

Ein multikriterieller evolutionärer Algorithmus mit
interaktiver Präferenzintegration – Angewendet zur
Optimierung von Hydraulikventilreglern

Dissertation zur Erlangung des Grades Doktor-Ingenieur
der Fakultät für Elektrotechnik und Informationstechnik
der Technischen Universität Dortmund

von
Johannes Krettek

Mündliche Prüfung am 03.12.2012 in Dortmund

Erstgutachter: Prof. Dr.-Ing. Prof. h.c. Dr. h.c. Torsten Bertram
Zweitgutachter: Prof. Dr. Günter Rudolph

Vorwort

Diese Arbeit ist während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Regelungssystemtechnik an der Technischen Universität Dortmund entstanden. Für die Möglichkeit am Lehrstuhl zu arbeiten danke ich dem Lehrstuhlinhaber, Herrn Prof. Dr.-Ing. Prof. h.c. Dr. h.c. Torsten Bertram. Mein besonderer Dank gilt ihm für die Betreuung der wissenschaftlichen Arbeit und die Begutachtung dieser Dissertation. Ebenso möchte ich Herrn Prof. Dr. Günter Rudolph für seine Tätigkeit als Zweitgutachter der Dissertation danken. Herr Dr. Hoffmann hat viel zur inhaltlichen Gestaltung meiner wissenschaftlichen Tätigkeit und damit dieser Arbeit beigetragen, ihm gilt mein Dank für unzählige Impulse, Ideen und konstruktive Diskussionen. Dem Team der wissenschaftlichen, technischen und studentischen Mitarbeiter des Lehrstuhls gebührt Dank für die langjährige gute Zusammenarbeit. Besonders hervorzuheben sind meine Kollegen Jan Braun und Jörn Malzahn, die mich bei der Erstellung dieser Ausarbeitung mit großem Einsatz durch Korrekturvorschläge, kritische Begutachtung und konstruktive Diskussionen unterstützt haben. Herrn Jan Braun gebührt darüber hinaus auch besonderer Dank für die über Jahre sehr produktive und angenehme Zusammenarbeit in gemeinsamen Projekten und Themen, für zahlreiche gemeinsame Publikationen und natürlich für das freundschaftliche Zusammenleben im gemeinsamen Büro. Viele der Ideen und Details dieser Arbeit sowie auch deren Umsetzung in Software und in Experimenten sind Ergebnis enger Teamarbeit und fortdauernder konstruktiver Diskussion.

Große Teile der Arbeit sind im Zusammenhang einer Forschungs Kooperation mit der Bosch Rexroth AG entstanden. Vielen Dank für die jahrelange gute Zusammenarbeit und die finanzielle Unterstützung sowie die Unterstützung beim Aufbau des Prüfstands für den experimentellen Teil dieser Arbeit. Besonders danken möchte ich hier den Herren Thomas Ewald und Ingo Glowatzky für die angenehme Zusammenarbeit.

Ich möchte mich bedanken bei meinen Eltern, die mich während meines Studiums unterstützt haben und meine wissenschaftliche Tätigkeit und diese Dissertation dadurch erst ermöglicht haben. Meiner Mutter danke ich ferner für das Lektorat und den orthographischen Feinschliff meiner Dissertation.

Meiner Frau Tanja und meinem Sohn Jonathan gilt mein Dank vor allem für Geduld, Verständnis und die Unterstützung, die sie aufzubringen bereit waren und die diese Arbeit dadurch möglich gemacht haben.

Johannes Krettek, am 31.12.2012

Alles entsteht durch Verwandlung, und die Natur liebt nichts so sehr, als das Vorhandene umzumodeln und Neues von ähnlicher Art zu erzeugen. Jedes Einzelwesen ist gewissermaßen der Same eines zukünftigen, und es wäre eine große Beschränktheit, nur das als ein Samenkorn anzusehen, was in die Erde oder in den Mutterschoß geworfen wird. [1]

Marc Aurel (121-180)

Inhaltsverzeichnis

Nomenklatur	VII
1 Einleitung	1
1.1 Komplexität als Motivation für Optimierungsalgorithmen	2
1.2 Die Darwinsche Evolutionstheorie als Inspiration für Optimierungsalgorithmen	4
1.3 Optimierung als Werkzeug in den Ingenieurwissenschaften	7
1.3.1 Integration von Optimierungsalgorithmen und Expertenwissen . . .	7
1.3.2 Optimierungsmethoden im Entwurfsprozess	8
1.3.3 Hardware-in-the-Loop-Optimierung	9
1.4 Zielsetzung der Arbeit	10
1.5 Gliederung	11
2 Stand der Technik	12
2.1 Evolutionsstrategien	12
2.2 Multikriterielle evolutionäre Algorithmen	14
2.3 Interaktive evolutionäre Optimierung	17
2.4 Optimierung von Hydraulikventilreglern	21
3 Benutzerpräferenzen in der multikriteriellen evolutionären Optimierung	23
3.1 Zusammenhang von Entscheidung und Optimierung	24
3.1.1 A priori Entscheidung	24
3.1.2 A posteriori Entscheidung	25
3.1.3 Progressive Entscheidung	27
3.2 Entscheidungsfindung im Entwicklungsprozess	28
3.2.1 Belastungen durch Entscheidungen	29
3.2.2 Psychologische Betrachtung der Entscheidungssituation	29
3.2.3 Partielle Ordnung in teilweise unbekanntem Lösungsmengen	30
3.2.4 Vergleichbarkeit von Lösungen	31
3.3 Integration der Entscheidungsprozesse in den Optimierungsalgorithmus . .	33
3.4 Interaktives Erfassen und Abbilden von Präferenzen	35
3.4.1 Schnittstelle zur interaktiven Präferenzartikulation	35
3.4.2 Instanzbasierte Präferenzmodellierung	36
3.4.3 Informationsmaximierende Auswahl von Entscheidungskandidaten .	38

3.5	Präferenzbasierte Selektion	41
3.5.1	Ähnlichkeitsbasierte Präferenzschätzung	42
3.5.2	Kompromissbildung zwischen Vergleichbarkeit und Präferenz	42
3.5.3	Bedeutung der Vergleichbarkeit für den Selektionsprozess	43
4	Parameter und Unsicherheiten der Präferenzmodellierung	44
4.1	Evaluation mit Test-Funktionen	44
4.1.1	Simuliertes Benutzerentscheidungsverhalten	45
4.1.2	Eindeutiger Präferenzschwerpunkt	46
4.1.3	Disjunkte Präferenzschwerpunkte	49
4.1.4	Einfluss der Dimension des Kriterienraums	51
4.2	Einfluss von Modellparametern	52
4.2.1	Statische Betrachtung des Präferenzmodells	52
4.3	Strategieparameter der Präferenzintegration	55
4.3.1	Die Intensität der Benutzerinteraktion	55
4.3.2	Bewertung der gezielten Auswahl von Interaktionskandidaten	58
4.3.3	Reduzierte Repräsentation der Lösungsmenge	58
4.4	Der Umgang mit Modellunsicherheiten	58
4.4.1	Wechselwirkungen von Problem, Benutzer und Parametern	59
4.4.2	Validierung von Präferenzschätzungen	61
5	Multikriterielle Optimierung von dynamischen Systemen	63
5.1	Optimale und optimierte Regler	64
5.2	Gütemaße und Bewertung von Systemverhalten	65
5.2.1	Bewertung von Sprungantworten	66
5.2.2	Analyse der Störanfälligkeit der Kriterien	68
5.2.3	Kritische Diskussion der Kriterien	71
5.3	Robustheit von Lösungen und Optimierung	72
5.3.1	Berücksichtigung stochastisch beeinflusster Fitnessfunktionen	73
5.3.2	Beispiel: Lineares Modell eines Hydraulikventils	74
5.3.3	Analyse der Robustheit anhand eines Beispiels	74
5.3.4	Zeitabhängig variierende Fitnessfunktion	79
5.3.5	Sensitivität von Parametern in der Optimierung	80
6	Optimierung von Reglern für Hydraulikventile unter Betriebsbedingungen	85
6.1	Hydraulische Regelventile	86
6.2	Struktur und Realisierung von Ventillagereglern	88
6.2.1	Digitale Regelung	89
6.3	Versuchsaufbau für die Regleroptimierung	92
6.3.1	Echtzeitsimulation des digitalen Reglers	93
6.3.2	Hydraulik-Experimentalsystem	94
6.4	Bewertung und Fitnessfunktion	95

6.4.1	Bewertungsexperiment	95
6.4.2	Kriterien und Bewertung der Sprungantworten	96
6.4.3	Definition von Randbedingungen und Parametergrenzen	97
6.4.4	Robustheit und Reproduzierkeit der Bewertung	97
6.4.5	Interaktionsschnittstelle	98
6.5	Optimierungsergebnisse	100
6.5.1	Multikriterielle Optimierung	100
6.5.2	Interaktive Optimierung mit Entscheidungsmodell	102
6.5.3	Interaktive Optimierung mit realer Bewertung	105
6.5.4	Praktische Umsetzung realer interaktiver Optimierung	106
6.5.5	Untersuchung der Robustheit von Lösungen	107
6.6	Robuste HIL-Optimierung	110
6.6.1	Optimierung mit Bewertung bei variierten Betriebsbedingungen	112
6.6.2	Analyse der Ergebnisse der robusten Optimierung	113
6.7	Sicherheit durch mehrstufige modellgestützte Optimierung	114
6.8	Übertragbarkeit auf andere Ventiltypen und andere Regelungskonzepte	116
7	Zusammenfassung und Ausblick	117
A	Benchmark-Ergebnisse	121
A.1	FON-Funktion	122
A.2	ZDT1-Funktion	126
A.3	ZDT3	130
B	HIL-Optimierung von Hydraulikventilreglern	135
B.1	Ergebnisse der MOEA-Optimierung	136
B.2	Ergebnisse der interaktiven Optimierung	137
B.3	Robustheitsanalyse am Hydraulikprüfstand	138
B.4	Der Versuchsaufbau	142
B.4.1	Details des hydraulischen Aufbaus	145
C	Die MOrEA-Toolbox	146
D	Verwendete Optimierungskonfigurationen	149
D.1	PI-Regler (verwendet in Kapitel 5)	150
D.2	Multikriterielle Ventilregler-Optimierung (verwendet in Kapitel 6)	151
D.3	Interaktive Ventilregler-Optimierung (verwendet in Kapitel 6)	152
D.4	Optimierung von Benchmark-Funktionen (verwendet in Anhang A)	154
	Literaturverzeichnis	154

Nomenklatur

Abkürzungen

CI	Computational Intelligence
EA	Evolutionärer Algorithmus
EMO	Evolutionäre Multikriterielle Optimierung
EMOA	Evolutionärer multiobjektiver Algorithmus, auch: MOEA
ES	Evolutionsstrategie
HIL	H ardware- I n-the- L oop
I-MOEA	Interaktiver M ultiobjektiver evolutionärer Algorithmus
IEA	Interaktiver E volutionärer Algorithmus
ISE	Integral of squared error
ISTE	Integral of squared time weighted error
LQR	L inear Q uadratic R egulator
LVDT	L inear V ariable D ifferential T ransformer
MOEA	M ultiobjektiver evolutionärer Algorithmus, auch: EMOA
NSGA-2	N on- S orting G enetic A lgorithm II
P, T, A, B	Hydraulische Anschlüsse des Wege-Ventils
PAES	P areto A rchived E volution S trategy
PWM	P ulsweiten- M odulation
SMS-EMOA	S - M etrik- S elektions EMOA
SPEA	S trength P areto E volutionary A lgorithm
SPS	S peicherprogrammierbare S teuerung

Formelzeichen

χ	Sensitivitätsindex einer Lösung
$\Delta_{(.)}$	Permutationsmaß / Abweichung einer Ordnung oder Rangfolge
ϵ	Schrittweite der Präferenzvariation
γ_ρ	Vergleichbarkeitsindex einer einzelnen Lösung
γ_σ	Präferenzindex einer einzelnen Lösung
$\hat{\rho}$	Geschätzte Vergleichbarkeit eines Lösungspaares
$\hat{\sigma}$	Geschätzte relative Präferenz für ein Lösungspaar

λ	Anzahl der Nachkommen
$[i_{min} \quad i_{max}]$	Obere und untere Begrenzung der Stellgröße, Optimierungsparameter des Ventillagereglers
$\{l_a, l_b\}$	Ein aktuell betrachtetes Lösungspaar
$\{p_i, p_j\}$	Ein Paar gespeicherter Lösungsprototypen
$\mathbf{a}_P, \mathbf{a}_I$	Stützwerte der Verstärkungskennlinien für P- und I-Zweig, Optimierungsparameter des Ventillagereglers
$\mathbf{e}_P, \mathbf{e}_I$	Stützstellen der Verstärkungskennlinien für P- und I-Zweig, Optimierungsparameter des Ventillagereglers
$\mathbf{J}(\mathbf{k})$	Vektor der Bewertungskriterien (in Kapitel 5 und 6), siehe auch: \mathbf{f}
\mathbf{k}	Vektor der Optimierungsparameter (in Kapitel 5 und 6), siehe auch: \mathbf{x}
\mathbf{q}	Zu bewertende Signale
μ	Populationsgröße der Eltern
$\omega(\{..\} \{..\})$	Ähnlichkeit zweier Lösungspaare
Φ_i	Eindeutige Präferenzregion eines Referenzpunktes $\mathbf{f}_{Ref,i}$
ρ	Vergleichbarkeit eines Lösungspaars
σ	Relative Präferenz für ein Lösungspaar, aber auch: Standardabweichung
σ_M	Durch das künstliche Entscheidungsmodell ermittelte Präferenz
τ	Abtastzeit
\mathbf{f}	Kriterien- oder Fitnessvektor für eine Lösung oder ein Individuum
$\mathbf{f}_1 \prec \mathbf{f}_2$	\mathbf{f}_1 dominiert \mathbf{f}_2 im Sinne der Pareto-Dominanz
\mathbf{f}_{Ref}	Referenzpunkt(e) des künstlichen Entscheidungsmodells
\mathbf{x}	Parameter oder Erbgut eines Individuums / einer Lösung
\ddot{U}	Maximales Überschwingen
$A \gg B$	A wird gegenüber B präferiert
$A \parallel B$	A und B sind nicht-vergleichbar
a, b, i, j	Laufindices
c	Parameter für Anzahl von Clustern
$d(\{..\} \{..\})$	Abstand zweier Lösungspaare im Kriterienraum
D_σ	Präferenz-Datenbank / Menge der bewerteten Prototypenpaare
D_I	Menge von interaktiv bewerteten Prototypenpaaren
d_k	Dimension des Kriterienraumes
D_P	Menge von Prototypenpaaren, die Entscheidungskandidaten darstellen
$G_D(s)$	Übertragungsfunktion im D-Teil des Ventillagereglers
$h(t)$	Sprungantwort
i_{ist}	Ist-Wert für den Strom in der Ventilendstufe. Regelgröße des unterlagerten Stromreglers
i_{soll}	Soll-Wert für den Strom in der Ventilendstufe. Stellgröße des Lagereglers, Führungsgröße des unterlagerten Stromreglers
k_D	Verstärkungen im D-Zweig, Optimierungsparameter des Ventillagereglers
k_I, k_{ID}	Verstärkungen im I-Zweig, Optimierungsparameter des Ventillagereglers

	lers
L	Menge von Individuen oder Lösungen
l	Lösung / Individuum
$l_a \geq l_b$	Ordnungsrelation für die Elemente l_a und l_b der Menge (L, \geq)
L_C	Menge der repräsentativen Lösungen als Ergebnis eines Clusterings
L_P	Pareto-Menge
L_R	Nicht selektierte Individuen/Lösungen
L_S	Selektierte Individuen/Lösungen
$L_{d=1}$	Menge der nicht-dominierten Lösungen mit Dominanzrang $d = 1$
n	Eine definierte Anzahl
n_f	Anzahl der Kriterien einer Fitnessfunktion
n_x	Anzahl der Parameter einer Fitnessfunktion
P	Eine Instanz der Präferenzdatenbank
P_i, N_i	Pol- und Nullstellen im D-Zweig, Optimierungsparameter des Ventillagereglers
p_{hyd}	Hydraulischer Druck am Versuchsaufbau
R	Rangfolge oder Ordnungsbeschreibung einer Lösungsmenge
r_i	Interaktionsrate (Entscheidungen/Generation)
T_a	Anstiegszeit
T_e	Einschwingzeit
t_{hyd}	Öltemperatur am Versuchsaufbau
t_{PWM}	Tastverhältnis des PWM-Eingangssignals der Endstufe, Stellgröße des Stromreglers
w_i	Gewichtungsfaktor
y_{ist}	Ist-Wert der Kolbenposition, Regelgröße der kaskadierten Ventillage- regelung
y_{soll}	Soll-Wert für die Kolbenposition, Führungsgröße für den Ventillage- regler

Kapitel 1

Einleitung

Bei der Betrachtung der technologischen Entwicklung im Verlauf der Menschheitsgeschichte oder auch spezieller der letzten Jahrzehnte kommt man zu dem Schluss, dass sich diese Entwicklung zunehmend beschleunigt. Dies mag zu einem gewissen Teil der Perspektive geschuldet sein, mit der man aus der eigenen Zeit auf vergangene Entwicklungen blickt. Auch darüber, ob diese Beschleunigung zwangsläufig auf so etwas wie eine technologische Singularität, wie sie zum Beispiel Kurzweil in [2] prognostiziert, hinauslaufen muss, kann trefflich gestritten werden. Nicht abzustreiten ist jedoch, dass zu allen Zeiten der technologische Fortschritt neue Probleme aufwarf oder neue Fragen zu stellen erlaubte, deren Lösungen zu suchen oder zu realisieren wiederum in Grenzbereiche des technologischen Fortschritts führte. Viele moderne Systeme und Produkte haben einen Grad an Komplexität, der von einzelnen Menschen, ganz gleich ob von überragender Intelligenz, ohne die Unterstützung von Computern nicht beherrschbar wäre. Ein bekanntes Beispiel ist die Halbleiterindustrie, in der nur Computer noch in der Lage sind, Entwurf und Layout ihrer eigenen wichtigsten Komponenten zu beherrschen. Ähnliche Situationen finden sich an den Spitzen aller Bereiche der Technologie oder Natur- und Ingenieurwissenschaft, sei es Statik, Dynamik, Elektronik, Maschinen oder Software. Computersysteme sind in der Lage, durch schiere Geschwindigkeit für Menschen nahezu unendlich dauernde Berechnungen in endlicher Zeit zu lösen. Diese Fähigkeit kann, mit Hilfe geeigneter Algorithmen, dazu genutzt werden, hochdimensionale Aufgaben und komplexe Fragen objektiv zu beantworten, die Menschen nicht lösen können. Das menschliche Gehirn, obgleich in anderer Hinsicht zu unvergleichlichen Leistungen fähig, ist in seiner Fähigkeit, solche Aufgaben objektiv als Ganzes zu bearbeiten, stark limitiert. Viele Aufgaben, die im Kontext und an der Spitze der Entwicklung moderner Technologie auftreten, stellen solche komplexen Probleme dar und lassen sich mit den Werkzeugen des menschlichen Gehirns, also beispielsweise Erfahrungswissen, Abstraktionsvermögen, Vereinfachung und Modularisierung, nicht mehr lösen, und bedürfen daher der Unterstützung durch geeignete computergestützte Methoden.

1.1 Komplexität als Motivation für Optimierungsalgorithmen

Die Notwendigkeit, gute oder beste Lösungen für ein Problem zu finden, ist nicht auf Anwendungen in den Ingenieurwissenschaften beschränkt, sondern erstreckt sich über alle Lebensbereiche. Viele Fragen, auch des alltäglichen Lebens, lassen sich als Optimierungsaufgaben formulieren, bei denen ausgewählte oder vorgegebene veränderliche Größen derart gewählt werden müssen, dass ein davon abhängiges Ergebnis im Hinblick auf ebenfalls ausgewählte oder vorgegebene Bewertungsmaßstäbe gut ausfällt. Umgangssprachlich spricht man bereits von Optimieren, wenn eine Veränderung vorgenommen wird, die das Ergebnis verbessert. Dass dieses Ergebnis auch formal als optimal bezeichnet werden kann, ist im Allgemeinen weder der Fall noch tatsächlich erforderlich.

Der Mensch ist beim Lösen vieler solcher Probleme zu erstaunlichen Leistungen fähig. Viele alltäglich und zum Teil unbewusst durchgeführte klassische Ingenieursaufgaben, aber auch handwerkliche Tätigkeiten oder beispielsweise das Würzen beim Zubereiten von Speisen, stellen relativ komplexe Probleme dar, die von Experten in wenigen Iterationsschritten gelöst werden können. Führt man sich vor Augen, was die Voraussetzungen für diese Leistungen sind, dann werden jedoch auch schnell die Grenzen der menschlichen Fähigkeiten klar. Die erfolgreiche Anwendung erfordert im Allgemeinen Erfahrung, die sich als erlerntes Modell des Prozesses betrachten lässt, der dem Zusammenhang zwischen veränderlichen Entscheidungsgrößen und dem Ergebnis zugrunde liegt. Dieses gedankliche Modell bildet, mehr oder weniger genau und vollständig, den n -dimensionalen Raum der Entscheidungsgrößen auf den m -dimensionalen Raum der Ergebnisgrößen ab. Von den $m \times n$ theoretischen Zusammenhängen ist jedoch oft nur eine begrenzte Untermenge tatsächlich relevant. Die Aufgabe ist zum einen einfacher lösbar, je kleiner die Werte von m und n sind, zum anderen je weniger Kopplungen in dieser fiktiven Modellstruktur auftreten. Auf das Beispiel des Würzens von Speisen bezogen kann dies bedeuten, dass die Salzigkeit als Ergebnisgröße im Wesentlichen von der variablen Menge des Salzes abhängt, das hinzugefügt wird. Natürlich hängt das tatsächliche Ergebnis auch vom Salzgehalt der anderen Zutaten ab. Das Vorhandensein eines (gedanklichen) Modells jedoch, das die Salzigkeit als Ergebnis von Salzmenge pro Gesamtmenge beschreibt, unterscheidet bereits deutlich zwischen Menschen mit und ohne Kocherfahrung. Die Erweiterung eines solchen Modells um weitere Verkopplungen, also um den Einfluss anderer Zutaten auf die Salzigkeit oder um die Wirkung des Salzes auf andere Ergebnisgrößen, beispielsweise Farbe oder Konsistenz der Speisen, macht den Unterschied zwischen Laien und Experten aus.

Neben solchen strukturellen Vereinfachungen ist die Generalisierbarkeit der Gedankenmodelle eine weitere wichtige Erfolgsvoraussetzung. Diese ermöglicht es dem Experten, sein Modell auf verschiedene ähnliche Prozesse anwenden zu können und so das Potential seiner Erfahrungen effizient zu nutzen. Der Zusammenhang der Salzigkeit ist beispielsweise nicht auf ein spezielles Gericht beschränkt, sondern unter Berücksichtigung einiger Nebenbedingungen auf viele Gerichte anwendbar. Der Experte gründet sein Gedankenmodell weniger auf die konkreten, allgemeingültigen analytischen Zusammenhänge, sondern trainiert einen

Prädiktor auf Grundlage von Beobachtungen. Entsprechend gelten sich daraus ergebende Einschränkungen für die Fähigkeit der Gedankenmodelle zur Extrapolation. Voraussetzung für die Generalisierbarkeit ist daher vor allem die Fokussierung auf eine Domäne, in der die gleichen grundlegenden Mechanismen wirken.

Diese drei wichtigsten Voraussetzungen, Dimensionen des Prozesses, Grad der effektiven Verkopplung und Beschränkung auf eine Domäne, sind für komplexere technische Problemstellungen häufig nicht mehr erfüllt.

Der technische Fortschritt und die Entwicklung immer stärker integrierter Systeme führt dazu, dass es für ein betrachtetes System unter Umständen keinen dezidierten Experten gibt, sondern jeweils nur Expertenwissen zu Teilaspekten eines Problems vorhanden ist. Sehr deutlich, wenngleich nicht darauf beschränkt, wird dieses Problem für mechatronische Systeme und deren Entwicklung. Die ganzheitliche Betrachtung des Systems, die im Zentrum des Konzepts der Mechatronik steht, bedeutet, dass mechanische, elektrische und informationstechnische Komponenten eines Systems nicht isoliert betrachtet werden können oder sollen. Werden einzelne Komponenten eines Systems nicht isoliert betrachtet, so ergibt sich daraus eine größere Anzahl von Variablen und eine höhere Dimension des Lösungsraums. Das Fehlen der Konzentration auf einzelne Komponenten hat auch zur Folge, dass sich ein Ergebnis oder eine Verbesserung nicht nach einem einzelnen Kriterium bewerten lässt. Im Kontext des mechatronischen Entwurfs ergeben sich neben Kriterien, die unmittelbar die angestrebte Funktionalität beschreiben, häufig weitere Kriterien, beispielsweise Energieeffizienz, Herstellungs- oder Wartungskosten, Dauerfestigkeit, Robustheit, Benutzerfreundlichkeit oder Vergleichbares. Mehrere, unter Umständen konfliktionäre Kriterien führen zu einer großen Komplexität der Optimierungsaufgabe. Die starke Verkopplung innerhalb der Systeme ergibt sich nicht aus dem mechatronischen Ansatz, sondern stellt eine Grundannahme und Motivation für diesen dar. Die Verbindung zwischen den verschiedenen Ingenieursdisziplinen führt zu einer domänenübergreifenden Problemformulierung und gefährdet damit auch die dritte genannte Voraussetzung für die Beherrschbarkeit der Optimierungsaufgabe durch einen menschlichen Experten.

Die begrenzten Fähigkeiten eines Experten, die Systeme ausreichend zu erfassen und gedanklich zu modellieren, werden abgelöst durch eine formale Beschreibung des Problems. Eine analytische Modellierung und vollständige mathematische Beschreibung des Systems erlaubt es im besten Fall, eine optimale Lösung für das beschriebene Problem und dessen Randbedingungen geschlossen anzugeben. Ist dies nicht möglich, können Algorithmen, abhängig von den Eigenschaften der Problembeschreibung, das System im Hinblick auf definierte Kriterien optimieren oder eine optimale Lösung ermitteln. Die Beschreibung der Optimierung als Algorithmus eröffnet ganz allgemein die Möglichkeit, die Leistungsfähigkeit des Algorithmus mit der Leistungsfähigkeit der verwendeten Rechner zu skalieren, und so komplexe Probleme zu lösen, deren Anforderungen die Fähigkeiten eines menschlichen Experten weit übersteigen.

Abhängig von Eigenschaften und Randbedingungen des Optimierungsproblems bieten sich eine Vielzahl von Algorithmen und Methoden an. Primär unterscheidet man drei Arten von betrachteten Problemen [3]. *Eigentliche Optimierungsprobleme*, bei denen nur der erreichbare Wert der Kriterien für die optimale Lösung interessant ist und *Entscheidungsprobleme*,

bei denen nur die Erfülltheit einer diskreten Bedingung für diese Kriterien betrachtet wird, sind häufig eher von theoretischem Interesse. Darin unterscheiden sie sich von *Suchproblemen*, bei denen neben dem Kriterienwert auch die Werte der Lösungsvariablen selbst interessant sind und die damit auch praktische Lösungen für gestellte Probleme anbieten. Für alle in dieser Arbeit betrachteten Optimierungsprobleme wird angenommen, dass es sich um Suchprobleme handelt.

Verschiedene Eigenschaften eines Suchproblems bestimmen darüber hinaus, welche Algorithmen für das Problem anwendbar sind und wie gut ihre zu erwartende Leistungsfähigkeit ist. Die Eigenschaften des Problems sind zum einen die Eigenschaften des Zusammenhangs zwischen Lösungsvariablen und Kriterien, beispielsweise dessen Nichtlinearität, ob es sich um eine analytische Beschreibung handelt oder ob eine rein numerische Simulation verwendet wird. Zum anderen sind Art und Anzahl sowohl der Lösungsvariablen als auch der Kriterien entscheidend für die Wahl eines geeigneten Optimierungsalgorithmus. Bieten sich für die Suche nach lokalen Optima differenzierbarer Probleme Algorithmen wie das Newton-Verfahren an, so ist man bei der Suche nach einem globalen Optimum eher auf heuristische Verfahren angewiesen, die häufig von der Natur inspiriert sind. Bei der Betrachtung hochdimensionaler Probleme mit mehreren Kriterien bieten populationsbasierte Verfahren, die eine Lösungsmenge anstelle einer einzelnen Lösung ermitteln, Vorteile. Ein charakteristisches Beispiel für komplexe technische Systeme ist ein Optimierungsproblem, bei dem für mehrere reellwertige Lösungsparameter im Hinblick auf mehrere Kriterien und Nebenbedingungen ein globales Optimum gesucht ist, bei dem für den nichtlinearen Zusammenhang zwischen Parametern und Kriterien jedoch keine geschlossene analytische Beschreibung und entsprechend keine Gradienten zur Verfügung stehen, sondern dessen Eigenschaften durch eine Simulation oder ein Experiment abgebildet werden.

Das in dieser Arbeit zentrale Anwendungsbeispiel, die Parameteroptimierung für den Regler eines hydraulischen Ventils, stellt ein so zu charakterisierendes Optimierungsproblem dar. Diese Art von Problemstellung erfordert leistungsfähige Optimierungsalgorithmen, deren Mechanismen durch ein leistungsfähiges natürlich vorkommendes Optimierungsverfahren, die natürliche Evolution von Lebewesen, inspiriert sind.

1.2 Die Darwinsche Evolutionstheorie als Inspiration für Optimierungsalgorithmen

Die natürliche Evolution von Lebewesen, der grundlegende Mechanismus zur Entwicklung komplexer Lebensformen und Arten, wurde von Charles Darwin entdeckt und als Evolutionstheorie in seinem Werk 'On the Origin of Species' [4] aus dem Jahr 1859 beschrieben. Darwin beschreibt darin einen Prozess, den er als *natürliche Zuchtwahl* bezeichnet. Dieser funktioniert auf der Grundlage der Vererbung von angeborenen Eigenschaften von Eltern auf deren Nachkommen. Zufällig veränderte Eigenschaften eines Lebewesens, Mutationen, werden mit höherer Wahrscheinlichkeit an einen Nachkommen weitergegeben, wenn diese Veränderungen für sein Überleben oder seinen Fortpflanzungserfolg von Nutzen sind. Im

Gegensatz zur von Darwin verwendeten Analogie, der *künstlichen Zuchtwahl*, findet jedoch keine Entscheidung über die Qualitäten einer veränderten Eigenschaft statt, die Vererbung wird einfach dadurch wahrscheinlicher, dass ein langlebiges oder sexuell erfolgreiches Lebewesen potentiell mehr Nachkommen besitzt, die diese Eigenschaft erben können. Der relative Fortpflanzungserfolg eines Individuums wird nach Darwin als *Fitness* bezeichnet. Diese Fitness beruht maßgeblich auf der Angepasstheit eines Individuums an seine Umwelt, ist aber nicht mit ihr gleichzusetzen. Für einzelne Lebewesen ist deren Fitness selbst nicht unbedingt relevant, sie beschreibt vielmehr rückblickend anhand der Häufigkeit des Auftretens in Nachkommen den Erfolg ihrer *Gene*. Das Konzept der Genetik war Darwin bei der Entstehung seiner Theorie jedoch nicht bekannt, es geht auf seinen Zeitgenossen Gregor Mendel zurück. Entsprechend ist Darwins ursprüngliche Theorie nicht frei von Fehlern im Detail, in den 150 Jahren seit der Veröffentlichung durch Darwin sind jedoch zahlreiche Lücken geschlossen worden. Die Genetik stellt dabei die wohl wichtigste Bestätigung für die Evolutionstheorie dar. Viele der Beobachtungen, die zur Erklärung der natürlichen Evolution herangezogen wurden, offenbaren ihren eigentlichen Sinn und Zweck erst in Verbindung mit dem Konzept von Genen und deren Funktionsweise. Der Evolutionsbiologe Richard Dawkins beschreibt in 'The Selfish Gene' [5] sehr anschaulich die Bedeutung der Gene und deren Überleben als eigentlichen Zweck von Evolution. Einen guten und anschaulichen Überblick sowohl über die Evolutionstheorie als auch deren Geschichte bieten Zrzavy, Storch und Mihulka in [6].

Die Evolution, im Wesentlichen eine statistische Verschiebung von Vererbungshäufigkeiten, hat lokal und auf wenige Individuen begrenzt betrachtet kaum Auswirkungen, sondern muss für eine große Anzahl von Individuen und über viele Generationen, also lange Zeiträume betrachtet werden. Damit wird sie zur Ursache für sowohl die Entwicklung der hoch komplexen Lebensformen, die wir heute kennen, als auch für deren große Diversität und Artenvielfalt. Der Grund für beide Effekte ist, dass eine Spezialisierung im Allgemeinen einen Vorteil im Hinblick auf die Fitness darstellt. Sowohl im Hinblick auf zum Beispiel klimatische oder geografische Unterschiede zwischen verschiedenen Regionen der Erde als auch im Hinblick auf ökologische Nischen, also spezielle Teile des Lebensraums, wie zum Beispiel Wasseroberfläche, Baumkronen et cetera, oder spezielle Teile des verfügbaren Nahrungsspektrums, ist ein Individuum mit angepassten Eigenschaften, die speziell oder ausschließlich in dieser Nische von Vorteil sind, einem Generalisten bei gleichem Energieaufwand überlegen.

Das Potential des evolutionären Mechanismus als Optimierungsverfahren zeigt sich also nicht nur in der Tatsache, dass er in der Lage ist Lösungen für komplexe Probleme zu schaffen. Hervorzuheben sind auch die große Robustheit und die Tatsache, dass Evolution nach dem gleichen Prinzip für eine große Zahl unterschiedlicher Optimierungsprobleme, also Kombinationen von Lebensformen und deren Lebensraum, zuverlässig funktioniert. Zurückzuführen ist dies darauf, dass die Mechanismen der Evolution ohne abstrakte Kenntnisse über das betroffene Individuum, dessen Verhalten oder dessen Leistungen funktionieren. Die einzige Voraussetzung für Evolution ist das Vorhandensein einer Struktur mit der Fähigkeit sich zu reproduzieren. Dies ist eine Aufgabe, die in der natürlichen Evolution der DNA als Träger der genetischen Information zukommt, die theoretisch aber nicht auf diese

beschränkt sein muss. Vor allem anderen ist aber die Fähigkeit, nicht nur eine einzelne Lösung, eine Spezies zu verbessern, von zentraler Bedeutung für die Leistungsfähigkeit der Evolution als Optimierungsverfahren. Sie hat darüber hinaus die Fähigkeit, gleichzeitig große und mehrdimensionale Lösungsräume mit vielen ökologischen oder regionalen Nischen durch verschiedene Spezies zu bevölkern. Neben diesen Vorteilen verblasst beinahe die Tatsache, dass Evolution nicht im engeren Sinne eine Optimierung darstellt, da weder die erzielten Ergebnisse noch das angestrebte Ziel optimale Lösungen sind. Relevant für die Evolution ist stets nur der relative Vergleich von Individuen in einer Konkurrenzsituation, der dazu führt, dass vielmehr schlechte Lösungen vermieden als tatsächlich gute Lösungen gesucht werden. Beispiele für nicht optimale oder perfekte, aber dennoch sehr erfolgreiche Lebensformen finden sich in der Natur in großer Zahl. Es fällt wegen der großen Zahl der konfliktionären Kriterien, nach denen die Angepasstheit eines Individuums an seine Umwelt zu bewerten wäre, tatsächlich schwer, etwas wie ein Optimum überhaupt zu formulieren. Wegen der großen Zeiträume, in denen Evolution stattfindet, lässt sich das Vermeiden von schlechten Lösungen und die Suche nach optimalen Lösungen gleichsetzen. Das bedeutet aber auch, dass Evolution, solange die sie motivierende Konkurrenzsituation besteht, nie vollständig abgeschlossen ist.

Evolutionäre Algorithmen

Evolutionäre Algorithmen (EA) bilden gemeinsam mit Fuzzy-Systemen und neuronalen Netzen die Gründungs-Disziplinen des Gebiets der *Computational Intelligence* (CI). Methoden, die diesem Gebiet zugerechnet werden, zeichnen sich dadurch aus, dass sie vergleichsweise universelle Ansätze zur Problemlösung bieten, indem sie auf eine Formalisierung oder Modellierung des Wissens über ein Problem weitgehend verzichten. Dies muss kompensiert werden durch einen im Allgemeinen höheren Rechenaufwand im Vergleich mit klassischen Problemlösungsverfahren [7]. Die EAs bilden eine Klasse von Verfahren, deren Funktionsweise die biologische Evolution zum Vorbild hat. Wie auch bei den neuronalen Netzen geht es dabei nicht um eine exakte Imitation der biologischen Evolution. Diese ist in Details noch nicht vollständig erklärt und generell zu komplex, um sinnvoll als Optimierungsverfahren modelliert und implementiert werden zu können. Auch die real auftretenden Zeiträume und Populationsgrößen sind bei Weitem zu groß. Der vereinfachte Evolutionsmechanismus, der den Algorithmen zugrunde liegt, ist daher zwar in der Lage komplexe technische Probleme zu lösen, deren Komplexität ist aber nicht vergleichbar mit den Leistungen und Problemen der biologischen Evolution.

Die ersten Ansätze zu EAs finden sich bereits in den fünfziger Jahren und im Laufe der Zeit haben sich, neben einigen anderen, drei wichtige Ansätze etabliert.

- Die *Evolutionstrategien* gehen zurück auf Rechenberg [8] und Schwefel [9] und wurden speziell für technische Optimierungsprobleme entwickelt. Sie zeichnen sich durch adaptive Eigenschaften der Optimierungsstrategie und die Verwendung kontinuierlicher Lösungsparameter aus.

- *Genetische Algorithmen* wurden von Holland [10] und De Jong [11] begründet. Ursprünglich werden hier Lösungen binär kodiert, sie eignen sich daher besonders für kombinatorische Probleme.
- Die *Genetische Programmierung* stellt eine Entwicklung dar, die maßgeblich durch Koza [12] popularisiert wurden. Im Gegensatz zu den anderen genannten Ansätzen, die vor allem auf die Parameteroptimierung abzielen, geht es bei der genetischen Programmierung um die Entwicklung optimaler Strategien und Programme.

Darüber hinaus ist historisch auch die *Evolutionäre Programmierung* relevant, die auf Fogel [13] zurückgeht, heute praktisch jedoch nur noch eine geringe Bedeutung hat. Für die vorliegende Arbeit sind vor allem die beiden erstgenannten Verfahren relevant, die sich inhaltlich nicht immer eindeutig voneinander abgrenzen lassen.

1.3 Optimierung als Werkzeug in den Ingenieurwissenschaften

Computergestützte Optimierungsmethoden im Allgemeinen und EAs im Speziellen sind geeignet, komplexe ingenieurwissenschaftliche Probleme erfolgreich zu lösen. Die Verfahren stellen dabei jedoch keinen Ersatz für die Leistungen und Tätigkeiten eines Ingenieurs dar, sondern stehen diesem als Werkzeug zur Verfügung. Die Optimierung dient dazu, eine optimale Lösung zu ermitteln oder anzunähern, bedarf dazu aber zunächst einer Definition des Problems. Diese Definition, die Gestaltung der Bewertungs- oder Fitnessfunktion, die Parametrierung und die Auswahl geeigneter Bewertungskriterien, erfordert den Einsatz von Wissen über den Prozess und die angestrebte Lösung. Die Leistung des Entwicklers ist dabei, eine möglichst präzise und zur Optimierung geeignete Problemdefinition zu erstellen und diese in einem iterativen Prozess auf Grundlage von Ergebnissen der Optimierung zu hinterfragen, zu bewerten und gegebenenfalls anzupassen. Die Realisierung der Bewertungsfunktion selbst, also beispielsweise Anbindung oder Transfer des realen Prozesses, erfordert ebenfalls die Fähigkeiten und Kenntnisse eines Ingenieurs mit entsprechendem Expertenwissen. Die Optimierung kann entsprechend nicht als Alternative zum klassischen Entwicklungsprozess gesehen werden, der ja ebenfalls als Ergebnis die Lösung für ein zuvor gestelltes Problem liefert. Vielmehr kann sie diesen im Detail erleichtern, indem sie für wohldefinierte Teilprobleme Lösungen liefert, auf denen der weitere Entwicklungsprozess aufgebaut werden kann.

1.3.1 Integration von Optimierungsalgorithmen und Expertenwissen

Die Anwendung computergestützter Optimierungsverfahren verschiebt wie beschrieben die Aufgaben des Anwenders oder Experten von der Lösung des eigentlichen Problems hin

zur geeigneten Definition von Kriterien und Randbedingungen. Für komplexe Optimierungsprobleme stellt diese Definition an sich eine komplexe Aufgabe dar. Vom Anwender werden Entscheidungen gefordert, die im Zusammenspiel mit dem Optimierungsalgorithmus maßgeblich das Ergebnis der Optimierung bestimmen. Die Definition des Problems ist auf der einen Seite ausschlaggebend für das Ergebnis, da sie implizit die Formulierung der Anforderungen an eine optimale Lösung enthält. Auf der anderen Seite ist sie in verschiedener Hinsicht, aber primär durch die resultierende Komplexität, entscheidend für die Leistungsfähigkeit, die Laufzeit und die Erfolgsaussichten des Optimierungsalgorithmus. Ein wichtiger Aspekt für das erfolgreiche Lösen der Aufgabe ist es daher, diese Entscheidungen „richtig“ zu treffen. Den Anwender hierzu in die Lage zu versetzen, ist Teil der Konzeption und Entwicklung einer Optimierungsmethode. Dieses Ziel kann dadurch erreicht werden, dass die Schnittstellen zwischen Anwender und Algorithmus, an denen diese Entscheidungen einwirken, derart gestaltet werden, dass der Experte sein Wissen optimal in diese Entscheidungen einbringen kann.

Speziell im Blick auf technische Fragestellungen ergeben sich daraus Anforderungen, die an den Charakter und die Eigenschaften der Entscheidungen gestellt werden. Aus dem Anspruch, ein möglichst universelles Werkzeug bereitzustellen, ergibt sich jedoch auch die Anforderung, wenig von dem Wissen des Experten vorwegzunehmen oder Annahmen bezüglich der Entscheidungen in der Optimierungsmethode zu verwenden. Aus diesen Anforderungen ergeben sich die zentralen Fragen, die zur Integration von Expertenwissen und Optimierungsalgorithmen zum Lösen komplexer ingenieurwissenschaftlicher Probleme zu beantworten sind.

1.3.2 Optimierungsmethoden im Entwurfsprozess

Im mechatronischen Entwurfsprozess nach VDI-Richtlinie 2206 [14], der in seiner Konzeption als exemplarisch für viele Entwurfs- und Entwicklungsmethoden betrachtet werden kann, ergeben sich verschiedene Ansatzpunkte, in denen Optimierungsalgorithmen einen konstruktiven Beitrag leisten können [15]. Mögliche Anwendungen für die numerische Optimierung ergeben sich zum einen in der Struktur- oder Parameteridentifikation, da der Entwurfsprozess stark auf der Verwendung von Modellen beruht. Evolutionäre Algorithmen können erfolgreich zur Identifikation von Modellparametern, aber auch von geeigneten Modellstrukturen angewendet werden, wie beispielsweise von Braun et al. in [16, 17] gezeigt.

Zum anderen ergeben sich Anwendungen in der Funktionsoptimierung, wo der Einsatz von Optimierungsalgorithmen die Möglichkeit eröffnet, die Funktion eines geeignet parametrisierten Teilsystems im Hinblick auf das Verhalten des Gesamtsystems zu optimieren. Hier stellen Optimierungsalgorithmen aufgrund der Eigenschaften des Problems, die aus der ganzheitlichen Betrachtung des Systems resultieren, unter Umständen die einzige praktikable Möglichkeit dar (vgl. Abschnitt 1.1). Ein Schwerpunkt der Anwendungsmöglichkeiten ist dabei die Regelungstechnik, nicht zuletzt, da sie eine zentrale Komponente mechatronischer Systeme verkörpert. Sie zeichnet sich zudem dadurch aus, dass der Regler im Allgemeinen ein Teilsystem mit definierten Parametern darstellt, das Verhalten des

Gesamtsystems jedoch eine vergleichsweise große Sensitivität hinsichtlich dieser Reglerparameter aufweist.

1.3.3 Hardware-in-the-Loop-Optimierung

Die Optimierung mit evolutionären Algorithmen stellt, verglichen mit anderen Optimierungsverfahren, wenige Anforderungen an die Eigenschaften des Optimierungsproblems. Neben der Existenz einer konkreten numerischen Bewertung für eine Lösung gibt es keine weiteren notwendigen Eigenschaften wie beispielsweise die Existenz oder Berechenbarkeit der Gradienten dieser Bewertung. Dies ermöglicht im Hinblick auf die Optimierung technischer Systeme den Ansatz der *Hardware-in-the-Loop*-Optimierung (HIL). Dabei wird der klassische Weg verlassen, der beispielsweise bei der Parameteroptimierung beschränkt wird: ein Modell des Systems zu identifizieren, modellbasiert zu optimieren und die Ergebnisse dann wieder auf das reale System zu übertragen. Verwendet man ein Modell als Grundlage für die zur Optimierung verwendeten Bewertungen, kann man bei der Modellierung die vom Optimierungsverfahren geforderten Eigenschaften im Modell berücksichtigen [18]. Die Modellbildung an sich kann sich jedoch abhängig vom betrachteten System als aufwändig und als an sich schon komplexe Optimierungsaufgabe darstellen [19]. Darüber hinaus besteht das inhärente Risiko, dass ein Fehler oder eine in Kauf genommene Vereinfachung zwischen Realität und Modell dazu führen, dass die Ergebnisse einer Optimierung nicht auf das reale System übertragbar sind. In diesem Fall liegt eine Art der Überanpassung der Lösung an das Modell vor, die auf Eigenschaften des Modells zurückzuführen ist, die die reale Strecke nicht aufweist.

Der HIL-Ansatz umgeht diese Probleme, indem in der beschriebenen Vorgehensweise die Optimierung am Modell durch eine Optimierung am realen System ersetzt wird. Die Bewertung einer Lösung erfordert in der Konsequenz ein reales Experiment anstelle einer Simulation mit einem Modell. Eine (Über-)Anpassung an Modelleigenschaften und -fehler wird vermieden, alle Aspekte und externe Beeinflussungen des Systems können direkt im Experiment abgebildet werden und erfordern keine zusätzliche Modellierung. Dem gegenüber steht das Risiko einer Anpassung an das konkret verwendete Exemplar der betrachteten Strecke. Ein Beispiel dafür ist das Ausnutzen von konkreten Ausprägungen von Streckenparametern innerhalb von Fertigungstoleranzen durch die Optimierung. Dies kann ebenfalls die Generalisierbarkeit und Übertragbarkeit des Optimierungsergebnisses und damit die Robustheit von Ergebnis und Methode einschränken.

Darüber hinaus fehlt mit einem Systemmodell auch die Grundlage für einen formalen Stabilitätsnachweis. Ein weiterer Nachteil von HIL ist der unter Umständen große experimentelle und messtechnische Aufwand. Die Durchführung von Bewertungen am realen Prozess in Echtzeit kann sich im Hinblick auf den gesamten Zeitaufwand im Vergleich mit der Verwendung eines Modells abhängig von dessen Komplexität sowohl positiv als auch negativ auswirken. Die HIL-Bewertung unterliegt realen Bedingungen, also auch realen Störungen und Umwelteinflüssen, die die Reproduzierbarkeit einer Bewertung einschränken, da sie nicht ohne Weiteres wie in einem Modell kontrolliert werden können. Die HIL-Optimierung beinhaltet demzufolge einen stochastischen Prozess, dessen Kontrolle je nach Anwendung

technisch anspruchsvoll sein kann und maßgeblich den für die Bewertungsexperimente erforderlichen Aufwand mitbestimmt.

Das zentrale Anwendungsbeispiel dieser Arbeit, das hydraulische Regelventil, wird HIL optimiert. Die primäre Motivation sind dabei die Schwierigkeit, ein ausreichend gutes Modell für das System aufzustellen und der Anspruch, Betriebsbedingungen realistisch berücksichtigen zu können. Die genannten Herausforderungen, die sich durch die HIL-Optimierung ergeben, motivieren die in dieser Arbeit behandelten Untersuchungen zur Robustheit der entwickelten Methoden und technischen Maßnahmen zur schnellen, sicheren und reproduzierbaren HIL-Bewertung der Regelung von Hydraulikventilen.

1.4 Zielsetzung der Arbeit

Diese Arbeit hat sich zum Ziel gesetzt, Benutzerwissen in Form von Präferenzen für Lösungen interaktiv in einen evolutionären Algorithmus zu integrieren. Dies dient zum einen dazu, den mit multikriteriellen Optimierungsproblemen verknüpften Entscheidungsprozess zu unterstützen. Gleichzeitig wird die Leistungsfähigkeit des Optimierungsverfahrens im Hinblick auf das zielgerichtete Ermitteln der präferierten Lösungen erhöht. Im Rahmen dieser Arbeit wird eine Methode zur interaktiven multikriteriellen Optimierung entwickelt und im Detail analysiert, die sich von bekannten Methoden (vgl. Abschnitt 2.3) vor allem in der Charakteristik der Entscheidung und in der Reduktion von Annahmen hinsichtlich der Struktur der Präferenzen des Anwenders unterscheidet. Diese innovativen Eigenschaften haben die praktische Anwendbarkeit der Methode im ingenieurwissenschaftlichen Kontext zum Ziel. Ein wichtiger Aspekt dabei ist es, die grundsätzlich bei jeder Optimierungsmethode auftretende und oft komplexe und erfolgsbestimmende Präferenzentscheidung für den Experten in einer Form zu gestalten, die einen größtmöglichen Vorteil für die Optimierung bei möglichst geringer Belastung des Experten ermöglicht. Darüber hinaus ist es ein Ziel, die Qualitäten der EAs als universelle Problemlöser nicht durch eine problemspezifische Präferenzintegration einzuschränken. Weiter ist für die praktische Anwendung wichtig, dass die Methode robust ist gegenüber Unsicherheiten sowohl im Zielsystem als auch in der Präferenzartikulation des Anwenders.

Die Methode zielt auf Anwendungen im Bereich des Entwurfs und der Parameteroptimierung von Regelungssystemen, da hier die verwendeten abstrakten Gütemaße und die subjektive Bewertung des Systemverhaltens durch einen Experten nicht immer in einem direkten Zusammenhang stehen. Das Systemverhalten jedes Reglers oder geregelten Systems ist im Allgemeinen ein Kompromiss, der von technischen Möglichkeiten und Anforderungen, aber auch von den konkreten Anwendungsszenarien der Systeme abhängt.

Technischer Schwerpunkt der Arbeit ist die Optimierung von Reglern für Hydraulikventile. Hierbei handelt es sich um mechatronische Systeme, deren Komplexität und deren Bandbreite in Modellvielfalt und Anwendungsfeldern die Entwicklung und Verwendung universeller Ansätze zur Optimierung motivieren. Dass die Optimierungsmethode kein Modellwissen über das betrachtete System benötigt, ist ein wichtiger Aspekt ihrer universellen

Anwendbarkeit und ermöglicht im konkreten Anwendungsfall eine HIL-Optimierung. Daraus ergeben sich technische Fragen, deren Beantwortung einen weiteren wichtigen Teil dieser Arbeit bilden. Zentrale Fragestellungen sind dabei verschiedene Aspekte von Robustheit der Lösung und der Bewertung, die sich aus der Betrachtung von realen Systemen mit Unsicherheiten, Störgrößen und rauschanfälliger Signalverarbeitung ergeben. Die vorliegende Arbeit entwirft und erforscht ein Optimierungsverfahren, das sich im Kontext der Ingenieurwissenschaften als unterstützendes Werkzeug für den menschlichen Entwickler anbietet. Die Arbeit analysiert und belegt dessen Leistungsfähigkeit an einer konkreten Anwendung und zeigt so exemplarisch, wie die Methode für Aufgaben im Entwicklungsprozess eingesetzt werden kann.

1.5 Gliederung

Die vorliegende Arbeit gliedert sich in mehrere Abschnitte, in denen Konzept und Methode der interaktiven Integration von Präferenzen erläutert, analysiert und anschließend angewendet werden. In Kapitel 2 wird zunächst der Stand der Technik dargestellt und die vorliegende Arbeit in diesen Kontext eingeordnet. Das Kapitel 3 stellt die Methode zur interaktiven Optimierung vor und diskutiert die grundlegenden Konzepte von Präferenzmodellierung und Entscheidungsfindung. Kapitel 4 umfasst die Analyse des Algorithmus und die Untersuchung der Parameter und Unsicherheiten der Modellierung. Das 5. Kapitel behandelt die Anwendung der multikriteriellen evolutionären Algorithmen für regelungstechnische Problemstellungen und die Optimierung dynamischer Systeme sowie den Aspekt der Robustheit in der Optimierung. Kapitel 6 dokumentiert und analysiert die Anwendung der entwickelten Methoden zur Optimierung von Reglern für Hydraulikventile, beschreibt den verwendeten Versuchsaufbau und zeigt exemplarische Ergebnisse. In Kapitel 7 finden sich eine Zusammenfassung und ein Ausblick auf mögliche anknüpfende Forschung.

Kapitel 2

Stand der Technik

Die vorliegende Arbeit ist thematisch interdisziplinär ausgerichtet und umfasst Aspekte aus den Themenbereichen der evolutionären Algorithmen, der Optimierung dynamischer Systeme, der Regelung von Hydraulikventilen sowie der Entscheidungsfindung und Modellierung von Präferenzen. Dieses Kapitel umfasst sowohl Grundlagen als auch den Stand der Technik in den genannten Themengebieten und dient der Einordnung der Arbeit in deren Kontext.

2.1 Evolutionsstrategien

Evolutionsstrategien (ES) stellen eine Klasse der evolutionären Algorithmen dar (vgl. Abschnitt 1.2), die im Kontext der Ingenieurwissenschaften am weitesten verbreitet sind. Sie grenzen sich von genetischen Algorithmen im Wesentlichen dadurch ab, dass sie für die Optimierung von Problemen mit reellwertigen Lösungsparametern und nicht für kombinatorische Probleme konzipiert sind. Da für praktische technische Problemstellungen diese klare Unterscheidung nicht existiert oder die Art der Probleme ineinander überführbar ist, kann und sollte man auch die Klassen der Algorithmen nicht immer klar trennen.

Das Ziel einer Evolutionsstrategie ist die Optimierung einer Zielfunktion $f : \mathbb{R}^n \rightarrow \mathbb{R}$, die einen Lösungsvektor \mathbf{x} mit n reellen zu optimierenden Parametern, der auch als *Chromosom* bezeichnet wird, auf einen reellwertigen Fitnesswert abbildet, der die Güte der Lösung beschreibt. Die Funktion $f(\mathbf{x})$ kann auch nur in einem Teilbereich des \mathbb{R}^n definiert sein. Der Algorithmus beginnt mit der zufälligen Initialisierung einer Startpopulation $L(0)$, die aus μ *Individuen* besteht. Die Parameter oder Chromosomen der Individuen werden im Allgemeinen auf geeignete Weise zufällig im Gültigkeitsbereich ausgewählt, können aber bei vorhandenem Vorwissen auch gezielt platziert werden. Die nachfolgende Population $L(t+1)$ jeder Population $L(t)$ wird erzeugt, indem aus einer selektierten Untermenge, den Eltern, λ Nachkommen erzeugt werden. Diese entstehen zum einen durch die *Rekombination*, bei der aus zwei oder mehr Eltern ein Nachkomme erzeugt wird, indem diese ausgewählte oder zufällige Teile ihres Chromosomes miteinander zu einem neuen Individuum kombinieren. Der zweite evolutionäre Mechanismus ist die *Mutation*, eine zufällige normal-

verteilte Variation des Chromosomes mit vergleichsweise kleiner Standardabweichung um dessen Ausgangswert. Evolutionsstrategien können, müssen aber nicht, beide Mechanismen in verschiedenen Ausprägungen anwenden. Die Mutation dient dabei, aufgrund ihres lokalen Charakters, eher der Tiefensuche.

Der Mechanismus der Rekombination dient praktisch dazu, dass sich gute Lösungen austauschen, um weiter besser werden zu können. Direkt den genetischen Algorithmen entlehnt ist die diskrete Rekombination, bei der jeweils einzelne Parameter oder Abschnitte der Chromosomen beteiligter Individuen gegeneinander ausgetauscht werden. Speziell für reellwertige Parameter geeignet ist die intermediäre Rekombination, bei der das Chromosom des Nachkommen als (gewichteter) Mittelwert der Chromosomen der Eltern entsteht. Verbreitete Varianten sind Kombinationen und Erweiterungen dieser Mechanismen.

Verschiedene Mutationsverfahren verwenden unterschiedliche Anpassungen der Mutations-schrittweite, die die Varianz der zufälligen Veränderungen beschreiben. Hier sind einfache deterministische Anpassungen über den Fortschritt der Evolution, aber auch verschiedene dynamische Adaptionen verbreitet. Bekannte Beispiele stellen die 1/5-Erfolgsregel nach Rechenberg [8] oder die Berücksichtigung der Schrittweite als zu optimierenden Parameter nach Schwefel [9] dar. Eine weitere erfolgreiche Methode ist die Berücksichtigung korrelierter Mutationen, beispielsweise die CMA-ES nach Hansen und Ostermeier [20], die durch die Adaption einer Kovarianzmatrix in der Lage ist, bei der Suche auch Abhängigkeiten zwischen den Dimensionen des Lösungsraums zu berücksichtigen.

Für alle so erzeugten Nachkommen wird mittels der Fitness-Funktion eine Bewertung ermittelt, auf deren Grundlage die Selektion der nächsten Population $L(t + 1)$ erfolgt. Dabei verwenden Evolutionsstrategien das Elite-Prinzip, bei dem sich, bewertet anhand ihrer eindeutigen Güte f , immer die besten μ Individuen durchsetzen. Man unterscheidet dabei verschiedene Strategien hinsichtlich der Zusammensetzung der Menge von Individuen, aus der die nächste Generation selektiert wird. Die *Plus-Strategie*, bei der aus der vereinigten Menge von Eltern und Nachkommen, also aus $\mu + \lambda$ Individuen, ausgewählt wird, hat die Eigenschaft, einmal erreichte Gütewerte zu erhalten. Der Nachteil besteht in dem Risiko der Konvergenz in ein lokales Minimum. Die Komma-Strategie, bezeichnet auch als (μ, λ) -ES, verringert dieses Risiko, indem nur aus den erzeugten Nachkommen selektiert wird. Dem dabei möglichen Verlust einmal erreichter Lösungen kann durch ein zusätzliches Archiv vorgebeugt werden.

Diese Schritte werden bei einer ES so lange iterativ wiederholt, bis ein definiertes Abbruchkriterium erreicht ist. Dies kann das Erreichen einer definierten maximalen Rechenzeit, einer Anzahl von Generationen oder Funktionsauswertungen sein. Das Erreichen einer Mindestgüte, das Ausbleiben einer weiteren Verbesserung oder die Konvergenz im Sinne der Unterschiede in der Güte der Population können ebenfalls als Abbruchkriterien verwendet werden. Für einen Überblick über Evolutionsstrategien und EAs im Allgemeinen sowie für Literaturverweise zu Details der einzelnen Methoden sei auf Gerdes et al. [7] verwiesen.

2.2 Multikriterielle evolutionäre Algorithmen

Die meisten realen Optimierungsprobleme lassen sich, wie schon in Abschnitt 1.1 angemerkt, nur unzureichend durch ein einzelnes Kriterium zur Beschreibung der Güte einer Lösung charakterisieren. Gerade bei der Optimierung technischer Systeme stellt die optimale Lösung oft einen Kompromiss zwischen verschiedenen Aspekten dar, es handelt sich also um multikriterielle oder auch multiobjektive Probleme (MOP). Naheliegende Beispiele sind der Kompromiss zwischen Haltbarkeit und Gewicht eines Bauteils, zwischen Qualität und Preis eines Produkts oder zwischen Anstiegszeit und Überschwingen einer Sprungantwort eines Dynamischen Systems. Ein anschauliches Beispiel ist der Kompromiss zwischen Komfort und Geschwindigkeit eines Verkehrsmittels.

Eine Alternative dazu, diesen Kompromiss bereits bei der Formulierung der Gütefunktion zu berücksichtigen, stellt die multikriterielle Optimierung dar. Deren Ziel ist nicht eine einzelne optimale Lösung, sondern es sind optimale Kompromisse zwischen mehreren Kriterien.

Diese Menge von Lösungen, die optimale Kompromisse im Hinblick auf definierte Kriterien darstellen, wird Pareto-Menge genannt. Deren Abbildung durch die nun mehrdimensionale Fitnessfunktion \mathbf{f} in den Kriterienraum wird als Pareto-Front bezeichnet. Für alle Lösungen $l \in L_P$, die Teil der Pareto-Menge sind, gilt, dass es keine Lösung gibt, die in einem der Kriterien besser ist, ohne gleichzeitig in mindestens einem anderen Kriterium schlechter zu sein.

Zur Beschreibung des Verhältnisses, in dem zwei Lösungen zueinander stehen können, wird der Begriff der Pareto-Dominanz verwendet [21]. Allgemein ausgedrückt dominiert ein Vektor $\mathbf{a} = (a_1, a_2, \dots, a_k)$ der Länge k einen Vektor $\mathbf{b} = (b_1, b_2, \dots, b_k)$ der gleichen Länge, bezeichnet mit $\mathbf{a} \prec \mathbf{b}$, wenn gilt:

$$\forall i \in \{1, 2, \dots, k\} : a_i \leq b_i \quad \wedge \quad \exists i \in \{1, 2, \dots, k\} : a_i < b_i \quad . \quad (2.1)$$

Lösungen des Optimierungsproblems können jeweils als Tupel $l = \{\mathbf{x}, \mathbf{f}\}$, bestehend aus den Vektoren der Parameter \mathbf{x} sowie der Kriterien \mathbf{f} beschrieben werden. Eine Lösung l_1 dominiert eine weitere Lösung l_2 , wenn für deren Kriterienvektoren $\mathbf{f}_1 \prec \mathbf{f}_2$ gilt. Trifft diese Bedingung oder deren Gegenteil $\mathbf{f}_2 \prec \mathbf{f}_1$ für zwei Lösungen nicht zu, so sind deren Kriterienvektoren entweder identisch oder aber *nicht vergleichbar*. Für alle Pareto-optimalen Lösungen, die gemeinsam die Pareto-Menge bilden, gilt, dass keine sie dominierenden Lösungen existieren und sie untereinander nicht vergleichbar sind. Formal ist die Pareto-Menge L_P als Untermenge des gesamten Lösungsraums Ω definiert als:

$$L_P := \{\mathbf{x} \in \Omega \mid \neg \exists \mathbf{x}' \in \Omega \quad f(\mathbf{x}') \prec f(\mathbf{x})\} \quad . \quad (2.2)$$

Das Ziel einer multikriteriellen Optimierung ist es, diese Pareto-Menge oder Pareto-Front ganz oder teilweise zu ermitteln oder zu approximieren, was im Ergebnis zu einer Menge von Lösungen führt. In dem speziellen Fall, dass die Kriterien nicht miteinander in Konflikt stehen, dominiert eine einzige Lösung alle anderen, was die Pareto-Front auf einen einzelnen Punkt reduziert.

EAs sind im Speziellen für die multikriterielle Optimierung geeignet, da sie aufgrund ihrer Eigenschaft, auf ganzen Populationen von Lösungsindividuen zu basieren, die Voraussetzung zum Approximieren einer Menge von Pareto-optimalen Lösungen erfüllen. Der zentrale Unterschied zwischen dem klassischen EA mit skalarer Fitness und der evolutionären multikriteriellen Optimierung (EMO) besteht darin, dass die Fitness eines Individuums nicht direkt mittels der aus der Fitnessfunktion gewonnenen Bewertung abgeleitet werden kann, sondern zunächst aus deren Ergebnis, den Kriterien, ermittelt werden muss, beispielsweise in Form der Dominanzrelation der beteiligten Individuen.

