

# Beitrag zur selbsteinstellenden Ladedruckregelung von aufgeladenen Ottomotoren

Dissertation

zur

Erlangung des Grades

Doktor-Ingenieur (Dr.-Ing.)

der Fakultät für Informatik und Elektrotechnik

der Universität Rostock

vorgelegt von

René Noack, geb. am 30.05.1978 in Hoyerswerda  
aus Senftenberg

Rostock 2018

**Gutachter:**

1. Gutachter Prof. Dr.-Ing. Torsten Jeinsch  
Institut für Automatisierungstechnik  
Universität Rostock
2. Gutachter Prof. Dr.-Ing. Steven X. Ding  
Institut für Automatisierungstechnik und Komplexe  
Systeme  
Universität Duisburg-Essen
3. Gutachter Prof. Dr.-Ing. Norbert Stoll  
Institut für Automatisierungstechnik  
Universität Rostock

Datum der Einreichung: 30. Juni 2017  
Datum der Verteidigung: 08. Mai 2018

# Vorwort

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter an der Fakultät für Informatik und Elektrotechnik der Universität Rostock und meiner vorherigen Tätigkeit als wissenschaftlicher Mitarbeiter an der Brandenburgischen Technischen Universität Cottbus-Senftenberg.

Mein außerordentlicher Dank gilt Herrn Prof. Dr.-Ing. T. Jeinsch, dem Leiter des Lehrstuhls für Regelungstechnik der Fakultät für Informatik und Elektrotechnik der Universität Rostock für die bereitwillige Betreuung, die fachliche Unterstützung meiner Arbeit und die stetige Förderung meiner Entwicklung. Er ermöglichte es mir, ein intensives Jahr in Warnemünde zu verbringen und so meine Promotion erfolgreich zu beenden.

Herrn Prof. Dr.-Ing. S. X. Ding möchte ich neben seinen fachlichen Anregungen vor allem für die Semester im Studium mit den Themen der Regelungstechnik danken, welche mir das Fachgebiet öffneten und mein Interesse weckten.

Herrn Dr.-Ing. W. Drewelow gilt mein Dank für seine Geduld und seine unermüdlichen Anregungen zur Fertigstellung meiner Arbeit.

Klaus Hauptvogel danke ich für seine Gründlichkeit beim Korrekturlesen.

Die Bearbeitung des Themas erfolgte in enger Zusammenarbeit mit der IAV GmbH in Gifhorn. Ihr danke ich für die Möglichkeit eine Theorie von der Idee bis zum praktischen Einsatz zu entwickeln. Die interessanten Diskussionen sowie die vielen Testfahrten im Fahrzeug waren wichtige Einflussfaktoren meiner Arbeit.

Bei allen Angehörigen des Lehrstuhls Regelungstechnik der Universität Rostock bedanke ich mich für die nette Aufnahme in meinem letzten Universitätsjahr, den interessanten fachlichen und nicht-fachlichen Diskussionen sowie auch den notwendigen außerberuflichen „Fachterminen“. Bei allen Angehörigen des Fakultät 5 der Brandenburgischen Technischen Universität Cottbus-Senftenberg bedanke ich mich für die angenehme Arbeitsatmosphäre und die Möglichkeit Erfahrungen auszutauschen.

Bedanken möchte ich mich bei meinen Eltern Ruth und Heinz Noack, die mir mein Studium ermöglichten und mich immer unterstützen.

Meiner Freundin Kathrin danke ich besonders. Ihre Geduld hat mir die Freiheit gegeben zu promovieren und Ihre Unterstützung die Energie sie zu beenden.

# Kurzfassung

In der Fahrzeugindustrie nimmt die Einstellung von Steuerungen, Regelungen und Diagnosefunktionen einen hohen Stellenwert ein. Von einer optimalen Einstellung verschiedener Parameter hängen wichtige Qualitätsmerkmale eines Fahrzeugs wie der Treibstoffverbrauch, die Antriebsleistung, der Fahrkomfort und die Abgasemissionen ab. Dabei bestehen die Algorithmen im Steuergerät häufig aus komplexen nichtlinearen Funktionen und die Applikation bzw. die Parametrierung dieser Funktionen erfordert einen hohen zeitlichen und finanziellen Aufwand, sowie großes Fachwissen der Applikationsingenieure. Je nach Funktion sind für die Ermittlung der optimalen Parameter verschiedene Versuche an Motorprüfständen und Messfahrten auf der Straße durchzuführen. Die zu applizierenden Parameter sind häufig als Kennlinien oder Kennfelder im Steuergerät abgelegt und bieten so die Möglichkeit nichtlineare Zusammenhänge abzubilden.

Die vorliegende Arbeit beschäftigt sich mit Verfahren zur automatisierten Einstellung bzw. Selbsteinstellung solcher Parameter. Die entwickelten Verfahren dienen zur Unterstützung der Applikation im Fahrzeug, sollen die Applikationszeit reduzieren und die Einstellung der Parameter erleichtern. Der verfolgte Ansatz baut auf der Theorie der iterativ lernenden Regelung (ILR) auf und ermöglicht so eine signalbasierte Vorgehensweise ohne zusätzlichen Modellierungsaufwand. Es ist notwendig, die bestehenden Verfahren der ILR zu erweitern, um sie zur Bestimmung von Parametern vorgegebener Regelungsstrukturen zu verwenden. Nach den durchgeführten Messfahrten liegt dann als Ergebnis ein optimierter Parametervektor für das Steuergerät vor.

Als Referenzprozess dient in dieser Arbeit die Aufladung eines Ottomotors durch einen Abgasturbolader mit pneumatischem Wastegate. An diesem Prozess erfolgt die simulative und experimentelle Anwendung der entwickelten Verfahren und demonstriert damit die Funktionalität und das Potential einer ILR-basierten Selbsteinstellung von Parametern.

## Abstract

In the automotive industry, the tuning of controls, regulations and diagnostic functions plays an important role. The quality characteristics of a vehicle, like the fuel consumption, the driving performance, the comfort or the exhaust emissions depends on the optimal setting of various parameters. The algorithms of the control unit of the vehicle often consists of complex nonlinear functions. The tuning of these parameters require a high degree of time and money as well as great expertise of application engineers. These

---

parameterization requires various tests on engine test benches or test drives on the road. These tuning parameters are often stored as characteristic curves or characteristic fields in the control unit.

The present thesis is concerned with the self-tuning of such parameters. The developed methods and algorithms are used to support the application of the vehicle parameters. The aim is to reduce the application time and costs. The proposed approaches are based on the theory of iterative learning control (ILC). It allows a data-based approach without additional modeling effort. The ILC-based methods are further combined with various methods for parameter optimization. The result is an optimized parameter vector for the control unit of the vehicle.

The reference process of this thesis is the charging of a gasoline engine with a turbocharger and a pneumatic wastegate. In this reference process the simulative and experimental tests of the developed methods is carried out. It demonstrate the functionality and the potential of an ILR-based self-tuning of parameters.

# Inhaltsverzeichnis

<b>Kurzfassung</b>	<b>IV</b>
<b>Abbildungsverzeichnis</b>	<b>IX</b>
<b>Abkürzungsverzeichnis</b>	<b>XII</b>
<b>Symbolverzeichnis</b>	<b>XIII</b>
<b>1. Einleitung</b>	<b>1</b>
<b>2. Verfahren zur Selbsteinstellung</b>	<b>5</b>
2.1. Aufgabe des Selbsteinstellungsverfahrens . . . . .	5
2.2. Beschreibung und Analyse bestehender Verfahren zur Selbsteinstellung von Regelungsparametern . . . . .	6
2.2.1. Iterative Feedback Tuning . . . . .	6
2.2.2. Virtual Reference Feedback Tuning . . . . .	8
2.2.3. Fictitious Reference Iterative Tuning . . . . .	10
2.2.4. Model Free Adaptive Control . . . . .	11
2.2.5. Control Performance Monitoring . . . . .	12
2.3. Iterativ lernende Regelung . . . . .	14
2.3.1. Einführende Festlegungen zu Signalen und Systemen . . . . .	16
2.3.2. Eigenschaften einer ILR . . . . .	23
2.3.3. ILR-Entwurfsverfahren . . . . .	29
<b>3. Die Aufladung von Ottomotoren</b>	<b>43</b>
3.1. Der einfach aufgeladene Ottomotor mit Abgasturbolader . . . . .	43
3.2. Systembeschreibung . . . . .	45
3.3. Die Ladedruckregelung (LDR) im Steuergerät . . . . .	51
3.3.1. Vorsteuerung der LDR . . . . .	52
3.3.2. PI-Regler der LDR . . . . .	54
3.4. Anforderungen des Prozesses an das selbsteinstellende Verfahren . . . . .	55
<b>4. Entwicklungen von ILR-basierten Verfahren zur Selbsteinstellung</b>	<b>57</b>
4.1. Diskussion zur Aufgabenstellung . . . . .	57
4.2. Erste Erweiterung zum ILR-basierten Selbsteinstellungsverfahren - Vari- ante I . . . . .	61
4.2.1. Variante I für Vorsteuerungen . . . . .	64
4.2.2. Variante I für Regler . . . . .	67

4.3.	Zweite Erweiterung zum ILR-basierten Selbsteinstellungsverfahren - Variante II . . . . .	69
4.3.1.	Variante II für Vorsteuerungen . . . . .	72
4.3.2.	Variante II für Regelungen . . . . .	73
4.4.	Vergleich der Variante I und der Variante II . . . . .	75
4.5.	Optimierung der Parameter . . . . .	75
<b>5.</b>	<b>Einsatz der entwickelten Verfahren am Prozess der Ladedruckregelung</b>	<b>77</b>
5.1.	Beschreibung der Testobjekte . . . . .	77
5.1.1.	Aufgeladener Ottomotor . . . . .	77
5.1.2.	BLDC-Motorprüfstand . . . . .	78
5.2.	Anwendung des ILR-basierten Selbsteinstellungsverfahrens - Variante I .	79
5.2.1.	Anwendung für die stationäre Vorsteuerung der LDR . . . . .	79
5.2.2.	Anwendung für die dynamische Vorsteuerung der LDR . . . . .	81
5.2.3.	Anwendung für den Regler der LDR . . . . .	81
5.2.4.	Anwendung für den Regler des BLDC-Motorprüfstandes . . . . .	82
5.3.	Anwendung des ILR-basierten Selbsteinstellungsverfahrens - Variante II	83
5.3.1.	Anwendung für die stationäre Vorsteuerung der LDR . . . . .	83
5.3.2.	Anwendung für die dynamische Vorsteuerung der LDR . . . . .	85
5.3.3.	Anwendung für den Regler der LDR . . . . .	89
5.3.4.	Anwendung für den Regler des BLDC-Motorprüfstandes . . . . .	90
<b>6.</b>	<b>Simulative und experimentelle Ergebnisse</b>	<b>92</b>
6.1.	Simulationsbedingungen . . . . .	92
6.1.1.	Simulationsbedingungen beim aufgeladenen Ottomotor . . . . .	92
6.1.2.	Simulationsbedingungen beim BLDC-Motorprüfstand . . . . .	95
6.2.	Simulationen zum ILR-basierten Selbsteinstellungsverfahren - Variante I	95
6.2.1.	Einstellung der stationären Vorsteuerung der LDR . . . . .	96
6.2.2.	Einstellung der dynamischen Vorsteuerung der LDR . . . . .	97
6.2.3.	Einstellung des Reglers der LDR . . . . .	98
6.2.4.	Einstellung des Reglers des BLDC-Motorprüfstandes . . . . .	99
6.3.	Simulationen zum ILR-basierten Selbsteinstellungsverfahren - Variante II	100
6.3.1.	Einstellung der stationären Vorsteuerung der LDR . . . . .	100
6.3.2.	Einstellung der dynamischen Vorsteuerung der LDR . . . . .	101
6.3.3.	Einstellung des Reglers der LDR . . . . .	102
6.3.4.	Einstellung des Reglers des BLDC-Motorprüfstandes . . . . .	104
6.4.	Tests im Fahrzeug und am BLDC-Motorprüfstand . . . . .	105
6.4.1.	Darstellung der Fahrversuche . . . . .	105
6.4.2.	Realisierung von Variante II für die stationäre Vorsteuerung der LDR . . . . .	105
6.4.3.	Realisierung von Variante II für die dynamische Vorsteuerung der LDR . . . . .	107
6.4.4.	Realisierung von Variante II für den Regler des BLDC-Motorprüfstandes . . . . .	108
6.5.	Diskussion und Bewertung . . . . .	109

<b>7. Zusammenfassung und Ausblick</b>	<b>113</b>
<b>A. Ergänzungen zum Kapitel 3</b>	<b>115</b>
<b>B. Diagramme</b>	<b>119</b>
<b>Literaturverzeichnis</b>	<b>126</b>
<b>Publikationsliste</b>	<b>132</b>
<b>Thesen</b>	<b>133</b>

# Abbildungsverzeichnis

2.1. Konzept eines adaptiven Regelkreises [Aström, 1995, S.2] . . . . .	6
2.2. Darstellung des geschlossenen Regelkreises [Hjalmarsson et al., 1998, S.28] . . . . .	7
2.3. Prinzipabbildung des VRFT (gestrichelt ist der virtuelle Teil) . . . . .	9
2.4. Darstellung der Pseudo-Partiellen-Ableitung (PPD) . . . . .	11
2.5. Schema der iterativen Regleroptimierung mittels CPM . . . . .	13
2.6. Regelungsschema der ILR . . . . .	15
2.7. Dreidimensionale Darstellung der Eingangs-Ausgangs-Matrix $\mathbf{G}$ des Impulsantwortmodells . . . . .	18
2.8. Dreidimensionale Darstellung der Eingangs-Ausgangs-Matrix $\mathbf{G}$ bei ver-rauschtem Ausgangssignal . . . . .	22
2.9. Parametrische ILR-Darstellung [Rockel and Konigorski, 2007, S.121] . . . . .	24
2.10. Strukturabbild einer Zustandsregelung . . . . .	25
2.11. Generalisierte parametrische Darstellung einer iterativ lernenden Rege-lung [Rockel and Konigorski, 2007, S.121] . . . . .	28
2.12. Zyklusbasierte Darstellung der erweiterten Struktur einer iterativ lernenden Regelung mit zusätzlichem Regler [Norrlöf, 2000, S.42] . . . . .	28
2.13. Parametrische Darstellung der erweiterten Struktur einer ILR mit zusätz-lichem Regler [Rockel and Konigorski, 2007, S.123] . . . . .	29
2.14. Darstellung der Entwicklung eines P-ILR-Typs mit verschiedenen Lern-faktoren an einem linearen und zeitinvarianten System erster Ordnung . . . . .	31
2.15. Vergleich der inversionsbasierten ILR . . . . .	37
2.16. Vergleich der MFAC-basierten ILR . . . . .	39
2.17. Darstellung der kontinuierlichen Impulsantwort und der diskreten Impul-santwortfolge eines Gauß-Filters . . . . .	40
2.18. Darstellung eines Q-Filters basierend auf dem Gauß-Filterentwurf . . . . .	41
3.1. Aufbau eines einfach aufgeladenen Ottomotors mit Abgasturbolader . . . . .	44
3.2. Verallgemeinerte Struktur der Ladedruckregelung . . . . .	51
3.3. Skizzierter Verlauf der vorgesteuerten LDR-Stellgröße . . . . .	53
3.4. Korrekturkennfeld, stationäre Vorsteuerung . . . . .	53
3.5. Korrekturkennfeld, dynamische Vorsteuerung . . . . .	54
3.6. Kennlinie der Reglerparameter . . . . .	54
4.1. Darstellung der Regelungsstruktur . . . . .	57
4.2. Allgemeine Struktur des Verfahrens . . . . .	60
4.3. Ablauf des ILR-basierten Selbsteinstellungsverfahrens: Variante I . . . . .	62
4.4. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante I für Vorsteuerungen . . . . .	65

4.5. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante I für Regler . . . . .	67
4.6. Zuordnung der Signalverläufe (ILR-basierten Selbsteinstellungsverfahren für Regler) . . . . .	68
4.7. Ablauf des ILR-basierten Selbsteinstellungsverfahrens: Variante II . . . . .	70
4.8. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante II für Vorsteuerungen . . . . .	72
4.9. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante II für Regler . . . . .	74
5.1. Struktur des Simulationsmodells . . . . .	77
5.2. Einordnung des Korrekturkennfeldes der stationären LDR-Vorsteuerung	80
5.3. Fläche $A_k$ . . . . .	85
6.1. Simulation einer Vollastbeschleunigung . . . . .	93
6.2. Simulation einer Teillastbeschleunigung . . . . .	93
6.3. Simulation einer Fahrt auf dem Rollenprüfstand (I) . . . . .	94
6.4. Simulation einer Fahrt auf dem Rollenprüfstand (II) . . . . .	95
6.5. Simulationsbeispiel des BLDC-Motorprüfstandes . . . . .	96
6.6. Simulationsergebnis der Variante I für das stationäre Kennfeld (ohne Variation) . . . . .	97
6.7. Simulationsergebnis der Variante I für die dynamische Vorsteuerung . . . . .	98
6.8. Simulationsergebnis der Variante I für den Regler (AP1, ohne Messrauschen) . . . . .	99
6.9. ILR-Parametereinstellung am BLDC-Prüfstand (Simulation Variante I) . . . . .	100
6.10. Simulationsergebnis der Variante II für das stationäre Kennfeld (ohne Variation) . . . . .	101
6.11. Simulationsergebnis der Variante II für die dynamische Vorsteuerung (ohne Variation) . . . . .	102
6.12. Simulationsergebnis der Variante II für die dynamische Vorsteuerung (mit Messrauschen und zufälligen Startbedingungen (I)) . . . . .	103
6.13. Simulationsergebnis der Variante II für den Regler (AP1, ohne Messrauschen) . . . . .	103
6.14. ILR-Parametereinstellung am BLDC-Prüfstand (Simulation der Variante II) . . . . .	104
6.15. Beispielmessung für eine Straßenfahrt des Testfahrzeugs . . . . .	106
6.16. ILR-Parametereinstellung der stationären Vorsteuerung . . . . .	106
6.17. Trend der ILR-Parametereinstellung bei unterschiedlichen Startparametern	107
6.18. ILR-Parametereinstellung der dynamischen Vorsteuerung (I) . . . . .	107
6.19. ILR-Parametereinstellung der dynamischen Vorsteuerung (II) . . . . .	108
6.20. ILR-Parametereinstellung am BLDC-Prüfstand . . . . .	109
B.1. Darstellung der Entwicklung der Stell- und Regelgröße einer ILR . . . . .	119
B.2. Darstellung der Systemantwort auf einen diskreten Einheitsimpuls . . . . .	119
B.3. Darstellung von ILR mit Q-Filter und Messrauschen . . . . .	120

B.4. Simulationsergebnis der Variante I für das stationäre Kennfeld (mit Messrauschen) . . . . .	121
B.5. Simulationsergebnis der Variante I für das stationäre Kennfeld (mit Variation des Startparametervektors) . . . . .	121
B.6. Simulationsergebnis der Variante I für den Regler (AP1, mit Messrauschen)	122
B.7. Simulationsergebnis der Variante I für den Regler (AP2, mit Messrauschen)	122
B.8. Simulationsergebnis der Variante II für das stationäre Kennfeld (mit Messrauschen) . . . . .	123
B.9. Simulationsergebnis der Variante II für das stationäre Kennfeld (mit Variation der Startbedingungen) . . . . .	123
B.10. Simulationsergebnis der Variante II für das stationäre Kennfeld (mit Variation des Startparametervektors) . . . . .	124
B.11. Simulationsergebnis der Variante II für die dynamische Vorsteuerung (mit Messrauschen und zufälligen Startbedingungen (II)) . . . . .	124
B.12. Simulationsergebnis der Variante II für den Regler (AP1, mit Messrauschen)	125
B.13. Simulationsergebnis der Variante II für den Regler (AP2, mit Messrauschen)	125

# Abkürzungsverzeichnis

1DoF	Regler mit einem Freiheitsgrad (1-Degree of Freedom)
2DoF	Regler mit zwei Freiheitsgraden (2-Degree of Freedom)
ATL	Abgasturbolader
BLDC	Brushless DC Motor
CCF-ILC	Current-Cycle Feedback ILC
CFDL	Compact Form Dynamic Linearization
CITE-FB	Current-Iteration Tracking Error ILC
CPM	Control Performance Monitoring
FFDL	Full Form Dynamic Linearization
FRIT	Fictitious Reference Iterative Tuning
IAE	Integral des absoluten Regelfehlers
IFT	Iterative Feedback Tuning
ILC	Iterative Learning Control
ILR	Iterative Lernende Regelung
LDR	Ladedruckregelung
MFAC	Model Free Adaptive Control
MFAILC	Model Free Adaptive Iterative Learning Control
MIMO	Multiple Input Multiple Output
PFDL	Partial Form Dynamic Linearization
PPD	Pseudo Partial Derivative
SISO	Single Input Single Output
VRFT	Virtual Reference Feedback Tuning

# Symbolverzeichnis

$\alpha$	Mittelungswert der Ableitung, PD-ILR
$\alpha_{DK}$	Stellgröße Drosselklappenwinkel
$l_D$	Lernfaktor D-ILR
$l_P$	Lernfaktor P-ILR
$\delta(\mathbf{u}_k)$	Änderung der ILC-Stellgröße
$\delta_{k+1}$	Richtungsvektor der Stellgrößenänderung (robuster ILR-Ansatz)
$\epsilon_{k+1}$	Skalierungsfaktor der Stellgrößenänderung (robuster ILR-Ansatz)
$\eta$	ILR, allgemeiner Wichtungsfaktor
$\eta_{Motor}$	Gesamtwirkungsgrad Motor
$\eta_{LLK}$	Wirkungsgrad Ladeluftkühler
$\eta_T$	Wirkungsgrad Turbine
$\eta_V$	Wirkungsgrad Verdichter
$\lambda$	Wichtungsfaktor
$\lambda_A$	Luftaufwand
$\lambda_L$	Luftverhältnis
$\lambda_{l,L}$	Liefergrad
$\kappa$	Isentropenexponent
$\mu$	Wichtungsfaktor
$\mu_D$	Durchflussbeiwert
$\Pi_T$	Turbinendruckverhältnis
$\Pi_V$	Verdichterdruckverhältnis
$\rho$	Reglerparametervektor
$\hat{\rho}$	Reglerparametervektor, Optimierungsergebnis
$\rho_t$	Parameter dynamische Vorsteuerung
$\rho_{Luft}$	Dichte Luft
$\rho_{Abgas}$	Dichte Abgas
$\phi_C(i)$	MFAC, realer PPD, CFDL-Ansatz
$\hat{\phi}_C(i)$	MFAC, geschätzter PPD, CFDL-Ansatz
$\Phi_G$	allgemeine Funktion des Systems
$\Phi_{ILR}$	allgemeine Funktion des ILR-Lerngesetzes
$\Omega$	Optimierungsziel, allgemein
$\omega_{ATL}$	Kreisfrequenz Abgasturbolader
<b>A</b>	Systemmatrix
$A_{bez}$	geometrischer Bezugsquerschnitt
<b>B</b>	Eingangsmatrix

$\mathbf{C}$	Ausgangsmatrix
$\mathbf{C}_R$	Eingangs-Ausgangs-Matrix des Reglers
$C_R$	Funktion des Reglers
$\mathbf{C}_V$	Eingangs-Ausgangs-Matrix der Vorsteuerung
$C_V$	Funktion der Vorsteuerung
$\Delta\mathbf{C}_a$	additiver Modellunsicherheit der Regelungsstruktur
$\Delta\mathbf{C}_m$	multiplikative Modellunsicherheit der Regelungsstruktur
$C_r(z)$	diskreter Regler (2DoF), Vorfilter
$C_y(z)$	diskreter Regler (2DoF), Rückführung
$C(z)$	diskrete Reglerübertragungsfunktion
$\mathbf{D}$	Durchgangsmatrix
$F(z)$	Filter, diskret
$\mathbf{G}$	Eingangs-Ausgangs-Matrix des Systems
$G(z)$	diskrete Übertragungsfunktion des Prozesses
$H_A$	Abgasenthalpie
$H_E$	Enthalpie der angesaugten Luft
$\mathbf{H}_\alpha$	Matrix der PD-ILR-Entwurfsgleichung
$H_u$	unterer Heizwert
$J_{ATL}$	Trägheitsmoment Abgasturbolader
$J$	Gütekriterium, Optimierungsfunktion
$L_{min}$	Mindestluftbedarf
$\mathbf{L}$	Lernoperator
$M$	Drehmoment
$N$	Anzahl der Abtastwerte
$P_e$	effektive Leistung
$P_T$	Turbinenleistung
$P_V$	Verdichterleistung
$\mathbf{Q}$	Lernoperator, Q-Filter
$R$	allgemeine Gaskonstante
$T_{KM}$	Temperatur Kühlmittel (LLK)
$T_{VWG}$	Stellgröße Tastverhältnis Wastegate
$\mathbf{T}_\alpha$	Transformationsmatrix
$T_{bez}$	Bezugstemperatur ATL-Vermessung
$T_{nLLK}$	Temperatur nach Ladeluftkühler
$T_{nT}$	Temperatur nach Turbine
$T_{nV}$	Temperatur nach Verdichter
$T_s$	Abtastzeit
$T_u$	Umgebungstemperatur
$T_{vDK}$	Temperatur vor Drosselklappe
$T_{vT}$	Temperatur vor Turbine
$T_{vV}$	Temperatur vor Verdichter
$T$	Dauer der Zyklusses
$V_H$	Motorhubvolumen
$X$	Anzahl der Iterationen

$c_p$	spezifische Wärmekapazität bei konstantem Druck
$c_v$	spezifische Wärmekapazität bei konstantem Volumen
$d_{ATL}$	Dämpfung Abgasturbolader
$\Delta H$	Enthalpieänderung durch Wärmeeintrag der Verbrennung
$d$	Störgröße
$e_d$	Vektor der Regelabweichung, Wunschverhalten
$e_k$	Vektor der Regelabweichung des Zyklus $k$
$e$	Regelabweichung
$f$	freie Antwort des Systems
$g$	Markov-Spaltenvektor
$h$	Prozessmessgröße
$i_A$	Anzahl der Arbeitsspiele pro Kurbelwellenumdrehung
$i$	diskrete Zeitvariable
$k + 1$	zukünftiger Zyklus
$k$	aktueller Zyklus
$\dot{m}_{Abgas}$	Abgasmassenstrom
$\dot{m}_{KS}$	eingespritzter Kraftstoffmassenstrom
$\dot{m}_{Motor}$	angesaugter Luftmassenstrom (Motor)
$\dot{m}_{T,bez}$	bezogener Turbinenmassenstrom
$\dot{m}_{T,s}$	Turbinensollmassenstrom
$\dot{m}_T$	Turbinenmassenstrom
$\dot{m}_{V,bez}$	bezogener Verdichtermassenstrom
$\dot{m}_V$	Verdichtermassenstrom
$\dot{m}_{WG,s}$	Wastegatesollmassenstrom
$\dot{m}_{WG}$	Wastegatemassenstrom
$n_{ATL,bez}$	bezogene Turboladerdrehzahl
$n_{ATL}$	Turboladerdrehzahl
$n_{mot}$	Motordrehzahl
$p_{DD}$	Wastegatedosendruck
$p_{bez}$	Bezugsdruck ATL-Vermessung
$p_{me}$	effektiver Mitteldruck
$p_{nT}$	Druck nach Turbine
$p_{nV}$	Druck nach Verdichter
$p_u$	Umgebungsluftdruck
$p_{vDK,s}$	Solldruck vor Drosselklappe
$p_{vDK}$	Druck vor Drosselklappe
$p_{vT}$	Druck vor Turbine
$p_{vV}$	Druck vor Verdichter
$p$	Anzahl der Eingangsgrößen
$q$	Anzahl der Ausgangsgrößen
$\mathbf{u}_{ILR}$	optimierter Stellgrößenvektor des ILR-Algorithmus
$\mathbf{u}_R$	Stellgrößenvektor des Reglers
$\mathbf{u}_V$	Stellgrößenvektor der Vorsteuerung
$\mathbf{u}_{k+1}$	Stellgrößenvektor des Zyklus $k + 1$

$\mathbf{u}_k$	Stellgrößenvektor des Zyklus $k$
$u$	Stellgröße
$v$	Rauschsignal, stochastisch
$x$	Zustandsgröße
$y_d$	Führungsgröße
$\mathbf{y}_d$	Führungsgrößenvektor des Zyklus $k$
$\mathbf{y}_k$	Regelgrößenvektor des Zyklus $k$
$y$	Regelgröße

# Kapitel 1.

## Einleitung

Der Klimaschutz ist eine der zentralen Aufgaben der Menschheit. In den Jahren 1991 und 1992 haben die Vereinten Nationen erstmals ein Rahmenübereinkommen über Klimaänderungen formuliert und Grundsätze zum internationalen Kampf gegen den Klimawandel festgelegt [94/69/EG, 1994], [2002/358/EG, 2002]. Laut [94/69/EG, 1994] ist die Europäische Union die Verpflichtung eingegangen, die Treibhausgasemissionen bis 2020 um mindestens 20% zum Stand von 1990 zu senken. Für die Treibhausgase Kohlendioxid ( $\text{CO}_2$ ), Methan ( $\text{CH}_4$ ), Distickstoffoxid ( $\text{N}_2\text{O}$ ), teilhalogenierte Fluorkohlenwasserstoffe (H-FCKW), perfluorierte Kohlenwasserstoffe (FKW / PFC) und Schwefelhexafluorid ( $\text{SF}_6$ ) gelten verbindliche mengenmäßige Ziele, die es zu erreichen gilt. Den mengenmäßig größten Anteil an den gesamten Treibhausgasemissionen hat dabei das Kohlendioxid. Davon sind laut [BMUB, 2008] ca. 26% durch den Verkehr bzw. 12% durch den Pkw-Verkehr verursacht. Mit der schrittweisen Einführung von Emissionsnormen für neue Personenkraftwagen soll bis 2020 der durchschnittliche  $\text{CO}_2$ -Ausstoß eines Neuwagens auf  $95 \frac{\text{g}}{\text{km}}$  gesenkt und der Kraftstoffverbrauch weiter reduziert werden.

Grundsätzlich sind verbrauchssenkende Maßnahmen durch die Reduzierung von Fahrwiderständen (z.B. Fahrzeugmasse, Strömungswiderstand), einer Optimierung der Getriebestrategien in verbrauchsgünstige Arbeitspunkte oder die Steigerung des motorischen Wirkungsgrades [Golloch, 2005, S. 1 f.] realisierbar. Eine Möglichkeit ist die Verlagerung der Betriebspunkte in Bereiche mit höherem Wirkungsgrad wie z.B. durch die Verwendung höherer Mitteldrücke. Gleichzeitig sind die Kundenwünsche hinsichtlich Fahrdynamik und Komfort zu erfüllen.

Das Downsizing von Motoren hat das Ziel, die Baugröße und die Masse des Motors zu verringern. Dadurch ist es möglich Kraftstoff einzusparen und die Schadstoffemissionen zu reduzieren. Um dennoch die geforderte Motorleistung zur Verfügung zu stellen, wird eine Aufladung des Motors durchgeführt. Ein aufgeladener Motor hat dadurch bei gleicher Antriebsleistung weniger Hubraum und eine geringere Masse als ein Saugmotor [Eichseder et al., 2008, S. 108 ff.]. Generell lässt sich die Reduzierung des Motorhubvolumens in das statische und das dynamische Downsizing unterscheiden. Bei dem dynamischen Downsizing erfolgt die Reduzierung des Motorhubvolumens während des Betriebes, z.B. durch die Deaktivierung von Zylindern in unteren Lastbereichen. Diese Vorgehensweise wird auch als Zylinderabschaltung (ZAS) bezeichnet. Dadurch ist es möglich die aktiven Zylinder höher zu belasten und in besseren Wirkungsgradbereichen zu betreiben [Golloch, 2005, S. 75 f.]. Beim statischen Downsizing wird während der Entwicklung des Motors ein geringeres Motorhubvolumen festgelegt. Um trotzdem die vom Kunden gewünschte Fahrdynamik zu gewährleisten, ist in diesem Fall eine zusätzliche Erhöhung des effektiven Mitteldruckes notwendig. Dies lässt sich im Wesentlichen nur durch eine zusätzliche Aufladung (Verdichtung der Luft) erreichen. Eine Möglichkeit

stellt der Abgasturbolader dar.

### **Motivation der Arbeit**

Um diese Motoren optimal zu betreiben, sind komplexe Steuerungs- und Regelungsstrategien in den Steuergeräten notwendig, die ständig weiterentwickelt werden. Die Aufgabe der Parametrierungen existierender und neuer Steuerungen und Regelungen wiederholt sich an vielen Stellen im Steuergerät von Fahrzeugen und ist auch an Prozessen außerhalb des Automobilbereiches ein wichtiger Arbeitsschritt. Das Interesse an automatisierten selbsteinstellenden Verfahren ist groß. Das Ziel ist, den Aufwand und die Zeit zur Einstellung der Regelungsparameter nach definierten Optimierungskriterien zu verringern und die Anzahl der notwendigen Testfahrten zu reduzieren. Gleichzeitig soll die Güte der bisherigen Ergebnisse gewährleistet bzw. verbessert werden.

In der Literatur existieren verschiedene Ansätze mit unterschiedlichen Systemanforderungen und Anwendungsbedingungen. Da während der Applikation von Steuergeräteparametern notwendigerweise Testfahrten und Prüfstandsmessungen durchgeführt werden, bieten signalbasierte Selbsteinstellungsverfahren wie z.B. Verfahren der Virtual Reference Feedback Tuning (VRFT), des Iterative Feedback Tuning (IFT), der Iterative Lernende Regelung (ILR) und des Control Performance Monitoring (CPM) Lösungsansätze.

### **Zielstellung der Arbeit**

Aufbauend auf dem Stand der Technik werden signalbasierte Verfahren zur Selbsteinstellung von Parametern existierender Steuerungs- und Regelungsstrukturen untersucht und weiterentwickelt. Diese Arbeit zeigt zunächst die Herausforderungen und Einschränkungen beim Einsatz der verschiedenen Verfahren auf, um dann die Lücke zwischen der Theorie der ILR und der Optimierung von Parametern zu schließen. Die vorliegende Arbeit verfolgt dabei drei grundlegende Ziele:

1. Die Entwicklung allgemeiner Verfahren zur Selbsteinstellung und Optimierung von Parametern existierender Steuerungen und Regelungen, um ein gewünschtes Verhalten zu erreichen.
2. Dabei ist auf Betriebsmessungen zurückzugreifen, um den Aufwand durch Prüfstandsversuche gering zu halten. Weiterhin ist zusätzlicher Modellierungsaufwand zu vermeiden.
3. Eine geringe Anzahl an Messfahrten erfordert eine hohe Lernrate. Gleichzeitig erfordern die Sicherheitsvorgaben während des Betriebes eine Gewährleistung von Konvergenz und Stabilität, um Mensch und Maschine zu schützen.

Damit stellt das Ergebnis dieser Arbeit eine Schnittstelle zwischen Physik und Regelungstechnik dar und liefert zwei Verfahren zur Selbsteinstellung für viele Anwendungsbereiche. Teile dieser Arbeit wurden bereits in [Noa10, NJW14a, NJWH14b, NJWH14a, NJW14b, NJSW15] veröffentlicht.

## Anwendungsbeispiel für die entwickelten Verfahren

Die entwickelten Verfahren sind an Regelungsstrukturen im Steuergerät von Ottomotoren zu erproben. Die einzustellenden Parameter können Faktoren oder arbeitspunktabhängige Kennlinien bzw. Kennfelder sein. Der betrachteten Anwendungsprozess ist die Ladedruckregelung eines einfach aufgeladenen Ottomotors. Bei dem betrachteten Lader-typ handelt es sich um einen einstufigen Abgasturbolader, dessen Ansteuerung durch ein pneumatisches Wastegate erfolgt. Die im Steuergerät verwendete Regelungsstruktur besteht aus einer modellbasierten Vorsteuerung und einem PI-Regler. Der Nachweis der Funktionalität der entwickelten Verfahren und die Bewertung der Ergebnisse erfolgt sowohl an einem Simulationsmodell als auch durch experimentelle Versuche und Testfahrten im Fahrzeug.

## Aufbau der Arbeit

**Kapitel 2:** Den Schwerpunkt des zweiten Kapitels bildet die Beschreibung und Untersuchung möglicher geeigneter Verfahren zur Selbsteinstellung. Dazu sind die Eigenschaften und die Einsatzmöglichkeiten der Verfahren zu analysieren und einzugrenzen. Der Hauptteil dieses Kapitels liefert die notwendigen theoretischen Grundlagen zu der Thematik der iterativ lernenden Regelung, welche die Basis der in Kapitel 4 entwickelten Verfahren bilden.

**Kapitel 3:** Dieses Kapitel stellt den Stand der Wissenschaft und Technik auf dem Gebiet der Aufladung von Ottomotoren dar. Nach der allgemeinen Beschreibung der Aufladung sowie deren Aufgabe und Funktion bei Verbrennungsmotoren folgt die gängige Modellvorstellung des Aufladungsprozesses für den einfach aufgeladenen Ottomotor mit Abgasturbolader. Ein weiterer Abschnitt dokumentiert ein aktuelles Verfahren zur Ladedruckregelung. Dies hat zwei Gründe. Erstens ist vor dem praktischen Test der entwickelten Verfahren im Fahrzeug ein simulativer Nachweis ihrer Funktionalität durchzuführen. Dies erfordert daher ein physikalisches Simulationsmodell des Prozesses. Zweitens ist eine Spezifizierung der einzustellenden Parameter der Ladedruckregelung notwendig, um die entwickelten Verfahren in Kapitel 5 anzuwenden. Den Abschluss dieses Kapitels bildet die Zusammenfassung der Anforderungen des Prozesses an ein Selbsteinstellungsverfahren.

**Kapitel 4:** Das Kapitel 4 diskutiert zunächst die Eignung der beschriebenen Verfahren zur Selbsteinstellung hinsichtlich der formulierten Anforderungen und begründet die Auswahl des ILR-Ansatzes. Weiterhin werden die Grenzen der ILR beschrieben, die eine Erweiterung der ILR-Methodik notwendig machen. Den Kern dieses Kapitels bildet die Entwicklung zweier Erweiterungen der iterativ lernenden Regelung, welche dadurch eine ILR-basierte Selbsteinstellung von Parametern vorgegebener Steuerungs- und Regelungsstrukturen ermöglichen. Diese Verfahren werden sowohl für Vorsteuerungen als auch für Regelungen beschrieben und analysiert. Ein wichtiger Punkt ist die Gewährleistung der Konvergenz bei der Kombination von der ILR und der Parameteroptimierung.

**Kapitel 5:** In Kapitel fünf ist die Realisierung der entwickelten Verfahren der ILR-basierten Selbsteinstellung am Prozess Ladedruckregelung (LDR) eines einfach aufgeladenen Ottomotors dokumentiert. Es beginnt mit der Beschreibung der zu applizierenden Parameter innerhalb der vorgegebenen LDR-Struktur und stellt die Rahmenbedingungen der durchzuführenden Applikationsfahrten auf. Nach der Vorstellung des Realisierungsobjektes erfolgt die Anwendung der entwickelten Verfahren aus Kapitel vier. Neben der Betrachtung von Konvergenz und erreichbarer Regelgüte ist ein Diskussionspunkt die Wahl des geeigneten ILR-Ansatzes innerhalb des Selbsteinstellungsverfahrens.

**Kapitel 6:** Das sechste Kapitel untersucht zunächst in verschiedenen Simulationsstudien die Anwendbarkeit der entwickelten Verfahren und Einflüsse wie Messrauschen oder abweichende Arbeitspunkte. Es beginnt mit der Vorstellung der verwendeten Modellversuche und präsentiert die Ergebnisse der Simulationen. Darauf folgt die Darstellung der experimentellen Versuche und Testfahrten im Fahrzeug und am Laborversuchsstand. Abschließend werden die Ergebnisse zusammengefasst und die Möglichkeiten der entwickelten Verfahren hinsichtlich der erreichten Regelgüte und der erreichten Konvergenz diskutiert.

**Kapitel 7:** Das letzte Kapitel fasst die entwickelten Verfahren und die erreichten Ergebnisse zusammen. Es folgt eine Bewertung der ILR-basierten Selbsteinstellung und ein Ausblick mit weiterführenden Aufgaben zu diesem Thema.

# Kapitel 2.

## Verfahren zur Selbsteinstellung

Das folgende Kapitel beschreibt relevante regelungstechnische Grundlagen dieser Arbeit. Es untersucht existierende adaptive Verfahren zur Selbsteinstellung von Regelungsparametern, analysiert deren Eigenschaften und Grenzen und stellt typische Anwendungsfälle dar. Außerdem greift dieses Kapitel der Auswahl des Verfahrens vorweg und liefert die notwendigen theoretischen Grundlagen zur Theorie der ILR ab dem Abschnitt 2.3. Auf diese Basis gestützt, erfolgt im Kapitel 4 die Entwicklung von ILR-basierten Selbsteinstellungsverfahren.

### 2.1. Aufgabe des Selbsteinstellungsverfahrens

Verfahren zur Selbsteinstellung von Parametern lassen sich den adaptiven Regelungen zuordnen. Adaptive Regelungen kommen zum Einsatz, wenn die Parameter einer Regelstrecke unbekannt oder zeitlich veränderbar sind [Böcker et al., 1986, S.317ff.]. Dies kann auf Grund von Alterung und Verschleiß, Arbeitspunktänderungen oder anderen Einflüssen geschehen. Das Ziel der adaptiven Regelung ist die Anpassung der Reglerparameter an die tatsächlichen Streckenparameter unter der Gewährleistung der Stabilität und der Einhaltung des gewünschten Regelkreisverhaltens. Beispiele für die Anwendung von adaptiven Regelungen lassen sich in der Literatur viele finden, wie z.B. in der Verfahrenstechnik [Hengen et al., 2004], in der Robotertechnik [Ortega and Spong, 1989] oder in der Automobilindustrie [Dambrosio et al., 2001].

Adaptive Regelungen weisen eine komplexe Struktur auf und besitzen zwei Regel Schleifen [Böcker et al., 1986, S.317ff] (Rückführung der Regelgröße, Anpassung der Regelparameter). Damit gehören sie zu den nichtlinearen und zeitvarianten Reglern. Die Abb. 2.1 zeigt die allgemeine Darstellung einer adaptiven Reglerstruktur mit der Führungsgröße  $y_d$ , der Stellgröße  $u$ , der Regelgröße  $y$ , der Störgröße  $d$ , den Zustandsgrößen  $x$ , dem Rauschsignal  $v$  und den weiteren Prozessmessgrößen  $h$ .

Ziel der Adaption ist es, für den Reglerparametervektor  $\boldsymbol{\rho}$  in wiederholten Vorgängen den gewünschten Parametersatz  $\hat{\boldsymbol{\rho}}$  der Minimierungsfunktion  $J$  zu finden

$$J(\Omega, y_d, d, v, \hat{\boldsymbol{\rho}}) = \arg \min_{\boldsymbol{\rho}} J(\Omega, y_d, d, v, \boldsymbol{\rho}), \quad (2.1)$$

bei der  $\Omega$  das gewünschte Verhalten des Regelkreises beschreibt.  $\Omega$  kann dabei aus einer Beschreibung von Regelgütefaktoren wie der Ausgleichszeit und der Überschwingweite von Führungsgrößen- oder Störanregungen, wie dem Amplituden- oder dem Phasenrand, wie der Polstellen- und Nullstellendefinition des geschlossenen Regelkreises oder anderen Bewertungskriterien bestehen [Bobál et al., 2005, S.6ff.].

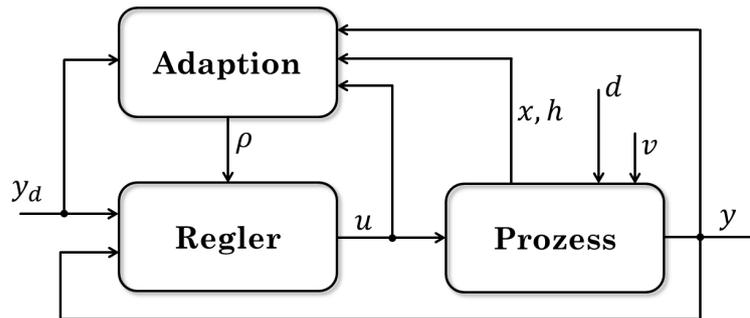


Abbildung 2.1. Konzept eines adaptiven Regelkreises [Aström, 1995, S.2]

Adaptive Regelungen stellen Ansätze zur automatischen Anpassung von Reglerparametern dar, die in Echtzeit und dauerhaft erfolgen [Landau et al., 2011, S.1ff.]. Dabei werden die Modellparameter des Prozesses in jedem Abtastschritt geschätzt und die Reglerparameter neu berechnet. Dies kann indirekt, d.h. mit expliziter Schätzung der Prozessparameter, oder direkt geschehen. Der Gradient  $\frac{\partial J}{\partial \rho}(\rho)$  zur Lösung der Gütefunktion wird oft analytisch anhand des bekannten Prozessmodells bestimmt. Zu diesen Verfahren gehören zum Beispiel die MIT-Regel und der Self-Tuning-Regulator aus [Aström and Wittenmark, 1994].

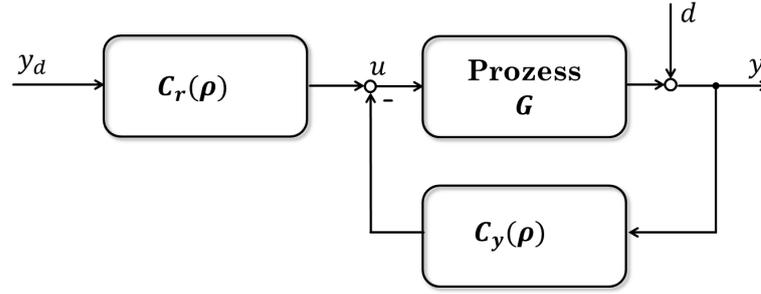
## 2.2. Beschreibung und Analyse bestehender Verfahren zur Selbsteinstellung von Regelungsparametern

Die Aufgabe der Selbsteinstellung erfordert zusätzliche Rahmenbedingungen. Zum einen wird die Anpassung der Parameter nur während einer begrenzten Zeit durchgeführt. Nach dem Beenden der Selbsteinstellung werden die Parameter nicht mehr verändert. Zum anderen erfolgt diese Selbsteinstellung überwacht, so dass in diesem Fall höhere Änderungsgradienten zulässig sind. Weiterhin ist es nicht immer gewährleistet, dass das Prozessmodell bekannt ist. Die Parameteränderung muss nicht in Echtzeit erfolgen, sondern kann auch aus Datensätzen mit  $N$  Abtastpunkten geschehen. Signalbasierte adaptive Verfahren setzen kein bekanntes Prozessmodell voraus, sondern nutzen einzig gemessene Daten am offenen oder geschlossenen Regelkreis zur Minimierung der Gütefunktion  $J$ . Bekannte Verfahren sind beispielsweise IFT [Hjalmarsson et al., 1998], VRFT [Campi et al., 2002] und ILR [Arimoto et al., 1984]. Aus diesem Grund stellt die Betrachtung dieser Verfahren den Ausgangspunkt dieser Arbeit dar.

### 2.2.1. Iterative Feedback Tuning

Unter IFT ist laut [Hjalmarsson et al., 1998, Mossberg et al., 2002] die iterative Optimierung von Reglerparametern zu verstehen, bei der sich der Gradient  $\frac{\partial J}{\partial \rho}$  durch gezielte Experimente am Prozess ermitteln lässt. Dazu sind an einem Regelkreis mit existierendem Regler mit zwei Freiheitsgraden (2-Degree of Freedom) (2DoF) drei Experimente in jeder Iteration durchzuführen.

Der in Abb. 2.2 dargestellte Prozess ist durch den linearen zeitinvarianten Operator  $G$  und den zeitdiskreten Größen  $u(i)$  (Eingangsgröße),  $y(i)$  (Ausgangsgröße),  $y_d(i)$



**Abbildung 2.2.** Darstellung des geschlossenen Regelkreises [Hjalmarsson et al., 1998, S.28]

(Führungsgröße) und der unbekannten Störung  $d(i)$  beschrieben. Der in der Abbildung dargestellte 2DoF-Regler ist ein linearer zeitinvarianter Regler, dessen Übertragungsfunktionen  $C_r(\boldsymbol{\rho})$  und  $C_y(\boldsymbol{\rho})$  vom Parametervektor  $\boldsymbol{\rho} \in \mathbb{R}^{n_\rho}$  abhängig sind.

Laut [Hjalmarsson et al., 1998] ist der Parametervektor so zu bestimmen, dass das Gütefunktional

$$J(\boldsymbol{\rho}) = \frac{1}{2N} \mathbb{E} \left[ \sum_{i=1}^N (e(i, \boldsymbol{\rho})^2 + \lambda u(i, \boldsymbol{\rho})^2) \right] \quad (2.2)$$

minimiert wird.  $\mathbb{E}$  ist der Erwartungswert,  $\lambda$  ein Wichtungsfaktor und  $N$  die Anzahl der abgetasteten Datenpunkte. In diesem Gütefunktional lassen sich weiterhin Filterungen der Regelabweichung  $e(i, \boldsymbol{\rho})$  und der Stellgröße  $u(i, \boldsymbol{\rho})$  sowie die Vorgabe eines Wunschverhaltens berücksichtigen.

Mit dem Gradienten

$$\frac{\partial J}{\partial \boldsymbol{\rho}}(\boldsymbol{\rho}) = \frac{1}{N} \mathbb{E} \left[ \sum_{i=1}^N e(i, \boldsymbol{\rho}) \frac{\partial e(i, \boldsymbol{\rho})}{\partial \boldsymbol{\rho}} + \lambda \sum_{i=1}^N u(i, \boldsymbol{\rho}) \frac{\partial u(i, \boldsymbol{\rho})}{\partial \boldsymbol{\rho}} \right] \quad (2.3)$$

ist nun iterativ das Optimierungsproblem zu lösen und der neue Parametervektor

$$\boldsymbol{\rho}_{k+1} = \boldsymbol{\rho}_k - \gamma_k R_k^{-1} \frac{\partial J}{\partial \boldsymbol{\rho}}(\boldsymbol{\rho}_k) \quad (2.4)$$

zu bestimmen. In dieser Gleichung ist  $\gamma_k$  ein Lernfaktor und  $R_k$  eine positiv definite Matrix.

Die Besonderheit des IFT-Verfahrens ist die signalbasierte Bestimmung bzw. Schätzung des Gradienten  $\frac{\partial J}{\partial \boldsymbol{\rho}}(\boldsymbol{\rho}_k)$ . Es sind zunächst drei Experimente in jeder Iteration  $k$  durchzuführen und die folgenden Signalverläufe zu bestimmen:

- (1) der Führungsgrößenverlauf  $y_{d,1,k}(i) = y_d(i)$ ,  
der Regelgrößenverlauf  $y_{1,k}(i, \boldsymbol{\rho}_k)$ ,  
und der Stellgrößenverlauf  $u_{1,k}(i, \boldsymbol{\rho}_k)$ ,
- (2) der Führungsgrößenverlauf  $y_{d,2,k}(i) = y_d(i) - y_1(i, \boldsymbol{\rho}_k)$ ,  
der Regelgrößenverlauf  $y_{2,k}(i, \boldsymbol{\rho}_k)$ ,  
und der Stellgrößenverlauf  $u_{2,k}(i, \boldsymbol{\rho}_k)$ ,

- (3) der Führungsgrößenverlauf  $y_{d,3,k}(i) = y_d(i)$ ,  
 der Regelgrößenverlauf  $y_{3,k}(i, \boldsymbol{\rho}_k)$ ,  
 und der Stellgrößenverlauf  $u_{3,k}(i, \boldsymbol{\rho}_k)$ .

Das Experiment 2 unterscheidet sich von den anderen durch die spezielle Vorgabe des Verlaufes der Führungsgröße. Laut [Hjalmarsson et al., 1998] lässt sich nun der geschätzte Gradient durch

$$\widehat{\frac{\partial J}{\partial \boldsymbol{\rho}}}(\boldsymbol{\rho}_k) = \frac{1}{N} \sum_{i=1}^N \left( e(i, \boldsymbol{\rho}_k) \frac{\partial y(i, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} + \lambda u(i, \boldsymbol{\rho}_k) \frac{\partial u(i, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} \right) \quad (2.5)$$

berechnen. Dafür sind die Signalverläufe  $e(i, \boldsymbol{\rho}_k) = y_{1,k}(i, \boldsymbol{\rho}_k) - y_d(i)$  und  $u(i, \boldsymbol{\rho}_k) = u_{1,k}(i, \boldsymbol{\rho}_k)$  und die im Bildbereich dargestellten geschätzten Gradienten

$$\widehat{\frac{\partial y(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}}} \triangleq \frac{1}{C_r(z, \boldsymbol{\rho}_k)} \left[ \left( \frac{\partial C_r(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} - \frac{\partial C_y(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} \right) y_{3,k}(z, \boldsymbol{\rho}_k) + \frac{\partial C_y(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} y_{2,k}(z, \boldsymbol{\rho}_k) \right] \quad (2.6)$$

$$\widehat{\frac{\partial u(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}}} \triangleq \frac{1}{C_r(z, \boldsymbol{\rho}_k)} \left[ \left( \frac{\partial C_r(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} - \frac{\partial C_y(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} \right) u_{3,k}(z, \boldsymbol{\rho}_k) + \frac{\partial C_y(z, \boldsymbol{\rho}_k)}{\partial \boldsymbol{\rho}} u_{2,k}(z, \boldsymbol{\rho}_k) \right] \quad (2.7)$$

zu berechnen. Für den neuen Parametervektor  $\boldsymbol{\rho}_{k+1}$  ergibt sich folgende Gleichung

$$\boldsymbol{\rho}_{k+1} = \boldsymbol{\rho}_k - \gamma_k R^{-1} \widehat{\frac{\partial J}{\partial \boldsymbol{\rho}}}(\boldsymbol{\rho}_k). \quad (2.8)$$

### Eigenschaften des Verfahrens

Das IFT-Verfahren stellt ein signalbasiertes modellfreies Verfahren zur Einstellung von Reglerparametern dar, dessen Durchführung am geschlossenen Regelkreis iterativ nach den durchzuführenden Experimenten erfolgt. Der zu parametrierende Regler muss durch diskrete, lineare und zeitinvariante Übertragungsfunktionen beschreibbar und deren parameterabhängiger Änderungsgradient analytisch bestimmbar sein. In jeder Iteration sind drei Experimente mit  $N$ -Abtastschritten durchzuführen. Der Prozess muss es zulassen, dass in Experiment 2 ein spezieller Führungsgrößenverlauf vorgebar ist. Eine direkte Vorgabe des Verhaltens des Regelkreises sowie eine zusätzliche Filterung der Verläufe der Regelabweichung und der Stellgröße ist möglich.

#### 2.2.2. Virtual Reference Feedback Tuning

Das VRFT ist eine „Ein-Schuss“-Methode zur Bestimmung von Reglerparametern. Hier erfolgt die Bestimmung des Gradienten  $\frac{\partial J}{\partial \boldsymbol{p}}$  anhand einer Messung aus dem laufenden Betrieb des Prozesses und der Erzeugung eines virtuellen Referenzsignals. Daher gilt VRFT als signalbasiertes Entwurfsverfahren [Campi et al., 2002, Lecchini et al., 2002, Campi et al., 2000]. Laut [Campi et al., 2002] stellen die ermittelten Reglerparameter eine gute Approximation des globalen Optimums dar.

