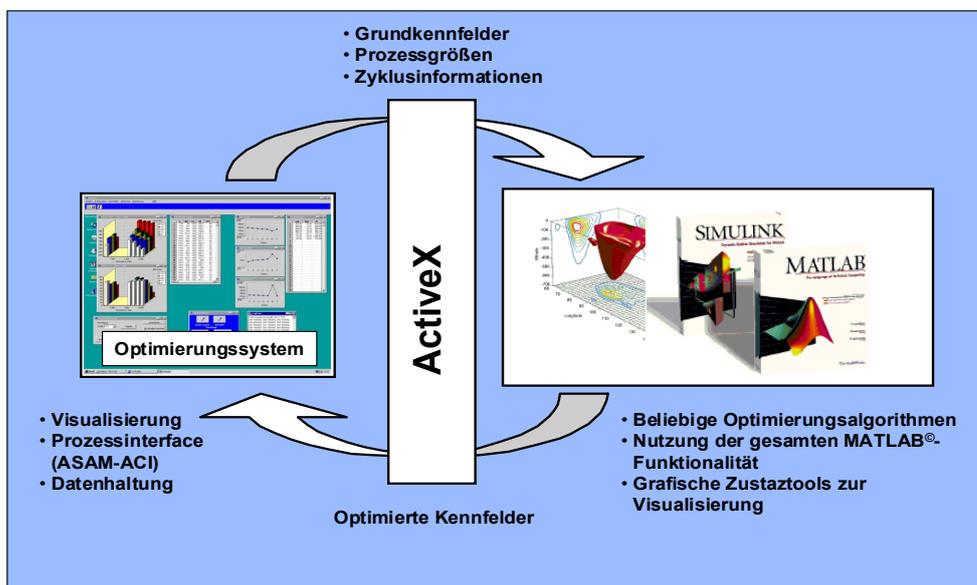


Abb. 8.3 MATLAB[®]-Schnittstelle des Optimierungssystems

Eine Übertragung der für den Offline-Einsatz gewonnenen Erkenntnisse auf die Online-Optimierung am dynamischen Motorenprüfstand ist durch die Kombination von DOMAIN III mit den unter MATLAB[®] entwickelten Fuzzy-Strategien im vollen Umfang gewährleistet.

Kapitel 9

Zusammenfassung

In dieser Arbeit wurde ein neuartiges wissensbasiertes Verfahren zur Online-Optimierung der Führungsgrößen-Kennfelder aufgeladener Dieselmotoren vorgestellt. Als Modelltriebwerk diente ein 4-Zylinder-DI-Dieselmotor mit Common-Rail-Einspritzsystem.

Die Wirkungsweise und das Potential des Verfahrens wurden im Rahmen einer Offline-Optimierung an einem mathematischen Modell des verwendeten Triebwerks nachgewiesen. Dieses Motormodell wurde mit Hilfe von Methoden der statistischen Versuchsplanung erstellt und beschreibt die stationären Prozesszusammenhänge zwischen den Eingangsgrößen Motordrehzahl, Motordrehmoment, Haupteinspritzbeginn, Piloteinspritzmenge und Raildruck und den Prozessgrößen Stickoxid- und Partikelemission bzw. spezifischer Kraftstoffverbrauch. Es wurde aufgezeigt, dass sich neuronale Netze der Klasse Multi-Layer-Perceptron auf Grund ihrer schlechten Inter- bzw. Extrapolationsgüte bei unvollständiger Versuchsdatenbasis nicht als Motormodell eignen. Radial-Basis-Netzwerke und Polynomansätze, die mit der Response-Surface-Methode basierend auf einem statistisch verifizierten Versuchsplan erstellt wurden, bilden hingegen alle signifikanten Prozesszusammenhänge in ausreichender Qualität ab.

Optimierungsziel der dieselmotorischen Prozessoptimierung stellt in der Regel die Minimierung des zu erwartenden Kraftstoffverbrauchs unter Einhaltung legislativer Emissionsgrenzwerte dar. Eine Optimierung kann dabei unter stationären oder zykluspezifischen Gesichtspunkten durchgeführt werden, wobei zusätzlich zwischen quasistationärer und echter dynamischer Optimierung unterschieden werden muss. Zur Schaffung einer Vergleichsbasis fand mit Hilfe des erstellten Motormodells zunächst eine Optimierung mit klassischen Hill-Climbing-Verfahren statt.