Die multikriteriellen evolutionären Algorithmen, englisch: *Multi-objective Evolutionary Algorithms* (MOEA), bilden ein umfangreiches eigenes Forschungsgebiet innerhalb des Gebiets der evolutionären Algorithmen, das eng mit dem Gebiet des *Operations Research* (OR) [22] und dabei speziell dem *Multi-Criteria Decision Making* (MCDM) verknüpft ist. Für einen detaillierten Einblick in diese Vielfalt von Algorithmen und Methoden sei hier auf die Übersichtswerke von Coello Coello, Lamont und Van Veldhuizen [21] sowie Deb [23] oder Fonseca und Fleming [24] verwiesen. Einen historischen Überblick bietet ebenfalls Coello Coello in [25]. Einen Vergleich im Hinblick auf die Leistungsfähigkeit verschiedener MOEA bieten Zitzler et al. in [26].

Pareto-Dominanz als Selektionsgrundlage

Das Herleiten einer eindeutigen Fitness als Grundlage für eine Selektionsentscheidung aus der multikriteriellen Bewertung der Individuen stellt den zentralen Aspekt eines MOEA dar. Hier stellt sich die EMO als eine Verbindung der Fragestellungen *Optimierung* und *Entscheidung* dar, auf die in Abschnitt 3.1 näher eingegangen wird. Eine Lösung besteht darin, das MOP in ein skalares Problem zu transformieren und mit herkömmlichen Methoden zu lösen. Die im eigentlichen Sinne multikriteriellen Ansätze zielen jedoch auf die Approximation der Pareto-Front durch eine Menge $L_{\hat{P}}$ Pareto-optimaler Lösungen und verwenden in der Mehrheit dominanzbasierte Selektionsverfahren.

Exemplarisch für viele im Detail unterschiedliche Verfahren wird das *nondominated sorting*, eine Sortierung nach dem Grad der *Nichtdominiertheit*, betrachtet [27]. Dabei wird aus der gesamten aktuellen Population L die Untermenge $L_{d=1}$ der nicht-dominierten Lösungen identifiziert, entfernt und mit einem Rang $d = 1$ versehen. Aus der reduzierten Menge $L \setminus L_{d=1}$ werden die nun nicht-dominierten Lösungen mit dem Rang $d = 2$ versehen und ebenfalls entfernt. Dieser Vorgang wird so lange fortgesetzt, bis allen $l \in L$ ein Rang zugeordnet wurde, der auf diese Weise den Grad der Nichtdominiertheit der Individuen beschreibt. Eine Selektion, die sich primär an diesem Rang als Fitness orientiert, bevorzugt die jeweils aktuell Pareto-optimalen Lösungen und führt so zu einer Approximation der wahren Pareto-Front.

Dieser primäre Selektionsmechanismus allein ist jedoch nicht ausreichend. Die Pareto-Front ist im Allgemeinen eine zumindest abschnittsweise stetige Hyperebene im Kriterienraum, weshalb theoretisch eine unendliche Zahl Pareto-optimaler Lösungen existieren kann. Da sich demnach auf einem beliebig kleinen Teil der Pareto-Front unendlich viele optimale Lösungen platzieren lassen, erfordert die Approximation der gesamten Front durch eine

endliche Population von Lösungen einen zusätzlichen Mechanismus, der eine Verteilung der Lösungen erwirkt. Dieser kann als Äquivalent zum Besetzen ökologischer Nischen in der natürlichen Evolution angesehen werden und wird deshalb auch als *Niching* bezeichnet. Auch hier existiert eine Vielzahl verschiedener Methoden. Populär sind Verfahren, die eine sekundäre Selektion innerhalb der Lösungsmenge gleichen Ranges dadurch realisieren, dass im Parameter- oder Kriterienraum eng benachbarte, also ähnliche, Lösungen abgewertet werden. Diese *Crowding Distance* fördert die Diversität innerhalb der Lösungsmenge und führt dadurch zu der angestrebten Verteilung. Andere Algorithmen verwenden verschiedene *Niching*-Verfahren mit ähnlicher Zielsetzung. Der SMS-EMOA [28] zum Beispiel maximiert den Beitrag einer einzelnen Lösung zur S-Metrik [29], die das von der Lösungsmenge dominierte Hypervolumen im Kriterienraum beschreibt. Ein adaptives Raster im Lösungsraum stellt bei PAES [30] den *Niching*-Mechanismus dar. Beim SPEA [31] wird der Dominanz-Rang um einen Faktor ergänzt, der den Dominanz-Rang archivierter Lösungen verwendet, um eine Verteilung der Individuen sicher zu stellen. Diese und andere Verfahren führen zu im Detail unterschiedlichen Verteilungen der Lösungen auf der approximierten Pareto-Front, deren vergleichende Bewertung zwangsläufig subjektiv vom gewünschten Ergebnis abhängt. Ein Mechanismus, der die Verteilung der Lösungen beeinflusst, stellt daher zwangsläufig einen Ansatzpunkt zur progressiven oder interaktiven Berücksichtigung von Präferenzen in der evolutionären Optimierung dar.

Referenz-Algorithmus: NSGA-II

Als Grundlage und Referenz für in dieser Arbeit entwickelte Methoden und Algorithmen wird der bekannte und verbreitete *Non-dominated Sorting Genetic Algorithm* (NSGA-II) von Deb et al. [32] verwendet. Der Algorithmus basiert auf dem beschriebenen Verfahren zur Sortierung nach Grad der Nichtdominiertheit. Der NSGA-II ist relativ leistungsfähig hinsichtlich seiner Geschwindigkeit und der universellen Anwendbarkeit für verschiedene Problemklassen, zumindest für Probleme mit kleiner Zahl von Kriterien, und ist aus diesen Gründen verbreitet und zum Vergleich geeignet. Das Bild 2.1 zeigt schematisch vereinfacht den Ablauf des Algorithmus. Der Algorithmus initialisiert und bewertet zunächst eine Startpopulation. In jeder Generation erzeugt der Algorithmus aus der aktuellen Population Nachkommen mit den evolutionären Operatoren Rekombination und Mutation (vgl. Abschnitt 2.1) und generiert einen Dominanz-Rang für jedes Individuum der zusammengefassten Menge aus der Eltern- und deren Nachkommen-Population. Dieser Rang wird zur Selektion der nächsten Eltern-Population durch die beschriebene *Crowding-Distance* ergänzt, um eine diverse Pareto-Front zu erzeugen.

Beim NSGA-II handelt es sich um den in der Literatur aktuell am häufigsten als Referenz verwendeten MOEA. Obwohl er nachweislich in verschiedenen Szenarien durch andere Algorithmen übertroffen wird, stellt er doch entsprechend des *No Free Lunch*-Theorems [33] einen guten Kompromiss dar. Das Theorem besagt vereinfacht, dass alle (optimalen) Optimierungsverfahren für die Gesamtheit aller möglichen Probleme gleich gute Leistungen erbringen und eine Verbesserung für eine Klasse von Problemen entsprechend zwangsläufig die universelle Leistungsfähigkeit reduziert. Der NSGA-II stellt in diesem Sinn einen guten

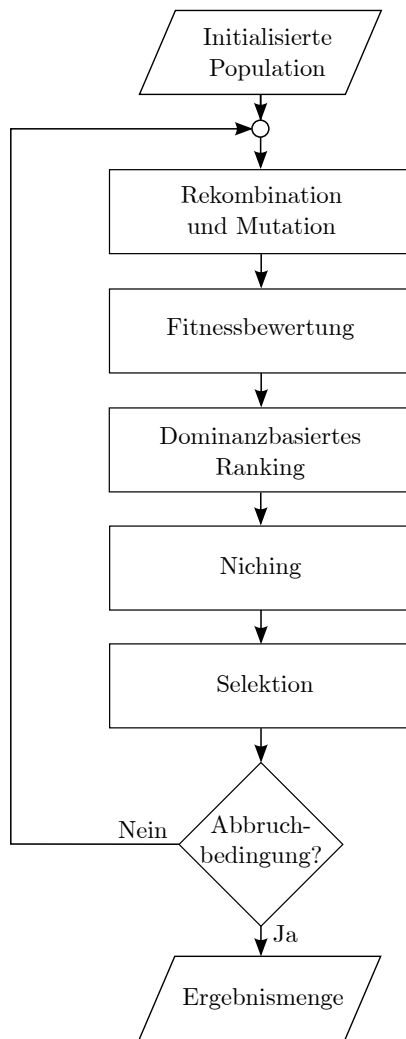


Bild 2.1: Ablaufdiagramm des MOEA

Kompromiss hinsichtlich der universellen Anwendbarkeit, des Implementierungsaufwands und der Ausführungszeit dar und ist daher aus Ingenieursperspektive geeignet.

2.3 Interaktive evolutionäre Optimierung

Für die meisten realen, technischen und nichttechnischen Problemstellungen sind die Prozesse der Entscheidungsfindung und der Optimierung stark miteinander verknüpft. Der Weg zur Ermittlung einer optimalen Lösung schließt dabei, unter Umständen an verschiedenen Stellen, Entscheidungsprozesse mit ein. Diese können sich auf die Formulierung des Optimierungsproblems, auf die Optimierungsstrategie oder auf die Wahl einer Kompromisslösung beziehen. Wie beispielsweise von Parmee et al. [34] und Horn [35] oder Evans [36] in verschiedenen Kontexten formuliert, lassen sich drei Möglichkeiten zur Integration

von Entscheidungen und Optimierung hinsichtlich des Zeitpunktes der Entscheidung relativ zum Optimierungsprozess unterscheiden, die *a priori* Entscheidung, die *a posteriori* und die *progressive* oder interaktive Entscheidung. Auf die konkreten Unterschiede wird in Abschnitt 3.1 im Detail eingegangen.

Der Schwerpunkt dieser Arbeit liegt auf der interaktiven Präferenzartikulation als Methode zur progressiven Integration des Entscheidungsprozesses und der multikriteriellen Optimierung. Obwohl sich speziell für praktische Anwendungen von MOEA die progressiven Techniken aus verschiedenen Gründen anbieten [21], stellen diese in der einschlägigen Literatur eher eine Nische dar. Ein möglicher Grund dafür ist, dass die progressive Technik im Allgemeinen einen Gewinn an Leistung des Optimierungsverfahrens erkaufte durch einen vergrößerten Aufwand für den menschlichen Entscheider. Dieser Mehraufwand ist einerseits nur schwer und für jeden individuellen Fall zu bewerten, der Umgang damit und dessen Reduktion stellt aber andererseits eine zentrale Motivation für diese und andere Arbeiten in diesem Kontext dar.

Generell sind zwar die Fragen, auf welche Art die Präferenzen formuliert werden und wann diese in die Optimierung eingreifen, klar zu trennen. Für eine *a priori* Artikulation fehlt für reale Anwendungen jedoch im Allgemeinen die belastbare Grundlage für eine Entscheidung, die erst durch die Optimierung entsteht. Die Formulierung von Präferenzen auf Grundlage einer endgültigen oder vorläufigen Lösungsmenge hingegen ist Grundlage sowohl für interaktive Techniken als auch für eine *a posteriori* Auswahl [37] geeigneter Lösungen, so dass sich die meisten Ansätze im Wesentlichen nur durch den Zeitpunkt ihrer Anwendung während oder nach der Optimierung unterscheiden. Die in der Literatur verbreiteten Ansätze für interaktive evolutionäre Algorithmen (IEA) lassen sich entsprechend ihrer Arbeitsweise und Repräsentation der Präferenzen in verschiedene Kategorien einteilen. Der folgende Überblick stützt sich im Wesentlichen auf Coello Coello et al. [21].

- Eine erste Kategorie umfasst Methoden der Vorgabe **erwünschter Ziele**. Die ersten Ansätze hierzu finden sich bei Tanaka und Tanino [38] sowie Tanino et al. [39] und Fonseca und Flemming [40]. Die Methoden basieren auf Zielvorgaben in Form einer Einteilung in zufriedenstellende und nicht zufriedenstellende Lösungen oder auf Zielpunkten oder akzeptablen Grenzwerten im Kriterienraum. Diese Vorgaben fließen dann in den Ranking-Mechanismus des MOEA als zusätzliche Kriterien ein und können interaktiv während der Optimierung verändert werden. Einen weiterentwickelten Ansatz stellen Tan et al. in [41] vor, allerdings ursprünglich als *a priori* Methode. Der Kriterienraum wird dabei durch Zielpunkte und deren logische Verknüpfung in Bereiche eingeteilt, die im Ranking unterschiedlich behandelt werden. Deb et al. [42] sowie Thiele et al. [43] verwenden Referenzpunkte zur Beschreibung präferierter Lösungen. Der relativ einfachen Repräsentation und Implementierung dieser Zielvorgaben steht der Nachteil entgegen, dass zum einen viel Information über das Problem und die erreichbaren Lösungen zur Formulierung der Ziele erforderlich ist und dass zum anderen die interaktive Beeinflussung des Rankings eine große Zahl nicht-dominierter Lösungen erfordert, um effektiv zu wirken.

- Eine weitere Kategorie stellt die Verwendung von **Nutzenfunktionen** [44] dar, die ebenfalls ursprünglich auf [40] zurückgeht. Diese Ansätze verwenden eine Funktion, die auf Grundlage der multikriteriellen Bewertung ein eindeutiges Ranking ermittelt. Diese Funktion beschreibt die Präferenzen des Anwenders im Hinblick auf die Relevanz der Kriterien und kann in Form einer linearen gewichteten Summe oder beispielsweise auch als Fuzzy-System oder neuronales Netz [45] repräsentiert sein. Ausgangspunkt dieser Ansätze ist eine a priori Beschreibung der Präferenzen, die progressiv angepasst werden kann. Greenwood et al. [46] leiten eine Rangfolge von Kriterien aus einer formulierten Rangfolge einer Menge von Lösungen ab. Der Ansatz von Branke et al. [47] verwendet eine Beschreibung der Präferenzen durch minimale und maximale lineare Gewichtungen und generiert daraus eine Modifikation des dominanzbasierten Rankings. Meneghetti et al. verwenden in [48] einen Ansatz, in dem der Entscheider eine präferierte Lösung aus einer Menge nicht-dominierter Lösungen wählt. Aus dieser Auswahl werden abschnittsweise lineare Nützlichkeitsfunktionen für jedes Kriterium erzeugt, die über Ungleichungen einen zulässigen Bereich des Kriterienraums begrenzen. Mehnen et al. betrachten in [49] einen Ansatz mit Nützlichkeitsfunktionen unter spezieller Berücksichtigung verrauschter Prozesse. Wagner und Trautmann präsentieren in [50] einen ähnlichen Ansatz in Kombination mit einem SMS-EMOA und bieten darüber hinaus eine gute Einordnung in den Literaturkontext. Der größte Nachteil der meisten dieser Ansätze dieser Kategorie ist, dass sie im Allgemeinen für die Präferenz keine Intransitivitäten, also logische Widersprüche in der Präferenzaussage bei der verknüpften Betrachtung mehrerer Einzelrelationen, erlauben. Sie setzen daher voraus, dass die Präferenz präzise und eindeutig formuliert werden kann. Darüber hinaus basieren viele Ansätze auf der Annahme, dass alle Kriterien als unabhängig voneinander betrachtet werden können, die Bewertung eines Kriteriums also nicht lokal vom Wert eines anderen abhängt, sondern global für den ganzen Kriterienraum beschrieben werden kann.
- Ein dritte Gruppe von Ansätzen basiert auf **Präferenzrelationen**, die im Hinblick auf die Optimierungskriterien definiert werden. Der Ansatz, der auf Cvetkovic und Parmee [51, 52] zurückgeht, ist ursprünglich als a priori Methode konzipiert, kann aber interaktiv verwendet werden [34]. Er basiert im Kern auf der linguistischen Beschreibung der Präferenz des Entscheiders für ein Paar von Kriterien. Die Motivation für diese Art der Beschreibung ist verknüpft mit der Anwendung der Verfahren für Design-Probleme, bei denen die psychologische Betrachtung der Entscheidungssituation von Bedeutung ist. Die gewonnene Information wird verwendet, um entweder durch gewichtetes Zusammenfassen der Kriterien oder eine Modifikation des Pareto-Rankings das Verhalten des MOEA zu beeinflussen. Das hier beispielhaft genannte Verfahren erfordert Transitivität der Bewertung von Kriterienpaaren, darüber hinaus ist die Skalierbarkeit der Methode eingeschränkt, da die Anzahl der notwendigen

Entscheidungen, zumindest theoretisch, quadratisch von der Anzahl der Kriterien abhängt.

- Die vierte wichtige Kategorie stellen die ***Outranking-Verfahren*** dar. Die von Rekiek et al. [53] oder Massebeuf et al. [54] vorgeschlagenen Verfahren basieren beispielsweise auf einem Entscheidungsanalysewerkzeug namens PROMETHEE [55], andere Autoren verwenden ELECTRE [56]. Einen Ansatz, der NSGA-II verwendet, jedoch die Pareto-Dominanz durch ein auf Fuzzy-Präferenzen basierendes Outranking ersetzt, präsentieren Fernandez et al. in [57]. Generell ist diese Kategorie stark mit Themen aus dem OR verbunden. Es werden verschiedene Verfahren und Werkzeuge verwendet, um aus Entscheidungen ein Ranking abzuleiten. Viele der dabei verwendeten Verfahren stellen aber durch eine große Zahl von zu wählenden Parametern selbst bereits ein komplexes Optimierungsproblem dar.

Über die genannten Kategorien hinaus existieren weitere Ansätze, die sich entweder nicht eindeutig zuordnen lassen oder von geringerer Bedeutung beziehungsweise Verbreitung sind. Detaillierte Literaturverweise findet man von Coello Coello in [21] oder [58]. Weitere Beiträge, die ihrerseits als Übersicht in diesem Themengebiet dienen können, gibt es von Cvetkovic et al. [59] oder Rachmawati und Srinivasan [60]. Der Beitrag von Sathe et al. [61] enthält ebenfalls eine Übersicht über repräsentative Ansätze für I-MOEAs und verwendet eine interessante graphische Methode zu deren systematischen Einordnung.

Die Zahl aller Veröffentlichungen im Themengebiet der IEAs ist relativ groß. Die hier genannten Beiträge stellen eine exemplarische Auswahl relevanter Veröffentlichungen dar, die Auswahl erhebt jedoch keinen Anspruch auf Vollständigkeit.

Ein großer Teil der Literatur nähert sich dem Thema von einer theoretischen Perspektive und betrachtet künstliche Benchmark-Probleme. Einen Ansatz zur theoretischen Analyse von interaktiven EAs bietet Rudolph in [62] in Form einer Beschreibung durch stochastische Automaten.

Die praktischen Applikationen von IEA erstrecken sich über verschiedenste Anwendungsgebiete. Takagi und Ohsaki [63] beschreiben die Verwendung einer interaktiven Optimierung zur Anpassung von Hörhilfen. Madar et al. beschreiben in [64] die Anwendung in der chemischen Prozesstechnik. Filipic und Juricic beschreiben in [65] eine Anwendung zur Optimierung von Reglerparametern. Einen Überblick über zahlreiche weitere Anwendungen mit Schwerpunkten auf solchen mit einem kreativen oder künstlerischen Aspekt sowie im Bereich des Designs, bei denen ein subjektiver Aspekt in der Beurteilung zwingend erforderlich ist, gibt Takagi in [66].

Einordnung der vorliegenden Arbeit

Das in dieser Arbeit vorgeschlagene Verfahren basiert auf den eigenen Beiträgen [67, 68, 69, 70] und lässt sich in der oben eingeführten Kategorisierung am ehesten dem *Outranking* zuordnen. Präferenzen werden in Form eines relativen *Rankings* oder Vergleichs von

zwei Lösungen ausgedrückt. Im Kontrast zu vielen anderen Verfahren dieser Kategorie [21] wird dabei auch explizit die Vergleichbarkeit von Lösungen berücksichtigt. Aus den beurteilten Vergleichen wird weder eine explizite Aussage zu Präferenzen im Hinblick auf Kriterien noch eine konkrete globale Nutzenfunktion abgeleitet. Die Beschreibung der Präferenz des Entscheiders und ein entsprechendes Ranking von Lösungsvorschlägen anhand von paarweisen Vergleichen von Lösungsrepräsentanten hat verschiedene Vor- und Nachteile, verglichen mit zum Beispiel Nutzenfunktionen [71, 72], und stellt die zentrale Idee des in dieser Arbeit vorgestellten Konzepts für einen IEA dar. Die präferenzbasierte Selektion von Lösungen erfolgt mittels berechneter Präferenz- und Vergleichbarkeits-Indizes, die direkt auf Grundlage bekannter bewerteter Vergleiche ermittelt werden. Diese stellen damit lokale Modelle dar, deren konkrete Interpretation von der zu bewertenden Population abhängig ist und die daher keine allgemeingültige Beschreibung der tatsächlichen Präferenzen darstellen. Diese Eigenschaften des interaktiv erstellten Präferenzmodells haben zur Folge, dass das Verfahren mit einer minimalen Zahl an zu wählenden Parametern auskommt, was es von vielen anderen Verfahren, speziell aus der Kategorie *Outranking*, unterscheidet. Hinsichtlich der Struktur und Eigenschaften der tatsächlichen Präferenzen sind, anders als bei der Verwendung von Nutzenfunktionen, keine einschränkenden a priori Annahmen erforderlich, abgesehen von der Voraussetzung, dass in einer prinzipiell beliebig kleinen lokalen Umgebung für im Kriterienraum ähnliche Lösungen auch entsprechend ähnliche Präferenzen gelten. Dieser lokale Ansatz und die Berücksichtigung der Vergleichbarkeit machen die vorgeschlagene Methode, im Kontrast zu Präferenzrelations-Methoden, robust und tolerant gegenüber Intransitivitäten. Sie ist in der Lage widersprüchliche Beurteilungen durch den Entscheider sowie zeitlich im Verlauf des Optimierungsprozesses veränderliche Beurteilungen zu verarbeiten und weist damit genug Robustheit für die angestrebte praktische Anwendung in ingenieurwissenschaftlichen Fragestellungen auf.

2.4 Optimierung von Hydraulikventilreglern

Zur Regelung von Hydraulikventilen und hydraulischen Systemen im Allgemeinen kommen zahlreiche klassische sowie fortgeschrittene Regelungskonzepte und Entwurfsverfahren zur Anwendung. Einen breiten Überblick bieten Jelali und Kroll in [73]. Die Verwendung von EAs zur Optimierung von Reglern ist dagegen vergleichsweise wenig verbreitet. Ottersbach in [74] sowie Nicolaus et al. in [75] beschreiben die Verwendung eines EA zur Optimierung eines Reglers für ein Proportional-Wegeventil mittels der Bewertung anhand eines skalaren Fuzzy-Gütemaßes. Aufbauend auf dieser Bewertung beschreibt eine eigene Arbeit [76] die Optimierung für ein komplexeres kaskadiertes Regelungskonzept für mehrstufige Hydraulikventile. Ein weiterer eigener Beitrag [77] präsentiert die multikriterielle HIL-Optimierung von Hydraulikventilreglern mittels eines MOEA. In [78] präsentieren Braun et al. die Anwendung eines MOEA mit Fitness-Surrogatmodellen für das gleiche Zielsystem. Im eigenen Beitrag [79] wird die Anwendung einer interaktiven Optimierung für die Parameteroptimierung des Reglers beschrieben, die auch in dieser Arbeit als Anwendungsszenario im Fokus steht. Einen Beitrag zur Auslegung und Strukturoptimierung von Reglern für Hy-

draulikventile mittels MOEA leisten Braun et al. in [80]. In [81] wird das Konzept der Modellunterstützung ausgeweitet auf den Aspekt der Sicherheit bei der HIL-Optimierung von Hydraulikventilen.

Die multikriterielle Optimierung im Kontext von Hydrauliksystemen ist Teil einer Arbeit von Andersson [82]. Er befasst sich mit der Optimierung von Reglern hinsichtlich des Kompromisses zwischen Regelfehler und Energieeffizienz und betrachtet dabei auch Aspekte der Robustheit und der geeigneten Parametrierung von Lösungen. In [83] verwenden Trachte und Albrecht ein HIL-Konzept zum Test von Ventilen der Mobilhydraulik. Im erweiterten Kontext bewegt sich die Arbeit von Braun et al. [16, 17], in der ein MOEA zur strukturvariablen Identifikation von Simulationsmodellen, unter anderem für ein Hydraulikventil, verwendet wird.

Kapitel 3

Benutzerpräferenzen in der multikriteriellen evolutionären Optimierung

Jedes Optimierungsverfahren und somit auch die evolutionäre Optimierung hat zum Ziel, optimale Lösungen für ein gegebenes Problem zu finden oder zu approximieren. Die Frage jedoch, was eine Lösung zu einer optimalen Lösung macht, wird nicht durch das Optimierungsverfahren und allenfalls indirekt durch das Optimierungsproblem bestimmt, sondern ist allgemein davon abhängig, was ein Benutzer oder Experte von der Lösung erwartet. Diese Benutzerpräferenzen sind das primäre Kriterium und haben sowohl auf die Definition des Optimierungsproblems und dessen Randbedingungen als auch auf die Auswahl der zu verwendenden Optimierungskriterien Einfluss. Allgemein formuliert bestimmen die Präferenzen alle Entscheidungen, die der Benutzer im gesamten betrachteten Entwicklungsprozess trifft. Darunter fallen zum einen sehr grundsätzliche Entscheidungen, beispielsweise für einen abstrakten Lösungsweg oder den Einsatz eines Optimierungsverfahrens. Die diesen Entscheidungen zugrunde liegenden Präferenzen lassen sich im Allgemeinen einfach und präzise formulieren und liegen außerhalb des hier betrachteten Optimierungsprozesses. Zum anderen muss der Benutzer Entscheidungen treffen, beispielsweise die Entscheidung für eine spezielle Parametrierung des entwickelten Systems, für die er seine Präferenzen gar nicht, nur unpräzise oder abhängig von Einflüssen des aktuellen Kontextes des Entwicklungs- oder Optimierungsprozesses formulieren kann. Dieses Kapitel stellt eine Methode vor, die Entscheidungen im Zusammenhang mit dem Optimierungsprozess in diesen integriert. Sie hat das Ziel, die Belastung des Benutzers durch diese schwierige Art von Entscheidungen zu reduzieren, dessen Präferenzen aber trotzdem zur effizienten Optimierung zu verwenden, um Lösungen zu ermitteln, die optimal im Sinne eben dieser Präferenzen sind.

3.1 Zusammenhang von Entscheidung und Optimierung

Im Kontext multikriterieller Probleme unterscheidet man drei grundsätzliche Möglichkeiten zur Integration von Entscheidungen und Optimierung hinsichtlich des Zeitpunktes der Entscheidung, Methoden mit *a priori* Entscheidung, mit *a posteriori* Entscheidung und Methoden mit *progressiver* oder interaktiver Entscheidung. Beispiele und einen Überblick zum Stand der Technik progressiver Methoden bietet Abschnitt 2.3. Die Unterschiede und Charakteristika der drei Kategorien werden im Folgenden aus Perspektive der Entscheidungsfindung erläutert.

3.1.1 A priori Entscheidung

Die zur Lösung des Gesamtproblems erforderlichen Entscheidungen werden vor der eigentlichen Optimierung getroffen. Das Optimierungsproblem wird dabei derart formuliert, dass es durch ein einziges skalares Gütemaß oder Kriterium abgebildet wird. Gegebenenfalls konfliktionäre Kriterien eines ursprünglich multikriteriellen Problems müssen hierbei geeignet zusammengefasst werden, beispielsweise durch eine gewichtete Summe. Unter der bereits formulierten Annahme, dass sich kaum ein Problem in allen Aspekten durch ein einzelnes Gütekriterium beschreiben lässt, ergeben sich bei diesem Ansatz verschiedene Probleme. Nur im Falle einer konvexen Pareto-Front (bei Betrachtung aus Richtung des Minimums) lässt sich jeder Kompromiss durch eine Gewichtung der einzelnen Kriterien beschreiben [84]. Daneben ist es generell schwierig eine Entscheidung für einen Kompromiss zu treffen, ohne die Menge der möglichen Alternativen zu kennen oder abschätzen zu können.

Das Bild 3.1 zeigt das Beispiel eines einfachen Transportproblems, bei dem ein optimales Verkehrsmittel für eine gegebene Reise gewählt werden muss. Das Bild verdeutlicht beispielhaft das Zusammenfassen der beiden fiktiven Kriterien $f_1 = \text{„Kosten“}$ und $f_2 = \text{„Zeitaufwand“}$ zu einem skalaren Kriterium $f = \text{„}w_1 \cdot \text{Kosten} + w_2 \cdot \text{Zeitaufwand“}$ durch eine gewichtete Summe. Es resultiert eine virtuelle neue Dimension, die eine eindeutige Ordnung der betrachteten Elemente erlaubt. Im konkreten Beispiel führt dies zur Reihenfolge $B > A > C > D$. Kritisch ist dabei die Wahl des Gewichtungsverhältnisses $\frac{w_1}{w_2}$. Im Allgemeinen stehen, wie auch im hier gewählten Beispiel, die Einheiten der einzelnen Kriterien nicht miteinander im Zusammenhang. Die Entscheidung für eine Gewichtung legt jedoch eine Relation der Einheiten zueinander fest und erfordert daher Wissen über die zu erwartenden Kriterienwerte. Das Bild zeigt die Pareto-Front als gestrichelte Linie, beispielhaft sind drei Pareto-optimale Lösungen und eine weitere Lösung markiert. Die Gewichtung kann als orthogonale Projektion aus dem zweidimensionalen Kriterienraum auf die durch die gewählte Gewichtung bestimmte neue Achse der aggregierten Kriterien dargestellt werden. Das globale Optimum für das skalare Kriterium wird bestimmt durch den Schnittpunkt dieser Achse mit der Pareto-Front. Dort existiert eine eindeutige, im Sinne dieser Gewichtung optimale Lösung. Alle anderen Lösungen, unabhängig davon, ob diese Teil der




Bild 3.1: Beispiel: Reduktion des Kriterienraumes auf ein skalares Kriterium durch gewichtete Summation

Pareto-Front sind, werden von dieser Lösung dominiert. Für die gesamte Lösungsmenge kann entsprechend immer eine vollständige Ordnung ermittelt werden.

Ist die Entscheidung für eine Gewichtung oder ein anderes skalares Gütekriterium getroffen, stellt sich die eigentliche Optimierung als vergleichsweise einfach dar. Für das Lösen auch nichtlinearer und komplexer Probleme mit nur einem Kriterium stehen neben einer Vielzahl evolutionärer Methoden auch zahlreiche andere bewährte Problemlösungs- und Optimierungsmethoden zur Verfügung (siehe Abschnitt 2.1).

3.1.2 A posteriori Entscheidung

Wird die Entscheidungsfindung dem eigentlichen Optimierungsverfahren nachgeordnet, so zielt dieses nicht auf das Auffinden einer einzelnen optimalen Lösung, sondern auf das Approximieren der Menge möglicher Kompromisse für alle Gütemaße des Problems, der Approximation der Pareto-Menge. Der Entscheider sieht sich nun mit der Aufgabe konfrontiert, aus dieser im Allgemeinen beliebig großen Menge eine einzelne Lösung auszuwählen, die seinen Präferenzen am besten entspricht. Diese Entscheidung kann, im Gegensatz zur a priori Entscheidung, unter Kenntnis aller möglicher Alternativen getroffen werden. Ein Benutzer kann, eine ausreichend präzise Approximation der wahren Pareto-Front vorausgesetzt, objektiv abschätzen, wie viel quantitativer Verlust in einem gegebenen Kriterium der Gewinn in einem anderen bedeutet. Der angenäherte lokale Gradient der Pareto-Front an einer betrachteten Stelle charakterisiert dabei den Kompromiss. Umgekehrt kann dieser, zumindest im Fall einer konvexen Form der Front, auf ein Gewichtungsverhältnis der Kriterien zurückgeführt werden, das im Fall einer a priori Entscheidung zu diesem Ergebnis geführt hätte.




Bild 3.2: Beispiel: Pareto-Front optimaler Kompromisse als Grundlage für die Entscheidung

Das Bild 3.2 zeigt eine mögliche Pareto-Front für das bereits bekannte Beispiel des Transportproblems. Mehrere Verkehrsmittel, in diesem Beispiel alle Lösungen auf der gestrichelten Linie, stellen optimale Kompromisse zwischen f_1 „Kosten“ und f_2 „Zeitaufwand“ dar und sind das Ergebnis der multikriteriellen Optimierung. Alle diese Lösungen sind besser als die ebenfalls gezeigten dominierten Lösungen „Schiff“ und „Dampfloek“, sind untereinander aber im Sinne der Pareto-Dominanz nicht vergleichbar. Bei der Beurteilung der Lösung „Schnellzug“ zum Beispiel, kann der Entscheider mögliche Alternativen berücksichtigen. In die Entscheidung kann beispielsweise mit einbezogen werden, wie viel mehr Kosten die Reduktion des Zeitaufwands durch die Lösung „Kleinwagen“ bedeuten würde.

Die Probleme dieser Vorgehensweise liegen zum einen im Detail des Entscheidungsprozesses. Der Benutzer sieht sich mit einer sehr großen Menge von Alternativen und damit verbunden mit einem sehr aufwändigen Prozess der Auswahl konfrontiert. Zum anderen ist gerade für hochdimensionale Optimierungsprobleme die Approximation der Pareto-Front schwierig. Ein auch als „Fluch der Dimensionalität“ [85] bekannter Effekt erklärt sich dadurch, dass die zur Beschreibung einer Funktion notwendige Anzahl von Daten, also in diesem Fall Lösungsprototypen oder Individuen zur Approximation der Pareto-Front, exponentiell mit der Dimension steigt. Noch darüber hinaus verhält sich die Wahrscheinlichkeit $P(l_i \succ l_j)$, dass eine beliebige gegebene Lösung l_i von einer zufälligen anderen l_j dominiert wird, mit $P(l_i \succ l_j) = 1/2^{d_k}$ ebenfalls exponentiell zur Dimension d_k des Kriterienraumes. Beide Effekte erschweren erheblich die Konvergenz eines MOEA und führen zu einem stark erhöhten Rechen- und Zeitaufwand oder können, da sich die klassischen dominanzbasierten Selektionsmechanismen nicht uneingeschränkt skalieren lassen [86, 87], die Konvergenz auch ganz verhindern. Betrachtet man die Optimierung unter der Voraussetzung eines

festen Budgets von Individuen und Bewertungen und des Vorhandenseins eines lokalen interessanten Bereichs der gesamten Pareto-Front, dann wird die Optimierung durch die Approximation von nicht interessanten Bereichen ineffizient. Zum einen entfällt auf die Approximation der relevanten Teilbereiche nur ein Teil des zur Verfügung stehenden Budgets von Bewertungen. Zum anderen reduziert die Verteilung von Populationen limitierter Größe auf die gesamte Pareto-Front die räumliche Auflösung der Approximation.

3.1.3 Progressive Entscheidung

Um die Einschränkungen und Probleme der beiden zuerst genannten Ansätze zu eliminieren, zielt die progressive Integration der Entscheidungsfindung darauf ab, nur die Vorteile der beiden Strategien durch eine Verlagerung des Entscheidungsprozesses in den Optimierungsprozess zu verknüpfen. Anstelle einer einzelnen monolithischen Entscheidung vor oder nach der Optimierung wird der Entscheidungsprozess hier in mehrere einzelne Entscheidungen über den Verlauf der Optimierung hinweg verteilt. Die Integration der Entscheidung resultiert in einem geschlossenen Kreis aus Optimierung und menschlichem Entscheider wie in Abb. 3.3 dargestellt. Der Entscheider fungiert dort ähnlich einem Regler und beeinflusst den Optimierungsprozess durch das Formulieren einer Auswahl auf Grundlage seiner im Allgemeinen abstrakten Präferenzen oder Vorstellungen von einer optimalen Lösung und einer vom aktuellen Zustand der Optimierung bestimmten Menge von Alternativen. Am Ende des gesamten Prozesses steht eine einzelne Lösung oder eine reduzierte Lösungsmenge, die den vorgegebenen Präferenzen bestmöglich entspricht.

Dieses Schließen des Kreises erfordert die Beantwortung einiger zentraler Fragen:

1. Welche Alternativen sollen dem Entscheider als Entscheidungsgrundlage vorgeschlagen werden und auf welche Art werden sie präsentiert?
2. Welche Art und Anzahl von Entscheidungen darf oder muss der menschliche Entscheider treffen?
3. Wie wird die aus der Entscheidung gewonnene Information zur Beeinflussung der Optimierung genutzt?

Kybernetisches Verständnis eines Entscheidungsprozesses

Bei der Betrachtung von Entscheidungsprozessen im kybernetischen Sinn nach von Foerster [88] kann der Entscheider als Teil eines geschlossenen, zeitdiskreten Regelkreises betrachtet werden, in dem er iterativ abhängig von einem aktuellen Zustand durch seine Entscheidung die weitere Entwicklung des Prozesses und damit den folgenden Zustand beeinflusst. Dies stellt eine Analogie zu dem in Bild 3.3 dargestellten Kreis dar. Für die anhand dieses Bilds definierten Fragestellungen lassen sich Entsprechungen in der formalen Betrachtung von Entscheidungsprozessen finden.

Die Entwicklung der in dieser Arbeit präsentierten Methode der interaktiven Optimierung

basiert auf einer im folgenden Abschnitt 3.2 dokumentierten Analyse des Entscheidungsprozesses und daraus abgeleiteten Konsequenzen. In Abschnitt 3.3 wird auf dieser Grundlage ein Verfahren entwickelt, das die drei zentralen Fragen im Zusammenhang mit der integrierten Entscheidungsfindung geeignet beantwortet.

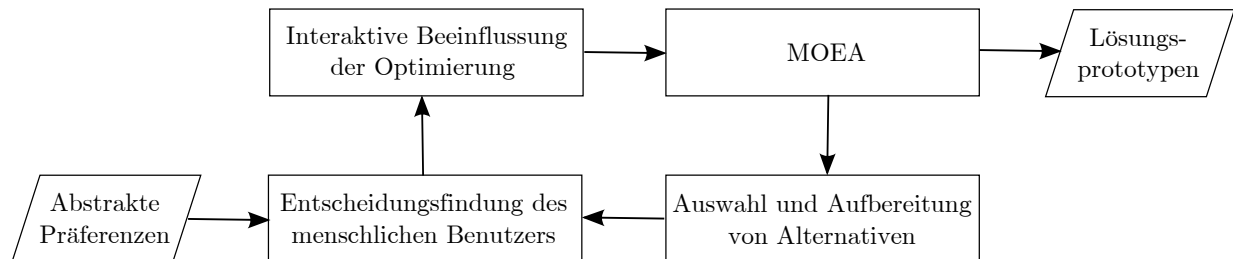


Bild 3.3: Ergänzung der multikriteriellen evolutionären Optimierung durch einen menschlichen Entscheider zu einem geschlossenen Kreis

3.2 Entscheidungsfindung im Entwicklungsprozess

Die Entscheidungsfindung durch einen Menschen ist allgemein beschrieben ein kognitiver Prozess, der das Ziel hat, zur Auswahl aus mehreren Alternativen zu führen. Die meisten einfachen Entscheidungen, die Menschen treffen, laufen dabei völlig unbewusst ab. An der Grenze zur bewussten Entscheidung findet man Vorgänge, die als Intuition beschrieben werden können. Wirklich bewusste und komplexere Entscheidungsprozesse finden nur dann statt, wenn die betrachteten Fragen auf diese Art eigentlich nicht entscheidbar sind [88]. Der dann stattfindende Entscheidungsprozess nutzt zusätzliche externe, persönliche oder im Problem selbst veranlagte Informationen, um für diese Fragen eine Auswahl treffen zu können. Ein Entscheidungsprozess lässt sich formal in die folgenden Schritte gliedern [89]:

1. Feststellen eines Entscheidungsbedarfs
2. Analyse des Entscheidungsumfeldes
3. Ermittlung der Alternativen
4. Beurteilung der zu erwartenden Konsequenzen jeder Alternative
5. Entscheidung oder Umsetzung einer Alternative
6. Beobachtung der Konsequenzen und gegebenenfalls Revision der Entscheidung

Die Integration der Entscheidungsfindung in einen Optimierungsprozess muss die einzelnen Schritte und Aspekte des Prozesses berücksichtigen. Das in dieser Arbeit vorgestellte

Verfahren hat zum Ziel, möglichst große Teile dieses Prozesses zu vereinfachen oder zu automatisieren und der direkten Verantwortung des menschlichen Entscheiders zu entziehen und auf den Optimierungsalgorithmus zu verlagern, um die Belastung des Entscheiders zu reduzieren. Das Feststellen eines Entscheidungsbedarfs sowie die Analyse des Entscheidungsumfeldes und die daraus resultierende Ermittlung der Alternativen kann weitgehend automatisiert stattfinden. Durch eine geeignete Gestaltung der Entscheidung selbst (vgl. Abschnitt 3.2.2) wird die Beurteilung der Konsequenzen der Entscheidung in die Nähe einer intuitiven Entscheidung verlagert. Die rückblickende Beurteilung der Entscheidung kann ebenfalls automatisiert und zur Adaption des Entscheidungsprozesses genutzt werden.

3.2.1 Belastungen durch Entscheidungen

Die Entscheidung selbst wird unter verschiedenen Gesichtspunkten als Belastung für den Benutzer betrachtet. Auf der Seite des Algorithmus stellt die Interaktion mit einem Menschen einen vergleichsweise langsamen Prozess dar, der die Bearbeitungszeit erhöht. Gestützt auf die ausreichend große Rechenleistung aktuell verfügbarer Computersysteme und die im Allgemeinen recht geringe Komplexität der verwendeten evolutionären Operatoren kann die eigentliche Rechenzeit für den EA praktisch vernachlässigt werden. Für die meisten realen Anwendungen stellt die Fitnessbewertung der Lösungen die deutlich größeren Anforderungen an die Rechenleistung. Allerdings ist die Zeitskala, auf der ein menschlicher Benutzer seine Entscheidungen trifft, erheblich langsamer, weshalb bereits die unvermeidlichen Wartezeiten bei der interaktiven Optimierung maßgeblich für die gesamte Laufzeit sind. Eine Herausforderung für den Optimierungsalgorithmus ergibt sich aus der zu erwartenden Ungenauigkeit und möglichen Fehlern in der Entscheidung, die die Nutzbarkeit und Belastbarkeit der Informationen einschränken. Schließlich ist auch aus der Sicht des Experten selbst die Entscheidungsfindung der aufwändigste und am meisten belastende Teil des ansonsten automatisierten Optimierungsprozesses. Unter den genannten Aspekten betrachtet ergibt sich für die Integration des Entscheidungsprozesses die Aufgabe, zum einen die Anzahl der vom Menschen zu treffenden Entscheidungen möglichst zu reduzieren, zum anderen diese Entscheidungen so weit wie möglich zu vereinfachen, auch um die Wahrscheinlichkeit für fehlerhafte Entscheidungen zu minimieren.

3.2.2 Psychologische Betrachtung der Entscheidungssituation

Die Entscheidung, die dem Experten abverlangt wird, ist in verschiedener Hinsicht so zu gestalten, dass die Entscheidung selbst möglichst wenig kognitive Belastung darstellt und wenig anfällig für Fehler im Entscheidungsprozess ist. Die Charakterisierung von Entscheidungssituationen führt zu der folgenden Reihe zentraler Aspekte [89], deren konkrete Ausgestaltung maßgeblich ist für die potentielle Belastung und Fehleranfälligkeit, die mit der Entscheidung verbunden ist.

- Die Optionenmenge ist vollständig vorgegeben und geschlossen, eine Auswahl und Aufbereitung der Optionen ist dadurch nicht erforderlich.

- Die Entscheidung ist einstufig, es ist nicht erforderlich weitere Entscheidungen zu treffen, die direkt durch vorangegangene Antworten bestimmt werden.
- Die Entscheidung ist einmalig. Eine spezifische Entscheidung muss oder kann nicht wiederholt werden. Dies macht zwar zum einen die Konsequenzen aus fehlerhaften Entscheidungen gravierender, zum anderen wird aber der Entscheider vom möglichen Druck konsistente Entscheidungen zu treffen entlastet.
- Der kognitive Aufwand wird gering gehalten. Primär durch eine intuitiv interpretierbare Repräsentation der Optionen und ihrer Konsequenzen kann die prinzipiell als *reflektiert* zu klassifizierende Entscheidung in Richtung einer *stereotypen* oder sogar *routinisierten* Entscheidung verändert werden, deren erforderlicher kognitiver Aufwand geringer ist [89].
- Die Wahl wird anhand von Präferenzen getroffen, eine Abwägung des tatsächlichen Nutzens wird durch die Gestaltung der Entscheidungssituation vermieden. Wird nur ein relativer Vergleich der Optionen gefordert, ist dieser durch den Entscheider einfacher zu quantifizieren als eine absolute Abschätzung des Nutzens der Konsequenzen der betrachteten Entscheidungsoptionen.

Die geeignete Berücksichtigung dieser Aspekte betrifft die Entscheidung selbst als den zentralen Punkt des Entscheidungsprozesses. Darüber hinaus wird die Belastung für den Entscheider auch indirekt dadurch beeinflusst, wie erfolgreich die übrigen Schritte des Entscheidungsprozesses vom Entscheider auf den Algorithmus verlagert werden können.

3.2.3 Partielle Ordnung in teilweise unbekanntem Lösungsmengen

Die durch einen integrierten Entscheidungsprozess ermittelte Präferenz dient dazu, innerhalb einer Menge nicht vergleichbarer Pareto-optimaler Lösungen eine Diskriminierung zu erzielen. *Diskriminierung* bedeutet in diesem Kontext die Unterscheidung auf Grundlage einer Wertung. Für die evolutionäre Selektion ist es ausreichend, eine präferierte Teilmenge zu bestimmen und für die nächste Generation auszuwählen. Dazu ist es nicht nötig, eine vollständige Ordnung für alle Lösungen $l_n \in L$ innerhalb der Lösungsmenge L herzustellen, es genügt eine partielle Ordnung, die es ermöglicht, die Lösungsmenge in eine zu selektierende Menge L_S und eine Menge L_R mit nicht selektierten Lösungen zu unterteilen. Dabei gilt für die Ordnungsrelation der Lösungen in der Menge (L, \geq) :

$$l_i \geq l_j \Leftrightarrow \forall i, j \mid l_i \in L_S \wedge l_j \in L_R \quad . \quad (3.1)$$

Nur im Fall eines eindimensionalen Optimierungsproblems mit einem Kriterium $f \in \mathbb{R}$ entspricht diese Ordnungsrelation auch der bekannten mathematischen Relation $f_i \geq f_j$ und führt in jedem Fall zu einer totalen Ordnung der Mengen. Im multikriteriellen Fall

gilt die Dominanzrelation (L, \succ) , die einem „komponentenweise größer oder gleich“ (\geq^n) für das n -Tupel der Kriterien entspricht, und führt zu der Selektionsbedingung:

$$\mathbf{f}_i \prec \mathbf{f}_j \Leftrightarrow \forall i, j \mid l_i \in L_S \wedge l_j \in L_R \quad . \quad (3.2)$$

Da diese Relation aufgrund der Nichtvergleichbarkeit von Kriterien-Tupeln ($\mathbf{f}_i \not\asymp \mathbf{f}_j$) nicht für alle Lösungspaare $\{l_i, l_j\}$ auch immer einer Ordnungsrelation entspricht ($l_i \geq l_j$), führt diese im Allgemeinen nur zu einer Teilordnung der Menge L , die nicht in jedem Fall eine eindeutige Teilung in L_S und L_R erlaubt. Da die Wahrscheinlichkeit für die Nichtvergleichbarkeit wie in 3.1.2 beschrieben mit der Dimension des Problems steigt, sind zusätzliche Mechanismen oder Informationen erforderlich, um eine eindeutige Selektionsentscheidung treffen zu können. Dabei ist es abermals nicht erforderlich eine totale Ordnung für L zu erzielen, eine Ordnung, die die Gleichung 3.1 erfüllt, reicht aus. Die erforderliche Information, um die notwendige Sortiertheit herzustellen, lässt sich dabei am besten über paarweise Relationen von Lösungen beschreiben. Da die Teilung in L_S und L_R primär durch die angestrebte Größe dieser Mengen bestimmt wird, existiert kein absolutes Kriterium für die Zuordnung einer Lösung zu einer der Mengen. Ist jedoch für eine Lösung bekannt, dass $l_i \in L_S$, so lässt sich daraus ableiten

$$l_j \in L_S : \forall l_j \mid l_j \geq l_i \wedge l_i \in L_S \quad . \quad (3.3)$$

Ebenso gilt im umgekehrten Fall

$$l_j \in L_R : \forall l_j \mid l_j \leq l_i \wedge l_i \in L_R \quad . \quad (3.4)$$

Darauf basierend kann eine zum Zweck der Selektion von L_S ausreichende partielle Ordnung allein durch die Verwendung relativer Vergleiche von Lösungspaaren aufgebaut werden, ohne ein absolutes skalares Kriterium verwenden zu müssen.

3.2.4 Vergleichbarkeit von Lösungen

Eine Beschreibung der Präferenz im Kriterienraum erfordert abhängig von deren Realisierung verschiedene Annahmen bezüglich der Struktur oder mathematischen Eigenschaften der Nutzenfunktion des Anwenders. So impliziert beispielsweise die Summe von positiv gewichteten Kriterien als Nutzenfunktion die Monotonie und Linearität der Benutzerpräferenz in allen Kriterien. Das Konzept der lokalen Modellierung anhand relativer Vergleiche erlaubt die Abbildung einer nichtlinearen Nutzenfunktion, erfordert aber immer noch die Monotonie im Hinblick auf die einzelnen Kriterien. Das Konzept der Nichtvergleichbarkeit von Lösungskandidaten ermöglicht indirekt voneinander unabhängige lokale nichtlineare Nutzenfunktionen für verschiedene Regionen des Kriterienraums. Aus Sicht der multikriteriellen Optimierung ist es dabei das Ziel, nur Lösungen, die miteinander vergleichbar sind, also für die die gleiche Nutzenfunktion gültig ist, zum Zweck der Selektion miteinander in Konkurrenz zu setzen. Lösungen hoher Präferenz verschiedener Bereiche sollen hingegen voneinander unabhängig und parallel weiter optimiert werden.

Abstrakt lassen sich also Präferenz und Vergleichbarkeit als Aspekte einer Ordnungsrelation betrachten, in der zwei Lösungen l_i und l_j in drei grundsätzlichen Beziehungen zueinander stehen können. Es kann eine Präferenz von l_i gegenüber l_j bestehen ($l_i \gg l_j$), beide können nicht vergleichbar sein ($l_i \parallel l_j$) oder aber beide sind vergleichbar und es gilt für beide die gleiche Präferenz ($l_i = l_j$). Diese Notation dient der Abgrenzung gegenüber den im Prinzip gleichen Relationen, die hinsichtlich der Pareto-Dominanz auftreten können. Sie werden jedoch als zusätzliche Relation und als im Allgemeinen unabhängig von der Dominanzrelation im Kriterienraum betrachtet.

Das Bild 3.4 soll mittels des Beispiels einer fiktiven Transport- oder Reiseaufgabe das Konzept der Vergleichbarkeit verdeutlichen. Das Bild zeigt die fiktive Pareto-Front für das Problem, dessen grundlegende Kriterien die Kosten sowie der Zeitaufwand der Reise sind. Alle markierten Lösungen A bis D sind hinsichtlich der Dominanzrelation nicht vergleichbar und nicht-dominiert und stellen somit optimale Kompromisse dar, für die zusätzlich die Präferenz des Benutzers formuliert werden soll. Denkbar ist ein Benutzer mit einer Präferenz, die sowohl das Bahnreisen als besonders komfortabel als auch den PKW wegen seiner Geschwindigkeit in Erwägung zieht. Weiter denkbar ist, dass dieser Lösung A gegenüber B vorzieht, da für die Entscheidung zwischen zwei PKW die sportliche Fahrweise präferiert wird, davon unabhängig ein Regionalzug D dem Schnellzug C vorgezogen wird, da der Fahrplan hier eine flexible Abfahrtszeit ermöglicht. Die verschiedenen der Präferenz zu Grunde liegenden Annahmen werden dadurch abgebildet, dass für A und B sowie C und D jeweils eine klare Dominanzrelation formuliert wird, Elemente verschiedener Gruppen jedoch nicht miteinander verglichen werden. Die vollständige Präferenzrelation kann also formuliert werden als:

$$(A \gg B) \parallel (D \gg C). \quad (3.5)$$

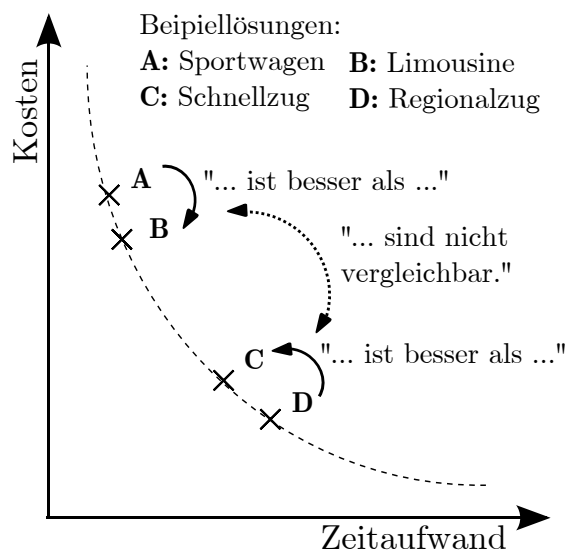


Bild 3.4: Beispiel zur Interpretation der Vergleichbarkeit von Lösungen

3.3 Integration der Entscheidungsprozesse in den Optimierungsalgorithmus

Die Nutzung der Benutzerpräferenzen stellt eine Erweiterung eines multikriteriellen evolutionären Algorithmus dar. Der hier beschriebene und den Ergebnissen und Analysen zugrunde liegende Algorithmus ist der in Abschnitt 2.2 bereits beschriebene NSGA-II. Die Beeinflussung durch Benutzerpräferenzen beschränkt sich auf den Selektionsmechanismus, die anderen Komponenten wie Mutations- oder Rekombinationsoperatoren entsprechen dem Ursprungsalgorithmus. Die Anwendbarkeit der beschriebenen interaktiven oder präferenzbasierten Mechanismen ist jedoch nicht auf den genannten Basisalgorithmus beschränkt, sondern kann prinzipiell auch mit anderen Realisierungen eines MOEA verwendet werden. Auf eine vergleichende Analyse verschiedener Basisalgorithmen wird in dieser Arbeit verzichtet, da die Eignung von NSGA-II als leistungsfähiger und vergleichsweise universeller MOEA weitgehend unumstritten ist und dieser als Referenzverfahren in der Literatur weit verbreitet ist [25].

Die Erweiterung der Selektion um die Berücksichtigung progressiv formulierter Präferenzen macht aus dem Algorithmus einen interaktiven MOEA (I-MOEA). Bild 3.5 zeigt den prinzipiellen Ablauf dieses erweiterten Algorithmus. An die Stelle, an der sich im NSGA-II die Selektion basierend auf Pareto-Dominanz und der sogenannten *Crowding Distance* als Mechanismus zur gleichmäßigen Verteilung der Lösungen auf der Pareto-Front findet, tritt für die präferenzbasierte Selektion zunächst eine auf der Pareto-Dominanz basierende Vorselektion. Die Benutzerpräferenzen sind nur dann relevant, wenn anhand der Optimierungskriterien nicht eindeutig Lösungen selektiert werden können, also eine Anzahl $n > \mu$ nicht-dominierte Lösungen ermittelt wurden. Für die Menge $L_{d=1}$ aller dieser Individuen wird die Präferenz anhand des aktuellen Modells ermittelt und dient als Grundlage zur Auswahl der am stärksten präferierten Untermenge L_S der gewünschten Populationsgröße μ . Das Präferenzmodell basiert auf einer Datenbank von real durch den Experten bewerteten Lösungspaaren und wird für jeden Selektionsprozess herangezogen. Diese Datengrundlage des Präferenzmodells wird bei Bedarf sukzessive erweitert durch das interaktive Bewerten von Lösungspaaren aus der Menge $L_{d=1}$ der nicht-dominierten Lösungen. Ist die Erweiterung der Datengrundlage für die Präferenzmodellierung erforderlich oder erwünscht, werden dem Experten in Abhängigkeit der gewählten Strategieparameter ein oder mehrere Lösungspaare zu Bewertung vorgelegt. Aus der aktuellen Teilpopulation $L_{d=1}$ werden wie nachfolgend in Abschnitt 3.4.3 beschrieben informationsmaximierende Lösungspaare ausgewählt und dem Experten mittels der in Abschnitt 3.4.1 eingeführten Schnittstelle zur Entscheidung vorgelegt. Die bewerteten Lösungspaare werden der Datengrundlage des Präferenzmodells hinzugefügt. Besteht zu Beginn des Optimierungsprozesses noch keine Datengrundlage für das Präferenzmodell, so werden dem Experten mehrere Fragen gestellt, die zufällig, also unabhängig von einem zu erwartenden Erkenntnisgewinn, ausgewählt werden.

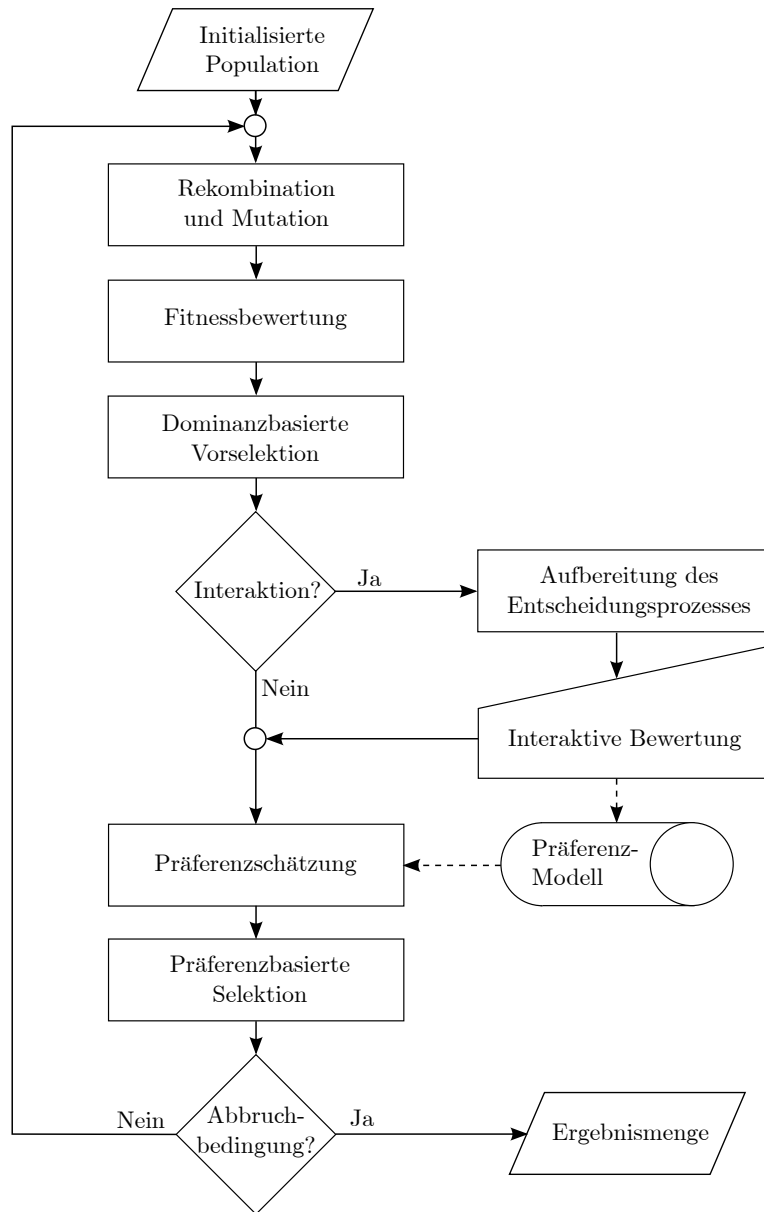


Bild 3.5: Flussdiagramm des MOEA mit interaktiver Präferenzintegration

3.4 Interaktives Erfassen und Abbilden von Präferenzen

Die vollständige Präferenzentscheidung eines Benutzers bezüglich eines Lösungspaars $\{l_i, l_j\}$ lässt sich formal durch einen Präferenzwert $\sigma(l_i, l_j) \in [-1, 1]$ und ein Vergleichbarkeitsattribut $\rho(l_i, l_j) \in [0, 1]$ beschreiben. Eine relative Präferenz von $\sigma = 1$ ist die größtmögliche Präferenz für l_i und entspricht einer absoluten Dominanz hinsichtlich der Präferenz ($l_i \gg l_j$). Ein $\sigma = -1$ ist die inverse Entscheidung und bedeutet die größtmögliche Präferenz von l_j über l_i . Für den Vergleichbarkeitsindex $\rho = 1$ sind beide Lösungen miteinander vergleichbar, für $\rho = 0$ sind beide Lösungen nicht vergleichbar ($l_i \not\geq l_j$) und sollen in keinerlei direkten Wettbewerb miteinander treten. Ein Benutzer kann seine Präferenz im Hinblick auf zwei mögliche Lösungen eines Problems formulieren, indem er die Werte σ und ρ für den relativen Vergleich der Kandidaten wählt. Andersherum kann die Präferenz für ein Lösungspaar durch diese beiden Werte eindeutig beschrieben werden.

Diese Relation wird als Ergänzung zur Pareto-Dominanz und demnach nur für untereinander nicht-vergleichbare Lösungskandidaten ermittelt. Für diese kann der MOEA auf Grundlage der Pareto-Dominanz keine Entscheidung treffen, ein Teil des Entscheidungsprozesses ist damit also schon automatisiert durchgeführt. Große Teile des in Abschnitt 3.2 skizzierten Entscheidungsprozesses ergeben sich als Teil des Algorithmus und finden ohne Beteiligung des Benutzers statt. Die initiale Feststellung des Entscheidungsbedarfs ergibt sich unmittelbar aus dem Selektionsprozess. Nur sofern ein Überschuss nicht-dominiertes, also im Sinne ihrer Dominanz-Relation *nicht-vergleichbarer* Lösungen vorhanden ist, entsteht der Bedarf eines zusätzlichen Merkmals zur Selektion. Die möglichen Alternativen sind dadurch bereits für eine Entscheidung aufbereitet, dass nur nicht-dominierte und hinsichtlich ihrer Eignung als eindeutig diskriminierende Repräsentanten ausgewählte Lösungen als Alternativen zur Verfügung stehen. Das Entscheidungsumfeld wird durch die vom Benutzer erfragte, lediglich relative Bewertung zweier Alternativen stark reduziert. Der Benutzer muss nur Umfeldfaktoren berücksichtigen, die direkt seine Präferenzen beeinflussen, bereits getroffene Entscheidungen hingegen müssen nicht berücksichtigt werden. Die Motivation für die zu treffende Entscheidung ist neben dem grundsätzlichen Anspruch ein optimales Ergebnis zu erzielen, die ja auch dem Einsatz eines Optimierungsverfahrens zugrunde liegt, stark abhängig vom Optimierungsproblem, dem aktuellen Fortschritt der Optimierung und möglicherweise auch strategischen Überlegungen des Anwenders. Wie die Präferenz an sich kann auch die Motivation für eine konkrete Entscheidung im Verlauf des Entwicklungs- oder Optimierungsprozesses variieren, sich beispielsweise in verschiedenen Phasen der Optimierung auf verschiedene Detaillierungsgrade einer Lösung beziehen. Das Verfahren zur interaktiven Integration von Benutzerpräferenzen muss dies berücksichtigen können.