Die grundlegende Idee des VRFT-Verfahrens soll im folgenden an einem einfachen System erläutert werden. Ein lineares diskretes SISO-System mit der Übertragungsfunktion  $G(z)$  und unbekanntem Parameter ist der Ausgangspunkt der Betrachtung. Vorgegeben ist ein Referenzmodell  $M(z)$  des geschlossenen Regelkreises und der Regler  $C(z, \boldsymbol{\rho})$ , dessen Struktur bekannt und der Parametervektor  $\boldsymbol{\rho}$  gesucht ist. Abb. 2.3 zeigt die VRFT-Struktur mit einem Regler mit einem Freiheitsgrad (1-Degree of Freedom) (1DoF). Ziel ist es das Gütefunktional [Campi et al., 2002, S.1]

$$J_M = \left\| \frac{C(z, \boldsymbol{\rho})G(z)}{1 + C(z, \boldsymbol{\rho})G(z)} - M(z) \right\|_2^2 \quad (2.9)$$

zu minimieren. Als Messdaten liegen der Stellgrößenverlauf  $u(z)$  und der Regelgrößenverlauf  $y(z)$  vor. Nun ist ein geeignetes Referenzsignal  $\bar{y}_M(z)$  zu finden, für das

$$M(z)\bar{y}_M(z) = y(z) \quad (2.10)$$

gilt. Da es nur weiteren Berechnungen dient und keine zusätzlichen Experimente erfordert, ist es ein „virtuelles“ Referenzsignal, das für das Wunschverhalten den gemessenen Regelgrößenverlauf ergibt. Dies ermöglicht die Berechnung des virtuellen Regelfehlers  $e_M(z) = \bar{y}_M(z) - y(z)$ . Der nächste Schritt ist die geeignete Filterung der Messgrößen durch den Filter mit der Übertragungsfunktion  $F(z)$ .

$$e_{M,F}(z) = F(z)e(z), \quad u_F(z) = F(z)u(z) \quad (2.11)$$

Die Regelparameter sind nun so zu bestimmen, dass aus  $e_{M,F}(z)$  der Stellgrößenverlauf  $u_F(z)$  entsteht. Dazu ist als Optimierungsproblem das Gütefunktional

$$J(\boldsymbol{\rho}) = \|u_F(z) - C(z, \boldsymbol{\rho})e_{M,F}(z)\|_2^2 \quad (2.12)$$

zu minimieren.

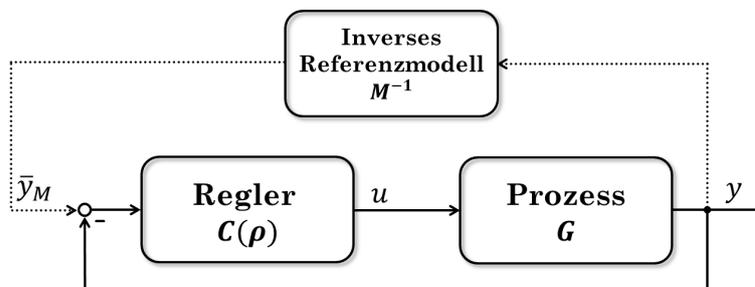


Abbildung 2.3. Prinzipabbildung des VRFT (gestrichelt ist der virtuelle Teil)

### Eigenschaften des Verfahrens

Das VRFT-Verfahren stellt ein signalbasiertes Reglerentwurfsverfahren dar, das kein Prozessmodell benötigt. Dieses Verfahren führt anhand des gemessenen Eingangs- und Ausgangssignalverlaufes des Prozesses einen einmaligen Reglerentwurf für eine vorgegebene Reglerstruktur durch und benötigt keine speziellen Anregungen bzw. Experimente.

Die Hauptaufgabe bei der Anwendung des VRFT ist es, eine geeignete Vorfilterung der Daten vorzunehmen und ein geeignetes Referenzverhalten zu definieren, mit dem sich das virtuelle Referenzsignal berechnen lässt. Dieses nicht iterative Verfahren ist auch für nichtlineare Systeme und 2DoF-Regler anwendbar. Bei diesem Entwurfsverfahren ist unter der Voraussetzung, dass Messungen am offenen Regelkreis möglich sind, keine Startparametrierung des Reglers notwendig. Damit kann es die Startreglerparameter für weitere iterative Optimierungsverfahren liefern.

### 2.2.3. Fictitious Reference Iterative Tuning

Bei dem Fictitious Reference Iterative Tuning (FRIT)-Verfahren handelt es sich wie bei dem VRFT-Verfahren um eine „Ein-Schuss“-Methode. Der Unterschied besteht darin, dass in diesem Fall das Gütekriterium iterativ bestimmt wird. Außerdem benötigt das FRIT-Verfahren eine Startparametrierung des Reglers, die den Regelkreis stabilisiert.

Ausgangspunkt des Verfahrens ist wiederum der Regelkreis in Abb. 2.3. Der Prozess  $G$  hat laut [Miyachi et al., 2006] eine unbekannte Dynamik, ist minimalphasig, linear und zeitinvariant. Vorgegeben ist weiterhin das gewünschte Regelkreisverhalten  $M(z)$ , die diskrete Reglerstruktur  $C(z)$  und der Initialisierungsregler  $C(z, \boldsymbol{\rho}_0)$ . Der Regler soll das Gütefunktional

$$J(\boldsymbol{\rho}) = \frac{1}{2N} \sum_{i=1}^N (e(i, \boldsymbol{\rho}))^2 \quad (2.13)$$

minimieren. Im Bildbereich ist die Regelabweichung durch  $e(z, \boldsymbol{\rho}) = y(z, \boldsymbol{\rho}) - M(z)y_d(z)$  gegeben.

Am geschlossenen Regelkreis erfolgt die Messung des Stellgrößenverlaufes  $u(i, \boldsymbol{\rho}_0)$  sowie des Regelgrößenverlaufes  $y(i, \boldsymbol{\rho}_0)$  nach einer Anregung  $y_d(i)$ . Weitere Experimente sind nicht durchzuführen, da die Iterationen zur Bestimmung des Gradienten  $\frac{\partial J}{\partial \boldsymbol{\rho}}(\boldsymbol{\rho}_k)$  offline erfolgen. Dazu führt [Miyachi et al., 2006] das fiktive Referenzsignal

$$\bar{y}_d(z, \boldsymbol{\rho}_k) = C^{-1}(z, \boldsymbol{\rho}_k)u(z, \boldsymbol{\rho}_0) + y(z, \boldsymbol{\rho}_0) \quad (2.14)$$

ein, aus dem die fiktive Regelabweichung

$$\bar{e}(z, \boldsymbol{\rho}_k) = y(z, \boldsymbol{\rho}_0) - M(z)\bar{y}_d(z, \boldsymbol{\rho}_k) \quad (2.15)$$

berechnet wird. Ziel ist es also, die fiktive Regelabweichung zu minimieren. Der Lösungsansatz ist wie beim IFT-Verfahren die Gauß-Newton-Methode

$$\boldsymbol{\rho}_{k+1} = \boldsymbol{\rho}_k - \gamma_k R^{-1} \frac{\partial \bar{J}}{\partial \boldsymbol{\rho}}(\boldsymbol{\rho}_k). \quad (2.16)$$

Dieses Verfahren lässt sich auf 2DoF-Regler [Kaneko et al., 2005] erweitern oder für den Entwurf von Störreglern anwenden [Masuda, 2012].

#### Eigenschaften des Verfahrens

Das FRIT-Verfahren ist ebenso wie das VRFT-Verfahren ein signalbasiertes Reglerentwurfsverfahren, das einmalig durchgeführt wird. Daher ähneln sich beide Verfahren.

Der Unterschied besteht zum einen in der iterativen Lösung des Gütefunktional und in der notwendigen Startparametrierung des Reglers. Eine weitere Voraussetzung ist die Invertierbarkeit des Reglers zur Bestimmung des fiktiven Referenzsignals.

### 2.2.4. Model Free Adaptive Control

Model Free Adaptive Control (MFAC) gehört zu den signalbasierten adaptiven Regelverfahren für nichtlineare Systeme [Hou and Jin, 2014]. Die Idee hinter diesem Verfahren ist die Einführung der Pseudo-Partiellen-Ableitung (engl. Pseudo Partial Derivative (PPD)) mit der das nichtlineare System als zeitvariantes lineares System betrachtet wird. Die PPD ist in jedem Abtastschritt neu zu bestimmen. Abb. 2.4 zeigt das Prinzip des PPD mit der Eingangsgröße  $u(i)$ , der Ausgangsgröße  $y(i)$  und dem PPD  $\phi_C(i)$ .

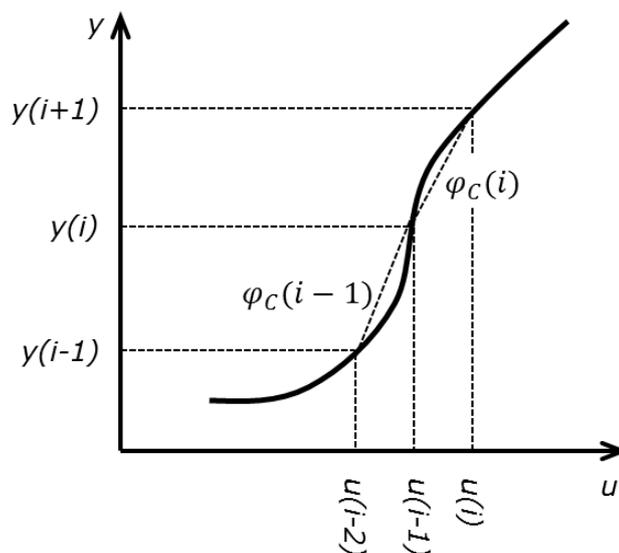


Abbildung 2.4. Darstellung der Pseudo-Partiellen-Ableitung (PPD)

In [Hou and Jin, 2014] sind drei Formen der PPD aufgeführt. Es handelt sich dabei um die Compact Form Dynamic Linearization (CFDL), die Partial Form Dynamic Linearization (PFDL) und die Full Form Dynamic Linearization (FFDL). Die CFDL stellt die einfachste Form der PPD dar. Der allgemeine CFDL-Modellansatz lautet wie folgt:

$$\Delta y(i+1) = \phi_C(i) \Delta u(i), \forall i \in \{0, 1, \dots, N\} \quad (2.17)$$

mit der Änderung der Ausgangsgröße  $\Delta y(i+1) = y(i+1) - y(i)$ , der Änderung der Eingangsgröße  $\Delta u(i) = u(i) - u(i-1)$  und dem zeitvariablen PPD-Parameter  $\phi_C(i)$ . Die PFDL und FFDL sind eine Verallgemeinerung der Darstellung des PPD durch die Erhöhung der Ordnung der Modellierung. Die PFDL berücksichtigt zusätzlich vorhergehende Stellgrößenänderungen und die FFDL weiterhin noch vorhergehende Ausgangsgrößenänderungen. Die FFDL hat die Ordnung  $L_y + L_u$ , die PFDL die Ordnung  $L_u$  und die CFDL die Ordnung 1.

Der erste Schritt der MFAC ist die rekursive Schätzung des modellierten PPD  $\hat{\phi}_C(i)$  durch das Lösen der Gütefunktion

$$J(\hat{\phi}_C(i)) = \left( y(i) - y(i-1) - \hat{\phi}_C(i) \Delta u(i-1) \right)^2 + \mu \left( \hat{\phi}_C(i) - \hat{\phi}_C(i-1) \right)^2 \quad (2.18)$$

mit dem Wichtungsfaktor  $\mu$ . Daraus ergibt sich

$$\hat{\phi}_C(i) = \hat{\phi}_C(i-1) + \frac{\Delta u(i-1)}{\mu + (\Delta u(i-1))^2} \left( y(i) - y(i-1) - \hat{\phi}_C(i-1) \Delta u(i-1) \right). \quad (2.19)$$

Das adaptive Regelgesetz leitet [Hou and Jin, 2014, S.77f.] aus folgender Gütefunktion her

$$J(u(i)) = (e(i+1))^2 + \lambda (u(i) - u(i-1))^2 \quad (2.20)$$

mit der Regelabweichung im nächsten Zeitschritt  $e(i+1)$ . Daraus ergibt sich der diskrete MFAC-Regler

$$u(i) = u(i-1) + \frac{\hat{\phi}_C(i)}{\lambda + \left( \hat{\phi}_C(i) \right)^2} (y_d(i) - y(i)) \quad (2.21)$$

mit dem Wichtungsfaktor  $\lambda$ .

Neben dieser Anwendung der MFAC-Theorie existieren Veröffentlichungen

- zum Einsatz an Mehrgrößensystemen (Multiple Input Multiple Output (MIMO)) [Hou and Jin, 2011],
- als adaptive und prediktive Regelung [Hou and Jin, 2014] (Model Free Adaptive Predictive Control)
- und als Erweiterung für iterativ lernende Regelungen (Model Free Adaptive Iterative Learning Control) [Hou and Rong-Hu, 2007].

### Eigenschaften des Verfahrens

Die MFAC-Theorie liefert ein adaptives Regelverfahren, das kein Prozessmodell benötigt. Der durch das Verfahren entstehende Regler ist in diskreter Form gegeben und kann nicht verändert werden. Stellbegrenzungen lassen sich im Stellgesetz berücksichtigen. Der Lernvorgang erfolgt nicht iterativ sondern in jedem Abtastschritt. Die Festlegung der Einstellfaktoren des diskreten MFAC-Reglers, um ein definiertes Regelverhalten vorzugeben, ist nicht direkt möglich und erfordert ein hohes Maß an Erfahrung.

#### 2.2.5. Control Performance Monitoring

Unter CPM ist im Allgemeinen die automatisierte Regelkreisüberwachung zu verstehen, die schlecht eingestellte Regler detektieren soll [Jelali, 2007]. In der CPM erfolgt die

Gütebewertung eines Regelkreises durch deterministische und statistische Kennzahlen wie z.B. das Integral des absoluten Regelfehlers (IAE)

$$IAE = \int_0^{\infty} |e(t)| dt, \quad (2.22)$$

der Flächenindex (Area Index), der sich aus den Flächen oberhalb und unterhalb des stationären Wertes der Stellgröße  $u_0$  nach einem Sollwertsprung oder Lastsprung zusammensetzt [Jelali, 2006, S.40]

$$A_I = \int_{t_0}^{t_e} |u(t) - u_0| dt, \quad (2.23)$$

oder der Harris-Index [Jelali, 2006, S.37], welcher die Varianz der Regelgröße mit der theoretisch erreichbaren Varianz eines Minimum-Varianz-Reglers vergleicht

$$\eta_{Harris} = \frac{\sigma_{MV}^2}{\sigma_y^2}. \quad (2.24)$$

Nach der Ermittlung solcher Kennzahlen folgt die Bestimmung von Performanzproblemen wie z.B. eine erhöhte Oszillation oder das langsame Erreichen des Sollwertes durch das Überwachungssystem. Die Weiterführung der automatisierten Regelkreisüberwachung ist die automatisierte und iterative Regleroptimierung anhand der CPM-Kennzahlen. Abb. 2.5 stellt den allgemeinen CPM basierten Optimierungsablauf dar. In

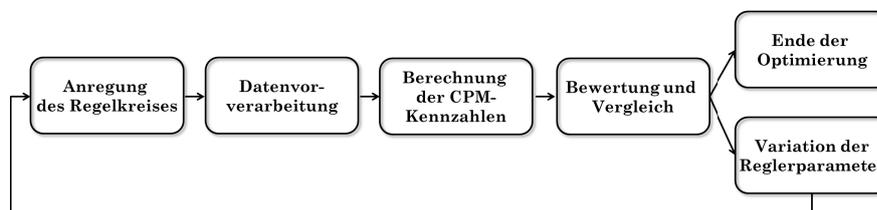


Abbildung 2.5. Schema der iterativen Regleroptimierung mittels CPM

Abhängigkeit der gewählten Indices basiert die Anregung des Prozesses auf normalen Betriebsabläufen bis hin zu gezielten Führungsgrößen- oder Störgrößenverläufen am geschlossenen Regelkreis. Der nächste Schritt ist eine Datenvorverarbeitung wie z.B. eine Filterung der Daten oder die Erkennung von Laständerungen. Nach der Berechnung der CPM-Kennzahlen findet die Bewertung und der Vergleich dieser Werte statt. Dann erfolgt die gezielte Veränderung der Reglerparameter nach festen indexabhängigen Regeln. [Jelali, 2007, S.15f.] unterscheidet für PID-Regler  $\left(G_R(s) = K_R \left(1 + \frac{1}{T_I s} + T_D s\right)\right)$  drei Variationsstrategien, welche sich in Anzahl der zu ändernden Parameter, Anzahl der notwendigen Iterationen und Transparenz bzw. Interpretierbarkeit unterscheiden. Die einfachste Variante ist die *separate Variation* der Reglerparameter beginnend mit der Variation von  $K_R$ . Alle anderen Parameter sind währenddessen festzuhalten. Ist keine Verbesserung mehr erkennbar, erfolgt die weitere Optimierung von  $T_I$  und  $T_D$ . Dieser

Ablauf ist solange zu wiederholen, bis keine Verbesserung mehr möglich ist. Bei der *simultanen Variation* findet die Veränderung aller Parameter in dem gleichen Schritt statt, wenn die Bewertungsregeln dies ermöglichen. Sie benötigt so die wenigsten Iterationen. Die dritte Variante ist die *sukzessive Variation*, bei der zuerst zu prüfen ist, welcher Parameter den größten Einfluss hat und dementsprechend zuerst zu ändern ist. Liegen die Kennzahlen im gewünschten Bereich, ist die Optimierung beendet.

### Eigenschaften des Verfahrens

Die Regleroptimierung mittels CPM-Güteindices stellt ein iteratives und signalbasiertes Verfahren zur Selbsteinstellung von Reglerparametern dar, das kein Prozessmodell erfordert. Die häufigste Anwendung dieses Verfahrens ist die Einstellung der Reglerparameter von PID-Reglern, für die ausgereifte Einstellregeln existieren. Allerdings wird die Definition dieser Regeln mit Zunahme der Komplexität des Reglers und der Anzahl der einzustellenden Parameter aufwändiger. Das separate Einstellen jedes Parameters, was mehrmals zu wiederholen ist, erleichtert die Definition der Regeln. Gleichzeitig nimmt die Anzahl der Iterationen und der damit durchzuführenden Versuche zu. Eine weitere Herausforderung ist die Festlegung der Änderungsschrittweite der einzustellenden Parameter. Diese hat Einfluss auf die Anzahl der notwendigen Iterationen und die Erreichbarkeit der optimalen Parameter.

## 2.3. Iterativ lernende Regelung

In [Moore et al., 2006, S.2352] beginnen die Autoren mit der Frage: „*Wir Menschen steigern unsere Fähigkeiten bei wiederholten Tätigkeiten, können dies Maschinen genauso tun?*“. Die Frage ist also, wie kann ein iterativ lernender Algorithmus die Performance von Maschinen oder Prozessen erhöhen. Mit dieser Problemstellung beschäftigt sich die Theorie der ILR. Eine ILR, im englischsprachigen Raum als Iterative Learning Control (ILC) bezeichnet, ist ein Regelverfahren für zyklisch wiederholte Prozesse. Zu den ersten Anwendungen gehörte das Folgen einer Bahntrajektorie in der Robotertechnik [Arimoto et al., 1984]. Weiterhin konnte die ILR erfolgreich in der Verfahrenstechnik [Hengen et al., 2004], in der metallverarbeitenden Industrie [Andres et al., 2002] und auch in der Medizintechnik [Nahrstaedt et al., 2008] an Beinprothesen erfolgreich angewendet werden.

Dieser Abschnitt gibt einen systematischen Überblick über die ILR-Theorie und beschreibt die notwendigen theoretischen Grundlagen. Die Betrachtung dieses Verfahrens erfolgt detaillierter als die vorherigen Verfahren, da die ILR-Theorie die Basis für die entwickelten Verfahren in Kapitel 4 darstellt. Den Anfang bildet eine allgemeine Signal- und Systembeschreibung zur Einführung des in dieser Arbeit verwendeten Supervektor-Formalismus [Moore et al., 2006, Ahn et al., 2007b]. Der Hauptteil dieses Abschnittes besteht aus der detaillierten Darstellung verschiedener ILR-Verfahren sowie dem Nachweis von Konvergenz bzw. Stabilität.

### Grundidee der ILR

Die ILR soll den Regelfehler beim Folgen einer zyklisch wiederholten Trajektorie oder einer zyklisch auftretenden gleichen Störung minimieren. Die Grundvoraussetzung für den Einsatz einer ILR sind gleiche Startbedingungen des Prozesses in jeder Iteration und eine konstante Zykluslänge  $T$  [Ahn et al., 2007b]. Die Optimierung durch das ILR-Verfahren erfolgt in jeder durchgeführten Iteration. Dabei berechnet das ILR - Verfahren aus dem gemessenen Verlauf der Stellgröße  $u_k(t)$  und dem Verlauf des aufgetretenen Regelfehlers  $e_k(t)$  der aktuellen Iteration  $k$  in der Zykluszeit  $t \in [0, T]$  den optimierten Verlauf der Stellgröße  $u_{k+1}(t)$  der nächsten Iteration  $k + 1$ . Die Abb. 2.6 zeigt das Regelungsschema der ILR.

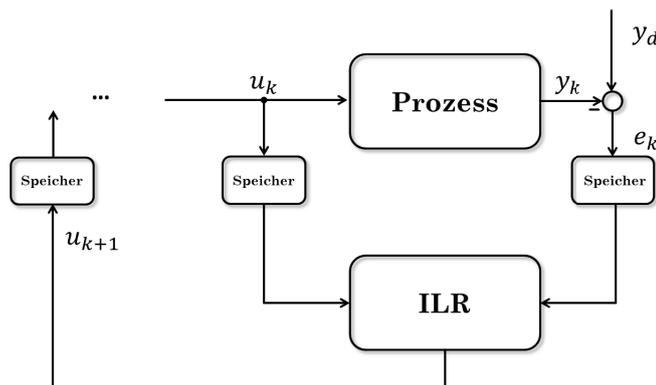


Abbildung 2.6. Regelungsschema der ILR

Das Basis ILR-Stellgesetz lautet wie folgt:

$$u_{k+1}(t) = Qu_k(t) + Le_k(t) \quad (2.25)$$

mit den Lernwerten  $Q$  und  $L$ . Diese Lernwerte können Faktoren, Matrizen oder Filter entsprechen und hängen von der Entwurfsmethodik ab. Die Optimierung erfolgt offline nach dem Beenden der aktuellen Iteration  $k$ .

Die ILR optimiert nach jedem wiederholten Versuch den Verlauf der Stellgröße und nutzt dazu die aufgetretene Regelabweichung, also die gemachte Erfahrung über die Güte des Versuches. Dieses Vorgehen wiederholt sich zyklisch, d.h. die Startbedingungen sind wieder herzustellen und die nächste Iteration  $k + 1$  mit der optimierten Stellgröße beginnt. Eine Iteration hat die Dauer  $T$  mit  $N$  Abtastpunkten. Daher ist die ILR für den Einsatz an zyklischen Prozessen wie z.B. wiederholten Bewegungsabläufen oder verfahrenstechnische Batch-Reaktoren geeignet. Abb. B.1 im Anhang zeigt beispielhaft die Änderung der Stellgröße und der Regelgröße nach zehn Iterationen.

Für den stabilen Prozess in der Iteration  $k$  mit der Ausgangsgröße  $y_k(t)$  und

$$y_k(t) = \Phi_G(u_k(t), x_k(t), d_k(t), x_{0,k}, v_k(t)) \quad (2.26)$$

mit der nichtlinearen Funktion  $\Phi_G$ , der Stellgröße  $u_k(t)$ , den Zustandsgrößen  $x_k(t)$ , der Störgröße  $d_k(t)$ , den Anfangsbedingungen  $x_{0,k}$  und dem Rauschen  $v_k(t)$  lautet das allgemeine ILR-Gesetz erster Ordnung

$$u_{k+1}(t) = \Phi_{ILR}(u_k(t), e_k(t)) \quad (2.27)$$

mit der Regelabweichung

$$e_k(t) = y_d(t) - y_k(t) \quad (2.28)$$

und dem ILR-Operator  $\Phi_{ILR}$ . Dieser Operator kann dabei linear, nichtlinear, zeitvariant, zeitinvariant, iterationsvariant, iterationsinvariant, kausal oder akausal sein. Akausalität bedeutet hier, dass die Berechnung des Stellgrößenverlaufes  $u_{k+1}(t)$  auch zeitlich spätere Daten der Iteration  $k$  z.B.  $e_k(t + \Delta t)$  berücksichtigen kann. Im Unterschied zur konventionellen Regelung, die zum Zeitpunkt  $t$  den vorherigen Verlauf der Regelabweichung  $e(t - \Delta t)$  verarbeitet, kann eine ILR die Regelabweichung zum gleichen Zeitpunkt  $e_k(t)$  und auch zukünftiger Zeitpunkte  $e_k(t + \Delta t)$  der Iteration  $k$  verwenden.

In der Literatur existieren ILR-Ansätze höherer Ordnung [Moore and Chen, 2002, Moore and Chen, 2003, Norrlöf, 2000], welche die Signalvektoren älterer Iterationen weiter verwenden

$$u_{k+1}(t) = \Phi_{ILR}(u_k(t), u_{k-1}(t), u_{k-2}(t), \dots, e_k(t), e_{k-1}(t), e_{k-2}(t), \dots). \quad (2.29)$$

Allerdings ist hier der ILR-Entwurf deutlich komplexer, sowie speicher- und rechenaufwändiger [Norrlöf, 2000, S.199].

Bei einer ILR handelt es sich um eine iterativ optimierte Vorsteuerung, bei deren Anwendung die Konvergenz über die Iterationen eine wichtige Entwurfsbedingung ist.

$$\|e_{k+1}(t)\| < \|e_k(t)\| \quad (2.30)$$

Das Ziel der ILR ist, eine Stelltrajektorie für die Zykluszeit  $0 < t < T$  zu finden, welche die Ausgangsgröße der Solltrajektorie möglichst genau folgen lässt. Dann konvergiert die Stellgröße

$$\lim_{k \rightarrow \infty} u_k(t) = u^*(t) \quad (2.31)$$

und die Ausgangsgröße

$$\lim_{k \rightarrow \infty} y_k(t) = y^*(t) \rightarrow y_d(t). \quad (2.32)$$

## Eigenschaften des Verfahrens

Die ILR ist ein signalbasiertes iteratives Optimierungsverfahren zur Bestimmung von Stellgrößen trajektorien, das keine Modellierung des Prozesses erfordert. Es gibt die Möglichkeit bei möglichst hohen Lernraten die Konvergenz der Optimierung zu gewährleisten und so wenige Versuche zu benötigen. Des Weiteren ist sie für nichtlineare Prozesse geeignet und kann Begrenzungen der Stellgröße berücksichtigen. Allerdings dient es bisher nicht zur Bestimmung gegebener Vorsteuerungen und Regler.

### 2.3.1. Einführende Festlegungen zu Signalen und Systemen

#### Signalbeschreibung

Die hier beschriebenen ILR-Verfahren verwenden die abgetasteten und gespeicherten Werte der Zeitfunktionen  $u(t)$ ,  $y_d(t)$  und  $y(t)$ . Für die Beschreibung dieser Signale ist eine diskrete Betrachtung und die Verwendung von Vektoren sinnvoll [Moore et al., 2006, Ahn et al., 2007b, Ahn et al., 2007a].

Dabei gilt folgende allgemeine Festlegung für Single Input Single Output (SISO)-Systeme. Die Elemente der Signalvektoren stellen die abgetasteten Werte der kontinuierlichen Signale dar. Die Vektoren haben für die Iteration  $k$  mit der Dauer  $T$  und  $N$  Abtastpunkten die Länge  $N$ . Der Stellgrößenvektor  $\mathbf{u}_k$  beschreibt sich durch

$$\mathbf{u}_k = [u_k(0) \quad u_k(1) \quad \cdots \quad u_k(N-1)]^T, \quad \mathbf{u}_k \in \mathbb{R}^{N \times 1}, \quad (2.33)$$

der Vektor der Regelgröße  $\mathbf{y}_k$  durch

$$\mathbf{y}_k = [y_k(0) \quad y_k(1) \quad \cdots \quad y_k(N-1)]^T, \quad \mathbf{y}_k \in \mathbb{R}^{N \times 1}, \quad (2.34)$$

der Referenzvektor  $\mathbf{y}_d$  durch

$$\mathbf{y}_d = [y_d(0) \quad y_d(1) \quad \cdots \quad y_d(N-1)]^T, \quad \mathbf{y}_d \in \mathbb{R}^{N \times 1} \quad (2.35)$$

und der Vektor der Regelabweichung  $\mathbf{e}_k = \mathbf{y}_d - \mathbf{y}_k$  durch

$$\mathbf{e}_k = [e_k(0) \quad e_k(1) \quad \cdots \quad e_k(N-1)]^T, \quad \mathbf{e}_k \in \mathbb{R}^{N \times 1}. \quad (2.36)$$

Handelt es sich um ein MIMO-System, lassen sich die Vektoren zu Blockvektoren mit  $p$  Eingangssignalen und  $q$  Ausgangssignalen erweitern. Die Anordnung der Vektoren unterscheiden sich laut [Hengen, 2002] in zwei Formen. Die kanonische Form hat sich bei der Verwendung von Systemansätzen wie Impulsantwortmodellen oder Sprungantwortmodellen bewährt. Dabei erweitern sich die Blockvektoren durch das Anhängen der weiteren Eingangs- und Ausgangsgrößen, dargestellt in den Gleichungen A.1 und A.2 im Anhang A. Erfolgen die Betrachtungen in der Zustandsraumdarstellung sind die Blockvektoren in der Zustandsform vorteilhafter. In diesem Fall sortieren sich die Vektoren nach den Abtastpunkten, dargestellt in den Gleichungen A.3 und A.4 im Anhang A. Die Signalvektoren bei MIMO-Systemen haben die Form  $\mathbf{u}_k \in \mathbb{R}^{p \cdot N \times 1}$ ,  $\mathbf{y}_k \in \mathbb{R}^{q \cdot N \times 1}$ ,  $\mathbf{y}_d \in \mathbb{R}^{q \cdot N \times 1}$  und  $\mathbf{e}_k \in \mathbb{R}^{q \cdot N \times 1}$ .

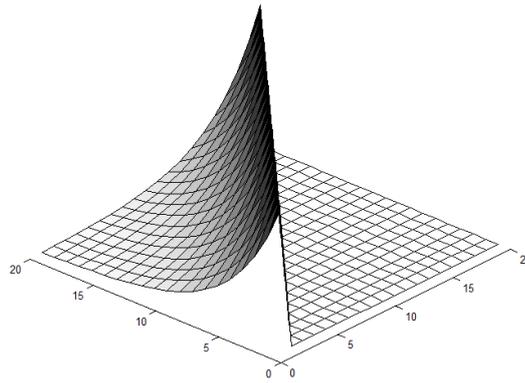
### Systembeschreibung

Die Beschreibung des Prozesses erfolgt auf Grund der diskreten Beschreibung des Stellgrößenverlaufes durch diskrete Modellansätze. Diese dienen zur Herleitung der ILR-Verfahren, dem Entwurf der Lernoperatoren und dem Nachweis der Konvergenz. Solche Modelle lassen sich auf vielfältige Weise z.B. durch Sprungantworten, der Aufstellung von Differentialgleichungen, der Identifikation von Zustandsraummodellen oder der Linearisierung im Arbeitspunkt bzw. der Arbeitstrajektorie bestimmen.

Als wichtiger Modellansatz hat sich die Systembeschreibung als Impulsantwortmodell erwiesen. Diese Beschreibungsform ist in vielen Veröffentlichungen und Büchern über ILR wie beispielsweise in [Ahn et al., 2007b, Andres et al., 2002, Chen and Wen, 1999, Norrlöf and Gunnarsson, 2002, Rockel and Konigorski, 2007] oder [Rogers et al., 2010] zu finden.

Die folgende Gleichung stellt das Impulsantwortmodell eines SISO-Systems dar

$$\mathbf{y}_k = \mathbf{G}\mathbf{u}_k + \mathbf{f}_k + \mathbf{d}_k + \mathbf{v}_k. \quad (2.37)$$



**Abbildung 2.7.** Dreidimensionale Darstellung der Eingangs-Ausgangs-Matrix  $\mathbf{G}$  des Impulsantwortmodells

Dabei stellt  $\mathbf{f}_k$  die freie Antwort des Systems auf die Anfangsbedingungen  $\mathbf{x}_0$ ,  $\mathbf{d}_k$  eine deterministische Störung und  $\mathbf{v}_k$  ein stochastisches Messrauschen dar.  $\mathbf{G}$  ist die Eingangs-Ausgangs-Matrix des Systems und hat die Struktur einer Tridiagonal-Toeplitz-Matrix [Rockel and Konigorski, 2007, S.120].

$$\mathbf{G} = \begin{bmatrix} g(0) & 0 & \cdots & 0 \\ g(1) & g(0) & \cdots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ g(N-1) & \cdots & g(1) & g(0) \end{bmatrix}, \quad \mathbf{G} \in \mathbb{R}^{N \times N} \quad (2.38)$$

Dabei ist  $\mathbf{g}$  der Markov-Spaltenvektor.

$$\mathbf{g} = [g(0) \quad g(1) \quad \cdots \quad g(N-1)]^T, \quad \mathbf{g} \in \mathbb{R}^{N \times 1} \quad (2.39)$$

Abb. 2.7 zeigt ein Darstellungsbeispiel der Eingangs-Ausgangs-Matrix eines Systems erster Ordnung (Verstärkungsfaktor 1) mit  $N = 20$  Elementen, beginnend in der Hauptdiagonalen mit dem Markov-Parameter  $g(0)$ .

**Bestimmung der E/A-Matrix aus der Impulsantwort:** Der Markov-Spaltenvektor entspricht der Gewichtsfolge eines Systems, also der Antwort des Systems auf einen diskreten Einheitsimpuls  $\delta_d(i)$  mit

$$\delta_d(i) = \begin{cases} 1, & i = 0 \\ 0, & i \neq 0 \end{cases}. \quad (2.40)$$

Das Ausgangssignal eines linearen Systems lässt sich durch die Faltungssumme zwischen einem beliebigen Eingangssignal und der Gewichtsfolge beschreiben [Unbehauen, 2007, S.106].

$$y_k(i) = \sum_{\tau=0}^i u_k(\tau)g(i-\tau) \quad (2.41)$$

Für den Einheitsimpuls ergibt sich somit

$$y_k(i) = u_k(0)g(i) = g(i) \quad (2.42)$$

wie auch in Abb. B.2 im Anhang B zu sehen ist. Die folgenden Abschnitte stellen weitere Ansätze zur Bestimmung des Markov-Spaltenvektors vor.

**Bestimmung der E/A-Matrix aus der Sprungantwort:** Aus dem Faltungsintegral 2.41 ergibt sich für eine Sprungantwort eines Eingangssprunges der Sprunghöhe  $\hat{u}$

$$y_k(i) = \hat{u} \sum_{\tau=0}^i g(i - \tau). \quad (2.43)$$

Das Ausgangssignal berechnet sich zu jedem Zeitpunkt  $i$  durch

$$\begin{aligned} y_k(0) &= \hat{u}g(0) \\ y_k(1) &= \hat{u}(g(0) + g(1)) \\ &\vdots \end{aligned} \quad (2.44)$$

so dass für  $\mathbf{G}$  gilt

$$\mathbf{G} = \frac{1}{\hat{u}} \begin{bmatrix} y_k(0) & 0 & \dots & 0 & 0 \\ y_k(1) - y_k(0) & y_k(0) & \dots & \dots & 0 \\ \vdots & \ddots & \ddots & \ddots & 0 \\ y_k(N-1) - \sum_{\tau=0}^{N-2} y_k(\tau) & \dots & \dots & \dots & y_k(0) \end{bmatrix}. \quad (2.45)$$

**Bestimmung der E/A-Matrix aus dem Zustandsraummodell:** Ausgehend vom diskreten Zustandsraummodell mit der Systemmatrix  $\mathbf{A}$ , der Steuermatrix  $\mathbf{B}$ , der Ausgangsmatrix  $\mathbf{C}$  und der Durchgangsmatrix  $\mathbf{D}$

$$\begin{aligned} \mathbf{x}(i+1) &= \mathbf{A}\mathbf{x}(i) + \mathbf{B}u(i) \\ y(i) &= \mathbf{C}\mathbf{x}(i) + \mathbf{D}u(i) \end{aligned} \quad (2.46)$$

ergibt sich durch rekursives Lösen der Gleichungen und  $x(0) = 0$  der Systemausgang zu jedem Zeitpunkt  $i$  durch

$$\begin{aligned} y_k(0) &= \mathbf{D}u_k(0) \\ y_k(1) &= \mathbf{C}\mathbf{B}u_k(0) + \mathbf{D}u_k(1) \\ y_k(2) &= \mathbf{C}\mathbf{A}\mathbf{B}u_k(0) + \mathbf{C}\mathbf{B}u_k(1) + \mathbf{D}u_k(2) \\ &\vdots \end{aligned} \quad (2.47)$$

und  $\mathbf{G}$  ergibt sich durch

$$\mathbf{G} = \begin{bmatrix} \mathbf{D} & 0 & \dots & 0 & 0 \\ \mathbf{C}\mathbf{B} & \mathbf{D} & \dots & \dots & 0 \\ \mathbf{C}\mathbf{A}\mathbf{B} & \mathbf{C}\mathbf{B} & \mathbf{D} & \ddots & 0 \\ \vdots & \ddots & \ddots & \ddots & 0 \\ \mathbf{C}\mathbf{A}^{N-2}\mathbf{B} & \dots & \dots & \mathbf{C}\mathbf{B} & \mathbf{D} \end{bmatrix}, \quad (2.48)$$

in der sich die Markov-Parameter aus den Zustandsraummatrizen berechnen.

**Bestimmung der E/A-Matrix aus der Übertragungsfunktion:** Ausgehend von der diskreten Übertragungsfunktion

$$G_S(z^{-1}) = \frac{\mathbf{B}(z^{-1})}{\mathbf{A}(z^{-1})} \quad (2.49)$$

und der dazugehörigen Differenzgleichung

$$\begin{aligned} \mathbf{A}(z^{-1})y(i) &= \mathbf{B}(z^{-1})u(i) \\ (1 + a_1z^{-1} + \dots + a_mz^{-m})y(i) &= (b_0 + b_1z^{-1} + \dots + b_mz^{-m})u(i) \end{aligned} \quad (2.50)$$

ergibt sich durch rekursives Lösen der Gleichungen und  $y(0) = 0$  eine Gleichung mit einer endlich langen Eingangsfolge. Damit lässt sich der Systemausgang zu jedem Zeitpunkt  $i$  beschreiben

$$\begin{aligned} y_k(0) &= b_0u_k(0) \\ y_k(1) &= (-a_1b_0 + b_1)u_k(0) + b_0u_k(1) \\ &\vdots \end{aligned} \quad (2.51)$$

und  $\mathbf{G}$  ergibt sich aus der Übertragungsgleichung durch

$$\mathbf{G} = \begin{bmatrix} b_0 & 0 & \dots & 0 \\ -a_1b_0 + b_1 & b_0 & \ddots & \vdots \\ a_1^2b_0 - a_2b_0 - a_1b_1 + b_2 & -a_1b_0 + b_1 & b_0 & 0 \\ \dots & \ddots & \ddots & \ddots \end{bmatrix}, \quad (2.52)$$

in der sich die Markov-Parameter aus den Koeffizienten der Übertragungsfunktion berechnen.

**Bestimmung der E/A-Matrix aus Messsignalen:** Gegeben sind die gemessenen Signale  $\mathbf{y}_k$  und  $\mathbf{u}_k$  der Iteration  $k$  des betrachteten Systems

$$\mathbf{y}_k = \mathbf{G}_k\mathbf{u}_k + \mathbf{v}_k \quad (2.53)$$

mit dem stochastischen Rauschsignal  $\mathbf{v}_k$ .

Eine Berechnung der Eingangs-Ausgangs-Matrix  $\mathbf{G}_k$  laut [Ahn et al., 2007b, S.121-123] durch

$$\mathbf{G}_k = \mathbf{y}_k\mathbf{u}_k(\mathbf{u}_k\mathbf{u}_k^T)^{-1} \quad (2.54)$$

ist nicht möglich, wenn  $(\mathbf{u}_k\mathbf{u}_k^T)$  eine singuläre Matrix ergibt. Ist  $u_k(0) \neq 0$ , gilt

$$\mathbf{y}_k = \mathbf{G}_k\mathbf{u}_k = \mathbf{U}_k\mathbf{g}_k \quad (2.55)$$

mit der Tridiagonal-Toeplitz-Matrix des Eingangssignals

$$\mathbf{U}_k = \begin{bmatrix} u_k(0) & 0 & 0 & \cdots & 0 \\ u_k(1) & u_k(0) & 0 & \cdots & 0 \\ u_k(2) & u_k(1) & u_k(0) & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ u_k(N-1) & u_k(N-2) & u_k(N-3) & \cdots & u_k(0) \end{bmatrix} \quad (2.56)$$

$\mathbf{U}_k \in \mathbb{R}^{N \times N}$

und dem Markov-Spaltenvektor

$$\mathbf{g}_k = [g_k(0) \quad g_k(1) \quad \cdots \quad g_k(N-1)]^T, \quad (2.57)$$

welcher der ersten Spalte der Eingangs-Ausgangs-Matrix  $\mathbf{G}_k$  entspricht. Im folgenden sind zwei übliche Verfahren zur Berechnung von  $\mathbf{g}_k$  beschrieben.

**Methode der kleinsten Fehlerquadrate:** Ein gängiges Verfahren ist die Methode der kleinsten Fehlerquadrate.  $\mathbf{g}_k$  berechnet sich aus

$$\mathbf{g}_k = (\mathbf{U}_k^T \mathbf{U}_k)^{-1} \mathbf{U}_k^T \mathbf{y}_k. \quad (2.58)$$

Hierbei ist keinerlei Kenntnis des Rauschsignals notwendig. Kleine Abtastzeiten führen im Zusammenhang mit stochastischem Messrauschen zu einer schlechten Schätzung des Markov-Spaltenvektors.

**Wiener-Filter:** In [Ahn et al., 2007b, S.122f.] empfehlen die Autoren den Einsatz eines Wiener-Filters, um die stochastischen Parameter des Rauschsignals zu berücksichtigen. So bestimmt sich  $\mathbf{g}_k$  aus

$$\mathbf{g}_k = (\mathbf{U}_k^T \mathbf{U}_k + \sigma_v^2 \mathbf{R}^{-1})^{-1} \mathbf{U}_k^T \mathbf{y}_k \quad (2.59)$$

mit  $\mathbf{R} = \mathbb{E}[\mathbf{g}_k, \mathbf{g}_k^T]$  und der Varianz des Rauschsignals  $\sigma_v^2$ . [Ahn et al., 2007b, S.122f.] fasst  $\mathbf{g}_k = \mathbf{g}_k^\circ + \Delta \mathbf{g}_k$  als Intervallvektor in den Grenzen  $\mathbf{g}_k = [\underline{\mathbf{g}}_k, \bar{\mathbf{g}}_k]$  auf und reduziert die Bestimmung von  $\mathbf{R}$  zu

$$\mathbf{R} = \mathbb{E}[\mathbf{g}_k, \mathbf{g}_k^T] = \begin{bmatrix} g_k^\circ(0)g_k^\circ(0) & g_k^\circ(0)g_k^\circ(1) & \cdots & g_k^\circ(0)g_k^\circ(N-1) \\ g_k^\circ(1)g_k^\circ(0) & g_k^\circ(1)g_k^\circ(1) & \cdots & g_k^\circ(1)g_k^\circ(N-1) \\ \vdots & \vdots & \ddots & \vdots \\ g_k^\circ(N-1)g_k^\circ(0) & g_k^\circ(N-1)g_k^\circ(1) & \cdots & g_k^\circ(N-1)g_k^\circ(N-1) \end{bmatrix}. \quad (2.60)$$

Da diese Matrix einen Rang von eins besitzt, ist zur Herstellung der Invertierbarkeit auf jedes Element eine leichte Intervallunsicherheit zu addieren.

Die Abb. 2.8 zeigt die Veränderung der Schätzung von Abb. 2.7 bei einem zusätzlichen Messrauschen.

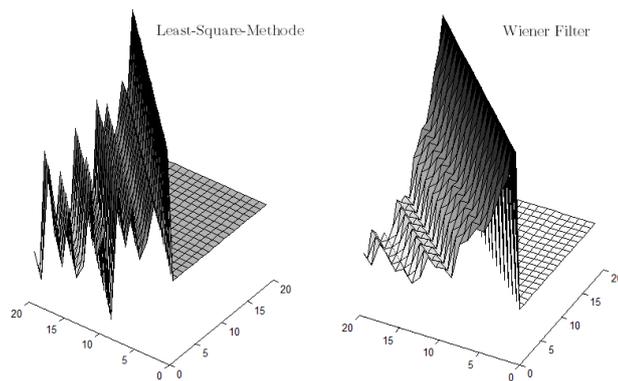


Abbildung 2.8. Dreidimensionale Darstellung der Eingangs-Ausgangs-Matrix  $G$  bei verrauschtem Ausgangssignal

### Berücksichtigung des Relativgrades

Bisher erfolgte die Systembetrachtung für Prozesse mit Durchgriff, d.h. in Gleichung 2.46 ist  $D \neq 0$  bzw. in Gleichung 2.50 ist  $b_0 \neq 0$ . Durchgriff bedeutet, dass mit der Änderung der Eingangsgröße eine sofortige Änderung der Ausgangsgröße erfolgt. Die meisten technischen Systeme sind allerdings ohne Durchgriff. Dies ist durch existierende Verzögerungszeiten und Totzeiten im Prozess begründet. Für die ILR ist dies eine wichtige Eigenschaft und führt zur Einführung der Beschreibungsform des „Lifted-System“, um nur den beeinflussbaren Teil der Ausgangsgröße zu betrachten. Eine Auskunft liefert die Bestimmung des Differenzgrades der diskreten Übertragungsfunktion.

**Definition 2.1 (Differenzgrad)** Der Differenzgrad  $m$  eines diskreten linearen Systems ist laut [Föllinger et al., 1995, S.489] definiert als die Differenz zwischen der Polynomordnung des Nennerpolynoms  $A(z)$  und der Polynomordnung des Zählerpolynoms  $B(z)$ .

$$m = \text{Ord}(A(z)) - \text{Ord}(B(z)) \quad (2.61)$$

Für nichtlineare Systeme ist der Relativgrad relevant [Schröder, 2010, S.409], der im Falle eines diskreten linearen Systems dem Differenzgrad entspricht. Ausgehend von einem nichtlinearem System

$$\dot{x}(t) = f(x(t)) + g(x(t))u(t), \quad t > 0 \quad (2.62)$$

$$y(t) = h(x(t)) \quad (2.63)$$

sind zur Bestimmung des Relativgrades die Lie-Ableitungen der Systemfunktion  $h(x)$  zu ermitteln.

**Definition 2.2 (Relativer Grad)** Das nichtlineare System (2.62) hat an der Stelle  $\bar{x} \in U$  einen Relativgrad  $m$ , wenn

$$a) \quad L_g L_f^n = 0 \text{ für } n = 0, \dots, m-2 \text{ und alle } x \in U, \text{ sowie}$$

$$b) L_g L_f^{m-1} h(\bar{x}) \neq 0.$$

Der Relativgrad entspricht der Anzahl der zeitlichen Differentiationen der Ausgangsgröße  $y(t)$  in der die Eingangsgröße erstmalig erscheint [Lunze, 2010, S.285f.]. Bei linearen Systemen ist der Relativgrad für alle  $x$  konstant und damit global gültig. Für nichtlineare Systeme gilt das nicht. Hier kann es zu Abhängigkeiten vom betrachteten Punkt  $\bar{x}$  kommen. In der Literatur wird daher noch in den gleichförmigen Relativgrad [Byrnes and Isidori, 1991], in den starken und in den schwachen Relativgrad [Fuchs et al., 1993] sowie in den strengen Relativgrad [Saberri and Lin, 1994] unterschieden.

Mit bekanntem relativem Grad erfolgt laut [Ahn et al., 2007b] die Beschreibung des „Lifted-System“ in der Super-Vektor-Schreibweise. Dazu ist die vektorielle Beschreibung in Gleichung 2.37 in den beeinflussbaren Teil und den nicht beeinflussbaren Teil der Ausgangsgröße zu strukturieren. Es gilt

$$\begin{bmatrix} \mathbf{y}_f \\ \mathbf{y}_b \end{bmatrix} = \begin{bmatrix} \mathbf{0} & \mathbf{0} \\ \mathbf{G} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{u}_b \\ \mathbf{u}_f \end{bmatrix} \quad (2.64)$$

mit dem nicht beeinflussbaren Vektor der Ausgangsgröße

$$\mathbf{y}_f = [y_k(0) \quad y_k(1) \quad \cdots \quad y_k(m-1)]^T, \quad (2.65)$$

mit dem beeinflussbaren Vektor der Ausgangsgröße

$$\mathbf{y}_b = [y_k(m) \quad y_k(m+1) \quad \cdots \quad y_k(N-1)]^T, \quad (2.66)$$

mit dem beeinflussenden Vektor der Eingangsgröße

$$\mathbf{u}_b = [u_k(0) \quad u_k(1) \quad \cdots \quad u_k(N-m-1)]^T \quad (2.67)$$

und mit dem nicht relevanten Vektor der Eingangsgröße

$$\mathbf{u}_f = [u_k(N-m) \quad u_k(N-m+1) \quad \cdots \quad u_k(N-1)]^T. \quad (2.68)$$

Damit beschreibt sich das „Lifted-System“ durch

$$\mathbf{y}_b = \mathbf{G}\mathbf{u}_b. \quad (2.69)$$

In den folgenden Abschnitten und Kapiteln erfolgt die weitere Betrachtung des Systems nun immer als „Lifted-System“ in der Schreibweise

$$\mathbf{y}_k = \mathbf{G}\mathbf{u}_k. \quad (2.70)$$

### 2.3.2. Eigenschaften einer ILR

Zu den wichtigsten Eigenschaften einer ILR gehört die Konvergenz bzw. die Stabilität. Für den Entwurf der Lernoperatoren  $Q$  und  $L$  ist das oberste Ziel die Gewährleistung der Konvergenz. Viele Entwurfsverfahren sind darauf ausgelegt, monotone Konvergenz



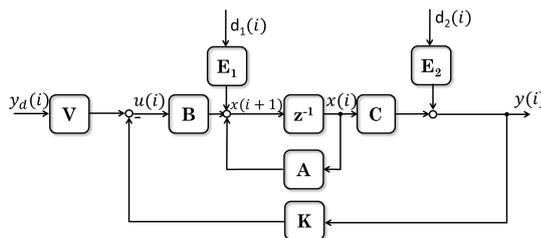


Abbildung 2.10. Strukturabbild einer Zustandsregelung

mit der Systemmatrix  $A$ , der Steuermatrix  $B$ , der Ausgangsmatrix  $C$ , dem Vorfilter  $V$ , der Rückführmatrix  $K$  und den Einkoppelmatrizen für Zustands- und Ausgangsstörungen  $E_1$  und  $E_2$  ergibt folgende Gemeinsamkeiten

$$Q = A, \quad I = B, \quad G = C, \quad (2.80)$$

$$0 = E_1, \quad I = E_2, \quad L = K, \quad L = V. \quad (2.81)$$

In dieser Darstellung ist die ILR ein MIMO-System mit  $N$  Zuständen,  $N$  Eingängen und  $N$  Ausgängen, da jeder Wert in der Zeitebene eine Zustandsgleichung in der Iterationsebene erzeugt. Laut [Rockel and Konigorski, 2007, S.122] führt die parametrische Darstellung einer zweidimensionalen Beschreibung eines SISO-ILR-Systems zu einer eindimensionalen Betrachtung eines MIMO-Systems.

Dies führt zur Darstellung der geregelten Zustandsgleichungen

$$x(i+1) = (A - BKC)x(i) + Vy_d(i) - BE_2d_2(i) + E_1d_1(i) \quad (2.82)$$

und

$$u_{k+1} = (Q - LG)u_k + Ly_d - L(f_k + d_k + v_k). \quad (2.83)$$

Diese sind stabil, wenn alle Polstellen der erweiterten Systemmatrizen  $(A - BKC)$  bzw.  $Q - LG$  innerhalb des Einheitskreises liegen [Rockel and Konigorski, 2007, S.122].

$$\det(z_{p_i}I - (Q - LG)) = 0 \quad (2.84)$$

$$\text{und } |z_{p_i}| < 1 \quad \forall i \in [1, \dots, N+1] \quad (2.85)$$

Dadurch lässt sich der Konvergenznachweis als Stabilitätsnachweis betrachten.

### Konvergenzbetrachtung mittels Normen

Die Regelabweichung der nächsten Iteration  $e_{k+1}$  ergibt sich aus 2.71 und 2.72 und  $Q = I$  zu

$$\begin{aligned} e_{k+1} &= y_d - y_{k+1} = y_d - Gu_{k+1} - f_{k+1} - d_{k+1} - v_{k+1} \\ &= y_d - Gu_k - GLe_k - f_{k+1} - d_{k+1} - v_{k+1}. \end{aligned} \quad (2.86)$$

Mit  $Gu_k = y_k + f_k + d_k + v_k$  ergibt sich damit

$$\begin{aligned} e_{k+1} &= y_d - y_k - GLe_k + (f_k - f_{k+1} + d_k - d_{k+1} + v_k - v_{k+1}) \\ &= (I - GL)e_k + (f_k - f_{k+1} + d_k - d_{k+1} + v_k - v_{k+1}). \end{aligned} \quad (2.87)$$

**Definition 2.3 (ILR-Entwurfsgleichung)** In der ILR-Theorie stellt der Term

$$\mathbf{e}_{k+1} = (\mathbf{I} - \mathbf{GL}) \mathbf{e}_k \quad (2.88)$$

die ILR-Entwurfsgleichung dar.

Bei vielen Entwurfsverfahren ist der Ansatz der Konvergenzbetrachtung durch Normen definiert. Damit ergibt sich für die ILR-Entwurfsgleichung folgende allgemeine Beschreibung [Ahn et al., 2007b, S.29]

$$\|\mathbf{e}_{k+1}\| = \|(\mathbf{I} - \mathbf{GL})\mathbf{e}_k\| \leq \|\mathbf{I} - \mathbf{GL}\| \|\mathbf{e}_k\|. \quad (2.89)$$

Ziel des Entwurfes muss es also sein, dass  $\|\mathbf{I} - \mathbf{GL}\| < 1$  ist und somit die Regelabweichung mit jeder Iteration abnimmt ( $\|\mathbf{e}_{k+1}\| < \|\mathbf{e}_k\|$ ).

Für den allgemeineren Fall, dass  $\mathbf{Q} \neq \mathbf{I}$  ist (Einsatz eines Q-Filters), bestimmt sich  $\mathbf{e}_{k+1}$  durch

$$\mathbf{e}_{k+1} = (\mathbf{Q} - \mathbf{GL}) \mathbf{e}_k + (\mathbf{I} - \mathbf{Q})\mathbf{y}_d + (\mathbf{f}_k - \mathbf{f}_{k+1} + \mathbf{d}_k - \mathbf{d}_{k+1} + \mathbf{v}_k - \mathbf{v}_{k+1}) \quad (2.90)$$

und die Konvergenzbetrachtung ergibt

$$\|\mathbf{e}_{k+1}\| = \|(\mathbf{Q} - \mathbf{GL})\mathbf{e}_k\| \leq \|\mathbf{Q} - \mathbf{GL}\| \|\mathbf{e}_k\|, \quad (2.91)$$

so dass in diesem Fall  $\|\mathbf{Q} - \mathbf{GL}\| < 1$  sein muss.

### Regelgüte

Die nächste wichtige Eigenschaft der ILR ist die Regelgüte, d.h. welches Ergebnis erreicht die ILR nach mehreren Iterationen. In der Annahme, dass die Anfangszustände in jeder Iteration konstant sind und damit die freie Antwort  $\mathbf{f}_k = \mathbf{f}$  des Systems iterationsinvariant und eine iterationsinvariante Störung  $\mathbf{d}_k = \mathbf{d}$  vorliegt, sowie das Messrauschen  $\mathbf{v}_k$  nicht vorhanden ist, lässt sich aus den bisherigen Gleichungen die Regelabweichung  $\mathbf{e}_\infty$  für  $k \rightarrow \infty$  herleiten. Aus  $\mathbf{e}_\infty = \mathbf{y}_d - \mathbf{y}_\infty$  und  $\mathbf{y}_\infty = \mathbf{G}\mathbf{u}_\infty + \mathbf{f} + \mathbf{d}$  ergibt sich

$$\mathbf{e}_\infty = \mathbf{y}_d - \mathbf{G}\mathbf{u}_\infty - \mathbf{f} - \mathbf{d}. \quad (2.92)$$

Da die Konvergenz nachgewiesen ist, kann in Gleichung 2.72 der Zusammenhang  $\mathbf{u}_{k+1} = \mathbf{u}_k = \mathbf{u}_\infty$  gelten. Es ergibt sich

$$\mathbf{u}_\infty = \mathbf{Q}\mathbf{u}_\infty + \mathbf{L}\mathbf{e}_\infty \quad (2.93)$$

und  $\mathbf{u}_\infty$  berechnet sich durch

$$\mathbf{u}_\infty = (\mathbf{I} - \mathbf{Q} + \mathbf{LG})^{-1} \mathbf{L}(\mathbf{y}_d - \mathbf{f} - \mathbf{d}). \quad (2.94)$$

Dadurch gilt

$$\mathbf{e}_\infty = (\mathbf{I} - \mathbf{G}(\mathbf{I} - \mathbf{Q} + \mathbf{LG})^{-1} \mathbf{L})(\mathbf{y}_d - \mathbf{f} - \mathbf{d}). \quad (2.95)$$

Diese Gleichung zeigt, dass die Regelabweichung für  $k \rightarrow \infty$  nur null erreicht, wenn  $\mathbf{Q}$  eine Einheitsmatrix ist. Aus den Vergleichen in 2.80 lässt sich erkennen, dass  $\mathbf{Q}$  die

Systemmatrix der offenen ILR ist. Daher stellt der Fall  $\mathbf{Q} = \mathbf{I}$  für die offene ILR eine Strecke mit  $N$ -fachem Integrator dar. Laut [Roover et al., 2000] ist dies mit dem „Internen-Modell-Prinzip“ (internal model principle) vergleichbar. Dieses Prinzip besagt folgendes: Wenn die Störunterdrückung bzw. die Folgeregelung sowie das interne Stabilitätsproblem gelöst sind, beinhaltet die interne Regelschleife ein exaktes Duplikat des Nenners der Inversen der externen Anregung an der Stelle, an der die externe Anregung auf den Regelkreis aufsummiert wird [Weinmann, 1991, S.461].