Schon ihre Anwendung bei der zyklusorientierten quasistationären Kennfeld-Optimierung (ZQKFO) machte deutlich, dass für vielparametrische Prozesse und konkurrierende Zielgrößen eine effiziente Bearbeitung der Optimierungsaufgabe online am Motorenprüfstand nicht möglich ist. Da zur Findung des globalen Optimums sehr kleine Abbruchschrittwerten für die Optimierung definiert werden müssen, ist mit einer unvermeidbar hohen Versuchsanzahl am Prüfstand zu rechnen. Des Weiter-

ren konnte festgestellt werden, dass bedingt durch die Vielzahl an Optimierungsparametern bei der Kennfeldoptimierung keine einzelne, absolut optimale Kennfeldbelegung existiert. Vielmehr erfüllt eine unendlich große Klasse von pareto-optimalen Führungsgrößen-Kennfeld-Belegungen das angestrebte Optimierungsziel.

Im Gegensatz zu den numerischen Hill-Climbing Verfahren arbeitet der vorgestellte wissensbasierte Fuzzy-Optimierer durch die Interpretation bereits bekannten Expertenwissens zum untersuchten Motorsystem. Die in einer motortypspezifischen Wissensbasis abgelegten linguistischen Regeln können direkt zur Bildung einer Fuzzy-Inferenz mit den unscharfen Eingangsgrößen des Optimierers verwendet werden. Wie entsprechende Vergleiche mit Literaturangaben gezeigt haben, lassen sich die aufgestellten qualitativen Regeln durchaus auf andere mit Common-Rail ausgerüstete Triebwerke der gleichen Hubraumklasse übertragen. Um den Optimierer auch auf nockengesteuerte Einspritzsysteme übertragen zu können, müsste die Wissensbasis allerdings entsprechend erweitert werden.

Vergleichende Optimierungsläufe am erstellten Motormodell haben gezeigt, dass mit dem wissensbasierten Optimierungsverfahren durchschnittlich eine 10-fache Beschleunigung des Optimierungsvorganges möglich ist. So konnte zum Beispiel die benötigte Versuchszahl zur Findung optimaler Führungsgrößen-Kennfelder (ZQK-FO) von ca. 10000 auf unter 800 verringert werden, was den Einsatz dieser Methodik zur Online-Optimierung am Motorenprüfstand äußerst sinnvoll erscheinen lässt.

Anhand entsprechender Voruntersuchen zum dynamischen Verhalten direkteinspritzender Dieselmotoren konnte ein gewisses Potential der dynamischen Optimierung hinsichtlich einer Verbesserung des Emissions-Kraftstoffverbrauchs-Zielkonfliktes aufgezeigt werden. Um dieses im gesamten Motorkennfeld nutzen zu können, muss eine Erweiterung des Definitionsraums der Führungsgrößen-Kennfelder um eine dynamische Beschreibungsgröße erfolgen. Die damit verbundene Einführung zusätzlicher Freiheitsgrade bei der Optimierung führt jedoch zur weiteren Komplexitätssteigerung der Optimierungsaufgabe. Eine effiziente Bearbeitung einer solchen erweiterten Kennfeldoptimierung unter Berücksichtigung von dynamischen Prozesszusammenhängen kann nur noch mit wissensbasierten Ansätzen erfolgen. Erste Vorschläge zur Erstellung einer Wissensbasis für solche hochkomplexen Optimierungsaufgaben wurden erarbeitet.

Mit den vorgestellten wissensbasierten Optimierungsroutinen lässt sich das Potential heutiger Motorsysteme durch einen effizienteren Entwicklungsprozess wesentlich kostengünstiger ausschöpfen, als das mit derzeit am Markt verfügbaren Optimierungssystemen möglich ist. Durch die konsequente Nutzung bereits eingeführter Software-Schnittstellen ist eine Implementierung dieser Algorithmen in bestehende Prüfstandsautomatisierungssysteme möglich.