3.4.1 Schnittstelle zur interaktiven Präferenzartikulation

Ist eine Entscheidung der beschriebenen Form durch einen Benutzer erforderlich, werden die beiden Lösungskandidaten mittels einer grafischen Schnittstelle dargestellt. Ein Bei-

spiel für den Aufbau der Schnittstelle ist in Bild 3.6 zu sehen. Im Wesentlichen besteht die Schnittstelle aus Eingabe-Elementen für die Werte σ und ρ , einer Visualisierung der Lösungen sowie den Zugriffsmöglichkeiten auf einige Verwaltungsfunktionalitäten (siehe Anhang C). Ein Schieberegler und Knöpfe ermöglichen die Eingabe der Werte für σ und ρ . Weitere Knöpfe erlauben den Zugriff auf Parameter des Verfahrens, die Korrektur bisheriger Bewertungen und verschiedene Methoden, die manuelle Interaktion zu beenden, ohne die Optimierung abubrechen. Die dem relativen Vergleich dienende Visualisierung der Lösungen ist problemspezifisch und kann grundsätzlich beliebig gewählt werden, in diesem Beispiel zeigt sie jeweils die Sprungantwort eines durch die zu bewertende Lösung charakterisierten dynamischen Systems. Die eigentliche Entscheidung kann damit sowohl im Kriterien- als auch im Lösungsraum oder basierend auf beliebigen Zusatzinformationen getroffen werden. Da der relative Vergleich zum Ziel hat, die eigentliche Entscheidung möglichst intuitiv treffen zu können (vgl. Abschnitt 3.2), bietet sich eine grafische Darstellung an, die ebenfalls einen möglichst intuitiven Vergleich erlaubt. Für den Einsatz im technischen Entwicklungsprozess bietet sich eine Betrachtung an, die auch ohne den Einsatz von Optimierungsmethoden zur Beurteilung eines Prototypen einer Lösung anwendungsspezifisch Verwendung findet.

3.4.2 Instanzbasierte Präferenzmodellierung

Alle bewerteten Lösungspaare bilden die Basis für die Modellierung der Benutzerpräferenzen in Form eines instanzbasierten Modells. Jedes Paar bildet dabei eine Instanz der Datenbank D_σ . Für ein unbekanntes Lösungspaar wird basierend auf dessen Ähnlichkeit zu den gespeicherten Instanzen ein lokales Präferenzmodell ermittelt. Dem liegt die Annahme zugrunde, dass der Benutzer Lösungspaare, die sich ähnlich sind, auch ähnlich bewerten würde.

Die präferenzbasierte Selektion stellt eine Erweiterung der dominanzbasierten Auswahl dar, die Ähnlichkeit von Lösungen wird daher wie diese ebenfalls im Kriterienraum ermittelt. Prinzipiell ist die Methode jedoch nicht darauf beschränkt, eine Betrachtung der Ähnlichkeit beispielsweise im Parameterraum ist ebenfalls denkbar. Abhängig ist dies davon, ob für den gewählten Raum die dem Verfahren zugrunde liegende Annahme gilt, dass ähnliche Präferenzen für lokale ähnliche Lösungen gelten.

Da absoluten Kriterienwerten wenig Aussagekraft zugemessen wird und die Unabhängigkeit der Raumdimensionen nur erhalten bleibt, wenn lediglich die relative Ordnung von Lösungen in einem Kriterium betrachtet wird, ist zur Ermittlung von Ähnlichkeiten eine Normalisierung des Kriterienraums erforderlich. Da weder Skalierung noch Minima und Maxima der einzelnen Kriterien a priori bekannt oder im Verlauf der Optimierung konstant sind, werden zur variablen Normierung der Kriterien die jeweils bisher aufgetretenen Minima und Maxima verwendet. Die Ähnlichkeit des zu bewertenden Paares $\{l_a, l_b\}$ mit jedem Paar $\{p_i, p_j\}$ aus der Menge D_σ wird bestimmt durch den Abstand d der Lösungen im auf diese Art normalisierten Kriterienraum nach Gleichung 3.6. Die veränderliche Normierung sorgt dafür, dass sich auch die formale Ähnlichkeit eines Lösungspaares im Verlauf der Evolution verändern kann und als relative Ähnlichkeit im Kontext der Verteilung von

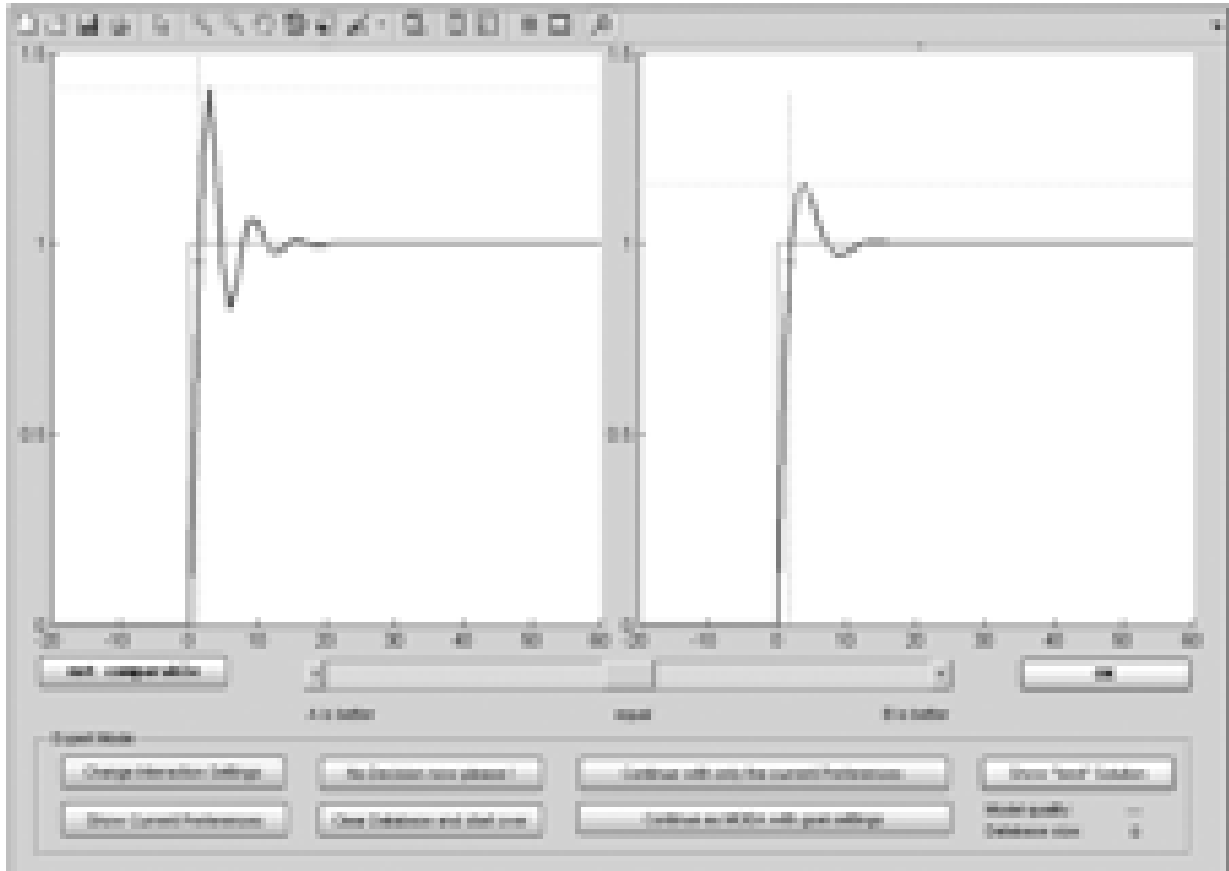


Bild 3.6: Beispiel für eine grafische Benutzerschnittstelle zur interaktiven Präferenzartikulation

Lösungen in der gesamten Lösungsmenge betrachtet werden muss.

$$d(\{l_a, l_b\}, \{p_i, p_j\}) = \|f(\mathbf{x}_i) - f(\mathbf{x}_a)\|_2 + \|f(\mathbf{x}_j) - f(\mathbf{x}_b)\|_2 \quad . \quad (3.6)$$

Formal kann ein und dasselbe Lösungspaar in zwei Erscheinungsformen betrachtet werden, also in diesem Fall auch als Paar $\{l_b, l_a\}$. Da die Definition der Präferenzbeschreibung durch σ und ρ symmetrisch und daher für die beiden möglichen Paare redundant ist, wird hier nur eine der Varianten betrachtet. Entsprechend wird die Ähnlichkeit jeweils nur zur ähnlichsten Variante jedes bekannten Prototypenpaares ermittelt. Der gewichtete Einfluss eines einzelnen Trainingsdatenpaares ist bestimmt durch eine Gauß'sche Verteilung über dieses Abstandsmaß

$$\omega(\{l_a, l_b\}, \{p_i, p_j\}) = \exp\left(-\frac{d(\{l_a, l_b\}, \{p_i, p_j\})}{d_{min}}\right)^2 \quad , \quad (3.7)$$

in der d_{min} dem mittleren kleinsten Abstand innerhalb der aktuell zu bewertenden Menge entspricht.

Die Schätzung der Präferenz für jedes aktuell betrachtete Lösungspaar wird entsprechend dieser Gewichtung mehr oder weniger durch alle Instanzen der Präferenzdatenbank beeinflusst.

Die geschätzte Präferenzrelation für ein Paar $\{l_a, l_b\}$ wird als gewichtete Summe der Präferenzen aller Trainingspaare berechnet als:

$$\hat{\sigma}(\{l_a, l_b\}) = \frac{\sum_{i,j} \sigma(p_i, p_j) \omega(\{l_a, l_b\}, \{p_i, p_j\})}{\sum_{i,j} \omega(\{l_a, l_b\}, \{p_i, p_j\})} . \quad (3.8)$$

Die Vergleichbarkeit $\hat{\rho}$ jedes Paares wird auf die gleiche Art bestimmt:

$$\hat{\rho}(l_a, l_b) = \frac{\sum_{i,j} (\rho(p_i, p_j) - 1) \omega(\{l_a, l_b\}, \{p_i, p_j\})}{\sum_{i,j} \omega(\{l_a, l_b\}, \{p_i, p_j\})} . \quad (3.9)$$

In beiden Fällen wird die ermittelte gewichtete Summe durch die Summe aller Gewichtungen dividiert. Die geschätzte Präferenz und Vergleichbarkeit aller aktuell betrachteten Lösungspaare ist die Grundlage für die in Abschnitt 3.5 beschriebene Schätzung der Präferenz für eine einzelne Lösung und die darauf basierende Selektion.

3.4.3 Informationsmaximierende Auswahl von Entscheidungskandidaten

Nahezu unabhängig vom tatsächlich zu optimierenden Problem stellt zumindest aus Sicht des Experten die interaktive Bewertung von Prototypen den größten Teil des Gesamtaufwandes für die Optimierung dar (vgl. Abschnitt 3.2.1). Ein wichtiger Aspekt einer interaktiven Optimierung ist es daher, mit möglichst wenigen Interaktionen eine schnelle Konvergenz der Suche zu erzielen, was beide für den Gesamtaufwand relevanten Aspekte, nämlich Anzahl der Gütebewertungen und Anzahl der Interaktionen, positiv beeinflusst. Um die Anzahl der dem Experten gestellten Fragen zu reduzieren, gilt es aus gestellten Fragen den größtmöglichen Informationsgewinn zu erzielen. Informationsgewinn bedeutet in diesem Zusammenhang eine Verbesserung der auf den modellierten Präferenzen basierenden Selektion. Die Grundidee der umgesetzten Methode ist es daher, als maßgebliches Kriterium zur Auswahl maximal diskriminierender Fragen die mit den möglichen Ergebnissen der Entscheidung einhergehende Änderung der Selektionsentscheidung zu verwenden. Die zu erwartende Änderung wird anhand des Vergleichs zwischen dem bisherigen Modell und dem um das zu erwartende Ergebnis der Entscheidung als zusätzliches Trainingsdatum erweiterten Modell abgeschätzt.

Hierzu werden zunächst für jedes Lösungspaar, das einen Kandidaten für eine zu stellende Frage darstellt, mögliche Antworten basierend auf dem aktuellen Modell prognostiziert. Der zu erwartende Einfluss, den diese prognostizierten Antworten auf die Selektion hätten, entscheidet über die zu stellenden Fragen.

Das Bild 3.7 zeigt schematisch den Ablauf dieses Algorithmus zur Auswahl informationsmaximierender Entscheidungskandidaten im Detail. Die durchgezogenen Pfeillinien stellen

in dieser Abbildung den Ablauf des Algorithmus dar, in Abweichung zu herkömmlichen Flussdiagrammen sind hier jedoch mehrere parallele Pfade möglich, die auch als parallel bearbeitet betrachtet werden. Die gestrichelten Pfeillinien sind so zu interpretieren, dass die Informationen des Startpunkts zu jeder Zeit an deren Ende zur Verfügung stehen oder angefordert werden können. Der beschriebene Ablauf erfolgt in jeder Generation, in der neue Entscheidungen durch den Experten erfragt werden sollen. Er findet jeweils auf Grundlage der aktuellen Populationen statt. Eingangsgrößen des dargestellten Systems sind zum einen eine aktuelle Approximation der Pareto-Front, also eine Menge nicht-dominierter und daher auf dieser Grundlage nicht vergleichbarer Lösungen (siehe ① in Bild 3.7), zum anderen die Menge oder auch Datenbank aller bisher bewerteten Lösungspaare (siehe ②).

Die Menge $L_{d=1}$ der nicht-dominierten Lösungen als Grundlage für die Auswahl der interaktiv zu bewertenden Lösungspaare besteht im Allgemeinen aus zahlreichen Lösungsprototypen, die insgesamt die ganze Breite aller aktuell optimalen Kompromisse abdecken, jedoch im Einzelfall einander auch sehr ähnlich sein können. Als tatsächliche Entscheidungsgrundlage dient daher eine Menge von Repräsentanten, deren Größe von der zu verarbeitenden Menge an Informationen abhängt. Es werden c repräsentative Prototypen durch die Anwendung eines hierarchischen Clustering-Algorithmus [90, 91] ermittelt (siehe ③). Hierbei wird die Menge der Lösungen im normalisierten Kriterienraum hierarchisch, beginnend bei den beiden ähnlichsten Individuen, in Gruppen von Lösungen mit größtmöglicher Ähnlichkeit zusammengefasst. Als Repräsentant jeder Gruppe dient die Lösung, die dem Zentrum des jeweiligen Clusters am nächsten liegt. Die Clusteranzahl c wird primär dadurch bestimmt, dass sich aus der Anzahl der Repräsentanten direkt die Zahl möglicher Vergleiche ergibt. Die tatsächliche Ähnlichkeit der Lösungen innerhalb eines Clusters ist zweitrangig, auch wird auf eine Anpassung der Clusterzahl auf die im Allgemeinen unbekannt Struktur der Verteilung der Lösungen im Kriterienraum verzichtet.

Aus der Menge der Lösungsrepräsentanten werden alle möglichen Paare gebildet. Besitzt die Menge die Mächtigkeit $|L_c| = c$ so ergeben sich daraus $\frac{c(c-1)}{2}$ mögliche Paare. Die weiteren Schritte werden für jedes mögliche Paar durchgeführt.

Für die Untersuchung und Bewertung der Relevanz des Lösungspaars $\{l_a, l_b\}$ wird zunächst die Präferenzentscheidung $\hat{\sigma}$ durch das aktuelle Modell geschätzt (siehe ④). Dies erfolgt analog zu dem auch für die spätere Selektion angewendeten Schätzverfahren, das in Abschnitt 3.5.1 detailliert beschrieben ist. Ergebnis der Schätzung sind $\hat{\sigma}\{l_a, l_b\}$ und $\hat{\rho}\{l_a, l_b\}$, die erwartete relative Präferenz und Vergleichbarkeit des Paares. Die Abschätzung der Relevanz der Bewertung dieses Paares beruht auf der Annahme, dass die tatsächliche Entscheidung der prognostizierten ähnlich sein wird, aber dennoch von ihr abweicht. Diese Annahme ist insofern zulässig, als dass eine exakt korrekte Vorhersage nur durch eine exakte Abbildung der Präferenzen durch das Modell möglich ist. In diesem Fall ist aber eine Erweiterung der Datenbasis gar nicht erforderlich und die Auswahl von Entscheidungskandidaten obsolet. Die mögliche Variabilität der Antwort im Vergleich zur Schätzung wird durch zwei hypothetische, der geschätzten Entscheidung ähnliche Antworten nachgebildet, nämlich $\hat{\sigma}\{l_a, l_b\} + \epsilon$ und $\hat{\sigma}\{l_a, l_b\} - \epsilon$ (siehe ⑤). Beide Antworthypthesen werden parallel weiter verfolgt und führen zu jeweils einem erweiterten Präferenzmodell. Die erweiterten

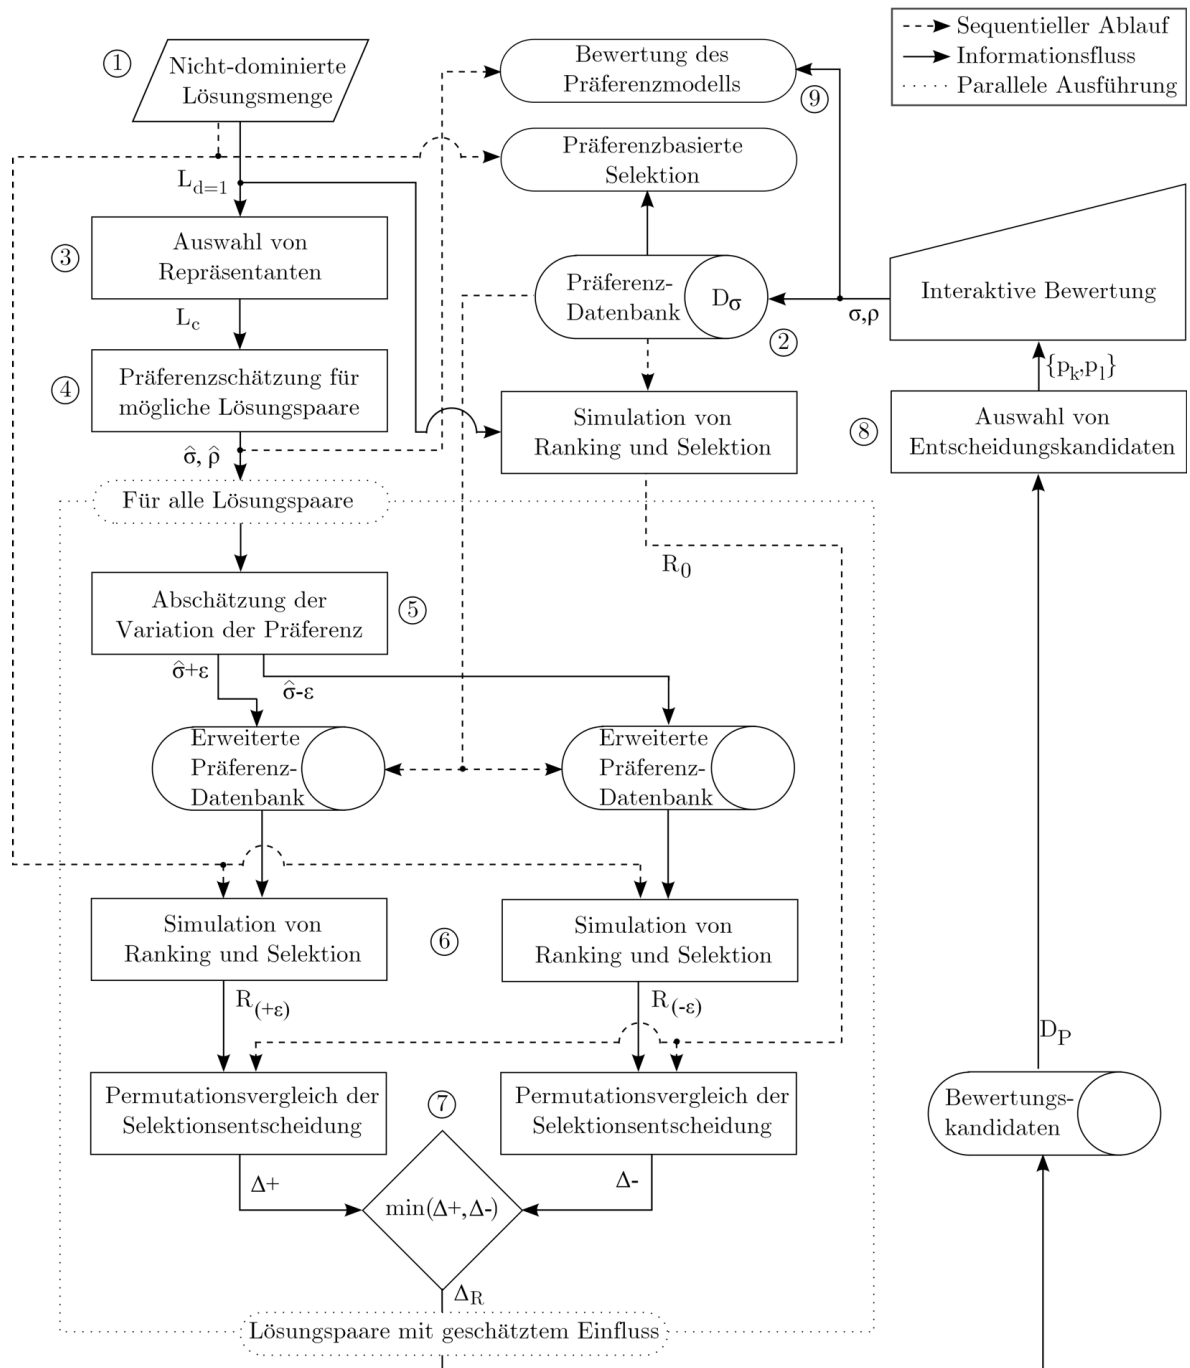


Bild 3.7: Ablaufdiagramm des Verfahrens zur Auswahl informationsmaximierender Entscheidungskandidaten

Modelle werden verwendet, um für die aktuelle Population je eine Selektionsreihenfolge $(R_{+\epsilon}, R_{-\epsilon})$ hinsichtlich der geschätzten Präferenz zu ermitteln (siehe ⑥). Diese Vorgehensweise wird ebenfalls analog zu der späteren tatsächlichen Selektion wie in Abschnitt 3.5 beschrieben durchgeführt.

Die ersten μ potentiell selektierten Individuen beider simulierten Rangfolgen werden mit der Rangfolge der ohne dieses neue Trainingsbeispiel ermittelten vorläufigen Selektionsentscheidung R_0 verglichen. Als Sensitivitätsmaß dient die Summe der Verschiebungen der Rangfolge innerhalb der μ besten Lösungen:

$$\Delta_{(+)} = \sum_{i=1}^{\mu} (R_{+\epsilon}(i) - R_0(i)) \quad \Delta_{(-)} = \sum_{i=1}^{\mu} (R_{-\epsilon}(i) - R_0(i)) \quad . \quad (3.10)$$

Die Abweichung Δ in der Selektionsreihenfolge stellt den Gradienten des möglichen Informationsgewinnes dar. Davon ausgehend, dass die größere der beiden Änderungen durch eine dem lokalen Trend gegenläufige Entscheidung hervorgerufen wird, dient die kleinere der beiden Änderungen $\Delta_R = \min(\Delta_+, \Delta_-)$ als Kriterium für die Relevanz einer Entscheidung (siehe ⑦). Dabei wird angenommen, dass die lokale Charakteristik der Präferenz des Experten auch durch deren erweiterte Umgebung gestützt wird. Es werden also Entscheidungsprototypen ermittelt, die das aktuelle Präferenzmodell präzisieren, dessen lokale Auflösung aber nicht unbedingt erweitern, da hierzu eine stärkere Vergrößerung der Datenbasis erforderlich ist. Führen lokale Unstetigkeiten, Minima oder Maxima in der tatsächlichen Präferenz des Benutzers dazu, dass die mögliche spätere Antwort signifikant von der Schätzung abweicht, so kann auf dieser Grundlage die Anzahl der Bewertungen erhöht werden, um die Auflösung des Modells zu erhöhen und auch diese Charakteristik abbilden zu können.

Abhängig von der verfügbaren Kapazität zur Bewertung von Lösungspaaren werden nun diejenigen zur Entscheidung vorgelegt, die dem ermittelten Kriterium entsprechend den größtmöglichen Informationsgewinn versprechen (siehe ⑧). Wie oft und wie viele reale Bewertungen durch einen Experten durchgeführt werden, sind einstellbare Parameter des beschriebenen Verfahrens, die sich an der gewünschten oder akzeptierten Belastung des Experten durch Entscheidungen sowie am konkreten Optimierungsproblem orientieren. Der Einfluss dieser Parameter wird in Kapitel 4 näher untersucht. Alle tatsächlich bewerteten Paare werden der aktuellen Präferenzdatenbank hinzugefügt und dienen den folgenden Selektionsprozessen als Grundlage. Abschließend wird die vom Experten tatsächlich getroffene Entscheidung mit der a priori Vermutung verglichen, die Abweichung steht als Maß für die aktuelle Qualität des Präferenzmodells zur Verfügung (⑨, siehe Abschnitt 4.4.2).

3.5 Präferenzbasierte Selektion

Die präferenzbasierte Selektion stellt eine Erweiterung eines auf der Pareto-Dominanz basierenden Selektionsverfahrens dar, das das primäre Selektionskriterium in Form einer Dominanzrangfolge liefert. Mit Hilfe der präferenzbasierten Selektion soll nun lediglich zwischen den nicht-dominierten und daher durch den Dominanz-Rang nicht unterscheidbaren

Lösungen differenziert werden. Das ermittelte Präferenzmodell dient dabei dazu, für die nicht-dominierten Lösungen $L_{d=1}$ der aktuellen Population eine Selektionsentscheidung zu bestimmen, ohne direkt die Präferenz für alle Lösungen aufwändig ermitteln zu müssen.

3.5.1 Ähnlichkeitsbasierte Präferenzschätzung

Um eine Aussage bezüglich der Präferenzen des Experten innerhalb der aktuell betrachteten Lösungsmenge treffen zu können, werden mit dem instanzbasierten Präferenzmodell die Präferenzrelation und Vergleichbarkeit aller möglichen Lösungspaare geschätzt. Diese werden gebildet aus der Kombination jeder der n Lösungen mit den jeweils anderen $n - 1$ Lösungen der Menge $L_{d=1}$. Entsprechend der in Abschnitt 3.4.2 beschriebenen Vorgehensweise erhält man Präferenzinformationen zu allen Lösungspaaren. Die für die Selektion erforderliche Ordnung innerhalb der Menge wird in Form eines Präferenz- und eines Vergleichbarkeitsindex abgebildet.

Für jede Lösung wird aus allen Paaren, an denen diese beteiligt ist, ein aggregierter Präferenzindex nach Gleichung 3.11 und ein Vergleichbarkeitsindex nach Gleichung 3.12 ermittelt als:

$$\gamma_{\sigma}(l_a) = \frac{\sum_{b=1}^n \hat{\sigma}(l_a, l_b) \hat{\rho}(l_a, l_b)}{\sum_{b=1}^n \hat{\rho}(l_a, l_b)} \quad . \quad (3.11)$$

Dieser Index γ_{σ} bildet die mittlere relative Präferenz einer Lösung im Vergleich zu ihren unmittelbaren Mitbewerbern ab. Die Vergleichbarkeit $\hat{\rho}$ der Lösung beschränkt dabei den Wettbewerb auf mehr oder weniger disjunkte Untermengen ähnlicher Individuen der gesamten Population. Der Vergleichbarkeitsindex γ_{ρ} erfasst die relative Dichte der Lösungen im Kriterienraum als:

$$\gamma_{\rho}(l_a) = \sum_{b=1}^n \hat{\rho}(l_a, l_b) \quad . \quad (3.12)$$

Die Indices müssen grundsätzlich anders interpretiert werden als die ihnen zugrunde liegenden Paarbewertungen. γ_{σ} ist zu verstehen als Erfolgsquote im direkten Vergleich mit den Mitbewerbern, γ_{ρ} hingegen gibt Auskunft über die Menge mit dieser Lösung konkurrierender Kandidaten. Beide Indices haben keinerlei generelle Aussagekraft bezüglich der Benutzerpräferenzen für die Lösung und haben ausschließlich im Kontext der aktuellen Lösungsmenge und des aktuellen Präferenzmodells eine Bedeutung.

3.5.2 Kompromissbildung zwischen Vergleichbarkeit und Präferenz

Für die endgültige präferenzbasierte Selektion der neuen Elternpopulation sind die ermittelten Präferenz- und Vergleichbarkeitsindices die maßgeblichen und als voneinander unabhängig betrachteten Kriterien. Die Selektion der Individuen zielt zum einen auf eine Maximierung im Hinblick auf deren Präferenz, zum anderen dient eine Minimierung des Vergleichbarkeitsindex der gleichmäßigen Verteilung der Individuen auf verschiedene

unter Umständen disjunkte Bereiche der Pareto-Front. Dieser Mechanismus ist vergleichbar mit bekannten und in allen MOEAs verwendeten Verfahren zur Diversifikation der Pareto-Menge wie beispielsweise einer *Crowding Distance* oder anderer *Niching*-Verfahren, bei denen dicht benachbarte Lösungen für die Selektion abgewertet werden. Im Unterschied dazu wird durch den Vergleichbarkeitsindex nicht die räumliche Nachbarschaft der Lösungen im bekannten Kriterienraum, sondern deren Ähnlichkeit oder Nachbarschaft im teilweise unbekanntem, durch die Präferenz des Benutzers erweiterten Raum verwendet. Als Anforderung ergibt sich die simultane Maximierung von γ_σ und Minimierung von γ_ρ , um ein ausgeglichenes Verhältnis zwischen Verbesserung und Erforschung zu erreichen. Die Menge L_S wird ausgewählt entsprechend dem multikriteriellen Selektionsschema nach Fonseca [40], bei dem der Rang eines Individuums von der Anzahl der von ihm dominierten Lösungen abhängig ist. Die μ Individuen mit dem besten Rang werden als Eltern der nächsten Generation selektiert. Prinzipiell sind hier alle multikriteriellen Selektionsverfahren geeignet, die auf die Selektion Pareto-optimaler Kompromisse abzielen, ohne die Kriterien quantitativ gegeneinander zu gewichten. Die Selektion anhand von Präferenz und Vergleichbarkeit ist also eine Abbildung des im Allgemeinen höher dimensionalen Kriterienraumes auf einen zweidimensionalen Präferenzraum.

3.5.3 Bedeutung der Vergleichbarkeit für den Selektionsprozess

Die präferenzbasierte Selektion ergänzt die vorgelagerte dominanzbasierte Vorselektion und bildet eine zusätzliche Entscheidungsgrundlage, die darauf abzielt die Konvergenz der Optimierung durch eine Reduktion des Kriterienraums zu befördern. Die größtmögliche Reduktion stellt dabei die Reduktion auf ein einzelnes skalares Gütemaß dar, wie es in der reinen Präferenzreihenfolge betrachteter Lösungen zu finden ist. Durch die zusätzliche Berücksichtigung der Vergleichbarkeit wird diese maximale Reduktion relativiert, die beschriebene präferenzbasierte Selektion liegt im Bereich zwischen einer rein multikriteriellen Selektion und einer eindimensionalen Präferenzreihenfolge als skalare Nützlichkeitsfunktion.

Werden im Extremfall alle betrachteten Lösungen für vergleichbar gehalten, so entspricht die Selektion der geschätzten Präferenzreihenfolge und reduziert den Kriterienraum damit auf ein einzelnes Kriterium. Werden im anderen Extremfall alle Lösungen als nicht vergleichbar behandelt, so sind im künstlich erzeugten Raum aus Präferenz und Vergleichbarkeit alle Lösungen Teil der Pareto-Front und damit gleichwertig. Die Selektion entspricht damit vollständig der dominanzbasierten Selektion im ursprünglichen Kriterienraum. In allen anderen Fällen bewegt sich die Selektion demnach in Abhängigkeit der tatsächlich getroffenen Entscheidungen zwischen diesen beiden Extremen und lässt sich durch entsprechende Entscheidungen in die eine oder andere Richtung beeinflussen.

Kapitel 4

Parameter und Unsicherheiten der Präferenzmodellierung

Der vorgestellte Algorithmus verwendet zur Optimierung modellierte Präferenzen eines Experten. Um die Funktionsfähigkeit des Verfahrens zu belegen, sind mehrere Aspekte zu beachten. Zum einen wird überprüft, inwiefern die tatsächlichen Präferenzen des Experten durch das gewählte Modell abgebildet werden und welche Parameter des Algorithmus diese Eigenschaften beeinflussen. Des Weiteren wird bewertet, wie die Parameter der Präferenzmodellierung und der Selektion die Optimierung in ihrer Konvergenzgeschwindigkeit und Präzision beeinflussen und wie robust das Verfahren gegenüber Unsicherheiten in der Präferenz ist.

4.1 Evaluation mit Test-Funktionen

Um für die genannten Analysen und Bewertungen reproduzierbare und objektiv quantifizierbare Ergebnisse zu erzielen, werden Experimente mit bekannten Benchmark-Problemen durchgeführt. Diese Test-Funktionen besitzen einen vollständig bekannten Lösungsraum und ein bekanntes Optimum in Form einer Pareto-Front, die einfache Implementierung der Funktionen und eine schnelle Ausführungszeit einzelner Bewertungen erlauben darüber hinaus die Durchführung einer großen Zahl von Experimenten.

Als universelle Test-Funktion dient die im Bereich der evolutionären Algorithmen verbreitete Kursawe-Funktion [92]:

$$f_1(\mathbf{x}) = \sum_{i=1}^{n_x-1} \left(-10 \exp \left(-0,2 \sqrt{x_i^2 + x_{i+1}^2} \right) \right) \quad , \quad (4.1)$$

$$f_2(\mathbf{x}) = \sum_{i=1}^{n_x} (|x_i|^{0,8} + 5 \sin(x_i)^3) \quad . \quad (4.2)$$

Diese Funktion ist mit ihren zwei Kriterien f_1 und f_2 gut zu visualisieren, die Anzahl der Parameter n_x und damit die Komplexität des Problems lässt sich frei skalieren. Die

Charakteristik der Pareto-Front der Funktion besteht sowohl aus konkaven wie auch aus konvexen Abschnitten und enthält Unstetigkeiten. Sie stellt daher eine vergleichsweise universelle Herausforderung für das Optimierungsverfahren dar.

Eine umfangreichere Betrachtung und quantitative Analyse auf Grundlage verschiedener weiterer ausgewählter Benchmark-Funktionen finden sich in Anhang A.

4.1.1 Simuliertes Benutzerentscheidungsverhalten

Bei der Entwicklung und Analyse interaktiver Mechanismen für EAs erweist sich die Einbeziehung eines menschlichen Experten als problematisch. In erster Linie ist die zeitliche Beanspruchung des Experten durch die hohe Anzahl von Versuchen und Entscheidungen kaum tragbar. Um das Verhalten verschiedener Varianten einer Optimierung objektiv miteinander zu vergleichen, muss das Antwortverhalten des Experten reproduzierbar sein. Es ist jedoch nicht gewährleistet, dass ein menschlicher Entscheider über einen längeren Zeitraum und wiederholte Experimente hinweg konsistente Entscheidungen trifft. Um eine objektive Analyse der Methoden zu gewährleisten, wird daher der Experte durch ein künstliches, dafür jedoch transparentes und konsistentes Entscheidungsmodell ersetzt, welches ein mögliches plausibles Entscheidungsverhalten nachbildet. Dieses künstliche Modell übernimmt anstelle des Experten die Beantwortung der ihm gestellten vergleichenden Bewertungen. Die evolutionäre Optimierung selbst und das interaktiv erlernte Präferenzmodell verfügen über keinerlei Kenntnisse dieses künstlichen Modells. Das Modell erlaubt die reproduzierbare Analyse hinsichtlich Häufigkeit und Auswahl der Vergleiche unterschiedlicher Varianten der Interaktionsstrategie sowie von Parametern des Präferenzmodells.

Das Antwortverhalten des künstlichen Entscheidungsmodells zielt auf die Minimierung des Abstands von Lösungen zu entweder einem oder mehreren hypothetischen optimalen Zielen \mathbf{f}_{Ref} im normalisierten Kriterienraum. Die das Benutzermodell definierenden hypothetischen Zielpunkte liegen dabei in der Nähe der tatsächlichen Pareto-Front, jedoch im nicht realisierbaren Gebiet des Kriterienraums. Das Optimum aus Sicht des Entscheidungsmodells ist die Pareto-optimale Lösung mit dem kleinsten Abstand zum hypothetischen Zielpunkt. Aus diesem Optimierungsziel leitet sich folgende abstands-basierte Präferenzrelation für ein Paar $\{l_i, l_j\}$ her:

$$\sigma_M(l_i, l_j) = \frac{\|f(\mathbf{x}_j) - \mathbf{f}_{\text{Ref}}\| - \|f(\mathbf{x}_i) - \mathbf{f}_{\text{Ref}}\|}{\|f(\mathbf{x}_i) - \mathbf{f}_{\text{Ref}}\| + \|f(\mathbf{x}_j) - \mathbf{f}_{\text{Ref}}\|} . \quad (4.3)$$

Die Präferenz ergibt sich aus der normierten Differenz der Abstände beider Lösungen zum Zielpunkt \mathbf{f}_{Ref} , wobei die nähere der beiden Lösungen bevorzugt wird. Im Falle mehrfacher konkurrierender Zielpunkte wird nur denjenigen Paaren eine Präferenz zugewiesen, bei denen beide Lösungen demselben Zielpunkt am nächsten liegen. Ist dies nicht der Fall, so wird das Paar als nicht vergleichbar ($\rho = 0$) bewertet.

4.1.2 Eindeutiger Präferenzschwerpunkt

Um die grundsätzliche Funktionalität der präferenzbasierten Optimierung zu verdeutlichen, werden die drei in Abschnitt 3.1 vorgestellten Möglichkeiten der Kombination von Optimierung und Entscheidung anhand eines Beispiels miteinander verglichen. Die Kursawe-Funktion mit $n_x = 6$ Parametern dient als Test-Funktion, der Referenzpunkt ist gewählt als $\mathbf{f}_{\text{Ref}} = (-35; -21,5)$. Die Konvergenz der interaktiven Optimierung mit Entscheidungsmodell wird verglichen mit einem multikriteriellen EA, dessen Selektion nur auf dem Dominanz-Ranking und einem Niching-Mechanismus basiert. Ebenfalls verglichen wird ein skalarer EA, als dessen Fitness der euklidische Abstand der Lösungen zum Referenzpunkt \mathbf{f}_{Ref} dient. Es wird erwartet, dass sich die interaktive Methode als weniger effizient gegenüber einer skalaren Optimierung mit praktisch a priori bekannten Präferenzen verhält, jedoch die Konvergenz der ungerichteten multikriteriellen Optimierung zur Pareto-Front übertrifft. Die Konvergenz wird anhand des Abstandes zwischen dem Referenzpunkt und der am nächsten gelegenen Lösung in der aktuellen Population bewertet. Der skalare Algorithmus optimiert direkt den Abstand zum Referenzpunkt, der multikriterielle Algorithmus dagegen berücksichtigt diesen Abstand nicht, da alle nicht-dominierten Lösungen als gleichwertig behandelt werden. Die interaktive Optimierung hat kein a priori Wissen über den Referenzpunkt, mit fortschreitender Optimierung bildet das erlernte Präferenzmodell jedoch den Abstand zum Referenzpunkt ab. Zur Visualisierung der unterschiedlichen Konvergenzverhalten wird eine Population mit lediglich $\mu = 10$ Eltern und $\lambda = 50$ Nachkommen über 20 Generationen evolviert. Die Bilder 4.1 bis 4.3 zeigen jeweils die Entwicklung der Population gegen die Pareto-Front. Der Grauwert illustriert das Fortschreiten der Generationen, von hellgrau zu Beginn bis zu schwarz in der letzten Generation.




Bild 4.1: Entwicklung der Population für einen Referenzpunkt $\mathbf{f}_{\text{Ref}} = (-35; -21,5)$: Skalare Optimierung

Skalare Optimierung:

Die skalare Optimierung des Abstandes zum Referenzpunkt, dargestellt in Bild 4.1, konvergiert schnell in Richtung Pareto-Front in der Umgebung des Referenzpunktes \mathbf{f}_{Ref} . Eine lineare Gewichtung zugrunde liegender Kriterien konvergiert nicht unbedingt in ein einziges Minimum. Die Verwendung des euklidischen Abstandes zum Referenzpunkt als Fitness-Bewertung führt jedoch zu einem eindeutigen Ergebnis.

Multikriterielle Optimierung:

Die multikriterielle Optimierung ohne die Berücksichtigung von Präferenzen entwickelt sich in Richtung der globalen Pareto-Front wie in Bild 4.2 gezeigt. Da der Referenzpunkt bei der Optimierung in keiner Weise berücksichtigt wird, verteilen sich die Lösungen gleichmäßig über die Pareto-Front. Die Konvergenz im Bezug auf den Referenzpunkt ist demnach erwartungsgemäß langsamer.




Bild 4.2: Entwicklung der Population für einen Referenzpunkt $\mathbf{f}_{\text{Ref}} = (-35; -21,5)$: Multikriterielle Optimierung

Multikriterielle Optimierung mit präferenzbasierter Selektion

Die Integration des Präferenzmodells zur Selektion resultiert in einer schnelleren Konvergenz in Richtung des Referenzpunktes, wie in Bild 4.3 dargestellt. Zu beachten ist, dass sich der I-MOEA auf Grundlage der paarweisen Vergleiche entwickelt. Die Population entwickelt sich in Richtung des Referenzpunktes, obgleich zu Beginn langsamer. Der Einfluss des Modells und auch das Akquirieren von Modellinstanzen beginnen nicht mit der ersten Generation, da nur für mehr als μ nicht-dominierte Lösungen die Präferenz als Entscheidungskriterium in die Selektion einbezogen wird. Das Präferenzmodell wird mit dem Fortschreiten der Optimierung genauer und nähert sich dem skalaren Optimum.




Bild 4.3: Entwicklung der Population für einen Referenzpunkt $\mathbf{f}_{\text{Ref}} = (-35; -21,5)$: Präferenzbasierte Optimierung

Das Bild 4.4 zeigt für alle drei zuvor dargestellten Optimierungsverläufe die Konvergenz der aktuell jeweils im Sinne des Abstandes zum Referenzpunkt besten Lösungen. Die Darstellung ist das Ergebnis einer Mittelwertbildung über 25 unabhängige Optimierungen. Erwartungsgemäß zeigt die skalare Optimierung die schnellste und auch final beste Konvergenz, das in der Abbildung betrachtete Fehlermaß ist äquivalent zum verwendeten skalaren Optimierungskriterium. Der MOEA erreicht zu keinem Zeitpunkt der betrachteten Optimierung den Abstand des skalaren EA. Dessen Ergebnis wird als Teil der Pareto-Front zwar theoretisch auch vom MOEA erreicht, die Anzahl der erforderlichen Fitnessbewertungen ist aber erheblich höher und liegt deutlich außerhalb der für diese Betrachtung analysierten Laufzeit des Algorithmus. Die Konvergenz des I-MOEA liegt zwischen der der beiden anderen Ansätze. Zu Beginn entsprechen der tatsächlich ausgeführte Algorithmus wie auch die Entwicklung des betrachteten Abstands dem des MOEA. Ist eine eindeutige Selektionsentscheidung auf Grundlage des Dominanzrankings und ohne Berücksichtigung der Präferenz zur Unterscheidung nicht-dominierter Lösungen möglich, ist der Algorithmus identisch mit dem klassischen MOEA. Mit fortschreitender Optimierung wächst die Präferenzdatenbank durch wiederholte simulierte interaktive Fragen an und bildet dadurch zunehmend schärfer die tatsächliche Präferenz, in diesem Fall die Entfernung zum Referenzpunkt, ab. Das Verhalten der präferenzbasierten Selektion nähert sich dadurch dem des skalaren Algorithmus an. Die Wahl der Parameter für das Verfahren zur Präferenzmodellierung, speziell die Intensität der Interaktion und damit die Quantität und Qualität der der Präferenzschätzung zugrunde liegenden bewerteten Instanzen, bestimmen die Einordnung der Konvergenz der Methode zwischen der des MOEA und des skalaren EA, also zwischen keinem und vollständigem Wissen um die tatsächlichen Präferenzen.

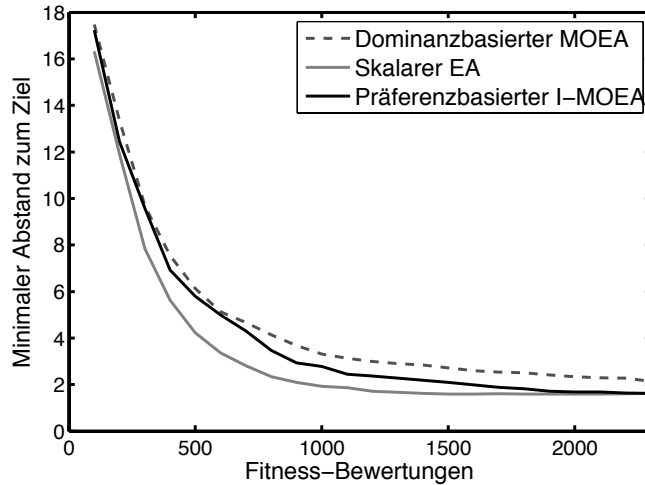


Bild 4.4: Vergleich der Konvergenz der Algorithmen für einen Referenzpunkt

4.1.3 Disjunkte Präferenzschwerpunkte

Das Konzept der Berücksichtigung von Nichtvergleichbarkeit von Lösungspaaren ermöglicht es, die Optimierung auf mehrere disjunkte Regionen des Kriterienraums zu fokussieren. Dieser Abschnitt analysiert beispielhaft hierfür die Konvergenz der Optimierung in Richtung zweier separater Referenzpunkte für die zweidimensionale Kursawe-Funktion. Das verwendete Benutzermodell hat eine positive Präferenz für die dem Referenzpunkt näher gelegene Lösung, sofern beide Lösungen näher an diesem als an einem anderen Referenzpunkt liegen. Liegen die Lösungen nahe zu verschiedenen Referenzpunkten, so wird das Lösungspaar als nicht vergleichbar eingestuft. Die Konvergenz des Algorithmus, ausgedrückt durch die Summe der beiden kürzesten Abstände zu den Referenzpunkten, wird für die multikriterielle Optimierung, zwei parallele skalare Optimierungen sowie die präferenzbasierte Optimierung verglichen. Die Algorithmen nutzen jeweils Konfigurationen mit $\mu = 20$ Eltern und $\lambda = 100$ Nachkommen. Bild 4.5 zeigt die Entwicklung der Population über den Verlauf der Optimierung hin zu den beiden Referenzpunkten $\mathbf{f}_{\text{Ref},1} = (-53; -21)$ und $\mathbf{f}_{\text{Ref},2} = (-60; -13)$. Das Bild 4.6 vergleicht die Konvergenz der drei beschriebenen Algorithmen im Hinblick auf die Summe der kleinsten Abstände zu den Referenzpunkten. Die Ergebnisse basieren wieder auf der Mittelwertbildung über 25 unabhängige Optimierungen. Für den skalaren Algorithmus werden einzelne Läufe für beide Referenzpunkte zusammengefasst, jedem dieser Läufe steht entsprechend nur die Hälfte der Auswertungen zur Verfügung. Der Algorithmus mit präferenzbasierter Selektion übertrifft nicht nur den normalen multikriteriellen Algorithmus, sondern ist im Mittel auch effizienter als die Kombination der skalaren Optimierungen. Dies zeigt deutlich die Möglichkeiten der interaktiven Optimierung zur Annäherung der Pareto-Front in Bereichen, die von Interesse für den Benutzer sind. Die initial deutlich größere Breite der Suche des MOEA mit präferenzbasierter Selektion im Vergleich zum EA verhindert eine vorzeitige falsche Konvergenz, die zu dem im Mittelwert für den EA schlechteren Ergebnis führt.




Bild 4.5: Entwicklung der Population für disjunkte Präferenzregionen

Bereits für den Fall eines nur zweidimensionalen Optimierungsproblems zeigt sich der Vorteil der interaktiven Integration von Präferenzen. Nachdem ein ausreichendes Präferenzmodell erlernt ist, ist die Leistung des interaktiven Algorithmus mit dem einer skalaren Optimierung vergleichbar. Anders als bei dieser ist jedoch keine a priori Festlegung der Präferenzen notwendig. Der Algorithmus bleibt multikriteriell und ist nicht auf ein einzelnes Ziel beschränkt.

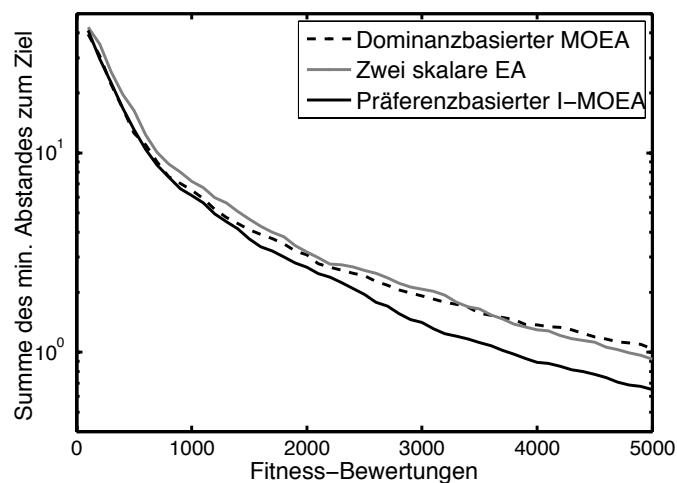


Bild 4.6: Vergleich der Konvergenz der Algorithmen für mehrere Referenzpunkte

4.1.4 Einfluss der Dimension des Kriterienraums

Die Verbesserung der Konvergenz der Optimierung im Hinblick auf den präferierten Teil der Pareto-Front hängt unabhängig von den gewählten Parametern der Strategie maßgeblich auch von der Dimension des betrachteten Kriterienraums ab. Das Konvergenzverhalten des dominanzbasierten MOEA wird, wie bereits in Abschnitt 3.1.2 aufgezeigt, mit wachsender Dimension des Suchraumes exponentiell schlechter. Die Reduktion auf ein skalares Gütemaß ist davon hingegen unbeeinflusst. Die präferenzbasierte Selektion entspricht ebenfalls einer Reduktion unabhängig von der ursprünglichen Dimension des Kriterienraums auf nur zwei Dimensionen. Dies zeigt sich bei höheren Raumdimensionen als wachsender Vorteil gegenüber der rein dominanzbasierten Selektion. Das Bild 4.7 zeigt diesen Effekt beispielhaft abermals anhand der bereits bekannten Kursawe-Funktion. Die ursprünglich zweidimensionale Funktion wird zwei- und dreifach, mit entsprechend größerer Zahl Parameter, gleichzeitig ausgewertet, um ein vier- beziehungsweise sechsdimensionales Problem vergleichbarer Struktur zu erhalten. Wie auch schon für das in Bild `refKonvVerglKur` gezeigte Beispiel werden die dominanzbasierte, die präferenzbasierte und die skalare Optimierung verglichen.

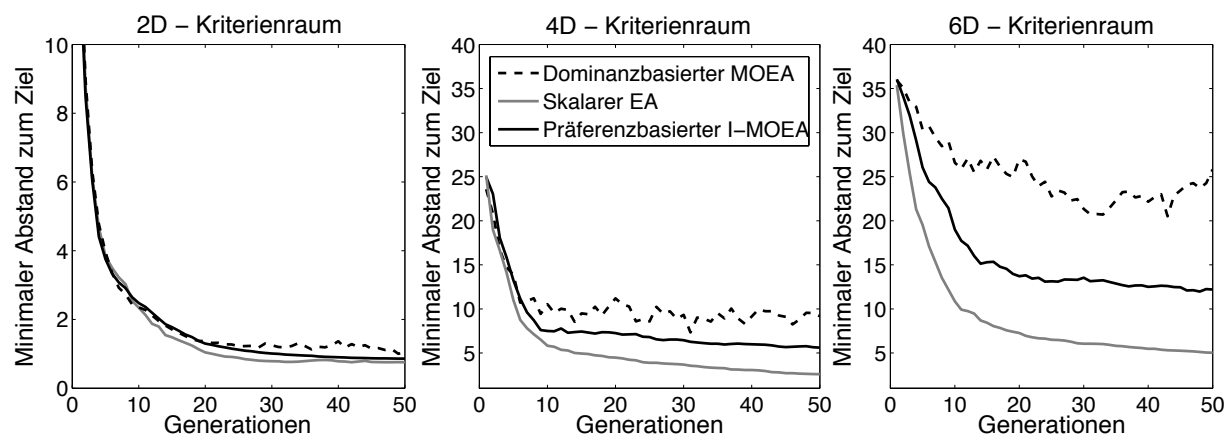


Bild 4.7: Einfluss der Dimension des Kriterienraumes auf die Konvergenz zum Referenzpunkt

Die Bewertung der linken Abbildung, also des zweidimensionalen Falls, entspricht qualitativ der Bewertung aus Abschnitt 4.1.2, das Konvergenzverhalten des präferenzbasierten Verfahrens liegt zwischen dem MOEA und dem skalaren Algorithmus. Diese Reihenfolge bleibt auch in den beiden anderen Fällen erhalten, der MOEA konvergiert jedoch deutlich schlechter mit wachsender Dimension. Auch das präferenzbasierte Verfahren verliert leicht im Vergleich zum skalaren EA, dies lässt sich vor allem durch die dominanzbasierte Vorselektion erklären, generell wird das Problem komplexer, was für alle Verfahren zu langsamerer Konvergenz und größeren Abständen zum Referenzpunkt führt.

4.2 Einfluss von Modellparametern

Die Funktionsweise und die Qualität der in Kapitel 3 vorgestellten Methode hängt von vielen Faktoren ab, von denen einige unbekannt, problemspezifisch oder auch abhängig vom Benutzer und seinen individuellen Entscheidungen sind, andere aber als Parameter der Strategie oder des Präferenzmodells betrachtet werden können.

Während der laufenden Optimierung hängt die Approximationsgüte des erlernten Präferenzmodells vor allem von der Art und Anzahl der zur Verfügung stehenden Instanzen ab. Diese wiederum werden beeinflusst durch die Häufigkeit der Interaktion g und die Anzahl der gestellten Fragen N . Für diese Analyse werden alle g Generationen N Fragen durch das Entscheidungsmodell beantwortet.

Im Gegensatz zu vielen herkömmlichen Modellierungsaufgaben ist die absolute Approximationsgüte im Kontext der evolutionären Optimierung weniger relevant. Entscheidend ist vielmehr der Einfluss der geschätzten Benutzerpräferenzen auf die Selektionsentscheidung. Der Approximationsfehler des Benutzermodells bewirkt, dass die präferenzbasierte Selektion andere Lösungen auswählt, als der Entscheider wählen würde. Dieser Selektionsfehler kann definiert werden als die Anzahl der fehlerhaft selektierten besten Lösungen im Vergleich zur idealen Selektion anhand des nominellen Entscheidungsmodells. Die Tabelle 4.1 zeigt den Einfluss der Anzahl der Fragen und der Häufigkeit der Interaktion auf den mittleren Selektionsfehler eines evolutionären Laufs für die bereits bekannte Kursawe-Funktion mit $\mu = 25$ Eltern und $\lambda = 100$ Nachkommen über 50 Generationen. Die in der Tabelle angegebenen Fehlerraten sind das Ergebnis einer Mittelwertbildung über zehn unabhängige Optimierungsläufe.

Die Ergebnisse zeigen, dass eine deutliche Reduktion der Interaktionsrate sowohl in der Anzahl der Fragen als auch deren Häufigkeit lediglich zu einer moderaten und durchaus akzeptablen Verschlechterung der Selektionsqualität führt.

Tabelle 4.1: Rate der falschen Selektionen in Prozent

	$N = 100$	$N = 25$	$N = 10$	$N = 5$
$g = 1$	2,98	3,34	4,18	5,24
$g = 5$	4,09	4,91	5,39	6,68
$g = 10$	4,90	5,75	5,98	6,92

4.2.1 Statische Betrachtung des Präferenzmodells

Das folgende Beispiel belegt, dass das instanzbasierte Präferenzmodell in der Lage ist, Präferenzen, wie sie durch das in Gleichung 4.3 beschriebene Entscheidungsmodell abgebildet werden, zu modellieren. Um die Qualität des Modells unbeeinflusst von durch die evolutionäre Optimierung verursachten Effekten beurteilen zu können, werden zunächst einfache statische Szenarien betrachtet. Für ein eindimensionales Szenario bilden zwei disjunkte Referenzpunkte die Grundlage für das Entscheidungsmodell. Das Präferenzmodell basiert auf

den aus zehn äquidistant im betrachteten Raum verteilten Prototypen gebildeten Instanzen.




Bild 4.8: Präferenzrelation von Lösungspaaren (l_a, l_b) des künstlichen Benutzermodells $\sigma_M(l_a, l_b)$ (links) und des geschätzten Präferenzmodells $\hat{\sigma}(l_a, l_b)$ basierend auf Instanzen bestehend aus zehn Prototypen (rechts)

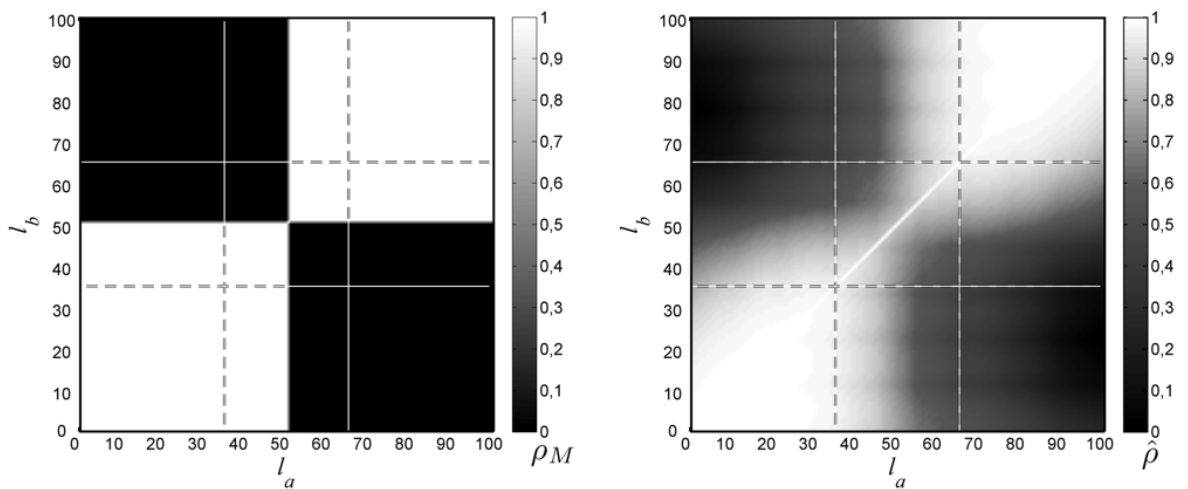


Bild 4.9: Vergleichbarkeitsindex von Lösungspaaren (l_a, l_b) des künstlichen Benutzermodells $\rho_M(l_a, l_b)$ (links) und des geschätzten Präferenzmodells $\hat{\rho}(l_a, l_b)$ (rechts)

Die Bilder 4.8 und 4.9 vergleichen die nominelle künstliche Benutzerpräferenz und nominelle Vergleichbarkeit von Lösungen mit denen der geschätzten Modelle. Die geschätzten Modelle basieren auf 45 paarweisen Vergleichen der zehn gleichmäßig verteilten Prototypen. Die dem Benutzermodell zugrunde liegenden Referenzpunkte im eindimensionalen Kriterienraum sind $f_{\text{Ref},1} = 35$ und $f_{\text{Ref},2} = 65$ und jeweils mit einer horizontalen und

vertikalen Linie markiert. Beide Achsen der Grafiken bilden jeweils den gleichen eindimensionalen Raum ab, sie sind aber den beiden unterschiedlichen Elementen der betrachteten Paare zugeordnet. Das Bild 4.8 zeigt, dass die nominelle Präferenz $\sigma(l_a, l_b)$ (links) und die geschätzte Präferenz $\hat{\sigma}(l_a, l_b)$ (rechts) prinzipiell übereinstimmen, der in der Nähe der Zielpunkte nicht kontinuierliche Verlauf der nominellen Präferenz wird jedoch durch die gewichtete Mittelwertbildung über die Instanzen deutlich geglättet.

Das Bild 4.9 vergleicht entsprechend die tatsächliche und die geschätzte Vergleichbarkeit eines Lösungspaars (l_a, l_b) . Für die nominelle Vergleichbarkeit sind die zwei Zielregionen $\Phi_1 = \{X | X \in [0, 50]\}$ und $\Phi_2 = \{X | X \in [50, 100]\}$ strikt disjunkt. Die Approximation dieser diskreten Partitionierung durch das geschätzte Modell weist wiederum in der Grenzregion einen geglätteten Verlauf auf. Dies führt dazu, dass Lösungen in der Grenzregion beiden Referenzpunkten gleichermaßen zugeordnet werden. Diese Unschärfe ist direkt von der Anzahl und der Nähe der zur Verfügung stehenden Modellinstanzen abhängig. Je mehr Information vorliegt, desto präziser wird das Modell, aufgrund seiner Eigenschaften als lokales Modell und der Abstandsgewichtung werden Unstetigkeiten oder Sprünge in der wahren Präferenz oder Vergleichbarkeit jedoch immer kontinuierlich approximiert.

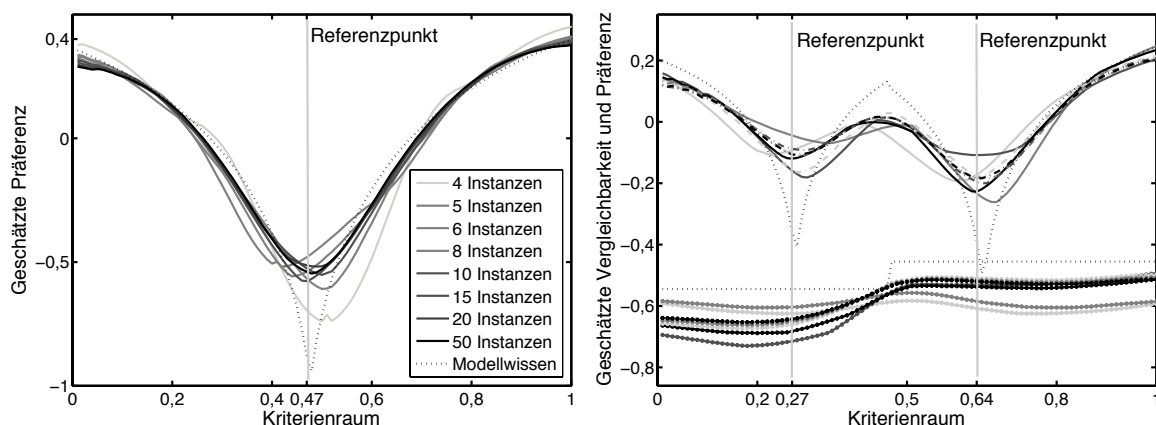


Bild 4.10: Qualität der Approximation von Präferenz und Vergleichbarkeit für unterschiedliche Anzahlen von Beispielinstanzen für einen (links) oder zwei (rechts) Referenzpunkte

Die Präzision der Abbildung der Präferenzen durch das erlernte Modell hängt unmittelbar von der Anzahl der Instanzen ab, die verwendet werden. Das Bild 4.10 zeigt diesen Zusammenhang für Modellszenarien mit einem und mit zwei künstlichen Referenzpunkten. Für eine Menge gleichmäßig in nur einer Dimension verteilter Lösungen werden die Präferenz und Vergleichbarkeit auf Grundlage verschiedener Mengen von Instanzen ermittelt. Diese Instanzen sind entsprechend dem in Abschnitt 4.1.1 eingeführten Entscheidungsmodell auf Grundlage der durch vertikale Linien markierten Referenzpunkte ermittelt. Die gepunktete Linie repräsentiert die volle Modellkenntnis, Präferenz und Vergleichbarkeit sind hier nicht anhand von Instanzen, sondern unmittelbar mit Hilfe des Entscheidungsmodells ermittelt. Die instanzbasierten Präferenzmodelle stellen jeweils eine Annäherung

dieser Verteilung dar. Die Instanzen sind jeweils alle Kombinationen ebenfalls gleichmäßig verteilter Lösungsrepräsentanten. Die linke Abbildung zeigt die Präferenz für Modelle mit verschiedener Anzahl von Instanzen für ein Beispiel mit einem einzelnen Referenzpunkt. Die rechte Seite zeigt ein Beispiel mit zwei Referenzpunkten, entsprechend ist hier auch die Vergleichbarkeit der Lösungen relevant und ebenfalls für alle Modelle dargestellt. Für beide Beispiele gilt, dass sich die Lage des Maximums der Präferenz mit wachsender Zahl an Instanzen dem Maximum für die volle Kenntnis des Entscheidungsmodells annähert. Der Wert des Maximums variiert dabei, dies ist eine Folge der unvermeidbaren Veränderung der Abstände durch die jeweils unterschiedliche Gleichverteilung der veränderlichen Anzahl von repräsentativen Lösungen. Auch die Unterschiede für beide Maxima der Verteilung im rechten Beispiel sind dadurch verursacht, die ermittelte Vergleichbarkeit ist ebenfalls von diesem Abstand abhängig und gleicht in der Selektion diese Unterschiede aus.