Bei iterationsvarianten Störungen und stochastischem Messrauschen ist das Ziel, die Regelabweichung zu null zu bekommen, nicht erreichbar. Sie bewirken im Gegenteil eine Verschlechterung des Ergebnisses. Der mögliche Einsatz eines Q-Filters dient zur Dämpfung des Einflusses dieser Rauschsignale auf die Stelltrajektorie. Möglich ist z.B. eine akasale Tiefpassfilterung mit dem Filter  $Q(z) = Q_1(z)Q_1^{-1}(z)$  ohne Phasendrehung [Nahrstaedt et al., 2008, S.499].

### Variierende Anfangszustände

Wie schon erwähnt, wirkt sich die freie Antwort des Systems auf die Anfangszustände nicht auf die ILR aus, wenn die Anfangsbedingungen  $\mathbf{x}_k(0) = \mathbf{x}(0) = \mathbf{x}_0$ ,  $\mathbf{x}_0 \in \mathbb{R}^q$  in jeder Iteration konstant sind und somit  $\mathbf{f}_{k+1} = \mathbf{f}_k = \mathbf{f}$  gilt. Dazu ist der Prozess vor jeder Iteration in den Anfangszustand  $\mathbf{x}_0$  zu bringen. Ist dies nicht der Fall, gibt es verschiedene Vorgehensweisen dem entgegenzuwirken.

1. robuster Entwurf der Lernoperatoren, was aber zu einem trägerem Lernverhalten führt [Laidig et al., 2014]
2. Einsatz eines Q-Filters
3. Kompensation der freien Antwort  $\mathbf{f}_{k+1} = \mathbf{G}_0 \mathbf{x}_{k+1}(0)$  [Hengen, 2002, S.46ff.]  
Die Voraussetzung hier ist, dass  $\mathbf{x}_{k+1}(0)$  bestimmbar ist und eine genaue Beschreibung von  $\mathbf{G}_0 = [\mathbf{C} \quad \mathbf{C}\mathbf{A} \quad \dots \quad \mathbf{C}\mathbf{A}^{N-1}]^T$  sowie der Eingangs-Ausgangs-Matrix  $\mathbf{G}$  vorliegt. Dann erweitert sich das ILR-Gesetz zu

$$\mathbf{u}_{k+1} = \mathbf{u}_k + \mathbf{L}\mathbf{e}_k - (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}_0 \mathbf{x}_{k+1}(0). \quad (2.96)$$

Es ergibt sich somit für  $\mathbf{y}_{k+1}$  der Zusammenhang

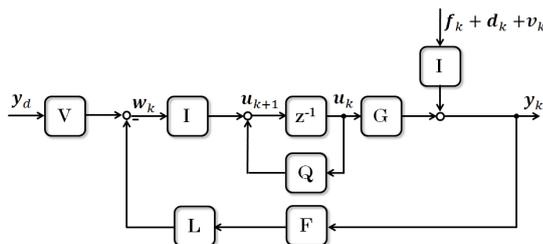
$$\mathbf{y}_{k+1} = \mathbf{G}(\mathbf{u}_k + \mathbf{L}\mathbf{e}_k - (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}_0 \mathbf{x}_{k+1}(0)) + \mathbf{G}_0 \mathbf{x}_{k+1}(0) \quad (2.97)$$

in dem  $\mathbf{f}_{k+1}$  kompensiert ist.

4. Erweiterung der ILR-Struktur durch einen Reglereinsatz und Berücksichtigung des Reglerstellanteils durch einen zusätzlichen Lernoperator [Sun and Wang, 2002]

### Generalisierte Darstellung und weitere ILR-Formen

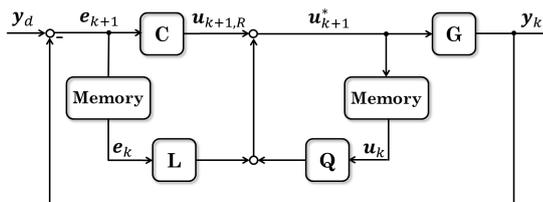
In [Rockel and Konigorski, 2007, S.121] ist eine generalisierte parametrische Darstellung einer ILR beschrieben. Die Autoren erweitern den Lernoperator mit einem zusätzlichen Filter der Regelgröße und trennen den Lernwert aus der Regelabweichung in den Sollwertanteil und Regelgrößenanteil auf, die unterschiedliche Lernoperatoren beinhalten



**Abbildung 2.11.** Generalisierte parametrische Darstellung einer iterativ lernenden Regelung [Rockel and Konigorski, 2007, S.121]

(Abb. 2.11). Dadurch sind weitere Entwurfsziele darstellbar und formulierbar. So ist nun eine (akausale) Filterung der Regelgröße beschreibbar. Durch  $\mathbf{V} = \mathbf{L}$  und  $\mathbf{F} = \mathbf{I}$  lässt sich die Standardform der ILR wiederherstellen.

Bei instabilen Prozessen ist ein Regler zur Stabilisierung notwendig. Dies macht die Kombination einer ILR mit einem Regler erforderlich. Diese Erweiterung hat in der Literatur die Bezeichnung Current-Iteration Tracking Error ILC (CITE-FB) bzw. Current-Cycle Feedback ILC (CCF-ILC) [Norrlöf, 2000, S.41f.]. Abb. 2.12 zeigt die Struktur der erweiterten ILR in der zyklusbasierten Darstellung. Es ist zu erkennen, dass der Regler ( $C$ ) im jeweils aktuellen Zyklus  $k$  aktiv ist, er selbst sich aber mit den Iterationen nicht ändert.



**Abbildung 2.12.** Zyklusbasierte Darstellung der erweiterten Struktur einer iterativ lernenden Regelung mit zusätzlichem Regler [Norrlöf, 2000, S.42]

Die folgende Gleichung beschreibt das ILR-Stellgesetz einer CITE-FB

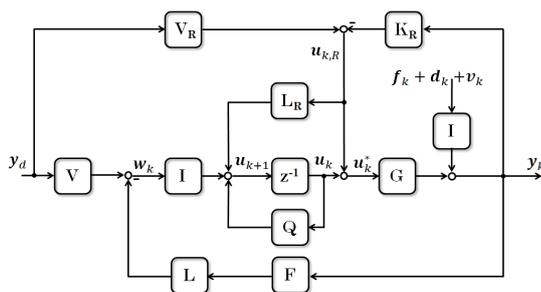
$$\mathbf{u}_{k+1} = \mathbf{Q}\mathbf{u}_k + \mathbf{L}\mathbf{e}_k + \mathbf{C}\mathbf{e}_{k+1}. \quad (2.98)$$

[Chen et al., 1996] untersucht die Eigenschaften eines D-Typ CITE-FB der Form

$$\mathbf{u}_{k+1} = \mathbf{u}_k + \mathbf{L}\dot{\mathbf{e}}_k + \mathbf{K}_R\dot{\mathbf{e}}_{k+1}, \quad (2.99)$$

die die Ableitung der Regelabweichung der aktuellen und der vorhergehenden Iteration im ILR-Stellgesetz verwendet. Die Autoren zeigen, dass der finale Regelfehler begrenzt ist und diese Grenze von den Systemungenauigkeiten und Störungen abhängig ist. Der Beitrag [Chen et al., 1997] erweitert diese Betrachtung auf ein CITE-FB höherer Ordnung.

Bei der erweiterten ILR handelt es sich nicht nur um eine simple Erweiterung durch einen parallel zur ILR geschalteten Regler. Hier ist es möglich, den Stellgrößenanteil des Reglers  $\mathbf{u}_{k_R}$  mit einem Lernoperator  $\mathbf{L}_R$  als zusätzlichen Lernwert in der ILR zu berücksichtigen. Die parametrische Darstellung aus [Rockel and Konigorski, 2007, S.123]



**Abbildung 2.13.** Parametrische Darstellung der erweiterten Struktur einer ILR mit zusätzlichem Regler [Rockel and Konigorski, 2007, S.123]

liefert dafür das Strukturbild Abb. 2.13. Der Regler besteht hier aus dem Vorfilter  $V_R$  und der Rückführung der Regelgröße durch  $K_R$ .

Eine besondere Form der CITE-FB stellt die Variante des Lernens aus der Reglerstellgröße dar. Hierbei sind  $\mathbf{V} = 0$ ,  $\mathbf{L} = 0$  und  $\mathbf{F} = 0$ . Dadurch reduziert sich der Lerneffekt der ILR auf den Stellgrößenverlauf des Reglers [Amann et al., 1994, Sun and Wang, 2002, Tayebi and Zaremba, 2003]. [Amann et al., 1994] beschreibt ein mögliches Stellgesetz einer reduzierten CITE-FB durch

$$\mathbf{u}_{k+1} = K\mathbf{e}_{k+1} + \sum_{j=1}^M \beta_j \mathbf{u}_{k+1-j}. \quad (2.100)$$

$M$  entspricht der Ordnung der ILR, d.h. die Bestimmung des Stellgrößenverlaufes  $\mathbf{u}_{k+1}$  beinhaltet somit die Verläufe der letzten  $M$  Iterationen.

### 2.3.3. ILR-Entwurfverfahren

Dieser Abschnitt stellt verschiedene ILR-Ansätze vor, beginnend bei den klassischen Verfahren bis hin zu neueren Beschreibungen z.B. aus der MFAC-Theorie. Der Ausgangspunkt des Entwurfes ist das ILR-Stellgesetz  $\mathbf{u}_{k+1} = \mathbf{u}_k + \mathbf{L}\mathbf{e}_k$ , bei dem der Filter  $\mathbf{Q}$  einer Einheitsmatrix  $\mathbf{I}$  entspricht.

#### Klassische ILR

Zu den ersten englischsprachigen Veröffentlichungen, die ein iterativ lernendes Regelgesetz beschreiben, gehört [Arimoto et al., 1984]. In diesem Beitrag erfolgt die ILR-Beschreibung noch mit kontinuierlicher Zeit für ein lineares zeitinvariantes System. Das Stellgesetz des so genannten „Arimoto-Algorithmus“ (auch als P-ILR-Typ bezeichnet) lautet dabei wie folgt:

$$u_{k+1}(t) = u_k(t) + l_P e_k(t) \quad (2.101)$$

mit dem Lernoperator  $l_P$ . Die Autoren zeigen, dass für dieses System (mit den Zustandsraummatrizen  $\mathbf{A}$ ,  $\mathbf{B}$  und  $\mathbf{C}$ ) sich der Lernoperator so bestimmen lässt, dass die Konvergenz gewährleistet ist und  $\lim_{k \rightarrow \infty} y_k(t) \rightarrow y_d(t)$  gilt. Eine generalisierte Darstellung

des Algorithmus stellt die ILR mit PID-Struktur [Moore, 2001a, Ahn et al., 2007b]

$$u_{k+1}(t) = u_k(t) + l_P e_k(t) + l_D \dot{e}_k(t) + l_I \int_{\tau=0}^t e_k(\tau) d\tau \quad (2.102)$$

mit den weiteren Lernoperatoren  $l_D$  und  $l_I$  dar. Die diskrete Schreibweise von 2.101 ist durch

$$u_{k+1}(i) = u_k(i) + l_P e_k(i + m) \quad (2.103)$$

gegeben. In der Vektorschreibweise der „Lifted-System“-Betrachtung ergibt sich diese Gleichung zu

$$\mathbf{u}_{k+1} = \mathbf{u}_k + l_P \mathbf{e}_k. \quad (2.104)$$

Wie in Abschnitt 2.3.2 beschrieben, muss  $\|\mathbf{I} - l_P \mathbf{G}_k\| < 1$  erfüllt sein, um ein konvergentes Lerngesetz zu erreichen. Die Beiträge [Moore, 2001b] und [Chen and Moore, 2002] zeigen, dass bei der Betrachtung der  $\infty$ -Norm der ILR-Entwurfsgleichung für ein diskretes, lineares und zeitinvariantes System

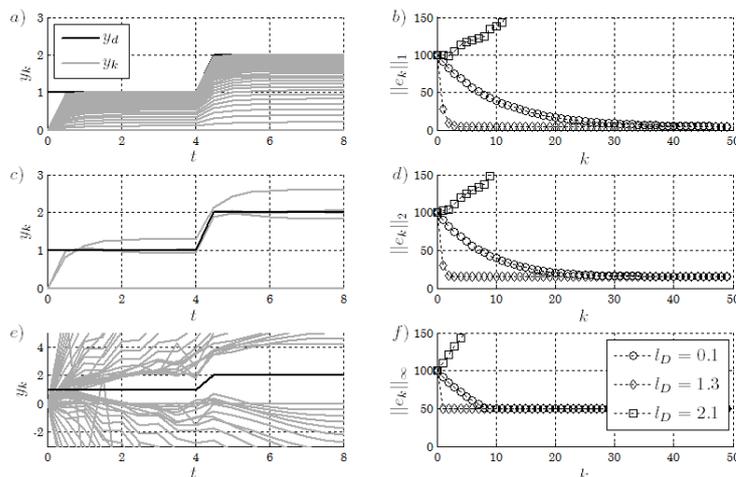
$$\|\mathbf{I} - l_P \mathbf{G}_k\|_\infty = \max_j \sum_{i=0}^{N-1} |(\mathbf{I} - l_P \mathbf{G}_k)| < 1 = |1 - l_P g(0)| + |l_P| \sum_{j=1}^{N-1} |g(j)| < 1 \quad (2.105)$$

der Lernoperator  $l_P$  durch die beiden Fälle

- a)  $1 - l_P g(0) > 0$  wenn  $|g(0)| > \sum_{j=1}^{N-1} |g(j)|$  und
- b)  $1 - l_P g(0) < 0$  wenn  $|l_P| < \frac{2}{|g(0)| + \sum_{j=1}^{N-1} |g(j)|} = \frac{2}{\|\mathbf{G}_k\|_\infty}$

bestimmt ist und die ILR monotone Konvergenz erreicht. Im Fall a) bestimmt sich  $l_P$  durch  $|l_P| < |\frac{1}{g(0)}|$ , wenn der Betrag des ersten Elements des Markov-Spaltenvektors größer ist als die Summe der Beträge aller restlichen Markov-Parameter. Oder  $|l_P| > |\frac{1}{g(0)}|$  im Fall b), wenn die  $l_P$  kleiner als 2 geteilt durch die Summe der Beträge des gesamten Markov-Spaltenvektors ist.

Abb. 2.14 zeigt ein Simulationsbeispiel einer P-ILR-Typ Struktur an einem System erster Ordnung und einer Abtastzeit von 0,5s. In diesem Beispiel ist  $g(0) = 0,63$  und  $\sum_{j=1}^{N-1} |g(j)| = 0,37$ , sodass durch Fall a) der Grenzwert für  $l_P$ , für den Konvergenz gewährleistet ist, bei  $l_P < \frac{1}{g(0)} = 1,58$  liegt. Die Diagramme a), c) und e) stellen den zeitlichen Verlauf des Sollwertes  $\mathbf{y}_d$  (schwarz) und die zeitlichen Verläufe der Regelgröße  $\mathbf{y}_k$  der einzelnen Iterationen (grau) bei einem unterschiedlichen Lernfaktor  $l_P$  dar. Die Diagramme b), d) und f) bilden die Verläufe der Normen: 1-Norm, 2-Norm und  $\infty$ -Norm der Regelabweichung der drei Lernvarianten über die Iteration  $k$  ab. Die Verläufe dieser Diagramme sind auf den Startwert  $\|\mathbf{e}_1\| = 100\%$  bezogen. Im Diagramm c) liegt der Lernfaktor in der Nähe des Grenzwertes. Daraus resultierend ergibt sich hier ein schnelle Lernrate von nur 3 Iterationen bis zum Endergebnis. Ist der Lernfaktor deutlich kleiner, wie im Diagramm a) dargestellt, nimmt die Lernrate ab. Das Diagramm e) zeigt ein divergentes Verhalten, da der Lernfaktor zu hoch gewählt ist. Die Ursache der Abweichung zu Beginn liegt in der Abtastrate. Zum Zeitpunkt  $t = 0s$  ist  $y_k(0) = 0$ . Daraus folgt, dass der Endwert der Norm-Verläufe ungleich null ist.



**Abbildung 2.14.** Darstellung der Entwicklung eines P-ILR-Typs mit verschiedenen Lernfaktoren an einem linearen und zeitinvarianten System erster Ordnung

### Erweiterung zum PD-ILR-Typ

Insbesondere bei schlecht gedämpften Systemen weist der P-ILR-Typ eine unzureichende Funktionalität auf. Der optimale Lernoperator  $l_P$  ist dann so klein, dass die ILR nur sehr langsam konvergiert [Chen and Moore, 2002]. Dies lässt sich durch die Erweiterung zum PD-ILR-Typ verbessern.

Die diskrete Schreibweise des PD-ILR-Typs mit der Verwendung des Differenzenquotienten lautet

$$u_{k+1}(i) = u_k(i) + l_P e_k(i) + l_D (e_k(i+1) - e_k(i)) \quad (2.106)$$

mit dem Lernfaktoren  $l_P$  und  $l_D$ . Die Differenz  $e_k(i+1) - e_k(i)$  bestimmt die Ableitung der Regelabweichung zum Zeitpunkt  $i$ . Diese Berechnung ist sehr rauschanfällig, so dass eine Bestimmung des Durchschnitts mehrerer Ableitungen praktikabler ist [Chen and Moore, 2002]. Dies führt zu der allgemeineren Darstellung

$$u_{k+1}(i) = u_k(i) + l_P e_k(i) + \frac{l_D}{\alpha} (e_k(i+1) - e_k(i+1-\alpha)) \quad (2.107)$$

mit der Anzahl der zu mittelnden Ableitungen  $\alpha$  ( $\alpha \in \mathbb{N}$ ). Die Überführung dieser Gleichung in die Super-Vektor-Darstellung benötigt eine Transformation der Vektoren, da in dieser Schreibweise der Vektor  $\mathbf{e}_k$  mit dem Element  $e_k(i+1)$  beginnt. Dazu dient die Transformationsmatrix  $\mathbf{T}_\alpha$

$$\mathbf{T}_\alpha = \begin{bmatrix} \mathbf{0}_{\alpha \times N} \\ \mathbf{I}_{(N-\alpha) \times (N-\alpha)} \quad \mathbf{0}_{(N-\alpha) \times \alpha} \end{bmatrix} \quad (2.108)$$

bestehend aus zwei Nullmatrizen und einer Einheitsmatrix. Das Beispiel  $\alpha = 1$  soll den

Aufbau des Vektors verdeutlichen. Die Matrix  $\mathbf{T}_\alpha = \mathbf{T}_1$  ergibt sich zu

$$\mathbf{T}_1 = \begin{bmatrix} 0 & 0 & 0 & \cdots & 0 & 0 \\ 1 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 1 & 0 & \cdots & 0 & 0 \\ 0 & 0 & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & 1 & 0 \end{bmatrix}. \quad (2.109)$$

Die Matrix  $\mathbf{T}_\alpha$  stellt eine untere Toeplitz-Matrix dar. Damit lässt sich das ILR-Lerngesetz durch

$$\mathbf{u}_{k+1} = \mathbf{u}_k + l_P \mathbf{T}_1 \mathbf{e}_k + \frac{l_D}{\alpha} (\mathbf{I} - \mathbf{T}_\alpha) \mathbf{e}_k \quad (2.110)$$

beschreiben. Die ILR-Entwurfsgleichung, zusammengefasst als Matrix  $\mathbf{H}_\alpha$ , lautet dann wie folgt:

$$\|\mathbf{H}_\alpha\| = \|\mathbf{I} - l_P \mathbf{G}_k \mathbf{T}_1 - \frac{l_D \mathbf{G}_k}{\alpha} + \frac{l_D \mathbf{G}_k}{\alpha} \mathbf{T}_\alpha\| < 1. \quad (2.111)$$

Wie bei dem P-ILR-Typ erfolgt in [Chen and Moore, 2002] die Konvergenzbetrachtung durch die  $\infty$ -Norm. Da die Matrizen  $\mathbf{G}_k$ ,  $\mathbf{T}_\alpha$  und  $\mathbf{T}_1$  untere tridiagonale Toeplitz-Matrizen sind, besitzt auch  $\mathbf{H}_\alpha$  diese Eigenschaft. Bei solchen Matrizen gilt, die Zeilensummennorm ist gleich der Spaltensummennorm. Dies entspricht der 1-Norm der ersten Spalte  $\mathbf{h}_\alpha$  von  $\mathbf{H}_\alpha$ .

$$\|\mathbf{H}_\alpha\|_\infty = \|\mathbf{H}_\alpha\|_1 = \|\mathbf{h}_\alpha\|_1 = \sum_{j=0}^{N-1} |h_\alpha(j)| \quad (2.112)$$

Der Spaltenvektor  $\mathbf{h}_\alpha$  ist folgendermaßen aufgebaut:

$$\begin{aligned} \mathbf{h}_\alpha &= [1 \quad \mathbf{0}_{1 \times (N-1)}]^T - l_P \mathbf{g}_1 - \frac{l_D}{\alpha} \mathbf{g} + \frac{l_D}{\alpha} \mathbf{g}_\alpha \\ &= [1 \quad \mathbf{0}_{1 \times (N-1)}]^T - [\mathbf{g}_1 \quad \frac{1}{\alpha} (\mathbf{g} - \mathbf{g}_\alpha)] \begin{bmatrix} l_P \\ l_D \end{bmatrix} \end{aligned} \quad (2.113)$$

mit den transformierten Vektoren

$$\mathbf{g}_1 \triangleq \mathbf{T}_1 \mathbf{g} = [0 \quad g(0) \quad \cdots \quad g(N-2)]^T \quad \text{und} \quad (2.114)$$

$$\mathbf{g}_\alpha \triangleq \mathbf{T}_\alpha \mathbf{g} = [\mathbf{0}_\alpha \quad g(0) \quad \cdots \quad g(N-\alpha-1)]^T. \quad (2.115)$$

Somit ist eine Optimierungsmethode zur Bestimmung von  $l_P$  und  $l_D$  gesucht, für die  $\|\mathbf{h}_\alpha\|_1 < 1$  gilt.

**Definition 2.4 (Optimierungsproblem PD-ILR-Typ)** In [Chen and Moore, 2002, S.57] ist das Optimierungsproblem definiert durch

$$J_{PD}^* = \min_{l_P, l_D} J_{PD} \triangleq \min_{l_P, l_D} \|\mathbf{h}_\alpha\|_2^2 = \min_{l_P, l_D} \mathbf{h}_\alpha^T \mathbf{h}_\alpha. \quad (2.116)$$

Es gilt, da  $\|\mathbf{h}_\alpha\|_1 < \sqrt{(N)} \|\mathbf{h}_\alpha\|_2$  und  $J_{PD}^*$  sehr klein sind, dass  $\|\mathbf{h}_\alpha\|_1 < 1$ .

Damit ergeben sich als Lösung für die Lernfaktoren folgende Gleichungen

$$l_P = -\frac{g(0)\mathbf{g}_1(\mathbf{g} - \mathbf{g}_\alpha)}{\mathbf{g}_1^T \mathbf{g}_1 (\mathbf{g} - \mathbf{g}_\alpha)^T (\mathbf{g} - \mathbf{g}_\alpha) - ((\mathbf{g}_1^T (\mathbf{g} - \mathbf{g}_\alpha)))^2} \quad \text{und} \quad (2.117)$$

$$l_D = \frac{\alpha g(0) \mathbf{g}_1^T \mathbf{g}_1}{\mathbf{g}_1^T \mathbf{g}_1 (\mathbf{g} - \mathbf{g}_\alpha)^T (\mathbf{g} - \mathbf{g}_\alpha) - ((\mathbf{g}_1^T (\mathbf{g} - \mathbf{g}_\alpha)))^2}. \quad (2.118)$$

Grundsätzlich gilt, das Optimierungsergebnis  $J_{PD}^* < J_P^*$  und die Lernrate des PD-ILR-Typs ist höher als beim P-ILR-Typ. Weiterhin ist die Lernrate des P-ILR-Typs von der Anzahl der Datenpunkte  $N$  abhängig. Dieser konvergiert mit steigendem  $N$  langsamer, da sich  $g(0)$  verringert bzw.  $\sum_{j=1}^{N-1} |g(j)|$  sich vergrößert. Daher ist ein PD-Typ besser geeignet. Tritt starkes Messrauschen auf, ist zur Bestimmung und Glättung des D-Lernbestandteils eine Mittelung über  $\alpha$ -Werte möglich. Dabei ist ein Kompromiss zwischen Lernrate und Rauschunterdrückung zu finden. Typische und praktische Werte für  $\alpha$  liegen bei  $\alpha \in [1 \dots 4]$ .

### Inversionsbasierte ILR

Unter den Begriff der inversionbasierten ILR fallen alle Verfahren, die die Inverse des Systems verwenden. Der Ausgangspunkt der Betrachtung soll die bekannte Eingangs-Ausgangs-Matrix  $\mathbf{G}$  sein. Ziel ist es, mit Hilfe dieses Systemwissens ein monoton konvergentes ILR-Gesetz zu bestimmen. Für diesen Entwurf haben sich normoptimale Ansätze zur Gewährleistung der Stabilität und Konvergenz bewährt [Rogers et al., 2010, Freeman et al., 2005]. Als relevante Norm in der Praxis hat sich die 2-Norm erwiesen [Hengen et al., 2004, S.39-45]. Im Folgenden sind folgende Verfahren vorgestellt:

- I) Darstellung der Grundidee durch Verwendung der Pseudoinversen
- II) Verwendung von Regularisierungsverfahren zur Behandlung von Messrauschen und Modellfehlern
- III) gradientenbasierte Methode zum Erreichen der größtmöglichen Lernrate
- IV) gradientenbasierte Methode mit Berücksichtigung von Modellungenauigkeiten

Im Gegensatz zum PID-ILR-Typ weisen diese ILR-Verfahren keine konstanten zeit- und iterationsinvarianten Lernoperatoren auf. I) und II) sind zeitvariant, d.h. in jedem Abtastschritt kommt ein angepasster Lernoperator vor. III) und IV) besitzen die zusätzliche Eigenschaft, dass sich die Lernoperatoren nach jeder Iteration ändern können.

**Ansatz der Pseudoinversen:** Bei diesem Ansatz ist das Gütefunktional  $J$  wie folgt definiert:

$$J(\mathbf{u}_{k+1}) = \|\mathbf{e}_{k+1}\|_2^2. \quad (2.119)$$

Der Stellgrößenverlauf  $\mathbf{u}_{k+1}$  ist so zu bestimmen, dass die 2-Norm der Regelabweichung der nächsten Iteration minimiert wird. Für das ILR-Stellgesetz gilt  $\mathbf{u}_{k+1} = \mathbf{u}_k + \delta(\mathbf{u}_k)$

mit der Änderung der Stellgröße  $\delta(\mathbf{u}_k)$ . Für das Gütekriterium  $J(\mathbf{u}_{k+1})$  lässt sich der Zusammenhang

$$\begin{aligned} J(\mathbf{u}_{k+1}) &= \|\mathbf{e}_{k+1}\|_2^2 = \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2^2 = \|\mathbf{y}_d - \mathbf{G}\mathbf{u}_{k+1}\|_2^2 \\ &= \|\mathbf{y}_d - \mathbf{G}(\mathbf{u}_k + \delta(\mathbf{u}_k))\|_2^2 = \|\mathbf{e}_k - \mathbf{G}\delta(\mathbf{u}_k)\|_2^2 \end{aligned} \quad (2.120)$$

herleiten. Die Änderung der Stellgröße soll damit so bestimmt werden, dass die aufgetretene Regelabweichung  $\mathbf{e}_k$  des Zyklus  $k$  eliminiert wird. Die Berechnung der 2-Norm ergibt folgende Lösung für das Gütekriterium  $J(\mathbf{u}_{k+1})$ :

$$\begin{aligned} J(\mathbf{u}_{k+1}) &= (\mathbf{e}_k - \mathbf{G}\delta(\mathbf{u}_k))^T (\mathbf{e}_k - \mathbf{G}\delta(\mathbf{u}_k)) = (\mathbf{e}_k^T - (\delta(\mathbf{u}_k))^T \mathbf{G}^T) (\mathbf{e}_k - \mathbf{G}\delta(\mathbf{u}_k)) \\ &= \mathbf{e}_k^T \mathbf{e}_k - 2(\delta(\mathbf{u}_k))^T \mathbf{G}^T \mathbf{e}_k + \delta(\mathbf{u}_k)^T \mathbf{G}^T \mathbf{G} \delta(\mathbf{u}_k). \end{aligned} \quad (2.121)$$

Für das Minimum von  $J(\mathbf{u}_{k+1})$  ergibt sich aus der ersten partiellen Ableitung von (2.121) nach der Änderung der Stellgröße  $\delta(\mathbf{u}_k)$ :

$$\delta(\mathbf{u}_k) = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \mathbf{e}_k \quad (2.122)$$

und entspricht damit einer Invertierung der Regelstrecke durch die Berechnung der Linkspseudoinversen [Hengen, 2002, S.58f.]. Dieses Stellgesetz würde durch die Invertierung des Systems schon nach einer Iteration das Optimierungsziel erreichen. Was aber in der Praxis auf Grund von Modellabweichungen, Mess- und Prozessrauschen nicht möglich ist.

**Ansatz der Pseudoinversen mit Regularisierung:** Der praktische Einsatz des Ansatzes der Pseudoinversen ist mit der Verwendung von Regularisierungsverfahren verbunden. Hierfür existieren verschiedene mathematische Verfahren.

Eine Möglichkeit ist die Durchführung einer Singulärwertzerlegung der Eingangs-Ausgangs-Matrix  $\mathbf{G}$  und Eliminierung der kleineren Singulärwerte. Diese kleinen Singulärwerte sorgen für eine Verstärkung des Rauschsignals. Durch das Abschneiden von Singulärwerten unterhalb eines Regularisierungsparameters  $\gamma$ , was einem Null setzen dieser Singulärwerte entspricht, wird eine Filterwirkung erreicht. [Louis, 1989, S.78-86]

Eine weitere Möglichkeit besteht in der Einführung weiterer Strafterme im Gütefunktional [Hengen, 2002]. Eine der ersten Regularisierungsfunktionen ist die Tikhonov-Regularisierung [Louis, 1989, S.87-102], die mit dem Strafterm den Verlauf der Optimierungsvariablen bewertet. In diesem Fall entspricht das dem Term  $\eta_1 \|\delta(\mathbf{u}_k)\|_2^2$ . Weitere Möglichkeiten der Glättung des Optimierungsergebnisses bieten die Strafterme, die die Änderung und die Kurvigkeit des zu optimierenden Stellgrößenverlaufes betrachten. Das Gütefunktional erweitert sich in diesem Fall zu

$$J(\mathbf{u}_{k+1}) = \|\mathbf{e}_k - \mathbf{G}\delta(\mathbf{u}_k)\|_2^2 + \eta_1 \|\delta(\mathbf{u}_k)\|_2^2 + \eta_2 \|\mathbf{E}\delta(\mathbf{u}_k)\|_2^2 + \eta_3 \|\mathbf{F}\delta(\mathbf{u}_k)\|_2^2 \quad (2.123)$$

mit dem diskreten Ableitungsoperator 1. Ordnung  $\mathbf{E}$  und dem diskreten Ableitungsoperator 2. Ordnung  $\mathbf{F}$

$$\mathbf{E} = \begin{bmatrix} -1 & 1 & 0 & \cdots & 0 \\ 0 & -1 & 1 & \ddots & 0 \\ 0 & \ddots & \ddots & \ddots & 0 \\ 0 & 0 & \cdots & -1 & 1 \end{bmatrix}, \mathbf{F} = \begin{bmatrix} -1 & 2 & -1 & 0 & \cdots & \cdots & 0 \\ 0 & -1 & 2 & -1 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & 0 \\ 0 & \cdots & \cdots & 0 & -1 & 2 & -1 \end{bmatrix}. \quad (2.124)$$

Der Wichtungsfaktor  $\eta_1$  bewertet die absolute Stellgröße,  $\eta_2$  starke Änderungen und  $\eta_3$  die Kurvigkeit der Stellgröße. Damit ergibt sich für das Stellgesetz folgendes Ergebnis:

$$\mathbf{u}_{k+1} = \mathbf{u}_k + (\mathbf{G}^T \mathbf{G} + \eta_1 \mathbf{I} + \eta_2 \mathbf{E}^T \mathbf{E} + \eta_3 \mathbf{F}^T \mathbf{F})^{-1} \mathbf{G}^T \mathbf{e}_k. \quad (2.125)$$

**Gradientenbasierter Ansatz:** Ausgangspunkt einer robusten und gradientenbasierten ILR ist analog dem Gütefunktional der Pseudoinversen in Gleichung (2.119) zur Minimierung der Regelabweichung im nächsten Zyklus. Der Ansatz laut [Rogers et al., 2007] für die Stellgröße ist  $\mathbf{u}_{k+1} = \mathbf{u}_k + \epsilon_{k+1} \boldsymbol{\delta}_{k+1}$  mit dem Skalierungsfaktor  $\epsilon_{k+1}$  und dem Richtungsvektor der Änderung  $\boldsymbol{\delta}_{k+1}$ . Für das Gütefunktional  $J(\mathbf{u}_{k+1})$  ergibt sich damit

$$\begin{aligned} J(\mathbf{u}_{k+1}) &= \|\mathbf{e}_{k+1}\|_2^2 = \|\mathbf{y}_d - \mathbf{G}(\mathbf{u}_k + \epsilon_{k+1} \boldsymbol{\delta}_{k+1})\|_2^2 = \|\mathbf{e}_k - \epsilon_{k+1} \mathbf{G} \boldsymbol{\delta}_{k+1}\|_2^2 \\ &= \|\mathbf{e}_k\|_2^2 - 2\epsilon_{k+1} \boldsymbol{\delta}_{k+1}^T \mathbf{G}^T \mathbf{e}_k + \epsilon_{k+1}^2 \boldsymbol{\delta}_{k+1}^T \mathbf{G}^T \mathbf{G} \boldsymbol{\delta}_{k+1}. \end{aligned} \quad (2.126)$$

Damit die monotone Konvergenz, d.h. die Verringerung der Regelabweichung mit jeder Iteration, gewährleistet ist, muss

$$\|\mathbf{e}_{k+1}\|_2^2 - \|\mathbf{e}_k\|_2^2 = -2\epsilon_{k+1} \boldsymbol{\delta}_{k+1}^T \mathbf{G}^T \mathbf{e}_k + \epsilon_{k+1}^2 \boldsymbol{\delta}_{k+1}^T \mathbf{G}^T \mathbf{G} \boldsymbol{\delta}_{k+1} < 0 \quad (2.127)$$

erfüllt sein. Ein möglicher Ansatz dafür ist laut [Rogers et al., 2007, S.405-407] die Bestimmung des Richtungsvektors durch  $\boldsymbol{\delta}_{k+1} = \mathbf{G}^T \mathbf{e}_k$ . Eingesetzt in (2.126) ergibt sich für das Gütefunktional  $J(\mathbf{u}_{k+1})$

$$J(\mathbf{u}_{k+1}) = \|\mathbf{e}_k\|_2^2 - 2\epsilon_{k+1} \|\mathbf{G}^T \mathbf{e}_k\|_2^2 + \epsilon_{k+1}^2 \|\mathbf{G} \mathbf{G}^T \mathbf{e}_k\|_2^2. \quad (2.128)$$

Aus der Berechnung des Minimums resultiert

$$\epsilon_{k+1} = \frac{\|\mathbf{G}^T \mathbf{e}_k\|_2^2}{\|\mathbf{G} \mathbf{G}^T \mathbf{e}_k\|_2^2}. \quad (2.129)$$

Das Stellgesetz ist damit durch

$$\mathbf{u}_{k+1} = \mathbf{u}_k + \epsilon_{k+1} \mathbf{G}^T \mathbf{e}_k = \mathbf{u}_k + \frac{\|\mathbf{G}^T \mathbf{e}_k\|_2^2}{\|\mathbf{G} \mathbf{G}^T \mathbf{e}_k\|_2^2} \mathbf{G}^T \mathbf{e}_k \quad (2.130)$$

beschrieben. Die Berechnung des Skalierungsfaktors  $\epsilon_{k+1}$  erfolgt in jeder Iteration und ermittelt den steilsten möglichen Gradienten zur Änderung der Stellgröße. Dabei ist die Konvergenz in (2.127) durch

$$\|\mathbf{e}_{k+1}\|_2^2 - \|\mathbf{e}_k\|_2^2 = -\frac{\|\mathbf{G}^T \mathbf{e}_k\|_2^4}{\|\mathbf{G} \mathbf{G}^T \mathbf{e}_k\|_2^2} < 0 \quad (2.131)$$

gegeben.

**Gradientenbasierter Ansatz mit Berücksichtigung von Modellungenauigkeiten:** Der Beitrag [Rogers et al., 2007, S.407-411] beschreibt die Betrachtung des gradientenbasierten ILR-Ansatzes mit multiplikativen Modellungenauigkeiten:

$$\mathbf{G} = \mathbf{G}_0 \mathbf{U}, \quad (2.132)$$

mit dem Nominalmodell  $\mathbf{G}_0$  und den multiplikativen Unsicherheiten  $\mathbf{U}$ . Für das ILR-Gesetz gilt nun

$$\mathbf{u}_{k+1} = \mathbf{u}_k + \epsilon_{k+1} \mathbf{G}_0^T \mathbf{e}_k. \quad (2.133)$$

Damit ergibt sich

$$\|\mathbf{e}_{k+1}\|_2^2 - \|\mathbf{e}_k\|_2^2 = -2\epsilon_{k+1} \mathbf{e}_k^T \mathbf{G}_0 \mathbf{U} \mathbf{G}_0^T \mathbf{e}_k + \epsilon_{k+1}^2 \mathbf{e}_k^T \mathbf{G}_0 \mathbf{U}^T \mathbf{G}_0^T \mathbf{G}_0 \mathbf{U} \mathbf{G}_0^T \mathbf{e}_k, \quad (2.134)$$

d.h. nur ein ausreichend kleines  $\epsilon_{k+1} > 0$  kann für monotone Konvergenz sorgen. Dies ist durch

$$\epsilon_{k+1} = \frac{\|\mathbf{G}_0^T \mathbf{e}_k\|_2^2}{\|\mathbf{G}_0 \mathbf{G}_0^T \mathbf{e}_k\|_2^2} \quad (2.135)$$

nicht gewährleistet. Die Erweiterung des Gütefunctionals

$$J(\mathbf{u}_{k+1}) = \|\mathbf{e}_{k+1}\|_2^2 + w \epsilon_{k+1}^2 \quad (2.136)$$

ergibt ein  $\epsilon_{k+1}$  von

$$\epsilon_{k+1} = \frac{\|\mathbf{G}_0^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_0 \mathbf{G}_0^T \mathbf{e}_k\|_2^2}, \quad (2.137)$$

welches bei einem ausreichend großem  $w$  monotone Konvergenz gewährleisten kann.

**Definition 2.5 (Bestimmung Parameter  $w$ )** In [Rogers et al., 2007, S.409] ist unter der Annahme, dass  $\mathbf{U} + \mathbf{U}^T > 0$ ,  $w$  wie folgt definiert

$$w > \frac{1}{2} \frac{\|\mathbf{G}_0^T\|_2^2 \|\mathbf{G} \mathbf{G}_0^T\|_2^2 \|\mathbf{e}_0\|_2^2}{\underline{\sigma} \left( \mathbf{G}_0 \frac{\mathbf{U} + \mathbf{U}^T}{2} \mathbf{G}_0^T \right)}. \quad (2.138)$$

Die Größe  $\underline{\sigma}(\cdot)$  beschreibt den kleinsten singulären Wert der Matrix.

**Vergleich der inversionsbasierten ILR:** Abb. 2.15 zeigt ein Simulationsbeispiel der aufgeführten inversionsbasierten ILR an einem System erster Ordnung. In den Diagrammen a) bis d) ist der zeitliche Verlauf des Sollwertes  $y_d$  (schwarz) und die zeitlichen Verläufe der Regelgröße  $y_k$  der einzelnen Iterationen (grau) dargestellt. Dabei zeigt das Diagramm a) den Verlauf der Iterationen durch die Pseudoinverse, das Diagramm b) den Verlauf der Pseudoinversen mit Regularisierung ( $\gamma_1 = 1$ ,  $\gamma_2 = 2$ ,  $\gamma_3 = 0$ ), das Diagramm c) den Verlauf der gradientenbasierten ILR und Diagramm d) den Verlauf der gradientenbasierten ILR mit dem Sicherheitsfaktor  $w = 25$ . Das Diagramm a) entspricht

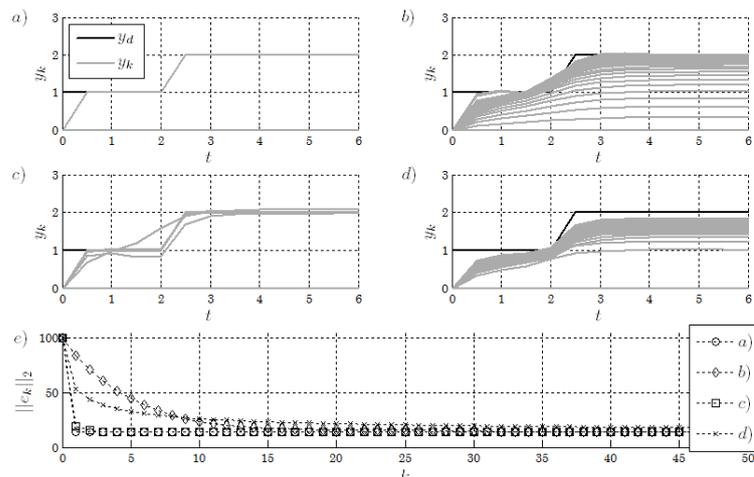


Abbildung 2.15. Vergleich der inversionsbasierten ILR

dem schnellstmöglichen Lernen in einer Iteration. Durch die Inverse des Prozesses und dem exakten Modell ist der Lernvorgang nach einem Schritt abgeschlossen. Dies ist auf Grund von Modellabweichungen und Messrauschen in der Praxis nicht erreichbar. Durch die Regulierungsfaktoren  $\gamma_1$  und  $\gamma_2$  in Diagramm b) verringert sich die Lernrate und das Optimierungsziel wird erst nach 15 Iterationen erreicht. Eine hohe Lernrate weist ebenfalls die gradientenbasierte ILR auf, die durch die Bestimmung von  $\epsilon_{k+1}$  in jeder Iteration den maximal möglichen Gradienten der Stellgrößenänderung gewährleistet. Machen vorhandene Modellgenauigkeiten und auftretendes Messrauschen die Einführung des Begrenzungsparameters  $w$  notwendig, sinkt die Lernrate und weitere Iterationen sind durchzuführen.

### MFAC basierte ILR

Neben der ursprünglichen Verwendung von MFAC-Reglern aus Abschnitt 2.2.4 lässt sich dieser Ansatz auch auf die ILR erweitern. Dies führt zu dem sogenannten Model Free Adaptive Iterative Learning Control (MFAILC) [Hou and Jin, 2014, S.193-205]. In den folgenden Abschnitten sind die einzelnen Konzepte dargestellt. Dabei wird das folgende SISO-System eines Wiederholungsprozesses betrachtet:

$$y(i+1, k) = f(y(i, k), \dots, y(i-n_y, k), u(i, k), \dots, u(i-n_u, k)) \quad (2.139)$$

mit dem Eingangssignal  $u(i, k)$ , dem Ausgangssignal  $y(i, k)$ , der diskreten Zeitvariablen  $i$  und der Iterationsvariablen  $k$ . Die Variablen  $n_y \in \mathbb{N}$  und  $n_u \in \mathbb{N}$  sind unbekannt und entsprechen der Ordnung der Ausgangsgröße bzw. der Eingangsgröße. Dabei sei  $f(\cdot)$  eine unbekannt nichtlineare Funktion, deren partielle Ableitung kontinuierlich ist.

**Definition 2.6** Für dieses System soll  $\forall i \in \{0, 1, \dots, N\}$  und  $\forall k \in \{1, 2, \dots, \infty\}$  entlang

der Iterationsachse die globale Lipschitzbedingung gelten [Hou and Jin, 2014]:

$$|\Delta y(i+1, k)| \leq K_L |\Delta u(i, k)|$$

mit  $\Delta y(i+1, k) = y(i+1, k) - y(i+1, k-1)$  und  $\Delta u(i, k) = u(i, k) - u(i, k-1)$  und  $K_L > 0$ .

**ILR in der MFAC-Form CFDL:** Ausgehend vom System (2.139) lautet der allgemeine CFDL-Modellansatz wie folgt:

$$\Delta y(i+1, k) = \phi_C(i, k) \Delta u(i, k), \forall i \in \{0, 1, \dots, N\} \quad (2.140)$$

mit dem iterationsabhängigen zeitvariablen PPD-Parameter  $\phi_C(i, k)$ . Er unterscheidet sich zum klassischen MFAC-Ansatz in der Bestimmung des geschätzten PPD-Parameters  $\hat{\phi}_C(i, k)$ . Dieser Parameter berechnet sich nicht aus dem zeitlich vorhergehenden  $\hat{\phi}_C(i-1, k)$ , sondern aus dem iterativ vorhergehenden  $\hat{\phi}_C(i, k-1)$ . Es ergibt sich aus dem Gütefunktional

$$J(\hat{\phi}_C(i, k)) = \left( \Delta y(i+1, k-1) - \hat{\phi}_C(i, k) \Delta u(i, k-1) \right)^2 + \mu \left( \hat{\phi}_C(i, k) - \hat{\phi}_C(i, k-1) \right)^2 \quad (2.141)$$

der rekursive Berechnungsalgorithmus für  $\hat{\phi}_C(i, k)$

$$\hat{\phi}_C(i, k) = \hat{\phi}_C(i, k-1) + \frac{\eta \Delta u(i, k-1)}{\mu + (\Delta u(i, k-1))^2} (\Delta y(i+1, k-1) - \Delta \hat{y}(i+1, k-1)) \quad (2.142)$$

mit  $\Delta \hat{y}(i+1, k-1) = \hat{\phi}_C(i, k-1) \Delta u(i, k-1)$ . Der Faktor  $\eta \in (0, 1]$  wird zusätzlich als Schrittweite und weiterer Tuningfaktor von [Hou and Jin, 2014] eingeführt.

Aufbauend auf diese rekursive Schätzung lässt sich der ILR-Algorithmus herleiten. Dazu ist das Minimum des folgenden allgemeinen Gütefunktionals:

$$J(u(i, k)) = (e(i+1, k))^2 + \lambda (u(i, k) - u(i, k-1))^2 \quad (2.143)$$

zu berechnen, welches das ILR-Stellgesetz:

$$u(i, k) = u(i, k-1) + \frac{\rho \hat{\phi}_C(i, k)}{\lambda + (\hat{\phi}_C(i, k))^2} e(i+1, k-1) \quad (2.144)$$

mit der generellen Schrittweite  $\rho \in (0, 1]$  ergibt. In jeder Iteration sind die beiden rekursiven Berechnungen von  $\hat{\phi}_C(i, k)$  und  $u(i, k)$  durchzuführen. Die MFAC-ILR-Form CFDL stellt den einfachsten MFAC-Ansatz dar und lässt sich als zeit- und iterationsvariablen P-ILR interpretieren, da sich  $\hat{\phi}_C(i, k)$  mit jeder Anregung durch Arbeitspunktänderungen, Parameteränderungen u.a. ändern kann. Treten keine Anregungen auf, bleibt der PPD konstant  $\hat{\phi}_C(i, k) = \hat{\phi}_C(i, 0)$ . In diesem Fall entspricht der MFAC-CFDL-ILR dem P-ILR-Typ und die Lernrate ist vom Startparameter  $\hat{\phi}_C(i, 0)$  abhängig. Zusätzlich ist die Lernrate und die Rauschempfindlichkeit mit den vier Parametern  $\eta$ ,  $\mu$ ,  $\rho$  und  $\lambda$  beeinflussbar. Weitere Formen der MFAC-basierten ILR sind unter A im Anhang aufgeführt.

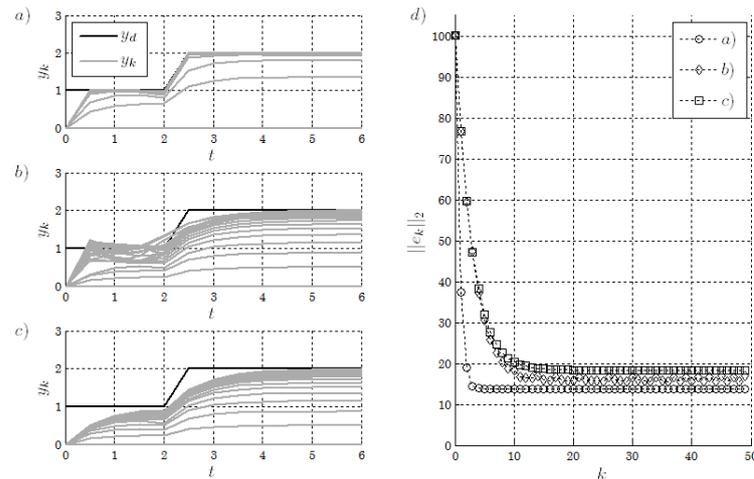
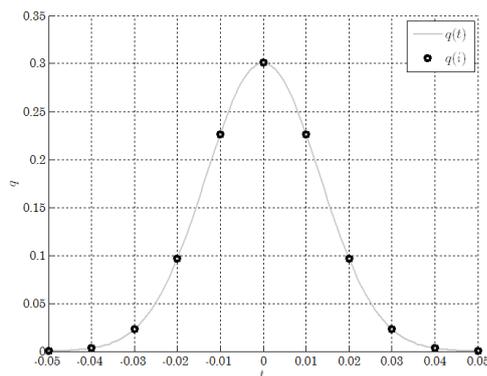


Abbildung 2.16. Vergleich der MFAC-basierten ILR

**Vergleich der MFAC-basierten ILR:** Abb. 2.16 zeigt ein Simulationsbeispiel der aufgeführten MFAC-basierten ILR-Typen an einem System erster Ordnung. In den Diagrammen a) bis c) ist der zeitliche Verlauf des Sollwertes  $y_d$  (schwarz) und die zeitlichen Verläufe der Regelgröße  $y_k$  der einzelnen Iterationen (grau) dargestellt. Dabei stellt das Diagramm a) das Ergebnis eines MFAC-CFDL-ILR-Typs, das Diagramm b) das Ergebnis eines MFAC-PFDL-ILR-Typs und das Diagramm c) das Ergebnis eines MFAC-FFDL-ILR-Typs dar. In diesen Simulationen sind die Parameter  $\lambda = \mu = 0,1$  und  $\eta = \rho = 1$  festgelegt. Die Anzahl der berücksichtigten Abtastschritte ist mit  $L_u = L_y = 10$  eingestellt. Der Startwert des PPD liegt bei dem CFDL-Typ bei 0,15 und bei den anderen beiden Typen bei 0,05. Das ist der Grund, warum die Lernrate des CFDL-Typs höher ist. Beim Einsatz des PFDL-Typs und des FFDL-Typs tritt eine Filterwirkung auf, die bei Mess- und Prozessrauschen Vorteile liefert. Allerdings nimmt auch der Rechen- und Speicheraufwand durch die Vergrößerung des PPD-Vektors zu.

### Q-Filter Entwurf

Auftretende nicht wiederholte Störungen und zusätzliches Messrauschen kann ein fehlerhaftes Lernen bewirken. Um diesen Effekt abzumildern, ist der Einsatz des Q-Filters möglich. Neben der intuitiv angewendeten klassischen Filterung bietet die ILR zusätzliche Filtermöglichkeiten. So ist es sinnvoll, eine akasale Filterung vorzunehmen, um eine Phasenverschiebung zu vermeiden. Eine Möglichkeit ist die Verwendung eines gleitenden Mittelwertes wie z.B. den Gauß-Filter [Plassmann and Schulz, 2013, S.390f.] und den Savitzky-Golay-Filter [Schafer, 2011]. Weiterhin ist es möglich, den Entwurf des Q-Filters mit dem Entwurf des Lernoperators  $L$  zu koppeln. So beschreibt der Beitrag [Hengen, 2002] den Entwurf der Operatoren durch ein allgemeines Gütefunktional, während der Beitrag [Bristow et al., 2007] den Entwurf eines zeitvariablen Q-Filters dokumentiert.



**Abbildung 2.17.** Darstellung der kontinuierlichen Impulsantwort und der diskreten Impulsantwortfolge eines Gauß-Filters

**Akausaler Filterentwurf:** Das Beispiel eines Gauß-Filters dient im folgenden der Beschreibung eines akausalen Q-Filterentwurfs. Ein solcher Filter stellt einen Tiefpass dar, dessen Verstärkung an der Knickfrequenz  $f_e$  um 3dB abfällt. Er heißt Gauß-Filter, weil der zeitliche Verlauf der Impulsantwort wie eine gaußsche Glockenkurve aussieht. Abb. 2.17 zeigt die kontinuierliche Impulsantwort und die diskrete Impulsantwortfolge eines solchen Filters mit einer Knickfrequenz von  $f_e = 10\text{Hz}$  und einer Abtastzeit von  $T_s = 10\text{ms}$ .