Literaturverzeichnis

- [1] ARSIE, I.; ET. AL.: *Information Based Selection of Neural Networks Training Data for S.I. Engine Mapping*. SAE-Paper 2001-01-0561, 2001.
- [2] ASSOCIATION FOR STANDARDISATION OF AUTOMATION AND MEASURING SYSTEMS (ASAM): *ASAM-Standardisations*. <http://www.asam.de>, 2001.
- [3] BANDEMER, H.; BELLMANN, A.: *Statistische Versuchsplanung*. BSB Teubner Verlagsgesellschaft, Leipzig, 3. Auflage, 1988.
- [4] BAUDER, R.; DORSCH, W.; MIKULIC, L.; PÖLZL, H.-W.; REUSS, T.: *Der neue V6-TDI-Motor von Audi, Teil 2. Thermodynamik*. MTZ, 58(10):620–626, 1997.
- [5] BAUER, M.: *Flexible Online-Prozeßoptimierung mit integrierten adaptiven Modellen*. Dissertation, TU Berlin, 1997.
- [6] BERNARD, P.: *The Control Design Automation Development Environment*. In: *1st International Automotive Conference*, Seiten 1–30, Stuttgart, 1998.
- [7] BERNDT, R.; GRIGORIADIS, P.; NICKEL, J.; PUCHER, H.: *Erweiterte Darstellung und Extrapolation von Turbolader-Kennfeldern als Randbedingungen der Motorprozesssimulation*. Zwischenbericht über das Vorhaben Nr. 754, Forschungsvereinigung Verbrennungskraftmaschinen, Dresden, 2001.
- [8] BERTRAM, T.: *Zur systematischen Analyse und Synthese nichtlinearer Systeme mit Fuzzy-Logik*. VDI-Fortschrittberichte Nr. 496, Reihe 8, VDI-Verlag, Düsseldorf, 1986.
- [9] BERTRAM, T.; SVARICEK, S.: *Kompensation der trockenen Reibung mit Hilfe von Fuzzy-Logik*. at, 41:180–184, 1993.
- [10] BOTHE, H.-H.: *Neuro-Fuzzy-Methoden*. Springer Verlag, Berlin, Heidelberg, 1. Auflage, 1998.
- [11] BREDENBECK, J.: *Motorprozess-Simulation als Wissensbasis*. Dissertation, TU Berlin, 1996.
- [12] BREDENBECK, J.: *Design of Experiments for Online Optimization of Internal Combustion Engines*. In: *VDI-Berichte 1470*, 1999.

- [13] BREDENBECK, J.: *Statistische Versuchsplanung für die Online-Optimierung von Verbrennungsmotoren*. In: *Tagungsband Mess- und Versuchstechnik im Fahrzeugbau, VDI-Berichte 1470*, Seiten 1–13, VDI-Gesellschaft Fahrzeug- und Verkehrstechnik, Mainz, 1999.
- [14] BRONSTEIN, I. N.; SEMENDJAJEW, K. A.: *Taschenbuch der Mathematik*. Verlag Neuka, Moskau, 24. Auflage, 1989.
- [15] BUCHWALD, R.: *Motorprozesssimulation als Werkzeug zur Optimierung von Ottomotoren*. Dissertation, TU Berlin, 2000.
- [16] CLARKE, G. M.; KEMPSON, R. E.: *Introduction to the Design and Analysis of Experiments*. Arnold, Hodder Headline Group, London, 1. Auflage, 1997.
- [17] COSFELD, R.; ET AL.: *Möglichkeiten und Grenzen elektronischer Motorsteuerungen*. In: *16. Internationales Wiener Motorensymposium*, Band 239 der Reihe *VDI-Fortschritt-Berichte 12*, Seiten 148–183, Wien, 1995.
- [18] DAEN, A.; VOSS, D.: *Design and Analysis of Experiments*. Springer Verlag, Berlin, New York, 1. Auflage, 1999.
- [19] DRECHSEL, D.: *Reglerbasierte Interpolation und Fuzzy Control*. Vieweg Verlag, Braunschweig, Wiesbaden, 1. Auflage, 1996.
- [20] FLETCHER, R.; POWELL, M. J. D.: *A Rapidly Convergent Descent Method for Minimization*. *Computer Journal*, 6(1):163–168, 1963.
- [21] FRÜWIRTH, R.; REGLER, M.: *Monte-Carlo-Methoden - Eine Einführung*. Bibliographisches Institut, Mannheim, Wien, Zürich, 1. Auflage, 1983.
- [22] GILL, P. E.; ET. AL.: *Procedures for Optimization Problems with a Mixture of Bounds and General Linear Constraints*. *ACM Transactions on Mathematical Software*, 58:282–298, 1984.
- [23] GÖBEL, U.; MUSSMANN, L.; TILLAART, J. V. D.: *The Influence of Storage Components on Catalytic Exhaust Gas Purification and their Significance for On Board Diagnosis*. In: *8. Aachener Kolloquium Fahrzeug- und Motorentchnik, Sonderdruck*, Seiten 275–290, Aachen, 1999.
- [24] HEIDER, G.: *Rechenmodell zur Vorausberechnung der NO-Emissionen von Dieselmotoren*. Dissertation, TU München, 1996.
- [25] HEIDT, V.; SCHUBERT, E.: *Ansätze für ein zylinderdruckgeführtes Motormanagementsystem*. In: *15. Internationales Wiener Motorensymposium*, Band 205 der Reihe *VDI-Fortschritt-Berichte 12*, Seiten 116–138, Wien, 1994.
- [26] HOFFMANN, U.; HOFMANN, H.: *Einführung in die Optimierung*. Verlag Chemie GmbH, Weinheim/Bergstr., 1. Auflage, 1971.