4.3 Strategieparameter der Präferenzintegration

Die Integration der präferenzbasierten Selektion sowie der Präferenzmodellbildung erfordern die Wahl verschiedener Parameter. Diese bestimmen zum einen entscheidend die Leistungsfähigkeit und das Ergebnis der Optimierung, sind aber zum anderen auch bestimmend für die Art und Intensität der Belastung für den Entscheider. Ein naheliegendes Beispiel für diesen Konflikt ist es, dass eine maximale Intensität der Interaktion die beste Modellierung gewährleistet, jedoch eine unverhältnismäßige Belastung des Entscheiders verursacht. Im Detail kann aber auch die Frequenz der Befragung oder die Art der Fragen mit Interessen des Entscheiders in Konflikt stehen. Im Allgemeinen ist die Wahl jeder Konfiguration ein Kompromiss zwischen diesen Aspekten. Die im folgenden Abschnitt gezeigten Untersuchungen und Ergebnisse treffen daher keine absoluten Aussagen zur Parametrierung der Strategie, sondern stellen vielmehr die Grundlage zur objektiven Kompromissbildung dar. Die hier betrachteten Parameter betreffen die Modellierung selbst nur indirekt, die Integration der Präferenzmodellierung bestimmt direkt nur Menge, Art und Zeitpunkt der Akquise neuer Modellinstanzen. Hierfür ist zum einen wichtig, wann der Entscheider wie viele Fragen zu beantworten hat. Ein zweiter Aspekt ist die Wahl einer repräsentativen Auswahl von Prototypen als Grundlage für die Entscheidung, hierzu wird der Einfluss des Clusterings der Lösungsmenge betrachtet.

4.3.1 Die Intensität der Benutzerinteraktion

Die Intensität der Interaktion wird bestimmt durch die Zeitpunkte oder die Frequenz der Befragung und die Anzahl der Fragen, die jeweils gestellt werden. Unter der Voraussetzung eines gleichmäßigen Fortschritts der generellen Konvergenz des Algorithmus in jeder Generation ist bei gegebener Anzahl von Fragen deren gleichmäßige Verteilung über die Generationen optimal. In diesem Fall kann die Intensität der Interaktion als Quotient

von Fragen und Generationen betrachtet und verglichen werden. Die Bilder 4.11 und 4.12 dienen zur Bewertung des Präferenzmodells im Verlauf einer Optimierung für die Kursawe-Testfunktion mit einem einzelnen Präferenz-Referenzpunkt. Das betrachtete Kriterium für die Qualität des Modells ist auch hier nicht die eigentliche Schätzung der Präferenz, sondern der Selektionsfehler im direkten Vergleich mit einer hypothetischen Entscheidung basierend auf der vollen Kenntnis der Präferenzen. Die präferenzbasierte Selektion jeder Generation wird mit der optimalen Entscheidung verglichen. Die Permutationen beider Reihen werden mit der Abstandsdifferenz zum Referenzpunkt des Entscheidungsmodells gewichtet. Dadurch haben Fehler in der Entscheidung dann einen großen Einfluss auf das Kriterium, wenn sie die Auswahl einer tatsächlich gravierend weniger präferierten Lösung verursachen. Eine lokal falsche Reihenfolge im Kriterienraum benachbarter Lösungen hingegen hat praktisch für den Algorithmus kaum negative Auswirkungen und wird auch durch diese Gewichtung weniger berücksichtigt. Das Bild 4.11 zeigt den Mittelwert des gewichteten Selektionsfehlers von zehn Optimierungen über je 50 Generationen für verschiedene Intensitäten der Interaktion. Als Vergleich dargestellt ist ebenfalls eine rein zufällige Selektion aus allen nicht-dominierten Kandidaten. Dies verdeutlicht den Einfluss der generellen Konvergenz des Algorithmus zur Pareto-Front auf die Entwicklung des betrachteten Kriteriums. Der

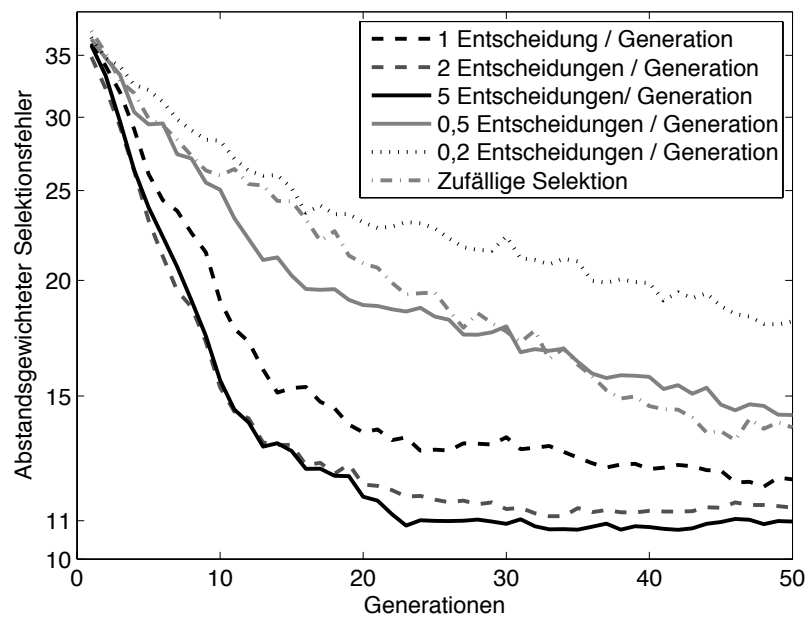


Bild 4.11: Vergleich des abstandsgewichteten Selektionsfehlers für verschiedene Interaktionsraten über den Verlauf der Generationen

Vergleich der Verläufe erlaubt bei Betrachtung der Ergebnisse für ein, zwei und fünf Fragen pro Generation zum einen die Interpretation, dass ein Mehraufwand an zusätzlichen Instanzen nicht in jedem Fall zu einer proportionalen Verbesserung des Modells führt, sondern im Bezug auf den Selektionsfehler zu einem Minimum konvergiert. Dies hängt jedoch stark

von der Charakteristik der tatsächlichen Präferenzen ab, für das hier verwendete einfache Entscheidungsmodell ist diese Konvergenz schneller zu erwarten, da vergleichsweise wenige Instanzen für dessen Modellierung ausreichen. Die Betrachtung der Ergebnisse für 0.2 oder 0.5 Entscheidungen pro Generation im Vergleich zur zufälligen Selektion lässt schließen, dass zu wenige Instanzen im Zusammenhang mit der dynamischen Entwicklung der Populationen im Verlauf der Optimierung zu einem Selektionsergebnis führen können, dessen Fehler über dem der zufälligen Lösungsauswahl liegt. Die Begründung dafür liegt zum einen in der zu starken Vereinfachung der Präferenzabbildung durch wenige Instanzen, zum anderen in den mit fortschreitender Konvergenz zur Pareto-Front wachsenden Anforderungen an das Präferenzmodell, das zunehmend ähnlichere Lösungen diskriminieren muss. Erlernte Instanzen, die zu Beginn der Optimierung in einem größeren Kontext zu einer richtigen Selektion führen, sind unter Umständen bei fortschreitender Fokussierung der Optimierung auf einen lokalen Bereich des Suchraumes nicht mehr für eine sinnvolle Unterscheidung der Lösungen geeignet. Für Anwendungen mit realen menschlichen Entscheidern wird dieser Effekt möglicherweise durch eine zeitliche Veränderlichkeit der tatsächlichen Präferenzen verstärkt; diese Art von Unsicherheiten werden später in Abschnitt 4.4 im Detail behandelt.

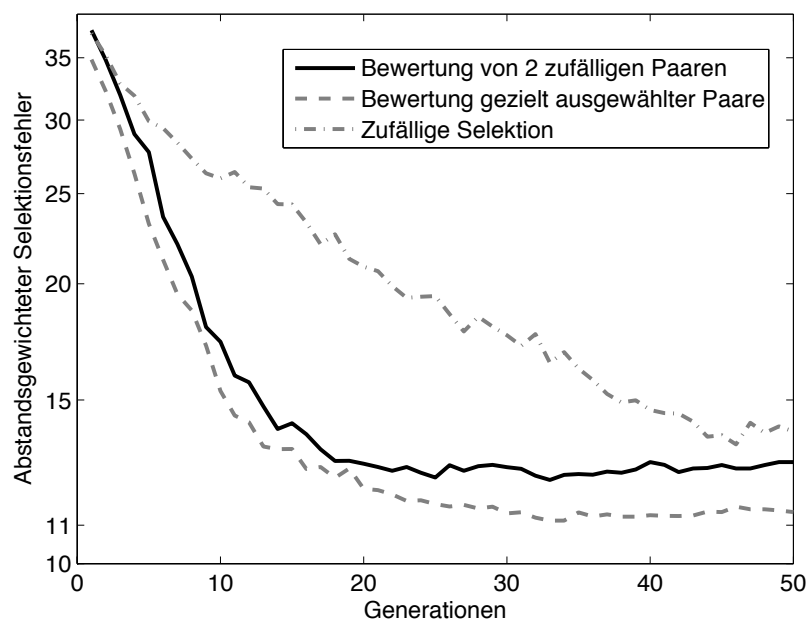


Bild 4.12: Vergleich des Selektionsfehlers für die interaktive Bewertung gezielt gewählter und zufällig gewählter Prototypen-Paare

4.3.2 Bewertung der gezielten Auswahl von Interaktionskandidaten

Das Ziel der in Abschnitt 3.4.3 beschriebenen gezielten Auswahl informationsmaximierender Entscheidungskandidaten ist die Reduktion der Bewertungen durch den Entscheider bei gleicher Qualität des Präferenzmodells. Das Bild 4.12 vergleicht den schon in Bild 4.11 gezeigten Selektionsfehler für eine zufällige Auswahl von zwei neuen Instanzen in jeder Generation mit dem Fehler für eine gezielte Auswahl der zwei Instanzen mit dem größten zu erwartenden Informationsgewinn. Zum Vergleich ist auch hier wieder der Fehler für eine Zufallsauswahl dargestellt.

Der Vergleich zeigt einen deutlich reduzierten Selektionsfehler bei der Verwendung der gezielt ausgewählten Paare und belegt damit die bei gleichem Aufwand für den Entscheider verbesserte Qualität des Präferenzmodells.

4.3.3 Reduzierte Repräsentation der Lösungsmenge

Die Verwendung eines Clustering-Verfahrens zur Auswahl von repräsentativen Lösungen ist in erster Linie durch die Notwendigkeit begründet, die Menge der Daten, für die eine Benutzerinteraktion und Präferenzschätzung durchgeführt wird, zu reduzieren. Im idealen Fall stellt die gesamte Lösungsmenge die Grundlage für die Auswahl geeigneter Interaktionskandidaten dar. Praktisch erfordert dies jedoch eine exponentielle, und damit im Allgemeinen zu große, Rechenzeit. Das Ergebnis der Reduktion durch Clustering stellt also immer einen Kompromiss zwischen Rechenzeit und Qualität der Repräsentanten dar. Die Wahl der Methode und Parametrierung ist dem untergeordnet. Durch den iterativen Charakter der interaktiven Abfrage der Präferenzen ist die Qualität eines einzelnen Repräsentanten ebenfalls von untergeordneter Bedeutung. Eine Zufallsauswahl einer geeigneten Untermenge wäre bei gleichmäßiger Verteilung der Lösungen prinzipiell ebenfalls geeignet. Die Verwendung eines hierarchischen Clustering-Verfahrens ermöglicht jedoch die Wahl von Repräsentanten aus Lösungsmengen, die durch die präferenzbasierte Selektion selbst induzierte ungleichmäßige Verteilungen von Lösungen aufweisen.

4.4 Der Umgang mit Modellunsicherheiten

Eine zentrale Eigenschaft der Klasse der in dieser Arbeit zur Modellierung der Präferenzen verwendeten lokalen instanzbasierten Modelle ist, dass die Modellqualität mit wachsender Datenbasis in Form von Modellinstanzen generell besser wird, vorausgesetzt die Instanzen sind vollständig korrekte Beschreibungen des modellierten Prozesses, also frei von Fehlern oder Unsicherheiten. In den vorangegangenen Abschnitten ist untersucht und dargestellt worden, dass die praktische Verwendung dieser Modelle jedoch einen Kompromiss im Hinblick auf die Modellqualität erfordert, da das Generieren zusätzlicher Instanzen immer auch eine zusätzliche Belastung des eingebundenen Entscheiders durch weitere Fragen bedeutet. Darüber hinaus ist die Annahme, dass die erzeugten Instanzen frei von Fehlern,

Ungenauigkeiten oder Unsicherheit sind, für praktische Anwendungen und reale menschliche Entscheider nicht haltbar. Auf der anderen Seite ist für die hier gezeigte Anwendung von Präferenzmodellen zur Selektion von Lösungen die Anforderung an die Qualität dieser Modelle insofern limitiert, als dass nur eine korrekte diskrete Selektionsentscheidung und nicht die absolute Genauigkeit der einzelnen Prädiktion entscheidend für Erfolg und Qualität des global betrachteten Optimierungsprozesses ist. Um sämtliche dieser Aspekte zu berücksichtigen, ist ein Modellmanagement erforderlich, das einen Kompromiss zwischen der Modellqualität und dem Aufwand für den Entscheider ermittelt.

4.4.1 Wechselwirkungen von Problem, Benutzer und Parametern

Die durch das kontinuierlich trainierte Modell prädizierte Präferenz weicht aus verschiedenen Gründen von der tatsächlichen Präferenz des Benutzers ab. Zum einen ist ein instanzbasiertes Modell auch unter der Annahme vollständig fehlerfreier Instanzen nur an diesen Stützstellen auch exakt, für andere Stellen des Lösungsraumes findet eine Interpolation statt. Der Fehler dieser Interpolation hängt von der Anzahl und Platzierung der Instanzen ab. Grundsätzlich führt eine größere Zahl bekannter Instanzen im lokalen Umfeld zu einer besseren Modellierung. Das absolute Ergebnis ist jedoch von der im Allgemeinen nicht vollständig bekannten Charakteristik des Problems abhängig. Eine größere Zahl lokaler Minima und Maxima oder sich ändernder Gradienten der die Präferenz beschreibenden Funktion erfordern auch eine größere Zahl von lokalen Stützstellen in Form von Modellinstanzen. Ein anderer Aspekt der Unsicherheit der Präferenzmodellierung entsteht durch die Unsicherheit der einzelnen Modellinstanzen. Diese wiederum kann verschiedene Ursachen haben:

Fehlerhafte Bewertungen durch den Entscheider

Eine naheliegende Ursache ist die fehlerhafte Bewertung eines Prototypenpaares durch den Entscheider. Ein Bedienfehler oder das unaufmerksame Durchführen der Bewertung führt zu einer fehlerhaften Modellinstanz. Die verschiedenen Bemühungen, die Anzahl der Befragungen und Instanzen zu reduzieren, führen hier dazu, dass eine einzelne falsche Instanz gravierende Auswirkungen auf das Modell haben kann. Die in Anhang C gezeigten Methoden zur Visualisierung der aktuellen Präferenzen erleichtern es dem Benutzer seinen Fehler rückwirkend zu erkennen und zu beheben.

Unsicherheit in der tatsächlichen Präferenz

Bleibt man beim Bild der Nützlichkeitsfunktion, die ein Entscheider auch unbewusst seinen Bewertungen zu Grunde legt, dann bedeutet die Wahl einer relativen Präferenz für ein zu bewertendes Prototypenpaar einen Transfer von dieser globalen Präferenz auf eine andere lokale Beschreibung. Für einen solchen kognitiven Prozess kann auch bei identischen Bedingungen und Voraussetzungen keine vollständig exakte Reproduzierbarkeit erwartet werden. Die Unsicherheit ist hier maßgeblich davon bestimmt, wie gut der Entscheider die

Repräsentation der betrachteten Lösungen in seiner Nützlichkeitsfunktion wiederfindet, oder praktisch formuliert, wie gut die Darstellungsart der Lösung mit den Vorstellungen des Entscheiders übereinstimmt.

Veraltete Modellinstanzen

Jede Modellinstanz beschreibt lokal die Präferenz des Anwenders, entscheidend für die Bewertung einer Modellinstanz ist jedoch deren Auswirkung auf die Selektion. Die Qualität einer Instanz kann daher nicht absolut betrachtet werden, sondern ist unmittelbar von dem Kontext abhängig, in dem sie verwendet wird. So kann ein bewertetes Lösungspaar beispielsweise zur Selektion in einem größeren Kontext des Kriterienraumes mit sehr unterschiedlichen Lösungen sinnvoll beitragen, jedoch die lokale Charakteristik der Präferenz nicht berücksichtigen. Ändert sich nun der Kontext der Entscheidung, zum Beispiel durch das Konvergieren der Optimierung, werden für Lösungen in diesem lokalen Kontext durch das gleiche Modell fehlerhafte Selektionsentscheidungen getroffen.

Zeitvariante Präferenzen

Der Prozess der interaktiven Optimierung stellt auch für den Entscheider einen kontinuierlichen Zugewinn an Informationen dar. Eine der Stärken von evolutionären Methoden oder auch allgemein von populationsbasierten Optimierungsverfahren besteht im Informationsgewinn, der im Bezug auf die Eigenschaften des betrachteten Problems erzielt wird. Dieser Lernprozess des Entscheiders ist zentrale Ursache für die Zeitveränderlichkeit von Präferenzen. Auch diese Veränderung führt dazu, dass Modellinstanzen nicht mehr sinnvoll oder auch negativ zum Modell beitragen.

Eine Möglichkeit, diesen beiden zeitlich bedingten Problemen zu begegnen, ist das gezielte *Vergessen* älterer Instanzen des Modells. Um eine für die angestrebte Qualität ausreichende Anzahl von Instanzen zu erhalten, ist jedoch tendenziell eine größere Anzahl an Bewertungen, also ein größerer Aufwand, erforderlich. Andererseits führt die konstant anwachsende Kardinalität der Menge an Instanzen jedoch dazu, dass einzelne, und damit auch ältere Instanzen an Einfluss verlieren. Eine genügend kleine Veränderung der Präferenz vorausgesetzt, können diese Problemursachen also vernachlässigt werden.

Nicht abgebildete Kriterien

Die einzelnen Modellinstanzen stellen eine Verbindung zwischen den Optimierungskriterien und der Präferenz des Benutzers dar, da die Ähnlichkeit von Lösungspaaren und Instanzen im Kriterienraum ermittelt wird (vgl. Abschnitt 3.4.2). Das Präferenzmodell ist im idealen Fall eine eindeutige Abbildung der Benutzerpräferenzen auf den Kriterienraum. Die Formulierung der diese Abbildung bestimmenden Bewertungen erfolgt jedoch im Allgemeinen unabhängig von diesem. Der Benutzer vergleicht Lösungsprototypen basierend auf einer individuellen und problemspezifischen Visualisierung, die auch mehr Informationen enthalten kann, als im Kriterienraum eindeutig beschrieben wird. Die Bewertung von Aspekten, in denen Lösungen oder Lösungspaare sich unterscheiden, die sich aber nicht

in den Kriterien widerspiegeln, kann zu mehrdeutigen Abbildungen zwischen Präferenz- und Kriterienraum führen. In der Folge erhalten, abhängig von den vorhandenen Modellinstanzen, Paare von Prototypen mit identischer Repräsentation zur Präferenzentscheidung unter Umständen unterschiedliche Präferenzschätzungen. Für die lokale Modellierung der Präferenz eines unbekanntes Lösungspaares führt dies durch eine Mittelwertbildung von allen in Frage kommenden Mehrdeutigkeiten zu einer fehlerhaften Modellaussage und einer Unsicherheit in der Präferenzschätzung.

4.4.2 Validierung von Präferenzschätzungen

Die Möglichkeit zum aktiven Modellmanagement wird durch die ständige Bewertung der Modellqualität im Laufe der Optimierung eröffnet. Die einzige Information zur Präferenz, die außerhalb des betrachteten Prozesses vorliegt und dadurch eine belastbare Aussage über die aktuelle Qualität des Präferenzmodells ermöglicht, sind die Aussagen des befragten Entscheiders. Jede echte Bewertung wird mit einer a priori Schätzung verglichen und gibt somit Aufschluss über die aktuelle Modellqualität zum Zeitpunkt vor der letzten interaktiven Befragung. Für alle Elemente der Menge D_I der interaktiv bewerteten Prototypenpaare wird die mittlere Abweichung vorher geschätzter und real bewerteter Präferenzen ermittelt:

$$\kappa(D_\sigma) = \frac{1}{|D_I|} \sum_{\forall P_i \in D_I} (|\sigma(P_i) - \hat{\sigma}(P_i)|) \quad . \quad (4.4)$$

Der resultierende Wert von κ beschreibt den aktuellen Modellfehler des durch die Instanzen D_σ bestimmten Präferenzmodells zum Zeitpunkt unmittelbar vor der letzten Interaktion. Einschränkungen zur Aussagekraft von κ ergeben sich durch die Betrachtung der Auswahl der Interaktionskandidaten P_I . Diese werden wie in Abschnitt 3.4.3 beschrieben nach dem größtmöglichen Einfluss auf die Selektionsentscheidung und damit auch hinsichtlich der maximalen Unsicherheit des aktuellen Präferenzmodells ausgewählt. Der Wert κ ist daher eher als Abschätzung der unteren Grenze des Prädiktionsfehlers und nicht als generelle Aussage zur Unsicherheit einer Präferenzschätzung geeignet. Darüber hinaus macht die minimierte Zahl der bewerteten Paare und die dadurch an Einfluss gewinnende Unsicherheit einer einzelnen Bewertung die aktuelle Qualität κ zu einem ebenfalls mit großer Unsicherheit behafteten Wert.

Das Bild 4.13 zeigt die Entwicklung von κ für Optimierungsverläufe mit unterschiedlicher Intensität von Interaktion. Die zu Grunde liegenden Daten stammen von der bereits betrachteten Optimierung der Kursawe-Testfunktion mit einer jeweils unterschiedlichen Zahl von Bewertungen pro Generation. Die Entwicklung von κ ist dabei für 20 einzelne Optimierungen gemittelt und zeigt dessen Durchschnittswert für die jeweils gleiche Generation. Dies ist die Ursache für den in den ersten Generationen zu verzeichnenden Verschleifungseffekt, da die präferenzbasierte Selektion in Abhängigkeit von der zum Teil zufälligen Zahl der

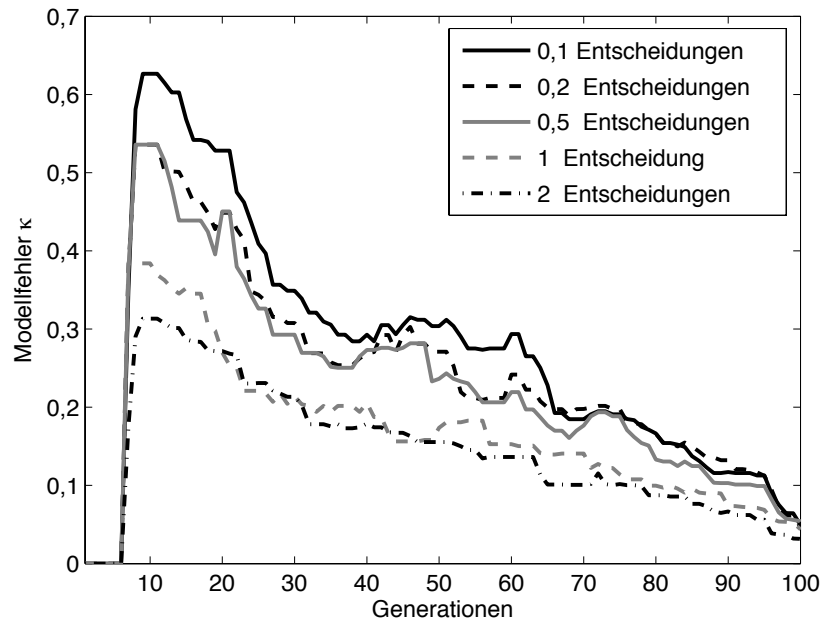


Bild 4.13: Entwicklung des Modellfehlers für Optimierungen mit verschiedenen Interaktionsraten

ermittelten nicht-dominierten Lösungen in unterschiedlichen Generationen begonnen wird. Generell ist der erwartete Zusammenhang zwischen Intensität der Interaktion und Qualität des Modells erkennbar, eine größere Zahl von Instanzen verbessert die Vorhersage. Mit dem Verlauf der Optimierung reduziert sich jedoch der Modellfehler für alle Interaktionsraten durch die allgemeine Konvergenz des Algorithmus, die auch bei größerem Modellfehler erreicht wird. Diese Beobachtung stützt erneut die Annahme, dass ein höherer Aufwand zwar mit der Qualität korreliert ist und zu einem reduzierten Modellfehler, jedoch nicht direkt proportional zu besseren Ergebnissen führt. Dies macht einen individuellen Kompromiss erforderlich hinsichtlich des angestrebten Ergebnisses und der Bereitschaft, interaktiv Bewertungen durchzuführen.

Kapitel 5

Multikriterielle Optimierung von dynamischen Systemen

Innerhalb der zahlreichen Einsatzmöglichkeiten für Optimierungsverfahren in vielen Bereichen der Ingenieurwissenschaften stellt die Optimierung dynamischer Systeme einen wichtigen Anwendungsbereich dar. Die Bandbreite der Anwendungen, speziell im Bereich des Entwurfs mechatronischer Systeme, wurde bereits einleitend in Abschnitt 1.3.2 skizziert. Das Ziel der Optimierung dynamischer Systeme ist es, das dynamische Verhalten eines durch die zu optimierenden Parameter beschriebenen Systems an ein gegebenes oder als gewünscht vorgegebenes Verhalten anzupassen. Soll dabei das Systemverhalten an das Verhalten eines anderen Systems angeglichen werden, so handelt es sich dabei allgemein ausgedrückt um eine Modellierung des Systemverhaltens, die schematisch in Bild 5.1 dargestellt ist. Wird ein gewünschtes Verhalten des optimierten Systems oder eines dieses System enthaltenden Gesamtsystems abstrakt formuliert, so entspricht dies eher einem Entwurfsverfahren, beispielsweise einer Reglerauslegung, dargestellt in Bild 5.2. Die für beide Anwendungen zu verwendenden Verfahren unterscheiden sich nicht grundsätzlich, auch ist diese allgemeine Betrachtung zunächst unabhängig von einer konkreten Art des Modells oder des zu optimierenden Systems. Für beide Fälle stellt \mathbf{k} die zu optimierenden Parameter dar. Die Vektoren \mathbf{q} und \mathbf{q}' sind die beobachteten oder gemessenen beziehungsweise gewünschten Ausgangsgrößen der Systeme als Reaktion auf eine Anregung w . Diese Größen bilden die Grundlage zur Ermittlung der Bewertungskriterien \mathbf{J} . Die bei der Optimierung dynamischer Systeme speziell zu beachtenden Aspekte betreffen zum einen die Repräsentation des Systems als Lösungsparameter eines Individuums, zum anderen die Bewertung des dynamischen Systemverhaltens und die Definition geeigneter Fitnessfunktionen und Kriterien.

Dieses Kapitel diskutiert die Optimierung der dynamischen Systeme mit dem Fokus auf dem Aspekt deren Bewertung. Als Grundlage dient daher eine vergleichsweise einfache Repräsentation, die sich auf lineare und zeitinvariante Systeme mit fester Struktur beschränkt. Die zur Bewertung von Prototypen verwendeten Mechanismen sind, wenn auch nicht vollständig unabhängig, prinzipiell auch für die Optimierung komplexer Repräsentation

tionen wie beispielsweise nichtlinearer Systeme oder variabler Systemstrukturen anwendbar. Die Nomenklatur für regelungstechnische Größen und Bezeichnungen orientiert sich in diesem Kapitel an der DIN EN 60027-6 [93], im Falle von Konflikten mit im Kontext des Algorithmus in den vorangegangenen Kapiteln verwendeten Bezeichnungen wird für diese eine abweichende Nomenklatur eingeführt. Der Buchstabe σ bezeichnet in diesem Kapitel, abweichend von den vorangegangenen, klassisch die Standardabweichung, die Lösungsparameter sind ab hier mit \mathbf{k} bezeichnet, da \mathbf{x} in diesem Kontext üblicherweise einen Zustandsvektor darstellt.

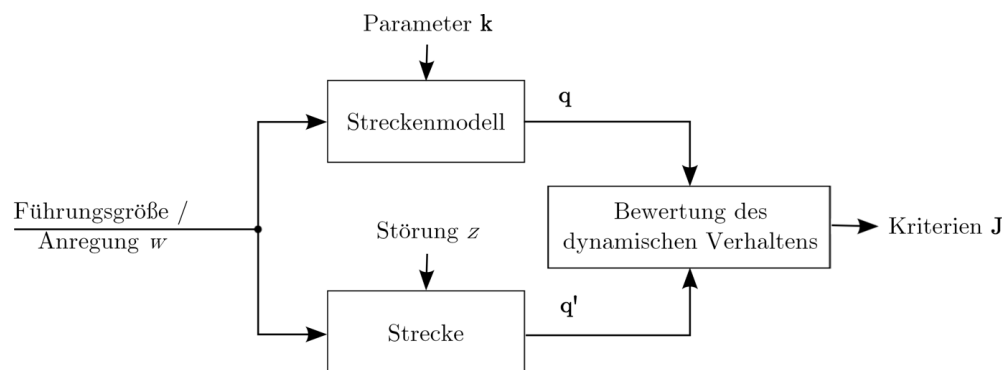


Bild 5.1: Optimierung dynamischer Systeme: Systemidentifikation

Neben der Auswahl geeigneter Gütemaße zur Bewertung des Systemverhaltens ist die Robustheit der Bewertungen ein wichtiger Aspekt bei der Optimierung dynamischer Systeme. Die in den Bildern 5.1 und 5.2 allgemein als z zusammengefassten Störungen beinhalten unterschiedliche Mechanismen, die Einfluss auf die Robustheit der Bewertung einer Lösung oder auch auf die Lösung selbst haben. Unabhängig von verschiedenen möglichen Ursachen der Störungen teilt sich das Problem der Robustheit im Kontext der Optimierung in zwei Bereiche. Auf der einen Seite ist es notwendig, die Kriterien zur Bewertung von Lösungen robust und reproduzierbar zu gestalten, um die Konvergenz der Optimierung nicht zu gefährden. Auf der anderen Seite ist die Robustheit der Lösung selbst gegenüber Unsicherheiten ein Ziel der Optimierung.

5.1 Optimale und optimierte Regler

Im Kontext der Optimierung von Regelungssystemen ist es notwendig, die zwei ähnlichen Begriffe des *optimierten Reglers* und des *optimalen Reglers* gegeneinander abzugrenzen. Die Anwendung evolutionärer Algorithmen führt, wie in Abschnitt 2.1 erläutert, im Allgemeinen zu einer Approximation der optimalen Lösung oder Lösungsmenge, man erhält einen optimierten Regler. Die tatsächliche optimale Lösung ist im Allgemeinen unbekannt und wird nicht vollständig erreicht. Bei bestimmten Klassen von Systemen jedoch ist die opti-

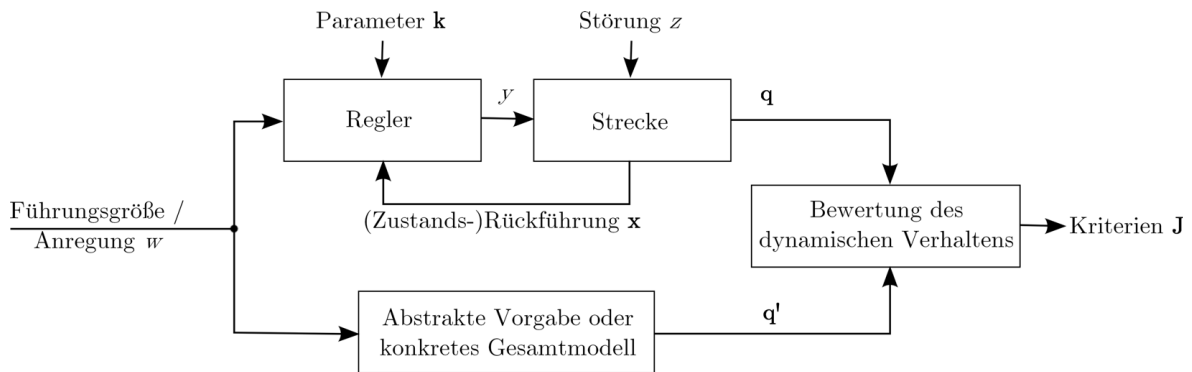


Bild 5.2: Optimierung dynamischer Systeme: Reglerauslegung

male Lösung hinsichtlich bestimmter Gütemaße bekannt, das optimale Reglergesetz lässt sich direkt ableiten. Ist für die betrachtete Kombination von Regelstrecke und Gütemaß eine optimale Lösung ermittelbar, so ist die Optimierung durch eine heuristische Methode obsolet. Für eine lineare Regelstrecke, wie in Abschnitt 5.3.2 als Beispiel eingeführt, und ein quadratisches Gütemaß, wie in Abschnitt 5.2 definiert, kann beispielsweise mit dem LQR-Verfahren (*Linear Quadratic Regulator*) ein optimales Reglergesetz ermittelt werden. Der LQR-Entwurf basiert im Wesentlichen auf der Lösung von Riccati-Differentialgleichungen und führt für ein Gütemaß J_{LQR} zu einem optimalen Zustandsregler. Die allgemeine Formulierung [94] des quadratischen Gütemaßes, das für den Entwurf von verbrauchsoptimalen linearen Zustandsreglern geeignet ist, lautet

$$J_{LQR} = \int_{t=0}^{t_e} (\mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{u}^T \mathbf{R} \mathbf{u}) dt \quad . \quad (5.1)$$

Die Matrizen \mathbf{Q} und \mathbf{R} sind Diagonalmatrizen mit Gewichtungsfaktoren für die betrachteten Größen auf der Hauptdiagonalen. Eine Kompromissbildung zwischen den Fehlern der einzelnen Zustandsgrößen und dem Verbrauch erfolgt über die Wahl dieser Gewichte. Die Wahl der Gewichtungsmatrizen des Gütemaßes entspricht einer a priori Präferenzartikulation, das Gütekriterium ergibt sich praktisch aus einer gewichteten Summe einzelner Kriterien.

Detaillierte Informationen zur Auslegung dieser und auch anderer optimaler Regler findet man beispielsweise bei Föllinger in [94].

5.2 Gütemaße und Bewertung von Systemverhalten

Die Beschreibung dynamischer Systeme erfolgt üblicherweise in zwei Domänen, dem Zeitbereich und dem Frequenzbereich. Die Bewertung von Systemverhalten kann entsprechend ebenfalls in beiden Domänen erfolgen, der Schwerpunkt der hier verwendeten Kriterien liegt aber aus verschiedenen Gründen bei der Bewertung im Zeitbereich. Die in theoretischen Aspekten überlegene Frequenzbereichsbetrachtung erweist sich für praktische Experimente

mit realen Messbedingungen als aufwändiger zu realisieren und als fehleranfälliger. Darüber hinaus entsprechen die Szenarien, die zur Bewertung im Zeitbereich geeignet sind, eher den üblichen Anwendungsszenarien im regelungstechnischen Kontext und sind dadurch für Anwender und Prozessexperten transparenter und intuitiver zu beurteilen.

5.2.1 Bewertung von Sprungantworten

Ein bewährtes Mittel zur Bewertung und Identifikation von dynamischen Systemen ist die Beobachtung des Systemverhaltens bei sprungförmiger oder auch impulsförmiger Anregung. Diese normierte Veränderung des Systemeingangs führt zu einer Anregung des gesamten Spektrums im Frequenzbereich und ist daher für lineare Systeme ausreichend, um umfassende Informationen über das Systemverhalten zu erlangen [95]. Im Gegensatz zu einer möglichen Bewertung des Systems im Frequenzbereich ermöglicht die Sprungantwort darüber hinaus eine vergleichsweise intuitive visuelle Inspektion durch einen regelungstechnisch vorgebildeten Anwender. Veränderungen des Verhaltens lassen sich im Hinblick auf vordergründig wichtige Aspekte der Systemdynamik wie Geschwindigkeit oder Genauigkeit leicht anhand der Beobachtung des Ausgangs des auf diese Art angeregten Systems beurteilen.

Zur formalen Beschreibung von Sprungantworten existieren eine Reihe verschiedener Kenngrößen, die sich zum Teil ergänzen, zum Teil redundant auf verschiedene Aspekte des Vergleichs zwischen dem sprungförmigen Verlauf des Systemeingangs $q_{step}(t)$ und dem resultierenden zeitlichen Verlauf des Ausgangs $q(t)$ beziehen. Die Maße zur Beschreibung einer Sprungantwort sind in der DIN IEC 60050-351 [96] definiert.

Bei der Wahl von Maßen zur Beschreibung der Sprungantwort, die als Optimierungskriterien geeignet sind, ergeben sich unter Umständen abweichende Anforderungen. Die mathematische Präzision oder anschauliche Berechenbarkeit sind sekundär, wichtiger für die Optimierung ist zum einen die lokale Stetigkeit der Kriterien, um eine möglichst einfache Abbildung der Optimierungsparameter auf diese Kriterien zu erzielen, zum anderen die vollständige Beschreibung der Sprungantwort mit einer minimalen Anzahl von einzelnen Kriterien, um die Komplexität des Optimierungsproblems zu begrenzen.

Die im Folgenden beschriebenen Kriterien stellen eine geeignete Auswahl zur Beschreibung dar, da sie alle Aspekte eines erwünschten Systemverhaltens beschreiben können, erheben aber keinen Absolutheitsanspruch. Im konkreten und praktischen Anwendungsfall hängt die Wahl geeigneter Kriterien unter Umständen von weiteren Randbedingungen wie der Signalqualität, der Messbarkeit und Messgenauigkeit sowie möglichen Einschränkungen im Hinblick auf die Durchführbarkeit einer sprungförmigen Anregung ab.

Charakteristische Größen der Sprungantwort

Die **Anstiegszeit** T_a , auch als Anschlagzeit oder Anregelzeit bekannt, kennzeichnet die Zeit, die der Systemausgang benötigt, um als Reaktion auf die Anregung den Endwert des Sprunges oder des betrachteten Toleranzbereichs um diesen Wert herum zum ersten Mal zu erreichen. Wird der Sollwert des Sprungs nicht erreicht, so ergibt sich theoretisch eine

$T_a = \infty$. Da praktisch jedoch kein unbegrenzter Zeitraum betrachtet wird, muss hier eine Ausnahmebehandlung erfolgen.

Die **Einschwingzeit** T_e kennzeichnet den Zeitpunkt, zu dem sich das Signal zum letzten Mal außerhalb des Toleranzbereichs befindet. Dadurch charakterisiert das Kriterium anteilig sowohl die absolut erreichte stationäre Genauigkeit als auch das dynamische Einschwingverhalten des Systems. Für eine Sprungantwort ohne Überschwingen sind Anstiegs- und Einschwingzeit identisch. Eine die Eignung für die evolutionäre Optimierung einschränkende Eigenschaft des Kriteriums ist das mögliche Auftreten von Unstetigkeiten bei kontinuierlicher Änderung des Systems. Dies ist bedingt durch das vollständige Eintreten einer Schwingungsperiode in den Fehlerschlauch, bei dem trotz nur kleiner Änderung der Amplitude die T_e zur nächsten Periode springt.

Das maximale **Überschwingen** \ddot{U} einer Sprungantwort ist die Differenz zwischen dem Maximalwert der Sprungantwort und dem Sprungswert. Sofern der Zielwert nicht erreicht wird, ist das minimale Überschwingen als $\ddot{U}_{min} = 0$ definiert. Das Nichterreichen des Zielwertes muss dann ergänzend von anderen Kriterien, beispielsweise von der bereits beschriebenen Anregelzeit, bestraft werden.

In Bild 5.3 ist eine exemplarische Sprungantwort mit den charakteristischen Größen T_a , T_e und \ddot{U} skizziert.




Bild 5.3: Skizze einer Sprungantwort mit charakteristischen Größen

Integral des quadratischen Fehlers

Ein allgemeines Kriterium für den Vergleich und die Bewertung des Unterschiedes von zwei Signalverläufen, die sich über ihren zeitlichen Verlauf (oder allgemein auch eine andere Größe) einander zuordnen lassen, ist das Integral des quadratischen Fehlers (ISE - Integral of Squared Error). Für einen normierten Sprung der Höhe q_{step} als verwendete Referenz berechnet sich das ISE der Sprungantwort $q(t)$ für den Zeitraum zwischen dem Auftreten des Sprungs bei $t = 0$ und dem Ende des betrachteten Zeitraums bei $t = t_e$ als:

$$ISE = \int_{t=0}^{t_e} (q(t) - q_{step})^2 dt \quad (5.2)$$

und wird angewendet auf die Fehlerfläche zwischen dem Sprung am Eingang und dem Systemausgang.

Eine Variante des ISE ist das zeitlich gewichtete Integral des quadratischen Fehlers (ISTE - Integral of Squared Time-weighted Error). Hier wird der Fehler mit der Zeit linear stärker gewichtet. Als Gütemaß eignet es sich für Vorgänge wie sprunghafte Anregungen, bei denen auf ein initiales Ereignis ein zeitliches Abklingen erwartet wird. Das *ISTE* ist definiert als

$$ISTE = \int_{t=0}^{t_e} t(q(t) - q_{step})^2 dt \quad . \quad (5.3)$$

Beide Gütemaße setzen ein asymptotisches Abklingen des Fehlers voraus, allgemein gilt daher $t_e = \infty$. Für die praktische Umsetzung zur Bewertung von Zeitreihen ist die korrekte Wahl von t_e kritisch, um ein aussagekräftiges Gütemaß zu erzielen.

Das *ISE* und das *ISTE* unterscheiden sich von den anderen Kriterien dadurch, dass hier kein singuläres Ereignis im Verlauf der Sprungantwort, sondern deren gesamtes Verhalten erfasst und beurteilt wird. Dies führt unweigerlich zu einer Überschneidung mit anderen Kriterien. Bei der gemeinsamen Verwendung mit den beiden zuvor genannten Kriterien hat das durch T_a und \ddot{U} beschriebene dynamische Verhalten ebenfalls Einfluss auf das *ISE*, dieses ergänzt aber eine Beschreibung der statischen Genauigkeit und des Einschwingverhaltens. Das *ISTE* verschiebt durch die zeitliche Gewichtung den Schwerpunkt der Bewertung von den dynamischen Vorgängen zum Sprungzeitpunkt hin zum Ausregelverhalten und ist somit im Allgemeinen eher zur Kombination mit T_a und \ddot{U} geeignet.

Eine Alternative zur Verwendung eines quadratischen Fehlermaßes ist das Integral der Absolutwerte der Fehler (IAE), dessen Berechnung die gleiche Fläche wie dem *ISE* zugrunde liegt, bei dem der Betrag des Fehlers jedoch nicht quadratisch eingeht.

Quadratische Gütemaße haben, wie schon in Abschnitt 5.1 angedeutet, eine große Bedeutung im Kontext der optimalen Regelung. Das J_{LQR} entspricht einer gewichteten Kombination von mehreren *ISE* für alle einzelnen Zustands- und Stellgrößen des Systems.

5.2.2 Analyse der Störanfälligkeit der Kriterien

Im Kontext der Optimierung realer Systeme und Prozesse, beispielsweise der HIL-Optimierung, erfolgt die Bewertung von Lösungen unter Umständen auf Grundlage von Messungen physikalischer Größen, die einen Teil der Fitnessfunktion bilden. Real gemessene Signale weisen einen Störanteil auf, der unterschiedlich sein kann und vereinfachend als weißes Rauschen, also als normalverteilter Zufallsprozess angenommen werden kann. Die Eignung von Kriterien zur Bewertung hängt davon ab, wie und wie stark diese durch die im betrachteten Prozess zu erwartende Störung beeinflusst werden.

Um die unterschiedliche Charakteristik des Verhaltens der Kriterien im Hinblick auf stochastische Störungen des betrachteten Signals zu bewerten, wird eine exemplarische Sprungantwort $q(t)$ eines schwingfähigen PT_2 -Systems mit einer Störung in Form einer normalverteilten Zufallsvariablen $\theta = \mathcal{N}(0, \sigma_{Sig})$ beaufschlagt. Die Sprungantwort ist normiert

auf einen statischen Endwert von Eins, für jeden Zeitpunkt ergibt sich der Wert der gestörten Sprungantwort als $\tilde{q}(t) = q(t) + \theta$. Die Standardabweichung σ_{Sig} des Rauschens wird variiert und die Auswirkungen auf die beschriebenen Kriterien werden ausgewertet. Die Tabelle 5.1 zeigt Mittelwerte und Standardabweichung der ermittelten Kriterien für ausgewählte Werte für σ_{Sig} , das Bild 5.4 zeigt den relativen Fehler, der durch die Störung verursacht wird. Grundlage der Abbildung sind je eintausend Experimente für jedes betrachtete $\sigma_{Sig,i} = 10^{-3}i$ für $\forall i : i \in \mathbb{N} \wedge i \in [0, 50]$.

In Bild 5.4 wird jeweils der Mittelwert des relativen Fehlers des Kriteriums als schwar-

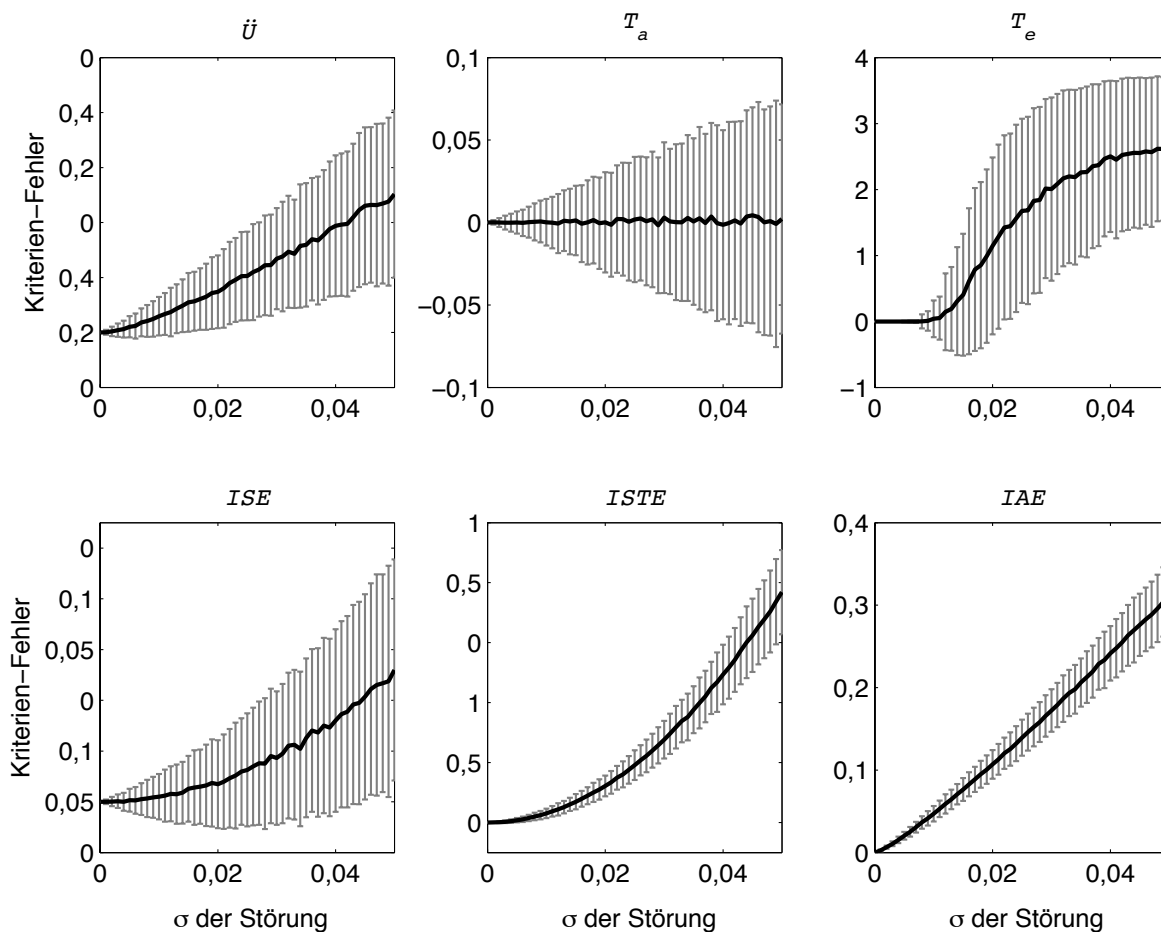


Bild 5.4: Auswirkungen verschieden starker Störungen einer Sprungantwort auf die Kriterien

zer Strich gezeigt und die Standardabweichung als symmetrisches graues Intervall um den Mittelwert für die beschriebenen Kriterien in Abhängigkeit von der Stärke der Störung. Die unterschiedlichen Charakteristiken der Kriterien im Bezug auf die Auswirkungen eines gestörten Signals treten deutlich hervor. Für das Überschwingen \ddot{U} steigt die Standardabweichung des Fehlers proportional zu der Standardabweichung der Störung, daneben stellt

sich jedoch ein mittlerer Fehler ein, der auch in etwa proportional ist. Die Anstiegszeit T_a variiert ebenfalls proportional zur Störung, im Mittel ist sie jedoch unbeeinflusst. Der Einfluss eines Fehlerschlauchs um den Sollwert wird beim Kriterium T_e , der Einschwingzeit, besonders deutlich. Für Störungen mit einer kleineren Standardabweichung als $\sigma_{Sig} = 0,01$ ist das Kriterium nahezu unbeeinflusst, da sich die Störung innerhalb des Fehlerschlauchs bewegt. Ist dieser überschritten, so nimmt auch der mittlere Fehler schnell zu, auf bis zu mehr als doppelt vergrößerte Werte des Kriteriums. Für starke Störungen wird kein Einschwingen mehr erkannt, der Fehler wird nur durch die maximal berücksichtigte Dauer der Sprungantwort $T_{e,max} = 3s$ begrenzt, der Mittelwert nähert sich für große σ_{Sig} dieser oberen Grenze.

Die zweite Zeile des Bildes zeigt die Kriterien, die nicht ein diskretes Ereignis im Verlauf der Sprungantwort, sondern ein Integral über deren gesamten Verlauf berücksichtigen. Bei etwa gleich großem Ansteigen ihrer Standardabweichungen für steigende σ_{Sig} unterscheiden sich die Kriterien deutlich im Hinblick auf den Mittelwert. Die beiden Kriterien ISE und $ISTE$ berücksichtigen für ihre Berechnung einen quadratischen Fehler, entsprechend zeigt auch der Mittelwert des Fehlers einen quadratischen Zusammenhang mit der Stärke der Störung. Der Fehler wächst aufgrund der zusätzlichen Gewichtung für das $ISTE$ deutlich schneller. Das IAE hingegen zeigt einen linearen Zusammenhang zwischen der Störung und dem Mittelwert des resultierenden Fehlers.

Tabelle 5.1: Ermittelte Kriterien für eine Sprungantwort mit exemplarischen Störungen

σ_{Sig}	\bar{U}	$\sigma_{\ddot{y}}$	\bar{T}_a	σ_{T_a}	\bar{T}_e	σ_{T_e}
0	0,208	0	0,96	0	2,30	0
0,005	0,210	0,004	0,96	0,007	2,30	0,03
0,01	0,214	0,007	0,96	0,014	2,35	0,51
0,05	0,260	0,032	0,96	0,071	8,47	2,33
σ_{Sig}	ISE	σ_{ISE}	$ISTE$	σ_{ISTE}	IAE	σ_{IAE}
0	5,00	0	1,64	0	8,58	0
0,005	5,00	0,02	1,65	0,01	8,75	0,04
0,01	5,01	0,05	1,69	0,03	8,98	0,08
0,05	5,25	0,22	2,90	0,24	11,24	0,37

Für die Beurteilung sind Mittelwert und Standardabweichung differenziert zu betrachten. Während ein größerer mittlerer Fehler allein noch nicht unbedingt ein Problem darstellt, kann eine große Unsicherheit eine Selektion auf Grundlage dieses Kriteriums negativ beeinflussen und zu fehlerhaften Selektionen führen. Ist der Fehler proportional zur Störung, sind diese Unsicherheiten unter Umständen abschätzbar. Noch problematischer sind daher Effekte, die einen mehr diskontinuierlichen Zusammenhang zwischen Störung und Fehler aufweisen, wie es bei T_e zu beobachten ist.

Die Tabelle 5.1 enthält als Referenz zu Bild 5.4 die ermittelten absoluten Werte der Kriterien und deren Standardabweichung. Die erste Zeile für jedes Kriterium enthält die für die ungestörte Sprungantwort ermittelten Kriterien, entsprechend ist die Standardabweichung für alle Kriterien $\sigma = 0$. Die weiteren Zeilen zeigen Mittelwert und Standardabweichung für jeweils tausend Auswertungen der mit einer jeweils gleich starken Rauschstörung beaufschlagten Sprungantwort. Die Daten der einzelnen Zeilen entsprechen den in Bild 5.4 für die entsprechenden σ_{sig} aufgetragenen Werten der Kriterien und Fehler, allerdings sind in der Tabelle die Absolutwerte angegeben, um einen Bezug zur realen Sprungantwort zu ermöglichen.

5.2.3 Kritische Diskussion der Kriterien

Alle Kriterien zur Bewertung von Sprungantworten zeigen verschiedene Vor- und Nachteile. Die Anwendung multikriterieller Optimierungsverfahren ermöglicht es hier jedoch durch Inkaufnahme von Redundanzen innerhalb der verwendeten Kriterien, eine Kombination sich gegenseitig ergänzender Vor- und Nachteile zu erzielen. Da diese sich in Abhängigkeit der betrachteten Anwendung und verschiedener Rahmenbedingungen verändern, ist die konkrete Kombination von Kriterien hier lediglich exemplarisch betrachtet.

Für die Kriterien T_a sowie \ddot{U} ist ein singuläres Ereignis wie das erstmalige Erreichen eines Wertes entscheidend. Wird eine Sprungantwort eines real gemessenen Systems betrachtet, so besteht durch ein überlagertes Rauschen für diese Kriterien eine relevante Wahrscheinlichkeit für einen Fehler, da ein einzelner rauschbedingter Messfehler eine kleinere T_a oder einen vergrößerten Wert von \ddot{U} zur Folge haben kann. Das *ISE* hingegen ist durch das Integrieren mehrerer Messwerte vergleichsweise unempfindlich gegen diesen Effekt. Dem entgegen steht, dass der Wert eines Integral- oder Summenkriteriums deutlich schlechter interpretierbar und wenig intuitiv zu bewerten ist. Hier sind die zuerst genannten Kriterien deutlich im Vorteil. Es bietet sich daher beispielsweise eine Kombination der drei genannten Kriterien an. Die Verwendung von T_e als Kriterium sowohl für das statische als auch das dynamische Verhalten kann abhängig von der betrachteten Anwendung zu einer Reduktion der Kriterienzahl führen, jedoch mit den bereits genannten Nachteilen eines unter Umständen nicht-kontinuierlichen Kriterienraums.

Neben dem Informationsgewinn, den man durch die Bewertung mit einem Kriterium erzielen will, sind die wichtigsten Aspekte und Einflussfaktoren bei der Auswahl geeigneter Kriterien:

- Realisierbarkeit der Bewertung und technische Rahmenbedingungen des Systems
- Wahl der Anregung des Systems und Qualität der Messung
- Anforderungen an die Interpretierbarkeit der Kriterien
- Minimierung der Dimension des Kriterienraumes zur Optimierung
- Robustheit und Reproduzierbarkeit der Bewertungen

- Reproduzierbare evolutionäre Fitness, also Dominanzrelation in der Lösungsmenge

Diese Aspekte können für ein betrachtetes Kriterium nicht pauschal behandelt werden. Die Relevanz einzelner Aspekte oder deren Konsequenzen für die Definition geeigneter Kriterien sind abhängig von der betrachteten Problemformulierung und müssen individuell berücksichtigt werden.

5.3 Robustheit von Lösungen und Optimierung

Bei der Anwendung evolutionärer Algorithmen und ähnlicher Optimierungsverfahren erfolgt die Bewertung einer möglichen Lösung auf Grundlage der Auswertung einer Zielfunktion oder Fitnessfunktion. Für viele reale Anwendungsszenarien, etwa wenn die auszuwertende Funktion Experimente und Messungen erfordert, oder wenn ein System mehr Variablen als die in der Optimierung berücksichtigten Parameter umfasst, ist eine Auswertung nicht zuverlässig reproduzierbar. In solchen Fällen stellt sich bei wiederholter Auswertung einer Lösung deren Bewertung nicht als einzelner definierter Punkt im Kriterienraum, sondern vielmehr als mehrdimensionale Verteilung in Abhängigkeit stochastischer oder deterministischer Variablen dar. Diese Variablen können problemabhängig unterschiedlicher Herkunft sein. Beispiel für eine stochastische Variable ist ein mögliches Messrauschen oder der in den Bildern 5.1 und 5.2 gezeigte Einfluss einer Störgröße. Deterministische Variablen sind beispielsweise unterschiedliche Bedingungen für das Experiment zur Bewertung der Lösung. Auch diese können als Störgröße betrachtet werden, sind aber in der Regel bekannt oder selbst gewählt. Einen Spezialfall dieser Art Variable stellen die Parametertoleranzen dar. Kann nicht sichergestellt werden, dass eine Lösung exakt wie optimiert auch umsetzbar ist, so wird die Robustheit der Lösung durch die Sensitivität gegenüber Variationen der Parameter bestimmt.

Die zentrale Motivation zur Berücksichtigung der Robustheit ist durch die Eigenschaft von EAs begründet, nicht primär nach optimalen Lösungen zu suchen, sondern schlechte Lösungen zu vermeiden. Die populationsbasierte Struktur des Algorithmus eröffnet Individuen die Möglichkeit, aufgrund einer einmaligen, zufällig oder deterministisch besseren, nicht reproduzierbaren Bewertung, die Ergebnisse in den folgenden Generationen zu beeinflussen. Eine Selektion auf Grundlage dieser Bewertungen führt dazu, dass der Algorithmus potentiell in dadurch entstehenden Nischen des Kriterienraums konvergiert, auch wenn diese nur zufällig oder temporär existieren.

Daher ist es notwendig, die Kriterien zur Bewertung von Lösungen robust und reproduzierbar zu gestalten, um eine korrekte und stabile Wirkungsweise der evolutionären Selektionsmethoden und damit generell das Funktionieren der Optimierung zu gewährleisten. Große Unsicherheiten in der Bewertung von Lösungen gefährden die Konvergenz des Algorithmus. Darüber hinaus kann in verschiedenen Komponenten und Operatoren des MOEA, beispielsweise der Selektion, der Mutation oder des Elite-Archives, durch die Berücksichtigung der die Robustheit bestimmenden Mechanismen ein robustes Optimierungsergebnis erzielt werden.

5.3.1 Berücksichtigung stochastisch beeinflusster Fitnessfunktionen

Die mit Rauschen behaftete Messung eines zu bewertenden Signals oder generell die experimentelle Bewertung eines realen Systemverhaltens mit Unsicherheiten führt zu einer stochastischen Verteilung für die erwarteten Werte der Kriterien zur Bewertungen einer Lösung. Unter der Voraussetzung normal verteilter, unkorrelierter Störeinflüsse und weiterer Idealisierungen ergibt sich auch für die Kriterienwerte eine Normalverteilung. Diese Annahme trifft nicht in allen Fällen zu (vgl. Bild 5.4), stellt aber eine gute Grundlage für weitere Überlegungen dar, da über die konkrete Verteilung im Allgemeinen keine Informationen vorliegen.

Die durch diese Art der Effekte verursachte Unsicherheit ist durch den Vorgang der Bewertung der Lösung, nicht durch die Lösung selbst verursacht. Das Ziel geeigneter Maßnahmen ist es daher nicht, die Unsicherheit der Bewertung mit in der Fitnessfunktion zu berücksichtigen, sondern diese möglichst zu eliminieren. Die Sensitivität verschiedener Kriterien gegenüber Signalstörungen wurde in Abschnitt 5.2.3 bereits angesprochen. Um das Auftreten solcher Fehler zu reduzieren, werden Methoden der Signalverarbeitung angewendet. Eine durch einzelne Ausreißer verursachte fehlerhafte Ermittlung beispielsweise des Überschwingens lässt sich durch eine Median-Filterung des gemessenen Signals verhindern. Andere verbreitete und bewährte Methoden sind zum Beispiel ein gleitender Mittelwert sowie eine Tief- oder Bandpassfilterung des Signalverlaufs. Hier stehen die Vermeidung von Ausreißern und die generelle Verfälschung des Signalverlaufes potentiell im Konflikt zueinander. Die Wahl einer ausreichend hohen Abtastrate ermöglicht jedoch die sichere Filterung einzelner gestörter Abtastungen. Sind fehlerhaft ermittelte Kriterien durch solche Maßnahmen der Signalkonditionierung nicht vollständig zu vermeiden, folgt darauf die Erkennung und Handhabung zufällig fehlerhafter Bewertungen. Die angenommene Verteilung der auftretenden Störung wird genutzt, um durch Mittelwertbildung über mehrere wiederholte Bewertungen den tatsächlichen Wert zu ermitteln. Abhängig von der Charakteristik der Störungen bietet sich alternativ auch ein Median über mehrere Bewertungen oder ein Mittelwert unter Ausschluss von Ausreißern an.