Ausgehend von der Gaußschen Verteilungsfunktion

$$q_G(t) = \frac{1}{\sigma_Q \sqrt{2\pi}} e^{-\frac{t^2}{2\sigma_Q^2}} \quad (2.145)$$

lässt sich für  $t = iT_s$  der diskrete Ausdruck

$$q_G(i) = \frac{1}{\sigma_Q \sqrt{2\pi}} e^{-\frac{(iT_s)^2}{2\sigma_Q^2}} \quad (2.146)$$

formulieren. Dabei stellt  $\sigma_Q$  die Standardabweichung dar, die einen 3dB-Abfall an der Knickfrequenz bedeutet:

$$\sigma_Q = \frac{\sqrt{\ln(2)}}{2\pi f_e}. \quad (2.147)$$

Damit lässt sich die Impulsantwortfolge für einen Filter mit einem Filterfenster der Länge  $2N_F + 1$  berechnen. Die Impulsfolge liegt zwischen den Abtastwerten  $-N_F \leq i \leq N_F$ . Der Bereich  $N_F \leq i$  repräsentiert den akausalen Anteil des Filters. Um eine Verstärkung von eins für den ungefilterten Bereich zu realisieren, ist weiterhin eine Normierung notwendig. Dies gelingt durch die Division der Impulsantwortfolge durch die Summe aller Werte von  $q_G(i)$  im Bereich  $-N_F \leq i \leq N_F$ . Der Filter berechnet sich durch

$$q(i) = \frac{q_G(i)}{\sum_{l=-N_F}^{N_F} q_G(l)}. \quad (2.148)$$

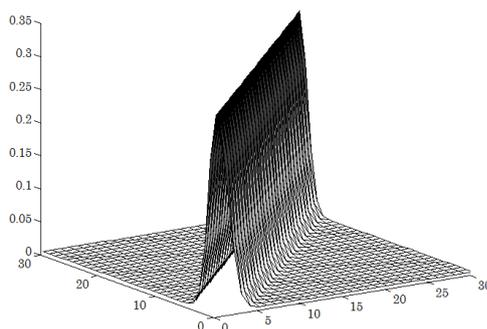


Abbildung 2.18. Darstellung eines Q-Filters basierend auf dem Gauß-Filterentwurf

Das gefilterte Signal ergibt sich durch die Faltung von  $q(i)$  mit dem Messsignal  $u(i)$ . Das stellt sich in der Vektor und Matrixschreibweise einer ILR folgendermaßen dar.

$$\begin{aligned} \mathbf{u}_{k,F} &= \mathbf{Q}\mathbf{u}_k \\ &= \begin{bmatrix} q(0) & q(1) & \cdots & \cdots & q(N_F) & 0 & \cdots & \cdots & 0 \\ q(-1) & q(0) & q(1) & \cdots & \cdots & q(N_F) & 0 & \cdots & 0 \\ \vdots & \ddots & 0 \\ q(-N_F) & \cdots & q(-1) & q(0) & q(1) & \cdots & q(N_F) & \cdots & 0 \\ \vdots & \ddots & 0 \\ 0 & \cdots & \cdots & \cdots & 0 & q(-N_F) & \cdots & q(-1) & q(0) \end{bmatrix} \mathbf{u}_k \end{aligned} \quad (2.149)$$

$$\mathbf{Q} \in \mathbb{R}^{N \times N} \quad (2.150)$$

Abb. 2.18 zeigt den Q-Filter für  $N$  Abtastwerte einer Iteration  $k$  basierend auf dem Gauß-Filter in Abb. 2.17. Wie in [Plassmann and Schulz, 2013, S.390f.] beschrieben, ist zu erkennen, dass die ersten  $N_F$  und die letzten  $N_F$  Zeilen der Matrix  $\mathbf{Q}$  nicht den Wert 1 ergeben, da hier der Normierungswert zu groß ist. Daher sind die Randbereiche separat zu normieren. Allerdings verändert sich für diese Bereiche die Dämpfung an der Knickfrequenz.

**Normoptimaler Filterentwurf:** Basierend auf den normoptimalen ILR-Entwürfen in Abschnitt 2.3.3 kann der Entwurf des Q-Filters zusammen mit dem Entwurf des Lernoperators  $L$  erfolgen. Der Ausgangspunkt ist das allgemeine Gütefunktional

$$J(\mathbf{u}_{k+1}) = \|\mathbf{e}_{k+1}\|_2^2 + \eta_1 \|\mathbf{u}_{k+1}\|_2^2 + \eta_2 \|\mathbf{u}_{k+1} - \mathbf{u}_k\|_2^2 \quad (2.151)$$

mit der Regelabweichung der nächsten Iteration  $k + 1$

$$\mathbf{e}_{k+1} = \mathbf{y}_d - \mathbf{y}_{k+1} + (\mathbf{y}_k - \mathbf{y}_k) = \mathbf{e}_k - \mathbf{G}_k \mathbf{u}_{k+1} + \mathbf{G}_k \mathbf{u}_k \quad (2.152)$$

und den Wichtungsfaktoren  $\eta_1$  und  $\eta_2$ . Der Unterschied zum Entwurf mit der Pseudoinversen in Abschnitt 2.3.3 ist hier, dass das ILR-Stellgesetz nicht explizit im Entwurf

enthalten ist. Es ergibt sich nun direkt aus der Lösung der Minimierungsaufgabe. Für  $J(\mathbf{u}_{k+1})$  ergibt sich damit folgende Gleichung

$$J(\mathbf{u}_{k+1}) = (\mathbf{e}_k - \mathbf{G}_k \mathbf{u}_{k+1} + \mathbf{G}_k \mathbf{u}_k)^T (\mathbf{e}_k - \mathbf{G}_k \mathbf{u}_{k+1} + \mathbf{G}_k \mathbf{u}_k) + \eta_1 \mathbf{u}_{k+1}^T \mathbf{u}_{k+1} + \eta_2 (\mathbf{u}_{k+1} - \mathbf{u}_k)^T (\mathbf{u}_{k+1} - \mathbf{u}_k). \quad (2.153)$$

Aus der partiellen Ableitung  $\frac{\partial J(\mathbf{u}_{k+1})}{\partial \mathbf{u}_{k+1}} = 0$  berechnet sich das ILR-Stellgesetz durch

$$\mathbf{u}_{k+1} = (\mathbf{G}^T \mathbf{G} + \eta_1 \mathbf{I} + \eta_2 \mathbf{I})^{-1} (\mathbf{G}^T \mathbf{G} + \eta_2 \mathbf{I}) \mathbf{u}_k + (\mathbf{G}^T \mathbf{G} + \eta_1 \mathbf{I} + \eta_2 \mathbf{I})^{-1} \mathbf{G}_k^T \mathbf{e}_k \quad (2.154)$$

$$= \mathbf{Q} \mathbf{u}_k + \mathbf{L} \mathbf{e}_k. \quad (2.155)$$

Somit ergeben sich die Zusammenhänge  $\mathbf{Q} = (\mathbf{G}^T \mathbf{G} + \eta_1 \mathbf{I} + \eta_2 \mathbf{I})^{-1} (\mathbf{G}^T \mathbf{G} + \eta_2 \mathbf{I})$  und  $\mathbf{L} = (\mathbf{G}^T \mathbf{G} + \eta_1 \mathbf{I} + \eta_2 \mathbf{I})^{-1} \mathbf{G}_k^T$ . Je kleiner die beiden Wichtungsfaktoren wählbar sind, desto stärker konvergiert die bleibende Regelabweichung  $\mathbf{e}_\infty$  gegen null. Für den Fall  $\eta_1 = 0$  stellt der Q-Filter eine Einheitsmatrix dar und die Gleichung beschreibt das ILR-Gesetz 2.125 aus Abschnitt 2.3.3. Die Aufgabe des Wichtungsfaktors  $\eta_2$  ist die Rauschunterdrückung. Eine Erhöhung von  $\eta_2$  verbessert diese, reduziert aber gleichzeitig die Lernrate. Im Fall  $\eta_1 = \eta_2 = 0$  ergibt sich das Dead-Beat-Verhalten der Pseudoinversen aus Gleichung 2.122.

Abb. B.3 zeigt ein Simulationsbeispiel zum Einsatz eines Q-Filters an einem System erster Ordnung. Die Regelgröße ist mit einem weißen Messrauschen überlagert. Die Diagramme  $a_1)$ ,  $b_1)$  und  $c_1)$  stellen den zeitlichen Verlauf des Sollwertes  $\mathbf{y}_d$  (schwarz) und die zeitlichen Verläufe der Regelgröße  $\mathbf{y}_k$  der einzelnen Iterationen (grau) dar. Die dazugehörigen Diagramme  $a_2)$ ,  $b_2)$  und  $c_2)$  präsentieren den Verlauf der berechneten Stellgrößen  $\mathbf{u}_k$ . Die Diagramme  $a_1)$  und  $a_2)$  zeigen eine ILR mit Pseudoinverse und einem Q-Filter  $\mathbf{Q} = \mathbf{I}$ . In den Diagrammen  $b_1)$  und  $b_2)$  ist das Ergebnis eines akasalen Gauß-Filters mit dem gleichen Lernoperator  $\mathbf{L}$  ( $T_s = 0,5s$ ,  $N_F = 4$ ,  $f_e = 0,1Hz$ ) und in den Diagrammen  $c_1)$  und  $c_2)$  das Ergebnis eines normoptimalen Q-Filters ( $\eta_1 = 0,1$ ,  $\eta_2 = 1,5$ ) dargestellt. Die Verläufe der jeweiligen 2-Norm, normiert auf den Ausgangsfehler, zeigt Diagramm d). Durch das Messrauschen verschlechtert sich das erreichte Lernergebnis bei Verwendung der Pseudoinversen verglichen mit Abb. 2.15. Insbesondere der Verlauf der Stellgröße zeigt den erwarteten hohen Rauschanteil. Der eingesetzte akasale Gaußsche Filter bewirkt die stärkste Glättung der drei dargestellten Fälle. Dadurch kann die Regelgröße dem Sollwert nur langsam folgen. Der normoptimale Q-Filter hat eine langsamere Lernrate, erreicht aber einen Stellgrößenverlauf, der weniger verrauscht als  $a_1)$  ist, und die Regelgröße kann dem Sollwert besser folgen als die Filter-Variante  $b)$ .

# Kapitel 3.

## Die Aufladung von Ottomotoren

Dieses Kapitel beschreibt den Stand der Technik im Bereich Aufladung und liefert die physikalische Beschreibung des Systems. Neben der Ermittlung der grundlegenden Prozesseigenschaften, die für die Anwendung eines Selbsteinstellungsverfahrens wichtig sind, beschreibt es die zu parametrierende Regelungsstruktur eines einfach aufgeladenen Ottomotors mit Abgasturbolader. Die Kenntnis von Struktur und Art der anzupassenden Parameter ist essentiell für ein Selbsteinstellungsverfahren.

Die Erstellung eines Modells ist für den Einsatz der zu entwickelnden Verfahren nicht notwendig. Es widerspricht sogar den Anforderungen an ein modellierungsfreies Selbsteinstellungsverfahren. Es dient hier nur zur Vorbereitung der simulativen Tests in Kap. 6 und damit dem praktischen Nachweis der Funktionalität der Verfahren. Neben dem mathematischen Nachweis von Konvergenz und Stabilität stellen diese Simulationen ein weiteres Freigabekriterium für die durchzuführenden Praxistests im Fahrzeug dar.

### 3.1. Der einfach aufgeladene Ottomotor mit Abgasturbolader

Die Aufladung von Motoren bewirkt eine Erhöhung des effektiven Mitteldruckes. War dies zu Beginn der Entwicklung vor allem zur Leistungssteigerung gedacht, hat es heute vor allem Bedeutung hinsichtlich der Verbrauchs- und der Emissionsreduzierung.

Eine Verringerung des Motorhubvolumens ist aus Kundensicht schwer zu akzeptieren, wenn sich dabei die Leistung verringert und die Fahrdynamik verschlechtert. Dies ist durch eine Erhöhung des effektiven Mitteldruckes zu kompensieren. Der effektive Mitteldruck ist durch

$$p_{me} = \rho_{Luft} \cdot \frac{H_u}{L_{min}} \cdot \frac{1}{\lambda_L} \cdot \eta_{Motor} \cdot \lambda_{l,L} \quad (3.1)$$

definiert [Golloch, 2005, S. 76]. Eine Erhöhung des Motorwirkungsgrades  $\eta_{Motor}$ , welcher sich aus inneren und mechanischen Wirkungsgraden zusammensetzt, oder des Liefergrades  $\lambda_{l,L}$  ist nur eingeschränkt möglich. Der untere Heizwert  $H_u$  und der Mindestluftbedarf  $L_{min}$  sind Materialkonstanten des Treibstoffes. Weiterhin ist die untere Grenze des Luftverhältnisses  $\lambda_L$  auf Grund der Abgasnachbehandlung vorgegeben. Somit stellt eine Anhebung der Dichte der zur Verbrennung zur Verfügung stehenden Luft  $\rho_{Luft}$  die wichtigste Maßnahme zur Erhöhung des effektiven Mitteldruckes dar. In der Motorentechnik lautet die Bezeichnung für dieses Verfahren Aufladung.

Im Laufe der Entwicklung sind viele Verfahren der Aufladung entstanden. Die Literatur [Merker et al., 2006, Mollenhauer and Tschöke, 2007, Golloch, 2005] unterscheidet

dabei grundsätzlich in Fremdaufladung und Selbstaufladung. Während bei der Fremdaufladung der Verdichter einen externen Antrieb besitzt, ist der Antrieb der Selbstaufladung innerhalb des eigenen Motorstranges integriert.

Abgasturbolader (ATL) sind die am häufigsten eingesetzten Ladertypen. Sie waren schon frühzeitig im Einsatz [Golloch, 2005, S. 169 f.] und stellen im Gegensatz zur mechanischen Aufladung die thermodynamische Kopplung von Motor und Turbolader dar. Ein Abgasturbolader besitzt eine Turbine im Abgasstrang auf der heißen Seite des Motors. Diese Turbine stellt den Antrieb des Turboladers dar und nutzt die vorhandene Energie des Abgasstromes. Die Turbine ist mittels einer starren Welle (Turboladerwelle) mit dem Verdichter im Luftpfad verbunden und treibt so den Turbolader an. Als Stellglied dienen Turbinen mit variabler Geometrie oder ein sogenanntes Wastegate, das einen Bypass für den Abgasmassenstrom parallel zur Turbine darstellt. Im Bereich der Ottomotoren sind hauptsächlich Wastegates im Einsatz. Die ersten Wastegates waren pneumatische unregelte Wastegates (mit Druckdose). Diese haben die Aufgabe den Ladedruck zu begrenzen [Mollenhauer and Tschöke, 2007, S. 54 f.]. In der Druckdose arbeitet eine Membran mittels Ladedruck gegen eine mechanische Feder und öffnet das Wastegate, wenn die Ladedruckgrenze erreicht ist. Stand der Technik ist heute ein geregelter Ladedruck. Dies kann mit einem pneumatischen Wastegate, in dem die Membran in der Druckdose mit einem gepulstem Ladedruck beaufschlagt ist, oder mit elektrischem Wastegate, in dem die Druckdose durch einen elektrischen Stellmotor ersetzt ist, geschehen. Dadurch kann eine qualitative und quantitative Regelung des Ladedruckes erfolgen.

Bei dem Anwendungsprozess dieser Arbeit handelt es um einen einfach aufgeladenen Ottomotor mit Abgasturbolader, dessen Stellglied ein pneumatisches Wastegate ist. Ein vereinfachter schematischer Aufbau ist in Abb. 3.1 dargestellt. Die wesentlichen

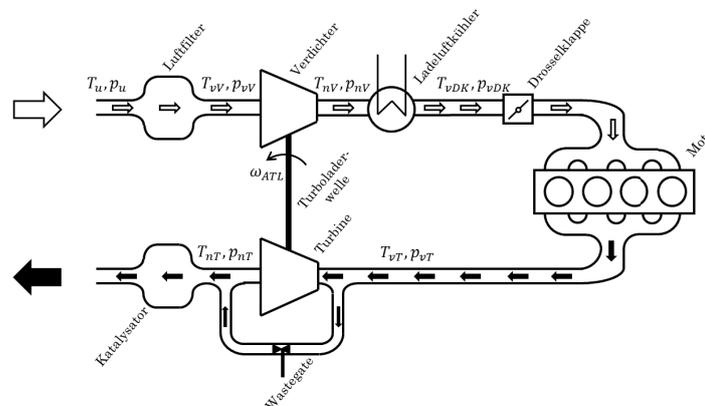


Abbildung 3.1. Aufbau eines einfach aufgeladenen Ottomotors mit Abgasturbolader

Komponenten ausgehend vom Luftfilter sind der Verdichter, die Ladeluftkühlung, die Drosselklappe, der Motor, die Turbine, die Turboladerwelle und der Katalysator. Diese Komponenten finden sich in den gängigen Modellansätzen des Prozesses wieder. Der **Luftfilter** hat die Aufgabe, die angesaugte Luft zu reinigen und so den Motor und seine Komponenten vor Verunreinigungen zu schützen. Im Automobilbereich gehören Trockenfilter zu den gängigsten Filtertypen. Nachteilig ist, dass der Einsatz eines Luft-

filters für einen Druckabfall des Umgebungsluftdruckes  $p_U$  zum Druck vor dem Verdichter  $p_{vV}$  führt. Zum eigentlichen Abgasturbolader gehört der **Verdichter**, die **Turbine** und die **Turboladerwelle**. Wichtige physikalische Größen sind hier der Druck und die Temperatur vor dem Verdichter ( $p_{vV}$ ,  $T_{vV}$ ), nach dem Verdichter ( $p_{nV}$ ,  $T_{nV}$ ), vor der Turbine ( $p_{vT}$ ,  $T_{vT}$ ), nach der Turbine ( $p_{nT}$ ,  $T_{nT}$ ) sowie die Turboladerdrehzahl ( $n_{ATL}$ ) bzw. die Turboladerkreisfrequenz ( $\omega_{ATL}$ ). Neben der Erhöhung des Druckes durch den Verdichter findet durch die Komprimierung der Luft und der isentropen Zustandsänderung auch eine Temperaturanhebung statt. Dies hat zwei wesentliche Nachteile. Zum einen wirkt sie der Anhebung der Luftdichte entgegen und zum anderen nimmt durch die höhere Temperatur der Luft die Klopfgefahr des Ottomotors zu [Merker et al., 2006, S. 243 f.] und [Golloch, 2005, S. 178 f.]. Dies macht die Verwendung einer **Ladeluftkühlung** notwendig. Dabei handelt es sich um einen Wärmeübertrager, der zwischen Verdichter und Drosselklappe eingebaut ist. Das Absenken der Temperatur bewirkt eine Anhebung der Luftdichte, verringert das Klopfisiko und bewirkt auch eine Optimierung der Schadstoffemissionen durch die Absenkung der allgemeinen Prozesstemperatur. Relevante physikalische Größen sind die Temperatur  $T_{vDK}$  und der Druck  $p_{vDK}$  vor der Drosselklappe. Bei  $p_{vDK}$  handelt es sich um die Regelgröße der Ladedruckregelung. Die **Drosselklappe** dient im Saugbetrieb zur Regelung der geforderten Luftmasse. Bei Forderungen über den Normalluftdruck ist die Drosselklappe komplett geöffnet und die Ladedruckregelung aktiv. Im **Motor** findet die fremdgezündete Verbrennung statt. Aus zugeführter Frischluft und eingespritzter Treibstoffmasse entsteht der Abgasmassenstrom mit dem Druck  $p_{vT}$  und der Temperatur  $T_{vT}$  vor der Turbine. Das **Wastegate** ist das Stellglied des Ladedruckregelkreises. Bei dem in dieser Arbeit betrachteten Anwendungsprozess handelt es sich um die pneumatische Ausführung. Die Stellgröße  $TV_{WG}$  steuert ein Ventil an, das den Druck in der Druckdose des Wastegates ablassen und so Drücke zwischen Umgebungsdruck ( $TV_{WG} = 100\%$ ) und Ladedruck ( $TV_{WG} = 0\%$ ) einstellen kann. Daraus ergibt sich eine Kraft, die gegen eine mechanische Feder in der Druckdose wirkt und damit den Öffnungsgrad des Wastegates und den resultierenden Wastegatemassenstrom einstellt. Im **Katalysator** erfolgt die Abgasnachbehandlung. Er reduziert die Schadstoffemissionen des Fahrzeugs. Der Katalysator stellt wie der Luftfilter einen Strömungswiderstand des Motors dar.

### 3.2. Systembeschreibung

Die Systembeschreibung eines aufgeladenen Ottomotors soll dazu dienen, ein grundlegendes Verständnis für den Prozess zu liefern und es ermöglichen, dessen Eigenschaften zu definieren. Das verwendete Simulationsmodell baut auf diese Modellannahmen auf. Für das zu entwickelnde Verfahren zur Selbsteinstellung ist eine Modellierung nicht erforderlich. Vertiefende Beschreibungen des Prozesses sind in [Isermann, 2010, Schwarzmann, 2007] zu finden.

Eine mögliche Variante der Modellierung des Luft- und Abgaspfades eines Motors stellt das Mittelwertmodell dar. Dabei erfolgt die Betrachtung der Prozessgrößen durch gemittelte Größen. Eine Unterscheidung der einzelnen Arbeitstakte des Motors ist nicht vorgesehen [Isermann, 2010, S. 103]. Die Modellierung setzt eine Zerlegung des Prozesses in Einzelkomponenten, wie in Abb. 3.1 dargestellt, voraus. Vor dem Luftfilter und nach

dem Katalysator sind die Umgebungsgrößen  $T_u$  und  $p_u$  zu definieren.

Der allgemeine Modellansatz nach [Merker et al., 2006, S. 144] für thermodynamische Prozesse ist auf die Füll- und Entleermethode zurückzuführen. Dabei wird für jede Teilkomponente ein Volumen (Behälter) und eine Drosselstelle (Verbindungsstelle) definiert [Isermann, 2010, S. 105 ff.]. Physikalisch stellen dabei die Komponenten die Drosselstelle und die verbindenden Rohrvolumina den Behälter dar (z.B. Verdichter und Saugrohr).

### Das Behältermodell

Die Modellierung des Behälters beruht auf einer statischen Bilanzierung einfließender und ausfließender Massenströme des betrachteten Gases (Luft bzw. Abgas). Ausgehend von der allgemeinen Gasgleichung

$$p \cdot V = m \cdot R \cdot T \quad (3.2)$$

mit dem Druck  $p$ , dem konstanten Volumen  $V$ , der Masse  $m$  und der Temperatur  $T$  des Gases, sowie der allgemeinen Gaskonstante  $R$  lässt sich durch die zeitliche Ableitung für den Druck die Differentialgleichung

$$\frac{d}{dt}p = \frac{R \cdot T}{V} \cdot \dot{m} \quad (3.3)$$

formulieren. Dabei stellt  $\dot{m} = \sum \dot{m}_E - \dot{m}_A$  die Summe aller einfließenden und ausfließenden Massenströme des Behälters dar.

### Die Drosselmodelle

Drosselstellen erzeugen auf Grund des Strömungswiderstandes einen Druckabfall zwischen dem Druck des vorherigen und des nachfolgenden Behälters. Es kommt zu einem Massenstrom zwischen den Behältern. Laut [Isermann, 2010, S. 107 f.] erfolgt die Berechnung der entstehenden Massenströme an den Drosselstellen durch Durchflussgleichungen. Für die Modellierung des Luft- und Abgaspfades sind zwei Strömungsvarianten relevant.

Für reibungsbehaftete inkompressible Strömungen ist laut [Isermann, 2010, S. 108] die Gleichung

$$\dot{m} = \mu_D \cdot A_{bez} \cdot \sqrt{\frac{2 \cdot p_{zu}}{R \cdot T_{zu}}} \cdot \sqrt{p_{zu} - p_{ab}} \quad (3.4)$$

definiert und gilt für Drosselstellen, die einen konstanten Öffnungsquerschnitt und einen niedrigen Druckabfall aufweisen. Dazu gehören Teilkomponenten wie der Luftfilter, der Ladeluftkühler und der Katalysator. Bei den verwendeten Formelzeichen handelt es sich um den Druck aus dem zufließenden Behälter  $p_{zu}$  und aus dem abfließenden Behälter  $p_{ab}$ , dem Durchflussbeiwert  $\mu_D$ , dem geometrischen Bezugsquerschnitt  $A_{bez}$  und den Isentropenexponenten  $\kappa = \frac{c_p}{c_v}$  von Luft bzw. Abgas.

Die Modellierung von Drosselstellen mit variablen Querschnitten, wie der Drosselklappe oder dem Wastegate, erfolgt mit der Gleichung für reibungsbehaftete kompressible

Strömungen

$$\dot{m} = \mu_D \cdot A_{bez} \cdot \frac{p_{zu}}{\sqrt{R \cdot T_{zu}}} \cdot \sqrt{\frac{2\kappa}{\kappa-1} \left( \Pi^{\frac{2}{\kappa}} - \Pi^{\frac{\kappa+1}{\kappa}} \right)}, \quad (3.5)$$

da hier große Strömungsgeschwindigkeiten und Druckabfälle entstehen können. Die Größe  $\Pi$  bestimmt sich durch

$$\Pi = \min \left( \max \left( \frac{p_{ab}}{p_{zu}}, \left( \frac{2}{\kappa+1} \right)^{\frac{\kappa}{\kappa-1}} \right), 1 \right). \quad (3.6)$$

Bei gleichem Druck vor und nach der Drosselstelle tritt kein Druckabfall auf und der resultierende Massenstrom ist gleich null. Der geometrische Bezugsquerschnitt  $A_{bez}$  stellt in diesem Fall keine Konstante dar, sondern ist abhängig von einem Stellsignal (z.B. dem Drosselklappenwinkel  $\alpha_{DK}$ ).

### Der Verdichter

Die übliche Beschreibung des Verdichters erfolgt, wie in [Eichseder et al., 2008] und [Merker et al., 2006] dargestellt, durch Kennfeld basierte Ansätze. Diese Daten sind vom Hersteller bei vorgegebenen Bezugsbedingungen vermessene Kennfelder und damit unabhängig von den tatsächlichen Umgebungsbedingungen. Bei den bezogenen Größen [Merker et al., 2006, S. 239] handelt es sich um den bezogenen Verdichtermassenstrom  $\dot{m}_{V,bez}$

$$\dot{m}_{V,bez} = \frac{p_{bez}}{p_{vV}} \sqrt{\frac{T_{vV}}{T_{bez}}} \dot{m}_V \quad (3.7)$$

und der bezogenen Turboladerdrehzahl  $n_{ATL,bez}$

$$n_{ATL,bez} = \sqrt{\frac{T_{bez}}{T_{vV}}} n_{ATL} \quad (3.8)$$

mit der Bezugstemperatur  $T_{bez}$  und dem Bezugsdruck  $p_{bez}$  der Vermessung. In den angegebenen dreidimensionalen Kennfeldern des Herstellers sind die bezogene Turboladerdrehzahl  $n_{ATL,bez}$  und der isentrope Verdichterwirkungsgrad  $\eta_V$  über die Achsen des Verdichterdruckverhältnis  $\Pi_V = \frac{p_{nV}}{p_{vV}}$  und des bezogenen Verdichtermassenstromes  $\dot{m}_{V,bez}$  abgebildet.

Die, für die mechanische Kopplung des Abgasturboladers über die Turboladerwelle benötigte, Verdichterleistung  $P_V$  berechnet sich laut [Mollenhauer and Tschöke, 2007, S. 46] durch

$$P_V = c_{p,Luft} \cdot T_{nV} \cdot \dot{m}_V \cdot \left( \left( \frac{p_{nV}}{p_{vV}} \right)^{\left( \frac{\kappa_{Luft}-1}{\kappa_{Luft}} \right)} - 1 \right) \cdot \frac{1}{\eta_V}. \quad (3.9)$$

Die Verdichtung der angesaugten Luft bewirkt gleichzeitig eine Erhöhung der Temperatur nach dem Verdichter  $T_{nV}$  und lässt sich laut [Merker et al., 2006, S. 242] durch

$$T_{nV} = T_{vV} \left( 1 + \frac{1}{\eta_V} \left( \left( \frac{p_{nV}}{p_{vV}} \right)^{\frac{\kappa_{Luft}-1}{\kappa_{Luft}}} - 1 \right) \right) \quad (3.10)$$

berechnen.

Bei den in diesen Gleichungen verwendeten Parametern handelt es sich um die spezifische Wärmekonstante bei konstantem Druck  $c_{p,Luft}$  von Luft und den Isentropenexponent von Luft  $\kappa_{Luft}$ .

### Der Ladeluftkühler

Bei dem Ladeluftkühler (LLK) handelt es sich um eine Drosselstelle mit reibungsbehafteter inkompressibler Strömung. Er lässt sich durch Gleichung 3.4 beschreiben. Zusätzlich ist seine Aufgabe, die Kühlung der verdichteten Luft zu modellieren. [Isermann, 2010, S. 108] verweist darauf, dies durch ein einfaches Wärmetauschermodell zu modellieren. Durch die Einführung des Wirkungsgrades des Ladeluftkühlers  $\eta_{LLK}$  ist die Temperatur nach dem Ladeluftkühler durch

$$T_{nLLK} = T_{nV} - \eta_{LLK} \cdot (T_{nV} - T_{KM}) \quad (3.11)$$

definiert [Schwarzmann, 2007, S. 171]. Die Größe  $T_{KM}$  kennzeichnet die Temperatur des Kühlmittels.

### Die Turbine

Ähnlich der Modellierung des Verdichters werden bei der Turbinenbeschreibung vom Hersteller vermessene Kennfelder herangezogen. Auch hier sind dafür auf die Vermessungsbedingung bezogene Größen erforderlich [Merker et al., 2006, S. 250]. Es handelt sich dabei um den bezogenen Turbinenmassenstrom

$$\dot{m}_{T,bez} = \dot{m}_T \frac{\sqrt{T_{vT}}}{p_{vT}} \quad (3.12)$$

und die bezogene Turboladerdrehzahl

$$n_{ATL,bez} = \frac{n_{ATL}}{\sqrt{T_{vT}}}. \quad (3.13)$$

In den Herstellerkennfeldern zur Turbine sind der bezogene Massenstrom  $\dot{m}_{T,bez}$  und der Turbinenwirkungsgrad  $\eta_T$  in Abhängigkeit vom Turbinendruckverhältnis  $\Pi_T = \frac{p_{nT}}{p_{vT}}$  und der bezogenen Turboladerdrehzahl  $n_{ATL,bez}$  dargestellt. Da  $\dot{m}_{T,bez}$  nur eine geringe Abhängigkeit von der Turboladerdrehzahl aufweist, wird dieser oft nur als Kennlinie über  $\Pi_T$  abgebildet.

Die, für die mechanische Kopplung des Abgasturboladers über die Turboladerwelle benötigte, Turbinenleistung  $P_T$  berechnet sich laut [Mollenhauer and Tschöke, 2007, S. 46] durch

$$P_T = c_{p,Abgas} \cdot T_{vT} \cdot \dot{m}_T \cdot \left( 1 - \left( \frac{p_{vT}}{p_{nT}} \right)^{\left( \frac{\kappa_{Abgas}-1}{\kappa_{Abgas}} \right)} \right) \cdot \eta_T. \quad (3.14)$$

Bei den in diesen Gleichungen verwendeten Parametern handelt es sich um die spezifische Wärmekonstante bei konstantem Druck  $c_{p,Abgas}$  vom Abgas und den Isentropenexponent vom Abgas  $\kappa_{Abgas}$ .

### Die Turboladerwelle

Die Dynamik der Turboladerkreisfrequenz lässt sich durch

$$J_{ATL} \cdot \frac{d}{dt} \omega_{ATL} = \frac{1}{\omega_{ATL}} \cdot (P_T - P_V) - \omega_{ATL} \cdot d_{ATL} \quad (3.15)$$

$$(3.16)$$

ausgehend von einer Startkreisfrequenz  $\omega_{ATL}(0) = \omega_{ATL,0}$  und  $\omega_{ATL}(t) \neq 0$  beschreiben. Darin stellt  $J_{ATL}$  das Trägheitsmoment und  $d_{ATL}$  die Dämpfung des Turboladers dar.

Für die erwähnten Kennfelder des Verdichters und der Turbine wird meist statt der Turboladerkreisfrequenz die Turboladerdrehzahl in  $\frac{U}{min}$  verwendet. Diese ist durch

$$n_{ATL} = \frac{60}{2\pi} \omega_{ATL} \quad (3.17)$$

zu berechnen.

### Das Wastegate

Das Wastegate entspricht einer Drosselstelle mit variablem Querschnitt und lässt sich durch die Gleichung für reibungsbehaftete kompressible Strömungen 3.5 beschreiben. Die interessante Frage an dieser Stelle ist, wie der vom Steller beeinflusste Bezugsquerschnitt  $A_{bez}$  zu definieren ist. Während bei einem elektrischen Wastegate der Öffnungsgrad bekannt ist, ist er bei einem pneumatischen Wastegate abhängig vom Luftdruck  $p_{DD}$  in der Druckdose. Eine Membran in der Druckdose arbeitet gegen eine mechanische Feder. Ist die Federkraft kleiner als die Kraft durch den Dosendruck, öffnet sich das Wastegate. Dies ist zugleich eine Sicherheitsfunktion, da bei hohen Ladedrücken das Wastegate geöffnet wird und damit die Leistung der Turbine abnimmt.

Das Stellsignal  $TV_{WG}$  wirkt auf ein Ventil zwischen Ladedruck und Umgebungsluftdruck und stellt damit einen Dosendruck zwischen Ladedruck (nach dem Ladeluftkühler)  $p_{vDK}$  und Umgebungsluftdruck  $p_u$  ein.

$$p_{DD} = p_u + (p_{vDK} - p_u) \cdot f_{DD}(TV_{WG}) \quad (3.18)$$

Zusätzlich beeinflusst die Druckdifferenz zwischen dem Druck vor der Turbine und dem Druck nach der Turbine ( $\Delta p_{WG} = p_{vT} - p_{nT}$ ) den Öffnungsgrad, da ein hoher Differenzdruck eine weitere Öffnung der Wastegateklappe bewirkt.

Für den Bezugsquerschnitt  $A_{WG,bez}$  ergibt sich der Zusammenhang

$$A_{WG,bez} = A_{WG,bez}(p_{DD}, \Delta p_{WG}) \quad (3.19)$$

und liegt als vermessenenes Kennfeld vor.

Bei  $TV_{WG} = 100\%$  ist  $p_{DD} = p_u$  und das Wastegate schließt. Damit entsteht die maximale Turbinenleistung in diesem Arbeitsbereich. Bei  $TV_{WG} = 0\%$  ist  $p_{DD} = p_{vDK}$  und das Wastegate öffnet. In diesem Fall entsteht die geringste Turbinenleistung, da der wesentliche Anteil des Abgasmassenstromes durch den Bypass an der Turbine vorbeigeführt wird ( $\dot{m}_{Abgas} = \dot{m}_T + \dot{m}_{WG}$ ).

### Der Ottomotor

Das Motormodell hat die Aufgabe, den Abgasmassenstrom und die Abgastemperatur zu berechnen. Dafür existieren in der Literatur verschiedene Ansätze, die sich nicht nur durch die Betrachtung eines Mittelwertmodells oder eines arbeitsspielaufgelösten Modells unterscheiden. Weiterhin spielt die Variante des Motors eine wesentliche Rolle. So ist z.B. eine vorhandene Abgasrückführung zu berücksichtigen.

In [Isermann, 2010, S. 114 ff.] ist eine einfache Modellannahme beschrieben. Sie geht davon aus, dass im Brennraum die gleichen Bedingungen wie im Saugrohr ( $p_{vDK}$  und  $T_{vDK}$ ) vorherrschen und der Motor als Pumpe wirkt. Für den angesaugten Luftmassenstrom des Motors  $\dot{m}_{Motor}$  ergibt sich demnach

$$\dot{m}_{Motor} = \frac{1}{2} \cdot \lambda_A \cdot n_{mot} \cdot V_H \cdot \frac{p_{vDK}}{R_{Luft} \cdot T_{vDK}} \quad (3.20)$$

mit dem Luftaufwand  $\lambda_A$ . Diese Größe beschreibt die Strömungsverluste im Einlassventil und in den Zylindern und lässt sich aus Messdaten im Kennfeld  $f_{LA}(n_{mot}, p_{vDK}, p_{vT})$  identifizieren. Der Faktor  $\frac{1}{2}$  ergibt sich aus der Anzahl der Arbeitstakte pro Zylinder und Umdrehung.

Der Abgasmassenstrom berechnet sich aus der Summe des angesaugten Luftmassenstromes und der eingespritzten Kraftstoffmenge

$$\dot{m}_{Abgas} = \dot{m}_{Motor} + \dot{m}_{KS}. \quad (3.21)$$

Zusätzlich sind hier gegebenenfalls weitere Summanden, wie z.B. Restgasmasse im Zylinder oder zurückgeführtes Restgas, zu berücksichtigen. Unter der Annahme, dass stöchiometrische Gasgemische auftreten, d.h. das Kraftstoff-Luft-Gemisch verbrennt vollständig, kann die eingespritzte Kraftstoffmasse durch  $\dot{m}_{KS} = \frac{1}{\lambda_L} \cdot \dot{m}_{Motor}$  berechnet werden.

Die Abgastemperatur  $T_{vT}$  berechnet sich laut [Isermann, 2010, S. 114] vereinfacht aus der Enthalpiebilanz

$$\dot{H}_A = \dot{H}_E + \Delta\dot{H} \quad (3.22)$$

mit der Abgasenthalpie  $H_A$ , der Enthalpie der angesaugten Luft  $H_E$  und der Enthalpiezunahme  $\Delta H$ . Die Größe  $\Delta H$  entspricht dem Wärmeeintrag der im Motor stattfindenden Verbrennung und wird durch ein vermessenes Kennfeld

$$\Delta\dot{H} = f_{AT}(n_{mot}, m_{KS}, m_{Motor}) \quad (3.23)$$

dargestellt. Aus der ermittelten Abgasenthalpie lässt sich die Abgastemperatur aus dem Zusammenhang

$$\dot{H}_A = c_{p,Abgas} \cdot \dot{m}_{Abgas} \cdot T_{vT} \quad (3.24)$$

bestimmen. In komplexeren Modellen erfolgt zusätzlich eine Berücksichtigung der Temperaturen der heißen Zylinderwände, durch die eine zusätzliche Erwärmung stattfindet.

### 3.3. Die Ladedruckregelung (LDR) im Steuergerät

Bei Fahrzeugmotoren ist es wichtig, auch bei geringeren Motordrehzahlen ein hohes Motormoment zu erzeugen und so das erforderliche Beschleunigungsvermögen zu erreichen. Daher sind die Turbinen des Abgasturboladers oft kleiner dimensioniert, als es der Betrieb bei Nennlast erfordern würde. Dadurch kann die Turbine bei kleinen Motordrehzahlen und dementsprechend geringeren Abgasmassenströmen hohe Ladedrücke erzeugen [Merker et al., 2006, S. 268]. Hohe Motordrehzahlen sind wiederum für eine solche Turbine problematisch. Zum einen kann der dabei erzeugte hohe Ladedruck außerhalb des zulässigen Betriebsbereiches des Verdichters liegen und zum anderen kann es zu einer mechanischen Überlastung des Motors kommen. Dies erfordert den Einsatz einer Ladedruckregelung (LDR) [Mollenhauer and Tschöke, 2007, S. 53 ff.], [Merker et al., 2006, S. 268 f.].

Die eingesetzten Ladedruckregelungen in aktuellen Steuergeräten weisen modellbasierte Ansätze auf und sind häufig durch physikalische Gleichungen in Kombination mit Kennlinien und Kennfeldern realisiert. Solche Kennfelder bilden komplexe Zusammenhänge bzw. Funktionen ab und ermöglichen so eine Reduzierung der erforderlichen Rechenlast im Steuergerät. Nachteilig ist, dass diese Kennfelder aufwändig an Prüfständen zu applizieren sind [Guhr et al., 2007, S. 3 f.]. Kommt es zu baulichen Änderungen oder Parameteränderungen anderer Motorfunktionen sind diese Kennfelder häufig neu zu ermitteln. Die Abb. 3.2 zeigt eine verallgemeinerte Struktur des Regelkreises. Stand

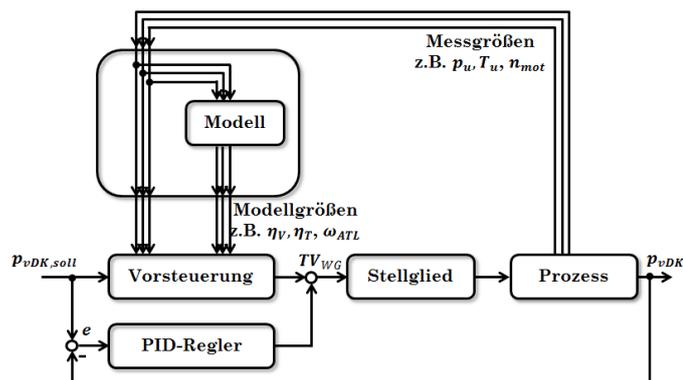


Abbildung 3.2. Verallgemeinerte Struktur der Ladedruckregelung

der Technik ist die Verwendung einer Vorsteuerung für das Führungsverhalten und einer PI-Regelung zur Korrektur von Modellabweichungen und Störungen. Die allgemeine Zielstellung der LDR ist das schnellstmögliche Erreichen des geforderten Ladedruckes ohne starkem Überschwingen. Ein leichtes Überschwingen ist gewünscht, um die vom Fahrer geforderte Fahrdynamik zu gewährleisten. Weiterhin sind zusätzliche Schwingungen im Ladedruck zu vermeiden bzw. zu dämpfen.

### 3.3.1. Vorsteuerung der LDR

Neben dem Sollwert und weiteren gemessenen Prozess- und Umgebungsgrößen, wie z.B.  $p_u$ ,  $T_u$ ,  $n_{mot}$  und  $p_{vDK}$ , dienen auch modellierte Prozessgrößen, wie z.B.  $\omega_{ATL}$ ,  $\eta_V$  und  $\eta_T$ , als Eingangsgrößen der Vorsteuerung. Vereinfacht betrachtet, gliedert sie sich in einen stationären Teil für das stationäre Führungsverhalten und einen dynamischen Teil für das Einschwingverhalten bei Aktivierung der LDR.

Der stationäre Teil beruht auf dem Modellansatz der Leistungsbilanz

$$P_V = P_T \quad (3.25)$$

bzw. mit Berücksichtigung der Gleichungen 3.9 und 3.14 auf der Überführung in die erste Turboladerhauptgleichung

$$\Pi_V = \frac{p_{nV}}{p_{vV}} = \left( 1 + \frac{\dot{m}_T}{\dot{m}_V} \cdot \frac{c_{p,Abgas}}{c_{p,Luft}} \cdot \frac{T_{vT}}{T_{vV}} \cdot \eta_T \cdot \eta_V \cdot \left( 1 - \left( \frac{p_{nT}}{p_{vT}} \right)^{\frac{\kappa_{Abgas}-1}{\kappa_{Abgas}}} \right)^{\frac{\kappa_{Luft}}{\kappa_{Luft}-1}} \right). \quad (3.26)$$

Es ergibt sich mit der Verwendung des Solldruckes  $p_{vDK,s}$  für den Turbinensollmassenstrom  $\dot{m}_{T,s}$  bzw. für den Wastegatesollmassenstrom  $\dot{m}_{WG,s}$

$$\dot{m}_{T,s} = \dot{m}_V \cdot \frac{c_{p,Luft}}{c_{p,Abgas}} \cdot \frac{T_{nV}}{T_{vT}} \cdot \frac{1}{\eta_T \cdot \eta_V} \cdot \frac{\left( \frac{p_{vDK,s}}{p_{vV}} \right)^{\frac{\kappa_{Luft}-1}{\kappa_{Luft}}} - 1}{1 - \left( \frac{p_{nT}}{p_{vT}} \right)^{\frac{\kappa_{Abgas}-1}{\kappa_{Abgas}}}} \quad (3.27)$$

$$(3.28)$$

und

$$\dot{m}_{WG,s} = \dot{m}_{Abgas} - \dot{m}_{T,s}. \quad (3.29)$$

Weiterhin ist eine Beschreibung der Zusammenhänge des pneumatischen Wastegates unter Berücksichtigung der Druck- und Federkräfte der Druckdose notwendig. Dies geschieht durch weitere Kennfelder, die das inverse Verhalten des Stellgliedes beschreiben [Merker et al., 2006, S. 269].

Die Abb. 3.3 zeigt vereinfacht den Verlauf der Stellgröße einer aktiven LDR bei einer Volllastanforderung (sprungförmige Änderung der Regelgröße). Im vorderen Abschnitt hat die dynamische Vorsteuerung den dominanten Stellgrößenanteil und ermöglicht die maximale Performance zum Erreichen des Sollwertes. Das betrachtete Korrekturkennfeld beeinflusst den Abschaltzeitpunkt der Vollensteuerung des Wastegates, welcher einen diskreten Zeitpunkt darstellt. Danach sorgt die stationäre Vorsteuerung für das Einhalten des Sollwertes in Abhängigkeit des jeweiligen Arbeitspunktes bzw. Betriebsbereiches.

Die Grundparametrierung der Kennfelder erfolgt durch Herstellerdaten der Bauteilkomponenten und durch spezielle Prüfstandsmessungen mit erweiterter Messtechnik. Um Quereinflüsse und nicht funktional abgebildete Zusammenhänge zu berücksichtigen, stehen Korrekturkennfelder zur Verfügung, die nach den Prüfstandsmessungen und Testfahrten einzustellen sind [Guhr et al., 2007, S. 4].

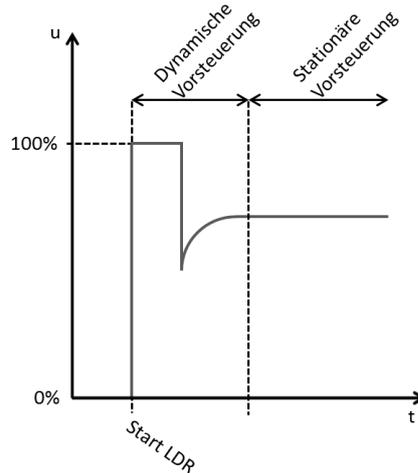


Abbildung 3.3. Skizzierter Verlauf der vorgesteuerten LDR-Stellgröße

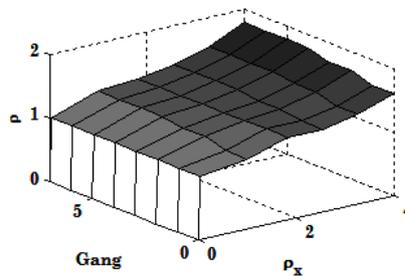


Abbildung 3.4. Korrekturkennfeld, stationäre Vorsteuerung

Das Korrekturkennfeld der stationären Vorsteuerung (Abb. 3.4) ist abhängig vom gewählten Gang und der normierten Eingangsgröße  $\rho_x$ . Zwischenwerte des Kennfeldes berechnet das Steuergerät durch eine lineare Interpolation in Abhängigkeit der Eingangsgröße  $\rho_x$ . Die Applikation der stationären Vorsteuerung erfolgt bei Versuchen mit Vollastfahrten. Dabei ist ein konstanter Gang anzuwählen, der PI-Regler zu deaktivieren und ein Beschleunigungsvorgang durchzuführen. Hierbei wird  $\rho_x$  in einem Bereich beginnend von  $\rho_{x,A}$  bis  $\rho_{x,E}$  durchfahren.

Das Korrekturkennfeld  $\rho_t$  der dynamischen Vorsteuerung (Abb. 3.5) ist abhängig vom Umgebungsluftdruck  $p_u$  und der Motordrehzahl  $n_{mot}$ . Die Applikation der dynamischen Vorsteuerung erfolgt bei Versuchen mit Vollastfahrten. Für die Änderung des Luftdruckes sind Höhererprobungen bzw. Druckkammern notwendig. Während der Applikation ist der PI-Regler zu deaktivieren und ein Beschleunigungsvorgang bei gewählten Drehzahlarbeitspunkten durchzuführen.

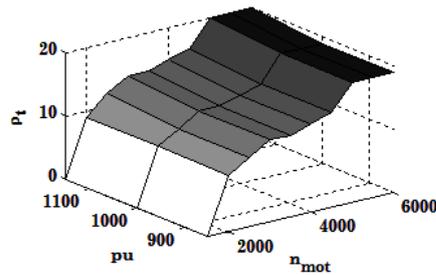


Abbildung 3.5. Korrekturkennfeld, dynamische Vorsteuerung

### 3.3.2. PI-Regler der LDR

Bei dem eingesetzten Regler handelt es sich um einen PI-Regler mit folgender Übertragungsfunktion

$$G_R(s) = K_P + \frac{K_I}{s}. \quad (3.30)$$

Der PI-Regler ist als Störregler auszulegen und die Reglerparameter  $K_P$  und  $K_I$  drehzahlabhängig zu bestimmen (Abb. 3.6). Dies entspricht einem Gain Scheduling der Reglerparameter. Während der Applikation sind für die gewählten Drehzahlarbeitspunkte Störeranregungen am Prozess durchzuführen, die vom PI-Regler zu dämpfen sind. Als Prozessanregung zum Anlernen des PI-Reglers lassen sich somit schnelle Änderungen in der Stellgröße als Störانregung verwenden. Als Szenarien von Störungen der Lade-

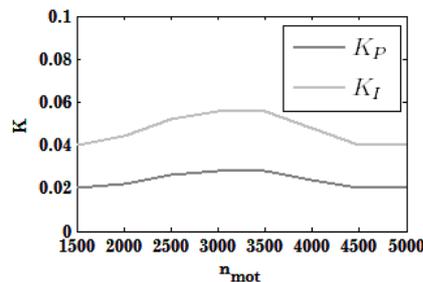


Abbildung 3.6. Kennlinie der Reglerparameter

druckregelung sind folgende Möglichkeiten denkbar.

- A Es sind Änderungen von Umgebungsbedingungen (Luftdruck  $p_u$ , Umgebungstemperatur  $T_u$ ) möglich. Diese Änderungen entstehen aber nicht innerhalb eines Beschleunigungsvorgangs bzw. einem Regelungsvorgang der LDR. Sie stellen somit keine relevanten Störungen des Prozesses in Hinblick auf den Reglerentwurf dar und sind direkt als Parameter in der Vorsteuerung berücksichtigt.
- B Weiterhin sind Aktuatorstörungen möglich, in der sich das Verhältnis zwischen  $\dot{m}_T$  und  $\dot{m}_{WG}$  ändert. Dies geschieht bei der Alterung und bei dem Verschleiß des Wastegates, z.B. durch Verschmutzung oder dem Nachlassen der Federkraft. Eine solche Störung tritt in einem sehr großen Zeithorizont auf, sodass ein Änderung

während einer aktiven LDR nicht spürbar ist und sie somit für den Entwurf des Reglers nicht relevant ist.

- C Die Einlassnockenwelle ist falsch gestellt. Dadurch treten geringe Änderungen im Ladedruck und der Füllung innerhalb des Regelungszeitraums einer aktiven LDR auf.
- D Schaltvorgänge durch Gangwechsel oder AVS-Umschaltung der Nockenwelle zwischen kleinen und großen Ventilhüben führen zu spontanen Wechseln der Arbeitspunkte. In Teilen kann die Vorsteuerung darauf reagieren, indem sie ebenfalls zwischen Kennfeldern umschaltet. Zur Vermeidung von Stellgrößensprüngen sind an solchen Stellen Umblendfunktionen aktiv. Zusätzlich treten Sollwertänderungen durch den geänderten Arbeitspunkt auf.

### 3.4. Anforderungen des Prozesses an das selbsteinstellende Verfahren

**Regelstruktur:** Das zu entwickelnde selbsteinstellende Verfahren hat die Aufgabe, die Parametrierung der Korrekturkennfelder zu automatisieren und den Applikateur in dieser Phase zu unterstützen. Der Prozess der Ladedruckregelung weist spezielle Anforderungen an ein solches Verfahren auf. Zunächst ist festzustellen, dass die Regelstruktur und die Einstellungsparameter durch die Programmierung des Steuergerätes vorgegeben und nicht zu ändern sind.

**Verwendung des Verfahrens:** Da die Parametrierung bei Fahrten auf der Straße erfolgen soll, sind viele reproduzierbare Versuche im Fahrzeug nicht realisierbar. Ziel muss es sein, die Anzahl der benötigten Versuche so gering wie möglich zu halten. Somit muss ein solches Selbsteinstellungsverfahren einen hohen Änderungsgradienten der Parameter aufweisen und gleichzeitig die Konvergenz des Verfahrens sicherstellen. Eine Verschlechterung des Fahrverhaltens (z.B. Leistungsverlust oder unruhige Fahrdynamik) ist nicht zulässig. Zur Gewährleistung der Sicherheit des Fahrers erfolgt die Verarbeitung der Messdaten und die Änderung der Parametrierung nach jeder durchgeführten Versuchsfahrt. Diese Anforderungen beschränken damit das gesuchte Verfahren auf eine offline-Variante, die nicht dauerhaft arbeitet. Ein solches Verfahren arbeitet iterativ nach jedem durchgeführten Versuch.

**Sollwertverlauf:** Auf Grund der Umgebungsbedingungen (z.B. den Straßenverhältnissen) und der Ausgangsbedingungen (z.B. unterschiedliche Startmotordrehzahlen) weichen die Sollverläufe der LDR in jedem Versuch voneinander ab. Die Berechnung des Sollwertverlaufes erfolgt durch das Steuergerät und ist nicht direkt veränderbar. Der Aufwand zum Ändern des Sollwertes ist sehr hoch, erfordert viel Systemwissen und ist daher zu vermeiden. Der Verlauf des Sollladedruckes ist sprungförmig und arbeitspunktabhängig.

**Begrenzungen:** Die Stellgröße ist durch den Öffnungsgrad des Wastegates begrenzt. So ist bei  $u = 100\%$  das Wastegate maximal geschlossen, so dass der Abgasmassenstrom fast ausschließlich über die Turbine strömt und damit die größtmögliche Turbinenleistung  $P_T$  erzeugt. Bei  $u = 0\%$  ist die Wastegateklappe komplett geöffnet und über die Turbine strömt ein minimaler Abgasmassenstrom, der sich zwischen Turbine und Wastegate aufteilt. Dadurch ist die Regelgröße ebenfalls begrenzt. Durch den minimalen Abgasmassenstrom bei  $u = 0\%$  stellt sich ein Grundladedruck ein, der über dem Normalluftdruck liegt. Ein maximaler Ladedruck ist auf Grund des Bauteilschutzes vorgegeben.

**Prozesswissen:** Die Anwendung eines selbsteinstellenden Verfahrens setzt die Kenntnis der Stellgröße und der Regelgröße, der einzustellenden Parameter und Kennfelder, sowie der Art und Weise der Versuchsfahrten voraus. Eine zusätzliche Modellierung des Selbsteinstellungsverfahrens ist zu vermeiden, da die Anwendung des Selbsteinstellungsverfahrens die Applikationszeit verringern soll und keinen Mehraufwand erzeugen darf.

### Zusammenfassung der wesentlichen Anforderungen

- Bei dem betrachteten Prozess handelt es sich um ein System mit einer Eingangsgröße und einer Ausgangsgröße.
- Die Regelungsstruktur (Vorsteuerung und Regler) ist vorgegeben.
- Gesucht ist ein offline-Verfahren mit hohem Änderungsgradienten und gewährleiteteter Konvergenz.
- Es ist eine iterative Vorgehensweise möglich.
- Der Verlauf der Sollgröße ist sprungförmig, arbeitspunktabhängig und nicht beeinflussbar.
- Die Stell- und die Regelgröße ist begrenzt.
- Zusätzlicher Modellierungsaufwand ist zu vermeiden.

# Kapitel 4.

## Entwicklungen von ILR-basierten Verfahren zur Selbsteinstellung

Dieses Kapitel beschreibt die entwickelten Verfahren zur Selbsteinstellung von Parametern gegebener Regelungsstrukturen. Dazu erfolgt zunächst die Auswahl des Verfahrens anhand der Prozessanforderungen. Im Hauptteil sind die entwickelten und modifizierten Selbsteinstellungsverfahren dokumentiert.

### 4.1. Diskussion zur Aufgabenstellung

#### Ziel des Verfahrens

Ziel dieser Entwicklung soll ein Verfahren sein, das es ermöglicht, die Parameter nichtlinearer komplexer Regelungsstrukturen, bestehend aus Vorsteuerung und Regler, automatisch einzustellen und so die Applikationszeit zu minimieren. In Abb. 4.1 ist diese grundlegende Regelungsstruktur dargestellt. Dabei wird von folgender Annahme ausgegangen.

**Annahme 4.1 (Voraussetzung des Selbsteinstellungsverfahrens)** *Für ein nichtlineares System existiert eine geeignete Regelungsstruktur, die aus einer Vorsteuerung  $C_V$  und einem Regler  $C_R$  besteht. Deren Parametervektor  $\hat{p}$  ist hinsichtlich definierter Ziele zu optimieren. Dabei sind für unterschiedliche Arbeitsbereiche bzw. Arbeitstrajektorien unterschiedliche Parameter zu optimieren.*

Aus den Prozessanforderungen in Abschnitt 3.4 sind die Rahmenbedingungen:

- das Verfahren soll offline arbeiten,
- das Verfahren soll für vorgegebene Regelungsstrukturen geeignet sein,
- die einzustellenden Parameter können Bestandteil von Kennfeldern sein,

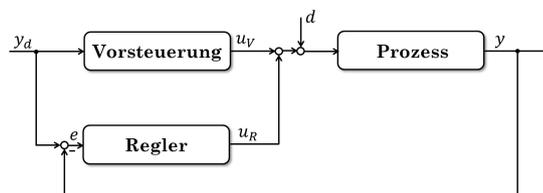


Abbildung 4.1. Darstellung der Regelungsstruktur

- die Eingangsgröße ist begrenzt,
- das Verfahren soll iterativ mit möglichst wenigen Iterationen (d.h. einem hohen Änderungsgradienten) arbeiten,
- der Sollwertverlauf ist berechnet und dadurch schwer veränderbar und
- es ist keine Modellierung des Prozesses notwendig

zu erfüllen.