- [27] HOFFMENN, K.-H.; HUMMEL, K.; MADERSTEIN, TH.; PETERS, A.: *Das Common-Rail-Einspritzsystem - ein neues Kapitel der Dieseleinspritztechnik*. MTZ, 58(10):572–582, 1997.
- [28] HOLZMANN, H.; HALFMANN, C.; ISERMANN, R.: *Neuro-Fuzzy-Modeling of Automotive SI-Engine Characteristics*. In: *IFAC Workshop on Advanced Automotive Control*, Ohio, USA, 1994.
- [29] ISERMANN, R.: *Diagnosemethoden Dieselmotor*. In: *FVV-Heft R509*, Seiten 27–50, Frankfurt/M., 2001.
- [30] ISERMANN, R.; HAFNER, M.; MÜLLER, N.; SCHÜLER, M.: *Der Einsatz neuronaler Netze zur Modellierung, Steuerung und Regelung von Verbrennungsmotoren*. In: *3. Stuttgarter Symposium Verbrennungsmotoren*, Stuttgart, 1996.
- [31] ISERMANN, R.; JOST, O.; SCHWARTE, A.: *Modellgestützte Reglerentwicklung für einen Abgasturbolader mit variabler Turbinengeometrie an einem DI-Dieselmotor*. MTZ, 61(3):184–193, 2000.
- [32] ISERMANN, R.; SCHMIDT, CH.; KESSEL, J.-A.: *Adaptive Dieselmotorsteuerung*. FVV-Abschlussbericht 602(1996), Frankfurt/M., 1996.
- [33] ISERMANN, R.; SINSEL, S.; SCHAFFNIT, J.: *Modeling and Real-Time-Simulation of Diesel Engines for Control Design*. SAE-Paper 98P-311, 1998.
- [34] JACOBI, H.-G.: *Rechnergestützte Optimierung statischer und dynamischer Systeme*. Springer Verlag Berlin, Heidelberg, 1. Auflage, 1982.
- [35] JELDEN, H.; VELDTEN, B.; WEISS, N.; WOLGAST, B.: *Elektronische Steuerung von Dieselmotoren*. MTZ-Sonderausgabe: 25 Jahre VW-Dieselmotoren, Seiten 80–85, 2001.
- [36] JEUTER, R.: *Efficient Tool Support for the Optimization and Calibration of Electronic Control Units*. In: *VDI-Jahrbuch Fahrzeug- und Verkehrstechnik*, Seiten 56–84, 1998.
- [37] KAMPELMÜHLER, F. T.: *Automatische Motormanagement-Abstimmung*. ATZ/MTZ-Sonderheft Motor und Umwelt '92, Seiten 46–49, 1992.
- [38] KESSEL, J.-A.; SINSEL, S.; ISERMANN, R.: *Methoden zur modellgestützten Steuerung und Regelung von Dieselmotoren mit Turbolader*. In: *16. Internationales Wiener Motorensymposium*, Band 239 der Reihe *VDI-Fortschritt-Berichte 12*, Seiten 104–124, Wien, 1995.
- [39] KIMMICH, F.; SCHWARTE, A.: *Modellgestützte präventive Diagnosemethoden für Dieselmotoren*. In: *FVV-Heft R503 (1999)*, Seiten 29–44, Frankfurt/M., 1999.
- [40] KOLBERG, G.: *Elektronische Motorsteuerungen für Kraftfahrzeuge*. MTZ, 46(4):129–133, 1985.