In der Literatur finden sich einige Analysen zum Einfluss stochastisch gestörter Fitnessfunktionen auf die Optimierung sowie verschiedene Ansätze zum Umgang mit gestörten Bewertungen. Goh und Tan vergleichen in [97] und [98] die Leistungsfähigkeit verschiedener MOEA unter dem Einfluss von verrauschten Fitnessfunktionen und schlagen ergänzende Mechanismen vor, die die Anfälligkeit der Algorithmen im Hinblick auf Konvergenz und Diversität der Lösungen reduzieren. Im Kontext der Evolutionsstrategien beschäftigt sich Beyer in [99] mit dem Einfluss von Rauschen und Konsequenzen für die Optimierung. Beyer und Sendhoff entwickeln in [100] Testfunktionen speziell für die Betrachtung von durch Rauschen induzierten Multimodalitäten und leiten darauf basierend Empfehlungen für die Wahl der Optimierungsstrategie ab. Deb und Gupta betrachten in [101] das Robustheitsproblem mit Blick auf die Veränderung der Pareto-Front und deren Form. Mit dem Konflikt zwischen höherer Robustheit durch eine größere Anzahl von Auswertungen und dem dadurch vergrößerten Aufwand beschäftigen sich Di Pietro et al. in [102].

Obwohl sich EAs gerade für reale Anwendungen und gestörte Fitnessfunktionen anbieten, ist die Zahl der systematischen Analysen im Vergleich zur Gesamtzahl an Publikationen in diesem Gebiet eher gering, wenngleich die oben genannten nur einen kleinen ausgewählten Teil dieser Veröffentlichungen darstellen. Erklärt werden kann dies dadurch, dass eine gestörte Fitnessfunktion zwar allgemein im Sinne eines abstrakten Rauschens, jedoch immer auch problemspezifisch betrachtet werden kann. Ein problemspezifisches Herangehen und Reduzieren oder Quantifizieren von Störungen ist für eine Anwendung isoliert betrachtet erfolgversprechender als allgemeine Lösungen im Sinne störungstoleranter Algorithmen. Auch in dieser Arbeit liegt das Hauptaugenmerk auf der Betrachtung von Störungen und Robustheit aus der Perspektive des Optimierungsproblems und auf der entsprechenden Auswahl der verwendeten Kriterien.

5.3.2 Beispiel: Lineares Modell eines Hydraulikventils

Die verschiedenen Aspekte der Optimierung dynamischer Systeme lassen sich anhand eines Beispiels leichter verdeutlichen. Als solches dient ein einfaches lineares Modell eines hydraulischen Wegeventils in Form einer Übertragungsfunktion 2. Ordnung nach Gleichung 5.4. Das Modell ist im Allgemeinen nicht in der Lage, die für dessen Regelung relevanten Charakteristika eines Wegeventils abzubilden und dient nur der vereinfachten Berücksichtigung der Dynamik eines solchen Ventils in größeren Modellzusammenhängen. In seiner Funktion als vereinfachtes Beispiel kann ein solches Modell jedoch auch zur Veranschaulichung verschiedener Aspekte der Regleroptimierung verwendet werden. Die Übertragungsfunktion in Gleichung 5.4 nähert das Übertragungsverhalten eines Wegeventils ohne die Berücksichtigung dessen starker Nichtlinearität und Hysterese an. Auch hydrodynamische Einflüsse sind nicht berücksichtigt. Der Modelleingang ist der Strom des Ventilmagneten, die Ausgangsgröße ist die Position des Ventilkolbens.

$$G_{HVM}(s) = \frac{866}{s^2 + 1071s + 70860} \quad (5.4)$$

Die Parameter des Modells wurden anhand aufgezeichneter Ein- und Ausgangsdaten mittels eines Regressionsverfahrens identifiziert, das Bild 5.5 zeigt die Charakteristik der Übertragungsfunktion anhand eines Bodediagramms und der Sprungantwort.

Das System wird in diesem Kapitel exemplarisch verwendet, um verschiedene Aspekte der Optimierung dynamischer Systeme anschaulich und in einem von unkontrollierten Einflüssen isolierten und definierten Szenario diskutieren zu können.

5.3.3 Analyse der Robustheit anhand eines Beispiels

Um den Einfluss verschiedener stochastischer Störungen auf das Optimierungsergebnis untersuchen zu können, werden die Auswirkungen von Rauscheinflüssen simuliert, die gezielt auf verschiedene Aspekte der Fitnessbewertung einwirken. Diese werden im Hinblick auf

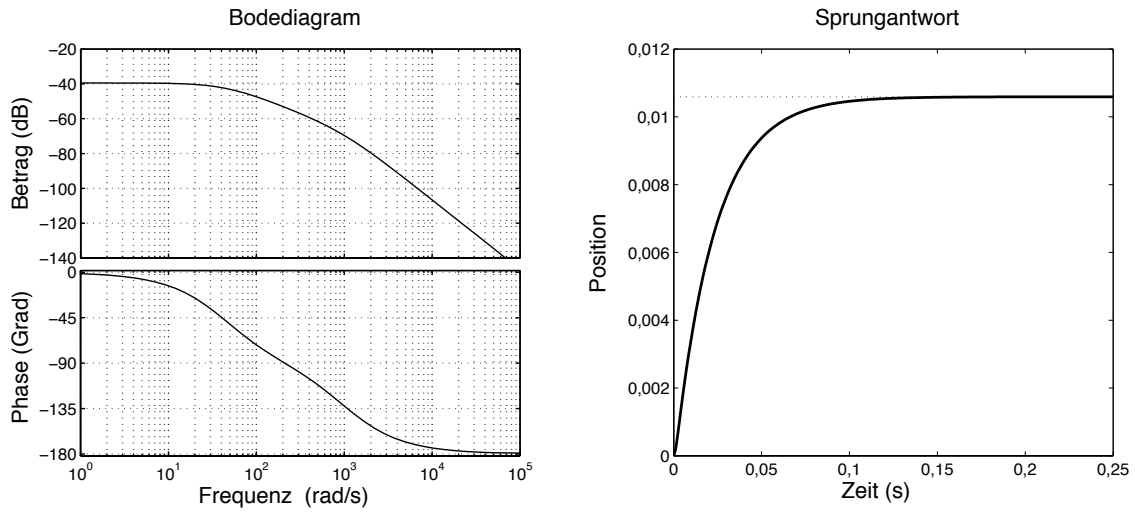


Bild 5.5: Bodediagramm (links) und Sprungantwort (rechts) der als Ventilmodell verwendeten linearen Übertragungsfunktion

ihre Wirkung auf die Optimierung analysiert. Als Grundlage dient auch hier das in Abschnitt 5.3.2 eingeführte lineare Systemmodell, das mit einem einfachen PI-Regler geregelt wird, dessen Reglerparameter evolutionär optimiert werden. Als Übertragungsfunktion des geschlossenen Regelkreises ergibt sich

$$R_{PI}(s) = \frac{(K_P T_N s + 1) G_{HVM}}{(K_P T_N s + 1) G_{HVM} + T_N s} \quad (5.5)$$

mit $\mathbf{k} = [K_P \quad T_N]^T$ als zu optimierende Parameter.

Die Kriterien zur Bewertung einer Lösung mit den Parametern \mathbf{k} ergeben sich aus der Auswertung der Sprungantwort $h(t, \mathbf{k})$. Die beiden Kriterien Anstiegszeit und Überschwingen bilden den Kriterienvektor $\mathbf{J} = [T_a(h) \quad \ddot{U}(h)]^T$. Eine normalverteilte Rauschstörung mit variierter Standardabweichung wirkt auf die Parameter \mathbf{k} , die ermittelte Sprungantwort am Ausgang des geschlossenen Kreises $h(t)$ oder auf die daraus ermittelten Kriterien \mathbf{J} .

In den drei betrachteten Fällen wirkt die Störung in Form einer normalverteilten mehrdimensionalen Zufallsvariablen $\theta = \mathcal{N}(0, \sigma_e)$, deren Dimension jeweils der der gestörten Größe entspricht. Verschiedene Standardabweichungen σ_e bestimmen die Intensität der Störung. Die gestörten Größen ergeben sich für jede Komponente unabhängig als $\tilde{J}_i = (\theta_i + 1)J_i$ für die Kriterien, als $\tilde{k}_i = (\theta_i + 1)k_i$ für alle Parameter und als $\tilde{q}_i = (\theta_i + 1)q_i$ für den Vektor der mit der Abtastzeit τ bis zum Zeitpunkt t_{ende} abgetasteten Sprungantwort $\mathbf{q} = h(t_i) \forall t_i \in [0, \tau, 2\tau, \dots, t_{ende}]$.

Analysiert wird der Einfluss dieser Störung auf die Konvergenz der Optimierung, die Geschwindigkeit, mit der eine Approximation der Pareto-Front ermittelt wird. Grundlage der ermittelten Daten sind jeweils 10 wiederholte und gemittelte Optimierungen mit der Konfiguration aus Anhang D.1.

Einfluss der Störung auf die Approximation der Pareto-Front

Die Konvergenz der Optimierung kann durch Störungen in der Fitnessfunktion beeinflusst werden. Ein aussagekräftiges Maß dafür ist die Anzahl der bis zum betrachteten Zeitpunkt ermittelten nicht-dominierten Lösungen. Da die Fitnessfunktion des verwendeten Beispiels keine lokalen Minima aufweist, erreicht die Optimierung zuverlässig die Maximalgröße der Elite-Population durch die Approximation der Pareto-Front. Veränderungen in der Entwicklung der Populationsgröße können daher als Veränderungen der Konvergenzgeschwindigkeit interpretiert werden.

Bild 5.6 zeigt die Entwicklung der Größe der Elite-Population für Optimierungen von auf verschiedene Art und in verschiedener Intensität gestörten Fitnessfunktionen. Für alle drei Arten der Störung und für jeweils alle $\sigma_i \in \{10^{-4}, 10^{-3}, 2 \cdot 10^{-3}, 10^{-2}, 2 \cdot 10^{-2}, 10^{-1}\}$ ist die Größe der Elite-Population über die Anzahl durchgeführter Fitnessbewertungen aufgetragen. Die ersten drei Darstellungen zeigen die verschiedenen Arten von Störung für alle σ , das vierte Bild zeigt einen Vergleich der Störungen für ein $\sigma = 0,01$. In Bild 5.6 oben links wirkt die Störung auf die Reglerparameter.

Für alle σ mit Ausnahme des größten ($\sigma = 0,1$) entspricht die Entwicklung der Menge nicht-dominiert Lösungen in etwa der in allen Bildern als durchgezogene schwarze Linie dargestellten Referenzoptimierung ohne Störung, in einigen Fällen wird deren Konvergenz übertroffen. Begründet ist dies durch die Tatsache, dass eine Störung auch Konfigurationen von Parametern ermöglicht, die außerhalb des durch die Parametergrenzen limitierten Lösungsraumes liegen. Diese Lösungen übertreffen sehr wahrscheinlich alle Lösungen, die innerhalb dieser Grenzen liegen in zumindest einem Kriterium und sind daher nicht-dominiert. Dieser Effekt kann sich über den Verlauf der Evolution verstärken, da Lösungen am Rand des Parameterraumes, die den beschriebenen Vorteil nutzen können, dadurch in der Selektion evolutionär bevorzugt sind und sich in der Population halten. Oben rechts zeigt das Bild 5.6 die Auswirkung einer Störung auf die Kriterien. Es zeigen sich Verlangsamungen, die qualitativ im Wesentlichen der Größe der Störung entsprechen. In diesem Störungsfall kann eine vollständig symmetrische Verteilung der Abweichungen von der ursprünglichen Lage im Kriterienraum vorausgesetzt werden, für den Fall der gestörten Parameter ist lokal für eine Lösung immerhin noch die Annahme gültig, dass diese Verteilung für jede der Raumrichtungen symmetrisch ist. In diesen Fällen ist die Wahrscheinlichkeit dafür, dass der gestörte Lösungsvektor $\tilde{\mathbf{J}}$ eine beliebige andere Lösung fälschlicherweise dominiert und damit das Selektionsergebnis verfälscht, primär abhängig von deren Abstand zueinander. Unter Vernachlässigung der konkreten Form der Pareto-Front kann im Allgemeinen davon ausgegangen werden, dass die Rate der falschen Selektionen, die für eine langsamere Konvergenz der Lösungsmenge zur Pareto-Front verantwortlich ist, abhängig ist vom Verhältnis der Standardabweichung der Störung zum durchschnittlichen Abstand der Lösungen innerhalb der Population.

Die Darstellung unten links in Bild 5.6 zeigt den Einfluss einer Störung des simulierten Signals der Sprungantwort. Hier zeigt sich die gravierendste Beeinträchtigung bei größeren Störungen. Für Störungen der Daten, auf deren Grundlage die Kriterien ermittelt werden, sind für die verwendeten Kriterien theoretisch zwei Szenarien zu unterscheiden. Zum einen

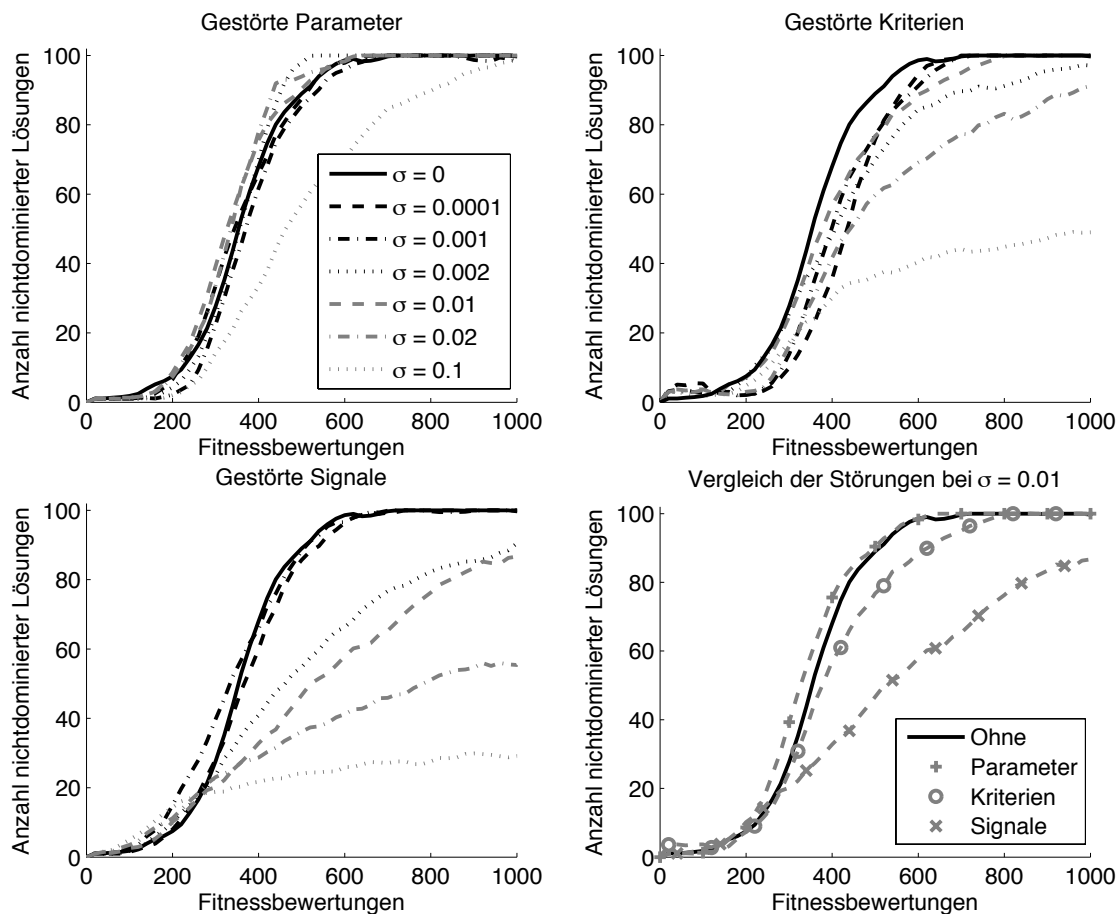


Bild 5.6: Auswirkungen verschiedener Störungen auf die während der Optimierung ermittelte Anzahl nicht-dominierter Lösungen

kann eine Veränderung des Wertes direkt das Kriterium verändern. Der Wert des Kriteriums \tilde{U} , die größte auftretende Amplitude, ist um den Betrag der Rauschamplitude an dieser Stelle vergrößert oder verringert. Die Auswirkungen der Störung entsprechen dann im Wesentlichen den Auswirkungen von gestörten Kriterien. Zum anderen ist jedoch auch eine Veränderung des durch die Kriterien bewerteten Ereignisses selbst möglich, was zu deutlicher fehlerhaften Bewertungen führen kann.

Bei normalverteiltem Rauschen mit relativ großen Amplituden, die ein eigentlich kontinuierliches Signal stören, ist es erheblich wahrscheinlicher, dass ein einzelner gestörter Wert vor dem eigentlichen Erreichen des Zielwerts zu einer verkürzten Anstiegszeit führt, als dass andersherum alle ähnlichen benachbarten Werte des ursprünglichen Signals derart gestört werden, dass eine fälschlicherweise deutlich längere Anstiegszeit ermittelt wird. Dies führt zu einer asymmetrischen Verteilung der Fehler im Kriterienraum und einer dadurch größeren Wahrscheinlichkeit einer fehlerhaften Selektionsentscheidung.

Die vierte Darstellung (unten rechts) zeigt einen Vergleich des Einflusses aller Störungen für ein ausgewähltes $\sigma = 0,01$. Das Verhältnis des Einflusses der unterschiedlichen Störun-

gen zueinander bestätigt die Interpretation der separaten Betrachtung. Die Störung des Signals hat den größten Einfluss, die Parameterstörung hingegen wirkt sich gar nicht negativ aus. Die quantitative Interpretation ist jedoch durch die Definition der Stärke der Störung relativ zum gestörten Wert eingeschränkt. Alle Störungen entwickeln ihren Einfluss im Kriterienraum, der Zusammenhang zwischen den Domänen, in denen die Störung auftritt, ist jedoch problemspezifisch.

Für den Optimierungsprozess ist letztlich nur eine Ordnung innerhalb der Lösungsmenge Grundlage der Selektion, ein und die selbe Ordnung kann aber unterschiedlich zu Stande kommen. Für den Kriterienraum ist daher der relative Unterschied zwischen Lösungen relevant. Der Zusammenhang zwischen Parameter- und Kriterienraum wird in diesem Beispiel bestimmt durch eine Übertragungsfunktion eines geschlossenen Regelkreises. Der Einfluss der absoluten Parameterwerte und damit auch der Einfluss der Störung dieser Parameter ist von der Charakteristik des geregelten Systems abhängig. Die gezeigten Daten dienen daher nur einer qualitativen Interpretation und der Illustration ausgewählter Mechanismen und lassen keine quantitativen Schlüsse bezüglich der Störanfälligkeit zu, die sich direkt auf andere Optimierungsprobleme übertragen lassen.

Das Bild 5.7 zeigt die Auswirkungen der verschiedenen Störungen auf die Ergebnismen-

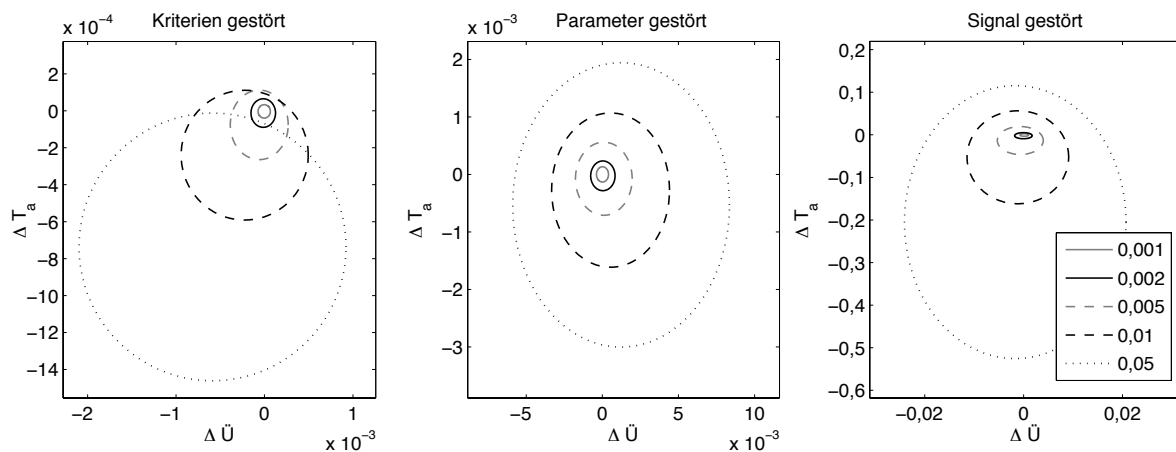


Bild 5.7: Verteilung der Fehler im Kriterienraum

gen der betrachteten Optimierungen. Für die beiden Dimensionen des Kriterienraums, T_a und \ddot{U} , werden der Mittelwert und die Standardabweichung des Fehlers aller Lösungen der finalen Elitepopulation betrachtet. Der Fehler, die Differenz zwischen den in der Optimierung ermittelten und den ungestörten Kriterien, ist gemittelt für alle Wiederholungen der Optimierung und führt für jedes σ zu einer Ellipse, deren Mittelpunkt dem Mittelwert und deren Radius jeweils der Standardabweichung des Kriteriums entspricht. Die drei Abbildungen zeigen die drei verschiedenen betrachteten Arten von Störung. Im Allgemeinen ist davon auszugehen, dass der Mittelwert des Fehlers aller gestörten Populationen immer in Richtung Minimum verschoben ist, niemals in die andere Richtung, da die Wahrscheinlichkeit für die Zugehörigkeit zu der betrachteten Elite-Population praktisch nur durch Verbesserungen von Lösungen vergrößert wird.

Für die Betrachtung der gestörten Kriterien wird deutlich, dass für die Elite-Individuen eine zufällige Verbesserung beider Kriterien ein direkter Vorteil ist. Die Verteilungen sind mit wachsender Störung in negativer Richtung verschoben. Für gestörte Parameter ergibt sich keine offensichtliche Verschiebung der Verteilungen, wie auch bei der Betrachtung der Konvergenz in Bild 5.6 zeigt sich der nur geringe systematische Einfluss. Bemerkenswert bei der Betrachtung der Verteilungen für den Signalfehler ist die Tatsache, dass der Mittelwert der Verteilungen, betrachtet im Verhältnis zur Standardabweichung, deutlicher in Richtung der Anstiegszeit T_a verschoben ist. Dies wird durch das Bild 5.4 bestätigt. Hier zeigt sich, dass ein durch eine Störung zufällig fehlerhaftes T_a sowohl verbessert als auch verschlechtert werden kann, das Überschwingen \ddot{U} hingegen so gut wie immer schlechter wird. Da nur Verbesserungen in einem Kriterium die Wahrscheinlichkeit für eine Elite-Zugehörigkeit erhöhen, setzen sich eben diese Fehler auch in den betrachteten Populationen stärker durch.

5.3.4 Zeitabhängig variierende Fitnessfunktion

Treten Störungen zwar nicht rein zufällig auf, lassen sich aber auch nicht unmittelbar im Sinne der Bedingungen des Experiments beeinflussen, so führt dies allgemein zu einer zeitabhängigen Variation der Fitnessfunktion. Die Zeit ist dabei nicht immer der primäre Faktor, aber auch andere korrelierte Veränderungen, die beispielsweise durch wiederholte Durchführungen des Experiments verursacht werden, können als zeitliche Variation betrachtet werden.

Die Problematik dieser Störeinflüsse betrifft im Wesentlichen zwei Aspekte der Optimierung. Vordergründig ist zunächst problematisch, dass bei sich verändernden Fitnessfunktionen die gefundenen optimalen Lösungen nur zeitlich begrenzt als optimal betrachtet werden können. Im Ergebnis führt dies zu Lösungen, die, vergleichbar zur Situation beim Vorliegen einer statischen Störung der Optimierungsbedingungen, eine Überanpassung an die Verhältnisse zum Optimierungszeitpunkt darstellen. Läuft die zeitliche Variation auf einer Zeitskala ab, die verglichen mit dem Optimierungsprozess deutlich größer ist, so beschränkt sich das Problem auch darauf. Die Optimierung an sich funktioniert in diesem Fall und führt zu optimalen Lösungen, lediglich deren Gültigkeit ist durch die zeitliche Veränderung begrenzt. Der zweite und gravierendere Aspekt der zeitlichen Variation tritt auf, wenn die Fitnessfunktion auch während einer Optimierung Veränderungen unterworfen ist, die nicht vernachlässigbar sind.

Für einige Strategievarianten der Optimierung ist eine Vergleichbarkeit von Lösungen aus verschiedenen Generationen erforderlich. Wurden diese jedoch mit signifikantem zeitlichen Abstand bewertet, so kommt dies der Bewertung mit einer unterschiedlichen Fitnessfunktion gleich. Elite-Strategien sind hier besonders anfällig, da sie ein Archiv von nicht-dominierten Lösungen über die gesamte Optimierung pflegen. Komma-Strategien hingegen sind so gut wie nicht betroffen, da nur Bewertungen einer Generation miteinander konkurrieren. Vorausgesetzt wird dafür, dass die Fitnessfunktion für eine Generation als unverändert betrachtet werden kann.

Grundsätzlich kann diesem Problem abgeholfen werden, indem durch erneutes Auswerten älterer Individuen sichergestellt wird, dass eine identische Fitnessfunktion Grundlage der aktuellen Selektionsentscheidung ist. Bei Plus-Strategien ist hierfür lediglich das erneute Auswerten der Eltern-Generation erforderlich, eine Elite-Strategie macht aber eine Neubewertung des in der Regel umfangreicheren Elite-Archivs notwendig. Um gerade bei aufwändigeren Fitnessfunktionen den Aufwand zu begrenzen, ist es möglich, die Anzahl realer Bewertungen durch Abschätzungen und Prädiktionen der zu erwartenden Veränderung zu reduzieren. Auf Grundlage der Annahme, dass der Veränderung der Fitnessfunktion ein Effekt oder Trend zu Grunde liegt, dessen Auswirkungen auch im Kriterienraum lokale Ähnlichkeiten aufweisen, kann die zu erwartende Veränderung der Kriterien bei erneuter Bewertung anhand der beobachteten Veränderung benachbarter Individuen geschätzt werden. Stroud et al. kombinieren zu diesem Zweck beispielsweise den bekannten Kalman-Filter mit evolutionären Algorithmen [103]. Hatzakis et al. verwenden in einem ähnlichen Kontext stochastische Zeitreihenmodelle zur Vorhersage einer Bewertung [104].

Zu beachten ist bei diesen Methoden jedoch, dass die gefundenen Lösungen trotz der robusten Optimierung nicht unabhängig von der zu Grunde liegenden Fitnessfunktion betrachtet werden können. Ein optimales Ergebnis ist lediglich optimal unter den berücksichtigten Bedingungen, eine Generalisierung darüber hinaus ist nicht möglich, vor allem da der Zustand der zeitlich veränderlichen Fitnessfunktion für die angestrebte Anwendung im Allgemeinen nicht vorhergesagt werden kann. Für die in dieser Arbeit thematisierte Optimierung von Regelungssystemen ist es daher vorzuziehen, entweder zeitlich veränderliche Aspekte der Bewertung zu eliminieren, beispielsweise indem Maßnahmen für stabile Betriebsbedingungen getroffen werden, oder jedoch die Veränderlichkeit der Bedingungen konzeptionell zu berücksichtigen, indem beispielsweise die betrachteten Systeme adaptiv [105] ausgelegt werden.

5.3.5 Sensitivität von Parametern in der Optimierung

Ein weiterer wichtiger Aspekt von Robustheit im Kontext von Optimierung ist verknüpft mit der Sensitivität der Lösungsparameter. Vordergründig ist diese zunächst vor allem relevant für die Anwendung einer ermittelten Lösung. Ein Regelungssystem ist unter anderem dann robust, wenn dessen Verhalten wenig sensitiv ist gegenüber einer Variation seiner Parameter. Im Kontext der evolutionären Optimierung kommt der Sensitivität der Parameter jedoch eine weitere Bedeutung zu. Eine wichtige Voraussetzung für die Wirkungsweise der evolutionären Optimierung ist es, lokale Eigenschaften der im Allgemeinen unbekanntem Zusammenhänge zwischen Parametern und Kriterien zu erhalten und zu nutzen. Die Mechanismen der Optimierungsalgorithmen, in erster Linie Mutationsoperatoren, können von einer Kenntnis über die Sensitivität von Parametern profitieren, da auf diesem Weg die bereits in Abschnitt 2.1 eingeführte Balance zwischen Tiefen- und Breitensuche erhalten oder erzeugt werden kann.

Das wichtigste und ursprüngliche Beispiel für eine Anpassung des Mutationsoperators an die Sensitivität ist die 1/5-Erfolgsregel nach Rechenberg [8] und Schwefel [106]. Neuere, obgleich schon erfolgreiche und etablierte Methoden und Algorithmen in diesem Bereich

stellen die CMA-ES von Hansen et al. [20, 107] und deren Weiterentwicklung für die multikriterielle Optimierung von Igel et al. [108] dar. Bei diesem Verfahren wird während der Optimierung eine Kovarianz-Matrix adaptiert, die eine individuelle Anpassung der Schrittweite der Mutation für alle Parameter an deren Sensitivität ermöglicht. Dies bewirkt eine im Vergleich mit rudimentären Strategien erheblich gesteigerte Effizienz bei der Exploration des Lösungsraums.

Im Hinblick auf die Anwendung einer ermittelten Lösung stellt die Robustheit im Sinne der Sensitivität jedoch unter Umständen kein absolutes Ziel, sondern vielmehr ein weiteres Kriterium dar. Gesucht ist in solchen Fällen nicht eine besonders robuste Lösung, sondern ein optimaler Kompromiss zwischen der Robustheit und den übrigen Kriterien, die mit der Robustheit unter Umständen in Konflikt stehen. Jin et al. führen Robustheit in [109] als zusätzliches zu maximierendes Optimierungskriterium für einen MOEA ein.

Sensitivität gegenüber Parametervariationen als Optimierungskriterium

Motiviert durch die Tatsache, dass der Gegenstand der Optimierung, sei es HIL oder im Modell, wenngleich aus unterschiedlichen Gründen, selten exakt dem System der beabsichtigten Anwendung entspricht, entsteht der Gedanke, die Sensitivität der Fitness hinsichtlich der Lösungsparameter in der Optimierung zu berücksichtigen. Im Allgemeinen ergibt sich dann auch hier ein Kompromiss zwischen der Qualität einer Lösung und ihrer Sensitivität. Ist nun a priori bekannt, dass die ermittelten Parameter nur mit begrenzter Präzision in der Anwendung reproduziert werden können, ist es sinnvoll eine Lösung zu wählen, deren Sensitivität geringer ist, auch wenn dies auf Kosten der primären Qualität, also der betrachteten Kriterien geht.

Entscheidendes Maß für die zu erwartende Veränderung der Kriterien ist deren Sensitivität gegenüber allen Lösungsparametern. Wird ein Lösungsparameter variiert, so verändert sich unter Umständen der Wert für alle Kriterien. Diese Sensitivitäten sind im Allgemeinen nicht unabhängig voneinander und abhängig vom Arbeitspunkt, also der betrachteten Ausgangslösung. Bild 5.8 verdeutlicht anhand eines einfachen eindimensionalen Beispiels die Sensitivität als lokal zu erwartende Fitnessveränderung. Die gleiche Variation im Parameterraum, hier betrachtet als finite Differenz $x \pm \delta$, führt je nach Arbeitspunkt zu unterschiedlichen Veränderungen im Kriterienraum.

Die Sensitivität einer Lösung gegenüber Parametervariationen kann durch (partielle) Gradienten für alle Kriterien \mathbf{f} im Hinblick auf alle Parameter \mathbf{x} ermittelt werden. Der maximale Gradient charakterisiert vereinfachend die Sensitivität der Lösung gegenüber Variationen und definiert einen Sensitivitätsindex χ :

$$\begin{aligned} \chi(l = \{\mathbf{x}, \mathbf{f}\}) &= \max(|\nabla \mathbf{f}|) \quad , \\ \nabla \mathbf{f} &= (\nabla f_1, \nabla f_2, \dots, \nabla f_{n_f}) \quad , \\ \nabla f_i &= \left(\frac{\partial f_i}{\partial x_1}, \frac{\partial f_i}{\partial x_2}, \dots, \frac{\partial f_i}{\partial x_{n_x}} \right)^T \quad . \end{aligned} \tag{5.6}$$




Bild 5.8: Beispiel für die unterschiedliche lokale Sensitivität einer Fitnesslandschaft und der Sensitivität einer Lösung als zusätzliches Kriterium für eine Pareto-Front

Der Wert von χ wird direkt als Maß für die Sensitivität einer Lösung verwendet und dient als zusätzliches Optimierungskriterium, da auch hinsichtlich der Robustheit ein optimaler Kompromiss zur eigentlichen Fitness gesucht wird. Diese Sensitivität bildet wie in Bild 5.8 dargestellt in Kombination mit den eigentlichen Kriterien eine Pareto-Front. Die Berücksichtigung der Robustheit einer Lösung als zusätzliches Optimierungskriterium ermöglicht einem Benutzer die objektive Kompromissentscheidung zwischen Robustheit und Fitness. Das Ermitteln der realen Sensitivität ist im Allgemeinen sehr aufwändig, da die Gradienten einer Lösung nicht bekannt sind. Diese durch finite Differenzen anzunähern, wie in Bild 5.8 skizziert, erfordert für n_x Lösungsparameter mindestens 2^{n_x} zusätzliche abweichende Bewertungen, um global alle möglichen Kombinationen von Abweichungen zu erfassen. Betrachtet man die Variation in den Parametern lokal als unabhängig voneinander, so reduziert sich diese Zahl auf $2n_x$ zusätzliche Versuche. In diesem Fall werden nicht die Ecken eines Würfels um den betrachteten Wert im Parameterraum untersucht, sondern lediglich Punkte auf dessen Seitenflächen.

Surrogatmodelle zur Bestimmung der Sensitivität

Die Anzahl der für die Bestimmung der Sensitivität erforderlichen zusätzlichen Fitnessbewertungen steigt mindestens proportional zur Anzahl der Parameter der Lösung und führt zu erheblichem Mehraufwand für eine Fitnessbewertung. Eine Lösung ist es, anstelle der realen Fitnessbewertungen ein Surrogatmodell zu verwenden. Das Verfahren ist grundsätzlich dasselbe wie bekannt aus dem Bereich der modellgestützten Optimierung [110, 111, 112, 78]. Hier ist der Zweck der Modelle das Ersetzen realer Fitnessbewertungen durch die schnellere oder die kostengünstigere Auswertung eines Surrogatmodells, um Zeitaufwand oder Kosten für die Optimierung zu reduzieren.

Auch für die Sensitivitätsschätzung ist das Ziel die Einsparung von Fitnessbewertungen. Wie in Bild 5.8 skizziert, werden hier die Gradienten nicht anhand von realen Fitnessbewertungen durch finite Differenzen angenähert, sondern basieren auf Schätzungen anhand eines instanzbasierten lokalen Modells, in das alle bisher durchgeführten realen Auswertun-

gen einfließen. Die Robustheit einer Lösung wird so anhand des aktuellen Modellwissens geschätzt und zur Bewertung der Lösung hinzugezogen.

$$\begin{aligned}
 \tilde{\chi}(l = \{\mathbf{x}, \mathbf{f}\}) &= \max(\tilde{\nabla} \mathbf{f}) \\
 \tilde{\nabla} \mathbf{f} &= (\nabla^{\max} f_1, \dots, \nabla^{\max} f_{n_f}) \\
 \nabla^{\max} f_i &= (\max(|d_1^+|, |d_1^-|), \dots, \max(|d_{n_x}^+|, |d_{n_x}^-|))^T \\
 d_j^+ &= \frac{f_i^*(x_1, \dots, x_j + \delta, \dots, x_{n_x}) - f_i(\mathbf{x})}{\delta} \\
 d_j^- &= \frac{f_i(\mathbf{x}) - f_i^*(x_1, \dots, x_j - \delta, \dots, x_{n_x})}{\delta}
 \end{aligned} \tag{5.7}$$

Die Gleichungen 5.7 beschreiben die Berechnung der Schätzung $\tilde{\chi}$ für die Sensitivität auf Grundlage einer Kombination realer und modellbasierter Bewertungen. Sie basiert, äquivalent zu Gleichung 5.6 auf einer Matrix geschätzter und angenäherter partieller Gradienten $\tilde{\nabla} \mathbf{f}$. Im Unterschied zur Berechnung werden die Gradienten durch finite Differenzen ersetzt. Für die definierte lokale Variation jedes Parameters in beide Richtungen wird der größere Einfluss für jedes Kriterium ermittelt. Dieser ergibt sich aus der Abweichung zwischen dem real ermittelten Wert f_i des Kriteriums für die Ausgangslösung und dem durch das Modell geschätzten Wert f_i^* des Kriteriums für die Konfigurationen mit $x_j \pm \delta$. Grundlage für $\tilde{\chi}$ ist damit der Gradient des Fitnessmodells an der betrachteten Stelle.

Das Bild 5.9 zeigt beispielhaft das Ergebnis einer einfachen Optimierungsaufgabe, der Mi-




Bild 5.9: Beispiel für Sensitivität als zusätzliches Kriterium

nimierung einer im linken Bild als gestrichelten Linie gezeigten Funktion f auf Basis einer Logarithmusfunktion mit einem Parameter x . Diese originär monokriterielle Funktion ist um die Sensitivität der Lösung als zweites Kriterium erweitert und führt zu einer nicht-dominierten Lösungsmenge, die in der rechten Abbildung im Kriterienraum mit $f(x)$ und

$\tilde{\chi}$ sowie in der linken Abbildung als $f(x)$ über x dargestellt ist.

Die Einfärbung der einzelnen Individuen dient nur der einfacheren Zuordnung zwischen beiden Bildern. Die Größe der Lösungsmenge ist der anschaulicheren Visualisierung halber auf 20 Individuen begrenzt. Das Beispiel verdeutlicht, wie ein Optimierungsproblem durch die zusätzliche Berücksichtigung der Sensitivität von Lösungen um einen zusätzlichen Kompromiss und damit um eine Dimension erweitert wird.

Diese Methode ist grundsätzlich gut geeignet, die im realen Entwurfsprozess relevante Information bezüglich der Robustheit eines Parameters bereits im Optimierungsprozess zu berücksichtigen. Praktisch ist jedoch die Verwendung lokaler Surrogatmodelle nur für Optimierungsprobleme mit relativ kleinem Parameterraum sinnvoll, da andernfalls eine große Menge Daten für die Modelle erforderlich ist. Dieser Mehraufwand steht wiederum in Konflikt mit dem Ziel, die Menge durchzuführender Fitnessbewertungen zu reduzieren.

Kapitel 6

Optimierung von Reglern für Hydraulikventile unter Betriebsbedingungen

Der Anwendungsschwerpunkt der in dieser Arbeit entwickelten und vorgestellten Methoden ist die Optimierung von Parametern von Reglern für Hydraulikventile. Diese Systeme stellen aus verschiedenen Gründen eine Herausforderung dar, die den Einsatz von Optimierungsalgorithmen motiviert.

Hydraulikventile sind komplexe mechanische oder auch mechatronische Systeme, die eine Vielzahl von durch ihren Anwendungszweck oder ihre Bauart verursachten Nebenbedingungen erfüllen müssen. Hohe zu erwartende Belastungen durch intensiven Betrieb im industriellen Anwendungskontext und die durch hohen hydraulischen Druck notwendige massive Bauart führen zu verschiedenen nichtlinearen Systemeigenschaften. Die Ursachen dafür sind sowohl statische Arbeitspunktabhängigkeiten als auch dynamische Reibungseffekte oder magnetische Hysterese. Daraus ergibt sich die Notwendigkeit für die Anwendung vergleichsweise komplexer Regelungssysteme, um die genannten Eigenschaften beherrschen zu können. Diese Komplexität wiederum macht es nur schwer oder gar unmöglich, ohne Unterstützung durch Algorithmen eine optimale Lösung für Parametrierungen von Reglern zu finden.

Darüber hinaus sind die an diese Systeme gestellten Anforderungen vielfältig und nicht trivial zu definieren. Bei der Suche nach einem optimierten Regler sind verschiedene Aspekte des Systemverhaltens gegeneinander abzuwiegen und gleichzeitig eine Vielzahl von Robustheits-, Umgebungs- und Anwendungsbedingungen einzubeziehen. Die Berücksichtigung mehrerer miteinander in Konflikt stehender Kriterien empfiehlt allein schon die Verwendung eines MOEA. Darüber hinaus ergeben sich Schwierigkeiten, die sich aus Expertenwissen ergebenden Anforderungen an das Systemverhalten abstrakt als Optimierungskriterien zu formulieren. In beiden Fragestellungen bietet die interaktive Integration von Präferenzen eine Möglichkeit, Expertenwissen gewinnbringend in der Optimierung einzubringen.

Dieses Kapitel dokumentiert exemplarisch die Anwendung der in Kapitel 3 vorgestellten multikriteriellen evolutionären Algorithmen mit Integration von Benutzerpräferenzen zur

Optimierung von Hydraulikventilreglern. Die Grundlagen für die Optimierungskriterien ergeben sich aus den in Kapitel 5 beschriebenen Untersuchungen und Betrachtungen zur Optimierung dynamischer Systeme.

6.1 Hydraulische Regelventile

Regelventile, auch als Regel-Wegeventile bezeichnet, sind solche Proportional-Wegeventile, die aufgrund der Charakteristik ihrer Volumenstrom-Kennlinie und ihrer Steuerkanten speziell für den Einsatz in hydraulischen Regelungsaufgaben geeignet sind. Bei diesen Ventilen verändert die Positionierung eines Kolbens im Ventil den Weg zwischen den verschiedenen Anschlüssen und beeinflusst so Richtung und Menge des Ölflusses durch das Ventil. Im Gegensatz zu Schaltventilen, die nur diskrete Schaltstellungen haben, ermöglicht bei drosselnden Wegeventilen die kontinuierliche Veränderbarkeit der Kolbenposition eine stetige Veränderung der Öffnungen im Ventil.

Die konkreten Bauformen und Ausstattungen von Wegeventilen sind extrem vielfältig [113]. Neben der Größe der Ventile, ausgedrückt durch ihre Nenngröße, unterscheidet man verschiedene manuelle, elektrische oder mehrstufig hydraulische Möglichkeiten die Kolbenposition zu verstellen. Weiter können verschiedene Typen von Anschlüssen des Ventils sowie Art und Konfigurationen des Steuerkolbens unterschieden werden. Schließlich existieren noch verschiedene Arten von Reglern sowie Sensoren zum Erfassen der Regelgrößen. Darüber hinaus erstreckt sich eine unüberschaubare Anzahl von im Detail unterschiedlichen Konfigurationsmöglichkeiten, die den jeweiligen Datenblättern der oben genannten Ventiltypen zu entnehmen sind. Diese Details sind mehrheitlich für die Anwendung der Optimierung nicht relevant. Die meisten der vorher genannten Merkmale haben zwar einen deutlichen Einfluss auf das Ergebnis der Optimierung, stellen aber keinen prinzipiellen Unterschied für die Anwendbarkeit der Methode dar. Aus diesem Grund beschränkt sich die Betrachtung in diesem Kapitel auf nur eine Bauform des Ventils und betrachtet lediglich unterschiedliche Konzepte zur Regelung.

Bei den in dieser Arbeit betrachteten Ventilen handelt es sich um sogenannte *direktgesteuerte 4/4-Regel-Wegeventile mit elektrischer Wegrückführung* der Nenngröße NG6. Eine schematische Darstellung eines solchen Ventils zeigt das Bild 6.1 [114]. Ein Steuerkolben ④ bewegt sich in einer Hülse innerhalb eines Ventilgehäuses ①. In diesem eingegossene Kanäle und die Kolbenform sowie -position bestimmen den Fluss von Öl durch das Ventil. Der Kolben eines *direktgesteuerten* Ventils wird mittels eines Proportionalmagneten ② verstellt, der, gekontert durch eine Feder auf der anderen Seite, eine Kraft auf den Kolben ausübt. Die Kraft ist idealerweise proportional zum elektrischen Strom durch die Spule des Magneten und wird von einer Endstufe erzeugt, die üblicherweise ein Teil des Reglers ist. Dieser Strom kann daher als dessen Stellgröße betrachtet werden. Die *elektrische Wegrückführung* ③ ist ein Sensor, der, in einem Gehäuse mit dem Magneten verbaut, mittels eines induktiven Wirkungsprinzips die lineare Verschiebung des Kolbens erfasst und diese Regelgröße in Form einer proportionalen Spannung dem Regler als Ist-Wert zur Verfügung




Bild 6.1: Schnittzeichnung eines 4/4-Regel-Wegeventils, Quelle: Bosch Rexroth AG

stellt. In der dargestellten Bauform ist der Regler (5) direkt am Ventil in einem auf dem Magneten und Ventilkörper montierten Gehäuse untergebracht.

Die Bezeichnung 4/4 bezeichnet zuerst die Anzahl der hydraulischen Anschlüsse, danach die Zahl der logischen Schaltstellungen des Kolbens, die jedoch bei diesem Ventiltyp stetig ineinander übergehen. Die vier Anschlüsse werden, wie in Bild 6.1 zu sehen, mit P, T, A und B bezeichnet. Der Anschluss P ist üblicherweise verbunden mit der Druckversorgung. Der Anschluss T ist die Verbindung zum Tank beziehungsweise die Rückleitung. Die Anschlüsse A und B sind die Arbeitsanschlüsse des Ventils. Im normalen Betrieb regelt das Ventil einen Ölstrom von der Druckversorgung über Anschluss P zu einem der beiden Arbeitsanschlüsse A oder B beziehungsweise von B oder A über Anschluss T zurück zum Tank.

Das Arbeitsprinzip des 4/4-Ventils wird durch Bild 6.2 verdeutlicht. Die Darstellung zeigt symbolisch nach DIN ISO 1219 [115] die Konfiguration des Ventils.

Zwischen den Anschlüssen und den Symbolen für Magnet, Feder und Regler links und rechts zeigt das Bild in seiner Mitte vier Quadrate, die die möglichen logischen Konfigurationen des Ventils darstellen und die Verbindungen innerhalb des Ventils symbolisieren. Die durchgezogenen Linien über und unter drei der vier Quadrate zeigen an, dass hier ein stetiges Verhalten vorliegt und diese Konfigurationen kontinuierlich ineinander übergehen. Legt man ein Quadrat zwischen die skizzierten Anschlüsse, dann zeigen die Linien oder Pfeile innerhalb die Konfiguration des Ventils. Die linke Konfiguration ist die sogenannte *Fail-Safe-Stellung*, die nach dem Abschalten der Stromversorgung eingenommen wird und




Bild 6.2: Symbolische Darstellung eines direktgesteuerten 4/4-Regel-Wegeventils

im Normalbetrieb keine Rolle spielt. Die verbleibenden drei Symbole charakterisieren den normalen Arbeitsbereich des Ventils. In der rechten Konfiguration ist der Anschluss P mit dem Anschluss A verbunden, durch den so Öl von der Quelle zu einem angeschlossenen Verbraucher fließen kann. Gleichzeitig kann durch den mit T verbundenen Anschluss B Öl zurückfließen. Steht das Ventil in der Mittelstellung, sind alle Anschlüsse gedrosselt miteinander verbunden. Idealisiert betrachtet fließt jedoch kein Öl und das Ventil gilt als geschlossen. Aufgrund der Steuerkantencharakteristik ohne Überdeckung, die einer linearen Volumenstromkennlinie dient, fließt jedoch praktisch immer eine geringe Menge, was durch die Verbindungen mit eingezeichneten Drosseln angezeigt ist. Zwischen diesen beiden Konfigurationen bewegt sich die positive Hälfte des kontinuierlichen Arbeitsbereichs. Eine Stellung des Ventils vollständig in der rechten Konfiguration entspricht einer Stellung von 100% im Arbeitsbereich und dem maximalen Volumenstrom in der beschriebenen Richtung. Die Mittelstellung entspricht 0%, Stellungen dazwischen erlauben einen Volumenstrom zwischen 0% und 100% proportional zur Position des Kolbens. In der linken der Betriebskonfigurationen fließt Öl von P nach B und von A zurück nach T. Dieser Teil des Arbeitsbereichs wird aufgrund des umgekehrten Flusses mit negativem Vorzeichen versehen und erstreckt sich von -100% bei voller Öffnung bis 0% in der Mittelstellung. Für die in diesem Kapitel betrachteten Regler stellt diese Kolbenposition die Regelgröße dar und wird über diese Definition des Arbeitsbereichs als relative Größe im Wertebereich von -100% bis 100% verwendet.

6.2 Struktur und Realisierung von Ventillagereglern

Die Lageregler, deren Parameter im Rahmen dieser Arbeit optimiert werden, sind Teil eines Regelkreises, der neben dem Regler und der in Abschnitt 6.1 beschriebenen Regelstrecke weitere periphere Komponenten enthält. Bild 6.3 zeigt den Aufbau des Regelkreises. Dem für die Optimierung betrachteten Lageregler ist ein Stromregler in einem unterlagerten Regelkreis nachgeordnet. Dieser erzeugt abhängig von der Differenz zwischen dem vom Lageregler vorgegebenen Stromistwert i_{soll} und dem gemessenen Strom in der Endstufe i_{ist} eine Stellgröße in Form eines Faktors t_{PWM} . Dieser gibt das Tastverhältnis für die in der Endstufe erzeugte pulsweitenmodulierte (PWM) Spannung vor, die erzeugt wird, um den Magnetaktuator zu treiben.

Die Regelgröße des äußeren Regelkreises ist die Kolbenposition. Diese wird durch einen

Lagesensor erfasst und als y_{ist} zurückgeführt. Der Sensor arbeitet nach dem Prinzip eines Differentialtransformators und wird entsprechend als LVDT (*Linear Variable Differential Transformer*) bezeichnet. An eine Primärspule, die um eine gemeinsame Achse mit Magnetanker und Ventilkolben platziert ist, wird eine Wechselspannung angelegt. Die induzierte Spannung in zwei ebenfalls um diese Achse liegenden Sekundärspulen hängt dann vom Kopplungsfaktor zwischen den Spulen ab, der von der aktuellen Position der Achse bestimmt wird. Die Differenz beider Sekundärspannungen dient zur präzisen Berechnung der linearen Position des Kolbens.




Bild 6.3: Blockschaltbild der Struktur des Regelkreises für ein Ventil

Gegenstand der Optimierung sind Parameter des Lagereglers, der generell bei gleicher oder ähnlicher Struktur der Peripherie auf verschiedene Arten realisiert sein kann. Der Fokus dieser Arbeit liegt auf digitalen Reglern, deren Struktur in Form eines Programms festgelegt ist und deren Parameter als Variablen verändert werden können. Darüber hinaus wird jedoch auch die Optimierung von Parametern analoger Regler betrachtet, die in Form von analogen Schaltungen realisiert sind und deren Parameter durch elektrische Bauteile repräsentiert werden.

6.2.1 Digitale Regelung

Der Lageregler ist in Form eines C-Programms realisiert und wird als kompilierte Software auf einer integrierten Elektronik ausgeführt, die neben der beschriebenen Peripherie einen zentralen Prozessor umfasst. Praktisch arbeitet der Regler als digitales System in einem diskreten Takt und mit diskretisierten Signalen. Da sowohl die Ausführungszeit des Programms als auch die Auflösung der Signale ausreichend groß sind, kann der Regler zur anschaulichen Darstellung, aber auch zur Parameteroptimierung als quasi-kontinuierlich betrachtet werden. Der Regler selbst sowie die ermittelten Parameter werden vor ihrer Anwendung in ein äquivalentes Abtastsystem überführt.

Der verwendete Regler ist in seiner Grundstruktur ein nichtlinear erweiterter PID-Regler. Die Struktur des Reglers, der von der Bosch Rexroth AG entwickelt wurde, ist in dieser Arbeit als gegeben angenommen. Gegenstand der evolutionären Optimierung sind Parameter verschiedener Komponenten des Reglers. Ein Strukturbild des Reglers ist in Bild 6.4 dargestellt. Als Eingangsgrößen liegen der vorgegebene Sollwert y_{soll} sowie die gemessene Kolbenposition y_{ist} vor. Die Differenz aus beiden bildet die Regelabweichung und dient als

Eingang für den P- und den I-Zweig des Reglers. Der D-Zweig in Form der Übertragungsfunktion $G_D(s)$ verwendet direkt den Ist-Wert y_{ist} . Die Regelabweichung wird im P- und im I-Zweig jeweils nichtlinear verstärkt. Die dazu verwendete Kennlinie ist abschnittsweise linear zusammengesetzt und wird über Stützstellen definiert. Zur verstärkten Regelabweichung wird im I-Zweig zum einen der mit einem Faktor k_{ID} verstärkte Ausgang des D-Zweigs addiert. Zum anderen beeinflusst ein *Anti-Windup*-System die Verstärkung dieser Signalsumme, bevor sie integriert wird. Das *Anti-Windup*-System vergleicht am Ausgang des Reglers, ob die minimale oder maximale Grenze des zulässigen Wertebereichs für die Stellgröße erreicht ist und reduziert in diesem Fall die Verstärkung k_I im I-Zweig. Die Stellgröße i_{soll} ergibt sich als die auf ein Intervall $[i_{min}, i_{max}]$ begrenzte Summe der einzelnen Zweige des Reglers.

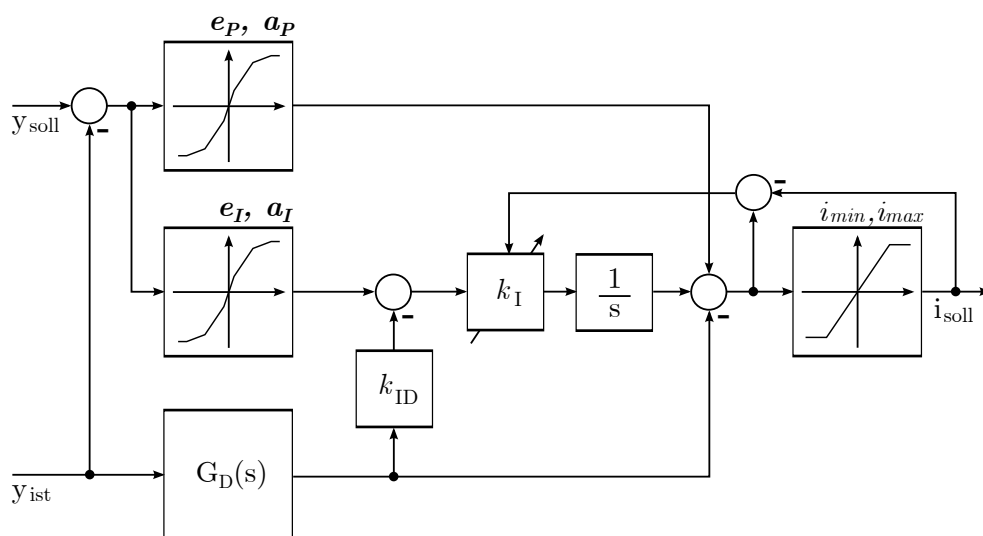


Bild 6.4: Blockschaltbild des Lagereglers

Neben den einfachen skalaren Verstärkungsfaktoren im I-Zweig verteilen sich die zu optimierenden Parameter auf die Stützstellen und Stützwerte der Verstärkungskennlinien sowie die Pol- und Nullstellen der Übertragungsfunktion im D-Zweig (siehe Gleichung 6.1).

Parametrisierung der Kennlinien

Der Anspruch der nichtlinearen Verstärkungskennlinie ist es, dem nichtlinearen Verhalten der Regelstrecke mittels verschiedener Verstärkungen für unterschiedliche Signalbereiche zu begegnen. Vereinfachend wird dabei die Regelabweichung, die die Eingangsgröße darstellt, in positiver sowie in negativer Richtung in die Kategorien Klein-, Mittel- und Großsignal eingeteilt. Daraus ergeben sich sechs Bereiche, für die eine konstante, aber jeweils eine unterschiedliche Verstärkung realisiert wird. Daraus ergibt sich die abschnittsweise lineare Struktur der Verstärkungskennlinie, die in Bild 6.5 dargestellt ist. Die linke und die rechte Seite zeigen zwei alternativ verwendete Parametrisierungen mit verschiedenen Vor- und Nachteilen, die sich eindeutig ineinander überführen lassen.




Bild 6.5: Varianten zur Parametrisierung der Verstärkungs-Kennlinien

Bei der in Bild 6.5 links gezeigten Variante sind Stützstellen und -werte als freie Parameter gewählt. Dazu kommt als Nebenbedingung, dass der Nulldurchgang im Ursprung liegt. Für Eingangswerte jenseits der minimalen und maximalen Stützpunkte wird konstant mit deren Stützwert extrapoliert, was einer oberen und unteren Begrenzung des Ausgangs entspricht. Die rechts gezeigte Variante der Parametrisierung verwendet nur Stützstellen sowie Verstärkungen oder Steigungen zwischen den definierten Stütz- beziehungsweise Knickstellen. Der Ausgangswert zwischen zwei Stützstellen ergibt sich als Summe der mit der entsprechenden Verstärkung multiplizierten Eingangsgröße und einem Offset, der sich aus der benachbarten Stützstelle ergibt. Weitere Parameter sind der minimale und der maximale Ausgangswert. Beide Varianten haben verschiedene Vorteile. Während die Verwendung von Stützpunkten eine bessere Entkopplung zwischen der Änderung einzelner Parameter und der resultierenden Änderung des Ein-/Ausgangsverhaltens gewährleistet, erlaubt die Definition von Knickstellen und Verstärkungen die einfachere Definition möglicherweise sinnvoller zusätzlicher Nebenbedingungen, beispielsweise von Minimal- oder Maximalverstärkungen.

Parametrisierung der Übertragungsfunktion

Die dynamische Charakteristik im D-Zweig wird von einer Übertragungsfunktion $G_D(s)$ bestimmt, die über ihre Pol- und Nullstellen sowie eine Verstärkung definiert ist:

$$G_D(s) = k_D \frac{(N_1 - s)s}{(P_1 - s)(P_2 - s)(P_3 - s)} \quad (6.1)$$

Der differenzierende Charakter entsteht durch eine feste Nullstelle im Ursprung, darüber hinaus bilden eine Nullstelle, drei Polstellen und die Verstärkung k_D die freien Parameter. Eine Parametrisierung von $G_D(s)$ über Pol- und Nullstellen zeigt sich als vorteilhaft gegenüber anderen möglichen Varianten wie zum Beispiel der Parametrisierung über die Koeffizienten, da sie stärker die lokalen Zusammenhänge zwischen der Änderung einzelner Parameter und der Änderung des Gesamtverhaltens erhält [16]. Diese Eigenschaft ist, wie schon gezeigt, vorteilhaft für die evolutionäre Optimierung. Für die reale Implementie-

rung in der Steuerungselektronik wird die kontinuierliche Übertragungsfunktion in diskrete Differenzgleichungen überführt.

6.3 Versuchsaufbau für die Regleroptimierung

Die meisten klassischen Ansätze zum Entwurf und zur Optimierung von Reglern sehen ein Modell der Regelstrecke als integralen Bestandteil des Prozesses vor. Abhängig vom Streckenmodell und dem verwendeten Regelungskonzept lassen sich damit analytisch oder basierend auf Simulationen ein geeigneter Regler und dessen Parameter ermitteln. Der potentielle Nachteil dieser Methode besteht im unter Umständen erheblichen Aufwand, der für die Erstellung und Identifikation eines geeigneten Modells besteht. Darüber hinaus stellt ein Modell immer eine Vereinfachung gegenüber der abgebildeten Realität dar, der Reglerentwurf und die optimierten Parameter beziehen sich entsprechend auch immer auf diese Vereinfachung. Die Übertragbarkeit des Reglers auf die reale Strecke hängt von der Qualität des Modells ab, im Allgemeinen entsteht jedoch eine Überanpassung des Reglers an das verwendete Modell und die bei der Modellierung berücksichtigten Aspekte der Strecke sowie deren äußere Einflussgrößen.

Der alternative, hier verfolgte Ansatz der *Hardware-in-the-Loop*-Optimierung (HIL) besteht darin, das Modell im Entwurfsprozess direkt durch die reale Strecke zu ersetzen. Zum einen kann dadurch die komplexe Modellierung des Hydraulikventils vermieden werden. Speziell die Anwendung von evolutionären Optimierungsverfahren und deren zuverlässige Fähigkeit zum Auffinden von Minima in großen Suchräumen resultieren in hohen Anforderungen an die Modellqualität. Modellfehler, die ein solches lokales Minimum erzeugen, führen dadurch zu einer Überanpassung des Optimierungsergebnisses an das Modell. Zum anderen vereinfacht der HIL-Ansatz die Anwendung des Optimierungsverfahrens auf verschiedene Regelstrecken. Das System erlaubt den einfachen Austausch der eingebundenen Regelstrecke gegen eine andere, wohingegen der klassische Optimierungsansatz ein neues Modell oder eine erneute Identifikation erfordern würde.

Diesen Vorteilen gegenüber steht der Realisierungsaufwand des HIL-Systems sowie ebenfalls der Aspekt der Robustheit und Stabilität der Optimierungsergebnisse, in diesem Fall jedoch resultierend aus Unsicherheiten der Umgebungs- und Einflussgrößen und nicht aus Unsicherheiten der System- beziehungsweise Modelleigenschaften. Die primäre Herausforderung bei der Umsetzung der HIL-Optimierung ist daher, die freien Parameter des Reglers für die Optimierung zugänglich zu machen und gleichzeitig die Echtzeitfähigkeit des Experiments zu gewährleisten. Eine spezielle Herausforderung stellt hierbei die vergleichsweise große Zahl der für die evolutionäre Optimierung notwendigen Fitnessbewertungen dar, die jeweils ein eigenes HIL-Experiment erfordern. Die zweite Herausforderung besteht darin, die freien Streckenparameter und die Umgebungsbedingungen im HIL-Experiment abbilden zu können sowie Störgrößen erfassen oder kontrollieren zu können.

Das Bild 6.6 zeigt einen Überblick über den gesamten Versuchsaufbau und dessen wesentliche Komponenten. Das Gesamtsystem kann in drei Bereiche gegliedert werden, die über verschiedene Größen und Signale miteinander verbunden sind. Der linke Teil des Bildes

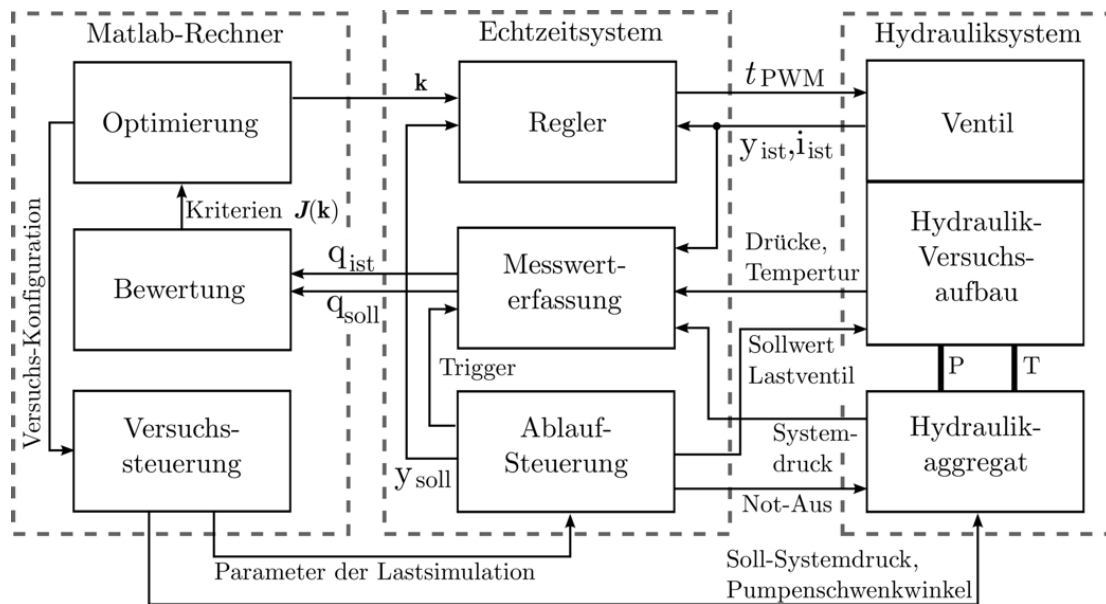


Bild 6.6: Schematische Übersicht des Versuchsaufbaus

zeigt den Matlab-Rechner, auf dem der Optimierungsalgorithmus mittels der MOEA-Toolbox (siehe Anhang C) ausgeführt wird und der für den Anwender die Schnittstelle zum Experiment oder dessen automatische Steuerung darstellt.