### Auswahl des Verfahrens

Die in Kapitel 2 aufgeführten Verfahren sind alle signalbasiert und benötigen kein Modell des Prozesses. Allerdings weisen sie teilweise Eigenschaften auf, die den Einsatz für diese Aufgabe erschweren. Dieser Abschnitt diskutiert deren Vor- und Nachteile im Bezug auf die Aufgabenstellung und begründet die Auswahl des verwendeten Verfahrens.

**IFT:** Das IFT-Verfahren ist aus mehreren Gründen für diese Aufgabe nicht geeignet. Zum einen benötigt es in jeder Iteration mehrere Experimente und erhöht damit den zeitlichen Aufwand und die Kosten durch eine erhöhte Anzahl von Versuchen bzw. Testläufen. Weiterhin erlaubt der Prozess nicht die Vorgabe eines speziellen Sollgrößenverlaufes. Eine weitere Herausforderung stellt die analytisch bestimmte partielle Ableitung der Regelungsstruktur des Parametervektors dar. Dieser Vektor enthält Elemente von Kennfeldern, die während der Versuchsfahrt durchfahren werden.

**VRFT & FRIT:** Beide Verfahren sind einmalige Entwurfsverfahren, die nur ein Experiment benötigen. Das VRFT-Verfahren benötigt die Vorgabe geeigneter Vorfilter und Referenzverhalten, um in die Nähe des Optimums zu gelangen. Dieses Verfahren kommt dann zum Einsatz, wenn für weitere iterative Optimierungsverfahren eine fehlende Startparametrierung zu ermitteln ist. Beim FRIT-Verfahren stellt die Invertierung des Reglers bei komplexen nichtlinearen Regelstrukturen eine Herausforderung dar und ist damit für die gegebene Aufgabenstellung ungeeignet.

**MFAC:** Diese Verfahren weisen eine eigene Regelungsstruktur auf und können damit nicht auf eine vorgegebene Regelungsstruktur angewendet werden. Zudem handelt es sich hier um online Verfahren, welche eines erhöhten Aufwandes zur Anpassung der Einstellfaktoren bedürfen, um das Optimierungsziel festzulegen.

**CPM:** Die Aufstellung von Einstellregeln anhand von Güteindices für die Parameter eines Kennfeldes gestaltet sich sehr aufwändig. Für jeden einzustellenden Parameter ist sein Einfluss auf die Güteindices zu bestimmen und es sind entsprechende Anpassungsregeln zu definieren.

**ILR:** Die ILR hat den Vorteil, dass sie für nichtlineare Prozesse anwendbar ist und komplette Verläufe optimiert. Dabei kommt sie ohne Modellierungsaufwand aus und benötigt nur wenig Prozesswissen. Weiterhin gibt sie die Änderungsrichtung der Parameter vor, welche nicht mehr separat zu ermitteln ist. Die existierenden ILR-Verfahren ermöglichen maximale Lernraten bei gleichzeitiger Konvergenz und können somit in wenigen Iterationen zum Ziel führen. Allerdings liefert die ILR bisher eine optimierte Stellgrößentrajektorie und keine Parameter für eine existierende Regelungsstruktur.

### Entwicklungsaufgabe

Das folgende Kapitel beschreibt Ansätze zur Selbsteinstellung von Parametern unter der Verwendung der ILR-Theorie. Die Grundüberlegung dieser Selbsteinstellung ist, dass eine entsprechend entworfene ILR den Stellgrößenverlauf nach jeder Iteration optimiert und eine Verbesserung im Folgeverhalten der Sollwerttrajektorie liefert. Dabei ist der Entwurf der ILR abhängig von der Modellgenauigkeit (Modellabweichungen, Nichtlinearitäten und Linearisierungsfehlern), dem Messrauschen aller relevanten Signale und weiteren stochastischen Störungen. Ausgehend von den Startwerten des Parametervektors  $\boldsymbol{\rho}_0$  und der vorgegebenen Sollwerttrajektorie  $\boldsymbol{y}_d$  beginnt die Optimierung. Der Parametervektor  $\boldsymbol{\rho}_0$  bestimmt die Startstellgrößentrajektorie  $\boldsymbol{u}_0$ . Daraus resultiert die Ausgangsgrößentrajektorie  $\boldsymbol{y}_0$  bzw. die Trajektorie der Regelabweichung  $\boldsymbol{e}_0$ .

$$\boldsymbol{u}_0 = \boldsymbol{u}(\boldsymbol{\rho}_0), \quad \boldsymbol{u} \in \mathbb{R}^{N \times 1} \quad (4.1)$$

$$\boldsymbol{y}_0 = \boldsymbol{y}(\boldsymbol{\rho}_0), \quad \boldsymbol{y} \in \mathbb{R}^{N \times 1} \quad (4.2)$$

$$\boldsymbol{e}_0 = \boldsymbol{e}(\boldsymbol{\rho}_0) = \boldsymbol{y}_d - \boldsymbol{y}_0, \quad \boldsymbol{e} \in \mathbb{R}^{N \times 1} \quad (4.3)$$

**Annahme 4.2 (Voraussetzung des Startparametervektors  $\boldsymbol{\rho}_0$ )** Für die bestehende und zu optimierende Regelungsstruktur existiert ein Startparametervektor  $\boldsymbol{\rho}_0$ . Dieser ermöglicht einen Versuch am Prozess, um so die Startverläufe  $\boldsymbol{y}_d$ ,  $\boldsymbol{u}_0$ ,  $\boldsymbol{y}_0$  und  $\boldsymbol{e}_0$  zu bestimmen.

Mit den Ansätzen der ILR-Theorie ist die optimierte Stellgrößentrajektorie  $\boldsymbol{u}_{ILR}$  und die daraus resultierende Ausgangsgrößentrajektorie  $\boldsymbol{y}_{ILR}$  zu bestimmen. Aus dem optimierten Stellgrößenverlauf erfolgt die Optimierung des Parametervektors  $\hat{\boldsymbol{\rho}}$ . Eine allgemeine Struktur des Verfahrens zeigt die Abb. 4.2. Dieses Vorgehen ist für jeden Arbeitspunkt bzw. für jede Arbeitstrajektorie zu wiederholen. Beispielsweise erfordert die Gangabhängigkeit der Vorsteuerung der Ladedruckregelung aus Abschnitt 3.3.1 die Wiederholung der ILR-basierten Parameteroptimierung für jeden Gang. Das grundlegende Ziel ist, den optimalen Parametervektor  $\hat{\boldsymbol{\rho}}$  in möglichst wenigen Schritten zu erreichen. Mit jeder Iteration soll sich der Parametervektor dem Optimierungsziel nähern. In der klassischen Verwendung einer ILR ist dies nicht möglich und erfordert verschiedene Modifikationen für die Anwendung als Selbsteinstellungsverfahren. Die folgenden Abschnitte beschreiben zwei grundlegende Varianten einer ILR-basierten Selbsteinstellung, die sich im Zeitpunkt der Parameteroptimierung unterscheiden und dadurch unterschiedliche Anforderungen an den Anwendungsfall aufweisen.

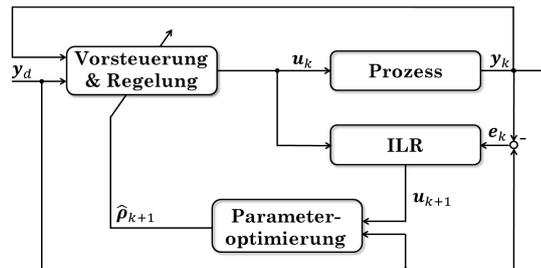


Abbildung 4.2. Allgemeine Struktur des Verfahrens

### Auswahl der ILR-Ansätze

Ausgehend von den Anforderungen an das Selbsteinstellungsverfahren ergeben sich Vorgaben an das verwendete ILR-Verfahren. Zunächst sollte das ILR-Verfahren monotone Konvergenz gewährleisten. Weiterhin ist eine möglichst hohe Lernrate zu erreichen. Damit reduziert sich die notwendige Anzahl an Iterationen und somit die Applikationszeit. Je nach Anwendungsfall kann es zu abweichenden Startbedingungen, zufälligen Störungen und Modellungenauigkeiten kommen. Die Auswirkungen dieser Einflüsse auf das Optimierungsergebnis sollten möglichst gering sein. Die Vorgabe der Einstellfaktoren für das Verfahren sollen verständlich sein, keinen Mehraufwand generieren und das Wunschverhalten abbilden können.

In der Tabelle 4.1 ist ein Vergleich der ILR-Verfahren dargestellt. Die, in Kapitel 1 erwähnte, eigene Veröffentlichung [NJW14b] diskutiert diesen Vergleich ausführlich und liefert weitere Informationen. Die Einteilung beginnt bei '-' für sehr ungeeignet endet bei '++' für sehr geeignet. Darin werden die folgenden Eigenschaften betrachtet:

- **Lernrate:** Gibt eine Aussage über die Anzahl der Iterationen, die für die Selbsteinstellung notwendig sind.
- **Regelgüte:** Bewertet die Konvergenz des Verfahrens, die erreichte Genauigkeit und die Streuung im Zielbereich.
- **Einstellungsfaktoren:** Wie viele einstellbare Faktoren hat das Verfahren?
- **Systemwissen:** Wie viel Prozesswissen ist notwendig?
- **Rauschanfälligkeit:** Bewertet den Einfluss von Mess- und Prozessrauschen.

Neben der Betrachtung der Regelgüte, der Konvergenz und der Lernrate geht in die Bewertung die Anzahl der einzustellenden Tuningparameter sowie das benötigte System- und Prozesswissen des jeweiligen ILR-Ansatzes ein. Hier haben die MFAC-basierten Ansätze den größten Vorteil, da der PPD in jeder Iteration rekursiv geschätzt wird. Alle normoptimierten Ansätze benötigen die Eingangs-Ausgangs-Matrix  $\mathbf{G}$ , welche signalbasiert und ohne zusätzlichen Modellierungsaufwand aus den Messsignalen ermittelt werden kann. Bei den MFAC-basierten ILR höherer Ordnung (PFDL und FFDL) nimmt mit der Ordnung auch die Zahl der einzustellenden Tuningparameter zu, was den Einsatz des Selbsteinstellungsverfahrens kompliziert.

ILR-Verfahren	Regelgüte	Lernrate	Prozesswissen	Einstellfaktoren	Messrauschen
klassische ILR (P)	-	--	+	++	-
klassische ILR (PD)	o	--	+	+	-
normoptimale ILR: mit Pseudoinverse	++	++	o	++	--
mit Pseudoinverse & Regularisierung	+	+	o	+	+
mit gradientenbasiertem Ansatz	++	++	o	++	o
MFAC-ILR (CFDL)	+	++	++	o	+
MFAC-ILR (PFDL)	+	o	++	--	+
MFAC-ILR (FFDL)	+	o	++	--	+

Tabelle 4.1. Vergleich der ILR-Verfahren

Die Ansätze mit den meisten Vorteilen für das beschriebene Selbsteinstellungsverfahren stellen somit normoptimale ILR-Verfahren, wie der Ansatz der Pseudoinversen mit Regularisierung oder der gradientenbasierten Ansatz, dar. Gegebenenfalls ist bei auftretendem Messrauschen ein akausaler Filter  $Q$  zu verwenden.

## 4.2. Erste Erweiterung zum ILR-basierten Selbsteinstellungsverfahren - Variante I

Dieser Abschnitt beschreibt die erste Modifikation der ILR-Verfahren, im folgenden Variante I genannt, zur Verwendung der Selbsteinstellung von Parametern existierender Vorsteuerungen und Regelungen. Die Abb. 4.3 zeigt den Ablauf dieses Verfahrens. Die Modifikation Variante I führt einen klassischen Einsatz einer ILR durch. Zunächst erfolgt die Optimierung der Stellgröße in mehreren Iterationen durch ein geeignetes ILR-Verfahren. Dies geschieht solange, bis die notwendige Regelgüte erreicht ist und die ILR die optimale Stellgrößentrajektorie  $\mathbf{u}_{ILR}$  ermittelt hat. Dabei sind folgende Schritte durchzuführen.

**Start:** Ausgangspunkt ist ein Startversuch (Iteration „1“), beginnend mit der Startstellgrößentrajektorie  $\mathbf{u}_0 = \mathbf{u}(\rho_0)$ .

**Datenvorverarbeitung:** Im nächsten Schritt ist eine Datenvorverarbeitung durchzuführen. Hier ist zunächst die Gültigkeit der Messung zu überprüfen. Dabei sind folgende Fragen zu klären.

- Ist die Messdauer ausreichend lang, um den Zyklus abzubilden?
- War der richtige Arbeitsbereich bzw. Arbeitspunkt (z.B. der richtige Gang) aktiv?
- War der Prozess ausreichend angeregt, so dass eine Freigabe der Steuerung bzw. Regelung erfolgt ist?
- Gab es Vorkommnisse während des Versuchs, die eine Weiterverarbeitung der Daten ausschließen?

Sind diese Forderungen erfüllt, sind die erreichten Arbeitspunkte bzw. Stützstellen des Parameterkennfeldes zu ermitteln, der relevante Datenbereich zu separieren und bei stark verrauschten Messsignalen gegebenenfalls eine akausale Filterung durchzuführen.

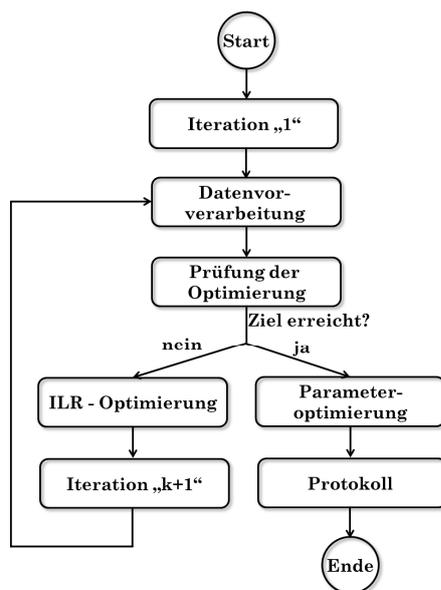


Abbildung 4.3. Ablauf des ILR-basierten Selbsteinstellungsverfahrens: Variante I

Den Abschluss der Datenvorverarbeitung bildet die Verschiebung der gemessenen Datenvektoren zur Bestimmung des „Lifted-System“ und die Berechnung der Eingangs-Ausgangs-Matrix  $G$ .

**Prüfung der Optimierung:** Dieser Schritt prüft, ob die optimierte Stellgrößentrajektorie den Prozess so angeregt hat, dass die gemessene Regelgröße die gegebene Sollwerttrajektorie und damit die geforderte Regelgüte erreicht hat oder ob keine weitere Verbesserung aufgetreten ist. In beiden Fällen erfolgt der Abbruch der Iterationsschleife und der Beginn der Parameteroptimierung.

**ILR-Optimierung:** Das gewählte ILR-Verfahren berechnet die optimierte Stellgröße. Den Abschluss dieses Schrittes bildet die Berücksichtigung von Stellgrenzen.

**Iteration „ $k + 1$ “:** Nach der erfolgten ILR-Optimierung des Stellsignals ist ein neuer Versuch bzw. die Iteration „ $k + 1$ “ durchzuführen. Mit den neuen Daten beginnt die Optimierungsschleife wieder bei der Datenvorverarbeitung.

**Optimierung der Parameter:** Tritt keine Verbesserung mehr auf, erfolgt die Optimierung der gesuchten Parameter durch das Lösen des Optimierungsproblems

$$\hat{\rho} = \arg \min_{\hat{\rho}} (\|u_{ILR,\infty} - u(\hat{\rho})\|_2), \quad \hat{\rho} \in \mathbb{R}, \quad (4.4)$$

bei dem die  $\hat{\rho}$ -abhängige Stellgrößentrajektorie der Regelstruktur die ILR-optimierte Stellgrößentrajektorie  $u_{ILR,\infty}$  bestmöglich abbilden soll. Je nach Anzahl der gesuchten Parameter und der Eigenschaften des Optimierungsproblems ist hier ein geeignetes Optimierungsverfahren auszuwählen.

**Protokoll:** Den Abschluss bildet eine automatische Protokollierung der Optimierungsergebnisse. Dazu ist als letzter Versuch der Test der neuen Parameter durchzuführen. Inhalt des Protokolls ist die Darstellung der Ausgangsmessung, der letzten ILR-Messung und der Test der neuen Parameter. Weiterhin sind die neuen Parameter in einer Datei zum Einlesen im Steuergerät vorzubereiten und abzuspeichern.

### Anwendungsvoraussetzung

Für die Anwendung dieses Verfahrens muss es möglich sein, die bestehende Regelungsstruktur zu deaktivieren, die ILR-Stellgrößentrajektorie zu speichern und dem Prozess aufzuprägen. Dies setzt entweder einen stabilen Prozess oder die Verwendung einer erweiterten ILR-Struktur mit Regler (CITE-FB) voraus. Weiterhin gelten die ILR-üblichen Randbedingungen für die zu wiederholenden Iterationen. Dazu gehört die Gewährleistung von konstanten Startbedingungen, einer konstanten Zyklendauer und gleichbleibender, iterationsinvarianter Sollgrößen oder Störungen.

### Betrachtung der Konvergenz

Der Nachweis der Konvergenz des Selbsteinstellungsverfahrens Variante I erfolgt durch die nachgewiesene Konvergenz des verwendeten ILR-Verfahrens. Auf Grund der Forderungen nach großen Lernraten und monotoner Konvergenz eignen sich besonders die inversionsbasierten ILR-Verfahren. Daher soll der Ansatz der Pseudoinversen laut Gleichung 2.122 und der gradientenbasierte Ansatz laut Gleichung 2.130 betrachtet werden.

Diese ILR-Verfahren benötigen die lineare Eingangs-Ausgangs-Matrix  $\mathbf{G}$  des Systems. Die Anforderungen an das zu entwickelnde Verfahren untersagen eine aufwändige Modellbildung. Daher erfolgt bei nichtlinearen Systemen die Bestimmung von  $\mathbf{G}$  aus den gemessenen Signalvektoren  $\mathbf{y}_k$  und  $\mathbf{u}_k$  laut Gleichung 2.58 durch eine Linearisierung um die gemessene Trajektorie. Auf Grund der Nichtlinearität treten Modellabweichungen zwischen der so berechneten Matrix  $\mathbf{G}_k$  und der unbekanntenen Matrix der Zieltrajektorie  $\mathbf{G}_\infty$  auf. solche Modellabweichungen lassen sich als additive Modellunsicherheiten

$$\mathbf{G}_\infty = \mathbf{G}_k + \Delta\mathbf{G}_a \quad (4.5)$$

oder als multiplikative Modellunsicherheiten

$$\mathbf{G}_\infty = \mathbf{G}_k \Delta\mathbf{G}_m \quad (4.6)$$

beschreiben. Dabei stellt  $\Delta\mathbf{G}_a$  die additive Modellunsicherheit und  $\Delta\mathbf{G}_m$  die multiplikative Modellunsicherheit dar. Da sowohl  $\mathbf{G}_k$  als auch  $\mathbf{G}_\infty$  untere Tridiagonal-Toeplitz-Matrizen sind, haben auch  $\Delta\mathbf{G}_a$  und  $\Delta\mathbf{G}_m$  diese Form.

Durch die vorhandenen Modellunsicherheiten können die erwähnten inversionsbasierten ILR-Ansätze die Konvergenz nicht gewährleisten, da die Konvergenz der in 2.88 definierten ILR-Entwurfsgleichung nicht mehr erfüllt ist. Dies führt zur Verwendung der in Gleichung 2.125 und Gleichung 2.137 beschriebenen Regularisierungsfaktoren. Es werden

A) der Ansatz der Pseudoinversen mit der Lernmatrix  $\mathbf{L} = (\mathbf{G}_k^T \mathbf{G}_k + \eta_1 \mathbf{I})^{-1} \mathbf{G}_k^T$  und

B) der gradientenbasierte Ansatz mit der Lernmatrix  $\mathbf{L} = \frac{\|\mathbf{G}_k^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_k \mathbf{G}_k^T \mathbf{e}_k\|_2^2} \mathbf{G}_k^T$

betrachtet. Das ILR-Gesetz ist durch

$$\mathbf{u}_{k+1} = \mathbf{u}_k + \mathbf{L} \mathbf{e}_k \quad (4.7)$$

gegeben. Damit die Konvergenz der ILR-Entwurfsgleichung erfüllt ist, muss die Bedingung

$$\|\mathbf{e}_{k+1}\|_2 < \|\mathbf{e}_k\|_2 \quad (4.8)$$

gelten. Unter der Berücksichtigung von additiven Modellunsicherheiten ergibt sich aus der Regelabweichung der nächsten Iteration  $\|\mathbf{e}_{k+1}\|_2 = \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2$  die Gleichung

$$\begin{aligned} \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{y}_d - (\mathbf{G}_k + \Delta\mathbf{G}_a)(\mathbf{u}_k + \mathbf{L}\mathbf{e}_k)\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k - \Delta\mathbf{G}_a\mathbf{u}_k - (\mathbf{G}_k + \Delta\mathbf{G}_a)\mathbf{L}\mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 < 0, \end{aligned} \quad (4.9)$$

die kleiner null sein muss. Für multiplikative Modellunsicherheiten gilt

$$\begin{aligned} \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{y}_d - (\mathbf{G}_k\Delta\mathbf{G}_m)(\mathbf{u}_k + \mathbf{L}\mathbf{e}_k)\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k(\mathbf{I} - \Delta\mathbf{G}_m)\mathbf{u}_k - (\mathbf{G}_k\Delta\mathbf{G}_m)\mathbf{L}\mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 < 0. \end{aligned} \quad (4.10)$$

Der Regularisierungsfaktor  $\eta_1$  bzw.  $w$  ist so zu bestimmen, dass die entsprechende Ungleichung erfüllt ist. Dies erfordert eine Abschätzung der Modellunsicherheit für den jeweiligen betrachteten Prozess und ist bei der Anwendung des Verfahrens prozessabhängig zu bestimmen. Dies ist für den aufgeladenen Ottomotor in Kapitel 5 mit Gleichung 5.2 bzw. 5.7 beschrieben.

Ist die Konvergenz gewährleistet, nähert sich die gemessene Trajektorie der Zieltrajektorie immer weiter an. Dies bedeutet gleichzeitig, dass die berechnete Eingangs-Ausgangs-Matrix  $\mathbf{G}_k$  gegen die unbekannte Matrix  $\mathbf{G}_\infty$  konvergiert. Es bedeutet weiterhin, dass bei der Betrachtung von additiven Modellunsicherheiten

$$\lim_{k \rightarrow \infty} \Delta\mathbf{G}_{a,k} \rightarrow \mathbf{O} \quad (4.11)$$

und bei der Betrachtung von multiplikativen Modellunsicherheiten

$$\lim_{k \rightarrow \infty} \Delta\mathbf{G}_{m,k} \rightarrow \mathbf{I} \quad (4.12)$$

gilt. Dabei kennzeichnet  $\mathbf{O} \in \mathbb{R}^{N \times N}$  eine Nullmatrix und  $\mathbf{I} \in \mathbb{R}^{N \times N}$  eine Einheitsmatrix. Somit ist es möglich, die Regulierungsfaktoren nach jeder durchgeführten Iteration zu verringern und damit die Lernrate zu steigern.

#### 4.2.1. Variante I für Vorsteuerungen

Die Abb. 4.4 zeigt die Struktur der ILR-basierten Selbsteinstellung Variante I für eine bestehende Vorsteuerung. Als Anregung dient eine gegebene iterationsinvariante Sollwerttrajektorie. Aus der gegebenen Vorsteuerung und dem Startparametervektor  $\boldsymbol{\rho}_0$  lässt sich die Startstellgrößentrajektorie  $\mathbf{u}_{V,0}$  berechnen. Während der Durchführung des Startversuches tritt der Regelfehler  $\mathbf{e}_0 = \mathbf{y}_d - \mathbf{y}_0$  auf. Nach diesem Versuch ist die Vorsteuerung zu deaktivieren und der ILR-Betrieb beginnt. In diesem Betrieb erfolgt

die iterative Optimierung der Stellgrößentrajektorie  $\mathbf{u}_{k+1} = \mathbf{u}_{ILR,k+1}$  bis die optimale Stellgrößentrajektorie erreicht ist.

$$\mathbf{u}_{ILR,1} \rightarrow \mathbf{u}_{ILR,2} \rightarrow \cdots \rightarrow \mathbf{u}_{ILR,X} \hat{=} \mathbf{u}_{ILR,\infty}$$

Der Parameter  $X$  kennzeichnet die Anzahl der durchzuführenden Iterationen. Ist der gewünschte Sollwert realisierbar, ist davon auszugehen, dass

$$\mathbf{y}_\infty = \mathbf{y}_d \quad (4.13)$$

gilt. Die Parameteroptimierung hat die Aufgabe den Parametervektor  $\hat{\rho}$  so zu bestimm-

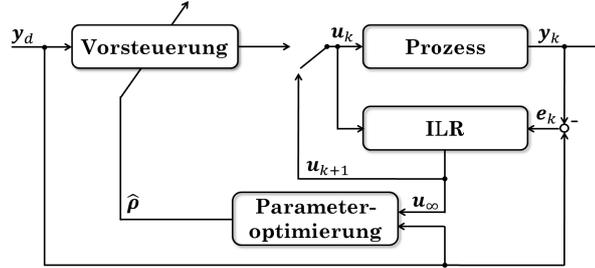


Abbildung 4.4. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante I für Vorsteuerungen

men, dass sich aus der Sollwerttrajektorie  $\mathbf{y}_d$  der Stellgrößenverlauf  $\mathbf{u}_{ILR,\infty}$  ergibt. Dies entspricht folgender Optimierungsaufgabe:

$$\hat{\rho} = \arg \min_{\hat{\rho}} (\|\mathbf{u}_{ILR,\infty} - \mathbf{u}_V(\hat{\rho})\|_2) \quad (4.14)$$

$$= \arg \min_{\hat{\rho}} (\|\mathbf{u}_{ILR,\infty} - \mathbf{C}_V(\hat{\rho})\mathbf{y}_d\|_2) \quad (4.15)$$

$$\hat{\rho} \in \mathbb{R}.$$

Die Matrix  $\mathbf{C}_V(\hat{\rho})$  entspricht der parameterabhängigen Eingangs-Ausgangs-Matrix der Vorsteuerung für die betrachtete Arbeitstrajektorie.

### Betrachtung der Güte der erreichten Parametrierung

Die vom ILR-Algorithmus bestimmte Stellgrößentrajektorie  $\mathbf{u}_{ILR,\infty}$  stellt die bestmögliche Stellgrößentrajektorie zur gewünschten Sollwerttrajektorie  $\mathbf{y}_d$  dar. Die Matrix  $\mathbf{C}_{ILR,V}$  ist damit die Eingangs-Ausgangs-Matrix der bestmöglichen Vorsteuerung.

$$\mathbf{u}_{ILR,\infty} = \mathbf{C}_{ILR,V}\mathbf{y}_d \quad (4.16)$$

Allerdings ist davon auszugehen, dass die Eingangs-Ausgangs-Matrix der zu parametrierenden Vorsteuerung  $\mathbf{C}_V(\hat{\rho})$  diese nicht exakt abbilden kann. Diese Abweichungen lassen sich als Modellunsicherheiten der Vorsteuerung interpretieren. Unter Berücksichtigung von additiven Modellunsicherheiten gilt somit

$$\mathbf{C}_V(\hat{\rho}) = \mathbf{C}_{ILR,V} - \Delta\mathbf{C}_a \quad (4.17)$$

bzw.

$$\mathbf{C}_V(\hat{\boldsymbol{\rho}}) = \Delta \mathbf{C}_m \mathbf{C}_{ILR,V} \quad (4.18)$$

für die Betrachtung von multiplikativen Modellunsicherheiten. Diese Unsicherheiten haben Auswirkungen auf die erreichbare Regelgüte. Es lässt sich folgender Zusammenhang zwischen der ILR-Stellgrößentrajektorie  $\mathbf{u}_{ILR,\infty}$  und der resultierenden Stellgrößentrajektorie  $\mathbf{u}_V(\hat{\boldsymbol{\rho}})$  der parameterabhängigen Vorsteuerung herleiten. Für die Beschreibung mittels additiven Modellunsicherheiten gilt

$$\begin{aligned} \mathbf{u}_V(\hat{\boldsymbol{\rho}}) &= \mathbf{C}_V(\hat{\boldsymbol{\rho}}) \mathbf{y}_d \\ &= (\mathbf{C}_{ILR,V} - \Delta \mathbf{C}_a) \mathbf{y}_d \\ &= \mathbf{u}_{ILR,\infty} - \Delta \mathbf{C}_a \mathbf{y}_d \\ &= \left( \mathbf{I} - \Delta \mathbf{C}_a \mathbf{y}_d (\mathbf{u}_{ILR,\infty}^T \mathbf{u}_{ILR,\infty})^{-1} \mathbf{u}_{ILR,\infty}^T \right) \mathbf{u}_{ILR,\infty} \\ &= \mathbf{F} \mathbf{u}_{ILR,\infty} \end{aligned} \quad (4.19)$$

und für die Beschreibung mittels multiplikativen Modellunsicherheiten gilt

$$\begin{aligned} \mathbf{u}_V(\hat{\boldsymbol{\rho}}) &= \mathbf{C}_V(\hat{\boldsymbol{\rho}}) \mathbf{y}_d \\ &= (\Delta \mathbf{C}_m \mathbf{C}_{ILR,V}) \mathbf{y}_d \\ &= \Delta \mathbf{C}_m \mathbf{u}_{ILR,\infty} \\ &= \mathbf{F} \mathbf{u}_{ILR,\infty}. \end{aligned} \quad (4.20)$$

Es zeigt sich, dass die Unsicherheiten der parameterabhängigen Vorsteuerung gegenüber der bestmöglichen Vorsteuerung als eine zusätzliche Filterung aufgefasst werden kann. Für die bleibende Regelabweichung ergibt sich damit

$$\begin{aligned} \mathbf{e}(\hat{\boldsymbol{\rho}}) &= \mathbf{y}_d - \mathbf{G}_\infty \mathbf{u}(\hat{\boldsymbol{\rho}}) = \mathbf{y}_d - \mathbf{G}_\infty \mathbf{F} \mathbf{u}_{ILR,\infty} \\ &= \mathbf{e}_{ILR,\infty} + \mathbf{y}_{ILR,\infty} - \mathbf{G}_\infty \mathbf{F} \mathbf{u}_{ILR,\infty} \end{aligned} \quad (4.21)$$

und weiter mit den Gleichungen 2.94 und 2.95

$$\mathbf{e}(\hat{\boldsymbol{\rho}}) = \left[ \mathbf{I} - \mathbf{G}_\infty \mathbf{F} (\mathbf{L} \mathbf{G}_\infty)^{-1} \right] \mathbf{y}_d. \quad (4.22)$$

Für die bleibende Regelabweichung ergibt sich damit bei Betrachtung der additiven Modellunsicherheiten  $\Delta \mathbf{C}_a$

$$\mathbf{e}(\hat{\boldsymbol{\rho}}) = \left[ \mathbf{I} - \mathbf{G}_\infty (\mathbf{L} \mathbf{G}_\infty)^{-1} \mathbf{L} - \Delta \mathbf{C}_a \right] \mathbf{y}_d \quad (4.23)$$

und bei Betrachtung der multiplikativen Modellunsicherheiten  $\Delta \mathbf{C}_m$

$$\mathbf{e}(\hat{\boldsymbol{\rho}}) = \left[ \mathbf{I} - \mathbf{G}_\infty \Delta \mathbf{C}_m (\mathbf{L} \mathbf{G}_\infty)^{-1} \mathbf{L} \right] \mathbf{y}_d. \quad (4.24)$$

Damit ist die entstehende Regelabweichung  $\mathbf{e}(\hat{\boldsymbol{\rho}})$  abweichend von der durch die ILR-Stellgrößentrajektorie bewirkten Regelabweichung  $\mathbf{e}_{ILR,\infty}$ . Streben  $\Delta \mathbf{C}_a \rightarrow \mathbf{O}$  bzw.  $\Delta \mathbf{C}_m \rightarrow \mathbf{I}$  entspricht die entstehende Regelabweichung der Regelabweichung des ILR-Algorithmus, d.h. die zu parametrierende Vorsteuerungsstruktur kann die ILR-Stellgrößentrajektorie exakt abbilden.

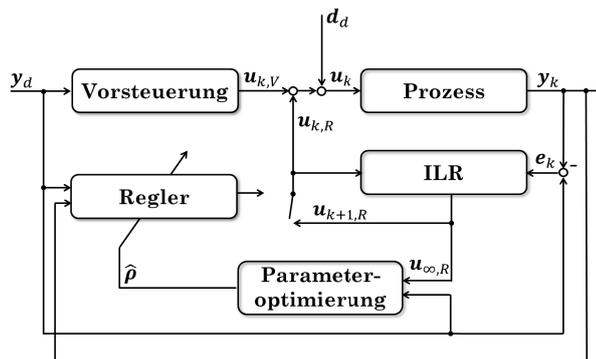


Abbildung 4.5. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante I für Regler

#### 4.2.2. Variante I für Regler

Die Abb. 4.5 zeigt die Struktur der ILR-basierten Selbsteinstellung Variante I für eine gegebene Reglerstruktur. Der Prozess ist durch die Vorsteuerung in den Arbeitspunkt zu bringen. Da der Regler hinsichtlich des Störverhaltens zu optimieren ist, muss die Prozessanregung durch eine Störung realisiert werden. Dabei kann es sich um aufgeprägte realistische Störungen auf der Stellgröße handeln oder um externe Störungen im Prozess. Diese Störung muss nicht messbar sein. Die einzige Voraussetzung ist eine iterationsinvariante Störung. Die Vorgabe für den Reglerentwurf beschreibt die Reaktion des Regelkreises auf die Störung und definiert die gewünschte Regelabweichung  $e_d$ . In der folgenden Betrachtung addiert sich die Störung  $d_d$ , wie in Abb. 4.5 dargestellt, auf die Stellgröße.

Aus dem Startparametervektor  $\rho_0$  resultiert die Stellgrößentrajektorie des Reglers  $\mathbf{u}_{R,0}$  mit dem Regelfehler  $\mathbf{e}_0 = \mathbf{y}_d - \mathbf{y}_0 \neq \mathbf{e}_d$ . Jetzt erfolgt die Umschaltung auf den ILR-Betrieb. Aus der gewünschten Regelabweichung  $\mathbf{e}_d$  ergibt sich der angepasste Sollwert des ILR-Betriebes dargestellt in Abb. 4.6 durch

$$\mathbf{y}_{ILR,d} = \mathbf{y}_d - \mathbf{e}_d \quad (4.25)$$

bzw. die im ILR-Algorithmus zu verwendende Regelabweichung

$$\mathbf{e}_{ILR,k} = \mathbf{y}_{ILR,d} - \mathbf{y}_k = \mathbf{e}_k - \mathbf{e}_d. \quad (4.26)$$

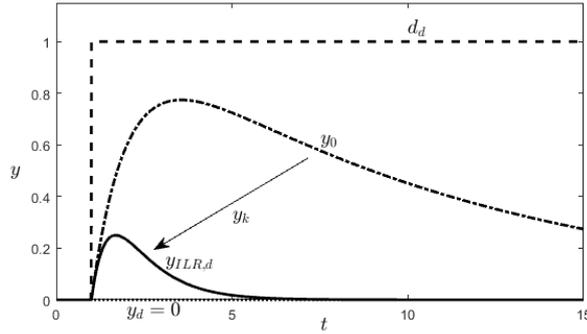
Im ILR-Betrieb ist der Regler deaktiviert und das ILR-Verfahren berechnet die optimale Stellgrößentrajektorie  $\mathbf{u}_{k+1,R} = \mathbf{u}_{ILR,k+1}$  und führt weitere Iterationen durch.

$$\mathbf{u}_{ILR,1} \rightarrow \mathbf{u}_{ILR,2} \rightarrow \cdots \rightarrow \mathbf{u}_{ILR,X} \hat{=} \mathbf{u}_{ILR,\infty}$$

Der Parameter  $X$  kennzeichnet die Anzahl der durchzuführenden Iterationen. Ist das gewünschte Verhalten realisierbar, ist davon auszugehen, dass

$$\mathbf{y}_{ILR,d} = \mathbf{y}_d - \mathbf{e}_d = \mathbf{y}_\infty \quad \text{bzw.} \quad \mathbf{e}_{ILR,\infty} = \mathbf{e}_d \quad (4.27)$$

gilt. Die Parameteroptimierung hat die Aufgabe, den Parametervektor  $\hat{\rho}$  so zu bestim-



**Abbildung 4.6.** Zuordnung der Signalverläufe (ILR-basierten Selbsteinstellungsverfahren für Regler)

men, dass der Regler aus dem gewünschten Störgrößenverhalten  $\mathbf{e}_d$  den Stellgrößenverlauf  $\mathbf{u}_{ILR,\infty}$  berechnet. Dies entspricht folgender Optimierungsaufgabe:

$$\hat{\boldsymbol{\rho}} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,\infty} - \mathbf{u}_R(\hat{\boldsymbol{\rho}})\|_2) \quad (4.28)$$

$$= \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,\infty} - \mathbf{C}_R(\hat{\boldsymbol{\rho}})\mathbf{e}_{ILR,\infty}\|_2) \quad (4.29)$$

$$= \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,\infty} - \mathbf{C}_R(\hat{\boldsymbol{\rho}})\mathbf{e}_d\|_2) \quad (4.30)$$

$$\hat{\boldsymbol{\rho}} \in \mathbb{R}.$$

Die Matrix  $\mathbf{C}_R(\hat{\boldsymbol{\rho}})$  entspricht der parameterabhängigen Eingangs-Ausgangs-Matrix des Reglers für die betrachtete Arbeitstrajektorie..

### Betrachtung der Güte der erreichten Parametrierung

Die vom ILR-Algorithmus bestimmte Stellgrößentrajektorie  $\mathbf{u}_{ILR,\infty}$  stellt die bestmögliche Stellgrößentrajektorie zum gewünschten Störverhalten  $\mathbf{e}_d$  dar. Die Matrix  $\mathbf{C}_{ILR,R}$  ist damit die Eingangs-Ausgangs-Matrix des bestmöglichen Reglers.

$$\mathbf{u}_{ILR,\infty} = \mathbf{C}_{ILR,R}\mathbf{e}_d \quad (4.31)$$

Allerdings ist davon auszugehen, dass die Eingangs-Ausgangs-Matrix des zu parametrierenden Reglers  $\mathbf{C}_R(\hat{\boldsymbol{\rho}})$  diese nicht exakt abbilden kann. Dies betrifft insbesondere lineare Regler, die ein nichtlineares Verhalten darstellen sollen. Diese Abweichungen lassen sich als Modellunsicherheiten des Reglers interpretieren. Unter Berücksichtigung von additiven Modellunsicherheiten gilt somit

$$\mathbf{C}_R(\hat{\boldsymbol{\rho}}) = \mathbf{C}_{ILR,R} - \Delta\mathbf{C}_a \quad (4.32)$$

bzw.

$$\mathbf{C}_R(\hat{\boldsymbol{\rho}}) = \Delta\mathbf{C}_m\mathbf{C}_{ILR,R} \quad (4.33)$$

für die Betrachtung von multiplikativen Modellunsicherheiten. Auch in diesem Fall lassen sich diese Unsicherheiten des parameterabhängigen Reglers wie bei der Vorsteuerung laut Gleichung 4.19 und 4.20 als eine zusätzliche Filterung auffassen.

Für die Beschreibung mittels additiven Modellunsicherheiten ergibt sich

$$\begin{aligned}
 \mathbf{u}_R(\hat{\boldsymbol{\rho}}) &= \mathbf{C}_R(\hat{\boldsymbol{\rho}})\mathbf{e}_d \\
 &= (\mathbf{C}_{ILR,R} - \Delta\mathbf{C}_a)\mathbf{e}_d \\
 &= \mathbf{u}_{ILR,\infty} - \Delta\mathbf{C}_a\mathbf{e}_d \\
 &= \left(\mathbf{I} - \Delta\mathbf{C}_a\mathbf{e}_d(\mathbf{u}_{ILR,\infty}^T\mathbf{u}_{ILR,\infty})^{-1}\mathbf{u}_{ILR,\infty}^T\right)\mathbf{u}_{ILR,\infty} \\
 &= \mathbf{F}\mathbf{u}_{ILR,\infty}
 \end{aligned} \tag{4.34}$$

und für die Beschreibung mittels multiplikativen Modellunsicherheiten gilt

$$\begin{aligned}
 \mathbf{u}_R(\hat{\boldsymbol{\rho}}) &= \mathbf{C}_R(\hat{\boldsymbol{\rho}})\mathbf{e}_d \\
 &= (\Delta\mathbf{C}_m\mathbf{C}_{ILR,R})\mathbf{e}_d \\
 &= \Delta\mathbf{C}_m\mathbf{u}_{ILR,\infty} \\
 &= \mathbf{F}\mathbf{u}_{ILR,\infty}.
 \end{aligned} \tag{4.35}$$

Für die bleibende Regelabweichung ergibt sich

$$\begin{aligned}
 \mathbf{e}(\hat{\boldsymbol{\rho}}) &= \mathbf{y}_d - \mathbf{G}_\infty(\mathbf{u}(\hat{\boldsymbol{\rho}}) + \mathbf{d}_d) \\
 &= \mathbf{e}_{ILR,\infty} + \mathbf{y}_\infty - \mathbf{G}_\infty(\mathbf{F}\mathbf{u}_{ILR,\infty} + \mathbf{d}_d) \\
 &= \mathbf{e}_d + \mathbf{G}_\infty(\mathbf{I} - \mathbf{F})\mathbf{u}_{ILR,\infty}.
 \end{aligned} \tag{4.36}$$

Das Einsetzen von  $\mathbf{F}$  führt zu

$$\mathbf{e}(\hat{\boldsymbol{\rho}}) = (\mathbf{I} + \Delta\mathbf{C}_a)\mathbf{e}_d \tag{4.37}$$

für die Betrachtung als additive Modellunsicherheit und

$$\mathbf{e}(\hat{\boldsymbol{\rho}}) = \mathbf{e}_d + \mathbf{G}_\infty(\mathbf{I} - \Delta\mathbf{C}_m)\mathbf{u}_{ILR,\infty} \tag{4.38}$$

für die Betrachtung als multiplikative Modellunsicherheit. Damit ist die entstehende Regelabweichung  $\mathbf{e}(\hat{\boldsymbol{\rho}})$  des parametrisierten Reglers abweichend von der durch die ILR-Stellgrößentrajektorie bewirkten Regelabweichung  $\mathbf{e}_{ILR,\infty} = \mathbf{e}_d$ .

### 4.3. Zweite Erweiterung zum ILR-basierten Selbsteinstellungsverfahren - Variante II

Die Variante I der Modifikation der ILR-Verfahren ermöglicht die Optimierung von Parametern bei wiederholbaren Iterationen. Allerdings ist dieses Vorgehen für viele Prozesse nicht durchführbar. Beispielsweise unterscheiden sich Fahrversuche auf der Straße durch einen variierenden Startpunkt, ein abweichendes Straßenprofile oder eine unterschiedliche Versuchsdauer.

Weiterhin ist eine Deaktivierung der Reglerstruktur und das Aufprägen einer Stellgrößentrajektorie nicht bzw. nur unter sehr hohem Vorbereitungsaufwand realisierbar. Dies erfordert eine zweite Erweiterung, im Folgenden Variante II genannt. Die Abb. 4.7 zeigt den geänderten Ablauf des Parameterschätzverfahrens.

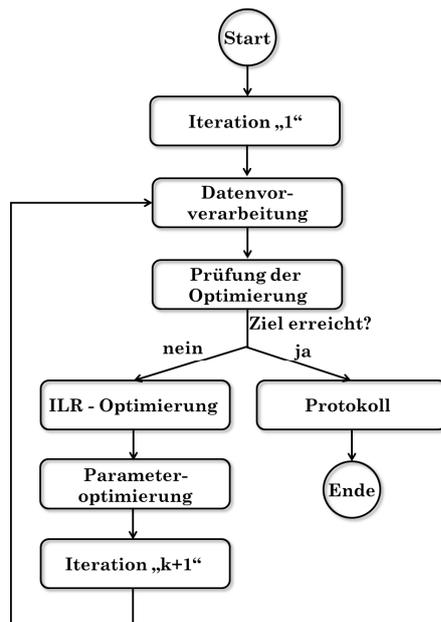


Abbildung 4.7. Ablauf des ILR-basierten Selbsteinstellungsverfahrens: Variante II

Im Gegensatz zur Variante I erfolgt in Variante II die Optimierung der Parameter in jedem Optimierungsschritt und der Stellgrößenverlauf der nächsten Iteration wird durch die aktualisierten Parameter berechnet. Dadurch müssen keine reproduzierbaren Versuche durchgeführt werden. Fehler oder Abweichungen durch die Optimierung der Parameter sind nun in jeder Iteration durch die ILR-Optimierung zu berücksichtigen. Der Ablauf ist folgendermaßen:

**Start:** Der Ausgangspunkt ist der Startversuch (Iteration 1) beginnend mit der Start-Stellgrößentrajektorie  $\mathbf{u}_0 = \mathbf{u}(\boldsymbol{\rho}_0)$ .

**Datenvorverarbeitung:** Danach erfolgt die Datenvorverarbeitung aus Variante I. Es ist die Gültigkeit der Messung zu prüfen, der Arbeitsbereich zu ermitteln und die Eingangs-Ausgangs-Matrix  $\mathbf{G}$  zu berechnen.

**Prüfung der Optimierungsbedingung:** Dieser Schritt prüft, ob die durch den optimierten Parametervektor berechnete Stellgrößentrajektorie den Prozess so angeregt hat, dass die geforderte Regelgüte erreicht ist oder keine weiteren Verbesserungen mehr auftreten. Ist dies der Fall, erfolgt der Abbruch der Optimierungsschleife.

**ILR-Optimierung:** Durch das ausgewählte ILR-Verfahren ist der optimierte Stellgrößenverlauf unter Berücksichtigung von Stellgrenzen zu berechnen.

**Optimierung der Parameter:** Die Optimierung ist in der Variante II in jeder Iteration durchzuführen. Dazu ist durch das Lösen des Optimierungsproblems

$$\hat{\boldsymbol{\rho}}_{k+1} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,k} - \mathbf{u}(\hat{\boldsymbol{\rho}})\|_2), \quad \hat{\boldsymbol{\rho}}_{k+1} \in \mathbb{R}, \quad (4.39)$$

derjenige Parametervektor  $\hat{\boldsymbol{\rho}}_{k+1}$  zu finden, der den ILR-optimierten Stellgrößenverlauf für die nächste Iteration  $k + 1$  bestmöglich abbildet.

**Iteration „k+1“:** Nach der Speicherung der ermittelten Parameter im Steuergerät ist der nächste Versuch (Iteration) freigegeben und kann ausgeführt werden.

**Protokoll:** Die Protokollfunktion fasst die erreichten Ergebnisse zusammen und sichert die ermittelten Parameter.

### Anwendungsvoraussetzung

Führungsgrößenverläufe oder Störanregungen müssen in Variante II nicht mehr konstant bzw. iterationsinvariant sein, da die neuen Stellgrößenverläufe durch die gegebenen Steuerungs- und Regelungsstrukturen bestimmt sind. Allerdings müssen die Anregungen messbar sein, um das gewünschte Verhalten des Regelkreises auf diese Anregung darstellen zu können. Weiterhin kommen nur ILR-Verfahren 1. Ordnung in Betracht, da Vorgänge der Iterationen  $k - 1$  und älter nicht verfügbar bzw. nicht verwendbar sind.

### Betrachtung der Konvergenz

Der Nachweis der Konvergenz erfolgt analog der Betrachtung von Variante I im Abschnitt 4.2. Allerdings ist in diesem Fall der Abbildungsfehler der Eingangs-Ausgangs-Matrix der gegebenen Regelstruktur  $C(\hat{\rho})$  gegenüber der Eingangs-Ausgangs-Matrix der bestmöglichen ILR-Regelstruktur  $C_{ILR}$  zusätzlich zu berücksichtigen. Wie in 4.2.1 und 4.2.2 gezeigt, können diese Abbildungsfehler als additive oder multiplikative Modellunsicherheiten betrachtet werden und bewirken eine zusätzliche Filterung der Stellgrößen-trajektorie der nächsten Iteration  $\mathbf{u}_{k+1}(\hat{\rho})$ . Unter der Berücksichtigung der additiven Modellunsicherheiten  $\Delta C_a$  ergibt sich analog 4.19 die Gleichung

$$\begin{aligned} \mathbf{u}_{k+1}(\hat{\rho}) &= \left( \mathbf{I} - \Delta C_a \mathbf{y}_d (\mathbf{u}_{ILR,k+1}^T \mathbf{u}_{ILR,k+1})^{-1} \mathbf{u}_{ILR,k+1}^T \right) \mathbf{u}_{ILR,k+1} \\ &= \mathbf{F} \mathbf{u}_{ILR,k+1}. \end{aligned} \quad (4.40)$$

Die Betrachtung von multiplikativen Modellunsicherheiten  $\Delta C_m$  ergibt analog 4.20 die Gleichung

$$\begin{aligned} \mathbf{u}_{k+1}(\hat{\rho}) &= \Delta C_m \mathbf{u}_{ILR,k+1} \\ &= \mathbf{F} \mathbf{u}_{ILR,k+1}. \end{aligned} \quad (4.41)$$

Dies ist gleichzusetzen mit dem Einsatz eines Q-Filters und muss beim Entwurf der Lernmatrix  $\mathbf{L}$  berücksichtigt werden. Das ILR-Gesetz ist daher durch

$$\mathbf{u}_{k+1}(\hat{\rho}) = \mathbf{u}_{k+1} = \mathbf{F}(\mathbf{u}_k + \mathbf{L} \mathbf{e}_k) \quad (4.42)$$

gegeben. Bei gewährleiteteter Konvergenz des Verfahrens repräsentiert der ermittelte Parametervektor  $\hat{\rho}$  das Ergebnis einer ILR mit Q-Filter und  $k \rightarrow \infty$ .

Die verwendeten ILR-Verfahren sind wie in Variante I die inversionsbasierten ILR-Ansätze von Gleichung 2.125 und Gleichung 2.137 mit der Lernmatrix

A) des Ansatzes der Pseudoinversen  $\mathbf{L} = (\mathbf{G}_k^T \mathbf{G}_k + \eta_1 \mathbf{I})^{-1} \mathbf{G}_k^T$  und

B) des gradientenbasierten Ansatzes  $\mathbf{L} = \frac{\|\mathbf{G}_k^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_k^T \mathbf{G}_k^T \mathbf{e}_k\|_2^2} \mathbf{G}_k^T$ .

Damit die Konvergenz der ILR-Entwurfsgleichung erfüllt ist, muss die Bedingung

$$\|e_{k+1}\|_2 < \|e_k\|_2 \quad (4.43)$$

gelten. Unter der Berücksichtigung von additiven Modellunsicherheiten ( $\mathbf{G}_{k+1} = \mathbf{G}_k + \Delta\mathbf{G}_a$ ) ergibt sich aus der Regelabweichung der nächsten Iteration  $\|e_{k+1}\|_2 = \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2$  die Gleichung

$$\begin{aligned} \|e_{k+1}\|_2 - \|e_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|e_k\|_2 \\ &= \|\mathbf{y}_d - (\mathbf{G}_k + \Delta\mathbf{G}_a) \mathbf{F}(\mathbf{u}_k + \mathbf{L}e_k)\|_2 - \|e_k\|_2 \\ &= \|e_k + (\mathbf{G}_k(\mathbf{I} - \mathbf{F}) - \Delta\mathbf{G}_a\mathbf{F})\mathbf{u}_k - (\mathbf{G}_k + \Delta\mathbf{G}_a)\mathbf{F}\mathbf{L}e_k\|_2 - \|e_k\|_2 \\ &< 0, \end{aligned} \quad (4.44)$$

die kleiner null sein muss. Für multiplikative Modellunsicherheiten ( $\mathbf{G}_{k+1} = \mathbf{G}_k\Delta\mathbf{G}_m$ ) gilt

$$\begin{aligned} \|e_{k+1}\|_2 - \|e_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|e_k\|_2 \\ &= \|\mathbf{y}_d - \mathbf{G}_k\Delta\mathbf{G}_m\mathbf{F}(\mathbf{u}_k + \mathbf{L}e_k)\|_2 - \|e_k\|_2 \\ &= \|e_k + \mathbf{G}_k(\mathbf{I} - \Delta\mathbf{G}_m\mathbf{F})\mathbf{u}_k - \mathbf{G}_k\Delta\mathbf{G}_m\mathbf{F}\mathbf{L}e_k\|_2 - \|e_k\|_2 < 0. \end{aligned} \quad (4.45)$$

Der Regularisierungsfaktor  $\eta_1$  bzw.  $w$  ist nun so zu bestimmen, dass die entsprechende Ungleichung erfüllt ist. Dies erfordert eine Abschätzung der Modellunsicherheit für den jeweiligen betrachteten Prozess (siehe Kapitel 5, Gleichung 5.15, 5.22 bzw. 5.51) und ist bei der Anwendung des Verfahrens prozessabhängig zu bestimmen.

#### 4.3.1. Variante II für Vorsteuerungen

Die Abb. 4.8 zeigt die Struktur der ILR-basierten Selbsteinstellung Variante II für eine bestehende Vorsteuerung. Die Anregung ist eine gewünschte Sollwerttrajektorie, die allerdings auf Grund von abweichenden Versuchsbedingungen iterationsvariant sein kann.

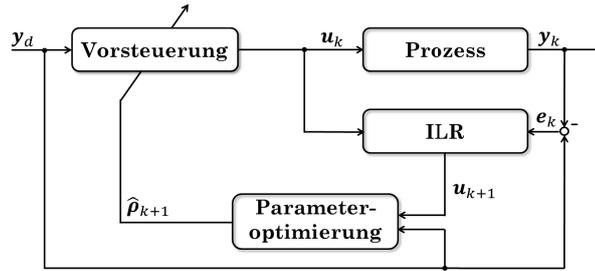


Abbildung 4.8. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante II für Vorsteuerungen

Aus der gegebenen Vorsteuerung und dem Startparametervektor  $\boldsymbol{\rho}_0$  ergibt sich die Startstellgrößentrajektorie  $\mathbf{u}_{V,0}$  und damit der Regelfehler  $\mathbf{e}_0 = \mathbf{y}_{d,0} - \mathbf{y}_0$ . Daraus berechnet der ILR-Algorithmus die optimierte Stellgrößentrajektorie  $\mathbf{u}_{ILR,k+1}$ . Diese Stellgrößentrajektorie wird nur zu Optimierungszwecken ermittelt und nicht dem Prozess

aufgeprägt. In der Optimierungsphase lässt sich der neue Parametervektor  $\hat{\boldsymbol{\rho}}_{k+1}$  durch das Lösen der Optimierungsaufgabe

$$\hat{\boldsymbol{\rho}}_{k+1} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,k+1} - \mathbf{u}_V(\hat{\boldsymbol{\rho}})\|_2) \quad (4.46)$$

$$= \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,k+1} - \mathbf{C}_V(\hat{\boldsymbol{\rho}})\mathbf{y}_{d,k}\|_2) \quad (4.47)$$

$$\hat{\boldsymbol{\rho}}_{k+1} \in \mathbb{R}$$

bestimmen. Die Matrix  $\mathbf{C}_V(\hat{\boldsymbol{\rho}})$  entspricht der parameterabhängigen Eingangs-Ausgangs-Matrix der Vorsteuerung für die betrachtete Arbeitstrajektorie. Der ermittelte Parametervektor wird der Vorsteuerung übergeben und die nächste Iteration kann beginnen. Aus der Sollwerttrajektorie  $\mathbf{y}_{d,k+1}$  ergibt sich durch den Parametervektor  $\hat{\boldsymbol{\rho}}_{k+1}$  die Stellgrößentrajektorie  $\mathbf{u}_{V,k+1}$  und damit der Regelfehler  $\mathbf{e}_{k+1} = \mathbf{y}_{d,k+1} - \mathbf{y}_{k+1}$ . Mit diesen Daten erfolgt die Durchführung des nächsten Optimierungsschrittes.