- [41] KONSTANDOPOLOUS, A.; SKAPERDOS, E.; WARREN, J.: *Optimized Filter Design and Selection Criteria Modeling for Continuously Regenerating Diesel Particulate Traps*. SAE-Paper 1999-01-0468, 1999.
- [42] KRÄMER, M.; ET. AL.: *Potential der Common-Rail-Einspritztechnologie beim DE Dieselmotor*. In: *20. Internationales Wiener Motorensymposium, Band 1*, Seiten 402–425, Düsseldorf, 1999.
- [43] KRYSZEWSKI, J.; ET. AL.: *Elektronische Steuerungen für Dieselmotoren*. MTZ, 40(11):712, 1979.
- [44] LAI, J. L.; HWANG, C. L.: *Fuzzy Multiple Objective Decision Making*. Springer Verlag, Berlin, Heidelberg, 1. Auflage, 1994.
- [45] LEE, T.; REITZ, R. D.: *Response Surface Method Optimization of a HS-DI Diesel Engine Equipped with a Common Rail Injection System*. In: *2001 Fall Technical Conference of the ASME Internal Combustion Engine Division*, Band 1, Seiten 89–95, Detroit, 2001.
- [46] LIEBL, J.; MUNK, F.; HOHENNER, H.; LUDWIG, B.: *Die Steuerung der neuen BMW Valvetronic-Motoren*. MTZ, 62(7/8):516–527, 2001.
- [47] LIEBL, J.; MUNK, F.; SCHNEIDER, J.; KÄMMER, A.; REUSS, H.-C.: *Motormodelle für den frühen Test von Motorsteuergeräten in der Konstruktionsphase des Motorprototypen*. In: *3. Symposium Steuerungssysteme für den Antriebsstrang von Kraftfahrzeugen*, Seiten 279–298, Berlin, 2001.
- [48] LI, N.: *Einfluss der Einspritzverlaufsformung auf das Emissionsverhalten eines Dieselmotors mit nockengesteuertem Hochdruck-Einspritzsystem*. Diplomarbeit, TU Berlin, 2000.
- [49] LITZ, L.; KÖHNIG, H.: *Fuzzy-Control als gemeinsames Entwurfsmittel für Steuerung, Regelung und Überwachung*. In: *4. Workshop Fuzzy-Control*, Seiten 209–222, Dortmund, 1994.
- [50] LUDS, R.; EBEL, P.: *A New Calibration System for the DaimlerChrysler Medium and Heavy Duty Diesel Engines An Exercise in Methods and Tools*. SAE-Paper 2001-01-1222, 2001.
- [51] MEISBERGER, D.; ALBERT, C.; BOURDON, K.: *Die neue Motorsteuerung ME 7.2 von Bosch für den neuen BMW V8-Motor*. MTZ, 58(12):826–834, 1997.
- [52] MITTERER, A.: *Optimierung vielparametrischer Systeme in der Kfz-Antriebsstrangentwicklung*. Dissertation, TU München, 2000.
- [53] MITTERER, A.; ZUBER-GOOS, F.: *Modellgestützte Kennfeldoptimierung - Ein neuer Ansatz zur Steigerung der Effizienz in der Steuergeräteapplikation*. ATZ, 102(3):188–196, 2000.