In der Mitte des Bildes befindet sich das im folgenden Abschnitt 6.3.1 beschriebene Echtzeitsystem, das mittels einer Glasfaser-Kommunikationsverbindung angebunden ist. Der rechte Teil des Bildes zeigt das Hydrauliksystem, detailliert beschrieben in Abschnitt 6.3.2, das aus dem Ventil selbst, dem Versuchsaufbau und einem Hydraulikaggregat besteht. Verschiedene Sensoren erfassen relevante Größen des Experiments und sind an das Echtzeitsystem angebunden, darüber hinaus besteht eine Verbindung zwischen Matlab-Rechner und Anlagensteuerung über einen Kommunikationsbus.

6.3.1 Echtzeitsimulation des digitalen Reglers

Um schnell und in großer Zahl HIL-Experimente mit variierten Parametern durchführen zu können, ist es erforderlich, dass sowohl die zu optimierenden Parameter zugänglich und zuverlässig veränderlich sind, als auch dass die relevanten Mess- und Systemgrößen mit hoher Abtastrate und ausreichender Qualität aufgezeichnet beziehungsweise erzeugt werden können. Die Verwendung eines digitalen Regelungskonzepts ermöglicht es, den Regler durch ein digitales Echtzeitsystem zu ersetzen. Die Software, die die Reglerstruktur auf der realen Reglerelektronik implementiert, wird stattdessen auf diesem Echtzeitrechner ausgeführt. Dieser bietet die Möglichkeit, Reglerparameter über definierte Schnittstellen zu ändern und die zur Bewertung erforderlichen Signale des Regelkreises aufzuzeichnen. Darüber hinaus dient der Echtzeitrechner zur Aufzeichnung und Kontrolle weiterer Systemgrößen und zur Steuerung des Ablaufs der Experimente.

6.3.2 Hydraulik-Experimentalsystem

Der Zweck des hydraulischen Versuchsaufbaus besteht darin, Störgrößen und Umgebungsbedingungen für das Hauptventil als betrachtete Regelstrecke im zu optimierenden System möglichst realistisch und reproduzierbar abbilden zu können. Die wichtigsten Komponenten sind dabei ein Hydraulikaggregat als Druckversorgung, ein Proportionalventil zur Simulation von Belastungen und die Sensorik zum Erfassen von Umgebungsgrößen. Das Bild 6.7 zeigt den Aufbau in Form eines Hydraulikschaltplanes nach DIN ISO 1219 [116]. Zur Vereinfachung wurde auf die Darstellung nicht relevanter Komponenten verzichtet, nähere Details finden sich in Anhang B.4.1.

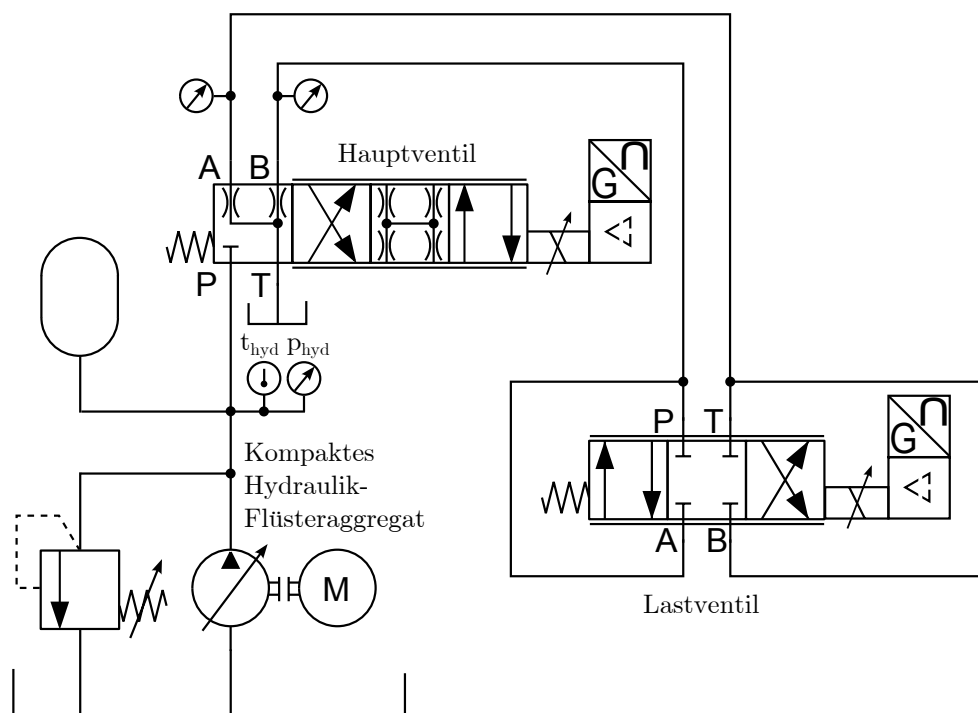


Bild 6.7: Vereinfachter Hydraulik-Schaltplan des Versuchsaufbaus

Relevante hydraulische Größen werden über Druckaufnehmer und Temperatursensoren aufgenommen, die über einen Messverstärker direkt an die Versuchssteuerung angebunden sind. Wie in Bild 6.7 dargestellt, werden Druck p_{hyd} und Öltemperatur t_{hyd} am P-Anschluss des Hauptventils sowie die Drücke an dessen Arbeitsanschlüssen A und B erfasst. Diese Sensoren lassen sich jedoch mittels flexibler Messanschlüsse auch abhängig vom durchgeführten Versuch an verschiedenen Stellen des Aufbaus platzieren.

Dem P-Anschluss des Hauptventils ist ein kleiner Druckspeicher mit 0,125 l Volumen vorgelagert, um während der Versuche auftretende Druckstöße zu mindern und so die Gefahr von Schäden am Versuchsaufbau zu reduzieren.

An den Arbeitsanschlüssen A und B des Hauptventils können statisch, mittels einer manuellen Drossel (optional und nicht abgebildet), oder dynamisch verschiedene Lastsitua-

tionen abgebildet werden. Ein weiteres Proportional-Wegeventil, dessen Anschlüsse P und A sowie B und T über eine Adapterplatte verbunden sind, funktioniert dadurch wie eine elektrisch betätigte und geregelte Drossel und verbindet die Arbeitsanschlüsse des Hauptventils. Abhängig vom vorgegebenen Sollwert q_{hyd} kann diese Verbindung ganz geschlossen oder definiert geöffnet werden. Dynamische Störgrößen können durch die Vorgabe einer Sollwertfunktion durch die Versuchssteuerung realisiert werden. Eine charakterisierende statische Volumenstrom-Kennlinie des Lastventils findet sich in Anhang B.4.1.

6.4 Bewertung und Fitnessfunktion

Die betrachtete Regleroptimierung führt zu Individuen mit einem Lösungsvektor \mathbf{k} , der sich aus den 24 in Abschnitt 6.2 definierten Parametern zusammensetzt. Bei diesen handelt es sich um Stützpunkte der Verstärkungskennlinien, Verstärkungsfaktoren und Pol- und Nullstellen einer Übertragungsfunktion. Jeder durch ein Individuum repräsentierte Regler wird durch ein HIL-Experiment im beschriebenen Versuchsaufbau erprobt. Auf Grundlage der Ergebnisse dieses Experiments wird ein Kriterienvektor $J(\mathbf{k})$ ermittelt, der das Ergebnis der Fitnessfunktion darstellt.

6.4.1 Bewertungsexperiment

Die Bewertung eines Reglers erfolgt auf Grundlage mehrerer Sprungantworten, die in einem Experiment als Ausgangsverhalten des geregelten Systems bei Vorgabe einer definierten Stimulus-Funktion als Sollwert aufgezeichnet werden. Die Stimulus-Funktion setzt sich aus mehreren konstanten Eingangswerten zusammen, die eine Folge von sprungförmigen Anregungen bilden. Die Sprünge sind so gewählt, dass verschieden große Amplituden in verschiedenen Bereichen des Arbeitsraums abgedeckt werden. Tabelle 6.1 zeigt für die Folge der Sollwerte die Arbeitsraumposition, den Zeitpunkt, zu dem dieser eingestellt wird, und die sich daraus ergebende Dauer und Amplitude des Sprungs. Die in der Tabelle beschriebene Sprungfolge ist als Sollwert beispielsweise in den Bildern 6.10 und 6.13 dargestellt.

Tabelle 6.1: Die Sprungfolge der Stimulusfunktion

Sprung #	–	1	2	3	4	5	6	7	8	9
Zeitpunkt [ms]	0	10	120	165	210	240	350	395	425	470
Dauer [ms]	10	110	45	45	30	110	45	30	45	45
Mindestlänge [ms]	10	100	30	30	25	100	30	25	35	35
Sprungamplitude [%]	–	175	-0,4	-20,6	11	-165	0,4	-2	41,6	-40
Position [%]	-85	90	89,6	69	80	-85	-84,6	-86,6	-45	-85

Für jedes Individuum werden zunächst die zu bewertenden Reglerparameter eingestellt. Danach wird für einen definierten Zeitraum das Ein-/Ausgangsverhalten des geschlossenen Regelkreises gemessen, während die Stimulus-Funktion als Sollwert vorgegeben wird. Die

Kolbenposition als Ausgangsgröße des Systems wird dazu synchron aufgezeichnet und anhand der Unstetigkeiten des Sollwerts in einzelne Sprungantworten zerlegt. Die Abweichung zwischen der in der Tabelle angegebenen Mindestlänge der Sprünge und deren tatsächlicher Dauer dient der Absicherung auswertbarer Messdaten und der Vermeidung von Synchronisierungsproblemen. Die Verlängerung der einzelnen Abschnitte garantiert die angegebene Mindestlänge der Messungen, die als Grundlage für die Bewertung dienen.

6.4.2 Kriterien und Bewertung der Sprungantworten

Bei der Bewertung der einzelnen Sprungantworten wird auf einige der in Abschnitt 5.2 vorgestellten Kriterien zurückgegriffen, die nach den in Abschnitt 5.2.3 diskutierten Überlegungen ausgewählt sind. Für jede der Sprungantworten werden die Anstiegszeit T_a und das maximale Überschwingen \ddot{U} ermittelt, um einen Kompromiss zwischen Geschwindigkeit und Genauigkeit im Anstiegsverhalten abzubilden. Hinzu kommt noch das Kriterium *ISTE*, um die Kompromissmenge um den Aspekt der stationären Genauigkeit zu erweitern und lokale Minima auszuschließen, die sich bei der ausschließlichen Verwendung der anderen Kriterien ergeben können.

Im Hinblick auf die Komplexität des Optimierungsproblems sind jedoch Kompromisse erforderlich. Wie in Abschnitt 2.2 dargestellt, kann der dominanzbasierte Selektionsmechanismus eines MOEA nicht uneingeschränkt für eine große Anzahl von Kriterien skaliert werden. Mit dem formulierten Ziel, dass die verschiedenen Sprünge alle relevanten Bereiche des Arbeitsraums abdecken, ergibt sich eine theoretische Gesamtzahl von 27 Kriterien zur Bewertung. Die Zahl ergibt sich aus der Anzahl von 9 unabhängigen Sprüngen mit jeweils 3 ermittelten Kriterien, zu viel, um sinnvoll eine Pareto-Front approximieren zu können. Der gewählte Ansatz, um die Kriterien zu reduzieren, fasst die Kriterien der einzelnen Sprungantworten zu einer gewichteten Summe für mehrere Sprünge zusammen. Für alle Sprungantworten werden jeweils die Kriterien T_a und *ISTE* zusammengefasst. Das Kriterium \ddot{U} wird für Gruppen von Sprüngen ermittelt, die nach definierten Kategorien zusammengefasst sind. Sprünge bis 20 % des Arbeitsraums werden dabei als *Kleinsignalsprünge* (KS), im Bereich zwischen 20 % und 100 % als *Mittelsignalsprünge* (MS) und Sprünge von mehr als 100 % als *Großsignalsprünge* (GS) bezeichnet. Diese Maßnahmen führen zu einer Reduktion auf fünf Kriterien, stellen aber im Bezug auf die zu erwartende Objektivität des Optimierungsergebnisses einen Kompromiss dar. Die dabei notwendigen Festlegungen von Gewichtungen und Kategorien stellen eine a priori Entscheidung auf Grundlage von Annahmen dar, die sich im Nachhinein durch das Ergebnis der Optimierung nicht mehr eindeutig belegen lassen und daher problematisch sind. Die geeignete Wahl von Gewichtungen ist daher empirisch auf der Basis von experimentellen Optimierungen validiert.

Die Normierung, Gewichtung und Zusammenfassung der Bewertung der einzelnen Sprünge führt darüber hinaus dazu, dass die resultierenden Kriterien als einheitenlose Größen betrachtet werden müssen und lediglich relativ zueinander und nicht absolut interpretiert werden können.

6.4.3 Definition von Randbedingungen und Parametergrenzen

Für sowohl die Parameter als auch die Kriterien gelten Grenzen und Bedingungen, die sich zum einen aus technischen Gründen und zum anderen aus dem gewünschten Systemverhalten ergeben. Für die Suche nach einem globalen Optimum werden die Grenzen der Parameter generell so groß wie möglich gewählt. Eine erste Einschränkung ergibt sich daher aus der technischen Begrenzung der verwendeten Variablen in der Implementierung der digitalen Reglerstruktur. Weitere Einschränkungen ergeben sich aus technischen Bedingungen. Verstärkungsfaktoren sind immer positive Werte, Polstellen der Übertragungsfunktion immer negative. Knickstellen von Kennlinien liegen innerhalb des definierten Eingangsbereichs, der durch die maximal mögliche Regelabweichung begrenzt ist.

Darüber hinaus wird der Suchraum des Algorithmus basierend auf Erfahrungen aus durchgeführten Optimierungen iterativ angepasst. Eine weitere Einschränkung der Parametergrenzen auf Bereiche, in denen Pareto-optimale Individuen zu erwarten sind, kann die Optimierung erheblich beschleunigen.

Aus berücksichtigten Nebenbedingungen ergeben sich weitere verkoppelte Einschränkungen mehrerer Parameter. Um der evolutionären Optimierung für bestimmte Parameter einen maximal großen Gültigkeitsbereich zu ermöglichen, aber gleichzeitig Mehrdeutigkeiten zu verhindern, werden gemeinsame Bedingungen für mehrere Parameter formuliert. Diese Bedingungen werden im Ablauf des Optimierungsalgorithmus nach dem Anwenden der Rekombinations- und Mutationsoperatoren durch eine Korrektur- oder Reparaturfunktion erzwungen. Für die Polstellen der Übertragungsfunktion wird durch eine Korrektur die Bedingung $P_1 > P_2 > P_3$ sichergestellt, um eine eindeutige Repräsentation der Lösung zu gewährleisten. Für die Knick- oder Stützstellen der Kennlinien gilt die Reparaturbedingung $e_1 < e_2 < \dots < e_6$, um ungültige Lösungen mit nicht eindeutigen oder nicht monotonen Kennlinien zu verhindern.

Im Bereich der Kriterien werden Nebenbedingungen definiert, die die Definition von Optimalität über die Pareto-Optimalität hinaus erweitern. Auf der Grundlage von festem, a priori bekanntem, Expertenwissen können Teile des Kriterienraumes, in dem Pareto-optimale Lösungen liegen, als nicht-optimal abgewertet werden. Diese Bereiche werden im Allgemeinen durch maximale oder minimale Werte für einzelne Kriterien definiert. Die dominanzbasierte Selektion von Individuen ist um eine zusätzliche Bestrafung von Verstößen gegen diese Grenzen erweitert.

6.4.4 Robustheit und Reproduzierbarkeit der Bewertung

Über die in Abschnitt 5.3 diskutierten Aspekte der Robustheit von Bewertungen hinaus ergibt sich aus den hier zur Bewertung verwendeten HIL-Experimenten ein weiterer. Wegen der großen Anzahl für die Optimierung erforderlicher Bewertungen stellen eine möglichst kurze Dauer einer einzelnen Ausführung der Fitnessfunktion sowie die schnelle Abfolge aller Auswertungen ohne unnötige Wartezeiten zwei zentrale Ziele der technischen Realisierung dar. Aus der schnellen wechselweisen Abfolge von Übertragung neuer Reglerparameter und Aufzeichnung des Positionssignals des angeregten Ventils ergibt sich, dass die Bewertung

eines Individuums nicht mehr unabhängig von einer anderen, vorangegangenen Bewertung betrachtet werden kann. Während des Änderns der Reglerparameter ergibt sich kurzzeitig eine undefinierte Systemkonfiguration. Diese und unter Umständen auch die Dynamik des vorher bewerteten Reglers haben Einfluss auf den Systemzustand zu Beginn der Aufzeichnung der nächsten Bewertung. Die möglichen Konsequenzen für die Bewertung werden besonders deutlich am Beispiel des Zustands der Kolbenposition. Befindet sich diese, zum Beispiel wegen einer instabilen Reglerkonfiguration in der vorangegangenen Bewertung, an einer anderen Stelle des Arbeitsraumes als durch den Stimulus vorgesehen, so verändert dies die Bedingungen für den folgenden Sprung. Die tatsächliche Sprunghöhe entspricht faktisch nicht mehr der für die Bewertung angenommenen. Das Problem tritt zwar ebenfalls innerhalb der Sprungfolge einer Bewertung auf, hier ist jedoch der Regler, der für diesen Zustand verantwortlich ist, identisch mit dem Regler, der auch bewertet wird.

In der implementierten Steuerung der Bewertungsexperimente sind Mechanismen vorgesehen, die einen definierten Anfangszustand für jede Messung herstellen sollen. Der Regelkreis wird während der Übertragung neuer Parameter aufgetrennt. Im offenen Regelkreis wird der Magnetaktuator mit einer Stellgröße gesteuert, die statisch der Position zu Beginn des Stimulus entspricht. Der Beginn der Stimulus-Funktion und damit auch die Messung der Position werden nach dem Schließen des Regelkreises mit neuen Parametern erst dann getriggert, wenn sich die Kolbenposition innerhalb eines definierten Fehlerschlauches um den Startwert befindet. Damit werden vergleichbare Anfangsbedingungen für alle Bewertungen erzwungen. Die Rückkopplung der aktuellen Kolbenposition erlaubt im Vergleich mit einer konstant verzögerten Ausführung der nächsten Messung eine Reduktion der Ausführungszeit bei unproblematischen Konfigurationen. Im anderen Extremfall, wenn eine Reglerkonfiguration instabil oder nicht in der Lage ist, den Startwert des Stimulus zu erreichen, wird der Trigger der Messung nach einer definierten maximalen Wartezeit ausgelöst. In diesem Fall ist zwar die Bewertung nicht reproduzierbar, im Falle eines instabilen Reglers sind die verwendeten Kriterien für Sprungantworten jedoch generell nicht in der Lage, den Regler differenziert zu bewerten, sondern bestrafen lediglich die instabile Lösung durch hohe Werte aller Kriterien. Für die Optimierung ist dies ausreichend, da eine differenzierte Vergleichbarkeit für Lösungen mit schlechter Fitness nicht erforderlich ist. Dies gilt nur unter der Voraussetzung, dass nicht alle Individuen nicht bewertbar sind und dadurch ein ausreichender Teil der aktuellen Population für die Selektion vergleichbar ist.

6.4.5 Interaktionsschnittstelle

Als Grundlage für eine Entscheidung im Prozess der interaktiven Optimierung (I-MOEA) dient, wie in Abschnitt 3.4.1 eingeführt, eine Schnittstelle, die dem Anwender Lösungsalternativen visualisiert und ihm die Möglichkeit zur Artikulation seiner Präferenz bietet. Die Visualisierung ist im Detail grundsätzlich problemspezifisch gestaltet. Für die Optimierung der Hydraulikventilregler wird dem Anwender die Sequenz der Sprungantworten beider Lösungen zum Vergleich vorgelegt. Da sich die Bewertung aller Aspekte des komplexen Problems auf Grundlage nur dieser Abbildung als schwierig gestaltet, wird die Darstellung durch weitere Informationen ergänzt. Das Bild 6.8 zeigt die verwendete Schnittstelle. Die

Sprungantworten werden durch eine tabellarische Darstellung der Kriterien für die einzelnen Sprungantworten ergänzt. Diese finden sich nicht einzeln, sondern nur in Form einer gewichteten Summe in den tatsächlichen Optimierungskriterien wieder. Sie stellen daher eine zusätzliche Information zur Bewertung der Lösungen dar. Da die Sprungsequenz sehr unterschiedliche Amplitudenbereiche umfasst, ist eine Inspektion aller Sprünge in einer einheitlichen Darstellung schwer möglich. Unterstützt wird der Entscheider daher von einem Vergrößerungswerkzeug, das eine Detailansicht von Ausschnitten ermöglicht. In einem zusätzlichen Fenster werden Eigenschaften der Parameter der betrachteten Individuen visualisiert. Die Darstellung zeigt die Verstärkungskennlinien, die Pol- und Nullstellen sowie die einzelnen Verstärkungsfaktoren. Sie ermöglicht es, Präferenzen auszudrücken, die nicht im Kriterien- sondern im Parameterraum begründet sind. Optional ermöglicht die Darstellung einen überlagerten Vergleich mit einer ausgewählten Referenzlösung. Die Eingabekomponenten der Schnittstelle bieten die in Abschnitt 3.4.1 vorgestellten Möglichkeiten zur Artikulation der Präferenzen und den Zugriff auf weitere technische Optionen zur Steuerung der Optimierung.




Bild 6.8: Interaktionsschnittstelle zur Ventillageroptimierung

6.5 Optimierungsergebnisse

Für das im Vorangegangenen beschriebene Optimierungsproblem wird die Pareto-Front approximiert und die Reproduzierbarkeit anhand einer mehrfachen Wiederholung der Optimierung belegt. Dem gegenübergestellt wird das Ergebnis der interaktiven Optimierung, bei der zum einen ein künstlicher Referenzpunkt einen reproduzierbaren Vergleich ermöglicht, zum anderen ein realer Experte seine Präferenzen anwendet. Die Ergebnisse der Optimierungen werden gegenübergestellt und verglichen, um sowohl eine quantitative Aussage über die durch die interaktive Optimierung erzielte Beschleunigung als auch eine qualitative Aussage über die erzielten Ergebnisse zu erreichen.

Ausgewählte Ergebnisse werden hinsichtlich ihrer Robustheit gegenüber Variationen der Umgebungsbedingungen analysiert. Darüber hinaus wird untersucht, inwiefern die Berücksichtigung veränderlicher Umgebungsbedingungen während der Optimierung die Robustheit der Ergebnisse beeinflusst.

6.5.1 Multikriterielle Optimierung

Die multikriterielle Optimierung wird durchgeführt über 100 Generationen mit einer Population von $\mu = \lambda = 100$ Individuen. Dabei wird NSGA-II als MOEA ohne Berücksichtigung von Präferenzen eingesetzt, mit dem Ziel, die vollständige Pareto-Front zu approximieren. Details zur Konfiguration des Algorithmus finden sich in Anhang D.2, die Betriebsbedingungen sind drucklos mit blockierten Arbeitsanschlüssen gewählt, die Temperatur des Aufbaus entspricht etwa 40°C. Die Optimierung erzeugt eine fünf-dimensionale Pareto-Front, deren Projektionen auf alle Paare von je zwei der Kriterien in Bild 6.9 gezeigt ist. Die an den Achsen aufgetragenen Kriterien müssen wie in Abschnitt 6.4.2 erläutert als einheitenlos betrachtet werden. Die unterschiedlichen kleinen Symbole aller gezeigten Lösungen dienen dazu, die Zuordnung zwischen den einzelnen Projektionen zu erleichtern. Eine Lösung ist in allen Projektionen durch das gleiche Symbol dargestellt. Alle Lösungen stellen optimale Kompromisse hinsichtlich der verwendeten Kriterien dar, viele der Individuen sind jedoch keine akzeptablen Lösungen für die tatsächliche Applikation als Regler. Lediglich eine Untermenge der Pareto-Front entspricht den Vorstellungen oder Präferenzen eines Anwenders.

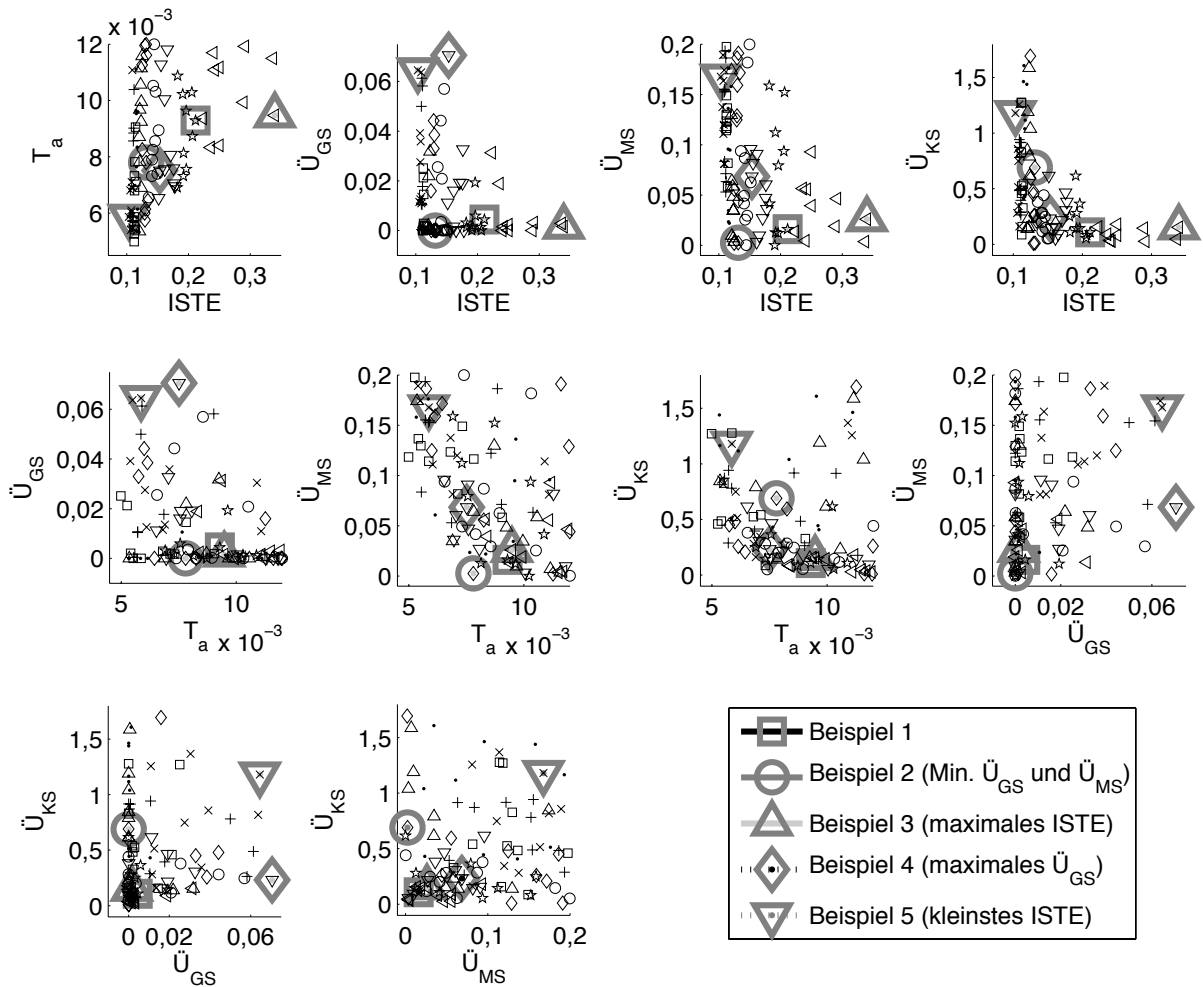


Bild 6.9: Approximierte Pareto-Front / Ergebnismenge der Ventilregleroptimierung mit NSGA-II

Um die Reproduzierbarkeit dieser Ergebnismenge zu charakterisieren, findet sich ein tabellarischer Vergleich mehrerer Optimierungen in Anhang B.1.

Eine repräsentative Auswahl von Individuen ist mit größeren grauen Symbolen in jeder Projektion markiert, sie stellen eine subjektive Auswahl oder Extremwerte in einzelnen Kriterien dar. Die in der Legende dokumentierten Symbole für unterschiedliche Beispiellösungen markieren in jeder Projektion den Punkt, der diesem Beispiel entspricht. So findet man das *Beispiel 3* in der Projektion oben links ungefähr an der Stelle $T_a \approx 0,0095$ und $ISTE \approx 0,35$ auf der rechten Seite des Bildes. Die gleiche Lösung findet man in der zweiten Projektion an der Stelle $\ddot{U}_{GS} \approx 0$ bei gleichem $ISTE$ in der rechten unteren Ecke des Koordinatensystems, in der unteren linken Projektion auf \ddot{U}_{GS} und \ddot{U}_{KS} findet man die entsprechend markierte Lösung in der Nähe des Koordinatensystemursprungs. Die Sprun-

antworten des geregelten Ventils für alle fünf so markierten Lösungen sind in Bild 6.10 gezeigt. Ziel der Darstellung dieser unterschiedlichen Beispiele ist es, einen Eindruck von der Diversität und Bandbreite der Unterschiede innerhalb der Menge nicht-dominierter Lösungen zu vermitteln.




Bild 6.10: Vergleich der beispielhaft ausgewählten Sprungantworten aus der Ergebnismenge der multikriteriellen Optimierung des Ventilreglers

6.5.2 Interaktive Optimierung mit Entscheidungsmodell

Aus einem bekannten optimierten Individuum wird durch eine Verschiebung in Richtung Minimum aller Kriterien ein künstlicher Referenzpunkt erzeugt. Dieser liegt durch die Verschiebung im nicht-erreichbaren Teil des Lösungsraums und dient als Grundlage für das in Abschnitt 4.1.1 beschriebene Entscheidungsmodell. Die Ergebnisse von Optimierungen mit simulierter Interaktion unterschiedlicher Intensität, deren Konfiguration im Anhang D.3 festgehalten ist, werden analysiert.

Untersucht wurden unterschiedliche Interaktionsraten r_i , lediglich die Ergebnisse mit $r_i = 2$, also zwei Entscheidungen in jeder Generation, werden hier analysiert, Ergebnisse für $r_i = 0,5$ und $r_i = 0,25$ finden sich in Anhang B.2.

In Bild 6.11 ist der Verlauf der interaktiven Optimierung als Entwicklung der Population im Kriterienraum dargestellt. Für alle möglichen Projektionen auf Kriterienpaare sind die Individuen als Punkte dargestellt, deren Graustufe der jeweiligen Generation entspricht. Im Verlauf der Optimierung werden die Individuen immer dunkler dargestellt. Man erkennt

deutlich die zunehmende Fokussierung auf den als helles Kreuz eingezeichneten Referenzpunkt. Die Verwendung eines einzelnen eindeutigen Referenzpunkts führt dazu, dass für die simulierte Interaktion zwei Lösungen immer vergleichbar sind und daher eine eindeutige Präferenz ermittelt werden kann.




Bild 6.11: Entwicklung der Population im Kriterienraum über den Verlauf der interaktiven Optimierung eines Hydraulikventilreglers

In Bild 6.12 ist diese Fokussierung im Kriterienraum während der Optimierung deutlich zu erkennen. Hier sind Minimal- sowie Maximalwerte für alle Kriterien der Population über die Generationen aufgetragen, gezeigt sind jeweils die Mittelwerte auf Grundlage von je drei wiederholten Optimierungen. Die schwarzen Linien markieren die entsprechenden Werte für die interaktive Optimierung (I-MOEA), die grauen Linien für die dominanzbasierte Optimierung (MOEA) mit NSGA-II. Die gestrichelte Linie zeigt die Lage des verwendeten Referenzpunkts. Für die Kriterien $ISTE$ und T_a ist deutlich erkennbar, dass die Minimal- und Maximalwerte der interaktiven Optimierung deutlich dichter am Referenzpunkt liegen als für den MOEA und dass der Referenzwert innerhalb des Intervalls dieser Werte liegt.

Im Fall von \ddot{U}_{GS} liegt der Referenzpunkt nicht zwischen beiden Werten, was darauf zurückzuführen ist, dass der Referenzpunkt unerreichbar vor der Pareto-Front liegt. Der Bereich mit dem minimalen euklidischen Abstand umschließt auf ein einzelnes Kriterium bezogen in diesem Fall nicht notwendigerweise den Referenzpunkt.

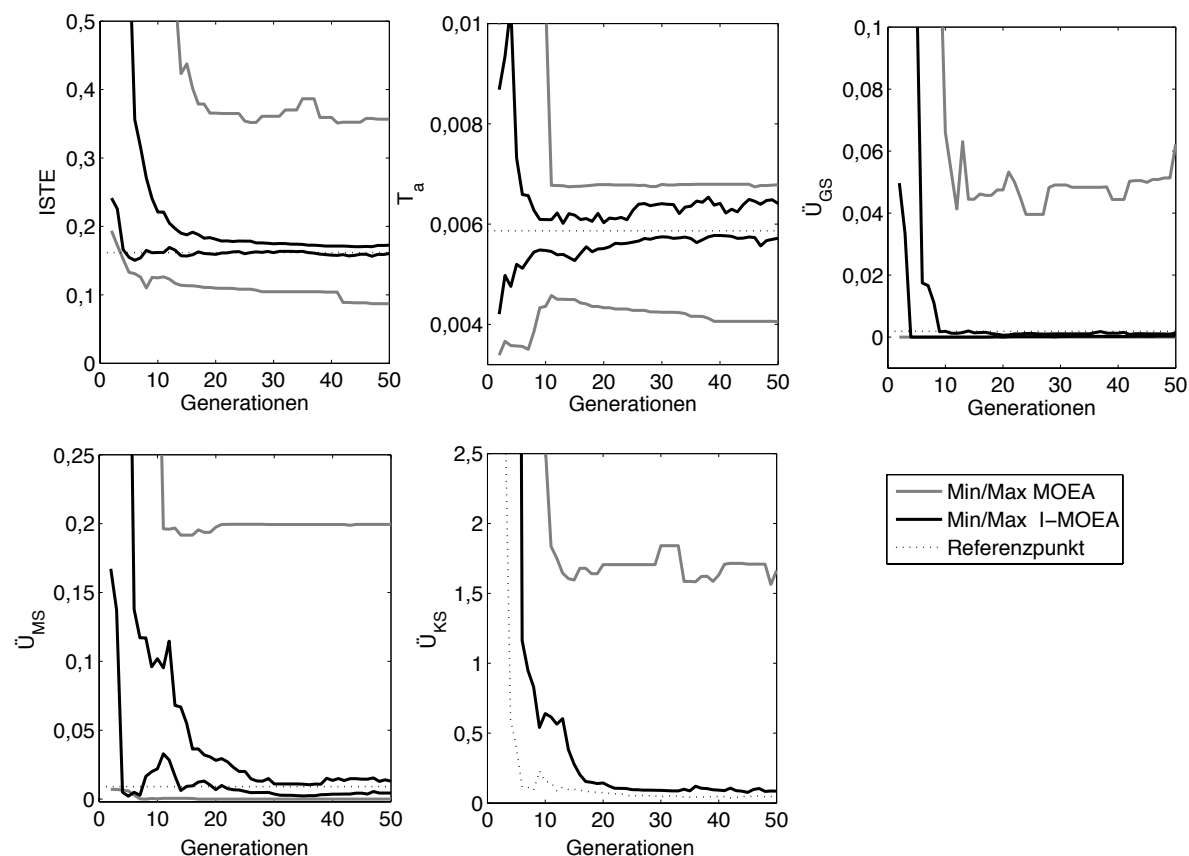


Bild 6.12: Vergleich der Verläufe von Minimal- und Maximalwerten der Kriterien für einen MOEA und eine interaktive Optimierung eines Hydraulikventilreglers

Das Bild 6.13 zeigt den Vergleich der Sprungantworten der als Referenzpunkt verwendeten und einer während der Optimierung gefundenen Lösung mit der stärksten Präferenz. Die im Bild integrierten Tabellen dokumentieren die für die einzelnen Sprünge ermittelten Bewertungskriterien, die die Grundlage für die Optimierungskriterien bilden. Der Vergleich zeigt, dass der Referenzpunkt und das Ergebnis prinzipiell miteinander vergleichbare Lösungen darstellen. In der Detailbetrachtung der Tabellen übertrifft das Ergebnis des I-MOEA für die meisten Sprünge die Referenzlösung, diese ist lediglich für die kleinsten Sprungamplituden in den Sprüngen 2 und 6 besser. Das Ergebnis belegt exemplarisch die Fähigkeit der interaktiven Optimierung, auf eine präferierte Region des Lösungsraums zu fokussieren, um dort verstärkt Detailspekte der Lösung entwickeln zu können.




Bild 6.13: Vergleich der Sprungantworten der als Referenz verwendeten Lösung und eines ausgewählten Ergebnisses der interaktiven Optimierung

6.5.3 Interaktive Optimierung mit realer Bewertung

Die Optimierung mit realer Interaktion ist aufgrund der intuitiven Bewertung und theoretisch unbekannter realer Präferenzen des Entscheiders schwer zu bewerten. Eine hier exemplarisch dokumentiert real bewertete Optimierung, durchgeführt ebenfalls mit der in Anhang D.3 dokumentierten Konfiguration und einer Interaktionsrate von $r_i = 0,5$, verwendet als Orientierung oder Leitbild für die getroffenen Entscheidungen die Sprungantwort aus Bild 6.13. Bild 6.14 zeigt analog zu Bild 6.12 die Entwicklung und Fokussierung der Kriterien im Verlauf der Optimierung im Vergleich zur dominanzbasierten Selektion.

Qualitativ ist der Verlauf der Minima und Maxima vergleichbar mit dem durch die künstlich simulierte Interaktion erzielten Ergebnis. Auch die Sprungantworten der ermittelten Ergebnismenge sind mit denen der simulierten Interaktion vergleichbar, die Fokussierung ist im Vergleich jedoch nicht so deutlich ausgeprägt. Die Hauptunterschiede begründen sich zum einen in der Möglichkeit, Lösungen als nicht-vergleichbar zu klassifizieren. Die Wahl dieser Option bei der Bewertung führt zu einer größeren Bandbreite selektierter Lösungen und kann unter Umständen, wie zwischen Generation 30 und 40 sichtbar, auch nachträglich wieder zu einer Verbreiterung des präferierten Bereichs führen. Wird in einer Region erstmals eine Lösung als nicht-vergleichbar den Modellinstanzen hinzugefügt, so werden ähnliche Lösungen mit ursprünglich schwacher Präferenz nun in einem anderen, potentiell

lokalen Kontext bewertet und somit eher selektiert. Darüber hinaus kann der menschliche Entscheider Präferenzen nie so eindeutig ermitteln und ausdrücken wie die Simulation und erzeugt damit zwangsläufig intransitive Bewertungen, die ebenfalls zu einer weicheren Fokussierung führen.

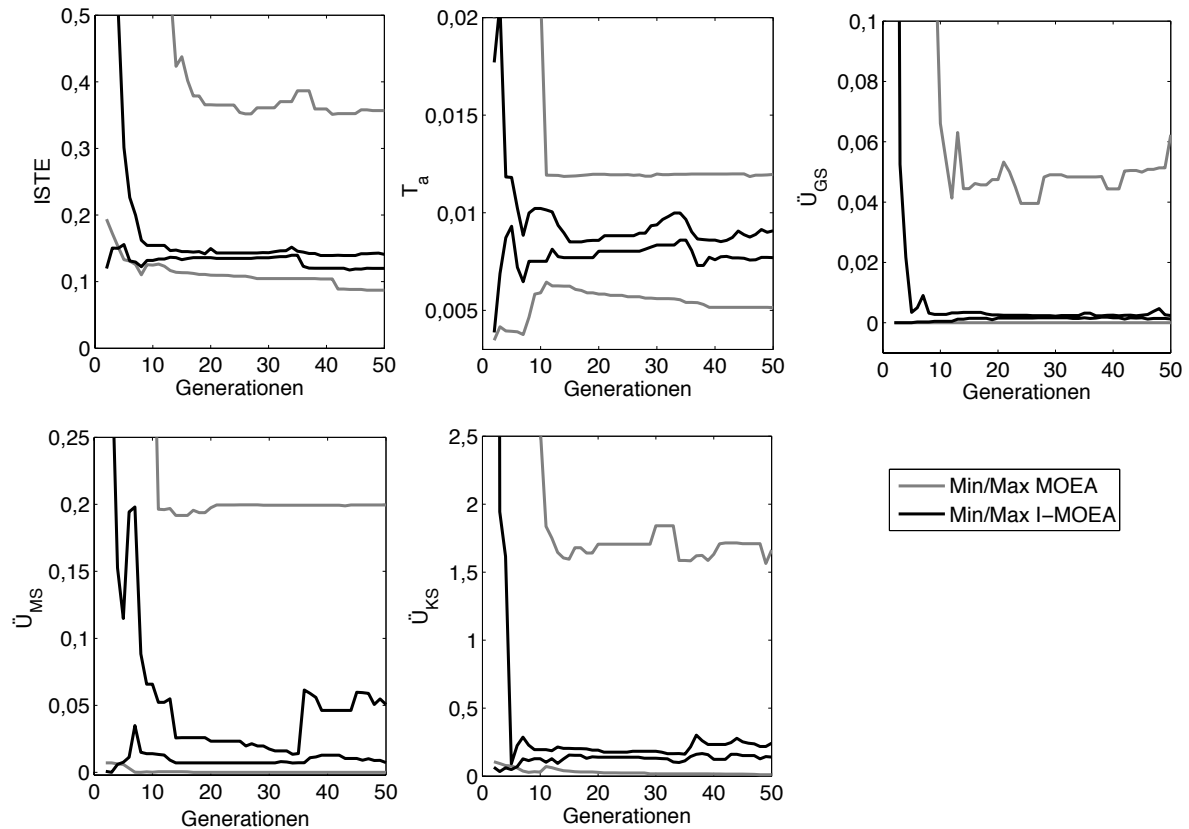


Bild 6.14: Vergleich der Verläufe von Minimal- und Maximalwerten der Kriterien für einen MOEA und eine real bewertete interaktive Optimierung eines Hydraulikventilreglers

6.5.4 Praktische Umsetzung realer interaktiver Optimierung

Über die in Abschnitt 6.5.3 dargestellte Anwendung der Methode der interaktiven Optimierung hinaus ist das Verfahren von mehreren unterschiedlichen Anwendern für die Optimierung von Ventillagereglern erfolgreich eingesetzt worden. Das Spektrum der Erfahrungen der Anwender erstreckt sich dabei von unterschiedlichen Experten für Ventilregler über Experten für Optimierungsalgorithmen bis hin zu technisch ausgebildeten, aber unerfahrenen Anwendern. Der objektive Erfolg ist dabei nur schwer einzuschätzen, da die konkreten Präferenzen, also die Vorstellungen der Anwender von einer guten Lösung, nicht bekannt sind. Darüber hinaus muss der Einsatz des I-MOEA, wie in Abschnitt 1.3 erläutert, als

Teil eines iterativen Prozesses betrachtet werden, dessen Ergebnis im konkreten Anwendungsfall nicht isoliert betrachtet werden kann. Es zeigt sich jedoch, dass Expertenwissen hinsichtlich kritischer Aspekte der Lösung und deren Zusammenhänge dabei hilft, bei der interaktiven Optimierung aus der großen Zahl als Grundlage zur Bewertung angebotener Informationen auszuwählen.

Der Einsatz des entwickelten I-MOEA erlaubt es, innerhalb einiger Stunden HIL-Optimierungsergebnisse zu erzielen, die ohne dessen Einsatz nach mehreren Tagen erzielt werden konnten. Aus dieser experimentellen Erprobung der Methode sind Aspekte der technischen Realisierung der Interaktion abgeleitet. Dies betrifft in erster Linie die tatsächliche Belastung des Anwenders durch Entscheidungen, die tatsächlich nicht wie vereinfacht angenommen als proportional zur Anzahl gestellter Fragen betrachtet werden kann. Die lange Dauer der HIL-Optimierung motiviert Möglichkeiten, in den Optimierungsprozess einzugreifen, um manuell einzelne fehlerhafte Entscheidungen rückgängig zu machen oder um eine begonnene Optimierung unbeaufsichtigt und ohne Interaktion fortzusetzen.

6.5.5 Untersuchung der Robustheit von Lösungen

Für die praktische Anwendung optimierter Reglerkonfigurationen stellt sich die entscheidende Frage, ob oder in welchem Maß das in der Optimierung erzielte Verhalten auch in der Praxis und unter realen Betriebsbedingungen reproduzierbar ist. Der automatisierte Hydraulikprüfstand eröffnet die Möglichkeit zur systematischen Untersuchung von Reglerkonfigurationen bei verschiedenen Betriebsbedingungen. Eine repräsentative Auswahl von Ergebnissen der Optimierung aus Abschnitt 6.5.1 wird bei verschiedenen Konfigurationen von zwei Parametern der Betriebsbedingungen untersucht. Betrachtet wird eine Variation des Betriebsdrucks p_{hyd} und des Ölflusses zwischen den Arbeitsanschlüssen A und B, charakterisiert durch die Öffnung q_{hyd} des Störventils. Konkret betrachtet werden die in Tabelle 6.2 dargestellten Kombinationen dieser beiden Parameter. Für fünf Reglerkonfi-

Tabelle 6.2: Bei der Robustheits-Analyse verwendete Konfigurationen der Betriebsbedingungen

Konfiguration #	1	2	3	4	5
p_{hyd} in bar	0	100	100	200	200
q_{hyd} in %	0	0	100	0	100

gurationen, die bereits in Bild 6.9 ausgewählt und in Bild 6.10 dargestellt sind, wird die Bewertung unter allen Betriebsbedingungen je 50 mal wiederholt durchgeführt, um sowohl die Robustheit gegenüber Änderungen der hydraulischen Größen als auch die Unterschiede in der Robustheit bei verschiedenen Konfigurationen zu ermitteln. Das Bild 6.15 visualisiert einen Teil der so gewonnenen Daten im Kriterienraum. Die Symbole entsprechen dabei den Beispiellösungen, die Färbung bezeichnet die verschiedenen Betriebsbedingungen. Aus allen betrachteten Konfigurationen von Druck und Durchfluss sind nur die jeweiligen Extremwerte dargestellt, die schwarz gefüllten Symbole markieren die durchschnittliche

Bewertung, die ein Individuum bei $p_{hyd} = 0$ bar und $q_{hyd} = 0\%$, also den Bedingungen, die auch bei der Optimierung herrschten, erzielt. Die grau gefüllten Symbole zeigen die Mittelwerte der Bewertungen bei einem Druck von $p_{hyd} = 200$ bar und geschlossenem Störventil $q_{hyd} = 0\%$. Die weiß gefüllten Symbole kennzeichnen die Ergebnisse für $p_{hyd} = 200$ bar und $q_{hyd} = 100\%$, also den maximalen Durchfluss und die entsprechend zu erwartenden Strömungskräfte, die auf den Ventilkolben wirken.

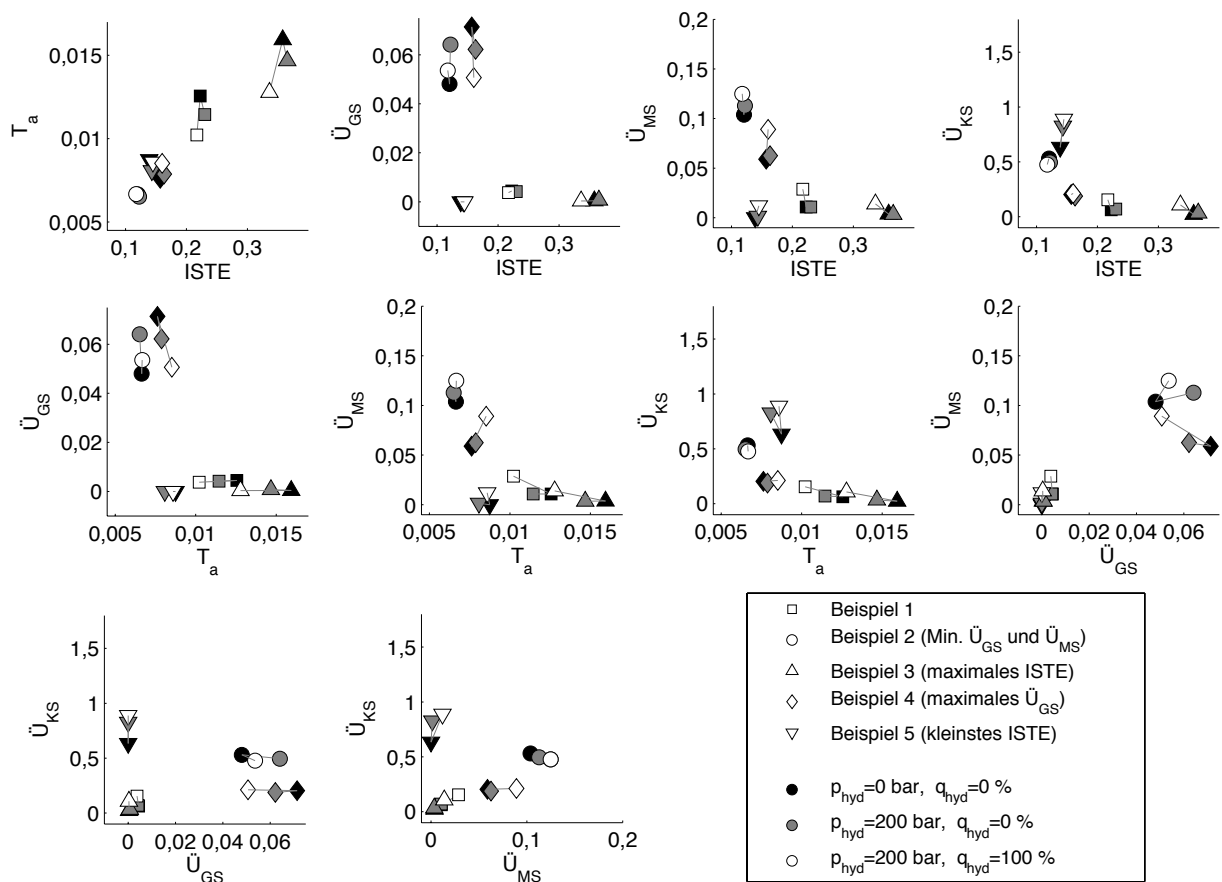


Bild 6.15: Einfluss veränderter Betriebsbedingungen auf die Bewertung ausgewählter Beispielindividuen

Die Darstellung erlaubt die Beurteilung der Robustheit einzelner Lösungen gegenüber Veränderungen der Betriebsbedingungen. Anordnung und Abstand der Symbole für ein Individuum geben Aufschluss darüber, hinsichtlich welcher Kriterien mehr oder weniger Veränderungen auftreten. Dabei wird deutlich, dass auch die Robustheit keine absolute Eigenschaft

ist, sondern ein zusätzlicher Aspekt der Kompromissbildung oder Bewertung durch den Anwender. Unter den hier betrachteten Lösungen befindet sich keine, die als absolut robuster als andere gelten kann, deren gemittelte Bewertungen also in allen Projektionen dicht beieinander liegen. Sehr wohl zeigt sich aber die unterschiedliche Robustheit von Lösungen jeweils hinsichtlich verschiedener Kriterien. Beispielhaft herausgestellt an den Beispiellösungen 1 und 3 erkennt man einen großen Einfluss der Bedingungen auf das T_a , der bei allen anderen Lösungen deutlich kleiner ausfällt. Diese beiden Lösungen zeigen jedoch, gemeinsam mit Beispiel 5, im Hinblick auf \dot{U}_{GS} kaum einen Einfluss, ganz im Gegensatz zu 2 und 4. Am selben Beispiel ist auch erkennbar, dass die Ähnlichkeit von Individuen im Kriterienraum nicht in jedem Fall einen Rückschluss auf ein ähnliches Verhalten hinsichtlich der Robustheit ermöglicht. Während für die benachbarten Beispiele 1 und 3 auch die relative Anordnung der Ergebnisse verschiedener Bedingungen zueinander ähnlich ist, stellen sich bei 2 und 4 trotz ähnlicher Lage im Kriterienraum und im Betrag ähnlicher Veränderungen durch verschiedene Bedingungen entgegengesetzte Richtungen dieser Veränderungen ein. Aus den Untersuchungen lassen sich also keine Aussagen über den allgemeinen Einfluss von Änderungen der Betriebsparameter oder die globale Robustheit einer Ergebnismenge ableiten. Die Analyse erzeugt zusätzliche Informationen, die dem Anwender oder Entscheider zur Bewertung und Auswahl einer geeigneten Lösung zur Verfügung stehen. Die ermittelten lokalen Zusammenhänge zwischen Betriebsparametern und Bewertung einer Lösung können dazu dienen, Aspekte von Robustheit bereits in der Optimierung zu berücksichtigen (vgl. Abschnitt 6.6), müssen aber individuell im Kontext der angestrebten Eigenschaften der optimierten Lösungen bewertet werden.

Eine weitere Ebene der Betrachtung der Robustheit ist der Einfluss von Betriebsbedingungen nicht auf die absoluten oder mittleren Werte der Kriterien für ein Individuum, sondern deren Einfluss auf die Sensitivität der Bewertung gegenüber Störungen oder stochastischen Einflüssen. Hierzu wird die Verteilung von 50 Bewertungen bei jeder Konfiguration der Betriebsparameter analysiert, um einen Aufschluss darüber zu erhalten, ob die Reproduzierbarkeit einer Lösung von diesen Parametern abhängt.

In Bild 6.16 sind Mittelwerte und Standardabweichungen exemplarisch für eine einzelne Lösung (Beispiel 1) jeweils als Verteilungen für die betrachteten Experimente in den Projektionen des Kriterienraums dargestellt. Die Tabelle 6.3 zeigt die Auswertung der Experimente für dieses Beispiel in Form von Mittelwert, Standardabweichung und Minimal- sowie Maximalwert für alle Bewertungskriterien bei den verschiedenen Konfigurationen.

In Bild 6.16 sind in den bekannten Projektionen des Kriterienraums die Mittelwerte der Bewertungen bei einer Konfiguration dargestellt und ergänzt um Ellipsen, deren Radien den Standardabweichungen der Bewertungen in dieser Konfiguration entsprechen. Die Länge der Halbachsen der Ellipsen geben den Einfluss einer Veränderung der Betriebskonfiguration auf die Reproduzierbarkeit der Bewertungen für die Kriterien dieser Projektion an. Die Darstellung zeigt einerseits, dass sich kein allgemeiner Zusammenhang zwischen der Standardabweichung und der Betriebskonfiguration herstellen lässt. Andererseits stellt auch diese Analyse dem Anwender zusätzliche Informationen zur Verfügung, die er bei der individuellen Beurteilung einer Lösung berücksichtigen kann, entweder im direkten Vergleich von Lösungskandidaten oder aber in der Beurteilung, ob eine Lösung definierten

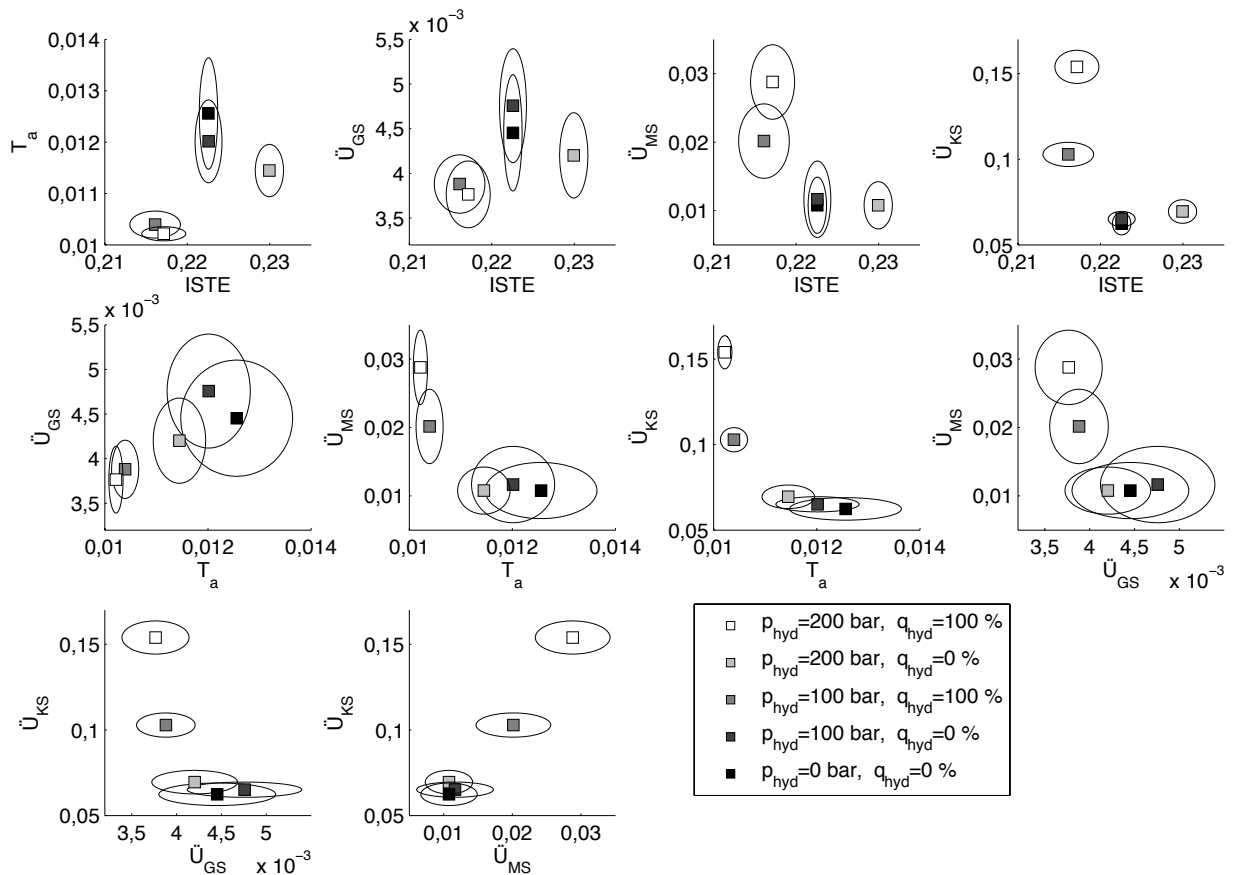


Bild 6.16: Verteilung der Ergebnisse von jeweils 50 wiederholten Bewertungen einer Lösung bei verschiedenen Betriebsbedingungen

Mindestanforderungen genügt. Für die exemplarisch betrachtete Lösung lassen sich schwache Zusammenhänge ablesen, die zum Beispiel für T_a oder \ddot{U}_{GS} auf eine Reduktion der Streuung der Bewertungen für Konfigurationen mit offener Drossel $q_{hyd} = 100 \%$ hindeuten. Die entsprechenden Daten für die übrigen in Bild 6.15 dargestellten Lösungen finden sich in Anhang B.3.

6.6 Robuste HIL-Optimierung

Ein Ansatz, um die Robustheit der optimierten Lösungen zu verbessern, besteht darin, die angestrebten oder zu erwartenden Betriebsbedingungen bereits bei der Optimierung zu berücksichtigen. Sind die Bedingungen der angestrebten Anwendung bereits a priori bekannt, so kann das für die Bewertung im Rahmen der Fitnessfunktion berücksichtigt werden, indem diese unter den angestrebten Bedingungen durchgeführt wird. Das Ergebnis ist, wie

Tabelle 6.3: Für Beispiel-Ergebnis 1: Mittelwert, Standardabweichung, Minimum und Maximum für alle Optimierungskriterien bei verschiedenen Konfigurationen der Versuchsbedingungen

		$p_{hyd} = 0,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 100$	$p_{hyd} = 200,$ $q_{hyd} = 0$	$p_{hyd} = 200,$ $q_{hyd} = 100$
<i>ISTE</i>	\emptyset	0,22257	0,22257	0,21610	0,22995	0,21715
	σ	0,00111	0,00163	0,00307	0,00171	0,00267
	<i>min</i>	0,21907	0,21689	0,20805	0,22300	0,20864
	<i>max</i>	0,22475	0,22615	0,22045	0,23266	0,22074
<i>T_a</i>	\emptyset	0,01256	0,01201	0,01039	0,01145	0,01022
	σ	0,00108	0,00081	0,00026	0,00051	0,00014
	<i>min</i>	0,00991	0,00948	0,00984	0,01003	0,00992
	<i>max</i>	0,01361	0,01321	0,01096	0,01253	0,01056
<i>Ü_{GS}</i>	\emptyset	0,00445	0,00476	0,00388	0,00420	0,00377
	σ	0,00065	0,00064	0,00033	0,00048	0,00037
	<i>min</i>	0,00342	0,00335	0,00297	0,00302	0,00277
	<i>max</i>	0,00564	0,00570	0,00450	0,00504	0,00444
<i>Ü_{MS}</i>	\emptyset	0,01079	0,01166	0,02015	0,01077	0,02878
	σ	0,00410	0,00557	0,00543	0,00344	0,00543
	<i>min</i>	0,00482	0,00489	0,01386	0,00737	0,01945
	<i>max</i>	0,02431	0,02847	0,03478	0,02196	0,04154
<i>Ü_{KS}</i>	\emptyset	0,06241	0,06511	0,10283	0,06948	0,15395
	σ	0,00657	0,00444	0,00707	0,00688	0,00968
	<i>min</i>	0,05153	0,05467	0,08607	0,05850	0,13747
	<i>max</i>	0,08895	0,07725	0,11631	0,08831	0,17782

in Abschnitt 6.5.1 bis 6.5.3 gezeigt, eine Menge optimaler Lösungen für jeweils diese Bedingungen. Diese Lösungen sind aber gegenüber Änderungen dieser Betriebsbedingungen generell nicht robuster als in Abschnitt 6.5.5 ermittelt. Wie dort gezeigt, ist der Einfluss von sich ändernden Parametern der Betriebsbedingungen sehr unterschiedlich für verschiedene lokale Lösungen und die verschiedenen betrachteten Kriterien. Darüber hinaus sind die betrachteten Größen keine diskreten Konfigurationen, die isoliert zu betrachtende Szenarien erzeugen, sondern stellen ein Kontinuum dar, das eine vollständige Berücksichtigung aller potentiellen Konfigurationen unmöglich macht.

Der hier verfolgte Ansatz zur robusten Optimierung sieht vor, einzelne potentiell kritische Konfigurationen zu identifizieren und zur Bewertung von Lösungskandidaten zu verwenden. Dem liegt die Annahme zu Grunde, dass sich zwischen den Bewertungskriterien und den Parametern der Betriebsbedingungen zumindest näherungsweise ein monotoner Zusammenhang ergibt, der durch Experimente an diskreten Punkten in diesem Konfigura-

tionsraum angenähert werden kann. Die für die Selektion verwendeten Kriterien ergeben sich dann aus den geeignet verarbeiteten Ergebnissen von mehreren einzelnen solcher Experimente.