### Betrachtung der Güte der erreichten Parametrierung

Aus dem Stellgesetz der Variante II mit der Berücksichtigung des Filters  $\mathbf{F}$  (Gleichung 4.42) und der Regelabweichung  $\mathbf{e}_k(\hat{\boldsymbol{\rho}}) = \mathbf{y}_{d,k} - \mathbf{G}_k\mathbf{u}_{V,k}(\hat{\boldsymbol{\rho}})$  ergibt sich für  $k \rightarrow \infty$  die Gleichung der Stellgröße

$$\mathbf{u}_{V,\infty}(\hat{\boldsymbol{\rho}}) = \mathbf{u}_{ILR,\infty} = (\mathbf{I} - \mathbf{F} + \mathbf{FLG}_\infty)^{-1} \mathbf{FLy}_{d,\infty} \quad (4.48)$$

und für die Regelabweichung der Zusammenhang

$$\mathbf{e}_\infty(\hat{\boldsymbol{\rho}}) = \mathbf{e}_{ILR,\infty} = \left( \mathbf{I} - \mathbf{G}_\infty (\mathbf{I} - \mathbf{F} + \mathbf{FLG}_\infty)^{-1} \mathbf{FL} \right) \mathbf{y}_{d,\infty}. \quad (4.49)$$

Damit ist die entstehende Regelabweichung  $\mathbf{e}_\infty(\hat{\boldsymbol{\rho}})$  abweichend von dem Ergebnis der Variante I. Bei geringen Modellunsicherheiten, d.h. für  $\Delta\mathbf{C}_a \rightarrow \mathbf{O}$  bzw.  $\Delta\mathbf{C}_m \rightarrow \mathbf{I}$ , nähern sich beide Varianten an und die entstehende Regelabweichung entspricht dem Ergebnis einer optimierten ILR-Stellgrößentrajektorie.

### 4.3.2. Variante II für Regelungen

Die Abb. 4.9 zeigt die Struktur der ILR-basierten Selbsteinstellung Variante II für bestehende Regler. Der Prozess ist durch die Vorsteuerung in den Arbeitspunkt zu bringen. Die Anregung erfolgt durch eine messbare Störung des Prozesses respektive, da dies in vielen Fällen nicht möglich sein wird, durch die Vorgabe einer realistischen Störung am Stelleingang des Prozesses. Aus dieser Messung ergibt sich nach der Vorgabe des gewünschten Störverhaltens der gewünschte Regelfehler  $\mathbf{e}_{d,k}$ .

Resultierend aus dem Startparametervektor  $\boldsymbol{\rho}_0$  des Reglers ergibt sich die Stellgrößentrajektorie des Reglers  $\mathbf{u}_{R,0}$  und damit der Regelfehler  $\mathbf{e}_0 = \mathbf{y}_d - \mathbf{y}_0 \neq \mathbf{e}_{d,0}$ . Aus der gewünschten Regelabweichung  $\mathbf{e}_{d,k}$  ergibt sich der angepasste Sollwert des ILR-Algorithmus für die aktuelle Iteration mit

$$\mathbf{y}_{ILR,d,k} = \mathbf{y}_{d,k} - \mathbf{e}_{d,k} \quad (4.50)$$

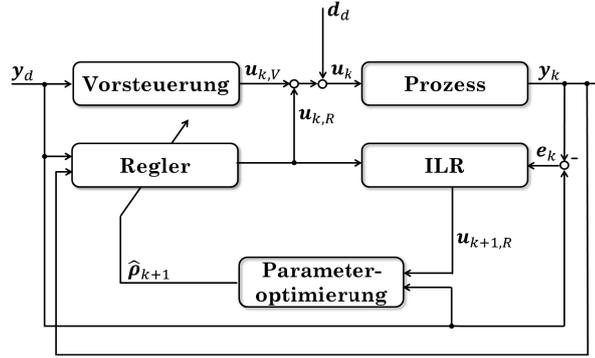


Abbildung 4.9. Struktur des ILR-basierten Selbsteinstellungsverfahrens: Variante II für Regler

bzw. die im ILR-Algorithmus zu verwendende Regelabweichung

$$e_{ILR,k} = \mathbf{y}_{ILR,d,k} - \mathbf{y}_k = \mathbf{e}_k - \mathbf{e}_{d,k}. \quad (4.51)$$

Der ILR-Algorithmus berechnet die optimierte Stellgrößentrajektorie  $\mathbf{u}_{ILR,k+1}$ . Dieser Vektor dient nur zur Parameteroptimierung und wird nicht dem Prozess aufgeprägt. Durch das Lösen des Optimierungsproblems

$$\hat{\boldsymbol{\rho}}_{k+1} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,k+1} - \mathbf{u}_{R,k+1}(\hat{\boldsymbol{\rho}})\|_2) \quad (4.52)$$

$$= \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,k+1} - \mathbf{C}_R(\hat{\boldsymbol{\rho}})\mathbf{e}_{d,k}\|_2) \quad (4.53)$$

$$\hat{\boldsymbol{\rho}}_{k+1} \in \mathbb{R}$$

ergibt sich der Parametervektor  $\hat{\boldsymbol{\rho}}_{k+1}$ . Die Matrix  $\mathbf{C}_R(\hat{\boldsymbol{\rho}})$  entspricht der parameterabhängigen Eingangs-Ausgangs-Matrix des Reglers für die betrachtete Arbeitstrajektorie. Das Ziel dabei ist, dass der parametrierte Regler aus dem gewünschten Störgrößenverhalten  $\mathbf{e}_{d,k}$  die optimierte Stellgrößentrajektorie  $\mathbf{u}_{ILR,k+1}$  berechnet. Der ermittelte Parametervektor wird dem Regler übergeben und die nächste Iteration  $k+1$  ist durchzuführen. Durch den Parametervektor  $\hat{\boldsymbol{\rho}}_{k+1}$  ergibt sich in der Iteration  $k+1$  die Reglerstellgröße  $\mathbf{u}_{R,k+1}$  und der Regelfehler  $\mathbf{e}_{k+1} = \mathbf{y}_{d,k+1} - \mathbf{y}_{k+1}$ . Mit der Vorgabe des gewünschten Störgrößenverhaltens und dem resultierenden gewünschten Regelfehler  $\mathbf{e}_{d,k+1}$  kann der nächste Optimierungsschritt berechnet werden.

### Betrachtung der Güte der erreichten Parametrierung

Aus dem ILR-Stellgesetz in Gleichung 4.42 und dem angepassten Sollwertvektor zur Vorgabe des Störverhaltens  $\mathbf{e}_d$  in Gleichung 4.50 ergibt sich für  $k \rightarrow \infty$  der Verlauf der Stellgröße durch

$$\mathbf{u}_\infty(\hat{\boldsymbol{\rho}}) = \mathbf{u}_{ILR,\infty} = (\mathbf{I} - \mathbf{F} + \mathbf{F}\mathbf{L}\mathbf{G}_\infty)^{-1} \mathbf{F}\mathbf{L}(\mathbf{y}_{d,\infty} - \mathbf{e}_{d,\infty} - \mathbf{G}_\infty \mathbf{d}_{d,\infty}) \quad (4.54)$$

und der Verlauf der Regelabweichung durch

$$\mathbf{e}_\infty(\hat{\boldsymbol{\rho}}) = \mathbf{e}_{ILR,\infty} = \left( \mathbf{I} - \mathbf{G}_\infty (\mathbf{I} - \mathbf{F} + \mathbf{F}\mathbf{L}\mathbf{G}_\infty)^{-1} \mathbf{F}\mathbf{L} \right) (\mathbf{y}_{d,\infty} - \mathbf{e}_{d,\infty} - \mathbf{G}_\infty \mathbf{d}_{d,\infty}). \quad (4.55)$$

## 4.4. Vergleich der Variante I und der Variante II

Worin unterscheiden sich die beiden Varianten und wie wirken sich diese Unterschiede aus? Die Tabelle 4.2 zeigt einen Überblick der Unterschiede. Im Wesentlichen ist zu

Vergleich	Variante I	Variante II
Anregung	iterationsinvariant	iterationsvariant, messbar
Startbedingungen	iterationsinvariant	iterationsvariant
Versuchsort	Prüfstände, keine abweichenden Umgebungsbedingungen	normale Betriebsmessungen (z.B. Straßenmessungen) verwendbar
Anzahl der Parameteroptimierungen	1 mal	gleich der Iterationsanzahl

**Tabelle 4.2.** Vergleich der Verfahren

erkennen, dass die Variante II universeller einsetzbar ist und vor allem unter praktischen Gesichtspunkten zur Versuchsdurchführung Vorteile liefert. Durch die Unabhängigkeit von gleichen Startparametern und von der Durchführung gleicher Iterationen ist dieser Ansatz einfacher zu realisieren. Zusätzlich setzt die Variante I voraus, dass die Steuerung bzw. Regelung im Steuergerät nach der Startiteration deaktiviert und durch die Vorgabe der neuen Stellgrößentrajektorie  $\mathbf{u}_{k+1}$  ersetzt werden kann.

Die Variante I liefert als Zwischenergebnis die bestmögliche ILR-Stellgrößentrajektorie. Erst danach beginnt die Bestimmung des Parametervektors der gegebenen Vorsteuerung bzw. des gegebenen Reglers. Sind nicht alle Zusammenhänge des Prozesses in der Regelungsstruktur berücksichtigt, kommt es zu Abweichungen zwischen ILR-Ergebnis und der parameterabhängigen Stellgrößentrajektorie der Regelstruktur. Dies hat weiterhin zur Folge, dass mehr Iterationen durchgeführt werden als notwendig sind. Die Variante II berücksichtigt die gegebene Regelungsstruktur als zusätzlichen Q-Filter in jeder Iteration. Dadurch entspricht das ILR-Ergebnis der parameterabhängigen Stellgrößentrajektorie und zusätzliche Iterationen werden vermieden. Allerdings ist damit zu rechnen, dass sich die Anzahl der durchzuführenden Iterationen erhöht, da bei unterschiedlichen Verläufen der einzelnen Iterationen nicht gewährleistet ist, dass der gesamte Arbeitsbereich erreicht wird.

Weiterhin zeigt der Vergleich der erreichten Regelabweichung des ermittelten Parametervektors der Gleichungen 4.22 und 4.49 (Vorsteuerung) und der Gleichungen 4.36 und 4.55 (Regler) unterschiedliche Ergebnisse der beiden Varianten. Der Einsatz eines zusätzlichen Q-Filters in jeder Iteration bei Variante II führt zu einer geänderten Regelabweichung.

## 4.5. Optimierung der Parameter

Die Optimierung der gesuchten Parameter erfolgt durch das Lösen der in den vorherigen Abschnitten beschriebenen Optimierungsprobleme. Die Literatur liefert zum Thema Optimierung viele Verfahren und Algorithmen, die unterschiedliche Anforderungen erfüllen. Solche Ansätze unterscheiden sich z.B. in lineare und nichtlineare Optimierungsprobleme. Es können Nebenbedingungen formuliert sein und Begrenzungen für die Parameter vorliegen, die die zulässige Lösungsmenge einschränken.

Zu den Standardverfahren der Optimierungstheorie gehören die Methode der kleinsten Fehlerquadrate und das Downhill-Simplex-Verfahren nach Nelder und Mead. Für beide Verfahren existieren Standardalgorithmen in vielen Softwarelösungen. Beide Verfahren kommen je nach Anwendungsbereich innerhalb dieser Arbeit zum Einsatz. Die Methode der kleinsten Fehlerquadrate gehört zu den Lösungsverfahren für lineare Optimierungsprobleme. Für die vorgegebenen Datenpunkte (Verlauf) der Zielgröße werden die linearen Parameter einer Funktion so berechnet, dass die Summe der quadratischen Fehler zwischen den Datenpunkten und dem Funktionsverlauf minimiert wird.

Mit dem Downhill-Simplex-Verfahren nach Nelder und Mead [Nelder and Mead, 1965, Papageorgiou, 2012, Kiranyaz et al., 2014] ist es möglich, nichtlineare Funktionen zu optimieren. Als Gütekriterium ist dafür ein Minimierungsproblem zu formulieren. Dieses Verfahren ist ein heuristischer und iterativer Algorithmus. Es kommt ohne die Bestimmung des Gradienten der zu optimierenden Funktion nach den gesuchten Parametern aus. Den Ausgangspunkt stellt die Startparametrierung  $\boldsymbol{\rho}_0$  dar. Der Parametervektor besteht aus  $m$  Elementen ( $\boldsymbol{\rho} = [\rho_1 \cdots \rho_m]^T$ ). Im ersten von drei Schritten sind weitere  $m$  Startparametervektoren durch die Änderung eines der Elemente  $\rho_i$  zu bestimmen. Dieser Satz an  $m + 1$  Parametervektoren stellt den sogenannten Simplex dar. Aus diesen Vektoren erfolgt die Berechnung des Gütekriteriums und die Feststellung des schlechtesten Ergebnisses im zweiten Schritt. Im dritten Schritt wird der ungünstigste Parametervektor  $\boldsymbol{\rho}_u$  gezielt verändert und der neue Wert des Gütekriteriums ermittelt. Bis zum Erreichen der Abbruchbedingung erfolgt die Wiederholung des dritten Schrittes.

# Kapitel 5.

## Einsatz der entwickelten Verfahren am Prozess der Ladedruckregelung

Die durchgeführten Erweiterungen der ILR-Methodik sind zur Selbsteinstellung der bestehenden Vorsteuerung und des bestehenden Reglers der Ladedruckregelung eines einfach aufgeladenen Ottomotors mit pneumatischem Wastegate aus 3.3 anzuwenden und sowohl simulativ als auch praktisch zu testen. Vor dem praktischen Einsatz am Fahrzeug erfolgt die Umsetzung und der Test des Verfahrens an der Drehzahlregelung eines Labor-motorprüfstandes mit bürstenlosen Gleichstrommotoren (Brushless DC Motor (BLDC)). Um eine Anwendung des ILR-basierten Selbsteinstellungsverfahrens zu ermöglichen, sind die Prozesseigenschaften zu ermitteln, die Anregungen des Prozesses zu definieren und die Entwurfsziele festzulegen. Dementsprechend kann die Auswahl des ILR-Verfahrens erfolgen und die Anwendung zur Parameteroptimierung beginnen.

### 5.1. Beschreibung der Testobjekte

Vor dem praktischen Test sind ausführliche Simulationsstudien zur Eignung des Verfahrens durchzuführen. Dazu sind im folgenden die Initialisierungsparameter, sowie die Eingangs- und Ausgangsgrößen des Simulationsmodells des aufgeladenen Ottomotors und des BLDC-Motorprüfstandes aufgeführt.

#### 5.1.1. Aufgeladener Ottomotor

Das in dieser Arbeit verwendete Simulationsmodell ist in Zusammenarbeit mit der IAV GmbH entstanden. Es erweitert das in [Beckmann, 2014] entwickelte Simulationsmodell des Luft- und Abgaspfades eines aufgeladenen Ottomotors um die Struktur der Ladedruckregelung aktueller Steuergeräte und einem Fahrzeugmodell, das die Dynamik des PKWs beschreibt, um notwendige Größen wie z.B. Fahrwiderstand und Fahrgeschwindigkeit bzw. Motordrehzahl zu berechnen.

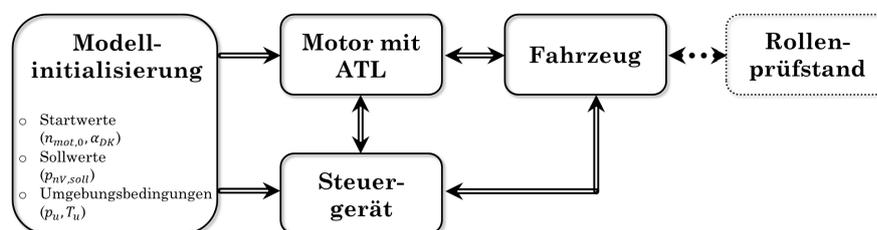


Abbildung 5.1. Struktur des Simulationsmodells

Dieses Modell dient dazu, Simulationen im aufgeladenen Bereich des modellierten Ottomotors bei Standardumgebungsbedingungen durchzuführen. Bei einer Vollastfahrt, die einem Beschleunigungsvorgang, ausgelöst durch das Durchtreten des Gaspedals, entspricht, wird die Drosselklappe komplett geöffnet und die Ladedruckregelung aktiviert. Solche Applikationsfahrten dienen auch zur Applikation der Korrekturkennfelder. Mit Hilfe des Modells lassen sich sowohl Straßenfahrten als auch Messungen auf einem Rollenprüfstand für Fahrzeuge (bei konstanten Drehzahlarbeitspunkten) simulieren. Die für die Modellinitialisierung zur Verfügung stehenden Größen sind in Tabelle 5.1 aufgelistet. Weiterhin sind die relevanten Messgrößen in Tabelle 5.2 dargestellt.

Formelzeichen	Wertebereich	Beschreibung
$n_{mot,0}$	1000 – 6000 $\frac{U}{min}$	Startmotordrehzahl der Simulation
$p_{nV,d}$	1400 – 1900 <i>mbar</i>	Solladedruck
$T_u$	293, 15 <i>K</i>	Umgebungstemperatur
$p_u$	1000 <i>mbar</i>	Umgebungsluftdruck
$\alpha_{DK,0}$	0 – 100%	Winkel der Drosselklappe
$B_{Ro}$	[0, 1]	Bit zur Auswahl Straße [0] oder Rollenprüfstand [1]

**Tabelle 5.1.** Parameter zur Initialisierung des Simulationsmodells

Formelzeichen	Beschreibung
$TV_{WG} = u$	Tastverhältnis Wastegate, Stellgröße, [%TV]
$p_{nV,d} = y_d$	Solladedruck, Sollgröße, [mbar]
$p_{nV} = y$	Ladedruck, Regelgröße, [mbar]
$e = y_d - y$	Regelabweichung, [mbar]
$\alpha_{DK,0}$	Winkel der Drosselklappe, [%]
$n_{mot}$	Motordrehzahl, [ $\frac{U}{min}$ ]
$v_{fzg}$	Fahrzeuggeschwindigkeit, [ $\frac{km}{h}$ ]
$r_L$	Luftfüllung, [%]
$\rho_x$	Arbeitspunkt des stationären Korrekturkennfeldes (normiert), [-]
$B_{LDR}$	Bit Freigabe Ladedruckregelung [-]

**Tabelle 5.2.** Stell-, Regel- und Messgrößen des Simulationsmodells des aufgeladenen Ottomotors

Aus der dargestellten Systembeschreibung in 3.2 ergeben sich bestimmte Eigenschaften des Prozesses, die bei weiteren Betrachtungen und der Anwendung des Selbststellungsverfahrens zu berücksichtigen sind. Dieses System ist nichtlinear, eingangsaffin, nichtminimalphasig und weist sowohl eine begrenzte Stellgröße als auch eine begrenzte Regelgröße auf.

### 5.1.2. BLDC-Motorprüfstand

Der verwendete Motorprüfstand ist Bestandteil der Laborausstattung der Universität Rostock im Institut für Automatisierungstechnik der Fakultät für Informatik und Elektrotechnik. Dieser Prüfstand und das hier verwendete Simulationsmodell sind im Rahmen der Masterarbeit [Schöley, 2014] entstanden. Der Prüfmotor M1 und der Lastmotor M2 sind durch eine Drehmomentenmesswelle miteinander verbunden. Die Verarbeitung der Messdaten, die Regelung des Prüfstandes und die Ansteuerung der Leistungselektronik erfolgt durch ein xPC-Target-System. Die zur Verfügung stehenden Größen sind in Tabelle 5.3 aufgeführt.

Formelzeichen	Beschreibung
$U_{I1}$	Steuerspannung Motor 1, Stellgröße, [V]
$U_{I2}$	Steuerspannung Motor 2, Stellgröße, [V]
$n_1$	Drehzahl Motor 1, $[\frac{U}{\text{min}}]$
$n_2$	Drehzahl Motor 2, $[\frac{U}{\text{min}}]$
$n_W$	Drehzahl Drehmomentenmesswelle, $[\frac{U}{\text{min}}]$
$M_W$	Drehmoment Drehmomentenmesswelle, [Nm]

**Tabelle 5.3.** Stell-, Regel- und Messgrößen des BLDC-Motorprüfstandes

Die Regelungsstruktur am BLDC-Motorprüfstand besteht ebenfalls aus einer Vorsteuerung und einem PI-Regler. Für das Führungsverhalten ist die in [Schöley, 2014] entwickelte Vorsteuerung verantwortlich. Der zu optimierende PI-Regler soll auftretende Störeinflüsse reduzieren. Der betrachtete Regelkreis ist die Drehzahlregelung des Motors 1. Das in [Schöley, 2014] erstellte Simulationsmodell wird als unbekanntes Streckenmodell übernommen und hat folgende bekannte Eigenschaften. Bei diesem Prozess handelt es sich um eine lineare Strecke mit Totzeit ohne Ausgleich. Das System ist eingangsaffin, hat eine begrenzte Stellgröße und eine begrenzte Regelgröße.

Bei dem verwendeten Regler handelt es sich um einen PI-Regler mit der Übertragungsfunktion

$$G_R(s) = K_P + \frac{K_I}{s}. \quad (5.1)$$

Der Regler ist als Störregler auszulegen und dafür sind die Reglerparameter  $K_P$  und  $K_I$  zu bestimmen. Die Regelung soll schnell auf plötzliche Laständerungen bzw. Störungen reagieren. Als Prozessanregung zum Anlernen des PI-Reglers lassen sich somit schnelle Änderungen in der Stellgröße als Störanregung verwenden.

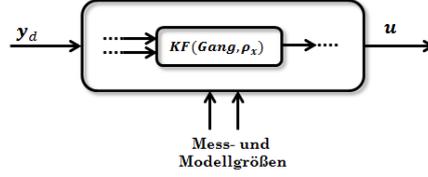
## 5.2. Anwendung des ILR-basierten Selbsteinstellungsverfahrens - Variante I

Das Verfahren Variante I der ILR-basierten Selbsteinstellung setzt gleiche und wiederholbare Iterationen voraus. Im Automobilbereich lässt sich das durch Versuche und Messfahrten auf Motorprüfständen und Rollenprüfständen realisieren. Die Voraussetzung der Verwendung einer ILR-Stellgrößentrajektorie während der durchgeführten Iteration ist der Einsatz eines Bypasses. Damit ist es möglich, den zu parametrierenden Teil der Regelstruktur im Steuergerät zu deaktivieren und durch die ILR-Stellgrößentrajektorie des Applikationsrechners zu ersetzen. Als ILR-Algorithmus kommen inversionsbasierte Verfahren zum Einsatz. Vor der Anwendung des Verfahrens ist daher eine Abschätzung der Modellunsicherheit der Eingangs-Ausgangs-Matrix  $\mathbf{G}_k$  notwendig. Nur so kann die monotone Konvergenz des Verfahrens gewährleistet werden.

### 5.2.1. Anwendung für die stationäre Vorsteuerung der LDR

Das zu applizierende Kennfeld ist Teil der modellbasierten Vorsteuerung. Da eine der Eingangsgrößen der eingelegte Gang ist, reduzieren sich bei der Einstellung eines konstanten Ganges die zur Verfügung stehenden Parameter auf eine Kennlinie. Diese Kenn-

linie ist nur noch von der modellierten und normierten Eingangsgröße  $\rho_x$  abhängig. Das gewünschte Verhalten der Sollwerttrajektorie  $\mathbf{y}_d$  gibt das Steuergerät vor.



**Abbildung 5.2.** Einordnung des Korrekturkennfeldes der stationären LDR-Vorsteuerung

Neben dem Sollwert gehen weitere Mess- und Prozessgrößen in die Vorsteuerung ein, aus denen die Stellgröße berechnet wird. Das zu parametrierende Kennfeld liefert eine Zwischengröße innerhalb der Vorsteuerungsstruktur.

Durch die Datenübernahme vorheriger Motorserien ist davon auszugehen, dass der Startparametervektor  $\boldsymbol{\rho}_0$  eine realisierbare Ausgangstrajektorie  $\mathbf{y}_0$  liefert. Die durch die Linearisierung über der Trajektorie ermittelte Eingangs-Ausgangs-Matrix  $\mathbf{G}_k$  unterscheidet sich von der Eingangs-Ausgangs-Matrix der Zieltrajektorie  $\mathbf{G}_\infty$ . Diese Abweichung ist als multiplikative Modellunsicherheit zu berücksichtigen und ist weiterhin durch

$$\|\Delta \mathbf{G}_m\|_\infty \leq \delta_m, \quad \delta_m \in \mathbb{R}^{>0} \quad (5.2)$$

begrenzt und wird durch

$$\Delta \mathbf{G}_m \leq \delta_m \mathbf{I} \quad (5.3)$$

beschrieben. Damit ergibt sich aus der Gleichung 4.10 zur Bestimmung der Konvergenzbedingung

$$\begin{aligned} \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k (\mathbf{I} - \Delta \mathbf{G}_m) \mathbf{u}_k - (\mathbf{G}_k \Delta \mathbf{G}_m) \mathbf{L} \mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k (\mathbf{I} - \delta_m \mathbf{I}) \mathbf{u}_k - (\mathbf{G}_k \delta_m \mathbf{I}) \mathbf{L} \mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + (1 - \delta_m) \mathbf{G}_k \mathbf{u}_k - \delta_m \mathbf{G}_k \mathbf{L} \mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \left\| \mathbf{e}_k + (1 - \delta_m) \mathbf{G}_k \mathbf{u}_k - \delta_m \mathbf{G}_k \frac{\|\mathbf{G}_k^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_k \mathbf{G}_k^T \mathbf{e}_k\|_2^2} \mathbf{G}_k^T \mathbf{e}_k \right\|_2 - \|\mathbf{e}_k\|_2. \end{aligned} \quad (5.4)$$

Für den gewählten gradientenbasierten ILR-Algorithmus von 2.137 ist der Regularisierungsfaktor  $w$  in der Lernmatrix  $\mathbf{L}$  (2.137) in Abhängigkeit von  $\delta_m$  so zu bestimmen, dass  $\|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 < 0$  und  $w \geq 0$  gilt.

Das Optimierungsproblem

$$\hat{\boldsymbol{\rho}} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR, \infty} - \mathbf{u}_V(\hat{\boldsymbol{\rho}})\|_2), \quad \hat{\boldsymbol{\rho}} \in \mathbb{R}^N, \quad \hat{\rho}_i > 0 \quad \forall \quad i \quad (5.5)$$

lässt sich mittels des Verfahrens nach Nelder und Mead (Abschnitt 4.5) lösen. Dafür gibt es mehrere Gründe.

- Das Gütekriterium ist nichtlinear.
- Der Startparametervektor  $\boldsymbol{\rho}_0$  ist vorgegeben.
- Der Parametervektor  $\hat{\boldsymbol{\rho}}$  besteht aus weniger als 10 Elementen.
- Die Funktionswerte des Simplex sind durch die Berechnung der Stellgröße aus der gegebenen Vorsteuerungsstruktur unter Verwendung des Sollwertes und weiterer Mess- und Modellgrößen zu berechnen.

### 5.2.2. Anwendung für die dynamische Vorsteuerung der LDR

Das einzustellende Kennfeld der dynamischen Vorsteuerung aus 3.3 mit dem Parameter  $\rho_t$  bestimmt, abhängig vom erreichten Arbeitspunkt, den Abschaltzeitpunkt der Vollansteuerung des Wastegate. Der Lernvorgang des ILR-Algorithmus entspricht dem der stationären Vorsteuerung und lässt sich für den ersten Stützpunkt im Kennfeld gleichzeitig mit der stationären Vorsteuerung applizieren. Weitere Informationen lassen sich aus der optimierten Stellgrößentrajektorie  $\mathbf{u}_{ILR,\infty}$  hinsichtlich der dynamischen Vorsteuerung nicht ermitteln. Der Parameter  $\rho_t$  bestimmt einen diskreten Zeitpunkt und ist daher in einer optimierten Trajektorie nur für einen Arbeitspunkt ermittelbar. Dies erfordert zusätzliche Optimierungsiterationen an weiteren Stützstellen des Kennfeldes. Die Konvergenzbetrachtung entspricht der Gleichung 5.4 im vorherigen Abschnitt. Die Lösung des Optimierungsproblems

$$\hat{\rho}_t = \arg \min_{\rho_t} (\|\mathbf{u}_{ILR,\infty} - \mathbf{u}_V(\hat{\rho}_t)\|_2), \quad \hat{\rho}_t \in \mathbb{R}^{\geq 0} \quad (5.6)$$

erfolgt mit dem Optimierungsverfahren nach Nelder und Mead (Abschnitt 4.5). Dazu wird aus den gemessenen und modellierten Größen die gesamte Vorsteuerstruktur berechnet.

### 5.2.3. Anwendung für den Regler der LDR

Nach der Durchführung der Iteration 1 stellt die Trajektorie des Regelfehlers den Ausgangsfehler  $\mathbf{e}_0$  der gegebenen Startparametrierung  $\boldsymbol{\rho}_0$  dar. Aus dieser Messung ist das Wunschstörverhalten durch die Wunschregelabweichung  $\mathbf{e}_d$  abzuleiten und damit die Sollwerttrajektorie  $\mathbf{y}_{ILR,d}$  zu bestimmen. Da die Störung für das Selbsteinstellungsverfahren Variante I iterationsinvariant sein muss, ist die Bestimmung von  $\mathbf{y}_{ILR,d}$  nur einmal durchzuführen. Danach erfolgt die Deaktivierung des Reglers, die Aufschaltung der ILR-Stellgröße  $\mathbf{u}_{ILR,k}$  als Reglerausgang und die Durchführung der ILR-Optimierung.

Auf Grund der optimierten Vorsteuertrajektorie befindet sich der Prozess im Bereich der Arbeitstrajektorie. Dadurch ist die ermittelte Eingangs-Ausgangs-Matrix  $\mathbf{G}_K$  nahezu konstant. Lediglich die Höhe der Störung bewirkt eine Abweichung von der Arbeitstrajektorie und durch die vorhandene Nichtlinearität im Prozess kommt es zu einer Modellabweichung. Diese geringe multiplikative Modellunsicherheit ist durch

$$\|\Delta \mathbf{G}_m\|_\infty \leq \delta_m, \quad \delta_m \in \mathbb{R}^{>0} \quad (5.7)$$

begrenzt und durch

$$\Delta \mathbf{G}_m \leq \delta_m \mathbf{I} \quad (5.8)$$

beschreibbar. Damit ergibt sich für die Konvergenzbedingung  $\|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 < 0$

$$\begin{aligned} \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k (\mathbf{I} - \Delta \mathbf{G}_m) \mathbf{u}_k - (\mathbf{G}_k \Delta \mathbf{G}_m) \mathbf{L} \mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k (\mathbf{I} - \delta_m \mathbf{I}) \mathbf{u}_k - (\mathbf{G}_k \delta_m \mathbf{I}) \mathbf{L} \mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + (1 - \delta_m) \mathbf{G}_k \mathbf{u}_k - \delta_m \mathbf{G}_k \mathbf{L} \mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2. \end{aligned} \quad (5.9)$$

Als ILR-Ansatz wird der Ansatz der Pseudoinversen mit der Lernmatrix

$$\mathbf{L} = (\mathbf{G}_k^T \mathbf{G}_k + \eta_1 \mathbf{I} + \eta_2 \mathbf{E}^T \mathbf{E})^{-1} \mathbf{G}_k^T \quad (5.10)$$

aus 2.125 gewählt. Durch den Parameter  $\eta_2$  ist es möglich, starke Änderungen beim Anlernen der Stellgrößentrajektorie zu unterdrücken und damit die Dynamik zu beeinflussen. Der Parameter  $\eta_1$  ist so zu bestimmen, dass die Konvergenzbedingung erfüllt ist.

Das Optimierungsproblem

$$\hat{\boldsymbol{\rho}} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,\infty} - \mathbf{u}_R(\hat{\boldsymbol{\rho}})\|_2) \quad (5.11)$$

mit  $\hat{\boldsymbol{\rho}} = [K_P \ K_I]^T$  und  $K_P \in \mathbb{R}^{\geq 0}$  sowie  $K_I \in \mathbb{R}^{\geq 0}$  wird iterativ durch das Verfahren nach Nelder und Mead (Abschnitt 4.5) gelöst. In diesem Fall ist die Bestimmung des Funktionswertes des Simplex durch die Berechnung der Reglerstruktur schnell durchführbar, da sowohl die Reglerstruktur als auch weitere notwendige Mess- und Steuersignale der Freigabelogik als Datenvektoren vorliegen. Für die Applikation weiterer Stützpunkte der Reglerkennlinien sind zusätzliche Optimierungsiterationen in anderen Arbeitspunkten durchzuführen.

#### 5.2.4. Anwendung für den Regler des BLDC-Motorprüfstandes

Beim BLDC-Motorprüfstand ist auf Grund des Streckenverhaltens ohne Ausgleich ein Regler zur Stabilisierung notwendig. In diesem Fall lässt sich, wie in Abschnitt 2.3.2 beschrieben, der Ansatz eines CITE-FB ohne zusätzliche Lernmatrix verwenden. Dies bedeutet, dass der iterative Lernvorgang nur vom Reglerausgang abhängig ist. Damit reduziert sich der Rechenaufwand, da so keine Eingangs-Ausgangs-Matrix zu berechnen ist und die Lernregel sich auf

$$\mathbf{u}_{k+1} = \mathbf{u}_k + \mathbf{u}_{R,k} = \mathbf{u}_k + \mathbf{R} \mathbf{e}_{k,i+1} \quad (5.12)$$

reduziert. Darin stellt  $\mathbf{u}_{R,k}$  den Stellanteil des Reglers,  $\mathbf{R}$  die Eingangs-Ausgangs-Matrix eines beliebigen stabilisierenden Reglers und  $\mathbf{e}_{k,i+1}$  den, um einen Abtastpunkt

verschobenen, Vektor der Regelabweichung dar. Weiterhin gilt

$$\begin{aligned}
 \mathbf{u}_R &= \mathbf{R}e_{k,i+1} \\
 &= \begin{bmatrix} R_0 & 0 & \cdots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ R_{N-1} & \cdots & \cdots & R_0 \end{bmatrix} \begin{bmatrix} 0 \\ e_k(0) \\ \vdots \\ e_k(N-2) \end{bmatrix} \\
 &= \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ R_0 & 0 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ R_{N-3} & \ddots & R_0 & 0 & \vdots \\ R_{N-2} & \cdots & R_1 & R_0 & 0 \end{bmatrix} \begin{bmatrix} e_k(0) \\ \vdots \\ e_k(N-1) \end{bmatrix} \\
 &= \mathbf{R}^1 e_k. \tag{5.13}
 \end{aligned}$$

Da der Regler zur Menge der stabilisierenden Regler gehört, ist die allgemeine ILR-Entwurfsgleichung 2.88 erfüllt.

Es gilt, das Optimierungsproblem

$$\hat{\boldsymbol{\rho}} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,\infty} - \mathbf{u}_R(\hat{\boldsymbol{\rho}})\|_2) \tag{5.14}$$

mit  $\hat{\boldsymbol{\rho}} = [K_P \ K_I]^T$  und  $K_P \in \mathbb{R}^{\geq 0}$  sowie  $K_I \in \mathbb{R}^{\geq 0}$  zu lösen. Da es sich hier um ein lineares Optimierungsproblem handelt, lässt sich der zu optimierende Parametervektor  $\hat{\boldsymbol{\rho}}$  durch die Methode der kleinsten Fehlerquadrate (siehe Abschnitt 4.5) berechnen.

### 5.3. Anwendung des ILR-basierten Selbsteinstellungsverfahrens - Variante II

Das Verfahren Variante II der ILR-basierten Selbsteinstellung zielt auf den Einsatz bei normalen Betriebsmessungen ab. Dabei können sich Startpunkte und Sollwerttrajektorien in jeder Iteration unterscheiden. Grundsätzlich muss aber eine ausreichende Anregung des Prozesses erfolgen. Dies ermöglicht die Verwendung des Verfahrens bei normalen Straßenfahrten und macht den Einsatz eines Bypasses unnötig. Als ILR-Algorithmus kommen inversionsbasierte Verfahren zum Einsatz. Auch hier ist eine Abschätzung der Modellunsicherheit der Eingangs-Ausgangs-Matrix  $\mathbf{G}_k$  zur Gewährleistung der monotonen Konvergenz des Verfahrens notwendig.

#### 5.3.1. Anwendung für die stationäre Vorsteuerung der LDR

Das Verfahren Variante I basiert darauf, während der Parameteroptimierung die gesamte Vorsteuerstruktur zu berechnen und durch das Kennfeld  $KF(\mathbf{Gang}, \boldsymbol{\rho}_x)$  an die ILR-optimierte Stellgrößentrajektorie  $\mathbf{u}_{V,ILR,\infty}$  anzupassen. Diese Berechnung setzt die Messung weiterer notwendiger Mess- und Modellgrößen nach der ILR-Optimierung voraus.

Dieser erhöhte Rechenaufwand ist für eine Durchführung in jeder Iteration unpraktisch. Das Vorgehen der Anwendung Variante II für die stationäre Vorsteuerung ändert sich dahingehend, dass nun direkt der Kennfeldausgang durch den ILR-Algorithmus optimiert wird. Die betrachtete Stellgröße ist daher  $u_V = KF(\mathbf{Gang}, \rho_x)$ . Der Vorteil hierbei ist, dass nach der ILR-Optimierung in jeder Iteration eine optimierte Trajektorie des Kennfeldausganges vorliegt und während der Parameteroptimierung nur noch dieses Kennfeld zu bestimmen ist.

Zur Erfüllung der Konvergenzbedingung laut Gleichung 4.45 sind zum einen die multiplikative Modellunsicherheit der Eingangs-Ausgangs-Matrix des Prozesses  $\Delta \mathbf{G}_m$  und zum anderen die multiplikative Modellunsicherheit der Eingangs-Ausgangs-Matrix der erreichbaren Vorsteuerung  $\Delta \mathbf{C}_m$  zu berücksichtigen. Dabei ist

$$\|\Delta \mathbf{G}_m\|_\infty \leq \delta_m, \quad \delta_m \in \mathbb{R}^{>0} \quad (5.15)$$

begrenzt und durch

$$\Delta \mathbf{G}_m \leq \delta_m \mathbf{I} \quad (5.16)$$

berücksichtigt. Die Modellunsicherheit der Vorsteuerung  $\Delta \mathbf{C}_m$  zwischen der Eingangs-Ausgangs-Matrix der ILR-Vorsteuerung  $\mathbf{C}_{ILR,V,k+1}$  und der Eingangs-Ausgangs-Matrix der erreichbaren Vorsteuerung  $\mathbf{C}_V(\hat{\rho})$  aus 4.18 ist ebenfalls durch

$$\|\Delta \mathbf{C}_m\|_\infty \leq \delta_C, \quad \delta_C \in \mathbb{R}^{>0} \quad (5.17)$$

begrenzt und durch

$$\Delta \mathbf{C}_m \leq \delta_C \mathbf{I} \quad (5.18)$$

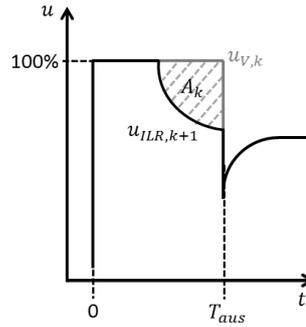
beschrieben. Dies ist laut 4.42 mit einem zusätzlichen Filter  $\mathbf{F}$  gleichzusetzen. Für das ILR-Stellgesetz gilt

$$\mathbf{u}_{V,k+1} = \mathbf{F}(\mathbf{u}_{V,k} + \mathbf{L}e_k) \quad (5.19)$$

mit  $\mathbf{F} = \Delta \mathbf{C}_m$ . Damit ergibt sich

$$\begin{aligned} \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k(\mathbf{I} - \Delta \mathbf{G}_m \mathbf{F})\mathbf{u}_{V,k} - (\mathbf{G}_k \Delta \mathbf{G}_m \mathbf{F})\mathbf{L}e_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k(\mathbf{I} - \Delta \mathbf{G}_m \Delta \mathbf{C}_m)\mathbf{u}_{V,k} - (\mathbf{G}_k \Delta \mathbf{G}_m \Delta \mathbf{C}_m)\mathbf{L}e_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k(\mathbf{I} - \delta_m \delta_C \mathbf{I})\mathbf{u}_{V,k} - (\mathbf{G}_k \delta_m \delta_C \mathbf{I})\mathbf{L}e_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + (1 - \delta_m \delta_C)\mathbf{G}_k\mathbf{u}_{V,k} - \delta_m \delta_C \mathbf{G}_k \mathbf{L}e_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \left\| \mathbf{e}_k + (1 - \delta_m \delta_C)\mathbf{G}_k\mathbf{u}_{V,k} - \delta_m \delta_C \mathbf{G}_k \frac{\|\mathbf{G}_k^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_k \mathbf{G}_k^T \mathbf{e}_k\|_2^2} \mathbf{G}_k^T \mathbf{e}_k \right\|_2 \\ &\quad - \|\mathbf{e}_k\|_2. \end{aligned} \quad (5.20)$$

Für den gewählten gradientenbasierten ILR-Algorithmus von 2.137 ist der Regularisierungsfaktor  $w$  in der Lernmatrix  $\mathbf{L}$  (2.137) in Abhängigkeit von  $\delta_m$  und  $\delta_C$  so zu bestimmen, dass  $\|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 < 0$  und  $w \geq 0$  gilt. Somit ist die Konvergenz gewährleistet und die Optimierung des Parametervektors  $\hat{\rho}$  in jeder Iteration möglich.


 Abbildung 5.3. Fläche  $A_k$ 

Da die Startpunkte und Sollwerttrajektorien in jeder Iteration variieren können, sind vor der Parameteroptimierung die erreichten Stützstellen von  $\rho_x$  zu ermitteln und daraufhin die dazugehörigen Parameter des Parametervektors  $\hat{\rho}$  für die Optimierung freizugeben. Dazu ist das Optimierungsproblem

$$\hat{\rho} = \arg \min_{\hat{\rho}} (\|\mathbf{u}_{ILR,k+1} - \mathbf{u}_V(\hat{\rho})\|_2), \quad \hat{\rho} \in \mathbb{R}^N, \quad \hat{\rho}_i > 0 \quad \forall \quad i \quad (5.21)$$

zu lösen. Bei dem verwendeten Optimierungsverfahren handelt es sich um das Verfahren nach Nelder und Mead (Abschnitt 4.5).

### 5.3.2. Anwendung für die dynamische Vorsteuerung der LDR

Die dynamische Vorsteuerung hat die Aufgabe, die maximale Performance der Ladedruckregelung zu erreichen, indem die maximale Stellgröße angefordert wird. Um ein starkes Überschwingen der Stellgröße zu vermeiden, ist diese Maximalanforderung rechtzeitig zum Zeitpunkt  $T_{aus}$  abzuschalten (Abb. 5.3). Aus Gründen des Fahrkomforts ist ein geringes Überschwingen möglich. Der einzustellende Kennfeldparameter  $\rho_t$  beeinflusst diesen Abschaltzeitpunkt.

Die Umsetzung des ILR-basierten Einstellungsverfahrens Variante II erweist sich im Bezug auf die dynamische Vorsteuerung mit dem Parameterkennfeld  $\rho_t$  als schwierig. In Abb. 5.3 ist die Problematik dargestellt. Die Herausforderung besteht darin, einen diskreten Zeitpunkt und den dazugehörigen Parameterwert von  $\rho_t$  zu ermitteln, der eine sprunghafte Änderung des Stellsignals bewirkt. Eine Optimierung dieses Signals kann der ILR-Algorithmus unter Gewährleistung der Konvergenz nur mit mehreren Iterationen durchführen. Das Einstellungsverfahren Variante II lässt aber nur eine Iteration zu, in der die neue Stellgrößentrajektorie zu berechnen und der Parameter zu optimieren ist. Dies führt zur Beibehaltung des Sprungzeitpunktes und einer geringen Veränderung der Stellgrößentrajektorie. Dazu ist in Abb. 5.3 vereinfacht der Verlauf der aktuellen Stellgrößentrajektorie  $\mathbf{u}_k$  (graue Linie) und der ILR-optimierten Stellgrößentrajektorie  $\mathbf{u}_{k+1}$  (schwarze Linie) dargestellt. Diesen Verlauf der ILR-optimierten Stellgrößentrajektorie  $\mathbf{u}_{k+1}$  kann die gegebene Struktur der dynamischen Vorsteuerung nicht darstellen und ist somit nicht direkt ermittelbar. Das Optimierungsproblem

$$\hat{\rho}_t = \arg \min_{\hat{\rho}_t} (\|\mathbf{u}_{ILR,k+1} - \mathbf{u}_V(\hat{\rho}_t)\|_2), \quad \hat{\rho}_t \in \mathbb{R}^{\geq 0}$$

ist in diesem Fall durch eine güteindexbasierte Parameteränderung wie bei den klassischen CPM-Verfahren lösbar und soll im nächsten Abschnitt erläutert werden.

Darauf aufbauend erfolgt der Nachweis der Konvergenz des gewählten inversions- und gradientenbasierten ILR-Algorithmus wie in 5.20 und berücksichtigt die begrenzte multiplikative Modellunsicherheit

$$\|\Delta \mathbf{G}_m\|_\infty \leq \delta_m, \quad \delta_m \in \mathbb{R}^{>0} \quad (5.22)$$

des Prozesses und

$$\|\Delta \mathbf{C}_m\|_\infty \leq \delta_C, \quad \delta_C \in \mathbb{R}^{>0} \quad (5.23)$$

der Vorsteuerstruktur. Das ILR-Stellgesetz lautet damit

$$\mathbf{u}_{V,k+1} = \Delta \mathbf{C}_m \left( \mathbf{u}_{V,k} + \frac{\|\mathbf{G}_k^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_k \mathbf{G}_k^T \mathbf{e}_k\|_2^2} \mathbf{G}_k^T \mathbf{e}_k \right). \quad (5.24)$$

Es ergibt sich der Zusammenhang

$$\begin{aligned} & \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \left\| \mathbf{e}_k + (1 - \delta_m \delta_C) \mathbf{G}_k \mathbf{u}_{V,k} - \delta_m \delta_C \mathbf{G}_k \frac{\|\mathbf{G}_k^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_k \mathbf{G}_k^T \mathbf{e}_k\|_2^2} \mathbf{G}_k^T \mathbf{e}_k \right\|_2 - \|\mathbf{e}_k\|_2, \end{aligned} \quad (5.25)$$

dessen Entwurfsparameter  $w \geq 0$  die Ungleichung  $\|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 < 0$  erfüllen muss.

### Güteindexbasierte Parameteränderung

Die Einführung des Güteindex

$$J_{T,k+1}(\Delta t) = (A_\alpha - A_{k+1})^2 \quad (5.26)$$

ermöglicht die Ermittlung der Änderung des Abschaltzeitpunktes  $\Delta t$  und damit die Bestimmung des Kennfeldparameters  $\rho_t$  im jeweiligen Arbeitspunkt. Dabei gilt für den zu ermittelnden Abschaltzeitpunkt der nächsten Iteration

$$T_{aus,k+1} = T_{aus,k} + \Delta t. \quad (5.27)$$

Die Größe  $A_k$  ist die Fläche, die von der aktuellen Stellgrößentrajektorie  $\mathbf{u}_k$  und der ILR-optimierten Stellgrößentrajektorie  $\mathbf{u}_{ILR,k+1}$  im Zeitbereich  $t = 0$  (Abtastwert  $i = 0$ ) bis  $T_{aus}$  (Abtastwert  $i = \frac{T_{aus,k}}{T_s} - 1$ ) umschlossen wird (Abb. 5.3). Es gilt

$$A_k = \sum_{i=0}^{\frac{T_{aus,k}}{T_s} - 1} (\mathbf{u}_k - \mathbf{u}_{ILR,k+1}). \quad (5.28)$$

Mit dem Parameter  $A_\alpha$  ist der Grenzwert der zugelassenen Überschwingung vorzugeben. Weiterhin gilt für die Fläche der nächsten Iteration

$$A_{k+1} = A_k + \Delta A \quad (5.29)$$

mit der Änderung der Fläche  $\Delta A$ , die abhängig von der Änderung der Abschaltzeit  $\Delta t$  ist. Die Fläche  $A_k$  ist eine nichtlineare Funktion der Abschaltzeit

$$A_k = f_A(T_{aus,k}). \quad (5.30)$$

Die Funktion  $f_A(T_{aus,k})$  ist stetig nach dem Lipschitz-Kriterium. Damit gilt

$$\begin{aligned} |A_{k+1} - A_k| &= |f_A(T_{aus,k+1}) - f_A(T_{aus,k})| \leq K_L |T_{aus,k+1} - T_{aus,k}| \\ \text{also} \\ |\Delta A| &\leq K_L |\Delta t| \end{aligned} \quad (5.31)$$

mit  $K_L > 0$ . Damit ergibt sich für das Gütekriterium

$$\begin{aligned} J_{T,k+1} &= (A_\alpha - A_k - \Delta A)^2 \\ &= (A_\alpha - A_k)^2 - 2(A_\alpha - A_k)\Delta A + (\Delta A)^2 \\ &= J_{T,k} - 2(A_\alpha - A_k)\Delta A + (\Delta A)^2 \end{aligned} \quad (5.32)$$

und für die Änderung des Gütekriteriums

$$\begin{aligned} \Delta J &= J_{T,k+1} - J_{T,k} \\ &= (-2(A_\alpha - A_k) + \Delta A) \Delta A. \end{aligned} \quad (5.33)$$

Zum Erreichen der Konvergenz muss  $\Delta J \leq 0$  sein. Folgende drei Fälle können auftreten:

**Fall 1:** Der Abschaltzeitpunkt ist korrekt und die ermittelte Fläche  $A_k = A_\alpha$ . In diesem Fall ist der Güteindex null und das Optimierungsziel erreicht.

**Fall 2:** Die Abschaltung erfolgt zu spät und es entsteht ein starkes Überschwingen. Für die ermittelte Fläche zwischen der aktuellen Stellgrößentrajektorie  $\mathbf{u}_k$  und der ILR-optimierten Stellgrößentrajektorie  $\mathbf{u}_{ILR,k+1}$  gilt

$$\begin{aligned} A_k &> A_\alpha \text{ bzw.} \\ A_\alpha - A_k &< 0, \end{aligned} \quad (5.34)$$

da der ILR-Algorithmus die Vollansteuerung der Stellgröße reduzieren will. Daher muss

$$\begin{aligned} A_{k+1} &< A_k \\ \Delta A &< 0 \end{aligned} \quad (5.35)$$

sein. Dies ist nur durch einen früheren Abschaltzeitpunkt realisierbar und es gilt

$$\begin{aligned} T_{aus,k+1} - T_{aus,k} &< 0 \\ \Delta t &< 0. \end{aligned} \quad (5.36)$$

Damit ergibt sich für die Änderung des Gütekriteriums

$$\Delta J = \underbrace{(-2(A_\alpha - A_k) + \Delta A)}_{>0} \underbrace{\Delta A}_{<0} < 0. \quad (5.37)$$

Somit muss

$$-2(\underbrace{A_\alpha - A_k}_{<0}) + \underbrace{\Delta A}_{<0} > 0 \quad (5.38)$$

gelten, und für  $\Delta A$  lässt sich

$$0 > \Delta A > 2(A_\alpha - A_k) \quad (5.39)$$

schreiben. Da sich weiterhin aus 5.31

$$\begin{aligned} |\underbrace{\Delta A}_{<0}| &\leq K_L |\underbrace{\Delta t}_{<0}| \\ \Delta A &\geq K_L \Delta t \end{aligned} \quad (5.40)$$

ableiten lässt, gilt somit für die Änderung des Abschaltzeitpunktes

$$0 > \Delta t > \frac{2}{K_L}(A_\alpha - A_k). \quad (5.41)$$

**Fall 3:** Die Abschaltung erfolgt zu früh und die maximale Performance wird nicht erreicht. Für die ermittelte Fläche zwischen der aktuellen Stellgrößentrajektorie  $\mathbf{u}_k$  und der ILR-optimierten Stellgrößentrajektorie  $\mathbf{u}_{ILR,k+1}$  gilt

$$\begin{aligned} A_k &< A_\alpha \text{ bzw.} \\ A_\alpha - A_k &> 0, \end{aligned} \quad (5.42)$$

da der ILR-Algorithmus die Vollansteuerung der Stellgröße erweitern will. Daher muss

$$\begin{aligned} A_{k+1} &> A_k \\ \Delta A &> 0 \end{aligned} \quad (5.43)$$

sein. Dies ist nur durch einen späteren Abschaltzeitpunkt realisierbar und es gilt

$$\begin{aligned} T_{aus,k+1} - T_{aus,k} &> 0 \\ \Delta t &> 0. \end{aligned} \quad (5.44)$$

Damit ergibt sich für die Änderung des Gütekriteriums

$$\Delta J = \underbrace{(-2(A_\alpha - A_k) + \Delta A)}_{<0} \underbrace{\Delta A}_{>0} < 0. \quad (5.45)$$

Somit muss

$$-2(\underbrace{A_\alpha - A_k}_{>0}) + \underbrace{\Delta A}_{>0} < 0 \quad (5.46)$$

gelten und für  $\Delta A$  lässt sich

$$0 < \Delta A < 2(A_\alpha - A_k) \quad (5.47)$$

schreiben. Da sich weiterhin aus 5.31

$$\underbrace{|\Delta A|}_{>0} \leq K_L \underbrace{|\Delta t|}_{>0}$$

$$\Delta A \leq K_L \Delta t \quad (5.48)$$

ableiten lässt, gilt für die Änderung des Abschaltzeitpunktes

$$0 < \Delta t < \frac{2}{K_L}(A_\alpha - A_k). \quad (5.49)$$

Daraus ergibt sich für den Betrag der Änderung des Abschaltzeitpunktes die allgemeine Lernregel

$$\left| \frac{2}{K_L}(A_\alpha - A_k) \right| > |\Delta t| > 0, \quad (5.50)$$

die die Konvergenz des Verfahrens gewährleistet. Der Kennfeldparameter  $\rho_t$  lässt sich aus  $\Delta t$  der gegebenen Vorsteuerungsstruktur und weiteren gemessenen bzw. modellierten Größen des Steuergerätes berechnen. Durch diese zusätzliche Begrenzung des Verfahrens ist mit einer erhöhten Anzahl an Iterationen zu rechnen.

### 5.3.3. Anwendung für den Regler der LDR

Die Anwendung der ILR-basierten Selbsteinstellung der Reglerparameter der Ladedruckregelung erfolgt nach dem gleichen Ansatz wie im Abschnitt 5.2.3. Durch die gegebene optimierte Vorsteuerung befindet sich der Prozess im Arbeitspunkt. Im Unterschied zum vorherigen Ablauf ist der PI-Regler aktiv und die Parameter des Reglers sind in jeder Iteration zu berechnen. Es ist daher unnötig, die optimierte ILR-Stellgrößentrajektorie der Stellgröße aufzuprägen. Dadurch ist die Einrichtung und Verwendung eines Bypasses zum Steuergerät nicht notwendig. Weiterhin kann in diesem Fall die Störangregung iterationsvariant sein, d.h. diese Störung muss bestimmbar sein und die Berechnung des Wunschstörverhaltens ermöglichen. Es ist zu gewährleisten, dass das Wunschstörverhalten iterationsinvariant ist.

Die betrachtete multiplikative Modellunsicherheit zwischen der Eingangs-Ausgangs-Matrix des Prozesses in der nächsten Iteration  $\mathbf{G}_{k+1}$  und in der aktuellen Iteration  $\mathbf{G}_k$  gilt als begrenzt durch

$$\|\Delta \mathbf{G}_m\|_\infty \leq \delta_m, \quad \delta_m \in \mathbb{R}^{>0} \quad (5.51)$$

und ist durch

$$\Delta \mathbf{G}_m \leq \delta_m \mathbf{I} \quad (5.52)$$

beschrieben. Die Höhe von  $\delta_m$  ist davon abhängig, wie stark die eintretende Störung den Prozess aus dem Arbeitspunkt auslenkt.