- [54] MOLLENHAUER, K. (HRSG.): *Handbuch Dieselmotoren*. Springer Verlag, Berlin, Heidelberg, 1. Auflage, 1997.
- [55] NAUMANN, T.; PUCHER, H.: *Wissensbasierte Verfahren zur Struktur- und Parameteroptimierung von Motormanagementsystemen*. In: *3. Symposium Steuerungssysteme für den Antriebsstrang von Kraftfahrzeugen*, Seiten 1–14, Berlin, 2001.
- [56] NELLES, O.: *LOLIMOT-Lokale, lineare Modelle zur Identifikation nichtlinearer, dynamischer Systeme*. *Automatisierungstechnik - at*, 45(4):163–173, 1997.
- [57] NELLES, O.: *Nonlinear System Identification*. Springer Verlag, Berlin, Heidelberg, 1. Auflage, 2001.
- [58] NELLES, O.; ERNST, S.; ISERMANN, R.: *Neuronale Netze zur Identifikation nichtlinearer, dynamischer Systeme: Ein Überblick*. *Automatisierungstechnik - at*, 45(6):251–261, 1997.
- [59] NEUMANN, D.: *Untersuchung der Voreinspritzung an einem direkteinspritzenden Common-Rail-Dieselmotor hinsichtlich hydraulischer Stabilität, Verbrennung, Emissionen und Geräusch*. Diplomarbeit, TU Berlin, 1999.
- [60] N. N.: *50 Jahre Bosch-Benzineinspritzung*. *MTZ*, 49(5):199, 1988.
- [61] OFFER, T.: *Numerische Lösungskonzepte für die Motor-Prozeßsimulation*. Dissertation, TU Berlin, 1999.
- [62] OTTO, F.; DITTRICH, P.; WIRBELEIT, F.: *Status of 3D-Simulation of Diesel Combustion*. In: *3rd Indicating Symposium*, Seiten 289–310, Mainz, 1998.
- [63] PAZMAN, A.: *Foundations of Optimum Experimental Design*. D. Reidel Publishing Company, Dordrecht, Boston, Lancaster, Tokyo, 1. Auflage, 1986.
- [64] PETERS, A. ET. AL.: *Das Common-Rail-Einspritzsystem - Ein neues Kapitel der Dieseleinspritztechnik*. *MTZ*, 58(10):572–582, 1997.
- [65] PETERS, A.; PÜTZ, W.: *Der neue Vierzylinder-Dieselmotor OM611 mit Common-Rail-Einspritzung*. *MTZ*, 58(12):760–767, 1997.
- [66] PISCHINGER, A.; PISCHINGER, F.; LIST, H. (HRSG.): *Die Verbrennungskraftmaschine, Band 7: Gemischbildung und Verbrennung im Dieselmotor*. Springer Verlag, Wien, 2. Auflage, 1957.
- [67] PISCHINGER, R.: *Instationäre Erfassung der Emissionen von LKW-Motoren im US-Transienttest und ihr Vergleich mit Stationärmessungen*. In: *11. Internationales Wiener Motorensymposium*, Band 141 der Reihe *VDI-Fortschritt-Berichte 12*, Seiten 148–181, Wien, 1990.