6.6.1 Optimierung mit Bewertung bei variierten Betriebsbedingungen

Um auf Grundlage mehrerer Bewertungen einer Lösung bei unterschiedlichen Bedingungen Kriterien zu definieren, die zur Selektion robuster Lösungen führen, gibt es verschiedene mögliche Ansätze. Diese sind in erster Linie bestimmt durch die Erwartungen, die an die optimierte Lösung gestellt werden, und die zu erwartenden Bedingungen, unter denen diese Erwartungen erfüllt werden müssen. Im Allgemeinen stellt die Robustheit einer Lösung ein zusätzliches Kriterium dar, das potentiell in Konflikt steht mit den primären Kriterien, die die Qualität der Lösung beschreiben (vgl. Abschnitt 5.3). Idealerweise entstehen daher auf Grundlage mehrerer Bewertungen neue Kriterien, die die angestrebte Approximation der Pareto-Menge um diesen Aspekt erweitern und so eine objektive a posteriori Entscheidung erlauben. Dazu kann beispielsweise aus mehreren Bewertungen eine Standardabweichung oder ein anderes Maß der Variation ermittelt werden, das als Beschreibung der Robustheit geeignet ist.

Aus praktischen Gesichtspunkten sprechen verschiedene Gründe gegen diese Methode. Zum einen erfordert die Berechnung einer Standardabweichung eine ausreichend große Stichprobe, die einen stark vergrößerten experimentellen Aufwand zur Folge haben kann. Speziell bei einem Prozess wie dem hier betrachteten, bei dem neben den kontrollierten Parametern der Betriebsbedingungen weitere stochastische Größen die Bewertung beeinflussen, ist eine große Zahl von Bewertungen erforderlich, um diese unterschiedlichen Einflüsse eindeutig trennen zu können. Zum anderen führt die Berücksichtigung der Robustheit jedes Kriteriums zu einer starken Vergrößerung der Dimension des Kriterienraums, was die bekannten Probleme für die Konvergenz und Laufzeit der Optimierung nach sich zieht.

In vielen Anwendungsfällen ist die Berücksichtigung von Robustheit als Dimension der Kompromissmenge schon daher nicht notwendig, da sich eindeutige Nebenbedingungen als Mindestanforderungen formulieren lassen, die direkt in die Optimierungskriterien einfließen können. Je nachdem ob für die angestrebten Anwendungen die Betriebsbedingungsparameter lokal um ein spezifisches Szenario verteilt liegen oder ob die Robustheitsanforderungen für einen definierten Bereich des Konfigurationsraums eingehalten werden sollen, bieten sich der Mittelwert der Kriterien für alle Experimente oder auch deren Maximalwert als konservative Abschätzung des schlechtesten zu erwartenden Falls an.

Unter der vereinfachenden Annahme, dass der Einfluss von p_{hyd} und q_{hyd} für jedes Kriterium einzeln betrachtet zu einer monotonen Änderung führt, wird die Optimierung aus Abschnitt 6.5.1 wiederholt. Dabei wird jedes Optimierungskriterium gebildet als der Maximalwert dieses Kriteriums bei drei Experimenten mit den Konfigurationen $p_{hyd} = 0$ bar, $q_{hyd} = 0\%$ sowie $p_{hyd} = 100$ bar, $q_{hyd} = 0\%$ und $p_{hyd} = 100$ bar, $q_{hyd} = 100\%$.

6.6.2 Analyse der Ergebnisse der robusten Optimierung

Das Ergebnis der beschriebenen Optimierung ist, wie auch beim normalen MOEA, eine Approximation der Pareto-Front in dem durch die gleichen Kriterien definierten Raum. Der Unterschied besteht darin, dass die Werte, die die einzelnen Lösungen für das jeweilige Kriterium erhalten, nicht direkt aus der Bewertung abgeleitet werden können, sondern sich wie beschrieben aus dem Maximalwert von drei Bewertungen ergeben. Das Bild 6.17 zeigt den Vergleich der Lösungsmenge des MOEA aus Abschnitt 6.5.1 mit der Lösungsmenge der robusten Optimierung.

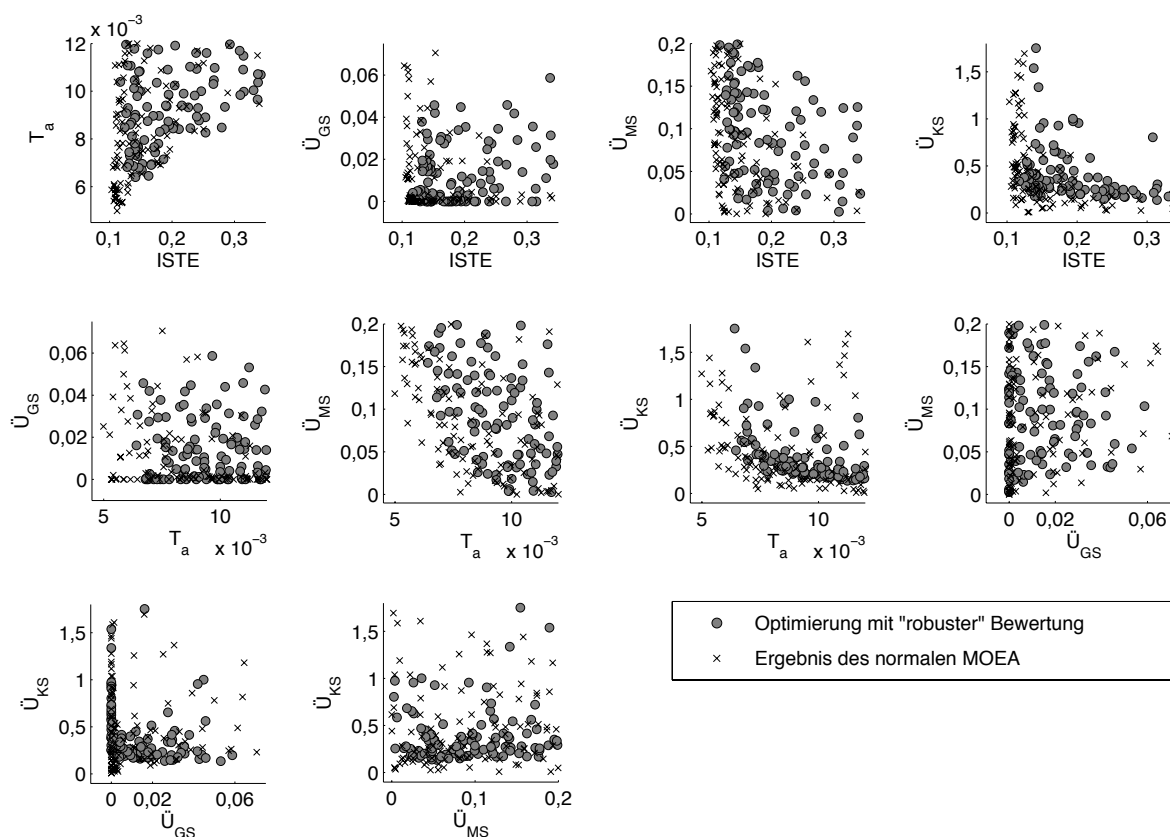


Bild 6.17: Vergleich der Ergebnismengen von normaler und robuster Optimierung

Beim Vergleich beider Lösungsmengen fällt zunächst die global vermeintlich bessere Konvergenz der Ergebnismenge des MOEA auf. Viele dieser Lösungen dominieren Teile der Lösungsmenge der robusten Optimierung und liegen in den dargestellten Projektionen erkennbar näher am Koordinatenursprung. In der gewählten Darstellung hat dies zwei Ursachen: Zum einen muss berücksichtigt werden, dass durch die gewählte Art der Bewertung

eine identische Lösung in der robusten Optimierung höchstens gleich gut oder schlechter bewertet werden kann verglichen mit dem normalen MOEA. Andersherum kann sich bei einer Selektion auf Grundlage einer einzelnen Bewertung eine Lösung durch eine einzelne gute Bewertung, zufällig abweichend oder durch die Betriebsbedingungen verursacht, einfacher durchsetzen als bei mehrfacher Bewertung.

Dieser Effekt liegt in einer Größenordnung, die anhand der Daten für die ausgewählten Beispiele in Abschnitt 6.5.5 abgeschätzt werden kann, und erklärt allein nicht die Unterschiede zwischen beiden Lösungsmengen. Am deutlichsten in der Projektion von T_a und $ISTE$ zu erkennen ist, dass größere zusammenhängende Bereiche der Pareto-Front wegfallen. Hier liegt die Ursache nicht in einer unabhängigen zufälligen Streuung der Bewertungen, sondern in Eigenschaften, die für ähnliche Individuen auch ähnliche Auswirkungen haben. Individuen in diesem Bereich erzielen nicht in allen betrachteten Szenarien eine nicht-dominierte Bewertung und werden daher in der robusten Optimierung nicht selektiert. Dies entspricht der definierten Zielsetzung, die nicht im eigentlichen Sinne darauf abzielt Lösungen zu finden, die sich unter allen Bedingungen gleich verhalten, sondern die unter allen Bedingungen eine Mindestanforderung erfüllen, die wiederum als Kompromiss hinsichtlich aller Kriterien zu verstehen ist.

6.7 Sicherheit durch mehrstufige modellgestützte Optimierung

Bei der evolutionären Optimierung stellen *Versuch und Irrtum* einen wichtigen Teil des Mechanismus dar. Im Kontext dieser HIL-Optimierung jedoch stellt die Bewertung instabiler Regler potentiell ein Risiko für den Versuchsaufbau oder sogar beteiligte Personen dar, das nicht vollständig zu vermeiden ist. Abgesehen von Maßnahmen basierend auf Vorwissen im Bezug auf Systemeigenschaften, das in die Definition des Optimierungsproblems einfließt, können Erweiterungen des Optimierungsalgorithmus angewendet werden, um das Risiko für Schäden zu reduzieren. Da potentiell problematische Individuen mit hoher Wahrscheinlichkeit auch schlecht bewertet werden, stellen die Erweiterungen des MOEA, die Surrogatmodelle für die Fitnessbewertung nutzen, um die Anzahl der realen Bewertungen zu reduzieren, indirekt auch eine Maßnahme zur Vermeidung sicherheitskritischer Bewertungen dar. Diese Methode wird von Braun et al. in [80, 111] vorgestellt und in [78] für die Optimierung der hier betrachteten Hydraulikventilregler angewendet. Für die Beurteilung der Sicherheit einer Bewertung ist eine modellbasierte Schätzung der Fitness des Individuums aber nicht in jedem Fall ausreichend. Der in [81] vorgestellte Ansatz zur mehrstufigen Modellunterstützung integriert, zusätzlich zur Fitnessmodellierung, eine weitere Modellstufe, die das dynamische Verhalten des Ventils, also der Regelstrecke, simuliert, um eine besser generalisierbare Vorhersage des Verhaltens des geregelten Systems zu ermöglichen. Das Bild 6.18 zeigt den Ablauf des um zwei Modellstufen erweiterten Algorithmus. Die Ergebnisse realer Auswertungen der Fitnessfunktion werden in Form der ermittelten Kri-

terien direkt zum Training des datenbasierten Fitnessmodells benutzt und in Form des gemessenen Ein- und Ausgangsverhaltens als Identifikationsdaten für ein Dynamikmodell verwendet. Das verwendete Modell, eine strukturvariable Kombination verschiedener linearer und nichtlinearer Modellelemente, und das Identifikationsverfahren sind in [16, 17, 80] publiziert und erläutert.

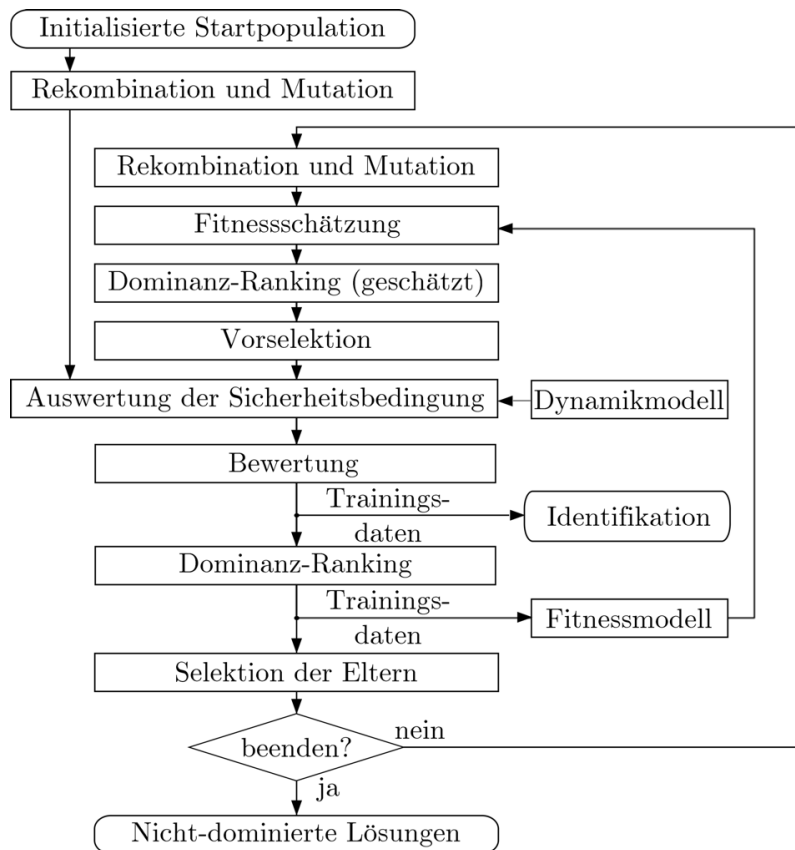


Bild 6.18: Ablauf des erweiterten MOEA mit zweistufiger Modellunterstützung

Die Erweiterung des Algorithmus erlaubt die Nutzung spezifischen Systemwissens, um Risiken zu reduzieren, jedoch auf Kosten einer höheren Laufzeit. Die Simulation des dynamischen Verhaltens dient, im Gegensatz zur Fitnessmodellierung, nicht dazu, die Zahl der realen Auswertungen zu reduzieren, sondern stellt einen Kompromiss zwischen Aufwand und Risiko dar. Darüber hinaus führt die Verwendung von a priori Systemwissen dazu, dass das Optimierungsergebnis zum Teil vom verwendeten Modell, und damit auch von der Qualität der Modellidentifikation, beeinflusst wird. Das Verfahren ist daher geeignet für erste Optimierungen an unbekannt Systemen, ist jedoch bei den in diesem Kapitel gezeigten Optimierungsergebnissen nicht verwendet.

6.8 Übertragbarkeit auf andere Ventiltypen und andere Regelungskonzepte

Die hier entwickelte Optimierungsstrategie ist grundsätzlich auf andere Aufgaben übertragbar. Das Bewertungsverfahren und alle anderen Aspekte der Optimierung dynamischer Systeme beziehen sich jedoch auf diese Art von Anwendung und setzen daher gewisse Ähnlichkeiten der Optimierungsprobleme voraus. Die Methode wurde auf verschiedene Ventile mit digitalen Reglern und auch auf Ventile mit als Ananalogschaltung realisierten Reglern übertragen. Das grundsätzliche Regelungskonzept ist bei allen Systemen identisch, leichte Abweichungen in der Struktur führen zu veränderten Lösungsparametern, die aber in der Funktion den in Abschnitt 6.2.1 beschriebenen Parametern ähnlich sind. Die Unterschiede zum beschriebenen System ergeben sich in Form einer veränderten Architektur des Versuchs. Wird die Reglerstruktur nicht, wie beschrieben, in einem Echtzeitsystem abgebildet, ergeben sich zusätzliche technische Herausforderungen im Hinblick auf die Kommunikation. Für die Optimierung analoger Reglerschaltungen ergibt sich aus der Beschränkung auf tatsächlich verfügbare Bauteile, die die Parameter des Reglers bilden, ein kombinatorisches Problem. Dies erfordert neben den veränderten technischen Anforderungen des Versuchsaufbaus auch Veränderungen der evolutionären Operatoren.

Das Optimierungsverfahren ist grundsätzlich auch übertragbar auf ähnliche Probleme mit abweichenden Eigenschaften. Die Ähnlichkeit bezieht sich dabei auf die Parametrierung und die Bewertung, die Abweichungen beziehen sich auf das System, das deren Zusammenhang maßgeblich bestimmt. Ein Beispiel für diese Art der Übertragung ist ein Ventil abweichender Baugröße mit ähnlicher Arbeitsweise. Um für ein Ventil der Nenngröße NG10 einen Regler zu optimieren, muss zum einen die Dauer der einzelnen Sollwerte der Sprungfolge verlängert werden, da das Ventil wegen der größeren Massenträgheiten und Abmessungen nicht die gleiche Geschwindigkeit erreichen kann. Die Art der Bewertung setzt jedoch das Einschwingen oder zumindest die theoretische Möglichkeit dazu voraus. Zum anderen müssen die Elemente der Bewertungsfunktion überprüft oder angepasst werden, die wie in Abschnitt 6.4.2 beschrieben a priori Kenntnisse und Annahmen für einen Kompromiss hinsichtlich der Komplexität der Kriterien nutzen. Auch die minimal und maximal zulässigen Parameterwerte sind problemspezifisch gewählt und erfordern eine Anpassung.

Alle diese unterschiedlichen Systeme und Anwendungen bilden zwar eigenständige Optimierungsprobleme, führen qualitativ aber zu keinen anderen Aussagen im Hinblick auf den Schwerpunkt dieser Arbeit. Auf die detaillierte Darstellung der Systeme, Experimente und der Optimierungsergebnisse wird aus diesem Grund verzichtet. Die Parametrierung und Bewertung von Lösungen müssen für jede Anwendung neu gestaltet oder hinsichtlich der Ähnlichkeit zu bestehenden Systemen untersucht und beurteilt werden. Die Mechanismen zur interaktiven Optimierung sind jedoch, wie in Kapitel 4 anhand von Testfunktionen gezeigt, universell anwendbar. Zum Nachweis deren grundsätzlicher Eignung zur Optimierung dynamischer Systeme im Allgemeinen und zur HIL-Optimierung von Hydraulikventilen im Speziellen dient exemplarisch die in diesem Kapitel dargestellte erfolgreiche Anwendung für ein ausgewähltes Zielsystem.

Kapitel 7

Zusammenfassung und Ausblick

Die wachsende Komplexität technischer Systeme motiviert die Verwendung von computer-gestützten Optimierungsverfahren im Kontext deren Entwicklungsprozesse. Evolutionäre Algorithmen stellen dabei eine der wichtigsten und leistungsfähigsten Methoden dar, weil sie zum einen in der Lage sind, bei minimalem Vorwissen globale Optima für komplexe Optimierungsprobleme zu ermitteln. Zum anderen erlaubt ihre populationsbasierte Funktionsweise einen multikriteriellen Ansatz, der als Ergebnis optimale objektive Kompromisse zwischen verschiedenen konfliktären Kriterien erlaubt, die für die Ansprüche an die Lösung für viele technische Probleme charakteristisch sind.

Die in diesem Zusammenhang entstehende Fragestellung der Kombination von Optimierung und Entscheidungsfindung ist der zentrale Aspekt dieser Arbeit. Die interaktive Optimierung bietet hier die Möglichkeit, Optimierungsprobleme mittels der Integration von Entscheidungsprozessen effizient zu lösen, ohne dabei entweder schwierige oder problematische a priori Annahmen treffen zu müssen oder aber aufwändig die ganze Pareto-Front zu approximieren. Der in dieser Arbeit verfolgte Ansatz basiert darauf, Expertenwissen in Form von Präferenzen zur Verbesserung der Optimierung und deren Ergebnissen zu erschließen, das über die formulierten Bewertungskriterien hinausgeht. Die durch die Methode realisierten zentralen Zielsetzungen sind dabei die folgenden:

- Der Methode liegen keine Annahmen oder Modelle bezüglich der Struktur der Präferenzen des Anwenders zu Grunde, eine wichtige Voraussetzung für ihre Robustheit und Praxistauglichkeit.
- Die Art der Entscheidungen und die Grundlage, auf denen diese getroffen werden müssen, orientieren sich an der Anwendung und dem Anwender und nicht am Optimierungsverfahren.
- Die interaktiv zu treffenden Entscheidungen sind möglichst einfach und daher nahezu intuitiv zu treffen.
- Die Anzahl der notwendigen Entscheidungen als Belastung für den Anwender wird auf ein Minimum reduziert.

Die vorgestellte Methode zur interaktiven multikriteriellen evolutionären Optimierung stellt eine Erweiterung des Selektionsmechanismus von dominanzbasierten MOEA dar, die zwischen nicht-dominierten Lösungen weiter unterscheidet, indem deren Präferenzen und Vergleichbarkeit innerhalb der betrachteten Lösungsmenge berücksichtigt werden. Die Methode erreicht die angestrebten Eigenschaften durch ein instanzbasiertes Präferenzmodell, das aus paarweisen relativen Vergleichen von ausgewählten Prototypen erzeugt wird. Die vorausgesetzte lokale Ähnlichkeit der Präferenzen für Lösungen erlaubt auf Grundlage weniger Modellinstanzen die Schätzung der Präferenz des Anwenders für ganze Populationen als Grundlage für die Selektionsentscheidung im evolutionären Algorithmus. Die Auswahl der Prototypen, die dem Anwender zum Erzeugen von Modellinstanzen iterativ im Verlauf des Optimierungsprozesses zur Entscheidung vorgelegt werden, geschieht mit dem Ziel, aus möglichst wenigen Antworten des Entscheiders einen maximalen Informationsgewinn zu erzielen. Mittels des so erzeugten Modells lassen sich aufgrund dessen lokalen Charakters prinzipiell beliebige Präferenzen eines Anwenders abbilden. Außer der Annahme, dass für in beliebig kleiner Umgebung benachbarte Lösungen ähnliche Präferenzen gelten, sind für die Struktur der Präferenzen keine Einschränkungen wie Transitivität, Monotonie oder andere mögliche Eigenschaften einer beschreibenden Funktion erforderlich.

Diese Arbeit beschreibt und analysiert die zur interaktiven Optimierung entwickelte Methode zunächst auf Grundlage von künstlichen Testproblemen, und belegt ihre Funktionsfähigkeit sowie dass sie die angestrebten Eigenschaften erfüllt. In einem zweiten Teil wendet sich die Arbeit der Anwendung der Methode der interaktiven Optimierung im Kontext dynamischer Systeme und der konkreten Anwendung für die Optimierung von Hydraulikventilreglern zu. Bei der Optimierung im Kontext dynamischer Systeme sind die Wahl geeigneter Kriterien und Maße zur Beurteilung von Systemverhalten im Zeitbereich sowie der Aspekt der Robustheit von Bewertung und Kriterien die zentralen Aspekte der Arbeit. Auf Grundlage einer Analyse der Vor- und Nachteile unterschiedlicher Maße zur Charakterisierung von Sprungantworten wird ein Konzept zur Bewertung realer Prozesse in HIL-Experimenten vorgeschlagen und begründet.

Die exemplarische Anwendung der entwickelten Methode ist die Optimierung von Parametern für Regler hydraulischer Proportional-Wegeventile. In diesem Zusammenhang wird, zur Optimierung anhand von HIL-Bewertungen unter realen Testbedingungen, der Aufbau eines Hydraulikprüfstandes und Experimentalsystems beschrieben. Diese Anlage ermöglicht es, das dynamische Verhalten von geregelten Ventilen unter angenähert realen Betriebsbedingungen, also variierten Druck- und Lastbedingungen, experimentell zu überprüfen. Der hohe Grad an Automatisierung des Versuchsaufbaus und die Möglichkeit zum Software-gesteuerten und reproduzierbaren Konfigurieren der Betriebsbedingungen ermöglicht eine systematische und statistisch aussagekräftige Analyse von Optimierungsergebnissen basierend auf einer großen Zahl von Experimenten.

Die bei der Optimierung von Hydraulikventilreglern erzielten und in dieser Arbeit präsentierten Ergebnisse zeigen die praktische Einsetzbarkeit und Leistungsfähigkeit der entwickelten Methode zur interaktiven Optimierung. Sie belegen deren Eignung als wirkungsvoll unterstützendes Werkzeug im Entwicklungsprozess, das durch das gezielte Ergänzen von

Wissen und Erfahrung eines Anwenders durch CI-Methoden und Optimierungsalgorithmen Synergien zum effizienten Lösen komplexer Aufgaben erschließen kann.

Im Hinblick auf diese Anwendung ist eine Weiterentwicklung denkbar, die noch stärker die Möglichkeiten eines stark automatisierten hydraulischen Versuchsaufbaus für die Optimierung nutzbar macht. An verschiedenen Stellen, an denen sich die vorliegende Arbeit auf die Betrachtung weniger statischer Szenarien von Versuchsbedingungen beschränkt, zeigen erste weiterführende Arbeiten und Experimente das Potential, auch dynamische Szenarien oder Lastsituationen zu berücksichtigen oder ganze Anwendungsszenarien durch einen HIL-Simulator abzubilden. Diese Ansätze stellen in verschiedener Hinsicht wissenschaftliche und technische Herausforderungen dar, führen darüber hinaus jedoch zwangsläufig auch zu einer Steigerung der Komplexität des resultierenden zu betrachtenden Optimierungsproblems.

Die wachsende Komplexität von in der Praxis zu optimierenden Systemen oder Prozessen, selbst mit verursacht durch die zunehmende Leistungsfähigkeit von Rechnern und Optimierungsmethoden und die dadurch entstehenden Möglichkeiten beispielsweise zur domänenübergreifenden Betrachtung, führt zu einer Veränderung der eigentlichen Herausforderungen in der Entwicklung von Optimierungsmethoden. Sowohl die exponentiell wachsende Leistungsfähigkeit von Computern als auch die Entwicklung von skalierbaren Methoden zu deren effektiven Nutzung führen dazu, dass die Rechenleistung oder die Bearbeitungszeit immer weniger den limitierenden Faktor für die Anwendung von CI-Methoden und Optimierungsalgorithmen darstellen. Technische Lösungen, die den effektiven Einsatz der Methoden unterstützen, wie das in dieser Arbeit präsentierte Konzept für einen automatisierten Hydraulikversuchsaufbau, tragen ebenfalls ihren Teil zu dieser Entwicklung bei.

Die Komplexität der betrachteten Anwendungen äußert sich vielmehr auch als Herausforderung für die Definition geeigneter Optimierungsprobleme und den entscheidenden Aspekt dabei, die Definition oder Auswahl geeigneter Bewertungskriterien.

Die vorliegende Arbeit stellt einen ersten Schritt zur Lösung dieses Problems dar, indem Teile der konkreten formalen Beschreibung von Präferenzen als Optimierungskriterien durch intuitiv artikulierbare relative Bewertungen einfacher Vergleiche ersetzt werden. Dies ermöglicht indirekt auch die Optimierung komplexerer Probleme mit einer größeren Anzahl von Kriterien. Im Rahmen der präsentierten Anwendung, der Optimierung von Hydraulikventilreglern, sind jedoch wie beschrieben bei der Definition der Optimierungskriterien bereits einschränkende a priori Annahmen erforderlich, um die Komplexität des Problems zu begrenzen.

Ein aussichtsreicher Ansatz, um zukünftig komplexere Aufgaben lösen zu können, ist eine Fortsetzung der Integration von Expertenwissen und leistungsfähigen CI-Methoden. Ein großer Bedarf an Computerunterstützung eines bislang verbreitet manuellen Prozesses entsteht speziell bei der Aufgabe, aus einer komplexen Problemstellung ein geeignetes Optimierungsproblem zu formulieren. Die interaktive Beeinflussung des Optimierungsprozesses darf sich hierzu nicht auf einen Entscheidungsprozess innerhalb eines definierten Rahmens von Kriterien und Lösungsparametern beschränken. Vielmehr muss hierzu die Definition von Optimierungsproblemen CI-gestützt und unter Umständen interaktiv in den größeren

Kontext des Entwicklungsprozesses integriert werden.

Für die in dieser Arbeit betrachtete Optimierung von Hydraulikventilreglern kann dies bedeuten, auf eine geschlossene Formulierung des Optimierungsproblems, wie sie in dieser Arbeit verwendet ist, zu verzichten. Stattdessen wird der Weg zur Lösung des Gesamtproblems als unter Umständen iterative Kombination von Teilproblemen betrachtet, deren Definition sowohl auf interaktiv eingebrachtem Expertenwissen als auch auf optimierten Lösungen vorangegangener betrachteter Teilprobleme basieren kann. CI-Methoden wie beispielsweise der entwickelte I-MOEA, lösen diese wohldefinierten und in ihrer Komplexität reduzierten Teilprobleme. Die Interaktion mit dem Anwender umfasst damit nicht nur die Entscheidung hinsichtlich der Bewertung von Lösungen. Sie beinhaltet darüber hinaus für die einzelnen Teilprobleme die Wahl zu optimierender Parameter, die verwendeten Kriterien, angewendete Nebenbedingungen und die Ausgestaltung des Bewertungsexperiments, also beispielsweise die Wahl eines geeigneten Stimulus. Praktisch kann das bedeuten, nicht eine Stimulus-Funktion mit dem Anspruch zu gestalten, alle relevanten Aspekte des Systemverhaltens abzubilden. Stattdessen führt ein Experiment mit vereinfachtem Stimulus, der nur beispielsweise das Großsignalverhalten abbildet, unter exklusiver Betrachtung der für dieses Verhalten relevanten Kriterien zu einer Teillösung für die Parameter des Reglers, die einen relevanten Einfluss auf den betrachteten Aspekt des Systemverhaltens haben. Ein MOEA oder ein anderes Verfahren ist, aufgrund der reduzierten Anzahl von Parametern und Kriterien, für diese Optimierungsaufgabe potentiell effizienter und zuverlässiger als für das komplexere Gesamtproblem. Die Integration von Algorithmus und Experten, dessen Aufgabe es ist, die für diese Problemdefinition notwendigen Entscheidungen zu treffen, stellt die eigentliche Herausforderung dar. Diese Entscheidungen als einzelne Schritte einer iterativen Vorgehensweise basieren auf Erkenntnissen aus der Analyse vorheriger Teillösungen. Diese können sich sowohl auf Erfahrung basierender als auch auf automatischer, beispielsweise regelbasierter, Auswertung von Ergebnissen ergeben.

Diese iterative Vorgehensweise stellt eine konsequente Weiterentwicklung des in dieser Arbeit propagierten Ansatzes dar, die Stärken von menschlichem Experten und Optimierungsalgorithmus in einer Art zu kombinieren, die größtmögliche Synergien im Hinblick auf das Erreichen des Ziels des Entwicklungs- oder Optimierungsprozesses erzeugt.

Anhang A

Benchmark-Ergebnisse

Die Leistungsfähigkeit der präferenzbasierten Selektion in der interaktiven Optimierung und die universelle Anwendbarkeit des Verfahrens für verschiedene Optimierungsprobleme wird belegt durch die Optimierung verschiedener bekannter Benchmark-Probleme. Exemplarisch ausgewählt sind dabei drei Funktionen, die eine konkave, eine konvexe und eine unstetige Pareto-Front repräsentieren [117]. Für alle drei Funktionen werden aus der echten Pareto-Front zehn Lösungen zufällig gewählt, um auf deren Grundlage künstliche Referenzpunkte für die Optimierung zu generieren. Durch Verschiebung dieser Punkte um -1% der Kriterienraumgröße entstehen nicht erreichbare Referenzpunkte. Die Referenzpunkte und die Pareto-Front sind jeweils in den Abbildungen A.1, A.3 und A.5 gezeigt. Grundlage der Analyse sind jeweils fünfmal wiederholte Optimierungen mit jedem einzelnen Referenzpunkt als Grundlage für das künstliche Entscheidungsmodell sowie für fünf Paare von Referenzpunkten, die durch das jeweils gleiche Symbol markiert sind. Betrachtet wird der mittlere Abstand $|\Delta\mathbf{f}|$ aller Lösungen der aktuellen Population zum Referenzpunkt \mathbf{f}_{Ref} in jeder Generation. Verglichen werden die Rate der Verringerung des Abstandes sowie deren Reproduzierbarkeit bei wiederholter Optimierung für zwei verschiedene Parametrierungen der interaktiven Selektion und bei einer dominanzbasierten Selektion. Die Konfiguration des Algorithmus ist in Anhang D.4 dokumentiert, als Parameter für die Interaktion wurden zum einen zwei Fragen in jeder Generation (Rate $r_i = 2$), zum anderen eine Frage jede zweite Generation ($r_i = 0,5$) betrachtet.

A.1 FON-Funktion

Die FON-Funktion dient als Beispiel für eine konkave Pareto-Front und ist wie folgt definiert:

$$\begin{aligned}
 f_1(\mathbf{x}) &= 1 - \exp\left(-\sum_{i=1}^{n_x}\left(x_i - \frac{1}{\sqrt{n}}\right)^2\right) \quad , \\
 f_2(\mathbf{x}) &= 1 - \exp\left(-\sum_{i=1}^{n_x}\left(x_i + \frac{1}{\sqrt{n}}\right)^2\right) \quad , \\
 -4 \leq x_i \leq 4 \quad i &= 1, 2, \dots, n_x \quad .
 \end{aligned}
 \tag{A.1}$$




Bild A.1: Pareto-Front und zufällig gewählte Referenzpunkte für die FON-Funktion

Tabelle A.1: FON-Funktion, Entwicklung des Abstands für einzelne Referenzpunkte

Generation		1		5		10		25		50	
Ref.	Konfig.	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $
1	$r_i = 0, 5$	0,757	0,048	0,647	0,093	0,255	0,155	0,041	0,013	0,032	0,012
	$r_i = 2$	0,730	0,022	0,633	0,022	0,225	0,090	0,061	0,008	0,028	0,008
	NSGA-II	0,678	0,001	0,559	0,041	0,445	0,058	0,423	0,030	0,467	0,033
2	$r_i = 0, 5$	0,681	0,042	0,567	0,042	0,296	0,063	0,052	0,011	0,026	0,004
	$r_i = 2$	0,715	0,024	0,620	0,043	0,308	0,104	0,054	0,020	0,033	0,009
	NSGA-II	0,749	0,001	0,630	0,044	0,507	0,062	0,477	0,038	0,504	0,049
3	$r_i = 0, 5$	0,795	0,019	0,746	0,031	0,338	0,134	0,058	0,017	0,028	0,003
	$r_i = 2$	0,786	0,007	0,693	0,076	0,373	0,126	0,065	0,032	0,025	0,003
	NSGA-II	0,988	0,001	0,876	0,045	0,747	0,067	0,678	0,051	0,674	0,075
4	$r_i = 0, 5$	0,989	0,002	0,936	0,039	0,437	0,119	0,032	0,007	0,022	0,005
	$r_i = 2$	0,990	0,002	0,885	0,100	0,484	0,178	0,025	0,007	0,017	0,004
	NSGA-II	0,927	0,002	0,825	0,075	0,640	0,058	0,665	0,054	0,680	0,070
5	$r_i = 0, 5$	0,937	0,005	0,842	0,086	0,509	0,172	0,042	0,011	0,021	0,006
	$r_i = 2$	0,933	0,002	0,824	0,064	0,315	0,139	0,055	0,014	0,021	0,005
	NSGA-II	0,575	0,001	0,470	0,035	0,340	0,049	0,383	0,045	0,454	0,074
6	$r_i = 0, 5$	0,678	0,042	0,570	0,106	0,312	0,082	0,062	0,031	0,033	0,013
	$r_i = 2$	0,696	0,030	0,549	0,083	0,266	0,082	0,043	0,009	0,031	0,008
	NSGA-II	0,615	0,001	0,497	0,034	0,393	0,055	0,378	0,028	0,443	0,020
7	$r_i = 0, 5$	0,729	0,045	0,614	0,084	0,293	0,091	0,068	0,025	0,033	0,013
	$r_i = 2$	0,677	0,020	0,579	0,044	0,295	0,087	0,055	0,019	0,024	0,005
	NSGA-II	0,957	0,001	0,844	0,045	0,714	0,067	0,646	0,050	0,648	0,073
8	$r_i = 0, 5$	0,960	0,005	0,888	0,041	0,540	0,166	0,034	0,007	0,022	0,006
	$r_i = 2$	0,965	0,005	0,859	0,044	0,449	0,133	0,038	0,006	0,024	0,005
	NSGA-II	0,754	0,002	0,648	0,067	0,472	0,050	0,525	0,043	0,557	0,076
9	$r_i = 0, 5$	0,810	0,024	0,747	0,053	0,414	0,072	0,047	0,014	0,027	0,004
	$r_i = 2$	0,803	0,011	0,640	0,116	0,310	0,161	0,046	0,012	0,024	0,004
	NSGA-II	0,883	0,001	0,768	0,045	0,637	0,067	0,583	0,045	0,592	0,067
10	$r_i = 0, 5$	0,900	0,008	0,780	0,071	0,385	0,193	0,053	0,017	0,021	0,001
	$r_i = 2$	0,900	0,009	0,832	0,067	0,490	0,216	0,046	0,015	0,028	0,008
	NSGA-II	0,577	0,001	0,460	0,030	0,361	0,055	0,353	0,035	0,432	0,023

Tabelle A.2: FON-Funktion, Entwicklung des Abstands für Referenzpunkt-Paare

Generation		1		5		10		25		50	
Ref.	Konfig.	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $
1 & 6	$r_i = 0,5$	0,752	0,041	0,664	0,077	0,375	0,126	0,161	0,063	0,062	0,011
		0,696	0,042	0,606	0,077	0,346	0,094	0,125	0,044	0,074	0,019
	$r_i = 2$	0,767	0,038	0,635	0,094	0,301	0,120	0,106	0,030	0,094	0,038
		0,724	0,047	0,585	0,110	0,284	0,110	0,102	0,037	0,064	0,019
	NSGA-II	0,678	0,001	0,559	0,041	0,445	0,058	0,423	0,030	0,467	0,033
		0,615	0,001	0,497	0,034	0,393	0,055	0,378	0,028	0,443	0,020
2 & 7	$r_i = 0,5$	0,764	0,011	0,647	0,071	0,321	0,163	0,208	0,027	0,207	0,024
		0,961	0,004	0,854	0,066	0,512	0,179	0,134	0,069	0,127	0,042
	$r_i = 2$	0,764	0,005	0,693	0,028	0,369	0,176	0,166	0,035	0,137	0,024
		0,966	0,002	0,906	0,030	0,549	0,225	0,121	0,035	0,139	0,034
	NSGA-II	0,749	0,001	0,630	0,044	0,507	0,062	0,477	0,038	0,504	0,049
		0,957	0,001	0,844	0,045	0,714	0,067	0,646	0,050	0,648	0,073
3 & 8	$r_i = 0,5$	1,165	0,322	1,082	0,307	0,824	0,324	0,816	0,530	0,871	0,537
		0,972	0,352	0,870	0,385	0,694	0,442	0,629	0,615	0,560	0,636
	$r_i = 2$	1,393	0,810	1,235	0,839	1,030	0,843	0,961	0,901	0,950	0,897
		0,819	0,027	0,700	0,098	0,576	0,172	0,552	0,264	0,549	0,277
	NSGA-II	0,988	0,001	0,876	0,045	0,747	0,067	0,678	0,051	0,674	0,075
		0,754	0,002	0,648	0,067	0,472	0,050	0,525	0,043	0,557	0,076
4 & 9	$r_i = 0,5$	0,936	0,013	0,859	0,041	0,697	0,102	0,736	0,228	0,721	0,224
		0,894	0,007	0,838	0,040	0,618	0,098	0,509	0,223	0,584	0,193
	$r_i = 2$	0,930	0,005	0,860	0,030	0,711	0,082	0,648	0,229	0,564	0,182
		0,892	0,006	0,840	0,051	0,600	0,107	0,621	0,222	0,716	0,192
	NSGA-II	0,927	0,002	0,825	0,075	0,640	0,058	0,665	0,054	0,680	0,070
		0,883	0,001	0,768	0,045	0,637	0,067	0,583	0,045	0,592	0,067
5 & 10	$r_i = 0,5$	0,660	0,017	0,554	0,057	0,342	0,091	0,304	0,096	0,278	0,069
		0,707	0,049	0,589	0,082	0,442	0,041	0,249	0,076	0,211	0,058
	$r_i = 2$	0,688	0,038	0,557	0,108	0,371	0,100	0,249	0,059	0,163	0,077
		0,694	0,061	0,579	0,066	0,402	0,116	0,193	0,056	0,326	0,097
	NSGA-II	0,575	0,001	0,470	0,035	0,340	0,049	0,383	0,045	0,454	0,074
		0,577	0,001	0,460	0,030	0,361	0,055	0,353	0,035	0,432	0,023

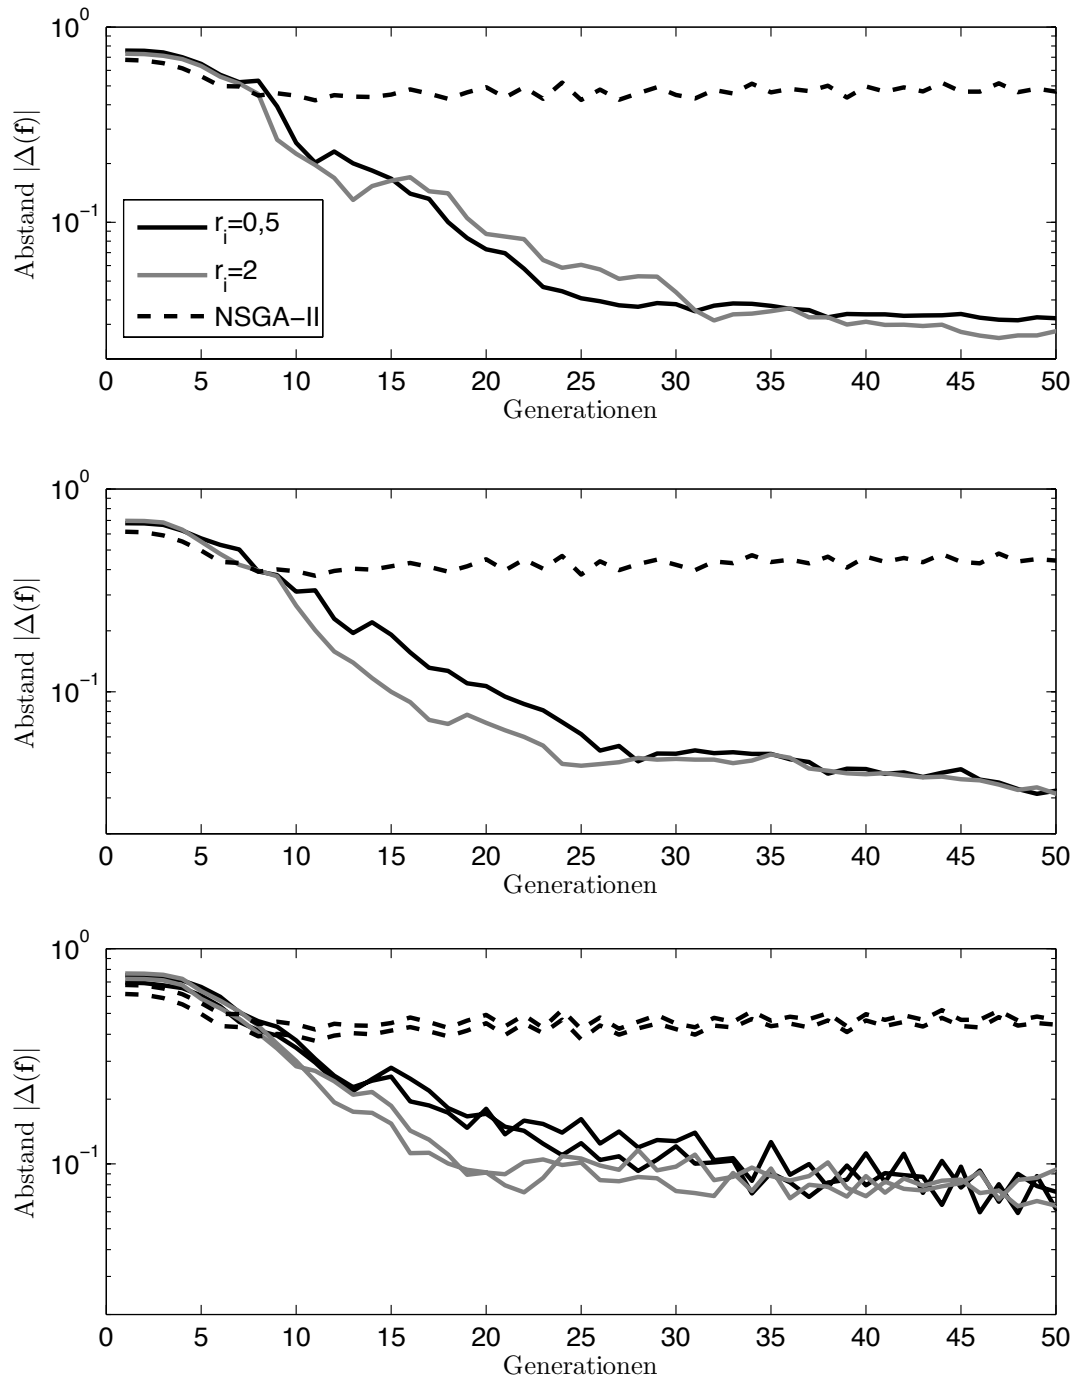


Bild A.2: Entwicklung des mittleren Abstands der Population zu jeweils den Referenzpunkten Ref₁ (oben), Ref₆ (mitte) oder Ref₁ & Ref₆ (unten) für die FON-Funktion

A.2 ZDT1-Funktion

Die ZDT1-Funktion dient als Beispiel für eine konvexe Pareto-Front und ist wie folgt definiert:

$$\begin{aligned}
 f_1(\mathbf{x}) &= x_1 \quad , \\
 f_2(\mathbf{x}) &= g \left(1 - \sqrt{\frac{x_1}{g}} \right) \quad , \\
 g(\mathbf{x}) &= 1 + \frac{9}{n_x - 1} \sum_{i=2}^{n_x} x_i \quad , \\
 0 \leq x_i &\leq 1, \quad i = 1, 2, \dots, n_x \quad .
 \end{aligned}
 \tag{A.2}$$




Bild A.3: Pareto-Front und zufällig gewählte Referenzpunkte für die ZDT1-Funktion

Tabelle A.3: ZDT1-Funktion, Entwicklung des Abstands für einzelne Referenzpunkte

Generation		1		5		10		25		50	
Ref.	Konfig.	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $
1	$r_i = 0, 5$	0,658	0,025	0,415	0,041	0,235	0,075	0,187	0,149	0,047	0,075
	$r_i = 2$	0,658	0,022	0,370	0,062	0,241	0,037	0,220	0,069	0,043	0,035
	NSGA-II	0,668	0,022	0,444	0,032	0,339	0,045	0,277	0,045	0,310	0,019
2	$r_i = 0, 5$	0,702	0,046	0,404	0,045	0,220	0,026	0,082	0,035	0,028	0,033
	$r_i = 2$	0,730	0,038	0,409	0,065	0,251	0,104	0,045	0,037	0,029	0,022
	NSGA-II	0,670	0,028	0,412	0,035	0,292	0,050	0,278	0,083	0,375	0,027
3	$r_i = 0, 5$	0,705	0,039	0,353	0,068	0,169	0,041	0,095	0,061	0,047	0,065
	$r_i = 2$	0,714	0,008	0,388	0,031	0,253	0,086	0,086	0,044	0,021	0,024
	NSGA-II	0,789	0,032	0,659	0,075	0,587	0,104	0,452	0,105	0,371	0,051
4	$r_i = 0, 5$	0,779	0,054	0,566	0,096	0,324	0,071	0,175	0,026	0,085	0,091
	$r_i = 2$	0,769	0,039	0,526	0,083	0,298	0,149	0,122	0,082	0,211	0,039
	NSGA-II	0,688	0,035	0,424	0,057	0,313	0,100	0,368	0,120	0,499	0,048
5	$r_i = 0, 5$	0,779	0,021	0,325	0,037	0,131	0,030	0,018	0,003	0,014	0,001
	$r_i = 2$	0,732	0,019	0,320	0,039	0,111	0,021	0,016	0,003	0,013	0,001
	NSGA-II	0,670	0,027	0,412	0,034	0,293	0,049	0,277	0,083	0,374	0,027
6	$r_i = 0, 5$	0,683	0,046	0,377	0,081	0,223	0,089	0,092	0,082	0,034	0,022
	$r_i = 2$	0,677	0,011	0,384	0,052	0,293	0,079	0,056	0,016	0,010	0,004
	NSGA-II	0,689	0,033	0,422	0,051	0,304	0,089	0,336	0,116	0,464	0,046
7	$r_i = 0, 5$	0,750	0,029	0,319	0,054	0,128	0,025	0,020	0,005	0,011	0,003
	$r_i = 2$	0,755	0,024	0,342	0,048	0,244	0,111	0,036	0,013	0,016	0,012
	NSGA-II	0,741	0,028	0,588	0,064	0,507	0,094	0,386	0,090	0,334	0,037
8	$r_i = 0, 5$	0,745	0,054	0,576	0,077	0,327	0,171	0,124	0,068	0,127	0,144
	$r_i = 2$	0,704	0,025	0,467	0,060	0,251	0,071	0,159	0,062	0,022	0,018
	NSGA-II	0,678	0,022	0,472	0,039	0,374	0,060	0,295	0,047	0,304	0,020
9	$r_i = 0, 5$	0,635	0,034	0,385	0,060	0,169	0,038	0,104	0,050	0,038	0,033
	$r_i = 2$	0,675	0,019	0,404	0,064	0,223	0,042	0,203	0,160	0,029	0,031
	NSGA-II	0,704	0,024	0,527	0,052	0,437	0,080	0,335	0,070	0,310	0,024
10	$r_i = 0, 5$	0,690	0,041	0,486	0,114	0,345	0,091	0,206	0,107	0,085	0,084
	$r_i = 2$	0,683	0,040	0,452	0,073	0,352	0,062	0,160	0,062	0,105	0,108
	NSGA-II	0,673	0,029	0,412	0,038	0,291	0,058	0,287	0,092	0,393	0,033

Tabelle A.4: ZDT1-Funktion, Entwicklung des Abstands für Referenzpunkt-Paare

Generation		1		5		10		25		50	
Ref.	Konfig.	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $
1 & 6	$r_i = 0, 5$	0,695	0,018	0,416	0,044	0,335	0,061	0,281	0,030	0,258	0,051
		0,706	0,036	0,358	0,062	0,248	0,202	0,083	0,059	0,104	0,046
	$r_i = 2$	0,675	0,037	0,417	0,039	0,283	0,050	0,234	0,059	0,273	0,039
		0,695	0,040	0,329	0,072	0,219	0,109	0,174	0,080	0,066	0,040
	NSGA-II	0,668	0,022	0,444	0,032	0,339	0,045	0,277	0,045	0,310	0,019
		0,689	0,033	0,422	0,051	0,304	0,089	0,336	0,116	0,464	0,046
2 & 7	$r_i = 0, 5$	0,650	0,026	0,330	0,044	0,208	0,039	0,293	0,209	0,190	0,140
		0,741	0,053	0,613	0,122	0,524	0,145	0,415	0,199	0,308	0,144
	$r_i = 2$	0,688	0,021	0,343	0,061	0,232	0,065	0,312	0,110	0,245	0,123
		0,720	0,027	0,566	0,048	0,385	0,124	0,244	0,129	0,269	0,123
	NSGA-II	0,670	0,028	0,412	0,035	0,292	0,050	0,278	0,083	0,375	0,027
		0,741	0,028	0,588	0,064	0,507	0,094	0,386	0,090	0,334	0,037
3 & 8	$r_i = 0, 5$	0,831	0,060	0,602	0,077	0,484	0,195	0,319	0,211	0,331	0,235
		0,687	0,045	0,398	0,079	0,311	0,069	0,297	0,131	0,206	0,144
	$r_i = 2$	0,739	0,046	0,584	0,050	0,349	0,119	0,108	0,065	0,135	0,072
		0,659	0,019	0,363	0,030	0,233	0,038	0,326	0,109	0,267	0,110
	NSGA-II	0,789	0,032	0,659	0,075	0,587	0,104	0,452	0,105	0,371	0,051
		0,678	0,022	0,472	0,039	0,374	0,060	0,295	0,047	0,304	0,020
4 & 9	$r_i = 0, 5$	0,728	0,026	0,396	0,079	0,395	0,134	0,256	0,149	0,175	0,201
		0,700	0,049	0,508	0,053	0,355	0,096	0,383	0,161	0,424	0,196
	$r_i = 2$	0,710	0,028	0,381	0,076	0,395	0,191	0,264	0,165	0,094	0,077
		0,705	0,061	0,528	0,087	0,338	0,094	0,360	0,155	0,501	0,060
	NSGA-II	0,688	0,035	0,424	0,057	0,313	0,100	0,368	0,120	0,499	0,048
		0,704	0,024	0,527	0,052	0,437	0,080	0,335	0,070	0,310	0,024
5 & 10	$r_i = 0, 5$	0,708	0,036	0,338	0,054	0,219	0,023	0,091	0,039	0,041	0,034
		0,717	0,039	0,336	0,055	0,217	0,038	0,104	0,050	0,048	0,030
	$r_i = 2$	0,694	0,042	0,351	0,030	0,297	0,117	0,054	0,027	0,020	0,007
		0,699	0,041	0,345	0,035	0,301	0,142	0,066	0,032	0,040	0,011
	NSGA-II	0,670	0,027	0,412	0,034	0,293	0,049	0,277	0,083	0,374	0,027
		0,673	0,029	0,412	0,038	0,291	0,058	0,287	0,092	0,393	0,033

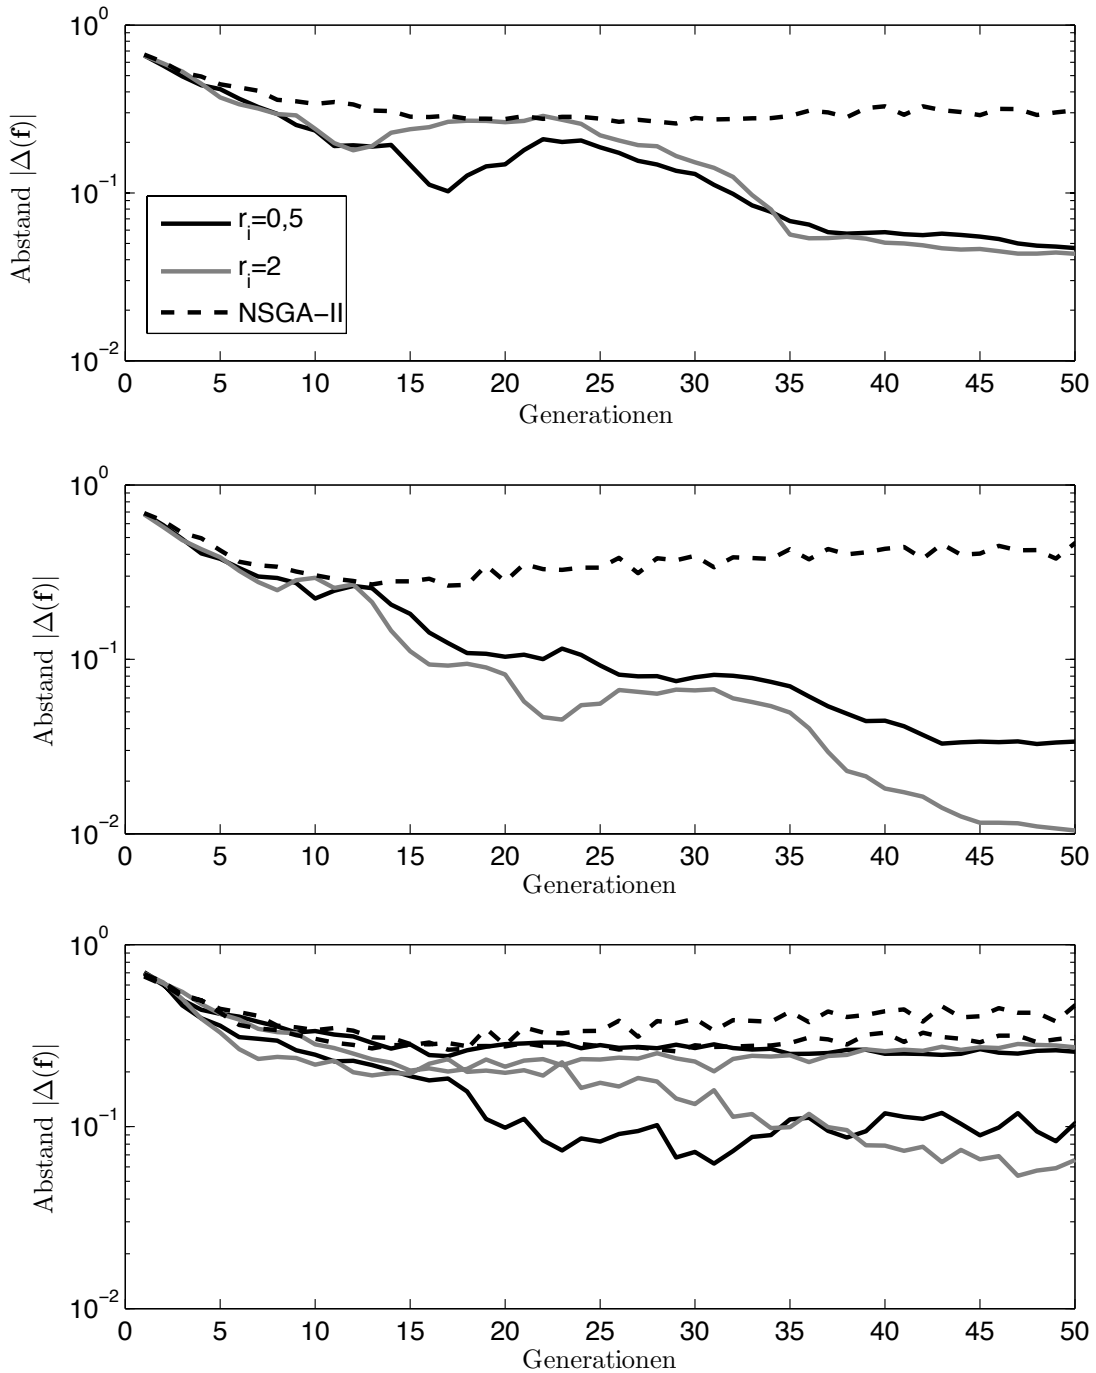


Bild A.4: Entwicklung des mittleren Abstands der Population zu jeweils den Referenzpunkten Ref₁ (oben), Ref₆ (mitte) oder Ref₁ & Ref₆ (unten) für die ZDT1-Funktion

A.3 ZDT3

Die ZDT3-Funktion dient als Beispiel für eine nicht-kontinuierliche Pareto-Front und ist wie folgt definiert:

$$\begin{aligned}
 f_1(\mathbf{x}) &= x_1 \quad , \\
 f_2(\mathbf{x}) &= g \left(1 - \sqrt{\frac{x_1}{g}} - \left(\frac{x_1}{g} \right) \sin(10\pi x_1) \right) \quad , \\
 g(\mathbf{x}) &= 1 + \frac{9}{n_x - 1} \sum_{i=2}^{n_x} x_i \quad , \\
 0 \leq x_i &\leq 1, \quad i = 1, 2, \dots, n_x \quad .
 \end{aligned}
 \tag{A.3}$$




Bild A.5: Pareto-Front und zufällig gewählte Referenzpunkte für die ZDT3-Funktion

Tabelle A.5: ZDT3-Funktion, Entwicklung des Abstands für einzelne Referenzpunkte

Generation		1		5		10		25		50	
Ref.	Konfig.	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $
1	$r_i = 0, 5$	0,621	0,031	0,382	0,042	0,262	0,079	0,192	0,165	0,102	0,135
	$r_i = 2$	0,671	0,036	0,442	0,084	0,209	0,029	0,127	0,064	0,046	0,069
	NSGA-II	0,618	0,016	0,447	0,020	0,332	0,042	0,251	0,015	0,272	0,027
2	$r_i = 0, 5$	0,645	0,028	0,465	0,028	0,183	0,052	0,134	0,086	0,056	0,079
	$r_i = 2$	0,717	0,050	0,511	0,045	0,227	0,047	0,060	0,073	0,020	0,011
	NSGA-II	0,615	0,018	0,384	0,054	0,273	0,050	0,266	0,070	0,310	0,018
3	$r_i = 0, 5$	0,654	0,021	0,335	0,005	0,264	0,075	0,106	0,066	0,041	0,053
	$r_i = 2$	0,626	0,037	0,358	0,024	0,250	0,074	0,182	0,160	0,011	0,002
	NSGA-II	0,599	0,019	0,362	0,061	0,259	0,058	0,278	0,079	0,325	0,018
4	$r_i = 0, 5$	0,648	0,016	0,372	0,053	0,237	0,019	0,098	0,069	0,050	0,045
	$r_i = 2$	0,612	0,034	0,345	0,070	0,225	0,127	0,120	0,104	0,088	0,080
	NSGA-II	0,751	0,033	0,694	0,072	0,604	0,100	0,455	0,093	0,428	0,032
5	$r_i = 0, 5$	0,793	0,045	0,534	0,089	0,269	0,143	0,088	0,073	0,077	0,072
	$r_i = 2$	0,841	0,060	0,564	0,117	0,202	0,106	0,117	0,074	0,106	0,075
	NSGA-II	0,654	0,029	0,384	0,073	0,307	0,085	0,381	0,094	0,409	0,027
6	$r_i = 0, 5$	0,720	0,056	0,355	0,055	0,149	0,029	0,032	0,013	0,010	0,001
	$r_i = 2$	0,719	0,040	0,391	0,046	0,244	0,124	0,030	0,004	0,015	0,008
	NSGA-II	0,647	0,025	0,540	0,034	0,438	0,073	0,318	0,056	0,311	0,033
7	$r_i = 0, 5$	0,640	0,033	0,468	0,082	0,229	0,051	0,139	0,074	0,076	0,071
	$r_i = 2$	0,623	0,055	0,400	0,059	0,127	0,036	0,019	0,007	0,016	0,007
	NSGA-II	0,653	0,028	0,384	0,073	0,304	0,083	0,373	0,093	0,401	0,027
8	$r_i = 0, 5$	0,719	0,033	0,382	0,041	0,213	0,096	0,030	0,006	0,009	0,001
	$r_i = 2$	0,709	0,022	0,329	0,027	0,142	0,017	0,031	0,005	0,010	0,003
	NSGA-II	0,611	0,016	0,440	0,022	0,326	0,042	0,249	0,016	0,272	0,027
9	$r_i = 0, 5$	0,662	0,023	0,389	0,058	0,224	0,064	0,097	0,085	0,046	0,072
	$r_i = 2$	0,648	0,036	0,378	0,019	0,218	0,021	0,213	0,055	0,045	0,059
	NSGA-II	0,653	0,024	0,545	0,035	0,443	0,073	0,320	0,057	0,312	0,033
10	$r_i = 0, 5$	0,679	0,068	0,474	0,112	0,238	0,078	0,135	0,063	0,116	0,082
	$r_i = 2$	0,680	0,019	0,394	0,059	0,194	0,034	0,113	0,075	0,093	0,089
	NSGA-II	0,649	0,025	0,541	0,034	0,439	0,073	0,318	0,056	0,311	0,033

Tabelle A.6: ZDT3-Funktion, Entwicklung des Abstands für Referenzpunkt-Paare

Generation		1		5		10		25		50	
Ref.	Konfig.	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $	$\overline{ \Delta \mathbf{f} }$	$\sigma \Delta \mathbf{f} $
1 & 6	$r_i = 0,5$	0,648	0,028	0,473	0,058	0,304	0,088	0,228	0,053	0,189	0,092
		0,693	0,047	0,570	0,098	0,342	0,127	0,278	0,145	0,242	0,175
	$r_i = 2$	0,631	0,026	0,419	0,044	0,251	0,095	0,186	0,075	0,129	0,073
		0,678	0,035	0,485	0,086	0,252	0,068	0,271	0,130	0,198	0,072
	NSGA-II	0,618	0,016	0,447	0,020	0,332	0,042	0,251	0,015	0,272	0,027
		0,647	0,025	0,540	0,034	0,438	0,073	0,318	0,056	0,311	0,033
2 & 7	$r_i = 0,5$	0,674	0,057	0,468	0,079	0,271	0,064	0,136	0,074	0,112	0,091
		0,681	0,054	0,444	0,102	0,278	0,049	0,137	0,042	0,121	0,061
	$r_i = 2$	0,671	0,017	0,414	0,025	0,222	0,048	0,107	0,035	0,125	0,060
		0,685	0,033	0,439	0,065	0,286	0,065	0,122	0,025	0,074	0,062
	NSGA-II	0,615	0,018	0,384	0,054	0,273	0,050	0,266	0,070	0,310	0,018
		0,653	0,028	0,384	0,073	0,304	0,083	0,373	0,093	0,401	0,027
3 & 8	$r_i = 0,5$	0,604	0,026	0,356	0,047	0,392	0,124	0,154	0,070	0,226	0,031
		0,627	0,039	0,462	0,050	0,303	0,075	0,180	0,039	0,111	0,156
	$r_i = 2$	0,617	0,044	0,348	0,051	0,285	0,111	0,181	0,066	0,195	0,083
		0,660	0,040	0,369	0,031	0,210	0,055	0,103	0,056	0,096	0,078
	NSGA-II	0,599	0,019	0,362	0,061	0,259	0,058	0,278	0,079	0,325	0,018
		0,611	0,016	0,440	0,022	0,326	0,042	0,249	0,016	0,272	0,027
4 & 9	$r_i = 0,5$	0,848	0,072	0,623	0,068	0,246	0,050	0,240	0,102	0,190	0,046
		0,717	0,060	0,460	0,053	0,136	0,059	0,110	0,132	0,082	0,086
	$r_i = 2$	0,823	0,056	0,634	0,120	0,373	0,173	0,155	0,025	0,136	0,050
		0,703	0,045	0,475	0,098	0,266	0,101	0,077	0,041	0,102	0,075
	NSGA-II	0,751	0,033	0,694	0,072	0,604	0,100	0,455	0,093	0,428	0,032
		0,653	0,024	0,545	0,035	0,443	0,073	0,320	0,057	0,312	0,033
5 & 10	$r_i = 0,5$	0,669	0,031	0,388	0,070	0,373	0,173	0,220	0,118	0,052	0,030
		0,715	0,060	0,533	0,078	0,394	0,107	0,428	0,113	0,571	0,024
	$r_i = 2$	0,660	0,036	0,408	0,073	0,417	0,180	0,452	0,178	0,340	0,164
		0,734	0,047	0,459	0,072	0,323	0,134	0,201	0,173	0,299	0,170
	NSGA-II	0,654	0,029	0,384	0,073	0,307	0,085	0,381	0,094	0,409	0,027
		0,649	0,025	0,541	0,034	0,439	0,073	0,318	0,056	0,311	0,033

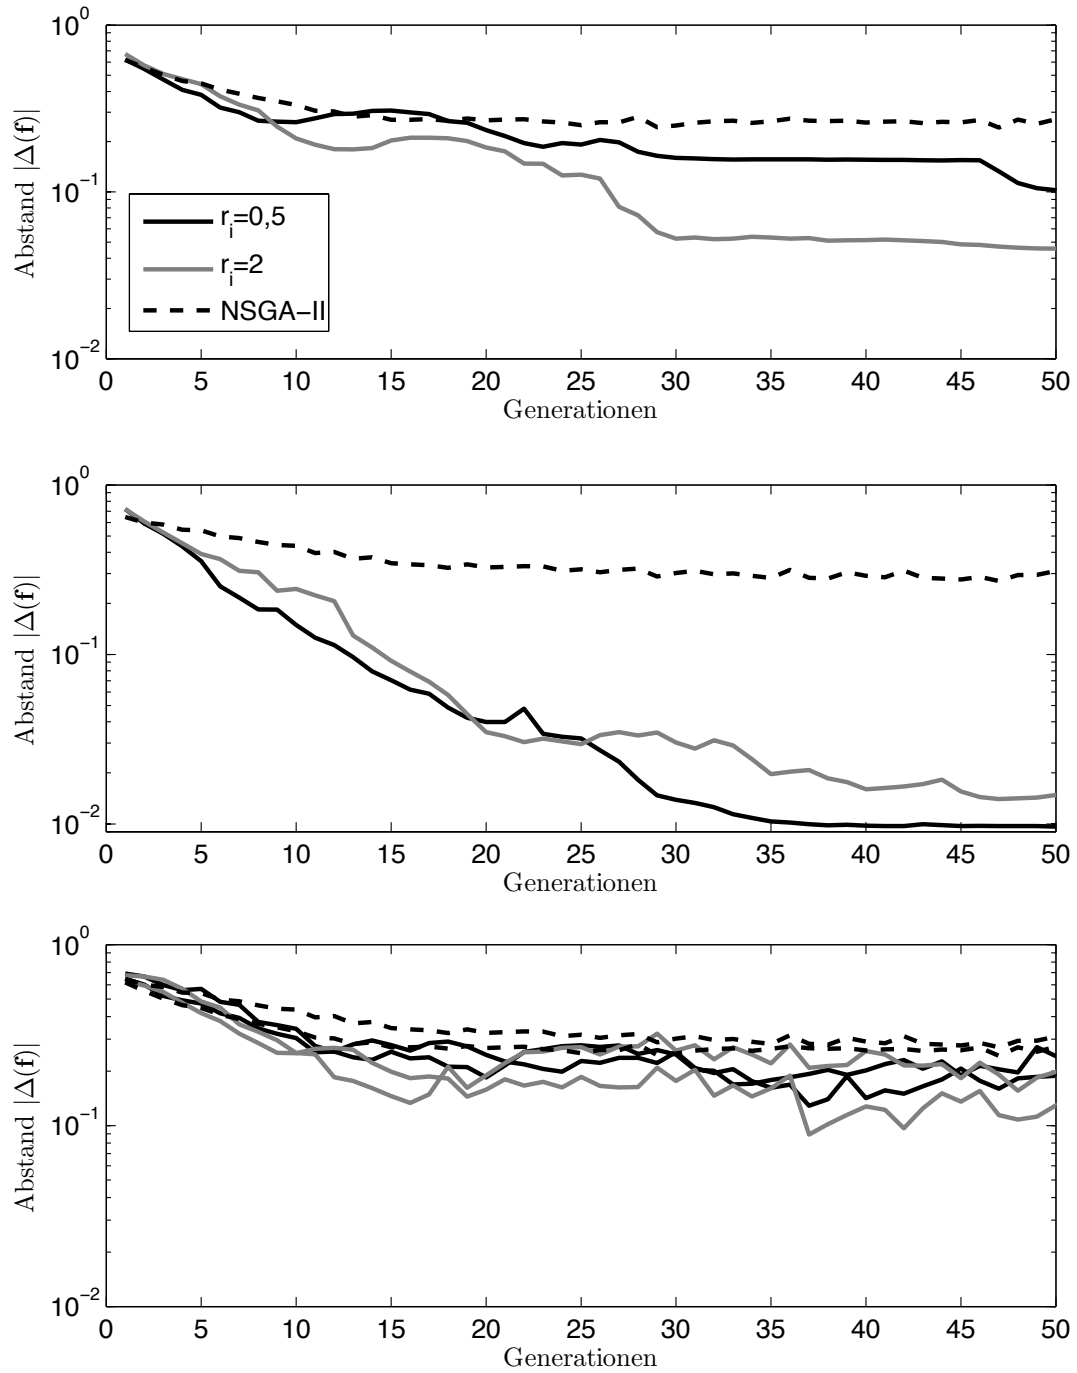


Bild A.6: Entwicklung des mittleren Abstands der Population zu jeweils den Referenzpunkten Ref_1 (oben), Ref_6 (mitte) oder Ref_1 & Ref_6 (unten) für die ZDT3-Funktion




Bild A.7: Entwicklung der Population im Kriterienraum für die ZDT3-Funktion und die zwei Referenzpunkte Ref_4 und Ref_9

Anhang B

HIL-Optimierung von Hydraulikventilreglern

B.1 Ergebnisse der MOEA-Optimierung

Die Reproduzierbarkeit der Ergebnisse aus Abschnitt 6.5.1 wird durch Tabelle B.1 charakterisiert. Die für den dort gezeigten (1) und fünf weitere (2 – 6) Optimierungsläufe ermittelte Lösungsmenge wird anhand der S-Metrik und der für jedes Kriterium ermittelten Maximal-, Minimal- und Mittelwerte verglichen. Es zeigt sich, dass die Ergebnisse im Wesentlichen vergleichbar sind und die Anwendung des MOEA zu reproduzierbaren Ergebnissen führt.