Die multiplikative Modellunsicherheit zwischen der geforderten Eingangs-Ausgangs-Matrix der ILR-Optimierung  $\mathbf{C}_{ILR,R,k+1}$  und der möglichen Eingangs-Ausgangs-Matrix des Reglers  $\mathbf{C}_R(\hat{\rho})$  ist durch

$$\mathbf{C}_{ILR,R,k+1} = \Delta \mathbf{C}_m \mathbf{C}_R(\hat{\rho}) \quad (5.53)$$

definiert, durch

$$\|\Delta\mathbf{C}_m\|_\infty \leq \delta_C, \quad \delta_C \in \mathbb{R}^{>0} \quad (5.54)$$

begrenzt und kann durch

$$\Delta\mathbf{C}_m \leq \delta_C \mathbf{I} \quad (5.55)$$

beschrieben werden. Für das ILR-Stellgesetz ergibt sich unter Berücksichtigung des Filters  $\mathbf{F} = \Delta\mathbf{C}_m$  die Lernregel

$$\mathbf{u}_{R,k+1} = \Delta\mathbf{C}_m (\mathbf{u}_{R,k} + \mathbf{L}\mathbf{e}_k) \quad (5.56)$$

und damit der folgende Zusammenhang

$$\begin{aligned} \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{y}_d - \mathbf{G}_k \Delta\mathbf{G}_m \Delta\mathbf{C}_m (\mathbf{u}_{R,k} + \mathbf{L}\mathbf{e}_k)\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k (\mathbf{I} - \Delta\mathbf{G}_m \Delta\mathbf{C}_m) \mathbf{u}_{R,k} - \mathbf{G}_k \Delta\mathbf{G}_m \Delta\mathbf{C}_m \mathbf{L}\mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + (1 - \delta_m \delta_C) \mathbf{G}_k \mathbf{u}_{R,k} - \delta_m \delta_C \mathbf{G}_k \mathbf{L}\mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \end{aligned} \quad (5.57)$$

zur Betrachtung der Konvergenz. Die Parameter  $\eta_1$  und  $\eta_2$  des inversionbasierten ILR-Algorithmus

$$\mathbf{L} = (\mathbf{G}_k^T \mathbf{G}_k + \eta_1 \mathbf{I} + \eta_2 \mathbf{E}^T \mathbf{E})^{-1} \mathbf{G}_k^T \quad (5.58)$$

aus 2.125 sind so zu ermitteln, dass sie das Optimierungskriterium  $\|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 < 0$  erfüllen.

Die Berechnung des Parametervektors  $\hat{\boldsymbol{\rho}} = [K_P \ K_I]^T$  mit den Parametern des Reglers  $K_P \in \mathbb{R}^{\geq 0}$  und  $K_I \in \mathbb{R}^{\geq 0}$  zur Lösung des Optimierungsproblems

$$\hat{\boldsymbol{\rho}} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,k+1} - \mathbf{u}_R(\hat{\boldsymbol{\rho}})\|_2) \quad (5.59)$$

wird mit dem Verfahren nach Nelder und Mead (Abschnitt 4.5) durchgeführt.

### 5.3.4. Anwendung für den Regler des BLDC-Motorprüfstandes

Bei der Anwendung des Verfahrens Variante II zur Einstellung des PI-Reglers am BLDC-Motorprüfstand liefert der ILR-Algorithmus in jeder Iteration einen optimierten Verlauf der Stellgröße des Reglers zur Realisierung des gewünschten Störverhaltens. Das ILR-Stellgesetz lautet hierfür wie folgt:

$$\mathbf{u}_{R,k+1} = \Delta\mathbf{C}_m (\mathbf{Q}\mathbf{u}_{R,k} + \mathbf{L}\mathbf{Q}\mathbf{e}_k). \quad (5.60)$$

Dabei stellt  $\mathbf{Q}$  eine akasale Filterung der gemessenen Trajektorien  $\mathbf{u}_k$  und  $\mathbf{e}_k$  dar, die auf Grund des Messrauschens auf den Prüfstandssignalen notwendig ist. Weiterhin berücksichtigt die multiplikative Modellunsicherheit  $\Delta\mathbf{C}_m$  des einzustellenden Reglers die Abweichung zwischen  $\mathbf{C}_{ILR,R,k+1}$  und  $\mathbf{C}_R(\hat{\boldsymbol{\rho}})$ . Die Matrix  $\Delta\mathbf{C}_m$  ist durch

$$\Delta\mathbf{C}_m = \delta_C \mathbf{I} \quad (5.61)$$

$$(5.62)$$

mit

$$\|\Delta \mathbf{C}_m\|_\infty \leq \delta_C, \quad \delta_C \in \mathbb{R}^{>0} \quad (5.63)$$

definiert. Für die multiplikative Modellunsicherheit der Eingangs-Ausgangs-Matrix  $\mathbf{G}_{k+1}$  gilt auf Grund des nahezu linearen Streckenverhaltens  $\Delta \mathbf{G}_m \approx \mathbf{I}$  und damit

$$\mathbf{G}_{k+1} = \mathbf{G}_k \Delta \mathbf{G}_m \approx \mathbf{G}_k. \quad (5.64)$$

Damit ergibt sich für die Betrachtung der Konvergenz folgender Zusammenhang:

$$\begin{aligned} \|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 &= \|\mathbf{y}_d - \mathbf{y}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{y}_d - \mathbf{G}_k \Delta \mathbf{C}_m (\mathbf{Q} \mathbf{u}_{R,k} + \mathbf{L} \mathbf{Q} \mathbf{e}_k)\|_2 - \|\mathbf{e}_k\|_2 \\ &= \|\mathbf{e}_k + \mathbf{G}_k (\mathbf{I} - \Delta \mathbf{C}_m \mathbf{Q}) \mathbf{u}_{R,k} - \mathbf{G}_k \Delta \mathbf{C}_m \mathbf{L} \mathbf{Q} \mathbf{e}_k\|_2 - \|\mathbf{e}_k\|_2 \\ &= \left\| \mathbf{e}_k + \mathbf{G}_k (\mathbf{I} - \delta_C \mathbf{Q}) \mathbf{u}_{R,k} - \delta_C \mathbf{G}_k \frac{\|\mathbf{G}_k^T \mathbf{e}_k\|_2^2}{w + \|\mathbf{G}_k \mathbf{G}_k^T \mathbf{e}_k\|_2^2} \mathbf{G}_k^T \mathbf{Q} \mathbf{e}_k \right\|_2 \\ &\quad - \|\mathbf{e}_k\|_2. \end{aligned} \quad (5.65)$$

Um die monotone Konvergenz zu gewährleisten, ist der Parameter  $w$  des inversions- und gradientenbasierten ILR-Algorithmus so zu bestimmen, dass  $\|\mathbf{e}_{k+1}\|_2 - \|\mathbf{e}_k\|_2 < 0$  erfüllt ist.

Die Berechnung des Parametervektors  $\hat{\boldsymbol{\rho}} = [K_P \ K_I]^T$  mit den Parametern des Reglers  $K_P \in \mathbb{R}^{\geq 0}$  und  $K_I \in \mathbb{R}^{\geq 0}$  zur Lösung des Optimierungsproblems

$$\hat{\boldsymbol{\rho}} = \arg \min_{\hat{\boldsymbol{\rho}}} (\|\mathbf{u}_{ILR,k+1} - \mathbf{u}_R(\hat{\boldsymbol{\rho}})\|_2) \quad (5.66)$$

wird mit der Methode der kleinsten Fehlerquadrate (Abschnitt 4.5) durchgeführt.

# Kapitel 6.

## Simulative und experimentelle Ergebnisse

Dieses Kapitel dokumentiert die Ergebnisse der entwickelten Verfahren zur Selbsteinstellung von Parametern der eingesetzten Reglerstruktur. Der erste Abschnitt stellt die verwendeten Simulationsmodelle und typische Versuche vor. Die darauf folgenden zwei Abschnitte präsentieren die Anwendung der Selbsteinstellungsverfahren an den Simulationsmodellen. Danach zeigen praktische Versuche die Umsetzung der Selbsteinstellungsverfahren an realen Systemen. Am Ende dieses Kapitels folgt eine Bewertung und Diskussion der eingesetzten Verfahren.

### 6.1. Simulationsbedingungen

#### 6.1.1. Simulationsbedingungen beim aufgeladenen Ottomotor

Das verwendete Simulationsmodell ist an einen 1,4l Motor und an das Fahrverhalten eines VW Golf angepasst. Die Parametrierung des Motormodells stammt aus der Dissertation [Beckmann, 2014]. Die identifizierten Parameter des Fahrverhaltens stammen von Messdaten der IAV GmbH.

Wie in Abschnitt 5.1 beschrieben, lassen sich mit dem Simulationsmodell verschiedene Fahr- und Testsituationen simulieren. Für den Einsatz der Selbsteinstellungsverfahren im Bereich der Ladedruckregelung sind zwei grundlegende Varianten wichtig, die so auch in der Praxis durchführbar sind. Dabei handelt es sich um Beschleunigungsfahrten auf der Straße und um Lastfahrten auf einem Rollenprüfstand.

#### Fahrsimulation auf der Straße

Diese Fahrsituation simuliert eine Beschleunigungsfahrt auf der Straße. Dazu ist ein Startpunkt bestehend aus Drosselklappenwinkel  $\alpha_{DK,0}$ , Motordrehzahl  $n_{mot,0}$  und Fahrzeuggeschwindigkeit  $v_{FZG,0}$  einzustellen. Die Beschleunigungsphase beginnt, indem die Drosselklappe vollständig geöffnet und ein Sollwert für den Ladedruck generiert wird. Erreicht die Motordrehzahl  $6500 \frac{U}{min}$ , ist die Beschleunigungsphase und die Ladedruckanforderung beendet. Zur Variation der Fahrsimulation lassen sich die Startparameter

- Startdrehzahl zwischen  $1000 \frac{U}{min} \leq n_{mot,0} \leq 5000 \frac{U}{min}$  und
- Ladedrucksollwert zwischen  $1300 \text{ mbar} \leq p_{nV,d} \leq 1900 \text{ mbar}$

verändern.

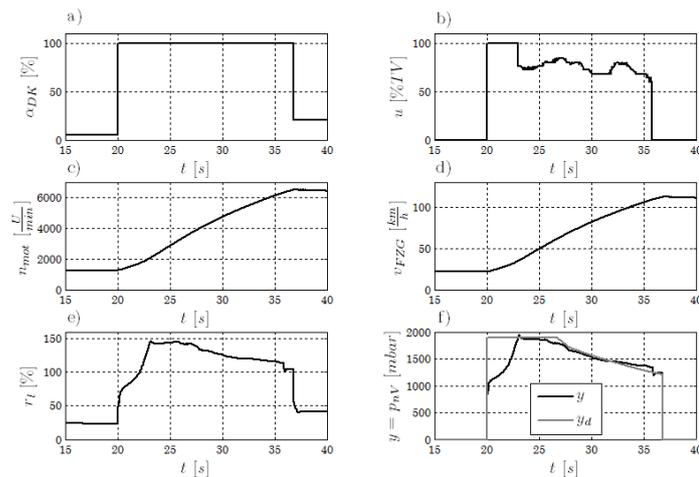


Abbildung 6.1. Simulation einer Volllastbeschleunigung

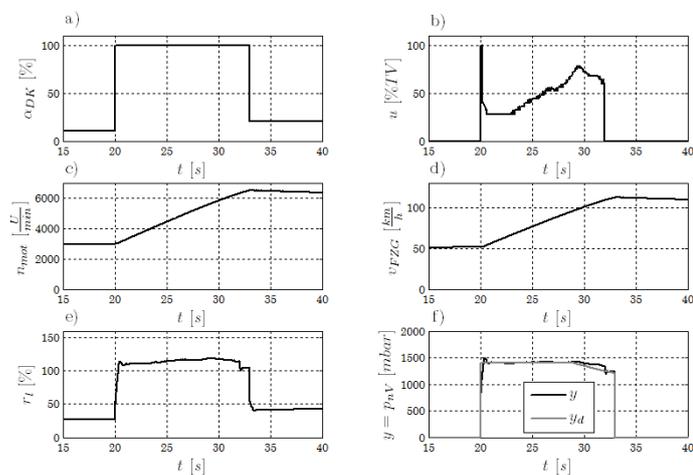


Abbildung 6.2. Simulation einer Teillastbeschleunigung

Die Abbildungen 6.1 und 6.2 zeigen Simulationsbeispiele einer möglichen Straenfahrt. Darin ist im Diagramm a) der Drosselklappenwinkel  $\alpha_{DK}$ , in Diagramm b) das Stellsignal der Ladedruckregelung (Tastverhltnis)  $u$ , in Diagramm c) die Motordrehzahl  $n_{mot}$ , in Diagramm d) die Fahrzeuggeschwindigkeit  $v_{FZG}$ , sowie in Diagramm e) die relative Fllung  $r_L$  und in Diagramm f) der Sollladedruck  $y_d = p_{nV,d}$  und Istladedruck  $y = p_{nV}$  dargestellt. Zum Zeitpunkt  $t = 20\text{ s}$  erfolgt der Lastsprung mit

$$\alpha_{DK}(t) = \begin{cases} \alpha_{DK,0}, & t < 20\text{ s} \\ 100\%, & t \geq 20\text{ s} \end{cases}$$

$$y_d = \begin{cases} 0, & t < 20\text{ s} \\ y_d, & t \geq 20\text{ s} \end{cases} .$$

Ab  $t = 20\text{ s}$  ist die Ladedruckregelung aktiv und das Fahrzeug beschleunigt.

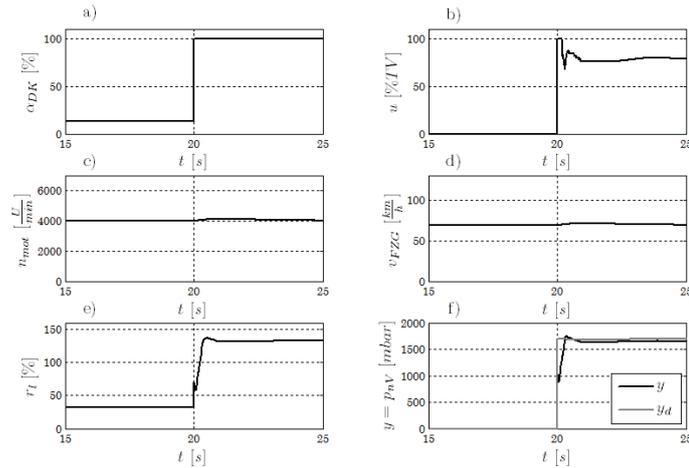


Abbildung 6.3. Simulation einer Fahrt auf dem Rollenprüfstand (I)

Abb. 6.1 zeigt eine Vollastbeschleunigung mit maximaler Forderung des Sollladedruckes  $p_{nV,d} = 1900 \text{ mbar}$  und einer Startdrehzahl  $n_{mot,0} = 1300 \frac{U}{min}$ . Ab einer Motordrehzahl von  $n_{mot,0} = 3500 \frac{U}{min}$  nimmt der maximal mögliche Sollladedruck des Abgasturboladers ab. Zu Beginn ist die Stellgröße  $u$  in der Stellgrößenbegrenzung und der ansteigende Ladedruck zu erkennen. Ist der Wert des Solldruckes erreicht, löst sich die Stellgröße von ihrer Begrenzung. Im aufgeladenen Bereich ( $y = p_{nV} > p_u$ ) steigt die relative Luftfüllung  $r_l$  über 100% und dem Fahrer steht eine erhöhte Motorleistung zur Verfügung.

Abb. 6.2 zeigt eine Teillastbeschleunigung mit einer geringeren Sollladedruckforderung von  $y_d = p_{nV,d} = 1400 \text{ mbar}$  und einer Startdrehzahl von  $n_{mot,0} = 2500 \frac{U}{min}$ . Durch den höheren Gradienten im Druckaufbau auf Grund der höheren Startdrehzahl und durch den kleineren Sollladedruck ist die Stellgröße in diesem Fall zeitlich kürzer an der Stellbegrenzung.

### Fahrsimulation auf einem Rollenprüfstand

Stellenweise ist es notwendig, gezielt Arbeitspunkte einzustellen und Testfahrten durchzuführen. Wie in Abschnitt 5.1 beschrieben, ist dies für den Betriebsbereich der Ladedruckregelung auf Rollenprüfständen möglich. Hierbei sind die antreibenden Räder auf einer Leistungsrolle positioniert, die den Widerstand darstellt. Dadurch ist es möglich, konstante Motordrehzahlen einzustellen. Bei der Rollensimulation können die Startparameter

- Startdrehzahl zwischen  $1000 \frac{U}{min} \leq n_{mot,0} \leq 6000 \frac{U}{min}$  und
- Ladedrucksollwert zwischen  $1300 \text{ mbar} \leq p_{nV,d} \leq 1900 \text{ mbar}$

variieren.

Die Abbildungen 6.3 und 6.4 zeigen Simulationsbeispiele einer möglichen Fahrt auf dem Rollenprüfstand. Darin ist im Diagramm a) der Drosselklappenwinkel  $\alpha_{DK}$ , in Diagramm b) das Stellsignal der Ladedruckregelung (Tastverhältnis)  $u$ , in Diagramm c) die

Motordrehzahl  $n_{mot}$ , in Diagramm d) die Fahrzeuggeschwindigkeit  $v_{FZG}$ , in Diagramm e) die relative Füllung  $r_l$  und in Diagramm f) der Sollladedruck  $y_d = p_{nV,d}$  und Istladedruck  $y = p_{nV}$  dargestellt. Es zeigt sich, dass die Regelung der Rollendrehzahl zum Zeitpunkt des Lastsprunges die Drehzahl nicht konstant halten kann. Dieser Effekt tritt auch an realen Rollenprüfständen auf.

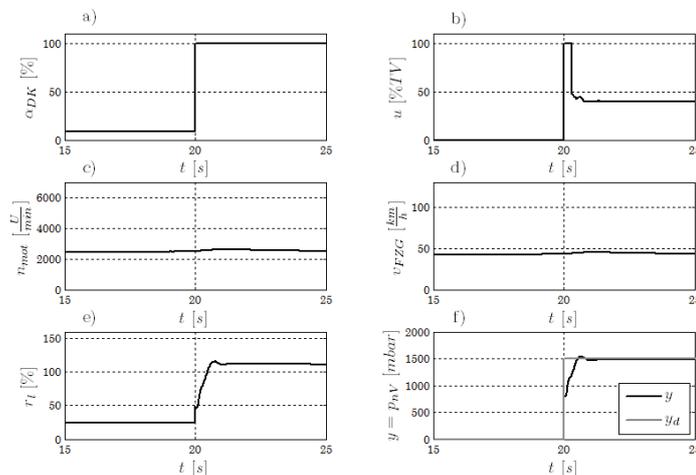


Abbildung 6.4. Simulation einer Fahrt auf dem Rollenprüfstand (II)

Der Arbeitspunkt bei  $n_{mot,0} = 4000 \frac{U}{min}$  und  $y_d = p_{nV,d} = 1500 \text{ mbar}$ , dargestellt in Abb. 6.3, entspricht für diese Drehzahl einer Volllast. Die Abb. 6.4 zeigt einen Lastsprung bei einer Rollendrehzahl von  $n_{mot,0} = 2500 \frac{U}{min}$  und einem Sollladedruck von  $y_d = p_{nV,d} = 1500 \text{ mbar}$ , was dem Teillastbereich entspricht.

### 6.1.2. Simulationsbedingungen beim BLDC-Motorprüfstand

Das in Abschnitt 5.1 angeführte Modell eines BLDC-Motorprüfstandes dient zur Simulation und dem Test eines ILR-basierten Reglerentwurfes. Die Abb. 6.5 zeigt ein Simulationsbeispiel des BLDC-Motorprüfstandes. In Diagramm a) ist Verlauf der Stellgröße  $u$ , in Diagramm b) der Verlauf der Regelgröße  $y$  und in Diagramm c) der Verlauf des Regelfehlers  $e$  dargestellt. Der Arbeitspunkt des Prozesses ist eine Wellendrehzahl  $n_W = 100 \frac{U}{min}$ . Das Anfahren des Arbeitspunktes erfolgt durch eine Vorsteuertrajektorie und mit aktivem PI-Regler. Dadurch stellt sich der stabile Arbeitspunkt wie gewünscht ein.

## 6.2. Simulationen zum ILR-basierten Selbsteinstellungsverfahren - Variante I

Dieser Abschnitt zeigt die Simulationsergebnisse des ILR-basierten Selbsteinstellungsverfahrens Variante I. Dieses Verfahren kann bei stabilen Prozessen angewendet werden, die die Vorgabe einer Vorsteuertrajektorie zulassen. In diesem Fall ist es notwendig, wiederholbare Iterationen mit reproduzierbaren Startbedingungen zu gewährleisten. Ein

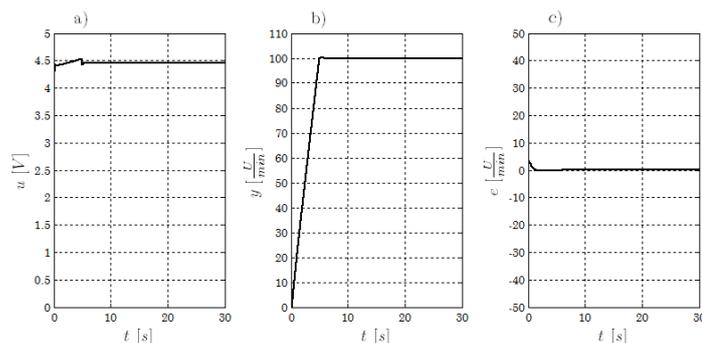


Abbildung 6.5. Simulationsbeispiel des BLDC-Motorprüfstandes

Beispiel ist die Verwendung eines Rollenprüfstandes mit der Vorgabe einer Beschleunigungsfahrt bzw. die Einstellung eines konstanten Arbeitspunktes.

### 6.2.1. Einstellung der stationären Vorsteuerung der LDR

Für die Einstellung der stationären Vorsteuerung sind, wie in Abschnitt 5.2.1 beschrieben, Beschleunigungsfahrten beginnend bei möglichst niedriger Motordrehzahl bis zur maximalen Motordrehzahl durchzuführen. Die Abb. 6.6 zeigt das Simulationsergebnis der Parametereinstellung im 3. Gang. Diese Simulation stellt den Grundfall dar. Darin werden keine zusätzlichen Störungen, Parameterschwankungen oder Messrauschen berücksichtigt.

Die Diagramme a), e) und i) zeigen die Verläufe der Simulation des Startparametervektors  $\rho_0$ , die Diagramme b), f) und j) die Verläufe der letzten Iteration und die Diagramme c), g) und k) die Verläufe des optimierten Parametervektors  $\hat{\rho}$ . Dabei sind in a), b) und c) die Verläufe der Stellgröße  $u$ , in e), f) und g) die Verläufe der Sollgröße  $y_d$  sowie der Regelgröße  $y$  und in i), j) und k) die Verläufe der Regelabweichung  $e$  dargestellt. Die Entwicklung des Parametervektors  $\rho$  ist im Diagramm d) und die Entwicklung der normierten 2-Norm der Regelabweichung über die durchgeführten Iterationen  $k$  in Diagramm h) abzulesen. Die Normierung ist auf den Wert der Ausgangsmessung bezogen. Es lässt sich feststellen, dass die Regelabweichung, welche durch die Startparametrierung  $\rho_0$  entsteht, minimiert wird. Durch den Einsatz der ILR sinkt die normierte 2-Norm des Regelfehlers auf unter 5% des Ausgangsfehlers. Wie in dem Verlauf des Regelfehlers der letzten ILR-Iteration zu sehen, ist der Regelfehler im Bereich der Regelgröße fast auf null reduziert. Da die gegebene Vorsteuerungsstruktur den Prozess nicht exakt invertiert, existiert kein Parametervektor  $\hat{\rho}$ , der diesen Verlauf nachbilden kann. Somit kommt es nach der Optimierung des Parametervektors zu einer Verschlechterung des Ergebnisses.

Weitere Simulationen zeigen, dass in diesem Anwendungsfall nicht mehr als 20 Iterationen notwendig sind, um das Optimierungsziel zu erreichen. Im Anhang sind zusätzliche Simulationsergebnisse aufgeführt. So ist während der Simulation

- in Abb. B.4 der Regelgröße ein zusätzliches weißes Messrauschen (Standardabweichung  $\sigma_y = 60 \text{ mbar}$ ) aufgeprägt und

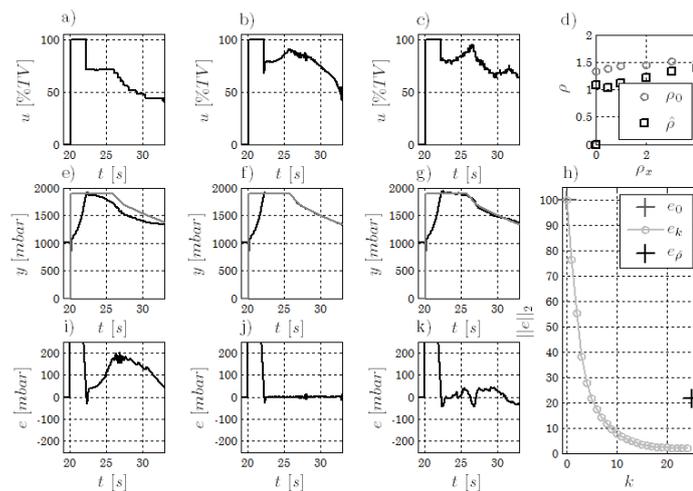


Abbildung 6.6. Simulationsergebnis der Variante I für das stationäre Kennfeld (ohne Variation)

- in Abb. B.5 ein geänderter Startparametervektor der Ausgangspunkt.

Das zusätzliche Messrauschen zeigt nur geringe Auswirkungen auf den optimierten Parametervektor. Der geänderte Startparametervektor bewirkt in diesem Fall das Erreichen der Stellgrößenbegrenzung. Damit ist auch der Regelfehler begrenzt. Aus Gründen der Vergleichbarkeit ist der Verlauf der 2-Norm auf den Ausgangswert der Simulation aus Abb. 6.6 normiert. Dadurch liegt in dieser Simulation der Ausgangswert bei 63,9%. Die erreichten Endergebnisse aller Simulationen zeigen vergleichbare Ergebnisse, so dass diese Methodik ein geeignetes Verfahren darstellt.

### 6.2.2. Einstellung der dynamischen Vorsteuerung der LDR

Die zu ermittelnden Parameter der dynamischen Vorsteuerung sind drehzahlabhängig und bei der Verwendung des Verfahrens Variante I auf einem Rollenprüfstand bei konstanter Drehzahl zu bestimmen. In Abb. 6.7 ist das Ergebnis der Optimierung im Arbeitspunkt  $n_{mot,AP} = 3000 \frac{U}{min}$  dargestellt.

Die Diagramme a), e) und h) dokumentieren den Ausgangszustand. Bei der Aktivierung der Ladedruckanforderung stellt die Ausgangsstellgröße einen Sprung durch  $u_0 = 60 \%TV$  dar und bewirkt den Verlauf der Regelgröße unterhalb des Sollwertes. In den Diagrammen b), f) und i) ist das Ergebnis der ILR-Lernphase dargestellt. Der erreichte Endzustand weist eine normierte 2-Norm des Ausgangsregelfehlers von 35,2% auf bei einem geringen Überschwingen von 20 mbar. Nach 5 Zyklen ist der Lernvorgang beendet. Die Diagramme c), g) und j) zeigen die Verläufe der optimierten Vorsteuerung. Der Arbeitsschritt der Parameteroptimierung ermittelt die Parameter  $\hat{\rho} = \rho_t = 19,5$  und liefert eine normierte 2-Norm des Ausgangsregelfehlers von 36,3% mit einem Überschwingen von 30 mbar. Die ermittelten Parameter bilden damit das gelernte Verhalten des ILR-Stellgrößenverlaufes ausreichend genau nach. Der Verlauf der 2-Norm des Regelfehlers ist über die Iterationen in Diagramm d) dargestellt.

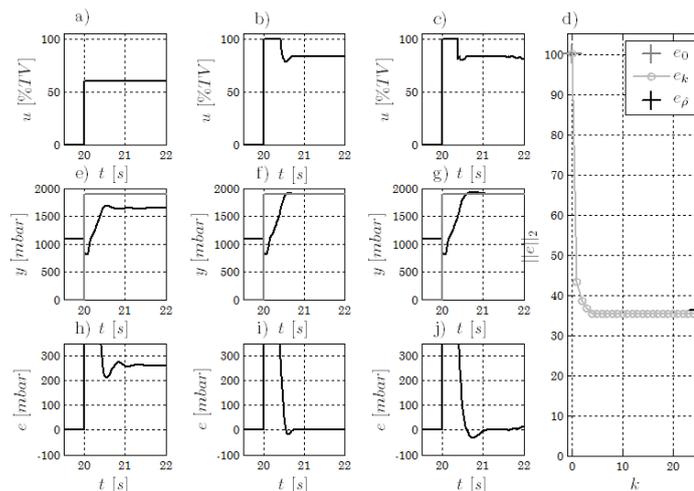


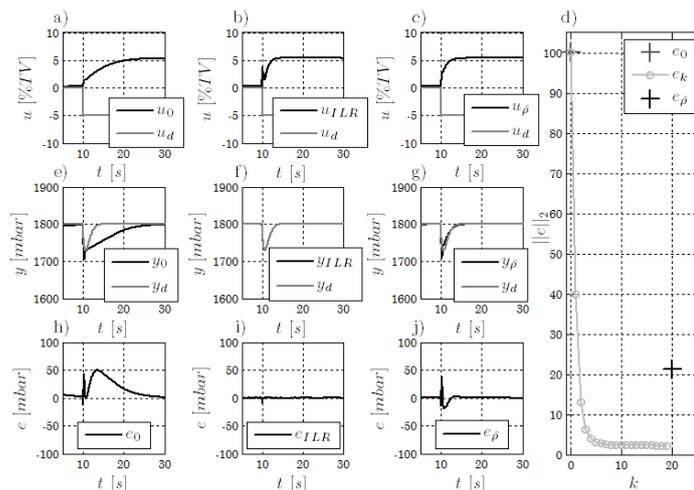
Abbildung 6.7. Simulationsergebnis der Variante I für die dynamische Vorsteuerung

### 6.2.3. Einstellung des Reglers der LDR

Ziel der Optimierung ist es, die Parameter des PI-Reglers für ein vorgegebenes Störverhalten zu ermitteln. Für den Entwurf der drehzahlabhängigen Reglerparameter  $K_P$  und  $K_I$  ist das Fahrzeug auf einem Rollenprüfstand in den jeweiligen Arbeitspunkt zu fahren und durch eine Störung der Eingangsgröße  $u$  anzuregen. Die sprunghafte Störung  $u_d$  tritt zum Zeitpunkt  $t = 10\text{ s}$  mit einer Höhe von  $-5\%TV$  auf. Dabei ist der Regler mit der Startparametrierung  $K_{P,0} = 0,01$  und  $K_{I,0} = 0,01$  während der ersten Messung aktiviert und dient zur Bestimmung des Stellgrößenverlaufes  $u_0$  der Ausgangsiteration  $k = 0$ . Danach ist die Regelstruktur deaktiviert und das gespeicherte Stellsignal der ILR dient zur Steuerung des Ladedruckes. Erreicht die ILR ihren Endzustand, findet die Optimierung der Reglerparameter statt.

Die Abb. 6.8, B.6 und B.7 stellen Beispiele zu den durchgeführten Simulationen dar. Dabei ist in den Diagrammen a), e) und h) der Ausgangspunkt, in den Diagrammen b), f) und i) der Endzustand der ILR und in den Diagrammen c), g) und j) das Ergebnis der Parameteroptimierung dargestellt. Das Diagramm d) zeigt den Verlauf der normierten 2-Norm des Regelfehlers. Die Diagramme a), b) und c) dokumentieren die jeweiligen Stellgrößenverläufe  $u$  und die Störgröße  $u_d$ . Die Diagramme e), f) und g) präsentieren die Verläufe der Regelgröße  $y$  und des Wunschstörverhaltens  $y_d$  und die Diagramme h), i) und j) zeigen die Verläufe der Regelabweichung  $e$ .

In Abb. 6.8 ist das Ergebnis für den Arbeitspunkt  $n_{mot,AP1} = 2000 \frac{U}{min}$  ohne zusätzliche Störungen dargestellt. Deutlich zu erkennen ist die Regelabweichung des Ausgangspunktes, die einen Höchstwert von  $max(e_0) \geq 50\text{ mbar}$  aufweist und erst nach  $15\text{ s}$  ausgeglet ist. Die ILR ist in der Lage, einen Stellgrößenverlauf  $u_{ILR}$  zu bestimmen, der den Regelfehler zum Wunschverhalten auf nahezu null bringt. Dazu sind weniger als 10 Iterationen notwendig. Die erreichte 2-Norm des Regelfehlers beträgt  $2,4\%$  des Ausgangswertes. Aus dem Regelfehler zwischen Wunschverhalten und Sollwert, sowie dem ermittelten Stellgrößenvektor  $u_{ILR}$  erfolgt die Parameteroptimierung von  $K_P = 0,021$  und  $K_I = 0,043$ . Diese Parameter geben bestmöglich das ILR-Ergebnis wieder. Der Test



**Abbildung 6.8.** Simulationsergebnis der Variante I für den Regler (AP1, ohne Messrauschen)

mit den so ermittelten Parametern zeigt, dass das ILR-Ergebnis auf Grund der nichtlinearen Strecke nicht exakt durch den PI-Regler darstellbar ist. Der erreichte Wert der 2-Norm beträgt hierbei 21,2%.

Auftretendes Messrauschen wie es in Abb. B.6 zu sehen ist, hat nur geringen Einfluss auf die optimierten Reglerparameter  $K_P = 0,020$  und  $K_I = 0,049$ . Der erreichte Wert der 2-Norm beträgt 54,8% und ist durch das Rauschniveau der Regelgröße begründet. Abb. B.7 zeigt das Simulationsergebnis für einen weiteren Arbeitspunkt  $n_{mot,AP2} = 3500 \frac{U}{min}$  mit zusätzlichem Messrauschen. Die ermittelten Reglerparameter sind  $K_P = 0,059$  und  $K_I = 0,068$ .

#### 6.2.4. Einstellung des Reglers des BLDC-Motorprüfstandes

In Abb. 6.9 ist das Simulationsergebnis der Optimierung durch das ILR-basierte Einstellungsverfahren Variante I bei der Einstellung des PI-Reglers am BLDC-Motorprüfstand dargestellt.

Diagramm a) zeigt den Verlauf der Stellgröße ohne Vorsteuertrajektorie und den Verlauf der Störangregung  $u_d$ .

$u_0$  ist der Ausgangspunkt der Optimierung mit aktivem PI-Regler ( $K_{P,0} = 0,017$ ,  $K_{I,0} = 0,017$ ) und  $u_{ILR}$  das Optimierungsergebnis der ILR.  $u_{\hat{p}}$  stellt den Verlauf, der durch die optimierten Reglerparameter entsteht, dar. Das Diagramm c) dokumentiert den Verlauf der Größen  $y_0$  (Ausgangsverlauf),  $y_d$  (gewünschter Sollverlauf als Reaktion auf die Störung),  $y_{ILR}$  (Optimierungsergebnis der ILR) und  $y_{\hat{p}}$  (Verlauf des optimierten PI-Reglers). Das Diagramm d) zeigt die dazugehörigen Verläufe der Regelabweichung. Der Trend des Optimierungsverlaufes ist in Diagramm b) zu sehen. Hier ist die 2-Norm der Regelabweichung normiert auf den Ausgangspunkt  $e_0$  dargestellt. Die Iteration  $k = 21$  präsentiert das Ergebnis der optimierten Parameter des PI-Reglers.

Nach dem Erreichen des Arbeitspunktes ( $n_W = 100 \frac{U}{min}$ ) erfolgt zum Zeitpunkt  $t = 15s$  eine Anregung des Prozesses durch einen Sprung der Stellgröße um  $u_d = -0,075 V$ . Nach 20 Iterationen ist das Optimierungsziel der ILR mit 10% der 2-Norm der Ausgangs-

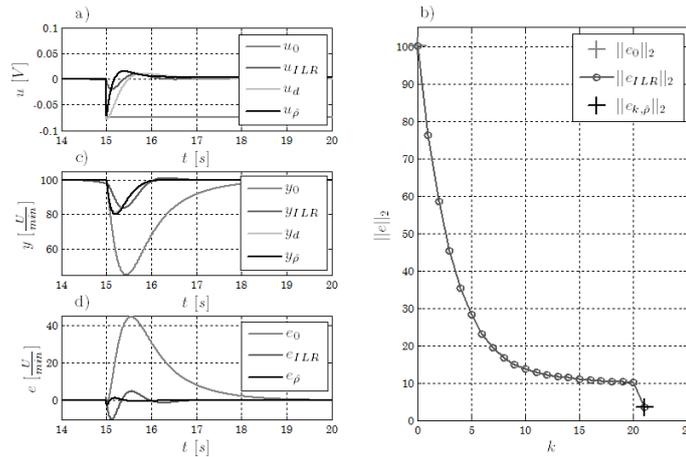


Abbildung 6.9. ILR-Parametereinstellung am BLDC-Prüfstand (Simulation Variante I)

regelabweichung erreicht. Die daraus ermittelten Reglerparameter sind  $K_P = 0,034$  und  $K_I = 0,099$ . Die bestmögliche Wiedergabe des ILR-basierten Stellgrößenverlaufes durch einen linearen PI-Regler erreicht dabei 3,6% der 2-Norm der Ausgangsregelabweichung.

### 6.3. Simulationen zum ILR-basierten Selbsteinstellungsverfahren - Variante II

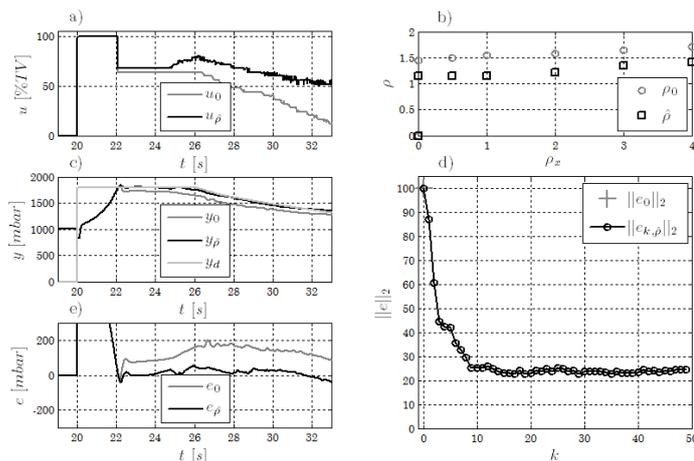
Dieser Abschnitt zeigt die Simulationsergebnisse des ILR-basierten Selbsteinstellungsverfahrens Variante II. Dieses Verfahren zielt auf Anwendungen, die eine aktive Regelungsstruktur benötigen oder ein Aufprägen eines Stellgrößenverlaufes nicht zulassen. Dies stellt einen möglichen Anwendungsfall für die Parametrierung der Ladedruckregelung dar, da sich hier normale Straßenmessungen verwenden lassen.

#### 6.3.1. Einstellung der stationären Vorsteuerung der LDR

Für die Einstellung der stationären Vorsteuerung sind, wie in Abschnitt 5.3.1 beschrieben, Beschleunigungsfahrten beginnend bei möglichst niedriger Motordrehzahl bis zur maximalen Motordrehzahl durchzuführen. Die Abb. 6.10 zeigt das Simulationsergebnis der Parametereinstellung im 3. Gang. Diese Simulation stellt den Grundfall dar. Darin werden keine zusätzlichen Störungen, Parameterschwankungen oder Messrauschen berücksichtigt.

Das Diagramm a) zeigt die Stellgrößenverläufe der Startparametrierung  $\mathbf{u}_0$  und des Optimierungsergebnisses  $\mathbf{u}_\rho$ . Im Diagramm c) sind die Verläufe der Sollgröße  $\mathbf{y}_d$  und die zu den Stellgrößen gehörigen Regelgrößen  $\mathbf{y}_0$  und  $\mathbf{y}_\rho$  dargestellt. Weiterhin lassen sich in dem Diagramm e) die resultierenden Regelabweichungen  $\mathbf{e}_0$  und  $\mathbf{e}_\rho$  erkennen. Die Entwicklung des Parametervektors  $\boldsymbol{\rho}$  ist in Diagramm b) und die Entwicklung der normierten 2-Norm der Regelabweichung über die durchgeführten Iterationen  $k$  in Diagramm d) abzulesen. Die Normierung ist auf den Wert der Ausgangsmessung bezogen.

Es ist deutlich zu erkennen, dass die Regelabweichung, welche durch die Startpara-



**Abbildung 6.10.** Simulationsergebnis der Variante II für das stationäre Kennfeld (ohne Variation)

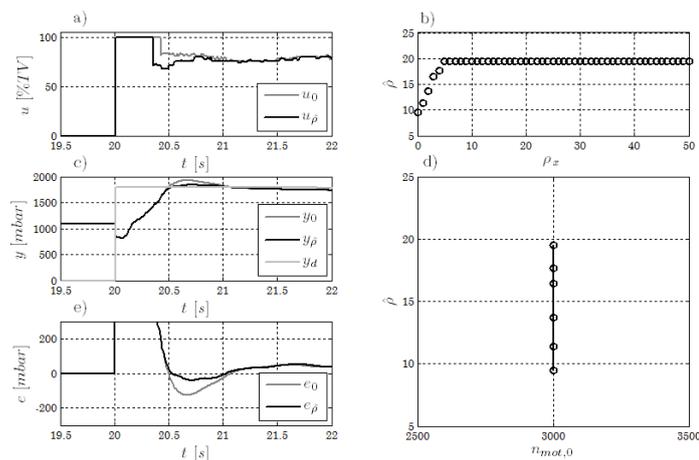
metrierung  $\rho_0$  entsteht, minimiert wird. Weitere Simulationen zeigen, dass in diesem Anwendungsfall nicht mehr als 10 Iterationen notwendig sind, um das Optimierungsziel zu erreichen. Im Anhang sind zusätzliche Simulationsergebnisse aufgeführt. So ist während der Simulation

- in Abb. B.8 der Regelgröße ein zusätzliches weißes Messrauschen (Standardabweichung  $\sigma_y = 60 \text{ mbar}$ ) aufgeprägt,
- in Abb. B.9 eine zufällige Streuung der Startparameter Motordrehzahl  $\sigma_{nmot} = 120 \frac{U}{min}$  und Solldruck  $\sigma_{psoll} = 60 \text{ mbar}$  aktiv und
- in Abb. B.10 ein geänderter Startparametervektor der Ausgangspunkt.

Das zusätzliche Messrauschen hat nur einen geringen Einfluss auf das Endergebnis. Die Streuung der Startparameter hat insofern einen Einfluss auf den Optimierungsvorgang, wenn Arbeitspunkte des einzustellenden Kennfeldes nicht erreichbar sind und damit weitere Iterationen notwendig werden. Die allgemeine Problematik der ILR mit veränderlichen Startwerten kommt hier nicht zum Tragen. Nach jeder Iteration ist die IRL durch die Parameterschätzung unterbrochen und beginnt danach wieder neu. Der geänderte Startparametervektor bewirkt in diesem Fall das Erreichen der Stellgrößenbegrenzung. Damit ist auch der Regelfehler begrenzt. Aus Gründen der Vergleichbarkeit ist der Verlauf der 2-Norm auf den Ausgangswert aus der Simulation von Abb. 6.10 bezogen. Dadurch liegt in dieser Simulation der Ausgangswert bei 44,1%. Die erreichten Endergebnisse aller Simulationen zeigen vergleichbare Ergebnisse, so dass dieses Verfahren einsetzbar ist.

### 6.3.2. Einstellung der dynamischen Vorsteuerung der LDR

Dieser Abschnitt präsentiert die Simulationsergebnisse der Anwendung des ILR-basierten Selbsteinstellungsverfahrens Variante II an der dynamischen Vorsteuerung der LDR. Wie in Abschnitt 5.3.2 beschrieben, lässt sich diese Parametereinstellung nur über den Weg einer ILR-Güteindex-basierten Selbsteinstellung realisieren.



**Abbildung 6.11.** Simulationsergebnis der Variante II für die dynamische Vorsteuerung (ohne Variation)

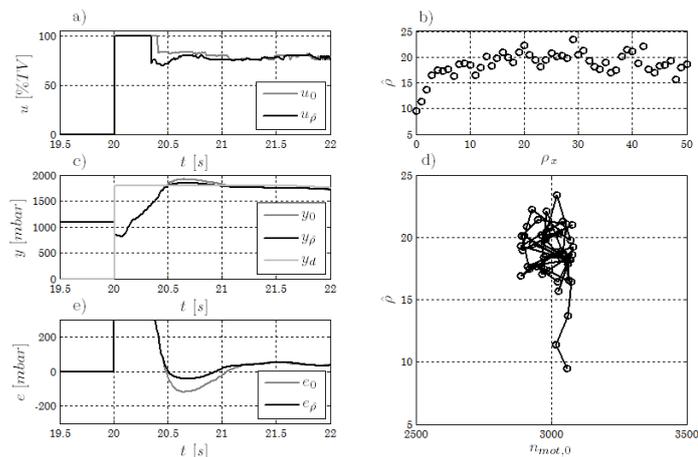
Die folgenden Simulationsergebnisse zeigen die Einstellung der dynamischen Vorsteuerung im Arbeitspunkt  $n_{mot,AP} = 3000 \frac{U}{min}$ . Abb. 6.11 stellt die Verläufe der Optimierung ohne zusätzliches Messrauschen und ohne weitere Störungen dar. Diese Simulation stellt somit den bestmöglichen Anwendungsfall dar. Dabei sind im Diagramm a) der Verlauf der Stellgrößen  $\mathbf{u}_0$  (Startparametrierung) und  $\mathbf{u}_\rho$  (Optimierungsergebnis), im Diagramm c) der Verlauf der Regelgrößen  $\mathbf{y}_0$  (Startparametrierung),  $\mathbf{y}_\rho$  (Optimierungsergebnis) und der Verlauf des Sollwertes  $\mathbf{y}_d$  und im Diagramm e) die dazugehörigen Verläufe der Regelabweichung  $\mathbf{e}_0$  und  $\mathbf{e}_\rho$  aufgeführt. Das Diagramm b) stellt den Trend des Parameters  $\rho$  über die Iterationen  $k$  und das Diagramm d) über den erreichten Arbeitspunkt der Motordrehzahl  $n_{mot}$  dar.

Es zeigt sich, dass die Einstellung des Parameters mit diesem Verfahren möglich ist. Der erreichte Wert im Arbeitspunkt  $n_{mot,AP} = 3000 \frac{U}{min}$  liegt bei  $\rho_t = 19,5$ . Bei Fahrversuchen auf der Straße ist das Einstellen eines konstanten Arbeitspunktes nicht möglich und es ist mit dem Auftreten einer Streuung zu rechnen.

Abb. 6.12 und Abb. B.11 zeigen die Auswirkungen dieser Streuung und zusätzliches Messrauschen auf die Parameterschätzung. Die Streuung in Abb. 6.12 mit der Standardabweichung von  $\sigma_{nmot,AP} = 60 \frac{U}{min}$  führt zu einem Rauschen des Optimierungsparameters mit dem Mittelwert  $\bar{\rho} = 19,1$  und der Standardabweichung  $\sigma_\rho = 1,1$ . In Abb. B.11 bewirkt die Streuung der Motordrehzahl mit der Standardabweichung  $\sigma_{nmot,AP} = 120 \frac{U}{min}$  einen Mittelwert des Optimierungsparameters  $\bar{\rho} = 18,8$  und der Standardabweichung  $\sigma_\rho = 1,5$ . Dies stellt eine besondere Herausforderung an das Selbsteinstellungsverfahren bei Straßenfahrten dar. Ist die Wiederholbarkeit der Messungen z.B. durch einen Rollenprüfstand gegeben, lässt sich die Anwendung dieses Verfahrens deutlich erleichtern.

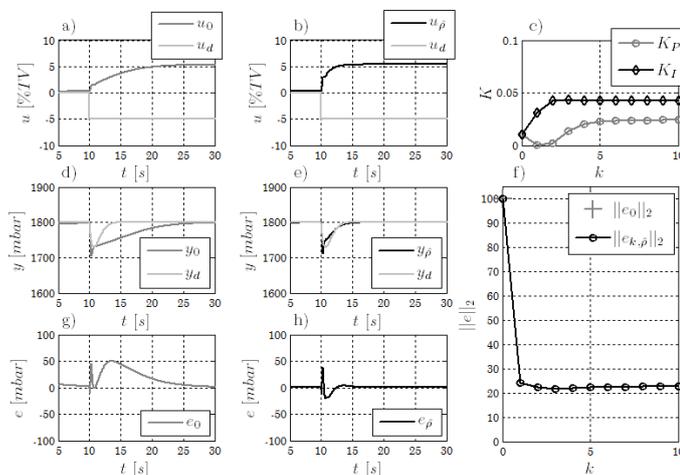
### 6.3.3. Einstellung des Reglers der LDR

Wie in Abschnitt 6.2.3 sind auch in diesem Fall die Parameter des PI-Reglers so zu optimieren, dass ein gewünschtes Störübertragungsverhalten eintritt. In Abb. 6.13 ist



**Abbildung 6.12.** Simulationsergebnis der Variante II für die dynamische Vorsteuerung (mit Messrauschen und zufälligen Startbedingungen (I))

die Simulation der Optimierung im Arbeitspunkt  $n_{mot,AP1} = 2000 \frac{U}{min}$  dargestellt. Die Diagramme a), d) und g) zeigen die Verläufe der Startparametrierung  $\rho_0$ . In den Diagrammen b), e) und h) sind die Verläufe des Optimierungsergebnisses  $\hat{\rho}$  zu sehen. Die Diagramme a) und b) stellen die Verläufe der Stellgrößen  $u_0$  und  $u_{\hat{\rho}}$  sowie die Störung  $u_d$  dar. In d) und e) sind die dazugehörigen Verläufe der Regelgrößen  $y_0$  und  $y_{\hat{\rho}}$  mit dem Sollwert  $y_d$  und in g) und h) die Verläufe der jeweiligen Regelabweichungen  $e_0$  und  $e_{\hat{\rho}}$  abgebildet. Das Diagramm c) zeigt die Entwicklung der Reglerparameter  $K_P$  und  $K_I$ , während im Diagramm f) der Trend der 2-Norm des Regelfehlers, normiert auf den Ausgangsregelfehler, dargestellt ist.



**Abbildung 6.13.** Simulationsergebnis der Variante II für den Regler (AP1, ohne Messrauschen)

Beginnend mit den Startparametern des Reglers  $K_{P,0} = 0,01$  und  $K_{I,0} = 0,01$  tritt zum Zeitpunkt  $t = 10s$  eine sprunghafte Störung von  $-5 \%TV$  am Stelleingang auf. Die Auswirkungen dieser Störانregung sind in den Diagrammen d) und g) zu sehen. Es

zeigt sich, dass der Abbau dieser Störung durch den Regler mit der Startparametrierung  $\hat{\rho}_0$  erst nach mehr als 15 s erfolgt. Dabei tritt eine maximale Regelabweichung von  $\max(e_0) \geq 50 \text{ mbar}$  auf. Diese Reglereinstellung zeigt eine zu langsame Reaktion beim Abbau der Störung - die Beschleunigungsfahrten von z.B. Abb. 6.10 oder B.8 dauern weniger als 15 s. Für die Vorgabe des Wunschverhaltens  $y_d$  gilt daher, dass die Störung in weniger als 3s und mit einer maximalen Regelabweichung von  $\max(e) \leq 25 \text{ mbar}$  zu kompensieren ist.

Nach der iterativen Optimierung ist die Parametereinstellung  $\hat{\rho}$  mit  $K_P = 0,024$  und  $K_I = 0,042$  erreicht. Nach nur 2 Iterationen tritt keine weitere Verbesserung mehr auf und die erreichte 2-Norm des Regelfehlers liegt bei 22,6% des Ausgangsregelfehlers. Die Anforderungen des Wunschverhaltens sind realisiert. Die Abweichungen vom Wunschverhalten können durch einen linearen Regler kompensiert werden. Die Abb. B.12 zeigt die gleiche Simulation mit zusätzlich auftretendem Messrauschen auf dem Messsignal der Regelgröße während der ILR-Verarbeitung. Auf das Lernergebnis hat dieses Rauschsignal nur geringe Auswirkungen. Die ermittelten Reglerparameter liegen bei  $K_P = 0,027$  und  $K_I = 0,045$ . Die normierte 2-Norm des Regelfehlers beträgt 45,5%. Die Ursache dafür ist das Messrauschen. Für den Arbeitspunkt  $n_{mot,AP2} = 3500 \frac{U}{min}$  in Abb. B.13 ergibt die Selbsteinstellung bei gleichem Wunschverhalten die Reglerparameter  $K_P = 0,057$  und  $K_I = 0,063$ .

#### 6.3.4. Einstellung des Reglers des BLDC-Motorprüfstandes

In Abb. 6.14 ist das Simulationsergebnis der Optimierung durch das ILR-basierte Selbsteinstellungsverfahren Variante II bei der Einstellung des PI-Reglers am BLDC-Motorprüfstand dargestellt. Dabei ist der PI-Regler dauerhaft aktiv und wird nach jeder Iteration angepasst. Die Ausgangsparameter sind  $K_{P,0} = 0,017$  und  $K_{I,0} = 0,017$ . Im

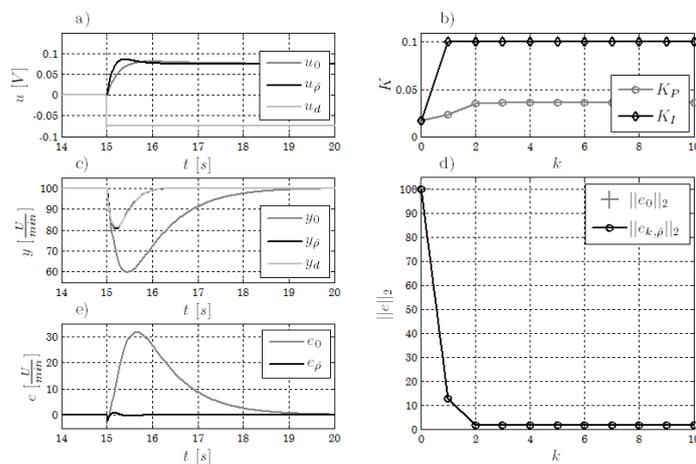


Abbildung 6.14. ILR-Parametereinstellung am BLDC-Prüfstand (Simulation der Variante II)

Diagramm a) ist der Verlauf der Stellgröße ohne Vorsteuertrajektorie und der Verlauf der Störangeregung  $u_d$  dargestellt, wobei  $u_0$  der Ausgangspunkt und  $u_{\hat{\rho}}$  das Optimierungsergebnis ist. Das Diagramm c) zeigt den Verlauf der Regelgrößen (den Ausgangsverlauf

$y_0$ , den gewünschte Sollverlauf  $y_d$  als Reaktion auf die Störung, den Verlauf des optimierten PI-Reglers  $y_{\hat{p}}$ ). Das Diagramm *e*) dokumentiert die dazugehörigen Verläufe der Regelabweichungen. Der Trend des Optimierungsverlaufes ist in Diagramm *d*) zu sehen. Hier ist die 2-Norm der Regelabweichung normiert auf den Ausgangspunkt  $e_0$  dargestellt. Das Diagramm *b*) zeigt die Entwicklung der Reglerparameter über die Iterationen  $k$ .

Nach dem Erreichen des Arbeitspunktes ( $n_W = 100 \frac{U}{min}$ ) erfolgt zum Zeitpunkt  $t = 15 \text{ s}$  eine Anregung des Prozesses durch einen Sprung der Stellgröße um  $u_d = -0,075 \text{ V}$ . Bereits nach 2 Iterationen ist das Optimierungsziel mit 1,7% der 2-Norm der Ausgangsregelabweichung erreicht. Es tritt keine Verbesserung mehr auf. Die daraus ermittelten Reglerparameter sind  $K_P = 0,036$  und  $K_I = 0,100$ .

## 6.4. Tests im Fahrzeug und am BLDC-Motorprüfstand

Dieser Abschnitt dokumentiert die Anwendung der entwickelten Selbsteinstellungsverfahren an realen Prozessen. Der erste Teil zeigt die Ergebnisse der Einstellung der Vorsteuerung eines Testfahrzeuges (VW Sharan mit 1,8 l Motor). Die Tests erfolgten bei Straßenfahrten, die nur den Einsatz des Selbsteinstellungsverfahrens Variante II ermöglichen. Im zweiten Teil ist die Selbsteinstellung der Reglerparameter eines PI-Reglers eines BLDC-Motorprüfstandes dargestellt. Auch in diesem Fall kommt das ILR-basierte Einstellungsverfahren Variante II zum Einsatz, da hier die Simulationen die besseren Ergebnisse zeigten.