- [68] PISCHINGER, R.; SAMS, T.; TIEBER, J.; PRETTERHOFEN, G.: *Dynamische Nutzfahrzeugemissionen am Motor- und Rollenprüfstand*. In: *14. Internationales Wiener Motorensymposium*, VDI-Fortschritt-Berichte 12, Seiten 230–253, Wien, 1993.
- [69] PISCHINGER, S.; ET AL.: *Regelung eines Pkw-Dieselmotors mit VTG-Lader im instationären Betrieb*. In: *FVV-Heft R503 (1999)*, Seiten 47–63, Frankfurt/M., 1999.
- [70] PISCHINGER, S.; PUNGS, A.; HOPP, M.: *Kinetik der Rußentstehung und -oxidation in DI-Dieselmotoren bei Abgasrückführung*. In: *FVV-Heft R501 (1999)*, Seiten 169–190, Frankfurt/M., 1999.
- [71] PISCHINGER, S.; PUNGS, A.; HOPP, M.: *Rußoxidationsmodell*. FVV-Abschlussbericht 671(1999), Frankfurt/M., 1999.
- [72] PLÖTT, N.: *Wissensbasierte Modellierung und Regelung dynamischer Systeme mit Fuzzy-Logik*. Dissertation, Universität Erlangen-Nürnberg, 1996.
- [73] PROBST, G.; PABST, F.: *Integrated Powertrain Control and ISG*. In: *3. Symposium Steuerungssysteme für den Antriebsstrang von Kraftfahrzeugen*, Seiten 267–277, Berlin, 2001.
- [74] PUCHER, H.; KRAUSE, F.-L.; BAUER, M.; BREDENBECK, J.; RAUBOLD, W.: *Dynamisches Motormanagement II, Abschlussbericht*. FVV-Heft 543 (1995), Frankfurt/M., 1995.
- [75] PUCHER, H.; KRAUSE, F.-L.; BAUER, M.; BREDENBECK, J.; RAUBOLD, W.: *Online Process Optimization for Diesel Engines - Working Principles and Chances*. In: *16. Internationales Wiener Motorensymposium*, Band 239 der Reihe *VDI-Fortschritt-Berichte 12*, Seiten 140–158, Wien, 1995.
- [76] PUCHER, H.; KRAUSE, F.-L.; BAUER, M.; BREDENBECK, J.; RAUBOLD, W.: *Management System for Online Process Optimization of Diesel Engines*. In: *3rd International Marine Engineering Conference*, Shanghai, 1996.
- [77] PUCHER, H.; KRAUSE, F.-L.; BAUER, M.; BREDENBECK, J.; RAUBOLD, W.: *Online-Prozessoptimierung für aufgeladene Dieselmotoren*. MTZ, 57(6):354–360, 1996.
- [78] PUCHER, H.; KRAUSE, F.-L.; BAUER, M.; NAUMANN, T.: *Dynamische Prozessoptimierung - Optimierung des dieselmotorischen Gesamtprozesses im dynamischen Betrieb, Abschlussbericht*. In: *8. Aachener Kolloquium Fahrzeug- und Motorentechnik*, Seiten 951–968, Aachen., 1999.
- [79] PUNGS, A.: *Rußoxidation I/II*. FVV-Abschlussbericht 537(1997), Frankfurt/M., 1997.

- [80] REISENWEBER, K.-U.; ET. AL.: *Modellgestützte Kennfeldoptimierung - ein neuer Ansatz zur Steigerung der Effizienz in Steuergeräteapplikationen*. In: *4. Internationales Symposium Verbrennungsdiagnostik*, Seiten 205–219, Baden-Baden, 2000.
- [81] ROFERT, A.: *Steuerung der Abgasrückführung*. MTZ, 58(5):412–419, 1997.
- [82] SASS, F.: *Geschichte des deutschen Verbrennungsmotorenbaus von 1860-1918*. Springer Verlag, Berlin, Heidelberg, 1. Auflage, 1962.
- [83] SCHEFFLER, E.: *Statistische Versuchsplanung und Auswertung*. Deutscher Verlag für Grundstoffindustrie, Stuttgart, 3. Auflage, 1997.
- [84] SCHEIBERLEIN, A.; LIST, H. (HRSG.): *Die Verbrennungskraftmaschine, Band 11: Der Aufbau der raschlaufenden Verbrennungskraftmaschine*. Springer Verlag, Wien, 2. Auflage, 1964.
- [85] SCHENK, J.; STRAUSS, W.; GREINER, A.: *Motorsteuerung ME 1.0 für die optimierten V8- und V12-Motoren von Mercedes-Benz*. MTZ, 56(11):666–673, 1995.
- [86] SCHMIDT, C.; ISERMANN, R.: *Dieselmotoren-Regelung*. FVV-Abschlussbericht 407(1992), Frankfurt/M., 1992.
- [87] SCHÜLER, M.; HAFNER, M.; ISERMANN, R.: *Einsatz schneller neuronaler Netze zur modellbasierten Optimierung von Verbrennungsmotoren, Teil 1*. MTZ, 61(10):704–711, 2000.
- [88] SCHÜLER, M.; HAFNER, M.; ISERMANN, R.: *Einsatz schneller neuronaler Netze zur modellbasierten Optimierung von Verbrennungsmotoren, Teil 2*. MTZ, 61(11):798–805, 2000.
- [89] SCHWARZBAUER, G.; WEISS, H.: *Digitale Dieselelektronik beim BMW-Turbodieselmodell 324td*. MTZ, 49(1):6–18, 1988.
- [90] SCHWARZ, C.: *Simulation des transienten Betriebsverhaltens aufgeladener Dieselmotoren*. Dissertation, TU München, 1993.
- [91] STAHL, M.; DORNSEIFF, M.; SAX, E.: *Durchgängige Testmethoden für komplexe Steuerungssysteme - Erhöhung der Prüftiefe durch Testautomatisierung*. In: *3. Symposium Steuerungssysteme für den Antriebsstrang von Kraftfahrzeugen*, Seiten 183–202, Berlin, 2001.
- [92] STEINPARZER, F.; KRATOCHWILL, H.; MATTES, W.; STEINMAYR, T.: *Neuer Vierzylinder-Dieselmotor von BMW*. MTZ, 62(11):888–897, 2001.
- [93] STRAUBEL, M.; SCHWARTZ, R.; RITTER, E.: *Weiterentwicklung der Bosch-Reiheneinspritzpumpe und ihrer Regler*. MTZ, 41(1):23–27, 1980.