Tabelle B.1: Charakterisierung der Lösungsmenge der wiederholten MOEA-Optimierung eines Hydraulikventilreglers

	S-Metrik			$ISTE$			T_a		
		Min	Mean	Max	Min	Mean	Max		
1	8,82298E-06	0,0404	0,1084	0,3347	0,0048	0,0082	0,0120		
2	4,05926E-05	0,0399	0,1127	0,4878	0,0047	0,0082	0,0120		
3	6,87158E-06	0,0405	0,1002	0,3573	0,0047	0,0080	0,0120		
4	3,06803E-05	0,0407	0,0971	0,3088	0,0048	0,0080	0,0120		
5	1,51386E-04	0,0423	0,1199	0,2818	0,0051	0,0083	0,0120		
6	6,19926E-05	0,0435	0,1143	0,3415	0,0051	0,0086	0,0120		
	\ddot{U}_{GS}			\ddot{U}_{MS}			\ddot{U}_{KS}		
	Min	Mean	Max	Min	Mean	Max	Min	Mean	Max
1	0	0,0336	0,2446	0	0,0756	0,2000	0,0100	0,3830	1,9268
2	0	0,0438	0,2040	0	0,0774	0,1999	0,0126	0,5394	1,9890
3	0	0,0383	0,1547	0	0,0880	0,1988	0,0089	0,3845	1,8412
4	0	0,0496	0,2469	0	0,0864	0,2000	0,0069	0,5489	1,9640
5	0	0,0430	0,1475	0	0,0927	0,1997	0,0173	0,5859	1,9814
6	0	0,0408	0,2072	0	0,0786	0,1980	0,0119	0,3813	1,7596

B.2 Ergebnisse der interaktiven Optimierung

Für die in Abschnitt 6.5.2 gezeigte interaktive Optimierung mit einem künstlichen Entscheidungsmodell wird lediglich die Interaktionsrate $r_i = 2$ im Detail betrachtet. In Bild B.1 erfolgt ein Vergleich mit den anderen Interaktionsraten $r_i = 0,5$ und $r_i = 0,25$. In Bild ist für alle Interaktionsraten der minimale Abstand zur besten Lösung über den Verlauf der Optimierung dargestellt, als Vergleich dazu ist die Entwicklung dieses Abstandes während der ausschließlich dominanzbasierten Optimierung aufgetragen. Die Optimierung mit dem I-MOEA konvergiert interaktiv jeweils näher zum Referenzpunkt.




Bild B.1: Entwicklung des minimalen Abstandes zum Referenzpunkt im Kriterienraum für NSGA-II und verschieden konfigurierte interaktive Optimierungen

B.3 Robustheitsanalyse am Hydraulikprüfstand

Die folgenden Tabellen ergänzen die in Abschnitt 6.5.5 gezeigten Ergebnisse der Robustheitsuntersuchung ausgewählter Lösungen. Die ausgewählten Beispiellösungen sind in Bild 6.9 und in Bild 6.10 dargestellt. Für die Verteilung von 50 Bewertungen bei jeder Konfiguration der Betriebsparameter zeigen die Tabellen B.2 bis B.5 Mittelwert, Standardabweichung und Minimal- sowie Maximalwert für alle Bewertungskriterien.

Tabelle B.2: Für Beispiel-Ergebnis 2: Mittelwert, Standardabweichung, Minimum und Maximum für alle Kriterien bei verschiedenen Konfigurationen der Versuchsbedingungen

		$p_{hyd} = 0,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 100$	$p_{hyd} = 200,$ $q_{hyd} = 0$	$p_{hyd} = 200,$ $q_{hyd} = 100$
$ISTE$	\emptyset	0,13893	0,13896	0,13969	0,14323	0,14492
	σ	0,00270	0,00278	0,00187	0,00120	0,00227
	min	0,13344	0,13207	0,13412	0,13812	0,13713
	max	0,14325	0,14347	0,14306	0,14488	0,15043
T_a	\emptyset	0,00874	0,00858	0,00822	0,00808	0,00859
	σ	0,00011	0,00015	0,00011	0,00021	0,00092
	min	0,00849	0,00822	0,00797	0,00774	0,00770
	max	0,00897	0,00881	0,00837	0,00837	0,01077
\ddot{U}_{GS}	\emptyset	0,00000	0,00000	0,00000	0,00000	0,00000
	σ	0,00000	0,00000	0,00000	0,00000	0,00000
	min	0,00000	0,00000	0,00000	0,00000	0,00000
	max	0,00000	0,00000	0,00000	0,00000	0,00000
\ddot{U}_{MS}	\emptyset	0,00000	0,00003	0,00236	0,00144	0,01196
	σ	0,00000	0,00015	0,00177	0,00182	0,00242
	min	0,00000	0,00000	0,00016	0,00000	0,00697
	max	0,00000	0,00107	0,00553	0,00440	0,01657
\ddot{U}_{KS}	\emptyset	0,63297	0,63833	0,80444	0,82609	0,88863
	σ	0,02523	0,01649	0,04220	0,05672	0,04485
	min	0,58087	0,59000	0,73025	0,75375	0,67990
	max	0,70962	0,66662	0,88662	0,93575	0,98717

Tabelle B.3: Für Beispiel-Ergebnis 3: Mittelwert, Standardabweichung, Minimum und Maximum für alle Kriterien bei verschiedenen Konfigurationen der Versuchsbedingungen

		$p_{hyd} = 0,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 100$	$p_{hyd} = 200,$ $q_{hyd} = 0$	$p_{hyd} = 200,$ $q_{hyd} = 100$
$ISTE$	\emptyset	0,35793	0,35761	0,34214	0,36535	0,33615
	σ	0,00391	0,00360	0,00546	0,00394	0,00444
	min	0,34512	0,34306	0,32640	0,34899	0,32030
	max	0,36413	0,36325	0,34988	0,37489	0,34255
T_a	\emptyset	0,01593	0,01580	0,01363	0,01467	0,01278
	σ	0,00019	0,00012	0,00018	0,00056	0,00039
	min	0,01504	0,01540	0,01331	0,01338	0,01172
	max	0,01611	0,01604	0,01420	0,01554	0,01330
\ddot{U}_{GS}	\emptyset	0,00039	0,00051	0,00038	0,00074	0,00035
	σ	0,00026	0,00027	0,00018	0,00026	0,00019
	min	0,00007	0,00020	0,00014	0,00040	0,00000
	max	0,00087	0,00100	0,00074	0,00114	0,00094
\ddot{U}_{MS}	\emptyset	0,00373	0,00560	0,00997	0,00348	0,01389
	σ	0,00199	0,00326	0,00562	0,00188	0,00439
	min	0,00138	0,00183	0,00358	0,00183	0,00713
	max	0,00879	0,01270	0,02034	0,00969	0,02563
\ddot{U}_{KS}	\emptyset	0,02197	0,03028	0,06303	0,03317	0,10739
	σ	0,00404	0,00279	0,00694	0,00491	0,01086
	min	0,01588	0,02350	0,04713	0,02700	0,08302
	max	0,03750	0,03750	0,07910	0,04550	0,12910

Tabelle B.4: Für Beispiel-Ergebnis 4: Mittelwert, Standardabweichung, Minimum und Maximum für alle Kriterien bei verschiedenen Konfigurationen der Versuchsbedingungen

		$p_{hyd} = 0,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 100$	$p_{hyd} = 200,$ $q_{hyd} = 0$	$p_{hyd} = 200,$ $q_{hyd} = 100$
$ISTE$	\emptyset	0,15698	0,15677	0,15402	0,16317	0,16018
	σ	0,00218	0,00189	0,00219	0,00182	0,00203
	min	0,15212	0,14891	0,14801	0,15697	0,15360
	max	0,16152	0,15988	0,15735	0,16582	0,16477
T_a	\emptyset	0,00762	0,00762	0,00799	0,00788	0,00852
	σ	0,00007	0,00007	0,00008	0,00006	0,00012
	min	0,00751	0,00751	0,00782	0,00779	0,00823
	max	0,00774	0,00778	0,00814	0,00801	0,00891
\ddot{U}_{GS}	\emptyset	0,07137	0,07189	0,06794	0,06220	0,05065
	σ	0,00355	0,00106	0,00164	0,00269	0,00231
	min	0,06144	0,06946	0,06486	0,05533	0,04701
	max	0,07624	0,07483	0,07164	0,06664	0,05496
\ddot{U}_{MS}	\emptyset	0,05899	0,06448	0,07719	0,06256	0,08914
	σ	0,00426	0,00246	0,00294	0,00452	0,00372
	min	0,05144	0,06109	0,07076	0,05366	0,08277
	max	0,06548	0,06953	0,08110	0,06997	0,09734
\ddot{U}_{KS}	\emptyset	0,20296	0,20803	0,16521	0,18726	0,21163
	σ	0,00898	0,01033	0,00930	0,01262	0,01558
	min	0,18175	0,18525	0,14342	0,15869	0,17740
	max	0,22103	0,23694	0,19686	0,21580	0,24708

Tabelle B.5: Für Beispiel-Ergebnis 5: Mittelwert, Standardabweichung, Minimum und Maximum für alle Kriterien bei verschiedenen Konfigurationen der Versuchsbedingungen

		$p_{hyd} = 0,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 0$	$p_{hyd} = 100,$ $q_{hyd} = 100$	$p_{hyd} = 200,$ $q_{hyd} = 0$	$p_{hyd} = 200,$ $q_{hyd} = 100$
$ISTE$	\emptyset	0,12038	0,11865	0,11670	0,12205	0,11757
	σ	0,00239	0,00171	0,00185	0,00167	0,00171
	min	0,11499	0,11523	0,11153	0,11873	0,11229
	max	0,12511	0,12172	0,12017	0,12599	0,12067
T_a	\emptyset	0,00664	0,00649	0,00672	0,00651	0,00667
	σ	0,00014	0,00008	0,00013	0,00009	0,00007
	min	0,00633	0,00620	0,00650	0,00633	0,00647
	max	0,00687	0,00668	0,00694	0,00667	0,00681
\ddot{U}_{GS}	\emptyset	0,04802	0,05381	0,04790	0,06409	0,05359
	σ	0,00397	0,00343	0,00224	0,00434	0,00194
	min	0,04182	0,04866	0,04502	0,05616	0,05027
	max	0,05525	0,06008	0,05320	0,07115	0,05740
\ddot{U}_{MS}	\emptyset	0,10386	0,11530	0,12386	0,11290	0,12491
	σ	0,00283	0,00220	0,00853	0,00366	0,02111
	min	0,09746	0,11039	0,09749	0,10410	0,08136
	max	0,10829	0,12082	0,13932	0,11985	0,16119
\ddot{U}_{KS}	\emptyset	0,52990	0,54862	0,44490	0,49561	0,47621
	σ	0,01368	0,01458	0,01714	0,02280	0,02379
	min	0,50070	0,51902	0,40117	0,45047	0,42361
	max	0,55742	0,58386	0,47622	0,54378	0,53869

B.4 Der Versuchsaufbau

Das Hydraulik-Labor des Lehrstuhls für Regelungssystemtechnik der Technischen Universität Dortmund besteht aus einem hydraulischen Aufbau und einem schallgeschützten Auswerteraum mit Mess- und Simulationstechnik. Der hydraulische Aufbau, zu sehen in Bild B.2, besteht aus einem kompakten Versorgungsaggregat (hinten rechts) und einem Prüfstand mit Versuchsaufbauten (vorne in der Mitte). Der gesamte Aufbau befindet sich in Wannen, die im Fall einer kritischen Störung und Leckage das gesamte Ölvolumen auffangen und eine Beeinträchtigung der Umwelt verhindern. Die Anlage ist an die zentrale Kühlwasserversorgung der Universität angebunden und wird von einem zentralen Steuer-schrank aus kontrolliert und mit Strom versorgt.




Bild B.2: Fotografie des Hydrauliklabors

Der Versuchsaufbau, zu sehen in Bild B.3, ist in einem schlagfesten Kunststoffgehäuse untergebracht, um im Fall einer Störung die Gefährdung des Bedieners zu reduzieren. Im Versuchstisch befinden sich elektrische und hydraulische Anschlüsse für Ventile der Nenngrößen NG6, NG10 und NG16 in verschiedenen Konfigurationen. Zur Messung hydraulischer Größen stehen zwei Drucksensoren mit Messverstärker sowie ein weiterer kombinierter Druck- und Temperatursensor zur Verfügung, die mittels Messanschlüssen flexibel an verschiede-

nen Stellen der Versuchsaufbauten appliziert werden können.

Bild B.4 zeigt eine Detailaufnahme des Inneren des Gehäuses. Zu sehen sind der Anschlussblock mit dem Haupt- und dem Lastventil sowie der Druckspeicher zur Dämpfung von Druckstößen. Hinten rechts sieht man einen montierten Druck- und Temperatursensor sowie ein Gehäuse, das Leistungs- und Sensorelektronik der Schnittstelle zwischen Ventil und Echtzeitsystem enthält.

Die Messwerte der Sensoren sowie die Signale zur Kommunikation mit den Komponenten des Versuchs stehen über verschiedene analoge und digitale Leitungen im Auswerterraum zur Verfügung. In dem in Bild B.5 gezeigten Auswerterraum befinden sich Arbeitsplätze, von denen aus Optimierung und Anlage gesteuert werden können. Die zentrale Steuerung erfolgt über ein Echtzeitsystem, mit dem auch die Signale der Sensoren ausgewertet und aufgezeichnet werden und das als Rapid-Prototyping-System für Ventilregler dient. Als Echtzeitsystem kommt ein modulares dSpace-System zum Einsatz. Es besteht aus einer DS1006 Prozessoreinheit und weiteren Modulen für digitale Ein- und Ausgänge sowie D/A- und A/D-Wandlung. Der Aufbau des Labors und die verschiedenen Kommunikationswege sind in Bild 6.6 in Abschnitt 6.3 dargestellt.




Bild B.3: Fotografie des Versuchsaufbaus




Bild B.4: Fotografie des Versuchsaufbaus (Detailansicht)



144
Bild B.5: Fotografie des Auswerterraums mit Messtechnik

B.4.1 Details des hydraulischen Aufbaus

Der hydraulische Aufbau des Versuchs ist in Abschnitt 6.3.2 erläutert. Die Druckversorgung wird durch ein kompaktes Hydraulikaggregat hergestellt. Eine mit 45 kW Leistung angetriebene Axialkolbenpumpe mit einer maximalen Fördermenge von 100 l/min ist mit peripheren Komponenten in einem Gehäuse integriert. Um die Geräuschbelastung zu reduzieren, sind die relevanten Komponenten von dem 630 l fassenden Tank umgeben, was zu einer kompakten Bauform führt. Die Pumpe verfügt über eine elektronische Schwenkwinkelregelung, die den durch einen Messaufnehmer am Pumpenausgang erfassten Druck auf einem konstanten Sollwert im Bereich von 0 bis 250 bar hält, indem sie die dazu erforderliche Fördermenge einstellt. Die Begrenzung auf den Maximalwert des Drucks ist zusätzlich durch ein auch in Bild 6.7 dargestelltes und fest eingestelltes Druckbegrenzungsventil sichergestellt. Die Peripherie des Aggregates umfasst einen Füllstands- und einen Temperatursensor für den Tank, eine Umwälzpumpe mit Wärmetauscher, der an eine zentrale Kühlwasserversorgung angeschlossen ist, sowie überwachte Ölfilter im Rücklauf und im Umwälzkreis. Die Pumpenregelung sowie die Überwachung und Steuerung dieser Peripherie erfolgen über eine Anlagensteuerung mit einer SPS, die in einem Schaltschrank untergebracht ist und über Bedienelemente auch den manuellen Betrieb der Anlage ermöglicht. Der Zugriff auf Soll- und Istwert der Pumpendruckregelung sowie die Auswertung und Steuerung weiterer Betriebsgrößen des Aggregates erfolgen über eine Kommunikationsverbindung zwischen der Anlagensteuerung und der zentralen Versuchssteuerung.

Die Simulation variabler Lasten erfolgt über ein analog geregeltes Wegeventil, das wie in Bild 6.7 mit Verbindungen zwischen A und P sowie B und T versehen ist. In Abhängigkeit der Öffnung des Ventils ergibt sich bei einem Druck von 200 bar ein Volumenstrom, der als Kennlinie in Bild B.6 dargestellt ist und der Charakterisierung der Konstruktion zur Lastsimulation dient.




Bild B.6: Volumenstrom-Kennlinie des Lastventils bei 200 bar Systemdruck

Anhang C

Die MOrEA-Toolbox

Die MOrEA-Toolbox ist eine am Lehrstuhl für Regelungssystemtechnik der Technischen Universität Dortmund entwickelte Matlab-Toolbox zur multikriteriellen Optimierung von Regelungssystemen mit evolutionären Algorithmen. Das Bild C.1 zeigt die grafische Benutzerschnittstelle als zentrales Element, das Zugriff auf die meisten Funktionen der modular aufgebauten Software erlaubt. Diese modulare Implementierung ermöglicht es, verschiedene selbst entwickelte oder der Literatur entnommene Algorithmen zu realisieren und diese zu erweitern oder miteinander zu kombinieren.

Die gezeigte Schnittstelle erlaubt die Auswahl von zu verwendenden Software-Modulen für alle Komponenten des Algorithmus, deren Parametrierung und die Steuerung und Überwachung des Optimierungsprozesses. Aus den in einer Ordnerstruktur verfügbaren Komponenten wird für jeden Aspekt der Optimierung eine Auswahl von Optionen erzeugt und dem Anwender zur Auswahl angeboten. Das einfache und flexible Hinzufügen neuer Optimierungsprobleme, aber auch anderer Operatoren für zum Beispiel Initialisierung, Mutation, Rekombination oder Ranking und Selektion wird durch festgelegte Schnittstellen ermöglicht. Die Konfiguration dieser Operatoren wird über eine zentrale Datenstruktur verwaltet, in der alle für eine Optimierung und das Optimierungsproblem relevanten Informationen abgelegt sind. In Abschnitt D ist diese Datenstruktur für die in dieser Arbeit verwendeten Konfigurationen und Optimierungsprobleme dokumentiert.



Bild C.1: Grafische Benutzerschnittstelle der Optimierungstoolbox MOrEA

Neben den eigentlichen Optimierungsalgorithmen umfasst MOrEA Methoden und Funktionen zur Optimierung und Bewertung regelungstechnischer Probleme sowie der Anbindung realer Versuche zur HIL-Optimierung. Darüber hinaus bietet die Toolbox zahlreiche Visualisierungs- und Analysewerkzeuge für einzelne Lösungen oder Lösungsmengen.

Ein zentrales Werkzeug ist der *Pareto-Analyser*, der in Bild C.2 dargestellt ist. Dieser bietet verschiedene Möglichkeiten zur Analyse von Ergebnismengen und erlaubt es dem Anwender, interaktiv einzelne Lösungen auszuwählen und zu visualisieren und Lösungsmengen einzugrenzen, zu sortieren, zu vergleichen oder statistisch auszuwerten. Die in dieser Arbeit verwendeten Darstellungen von Lösungsmengen (zum Beispiel Bild 4.3, Bild 6.9 oder Bild 6.17) werden mittels dieser Schnittstelle konfiguriert und erzeugt. Das Analysewerkzeug ist elementarer Bestandteil des mit der Optimierung verknüpften Entscheidungsprozesses und ermöglicht es, Rückschlüsse über die Eignung oder Relevanz von Parametergrenzen, Kriterien, Nebenbedingungen oder Strategieparametern zu gewinnen und in die Optimierung zurückfließen zu lassen.

Anhang D

Verwendete Optimierungskonfigurationen

Die MOrEA-Toolbox verwendet zur Definition des zu optimierenden Problems eine Beschreibung in Form einer Datenstruktur mit Baumcharakter. Alle relevanten charakterisierenden Daten, also Populationsgrößen, Generationen, Parameteranzahl und -grenzen sowie die Kriterienzahl und mögliche Nebenbedingungen werden hier festgelegt. Die in der Optimierung zu verwendenden Operatoren und deren Parameter werden kodiert und darüber hinaus mögliche problemspezifische Parameter.

Die im Folgenden dokumentierten Konfigurationen sind auf die relevanten Einträge reduziert und ermöglichen es, die gezeigten Ergebnisse mit der MOrEA-Toolbox zu reproduzieren. Die in den jeweiligen Optimierungsexperimenten untersuchten und variierten Parameter sind mit dem Wert “?“, versehen. Die konkrete Wahl dieser Parameter ist in den entsprechenden Abschnitten oder Kapiteln behandelt.

D.1 PI-Regler (verwendet in Kapitel 5)

```
opt.evaluation.funcName = 'eval_PID_Controller';
opt.evaluation.parNumber = 2;
opt.evaluation.parRange = [0.001 0.001; ...
                           10 10];
opt.evaluation.parNames{1} = 'K_p';
opt.evaluation.parNames{2} = 'T_v';
opt.evaluation.objNumber = 2;
opt.evaluation.objNames{1} = 'MO';
opt.evaluation.objNames{2} = 'T_a';
opt.evaluation.tsample = 0.02;
opt.evaluation.numsample = 300;
opt.evaluation.PIDsys = tf([0 0 866.13643450434],...
                           [1 1070.86155449411 70861.5544941105],0);
opt.size.parents = 20;
opt.size.pop = 20;
opt.size.elite = 100;
opt.strategy.initPopulation = 'random_Initialization';
opt.strategy.mutation = 'NSGAIL_Mutate';
opt.strategy.recom = 'NSGAIL_SBX';
opt.strategy.selBase = 'Plus';
opt.strategy.selScheme = 'NSGAIL_CrowdingDistance';
opt.ranking.method = 'NSGAIL_Fast_Non_Dominated_Sorting';
opt.settings.stopCond = 'Fitness Tests';
opt.settings.stopValue = 2000;
opt.settings.runNumber = 30;
opt.system.codeVersion = 2320;
opt.system.matlabVersion = '7.12.0.635 (R2011a)';
%% Variierte Parameter
opt.evaluation.parameternoiseScale = ??;
opt.evaluation.signalnoiseScale = ??;
opt.evaluation.objectivenoiseScale = ??;
opt.evaluation.repeat = ??;
opt.evaluation.robMethod = ??;
```

D.2 Multikriterielle Ventilregler-Optimierung (verwendet in Kapitel 6)

```
opt.evaluation.funcName = 'eval_BR_Ventil';
opt.evaluation.objNumber = 5;
opt.evaluation.parNumber = 24;
opt.evaluation.objNames{1} = 'ISTE90';
opt.evaluation.objNames{2} = 'Tr';
opt.evaluation.objNames{3} = 'MO_GS';
opt.evaluation.objNames{4} = 'MO_MS';
opt.evaluation.objNames{5} = 'MO_KS';
opt.evaluation.constraint = [NaN 2 NaN; ...
                             NaN 0.012 NaN; ...
                             NaN 0.5 NaN; ...
                             NaN 0.20000000000000000001 NaN; ...
                             NaN 2 NaN];

opt.evaluation.parRange =
[10 0 0 0 0.0001 0.5 1 -3 0 0 0 0 0.0001 0.0001 1 ...
... -3 0 0.5 2.220e-016 15000000 -15000 -45000 -30000 -30000;
50 20 10 10 0.5 2 3 -1 100 25 20 20 0.200 2 3 -1 ...
... 0.5 10 10 30000000 -5000 -30000 -20000 -2.220e-016];
opt.evaluation.DelayPuffer = 0.005;
opt.evaluation.parkPos = -85;
opt.evaluation.Wartezeit = 0.200;
opt.evaluation.sequence =
[90 89.6 69 80 -85 -84.6 -86.6 -45 -85; ...
 0.100 0.030 0.030 0.025 0.100 0.030 0.025 0.035 0.035];
opt.evaluation.t_sample = 0.0001;
opt.evaluation.lengthSampData = 6500;
opt.evaluation.nrofsteps = 9;
opt.evaluation.ventilNG = 6;
opt.size.parents = 100;
opt.size.pop = 100;
opt.size.elite = 100;
opt.settings.stopCond = 'Generations';
opt.settings.stopValue = 50;
opt.strategy.initPopulation = 'random Initialization';
opt.strategy.mutation = 'NSGAIL_Mutate';
opt.strategy.recom = 'NSGAIL_SBX';
opt.strategy.selBase = 'Plus';
opt.strategy.selScheme = 'NSGAIL_CrowdingDistance';
opt.ranking.method = 'NSGAIL_Fast_Non_Dominated_Sorting';
opt.system.codeVersion = 2521;
```


D.3 Interaktive Ventilregler-Optimierung (verwendet in Kapitel 6)

```
opt.evaluation.funcName = 'eval_BR_Ventil';
opt.evaluation.objNumber = 5;
opt.evaluation.parNumber = 24;
opt.evaluation.objNames{1} = 'ISTE90';
opt.evaluation.objNames{2} = 'Tr';
opt.evaluation.objNames{3} = 'MO_GS';
opt.evaluation.objNames{4} = 'MO_MS';
opt.evaluation.objNames{5} = 'MO_KS';
opt.evaluation.constraint = [NaN 2 NaN; ...
                             NaN 0.012 NaN; ...
                             NaN 0.5 NaN; ...
                             NaN 0.200000000000000001 NaN; ...
                             NaN 2 NaN];

opt.evaluation.parRange =
[10 0 0 0 0.0001 0.5 1 -3 0 0 0 0 0.0001 0.0001 1 ...
... -3 0 0.5 2.220e-016 15000000 -15000 -45000 -30000 -30000;
50 20 10 10 0.5 2 3 -1 100 25 20 20 0.200 2 3 -1 ...
... 0.5 10 10 30000000 -5000 -30000 -20000 -2.220e-016];
opt.evaluation.DelayPuffer = 0.005;
opt.evaluation.parkPos = -85;
opt.evaluation.Wartezeit = 0.200;
opt.evaluation.sequence =
[90 89.6 69 80 -85 -84.6 -86.6 -45 -85; ...
0.100 0.030 0.030 0.025 0.100 0.030 0.025 0.035 0.035];
opt.evaluation.t_sample = 0.0001;
opt.evaluation.lengthSampData = 6500;
opt.evaluation.nrofsteps = 9;
opt.evaluation.ventilNG = 6;
opt.size.parents = 20;
opt.size.pop = 100;
opt.size.elite = 100;
opt.strategy.initPopulation = 'random_Initialization';
opt.strategy.mutation = 'NSGAIL_Mutate';
opt.strategy.recom = 'NSGAIL_SBX';
opt.strategy.selBase = 'Plus';
opt.strategy.selScheme = 'PairPreferenceSelection';
opt.ranking.method = 'NSGAIL_Fast_Non_Dominated_Sorting';
opt.settings.stopCond = 'Generations';
opt.settings.stopValue = 50;
opt.interaction.interRate = 2;
opt.interaction.MaxClusterNumber = 9;
```

```
opt.interaction.InitialNumberOfClusters = 2;
opt.interaction.MaxDecisionNumber = 1;
opt.interaction.realUser = 1;
opt.interaction.maxDBage = 0;
opt.interaction.selectPromisingCandidates = 1;
opt.interaction.RefPoint = [0.2298;
                             0.009228;
                             0.005625;
                             -9.0257e-005;
                             0.09819];
opt.system.codeVersion = 2518;
```

D.4 Optimierung von Benchmark-Funktionen (verwendet in Anhang A)

```
opt.evaluation.funcName = 'eval_FON';
opt.evaluation.parNumber = 7;
opt.evaluation.parRange = [-4 -4 -4 -4 -4 -4 -4; ...
                           4 4 4 4 4 4 4];
opt.evaluation.objNumber = 2;
opt.evaluation.objNames{1} = 'Kriterium f1';
opt.evaluation.objNames{2} = 'Kriterium f2';
opt.interaction.RefPoint =
[0.347 0.266 0.016 0.935 0.734 0.428 0.048 0.865 0.123 0.489; ...
 0.822 0.863 0.958 0.078 0.492 0.776 0.944 0.261 0.919 0.735];
opt.size.parents = 10;
opt.size.pop = 50;
opt.size.elite = 100;
opt.strategy.initPopulation = 'random_initialization';
opt.strategy.mutation = 'NSGAIIMutate';
opt.strategy.recom = 'NSGAIISBX';
opt.strategy.selBase = 'Plus';
opt.ranking.method = 'NSGAIIFastNonDominatedSorting';
opt.interaction.MaxClusterNumber = 9;
opt.interaction.InitialNumberOfClusters = 2;
opt.interaction.realUser = 0;
opt.interaction.maxDBage = 0;
opt.interaction.selectPromisingCandidates = 1;
opt.settings.stopCond = 'Fitness Tests';
opt.settings.stopValue = 5000;
opt.settings.runNumber = 5;
opt.system.codeVersion = 2467;
opt.system.matlabVersion = '7.8.0.347 (R2009a)';

%% Variierte Parameter
opt.interaction.interRate = ??;
opt.interaction.MaxDecisionNumber = ??;
opt.strategy.selScheme = ??;
```

Literaturverzeichnis

- [1] Marc Aurel. *Selbstbetrachtungen*. Herausgegeben von Alexander von Gleichen-Rußwurm. Deutsche Bibliothek, Berlin, 1857.
- [2] Raymond Kurzweil. *The singularity is near: when humans transcend biology*. A Penguin Book: Science. Viking, 2005.
- [3] Ingo Wegener. *Theoretische Informatik - eine algorithmenorientierte Einführung, 2. Auflage*. B.G. Teubner Verlag, 1999.
- [4] Charles Darwin. *On the Origin of Species*. John Murray, London, 1859.
- [5] Richard Dawkins. *Das egoistische Gen*. Spektrum Akademischer Verlag, Aug. 1994.
- [6] David Storch, Jan Zrzavý und Stanislav Mihulka. *Evolution - Ein Lese-Lehrbuch*. Springer, Sep. 2009.
- [7] Ingrid Gerdes, Frank Klawonn und Rudolf Kruse. *Evolutionäre Algorithmen*. Vieweg und Teubner, Juli 2004.
- [8] Ingo Rechenberg. *Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*. Frommann-Holzboog, 1973.
- [9] Hans-Paul Schwefel. “Evolutionsstrategie und numerische Optimierung”. Dissertation. TU Berlin, 1975.
- [10] John Henry Holland. *Adaption in natural and adaptive systems*. University of Michigan Press. Ann Arbor, 1975.
- [11] Kenneth A De Jong. “An analysis of the behavior of a class of genetic adaptive systems”. Dissertation. Ann Arbor: Univ. Michigan, 1975.
- [12] John Reed Koza. *Genetic programming: A paradigm for genetically breeding populations of computer programs to solve problems*. Technischer Bericht. 1990.
- [13] Lawrence J. Fogel, Al J. Owens und Michael J. Walsh. *Artificial Intelligence through Simulated Evolution*. New York, USA: John Wiley, 1966.
- [14] VDI-Fachbereich Produktentwicklung und Mechatronik. *VDI-Richtlinie 2206: Entwicklungsmethodik für mechatronische Systeme*. Beuth-Verlag GmbH, 2004.
- [15] Stephan Klotzbach, Stefan Oedekoven und Oliver Grassmann. “Optimierung im mechatronischen Entwicklungsprozess”. In: *5. VDI-Mechatroniktagung - Innovative Produktentwicklung*. Band 1753. 2003, Seiten 189–208.

- [16] Jan Braun, Johannes Krettek, Frank Hoffmann, Torsten Bertram, Horst Lausch und Georg Schoppel. “Struktur- und Parameteridentifikation mit Evolutionären Algorithmen”. In: *at - Automatisierungstechnik* 59.6 (Juni 2011), Seiten 340–352.
- [17] Jan Braun, Johannes Krettek, Frank Hoffmann und Torsten Bertram. “Structure and Parameter Identification of Nonlinear Systems with an Evolution Strategy”. In: *Proceedings of the 2011 IEEE Congress on Evolutionary Computation*. New Orleans, Apr. 2011, Seiten 1–8.
- [18] Lennart Ljung. *System identification*. Prentice Hall, 1999.
- [19] Paul Van den Hof. “Closed-loop issues in system identification”. In: *Annual reviews in control* 22 (Jan. 1998), Seiten 173–186.
- [20] Nikolaus Hansen und Andreas Ostermeier. “Adapting arbitrary normal mutation distributions in evolution strategies: the covariance matrix adaptation”. In: *Evolutionary Computation, 1996., Proceedings of IEEE International Conference on*. 1996, Seiten 312–317.
- [21] Carlos A Coello Coello, Gary B Lamont und David A Van Veldhuizen. *Evolutionary algorithms for solving multi-objective problems*. Springer-Verlag New York Inc, 2007.
- [22] Wolfgang Domschke und Andreas Drexl. *Einführung in Operations Research*. Springer, 2002.
- [23] Kalyanmoy Deb. *Multi-Objective Optimization Using Evolutionary Algorithms*. New York, USA: Wiley, 2001.
- [24] Carlos M Fonseca und Peter J Fleming. “An Overview of Evolutionary Algorithms in Multiobjective Optimization”. In: *Evolutionary Computation* 3.1 (Juli 1995), Seiten 1–16.
- [25] Carlos Artemio Coello Coello. “Evolutionary Multi-Objective Optimization: A Historical View of the Field”. In: *IEEE Computational Intelligence Magazine* (2006), Seiten 28–36.
- [26] Eckart Zitzler, Kalyanmoy Deb und Lothar Thiele. “Comparison of Multiobjective Evolutionary Algorithms: Empirical Results”. In: *Evolutionary Computation* 8.2 (2000), Seiten 173–195.
- [27] N Srinivas und Kalyanmoy Deb. “Multiobjective Optimization Using Nondominated Sorting in Genetic Algorithms”. In: *Evolutionary Computation* 2.3 (1994), Seiten 221–248.
- [28] Nicola Beume, Boris Naujoks und Günter Rudolph. “SMS-EMOA – Effektive evolutionäre Mehrzieloptimierung (SMS-EMOA – Effective Evolutionary Multiobjective Optimization)”. In: *at - Automatisierungstechnik* 56.7 (Juli 2008), Seiten 357–364.
- [29] Eckart Zitzler und Lothar Thiele. “Multiobjective optimization using evolutionary algorithms - A comparative case study”. In: *Parallel Problem Solving from Nature - PPSN V*. Herausgegeben von Agoston Eiben, Thomas Bäck, Marc Schoenauer und Hans-Paul Schwefel. Berlin/Heidelberg: Springer, 1998, Seiten 292–301.

- [30] Joshua D Knowles und David Corne. “Approximating the Nondominated Front Using the Pareto Archived Evolution Strategy.” In: *Evolutionary Computation* 8.2 (2000), Seiten 149–172.
- [31] Eckart Zitzler und Lothar Thiele. “Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach”. In: *IEEE Transactions on Evolutionary Computation* 3.4 (1999), Seiten 257–271.
- [32] Kalyanmoy Deb, Samir Agraval, Amrit Pratap und T Meyarivan. “A Fast Elist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II”. In: *Proceedings of the Parallel Problem Solving from Nature VI Conference*. Paris, 2000, Seiten 849–858.
- [33] David Wolpert und William G Macready. “No free lunch theorems for optimization.” In: *IEEE Transactions on Evolutionary Computation* 1.1 (1997), Seiten 67–82.
- [34] Ian C Parmee, Dragan Cvetkovic, A Watson und C Bonham. “Multiobjective Satisfaction within an Interactive Evolutionary Design Environment”. In: *Evolutionary Computation* 9.2 (2000), Seiten 197–222.
- [35] Jeffrey Horn. “Multicriterion decision making”. In: *Handbook of Evolutionary Computation*. Herausgegeben von Thomas Bäck, David Fogel und D Michalewicz. Oxford University Press, 1997, F1.9:1–F1.9:15.
- [36] Gerald W Evans. “An overview of techniques for solving multiobjective mathematical programs”. In: *Management Science* (1984), Seiten 1268–1282.
- [37] Jose C Ferreira, Carlos M Fonseca und Antonio Gaspar-Cunha. In: *Proceedings of the 9th annual conference on Genetic and evolutionary computation*. GECCO '07. London, England: ACM, 2007, Seiten 789–796.
- [38] Masahiro Tanaka und Tetsuzo Tanino. “Global optimization by the genetic algorithm in a multiobjective decision support system”. In: *Proceedings of the 10th International Conference on Multiple Criteria Decision Making*. Band 2. 1992, Seiten 261–270.
- [39] Tetsuzo Tanino, Masahiro Tanaka und Chihiro Hojo. “An interactive multicriteria decision making method by using a genetic algorithm”. In: *Proceedings of the Second International Conference on Systems Science and Systems Engineering (ICSSSE'93)*. 1993, Seiten 381–386.
- [40] Carlos M Fonseca und Peter J Fleming. “Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization”. In: *Proceedings of the Fifth International Conference on Genetic Algorithms* (1993), Seiten 416–423.
- [41] Kay Chen Tan, Eik Fun Khor, Tong Heng Lee und Ramasubramanian Sathikannan. “An Evolutionary Algorithm with Advanced Goal and Priority Specification for Multi-objective Optimization”. In: *Journal of Artificial Intelligence Research* 18 (Feb. 2003), Seiten 183–215.

- [42] Kalyanmoy Deb, J Sundar und Chaudhuri Shamik. “Reference Point Based Multi-Objective Optimization Using Evolutionary Algorithms”. In: *International Journal of Computational Intelligence Research* 2.3 (Mai 2006), Seiten 273–286.
- [43] Lothar Thiele, Kaisa Miettinen, Pekka J Korhonen und Julian Molina. “A Preference-Based Evolutionary Algorithm for Multi-Objective Optimization”. In: *Evolutionary Computation* 17.3 (2009), Seiten 411–436.
- [44] Ralph L. Keeney und Howard Raiffa. *Decisions with Multiple Objectives: Preferences and Value Tradeoffs*. New York, USA: Wiley, 1976.
- [45] Masahiro Tanaka, H Watanabe, Y Furukawa und Tetsuzo Tanino. “GA-based decision support system for multicriteria optimization”. In: *IEEE International Conference on Systems, Man and Cybernetics 1995* (1995).
- [46] Garrison W Greenwood, Xiaobo Hu und Joseph G D’Ambrosio. “Fitness Functions for Multiple Objective Optimization Problems: Combining Preferences with Pareto Rankings”. In: *FOGA* (1996), Seiten 437–455.
- [47] Jürgen Branke, Thomas Kauler und Hartmut Schneck. “Guidance in Evolutionary Multi-Objective Optimization”. In: *Advances in Engineering Software* 32 (2001), Seiten 499–507.
- [48] G. Meneghetti, Valentino Pediroda und Carlo Poloni. “Application of a Multi Objective Genetic Algorithm and a Neural Network to the optimisation of foundry processes.” In: *Evolutionary Algorithms in Engineering and Computer Science* (1999), Seiten 457–470.
- [49] Jorn Mehnen, Heike Trautmann und Ashutosh Tiwari. “Introducing user preference using Desirability Functions in Multi-Objective Evolutionary Optimisation of noisy processes”. In: *Proceedings of the 2007 IEEE Congress on Evolutionary Computation*. IEEE, Seiten 2687–2694.
- [50] Tobias Wagner und Heike Trautmann. “Integration of Preferences in Hypervolume-Based Multiobjective Evolutionary Algorithms by Means of Desirability Functions”. In: *IEEE Transactions on Evolutionary Computation* 14.5 (2010), Seiten 688–701.
- [51] Dragan Cvetkovic und Ian C Parmee. “Preferences and their application in evolutionary multiobjective optimization ”. In: *IEEE Transactions on Evolutionary Computation* 6.1 (2002), Seiten 42–56.
- [52] Dragan Cvetkovic und Ian C Parmee. “Use of Preferences for GA-based Multi-objective Optimisation.” In: *Proceedings of GECCO* (1999), Seiten 1504–1509.
- [53] Brahim Rekiek, Pierre De Lit und Fabrice Pellichero. “Dealing with user’s preferences in hybrid assembly lines design”. In: *Proceedings of the Management and Control of Productions and Logistics 2000 Conference*. 2000.

- [54] Silvere Massebeuf, Christian Fonteix, Laszlo N Kiss, I Marc, Fernand Pla und K Zaras. “Multicriteria optimization and decision engineering of an extrusion process aided by a diploid genetic algorithm”. In: *Proceedings of the 1999 IEEE Congress on Evolutionary Computation*. 1999.
- [55] Jean-Pierre Brans und Phillipe Vincke. “A Preference Ranking Organisation Method: (The PROMETHEE Method for Multiple Criteria Decision-Making)”. In: *Management Science* 31.6 (1985), Seiten 647–656.
- [56] Raphael Benayoun, Bernard Roy und B Sussmann. *ELECTRE: Une method pour guider le choix en presence de vues multiples*. Note de travail 49. Direction Scientifique, 1966.
- [57] Eduardo Fernandez, Edy Lopez, Sergio Bernal, Carlos A Coello Coello und Jorge Navarro. “Evolutionary multiobjective optimization using an outranking-based dominance generalization”. In: *Computers and Operation Research* 37.2 (Aug. 2009), Seiten 390–395.
- [58] Carlos A Coello Coello. “Handling Preferences in Evolutionary Multiobjective Optimization: A Survey”. In: *Proceedings of the 2000 IEEE Congress on Evolutionary Computation*. Piscataway, NJ. 2000, Seiten 30–37.
- [59] Dragan Cvetkovic und Carlos A Coello Coello. “Human Preferences and their Applications in Evolutionary Multi-Objective Optimisation”. In: *Knowledge Incorporation in Evolutionary Computation* (Juli 2005), Seiten 479–502.
- [60] Lily Rachmawati und Dipti Srinivasan. “Preference Incorporation in Multi-objective Evolutionary Algorithms: A Survey”. In: *Proceedings of the 2006 IEEE Congress on Evolutionary Computation* (2006), Seiten 3385–3391.
- [61] Madan Sathe, Günter Rudolph und Kalyanmoy Deb. “Design and validation of a hybrid interactive reference point method for multi-objective optimization”. In: *Proceedings of the 2008 IEEE Congress on Evolutionary Computation*. IEEE, 2008, Seiten 2909–2916.
- [62] Günter Rudolph. “On interactive evolutionary algorithms and stochastic mealy automata”. In: *Parallel Problem Solving from Nature — PPSN IV*. Springer Berlin / Heidelberg, 1996, Seiten 218–226.
- [63] Hideyuki Takagi und Miho Ohsaki. “Interactive Evolutionary Computation-Based Hearing Aid Fitting”. In: *IEEE Transactions on Evolutionary Computation* 11.3 (Mai 2007), Seiten 414–427.
- [64] Janos Madar, Janos Abonyi und Ferenc Szeifert. “Interactive evolutionary computation in process engineering”. In: *Computers and Chemical Engineering* (2005).
- [65] Bogdan Filipic und D Juricic. “An interactive genetic algorithm for controller parameter optimization”. In: *The International Conference on Artificial Neural Nets and Genetic Algorithms*. 1993, Seiten 458–462.

- [66] Hideyuki Takagi. “Interactive evolutionary computation: fusion of the capabilities of EC optimization and human evaluation”. In: *Proceedings of the IEEE* 89.9 (Sep. 2001), Seiten 1275–1296.
- [67] Johannes Krettek, Jan Braun, Frank Hoffmann und Torsten Bertram. “Preference modeling and model management for interactive multi-objective evolutionary optimization”. In: *IPMU’10: Proceedings of the 13th international conference on Information processing and management of uncertainty in knowledge based systems*. Springer-Verlag, Juni 2010, Seiten 574–583.
- [68] Johannes Krettek, Jan Braun, Frank Hoffmann und Torsten Bertram. “Interactive Incorporation of User Preferences in Multiobjective Evolutionary Algorithms”. In: *Advances in Intelligent and Soft Computing*. Herausgegeben von J. Mehnen, M. Köppen, A. Saad und A. Tiwari. Band 58. Applications of Soft Computing. Springer-Verlag, 2009, Seiten 379–388.
- [69] Johannes Krettek, Jan Braun, Frank Hoffmann und Torsten Bertram. “Benutzerpräferenzmodellierung zur interaktiven multiobjektiven evolutionären Optimierung”. In: *Proceedings of the 18. Workshop Computational Intelligence, GMA-FA 5.14*. Universitätsverlag Karlsruhe, 2008, Seiten 74–89.
- [70] Johannes Krettek, Jan Braun, Frank Hoffmann und Torsten Bertram. “Interactive Incorporation of User Preferences in Multiobjective Evolutionary Algorithms”. In: *Online World Conference on Soft Computing in Industrial Applications* (2008).
- [71] Eyke Hullermeier und Johannes Furnkranz. “Ranking by pairwise comparison a note on risk minimization”. In: *Proceedings of the 2004 IEEE International Conference on Fuzzy Systems*. Band 1. 2004, Seiten 97–102.
- [72] Eyke Hullermeier und Johannes Furnkranz. *Preference Learning: Models, Methods, Applications*. Technischer Bericht. 2003.
- [73] Mohieddine Jelali und Andreas Kroll. *Hydraulic Servo-systems. modelling, identification and control*. 1st Edition. Springer, 2003.
- [74] Barbara Ottersbach. “Dezentrale Strategieelemente für Evolutionsstrategien und Anwendung zum Reglerentwurf”. Dissertation. Technische Universität Dortmund, 2005.
- [75] Barbara Nicolaus, Harro Kiendl, W Blumendeller und U Schwane. “Evolutionary optimization of an Industrial Hydraulic valve with the help of a fuzzy performance index”. In: *Proceedings of the 10th IEEE International Conference on Fuzzy Systems, Melbourne, Australia*. 2001, Seiten 139–142.
- [76] Johannes Krettek, Daniel Schauten, Frank Hoffmann und Torsten Bertram. “Evolutionary hardware-in-the-loop optimization of a controller for cascaded hydraulic valves”. In: *2007 IEEE/ASME International Conference on Advanced Intelligent Mechatronics* (Aug. 2007), Seiten 1–6.

- [77] Johannes Krettek, Frank Hoffmann und Torsten Bertram. “Evolutionary Multi-objective Hardware-in-the-Loop Optimization of an Hydraulic Valve Controller”. In: *6th International Fluid Power Conference (IFK 2008), Dresden 2* (2008), Seiten 525–537.
- [78] Jan Braun, Johannes Krettek, Frank Hoffmann und Torsten Bertram. “Datenbasierte Modellunterstützung zur evolutionären Optimierung von Hydraulikventilreglern”. In: *7th International Fluid Power Conference (IFK 2010)*. Aachen, März 2010, Seiten 435–446.
- [79] Johannes Krettek, Jan Braun, Frank Hoffmann, Torsten Bertram, Thomas Ewald, Hans-Georg Schubert und Horst Lausch. “Interactive Evolutionary Multiobjective Optimization for Hydraulic Valve Controller Parameters”. In: *2009 IEEE/ASME International Conference on Advanced Intelligent Mechatronics* (Juni 2009), Seiten 816–821.
- [80] Jan Braun, Johannes Krettek, Frank Hoffmann und Torsten Bertram. “Automatisierter Entwurf von Hydraulikventilreglern: Eine Evolutionsstrategie für Optimierungsprobleme mit variabler Parameteranzahl”. In: *Proceedings of the 19th Workshop Computational Intelligence, GMA-FA 5.14*. Universitätsverlag Karlsruhe, Okt. 2009, Seiten 141–155.
- [81] Johannes Krettek, Jan Braun, Frank Hoffmann und Torsten Bertram. “A Three-Stage Evaluation Scheme for Safe and Efficient Hardware-in-the-Loop-Optimization of Hydraulic Valve Controllers”. In: *Scandinavian International Conference on Fluid Power*. Band 2. Tampere, Mai 2011, Seiten 327–340.
- [82] Johan Andersson. “Multiobjective Optimization in Engineering Design”. Dissertation. Linköpings University, Division of Fluid und Mechanical Engineering Systems, Mai 2001.
- [83] Adrian Trachte und Andreas Albrecht. “Hardware-in-the-Loop Simulation of Hydraulic Valves with Virtual Loads”. In: *at - Automatisierungstechnik* 60.3 (Jan. 2012), Seiten 168–176.
- [84] Indraneel Das und John E Dennis. “A closer look at drawbacks of minimizing weighted sums of objectives for Pareto set generation in multicriteria optimization problems”. In: *Structural and Multidisciplinary Optimization* 14.1 (1997), Seiten 63–69.
- [85] Michael Verleysen und D. François. “The curse of dimensionality in data mining and time series prediction”. In: *Computational Intelligence and Bioinspired Systems* (2005), Seiten 85–125.
- [86] Hisao Ishibuchi, Noritaka Tsukamoto und Yusuke Nojima. “Evolutionary Many-Objective Optimization”. In: *3rd International Workshop on Genetic and Evolving Fuzzy Systems* 1 (Feb. 2008), Seite 6.

- [87] Tobias Wagner, Nicola Beume und Boris Naujoks. “Pareto-, aggregation-, and indicator-based methods in many-objective optimization”. In: *Proceedings of the 4th international conference on Evolutionary multi-criterion optimization*. Band 4403. Lecture Notes in Computer Science. 2007, Seiten 742–756.
- [88] Heinz von Forster. *Kybernetik*. Merve, 1993.
- [89] Helmut Jungermann, Hans-Rüdiger Pfister und Katrin Fischer. *Die Psychologie der Entscheidung: Eine Einführung*. Springer, 2009.
- [90] Joe H Ward. “Hierarchical Grouping to Optimize an Objective Function”. In: *JSTOR: Journal of the American Statistical Association* 58.301 (1963), Seiten 236–244.
- [91] Trevor Hastie, Robert Tibshirani und Jerome Friedman. *Elements of Statistical Learning: data mining, inference, and prediction*. Springer Series in Statistics. Springer, 2009.
- [92] Frank Kursawe. “A Variant of Evolution Strategies for Vector Optimization”. In: *Parallel Problem Solving from Nature (Proceedings of PPSN)*. 1991, Seiten 193–197.
- [93] DIN EN 60027-6. *Formelzeichen für die Elektrotechnik - Teil 6: Steuerungs- und Regelungstechnik*. Norm. Feb. 2008.
- [94] Otto Föllinger. *Optimale Regelung und Steuerung*. Oldenbourg Wissenschaftsverlag, 1994.
- [95] Jan Lunze. *Regelungstechnik 1: Springer-Lehrbuch*. Springer, 2008.
- [96] DIN IEC 60050-351. *Internationales Elektrotechnisches Wörterbuch - Teil 351: Leittechnik*. Norm. Apr. 2009.
- [97] Chi-Keong Goh und Kay Chen Tan. “An Investigation on Noisy Environments in Evolutionary Multiobjective Optimization”. In: *IEEE Transactions on Evolutionary Computation* 11.3 (2007), Seiten 354–381.
- [98] Chi-Keong Goh und Kay Chen Tan. “Noise Handling in Evolutionary Multi-Objective Optimization”. In: *Proceedings of the 2006 IEEE Congress on Evolutionary Computation* (2006), Seiten 1354–1361.
- [99] Hans-Georg Beyer. “Evolutionary algorithms in noisy environments: theoretical issues and guidelines for practice”. In: *Computer Methods in Applied Mechanics and Engineering* 186.2-4 (Juni 2000), Seiten 239–267.
- [100] Hans-Georg Beyer und Bernhard Sendhoff. “Functions with noise-induced multimodality: a test for evolutionary robust Optimization-properties and performance analysis”. In: *IEEE Transactions on Evolutionary Computation* 10.5 (2006), Seiten 507–526.
- [101] Kalyanmoy Deb und Himanshu Gupta. “Searching for Robust Pareto-Optimal Solutions in Multi-objective Optimization”. In: *Proceedings of the 3rd International Conference on Evolutionary Multi-Criterion Optimization*. Band 3410. Lecture Notes in Computer Science. Springer, 2005, Seiten 150–164.

- [102] Anthony Di Pietro, Lyndon While und Luigi Barone. “Applying evolutionary algorithms to problems with noisy, time-consuming fitness functions”. In: *Proceedings of the 2004 IEEE Congress on Evolutionary Computation 2* (2004), Seiten 1254–1261.
- [103] Phillip D Stroud. “Kalman-extended genetic algorithm for search in nonstationary environments with noisy fitness evaluations”. In: *IEEE Transactions on Evolutionary Computation* 5.1 (März 2001), Seiten 66–77.
- [104] Iason Hatzakis und David Wallace. “Dynamic multi-objective optimization with evolutionary algorithms: a forward-looking approach”. In: *GECCO '06: Proceedings of the 8th annual conference on Genetic and evolutionary computation*. ACM, Juli 2006, Seiten 1201–1208.
- [105] Shankar Sastry und Marc Bodson. *Adaptive Control: Stability, Convergence and Robustness*. Dover Publications, 1989.
- [106] Hans-Paul Paul Schwefel. *Evolution and Optimum Seeking: The Sixth Generation*. New York, NY, USA: John Wiley & Sons, Inc., Aug. 1993.
- [107] Nikolaus Hansen und Andreas Ostermeier. “Completely Derandomized Self-Adaptation in Evolution Strategies”. In: *Evolutionary Computation* 9.2 (2001), Seiten 159–195.
- [108] Christin Igel, Nikolaus Hansen und Stefan Roth. “Covariance Matrix Adaptation for Multi-objective Optimization”. In: *Evolutionary Computation* 15.1 (März 2007), Seiten 1–28.
- [109] Yaochu Jin und Bernhard Sendhoff. “Trade-Off between Performance and Robustness: An Evolutionary Multiobjective Approach”. In: *Lecture Notes in Computer Science* 2 (2003), Seite 237.
- [110] Jan Braun, Johannes Krettek, Frank Hoffmann und Torsten Bertram. “Multi-Objective Optimization with Controlled Model Assisted Evolution Strategies”. In: *Evolutionary Computation* 17.4 (Dez. 2009), Seiten 577–593.
- [111] Jan Braun, Frank Hoffmann, Johannes Krettek und Torsten Bertram. “Multikriterielle Optimierung mit λ -geregelten modellgestützten Evolutionsstrategien”. In: *at - Automatisierungstechnik* 57 (2009), Seiten 115–128.
- [112] Yaochu Jin, Markus Olhofer und Bernhard Sendhoff. “A framework for evolutionary optimization with approximate fitness functions”. In: *IEEE Transactions on Evolutionary Computation* 6.5 (2002), Seiten 481–494.
- [113] R. Ewald, J. Hutter, D. Kretz, F. Liedhegener, W. Schenkel, A. Schmitt und M. Reik. *Proportional- und Servoventil-Technik*. Herausgegeben von Rudi A Lang. Der Hydraulik-Trainer, Band 2. Bosch Rexroth AG, 2003.
- [114] Datenblatt 4WRPEH6. *4/4-Regel-Wegeventile, direkt gesteuert, mit elektrischer Wegrückführung und integrierter Elektronik*. Bosch Rexroth AG. Okt. 2010.
- [115] DIN-ISO-1219-1. *Fluidtechnik - Graphische Symbole und Schaltpläne - Teil 1: Graphische Symbole für konventionelle und datentechnische Anwendungen*. Norm. Dez. 2007.

- [116] DIN ISO 1219-2. *Fluidtechnik - Graphische Symbole und Schaltpläne - Teil 2: Schaltpläne*. Norm. Nov. 1996.
- [117] Simon Huband, Phil Hingston, Luigi Barone und Lyndon While. “A Review of Multiobjective Test Problems and a Scalable Test Problem Toolkit”. In: *IEEE Transactions on Evolutionary Computation* 10.5 (Apr. 2006), Seiten 477–506.