-
- [94] THE MATHWORKS INC.: *Neural Network Toolbox User's Guide*. Natick, MA, 4. Auflage, 2000.
- [95] THE MATHWORKS INC.: *Optimization Toolbox User's Guide*. Natick, MA, 4. Auflage, 2000.
- [96] THIEMANN, W.; FINKBEINER, H.-J.; BRÜGGEMANN, H.: *Der neue Common-Rail-Dieselmotor mit Direkteinspritzung für den Smart*. MTZ, 60(11):650–665, 1999.
- [97] WIRBELEIT, F.; ET. AL.: *Emissionsverbesserung an Dieselmotoren mit Direkteinspritzung mittels Einspritzverlaufsformung*. MTZ, 60(9):552–558, 1999.
- [98] WISSLER, G.; AUST, M.; RABL, H. P.: *SINOx - A SCR based Exhaust-Emission Treatment System for Diesel Engines*. In: *8. Aachener Kolloquium Fahrzeug- und Motorentechnik, Sonderdruck*, Aachen, 1999.
- [99] ZELLBECK, H.; FRIEDRICH, J.: *Optimierung des dynamischen Verhaltens aufgeladener Verbrennungsmotoren*. MTZ, 62(6):474–480, 2001.
- [100] ZIMMERMANN, H.-J.: *Fuzzy-Logik, Band III: Anwendungen*. R. Oldenbourg Verlag, München, Wien, 1. Auflage, 1994.

Über den Autor

Tino Naumann

geboren am 20. Oktober 1971 in Leipzig

1978-1986	Polytechnische Oberschule in Leipzig
1986-1990	Spezialschule mathematisch-naturwissenschaftlich-technischer Richtung „Wilhelm Ostwald“ in Leipzig
1990-1991	Zivildienst
1991-1996	Studium der Elektrotechnik, Fachrichtung Automatisierungstechnik an der Technischen Hochschule Leipzig
1997-2002	Tätigkeit als Wissenschaftlicher Mitarbeiter am Fachgebiet Verbrennungskraftmaschinen der Technischen Universität Berlin
Juli 2002	Promotion zum Thema „Wissensbasierte Optimierungsstrategien für elektronische Steuergeräte an Common-Rail-Dieselmotoren“
seit März 2002	Tätigkeit als Unternehmensplaner bei der Leopold Kostal GmbH & Co. KG in Lüdenscheid

Sonstige Veröffentlichungen (Auswahl):

Naumann, T.; Pucher, H.; Pumplun, K.: *Optimierung von Betriebsstrategien diesel-elektrischer Hybridantriebe für Stadtbusse*, Automobiltechnische Zeitschrift (ATZ) 102(12): 1108-1115, 2000

Naumann, T.; Pucher, H.; Krause, F.-L.; Bauer, M.: *Dynamische Prozessoptimierung*, Abschlussbericht, FVV-Heft R501 (1999), Frankfurt am Main, 1999

Naumann, T.; Pucher, H.; Krause, F.-L.; Bauer, M.: *Optimierung des dieselmotorischen Gesamtprozesses im dynamischen Betrieb*, in: Tagungsband zum 8. Aachener Kolloquium Fahrzeug- und Motorentchnik, Seiten 951-968, 1999

Naumann, T.; Pucher, H.: *Wissensbasierte Verfahren zur Struktur- und Parameteroptimierung von Motormanagementsystemen*, in: Tagungsband zum 3. Symposium Steuerungssysteme für den Antriebsstrang von Kraftfahrzeugen, Berlin, 2001