### 6.4.1. Darstellung der Fahrversuche

Die Abb. 6.15 dokumentiert ein Beispiel einer Beschleunigungsfahrt auf der Straße im dritten Gang. Das Diagramm *a*) zeigt den Aktivierungszeitraum des aufgeladenen Bereiches durch das Aktivierungsbit  $B_{LDR}$ . Der Grund der Aktivierung ist eine Betätigung des Gaspedals durch den Fahrer, die einen Beschleunigungswunsch kennzeichnet. Diese erhöhte Anforderung eines Antriebsmomentes ist durch eine höhere relative Luftfüllung  $r_{l,soll}$  erreichbar (Diagramm *b*). Daraus ergibt sich der Sollladedruck  $y_d$  und der Istladedruck  $y$  in Diagramm *e*) sowie der Verlauf der Stellgröße  $u$  in Diagramm *d*). Abschließend ist in Diagramm *c*) der Trend der Motordrehzahl  $n_{mot}$  dargestellt.

### 6.4.2. Realisierung von Variante II für die stationäre Vorsteuerung der LDR

Der praktische Test zur Einstellung des stationären Vorsteuerkennfeldes erfolgt im Fahrzeug gangabhängig mit deaktiviertem PI-Regler und mit verschiedenen Startparameterkonfigurationen. Zum Einsatz kommt Variante II des ILR-basierten Einstellungsverfahrens.

Abb. 6.16 zeigt ein Optimierungsbeispiel im 2. Gang. Die Diagramme *a*), *d*) und *g*) stellen den Ausgangspunkt und die Diagramme *b*), *e*) und *h*) das Optimierungsergebnis dar. Dabei zeigen die Diagramme in der ersten Zeile die Regelgröße  $y$  und den Sollwert  $y_d$ , die Diagramme in der zweiten Zeile die aufgetretene Regelabweichung  $e$  und die Diagramme in der dritten Zeile die Stellgröße  $u$ . In Diagramm *c*) ist die Entwicklung des

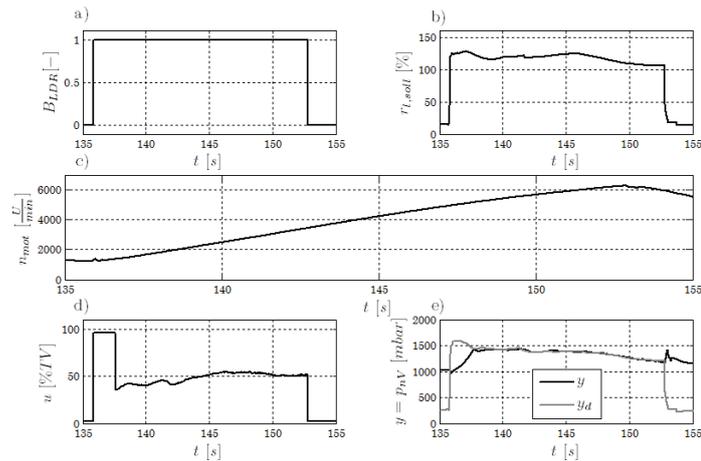


Abbildung 6.15. Beispielmessung für eine Straßenfahrt des Testfahrzeugs

normierten Parametervektors und in Diagramm *f*) der Trend der normierten 2-Norm der Regelabweichung dargestellt. Im Bereich der begrenzten Stellgröße tritt eine große Regelabweichung auf, die nicht beeinflussbar ist. Danach zeigt der Vergleich der Regelabweichungen eine deutliche Reduzierung der Regelabweichung nach der Optimierung. In diesem Beispiel ist das Optimierungsziel nach 4 Iterationen erreicht und es treten keine weiteren Verbesserungen auf. Weitere praktische Versuche bestätigen diese hohe Lernrate und erreichen das Optimierungsziel in weniger als 10 Iterationen.

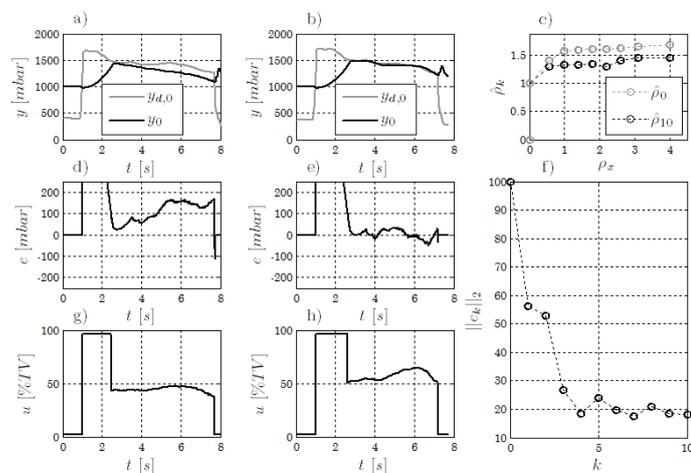


Abbildung 6.16. ILR-Parametereinstellung der stationären Vorsteuerung

In Abb. 6.17 ist die Entwicklung des Parametervektors nach der ersten Iteration bei unterschiedlichen Startparameterkonfigurationen in den Fällen *a*), *b*) und *c*) dargestellt. Dabei kennzeichnen die hellgrauen „x“-Datenpunkte den Ausgangsparametervektor  $\hat{p}_0$ , die schwarzen „o“-Datenpunkte den Parametervektor nach der ersten Iteration  $\hat{p}_1$  und die dunkelgrauen „+“-Datenpunkte den Zielparametervektor  $\hat{p}_Z$ . Prinzipiell ist zu erkennen, dass sich nach der ersten Messfahrt die Parameter in Richtung Zielbereich bewegen

und es zu keiner Verschlechterung kommt. Bei großen Abständen der Parameter von den Zielparametern tritt meist eine hohe Regelabweichung auf, die auch eine hohe Lernrate bewirkt. Dies hat zur Folge, dass auch die Parameter eine große Änderung erfahren. In Diagramm a) ist deutlich zu erkennen, dass sich der 2. bis 4. Parameter des Parametervektors  $\hat{p}$  kaum ändert. Der Grund hierfür ist die geringe Anregung des Prozesses in diesem Arbeitspunkt.

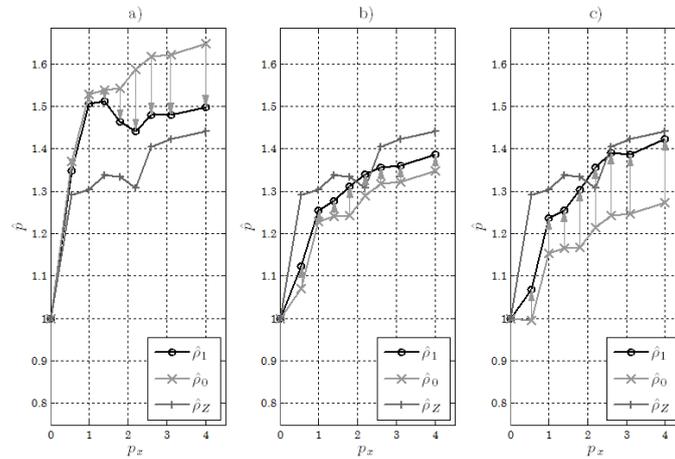


Abbildung 6.17. Trend der ILR-Parametereinstellung bei unterschiedlichen Startparametern

### 6.4.3. Realisierung von Variante II für die dynamische Vorsteuerung der LDR

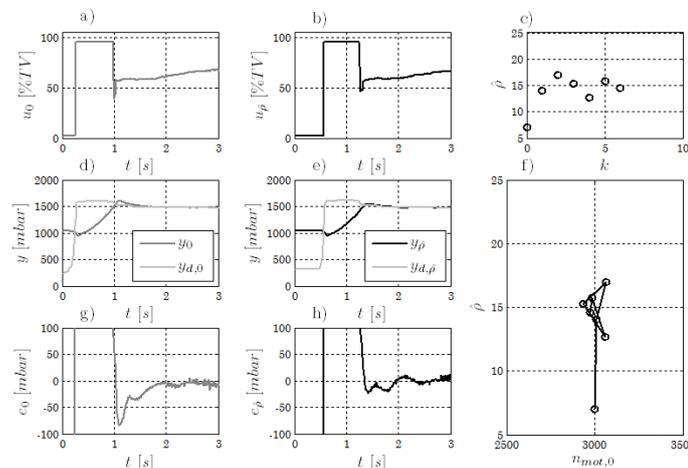


Abbildung 6.18. ILR-Parametereinstellung der dynamischen Vorsteuerung (I)

Die Abb. 6.18 und 6.19 zeigen die Ergebnisse der Optimierung des Parameters Prädiktionszeit der dynamischen Vorsteuerung. Diese Versuche erfolgen bei Straßenmessungen, die nur die Anwendung des ILR-basierten Einstellungsverfahrens Variante II erlauben.

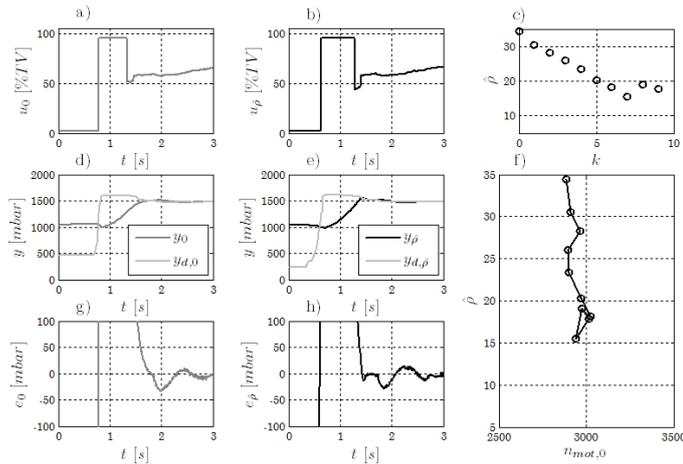


Abbildung 6.19. ILR-Parametereinstellung der dynamischen Vorsteuerung (II)

Reproduzierbare wiederholte Fahrversuche mit gleichen Startbedingungen und ein externes Aufprägen der Stellgröße sind bei Straßenfahrten nicht möglich bzw. nur mit hohem Aufwand realisierbar.

Beide Abbildungen dokumentieren die Parameterentwicklung der dynamischen Vorsteuerung an der Stützstelle  $n_{mot,AP} = 3000 \frac{U}{min}$ . In Abb. 6.18 ist der Startparameter kleiner und in Abb. 6.19 größer als das Optimierungsziel. Die Diagramme a), d) und g) zeigen die Verläufe der Ausgangsparametrierung und die Diagramme b), e) und h) die Verläufe des Optimierungsergebnisses. In Diagramm c) ist die Entwicklung des gesuchten Parameters über die Iterationen  $k$  und in Diagramm f) über die jeweilige erreichte Startdrehzahl dargestellt. Die Messergebnisse bestätigen die Ergebnisse der Simulationen und die besonderen Herausforderungen bei der Einstellung dieses Parameters. In diesem Fall ist die Verwendung eines Rollenprüfstandes mit der Einstellung eines konstanten Arbeitspunktes zu empfehlen.

#### 6.4.4. Realisierung von Variante II für den Regler des BLDC-Motorprüfstandes

Dieser Abschnitt zeigt das Ergebnis der Parametereinstellung des PI-Reglers am BLDC-Motorprüfstand. Der praktische Test erfolgt durch das ILR-basierte Einstellungsverfahren Variante II. Die Reglerstartparameter sind  $K_{P,0} = 0.017$  und  $K_{I,0} = 0.017$ . Durch eine Vorsteuertrajektorie erfolgt das Anfahren des Arbeitspunktes von  $n_{AP} = 100 \frac{U}{min}$ . Die Gesamtzeit des Zyklusses ist  $T = 30 s$  mit  $N = 30000$  Abtastwerten. Für die weitere Bearbeitung erfolgt eine Datenreduzierung um den Faktor 20 auf  $N = 1500$  Abtastwerte. Nach 15s tritt eine sprunghafte Störung mit einer Höhe von  $d = -0,075 V$  im Verlauf der Vorsteuerung auf. Ziel ist es, diese Störung innerhalb von 1 s abzubauen und ein Absinken der Drehzahl um mehr als  $\Delta n = 20 \frac{U}{min}$  zu verhindern. Abb. 6.20 zeigt den Ausgangszustand (graue Linien) und das Optimierungsergebnis (schwarze Linien). Die hellgrauen Linien kennzeichnen die Störanregung bzw. den Sollverlauf der Drehzahl. Im Diagramm a) sind die zeitlichen Verläufe der Stellgröße (Motorstrom in A), im Diagramm c) die Verläufe der Drehzahl und im Diagramm e) die Verläufe der Regelab-

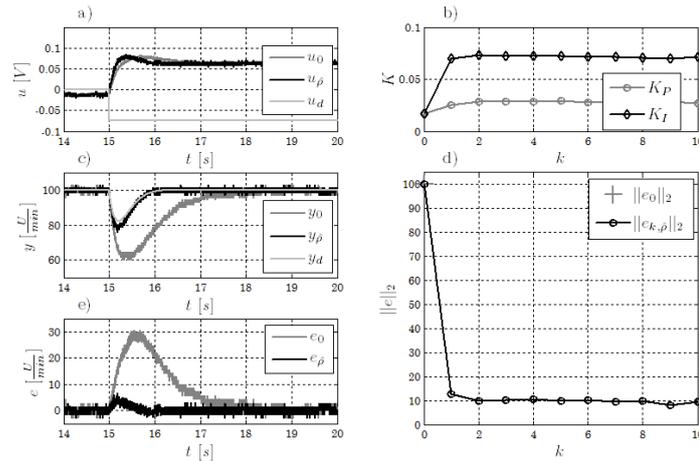


Abbildung 6.20. ILR-Parametereinstellung am BLDC-Prüfstand

weichung dargestellt. Die optimierten Reglerparameter ( $K_P = 0.029$  und  $K_I = 0.071$ ) dämpfen die eintretende Störung nach den gewünschten Sollvorgaben. Das Diagramm *b*) zeigt die Änderung der Reglerparameter  $K_P$  und  $K_I$  und das Diagramm *d*) den Trend von  $\|e_k\|_2$  (normiert auf den Ausgangsfehler  $\|e_0\|_2$ ) über 10 Iterationen. Auf Grund der verrauschten Signale erfolgt eine Filterung der Signale durch einen nullphasigen Tiefpass mit einer Grenzfrequenz von 10 Hz. Bei dem verwendeten Lerngesetz handelt es sich um einen inversions- und gradientenbasierten Ansatz. Damit ist das Optimierungsziel in nur 2 Iterationen erreicht und weist keine Verschlechterung nach weiteren Iterationen auf.

## 6.5. Diskussion und Bewertung

Die erreichten Ergebnisse in den durchgeführten Simulationen und experimentellen Versuchen bestätigen die Funktionsweise und die Einsatzfähigkeit der entwickelten Verfahren zur ILR-basierten Selbsteinstellung von Steuerungs- und Regelungsparametern.

### Einstellung der Ladedruckregelung

Die Simulationsergebnisse (Tabelle: 6.1) zeigen, dass unabhängig von den simulierten Szenarien die ermittelten Parameter reproduzierbar sind und die erreichte Regelgüte gleich bleibt. Die gewählten inversionsbasierten ILR-Ansätze können die geforderte monotone Konvergenz und eine geringe Anzahl von notwendigen Lerniterationen gewährleisten. Die formulierten Anforderungen an das Selbsteinstellungsverfahren sind damit erfüllt.

Beide Varianten des Selbsteinstellungsverfahrens liefern in der Simulation optimale Ergebnisse. In der Simulation sind die Rahmenbedingungen so eingestellt, dass auch die Variante I zum Einsatz kommen kann. Diese Variante benötigt wenige Iterationen bis zum Erreichen des Optimierungsbereiches der ermittelten Parameter. Allerdings ist die ILR-Stellgrößentrajektorie in diesem Fall noch nicht in ihrem Optimum und es erfolgen weitere Optimierungsiterationen. Dies lässt sich aber durch die gegebene Struktur

Test bedingung	Var.	Parameter	$\ e_{OPT}\ _2$
Stationäre Vorsteuerung, Grundmodell	I	$\hat{\rho} = [0 \quad 1,07 \quad 1,03 \quad 1,11 \quad 1,21 \quad 1,33 \quad 1,40]$	21,6%
Stationäre Vorsteuerung, Grundmodell	II	$\hat{\rho} = [0 \quad 1,14 \quad 1,14 \quad 1,14 \quad 1,22 \quad 1,34 \quad 1,41]$	24,0%
Stationäre Vorsteuerung, Messrauschen	I	$\hat{\rho} = [0 \quad 1,07 \quad 1,03 \quad 1,15 \quad 1,17 \quad 1,33 \quad 1,34]$	24,3%
Stationäre Vorsteuerung, Messrauschen	II	$\hat{\rho} = [0 \quad 1,11 \quad 1,14 \quad 1,14 \quad 1,23 \quad 1,33 \quad 1,40]$	24,4%
Stationäre Vorsteuerung, geänderter Startparametervektor	I	$\hat{\rho} = [0 \quad 1,07 \quad 1,08 \quad 1,12 \quad 1,20 \quad 1,33 \quad 1,40]$	23,8%
Stationäre Vorsteuerung, geänderter Startparametervektor	II	$\hat{\rho} = [0 \quad 1,10 \quad 1,10 \quad 1,11 \quad 1,22 \quad 1,31 \quad 1,37]$	24,7%
Stationäre Vorsteuerung, zufällige Startbedingungen	II	$\hat{\rho} = [0 \quad 1,09 \quad 1,11 \quad 1,12 \quad 1,21 \quad 1,32 \quad 1,39]$	23,1%
Dynamische Vorsteuerung, Grundmodell	I	$\rho_t = 19,5$	36,3%
Dynamische Vorsteuerung, Grundmodell	II	$\rho_t = 19,5$	36,3%
Dynamische Vorsteuerung, zufällige Startbedingungen (I)	II	$\rho_t = 19,1$	36,8%
Dynamische Vorsteuerung, zufällige Startbedingungen (II)	II	$\rho_t = 18,8$	45,5%
PI-Regler, AP1, kein Messrauschen	I	$K_P = 0,021, K_I = 0,043$	21,2%
PI-Regler, AP1, kein Messrauschen	II	$K_P = 0,024, K_I = 0,042$	22,6%
PI-Regler, AP1, Messrauschen	I	$K_P = 0,020, K_I = 0,049$	54,8%
PI-Regler, AP1, Messrauschen	II	$K_P = 0,027, K_I = 0,045$	45,5%
PI-Regler, AP2, Messrauschen	I	$K_P = 0,059, K_I = 0,068$	59,5%
PI-Regler, AP2, Messrauschen	II	$K_P = 0,057, K_I = 0,063$	52,6%

**Tabelle 6.1.** Vergleich der Simulationsergebnisse der Ladedruckregelung

nicht weiter abbilden. Die Variante II erreicht ähnliche Lernraten wie Variante I, da hier gleich das Optimum der gegebenen Struktur angelernt wird. Dies zeigt sich besonders während der Einstellung der stationären Vorsteuerung. ILR-Algorithmen können neben der stationären Genauigkeit auch optimale Ergebnisse bei dynamischen Verläufen liefern, z.B. beim Lernvorgang zur Einstellung der dynamischen Vorsteuerung. Das Selbsteinstellungsverfahren Variante I kann eine Stellgrößentrajektorie ermitteln, bei der schnellstmöglich der Sollwert erreicht und eingestellt wird. Aus diesem Verlauf ist der zu optimierende Parameter leicht zu ermitteln. Im Gegensatz dazu erfordert die Variante II eine Erweiterung des Verfahrens durch die Verwendung eines Bewertungsindex. Dies verringert die Lernrate und macht zusätzliche Iterationen notwendig. Die durchgeführten Simulationen zeigen die Abhängigkeit der erreichten Ergebnisse (Mittelwert und Streuung) von der Einstellgenauigkeit des Arbeitspunktes. Dies kennzeichnet prinzipiell die Problematik, einen Parameter, welcher ein zeitdiskretes Ereignis bewirkt, anhand einer Messung einzustellen. Die Bestimmung der Reglerparameter als Störregler erfordern definierte und messbare oder iterationsinvariante Störanregungen des Prozesses, welche sich auf einem Rollenprüfstand realisieren lassen. Ein solcher Rollenprüfstand ermöglicht gezielte Versuche in verschiedenen Drehzahlarbeitspunkten und damit die Bestimmung der Reglerparameter als Gain Scheduling über die Motordrehzahl. Weiterhin ist die Vorgabe des Wunschverhaltens für den Abbau der Störung notwendig. Nach jeder Iteration liegt ein ILR-Stellgrößenverlauf zur Parameteroptimierung vor. Beide Erweiterungen des ILR-basierten Selbsteinstellungsverfahrens (Variante I und II) liefern ähnliche Optimierungsergebnisse. Allerdings führt die im Kapitel 4.3 beschriebene Aus-

wirkung der Parameteroptimierung in jedem Iterationsschritt von Variante II dazu, dass das Ergebnis von Variante I nicht erreicht werden kann. Daher ist im Standardfall die 2-Norm des Regelfehlers der optimierten Parameter von Variante II größer als die von Variante I. Dieser Unterschied ist bei realistischen Versuchsbedingungen (z.B. mit Messrauschen) nicht mehr festzustellen. Weiterhin benötigt das Selbsteinstellungsverfahren Variante II mehr Iterationen.

Die Testergebnisse aus dem Fahrzeug bestätigen die Simulationsergebnisse. Diese Tests beruhen auf dem ILR-basierten Selbsteinstellungsverfahren Variante II, da hier nur normale Betriebsmessungen bei Straßenfahrten zur Verfügung stehen. Die Versuchsbedingungen der praktischen Messfahrten zeigen, dass die Anwendung der Variante I aufwändiger ist und kostenintensive Prüfstandszeit benötigt. Die starken Anforderungen nach wiederholbaren Iterationen und gleichen Start- und Umgebungsbedingungen erschweren den Einsatz dieser Methode. Weiterhin ist das Ersetzen der Regelungsstruktur durch eine Stellgrößentrajektorie im Falle der Ladedruckregelung nicht möglich.

Die ermittelten Steuergeräteparameter der Ladedruckregelung erfüllen die festgelegten Optimierungskriterien. Die Einstellung der stationären Vorsteuerung erfolgt durch Messungen bei Straßenfahrten, ist unabhängig von Start- und Umgebungsbedingungen und benötigt weniger als 10 Wiederholungen, die sich sehr schnell durchführen lassen. Da für die Einstellung dieses Kennfeldes der gesamte Fahrverlauf optimiert wird, stehen für die Parameteroptimierung viele Messdaten zur Verfügung. Werden während einer solchen Messung Betriebsbereiche nicht angefahren, gibt es keine Änderung der entsprechenden Parameter. In diesem Fall ist die Anregung nicht ausreichend und es sind weitere Fahrten durchzuführen. Im Gegensatz dazu besteht die Einstellung der dynamischen Vorsteuerung in der Optimierung eines diskreten Zeitpunktes, der der Abschaltung der Vollensteuerung des Stellgliedes entspricht. Daher stehen nur wenige Informationen durch eine einzelne Messung zur Verfügung. Dies erschwert die Bestimmung des Parameters. Eine große Streuung tritt auf, wenn der einzustellende Arbeitspunkt in den Messfahrten nicht genau angefahren wird. Diese Streuung lässt sich durch eine Gültigkeitsprüfung zum jeweiligen Arbeitspunkt während der Datenvorverarbeitung reduzieren. Zusammenfassend ist festzustellen, dass das Ergebnis der Selbsteinstellung der gesamten Vorsteuerung eine gut fahrbare und reproduzierbare Parametrierung ist.

### **Einstellung am BLDC-Prüfstand**

Die Einstellung des PI-Reglers am BLDC-Prüfstand erfolgt durch die Modifikation Variante II des Selbsteinstellungsverfahrens, da das integrale Streckenverhalten einen aktiven PI-Regler erfordert. Auf Grund des hohen Rauschanteils der Messsignale ist hier der Einsatz eines Q-Filters notwendig. Nach den durchgeführten Simulationen konnten erfolgreiche Tests am realen Prüfstand durchgeführt werden. Diese bestätigen die Simulationsergebnisse. In Tabelle 6.2 sind die ermittelten Parameter aus Simulationen und einem Testversuch am BLDC-Prüfstand dargestellt. Die erreichten Parameterwerte von  $K_P$  und  $K_I$  liegen in der Simulation für beide Varianten im gleichen Wertebereich. Auch die ermittelten Werte am Prüfstand sind unter der Berücksichtigung von Modellabweichungen vergleichbar mit den Simulationsergebnissen. Da an diesem Prozess nur geringe Nichtlinearitäten auftreten, ist eine genaue Bestimmung der Eingangs-Ausgangs-Matrix  $\mathbf{G}$  möglich, die sich während der Iterationen nicht ändert. In diesem Fall ist eine zusätz-

Testbedingung	Mod.	Parameter	$\ e_{OPT}\ _2$
Regler, Simulation, Grundmodell	V. I	$K_P = 0,034, K_I = 0,099$	3,6%
Regler, Simulation, Grundmodell	V. II	$K_P = 0,036, K_I = 0,100$	1,7%
Regler, Experiment, Prüfstand	V. II	$K_P = 0,029, K_I = 0,071$	10,0%

**Tabelle 6.2.** Vergleich der Ergebnisse am BLDC-Motorprüfstand

liche Begrenzung der Lernrate nicht notwendig und die ermittelten Parameter liegen nach der ersten Iteration im Bereich der finalen Parameterwerte.

# Kapitel 7.

## Zusammenfassung und Ausblick

Die vorliegende Arbeit beschäftigt sich mit der Thematik der Selbsteinstellung von Parametern bestehender Regelungsstrukturen und präsentiert zwei Verfahren der Selbsteinstellung. Die Verfahren basieren auf der Theorie der iterativ lernenden Regelungen. Die ILR stellt das Grundgerüst der Selbsteinstellungsverfahren dar und wird um eine Parameteroptimierung erweitert.

Die Motivation dieser Arbeit liegt in der Entwicklung von Werkzeugen, die die Parametrierung von bestehenden Regelungsstrukturen in Steuergeräten unterstützen und automatisieren sollen. Der Anwendungsschwerpunkt ist die Applikation der komplexen Vorsteuerungs- und Reglerstruktur der Ladedruckregelung eines einfach aufgeladenen Ottomotors mit einem Abgasturbolader und einem Wastegate. Ein zweite Anwendung beschäftigt sich mit der Parametrierung des PI-Reglers eines Prüfstandes für BLDC-Motoren.

Das Grundprinzip einer ILR-basierten Selbsteinstellung von Parametern basiert auf der Idee, dass eine ILR in jeder Iteration eine optimierte Stellgrößentrajektorie berechnen kann und diese Trajektorie durch die gegebene Regelungsstruktur zu realisieren ist. Die angewendete ILR liefert somit ein optimiertes Ausgangssignal der zu parametrierenden Regelungsstruktur. Die Aufgabe der Selbsteinstellung der Parameter lässt sich auf eine Parameteroptimierung zurückführen. In Kapitel 4 werden zwei verschiedene Ansätze entwickelt. Es endet mit einem Vergleich der jeweiligen Anwendungsbedingungen und den Vor- und Nachteile beider Ansätze. Die vorgestellten Verfahren erfordern keine zusätzliche und aufwändige Modellbildung. Sie nutzen einzig die Messdaten einer Applikationsmessung im Fahrzeug und sind daher zu den signalbasierten Verfahren zu zählen. Die verwendeten ILR-Verfahren sind so einzustellen, dass in jeder Iteration eine Verbesserung der Regelgüte erreicht wird, d.h. die ILR-Optimierung ist monoton konvergent. Gleichzeitig können diese Algorithmen hohe Lernraten gewährleisten und damit sowohl die Anzahl der durchzuführenden und notwendigen Versuche, als auch die Applikationszeit reduzieren.

Die Linearisierung um eine Trajektorie ermöglicht die Beschreibung des Systems entlang der Arbeitstrajektorie. Dies geschieht anhand der gemessenen Trajektorien der Stell- und Regelgröße des Prozesses ohne vorheriger Modellbildung. Dabei kommt es zu Abweichungen zwischen der gemessenen Starttrajektorie und der zu erreichenden Zieltrajektorie, die beim Entwurf der ILR-Algorithmen zu beachten sind. Dazu wird in Kapitel 4 die Berücksichtigung dieser Abweichungen durch additive bzw. multiplikative Modellunsicherheiten erläutert. Zusätzlich spielt die Realisierbarkeit der optimierten ILR-Stellgrößentrajektorie durch die vorgegebene Regelungsstruktur eine wichtige Rolle für die erreichbare Regelgüte des Verfahrens. Diese werden ebenfalls durch additive bzw. multiplikative Modellunsicherheiten berücksichtigt und gehen in den Entwurf der

ILR ein. Die Entwurfsparameter der ILR-Algorithmen reduzieren sich damit auf die Abschätzung der Modellunsicherheiten.

Das Kapitel 5 dokumentiert die Anwendung dieser Verfahren auf den nichtlinearen Prozess der Ladedruckregelung zur Parametrierung der nichtlinearen Vorsteuerung und des PI-Reglers. Dabei liegt der Anwendungsschwerpunkt auf dem in Kapitel 2 beschriebenen Prozess und der verallgemeinerten Regelungsstruktur im Steuergerät. Bei den zu optimierenden Parametern handelt es sich um verschiedene Kennfelder der Vorsteuerung und die Gain-Scheduling-Parameter des PI-Reglers. Die erfolgreiche Umsetzung und die erreichten Ergebnisse der entwickelten Verfahren sind in Kapitel 6 zusammengefasst.

Als Erweiterung dieser Verfahren ist eine Optimierung der Stützstellen der einzustellenden Kennfelder möglich. Aus dem Verlauf der ILR-optimierten Stellgrößentrajektorie sind die Stützstellen so festzulegen, dass der Fehler zwischen dem optimalen nichtlinearen Verlauf der Trajektorie und dem interpolierten Verlauf des Kennfeldes minimal ist. Das Ziel wäre eine optimierte Abbildung der Trajektorie durch die gegebene Regelungsstruktur. Die Eignung und die Anwendungsanforderungen der entwickelten ILR-basierten Einstellungsverfahren Variante I und Variante II für diese Stützstellenoptimierung ist im Vorfeld zu prüfen und zu bewerten.

Neben der Anwendung der entwickelten Verfahren für weitere Prozesse ist die Verwendung der Variante I zur Validierung einer existierenden Vorsteuerung möglich. Es kann die Frage beantworten, mit welcher Güte diese Vorsteuerung die optimale ILR-Stellgrößentrajektorie abbilden kann. Wie groß sind beispielsweise die entstehenden Abweichungen auf Grund von Modellvereinfachungen bzw. von nicht berücksichtigten oder auch unbekanntem Teilmodellen.

## Anhang A.

### Ergänzungen zum Kapitel 3

#### Signaldarstellung der ILR bei MIMO-Systemen

$$\mathbf{u}_k = \begin{bmatrix} u_{1,k}(0) \\ u_{1,k}(1) \\ \vdots \\ u_{1,k}(N-1) \\ \hline u_{2,k}(0) \\ u_{2,k}(1) \\ \vdots \\ u_{2,k}(N-1) \\ \hline \vdots \\ \hline u_{p,k}(0) \\ u_{p,k}(1) \\ \vdots \\ u_{p,k}(N-1) \end{bmatrix}, \quad \mathbf{y}_k = \begin{bmatrix} y_{1,k}(0) \\ y_{1,k}(1) \\ \vdots \\ y_{1,k}(N-1) \\ \hline y_{2,k}(0) \\ y_{2,k}(1) \\ \vdots \\ y_{2,k}(N-1) \\ \hline \vdots \\ \hline y_{q,k}(0) \\ y_{q,k}(1) \\ \vdots \\ y_{q,k}(N-1) \end{bmatrix} \quad (\text{A.1})$$

$$\mathbf{y}_d = \begin{bmatrix} y_{1,d}(0) \\ y_{1,d}(1) \\ \vdots \\ y_{1,d}(N-1) \\ \hline y_{2,d}(0) \\ y_{2,d}(1) \\ \vdots \\ y_{2,d}(N-1) \\ \hline \vdots \\ \hline y_{q,d}(0) \\ y_{q,d}(1) \\ \vdots \\ y_{q,d}(N-1) \end{bmatrix}, \quad \mathbf{e}_k = \begin{bmatrix} e_{1,k}(0) \\ e_{1,k}(1) \\ \vdots \\ e_{1,k}(N-1) \\ \hline e_{2,k}(0) \\ e_{2,k}(1) \\ \vdots \\ e_{2,k}(N-1) \\ \hline \vdots \\ \hline e_{q,k}(0) \\ e_{q,k}(1) \\ \vdots \\ e_{q,k}(N-1) \end{bmatrix} \quad (\text{A.2})$$

$$\mathbf{u}_k = \begin{bmatrix} u_{1,k}(0) \\ u_{2,k}(0) \\ \vdots \\ u_{p,k}(0) \\ \hline u_{1,k}(1) \\ u_{2,k}(1) \\ \vdots \\ u_{p,k}(1) \\ \hline \vdots \\ \hline u_{1,k}(N-1) \\ u_{2,k}(N-1) \\ \vdots \\ u_{p,k}(N-1) \end{bmatrix}, \quad \mathbf{y}_k = \begin{bmatrix} y_{1,k}(0) \\ y_{2,k}(0) \\ \vdots \\ y_{q,k}(0) \\ \hline y_{1,k}(1) \\ y_{2,k}(1) \\ \vdots \\ y_{q,k}(1) \\ \hline \vdots \\ \hline y_{1,k}(N-1) \\ y_{2,k}(N-1) \\ \vdots \\ y_{q,k}(N-1) \end{bmatrix} \tag{A.3}$$

$$\mathbf{y}_d = \begin{bmatrix} y_{1,d}(0) \\ y_{2,d}(0) \\ \vdots \\ y_{q,d}(0) \\ \hline y_{1,d}(1) \\ y_{2,d}(1) \\ \vdots \\ y_{q,d}(1) \\ \hline \vdots \\ \hline y_{q,d}(N-1) \\ y_{q,d}(N-1) \\ \vdots \\ y_{q,d}(N-1) \end{bmatrix}, \quad \mathbf{e}_k = \begin{bmatrix} e_{1,k}(0) \\ e_{2,k}(0) \\ \vdots \\ e_{q,k}(0) \\ \hline e_{1,k}(1) \\ e_{2,k}(1) \\ \vdots \\ e_{q,k}(1) \\ \hline \vdots \\ \hline e_{1,k}(N-1) \\ e_{2,k}(N-1) \\ \vdots \\ e_{q,k}(N-1) \end{bmatrix} \tag{A.4}$$

## Weitere Formen der MFAC-basierten ILR

**ILR in der MFAC-Form PFDL:** Die PFDL-Methodik lässt sich auch für die MFAC-basierte ILR verwenden. Dabei gilt für den PFDL-Modellansatz

$$\Delta y(i+1, k) = \phi_P(i, k) \Delta \mathbf{u}(i, k), \forall i \in \{0, 1, \dots, N\} \quad (\text{A.5})$$

mit dem Eingangssignalvektor  $\Delta \mathbf{u}(i, k) \in \mathbb{R}^{L_u}$

$$\Delta \mathbf{u}(i, k) = [\Delta u(i, k) \quad \Delta u(i-1, k) \quad \dots \quad \Delta u(i-L_u+1, k)]^T \quad (\text{A.6})$$

und dem zeitvariablen PPD-Vektor  $\phi_P(i, k) \in \mathbb{R}^{L_u}$

$$\phi_P(i, k) = [\phi_{P,1}(i, k) \quad \dots \quad \phi_{P,L_u}(i, k)]. \quad (\text{A.7})$$

Der Parameter  $L_u$  legt die Anzahl der berücksichtigten vergangenen Zeitschritte fest. Die CFDL ist ein Spezialfall der PFDL mit  $L_u = 1$ . Die Berechnung dieses Vektors erfolgt in jeder Iteration  $k$  für jeden Zeitschritt  $i$ , so dass  $\phi_P(k)$  einer Matrix entspricht. Ist der Parameter  $L_u$  groß genug gewählt, entspricht  $\phi_P(i, k)$  dem Markov-Spaltenvektor.

Wie in 2.141 lässt sich folgende Kostenfunktion

$$\begin{aligned} J(\hat{\phi}_P(i, k)) &= \left( \Delta y(i+1, k-1) - \hat{\phi}_P(i, k) \Delta \mathbf{u}(i, k-1) \right)^2 \\ &\quad + \mu \left( \|\hat{\phi}_P(i, k) - \hat{\phi}_P(i, k-1)\| \right)^2 \end{aligned} \quad (\text{A.8})$$

definieren. Damit ergibt sich die rekursive Berechnungsvorschrift

$$\hat{\phi}_P(i, k) = \hat{\phi}_P(i, k-1) + \frac{\eta \Delta \mathbf{u}(i, k-1)}{\mu + \|\Delta \mathbf{u}(i, k-1)\|^2} (\Delta y(i+1, k-1) - \Delta \hat{y}(i+1, k-1)) \quad (\text{A.9})$$

des zeitveränderlichen Vektors  $\hat{\phi}_P(i, k)$  mit  $\Delta \hat{y}(i+1, k-1) = \hat{\phi}_P(i, k-1) \Delta \mathbf{u}(i, k-1)$ . Durch Minimierung des Gütefunktional 2.143 ergibt sich das ILR-Stellgesetz zu

$$\begin{aligned} u(i, k) &= u(i, k-1) + \frac{\rho_1 \hat{\phi}_{P,1}(i, k)}{\lambda + \left( \hat{\phi}_{P,1}(i, k) \right)^2} e(i+1, k-1) \\ &\quad - \frac{\hat{\phi}_{P,1}(i, k) \sum_{m=2}^{L_u} \left( \rho_m \hat{\phi}_{P,m}(i, k) \Delta u(i-m+1, k-1) \right)}{\lambda + \left( \hat{\phi}_{P,1}(i, k) \right)^2} \end{aligned} \quad (\text{A.10})$$

mit der generellen Schrittweite  $\rho_m \in (0, 1]$ .

Die Lernrate und die Rauschempfindlichkeit des MFAC-PFDL-ILR-Typs ist durch die drei Parameter  $\eta$ ,  $\mu$  und  $\lambda$ , sowie durch den Parametervektor  $\boldsymbol{\rho} = [\rho_1 \quad \rho_m]$  beeinflussbar.

**ILR in der MFAC-Form FFDL:** Dieser Abschnitt beschreibt die Anwendung der allgemeinen Betrachtung der MFAC-Theorie durch die FFDL-Beschreibung als ILR. Für den FFDL-Modellansatz gilt:

$$\Delta y(i+1, k) = \phi_F(i, k) \Delta \mathbf{H}(i, k), \forall i \in \{0, 1, \dots, N\} \quad (\text{A.11})$$

mit dem Signalvektor  $\Delta \mathbf{H}(i, k) \in \mathbb{R}^{L_y+L_u}$

$$\Delta \mathbf{H}(i, k) = [\Delta y(i, k) \quad \dots \quad \Delta y(i - L_y + 1, k) \quad \Delta u(i, k) \quad \dots \quad \Delta u(i - L_u + 1, k)]^T \quad (\text{A.12})$$

und dem zeitveränderlichen Vektor (Pseudo Gradient)  $\phi_F(i, k) \in \mathbb{R}^{L_y+L_u}$

$$\phi_F(i, k) = [\phi_{F,1}(i, k) \quad \dots \quad \phi_{F,L_y}(i, k) \quad \phi_{F,L_y+1}(i, k) \quad \dots \quad \phi_{F,L_y+L_u}(i, k)]. \quad (\text{A.13})$$

Dies stellt den allgemeinen Fall der dynamischen Linearisierung dar und berücksichtigt vergangene Stellgrößenänderungen als auch vergangene Regelgrößenänderungen. Mit den Festlegungen  $L_u = 1$  und  $L_y = 0$  lässt sich die CFDL-Variante und mit  $L_u = L_y$  und  $L_y = 0$  die PFDL-Variante herleiten.

Analog 2.141 lässt sich folgende Kostenfunktion

$$J(\hat{\phi}_F(i, k)) = \left( \Delta y(i+1, k-1) - \hat{\phi}_F(i, k) \Delta \mathbf{H}(i, k-1) \right)^2 + \mu \left( \|\hat{\phi}_F(i, k) - \hat{\phi}_F(i, k-1)\| \right)^2 \quad (\text{A.14})$$

definieren. Damit ergibt sich die rekursive Berechnungsvorschrift

$$\hat{\phi}_F(i, k) = \hat{\phi}_F(i, k-1) + \frac{\eta \Delta \mathbf{H}(i, k-1)}{\mu + \|\Delta \mathbf{H}(i, k-1)\|^2} (\Delta y(i+1, k-1) - \Delta \hat{y}(i+1, k-1)) \quad (\text{A.15})$$

des zeitveränderlichen Vektors  $\hat{\phi}_F(i, k)$  mit  $\Delta \hat{y}(i+1, k-1) = \hat{\phi}_F(i, k-1) \Delta \mathbf{H}(i, k-1)$ . Zudem bedeutet das, die Berechnung des Vektors  $\hat{\phi}_F(i, k)$  erfolgt in jedem Zeitschritt  $i$ . Durch Minimierung des Gütefunktional 2.143 ergibt sich das ILR-Stellgesetz zu

$$u(i, k) = u(i, k-1) + \frac{\rho_1 \hat{\phi}_{F,L_y+1}(i, k)}{\lambda + \left( \hat{\phi}_{F,L_y+1}(i, k) \right)^2} e(i+1, k-1) \quad (\text{A.16})$$

$$- \frac{\hat{\phi}_{F,L_y+1}(i, k) \sum_{m=L_y+2}^{L_y+L_u} \left( \rho_m \hat{\phi}_{F,m}(i, k) \Delta u(i-m+1, k-1) \right)}{\lambda + \left( \hat{\phi}_{F,L_y+1}(i, k) \right)^2}$$

$$- \frac{\hat{\phi}_{F,L_y+1}(i, k) \sum_{n=1}^{L_y} \left( \rho_n \hat{\phi}_{F,n}(i, k) \Delta y(i-n+1, k-1) \right)}{\lambda + \left( \hat{\phi}_{F,L_y+1}(i, k) \right)^2}$$

mit den generellen Schrittweiten  $\rho_1 \in (0, 1]$ ,  $\rho_m \in (0, 1]$  und  $\rho_n \in (0, 1]$ .

Die Lernrate und die Rauschempfindlichkeit des MFAC-FFDL-ILR-Typs ist durch die drei Parameter  $\eta$ ,  $\mu$  und  $\lambda$ , sowie durch den Parametervektor  $\boldsymbol{\rho} = [\rho_1 \quad \boldsymbol{\rho}_m]$  beeinflussbar.

# Anhang B. Diagramme

## Erläuternde Abbildungen zum Kapitel 2

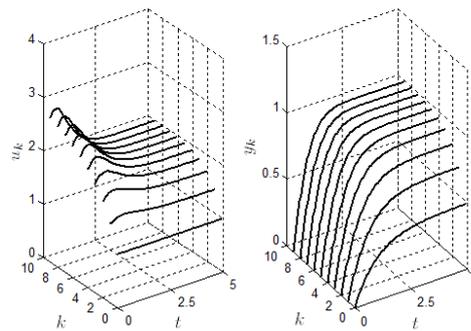


Abbildung B.1. Darstellung der Entwicklung der Stell- und Regelgröße einer ILR

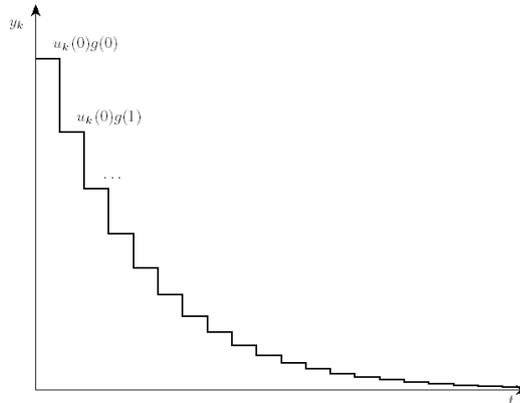


Abbildung B.2. Darstellung der Systemantwort auf einen diskreten Einheitsimpuls

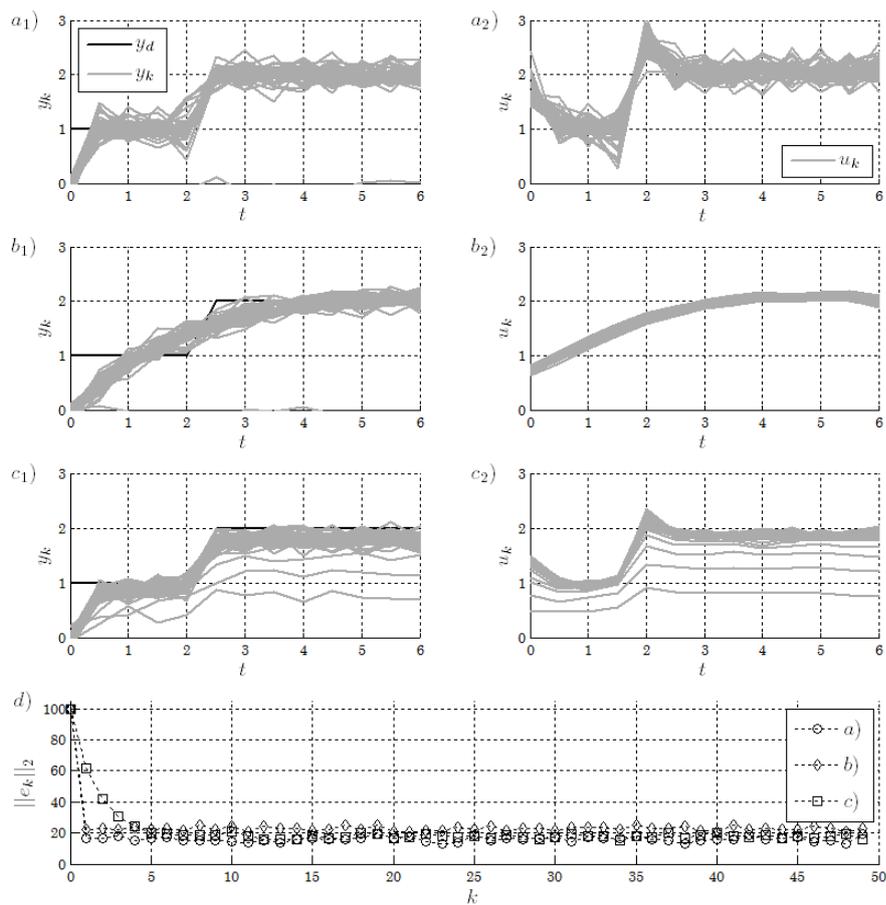


Abbildung B.3. Darstellung von ILR mit Q-Filter und Messrauschen

## Simulationen zum ILR-basierten Selbsteinstellungsverfahren Variante I

### Einstellung der stationären Vorsteuerung mit zusätzlichem Messrauschen

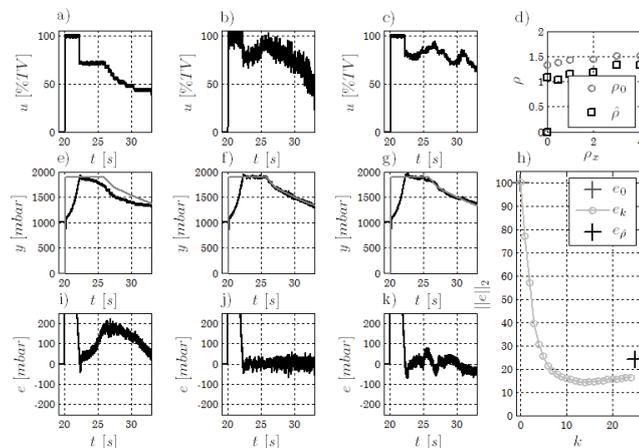


Abbildung B.4. Simulationsergebnis der Variante I für das stationäre Kennfeld (mit Messrauschen)

### Einstellung der stationären Vorsteuerung mit geändertem Startparametervektor $\rho_0$

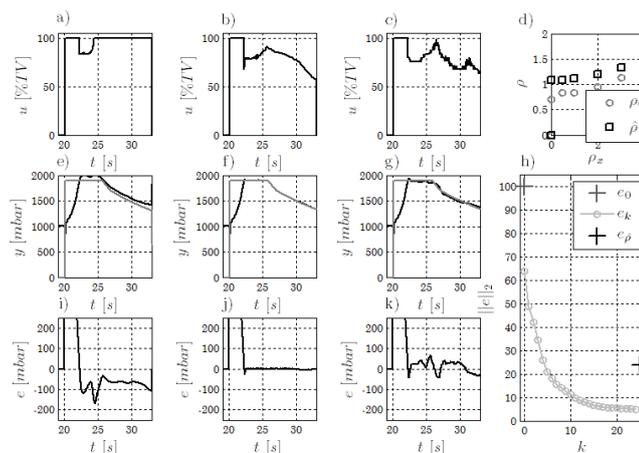


Abbildung B.5. Simulationsergebnis der Variante I für das stationäre Kennfeld (mit Variation des Startparametervektors)

**Einstellung des PI-Reglers der Ladedruckregelung mit zusätzlichem Messrauschen**

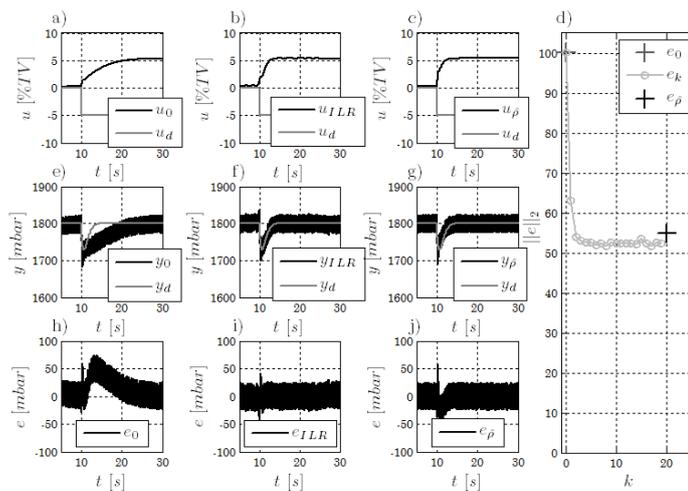


Abbildung B.6. Simulationsergebnis der Variante I für den Regler (AP1, mit Messrauschen)

**Einstellung des PI-Reglers der Ladedruckregelung bei geändertem Arbeitspunkt und zusätzlichem Messrauschen**

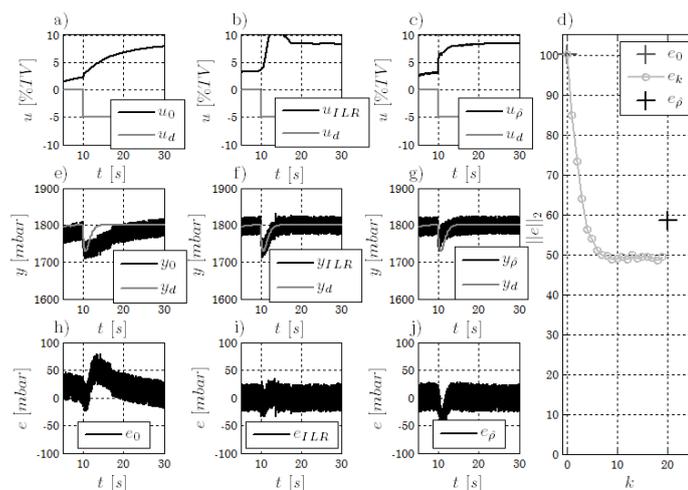


Abbildung B.7. Simulationsergebnis der Variante I für den Regler (AP2, mit Messrauschen)

## Simulationen zum ILR-basierten Selbsteinstellungsverfahren Variante II

### Einstellung der stationären Vorsteuerung mit zusätzlichem Messrauschen

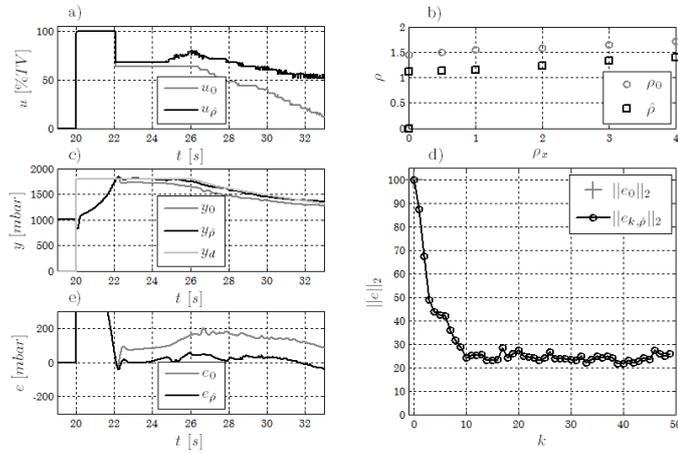


Abbildung B.8. Simulationsergebnis der Variante II für das stationäre Kennfeld (mit Messrauschen)

### Einstellung der stationären Vorsteuerung mit zufälligen Startbedingungen

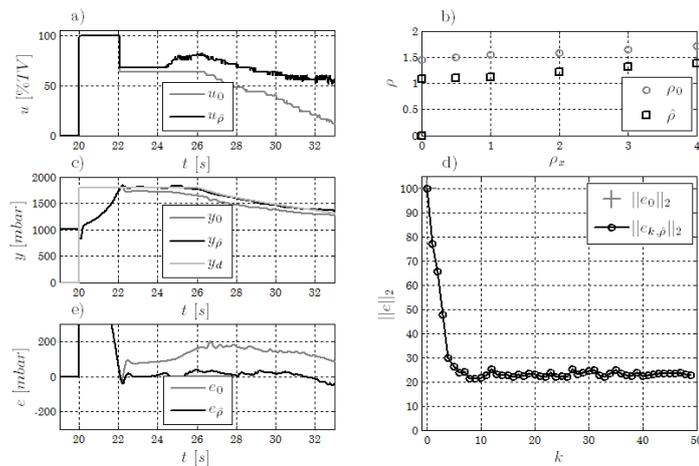


Abbildung B.9. Simulationsergebnis der Variante II für das stationäre Kennfeld (mit Variation der Startbedingungen)

Einstellung der stationären Vorsteuerung mit geändertem Startparametervektor

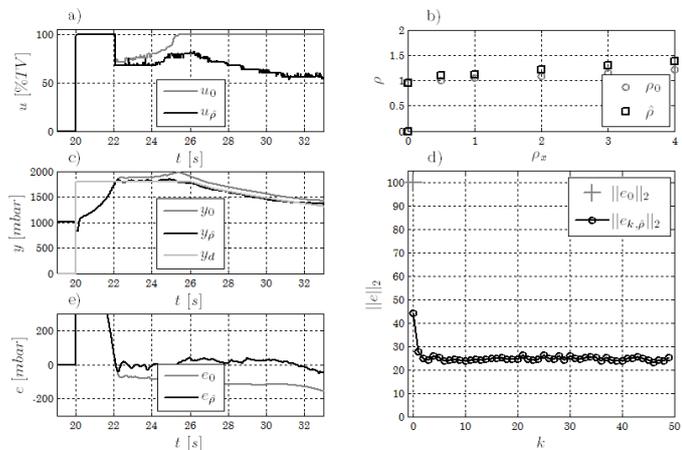


Abbildung B.10. Simulationsergebnis der Variante II für das stationäre Kennfeld (mit Variation des Startparametervektors)

Einstellung der dynamischen Vorsteuerung mit zufälligen Startbedingungen (II)

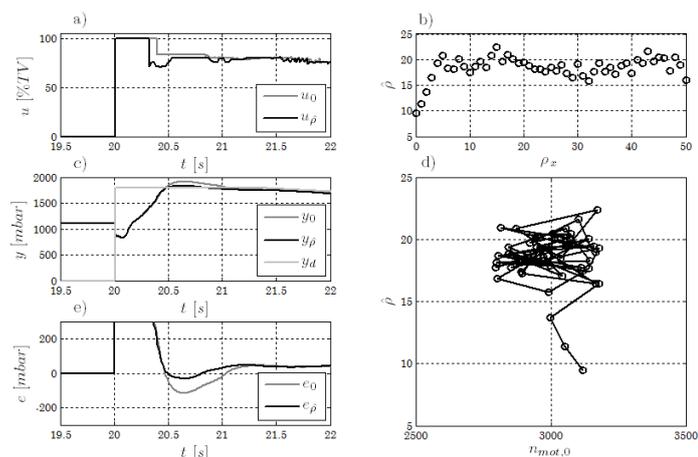


Abbildung B.11. Simulationsergebnis der Variante II für die dynamische Vorsteuerung (mit Messrauschen und zufälligen Startbedingungen (II))

Einstellung des PI-Reglers der Ladedruckregelung mit zusätzlichem Messrauschen

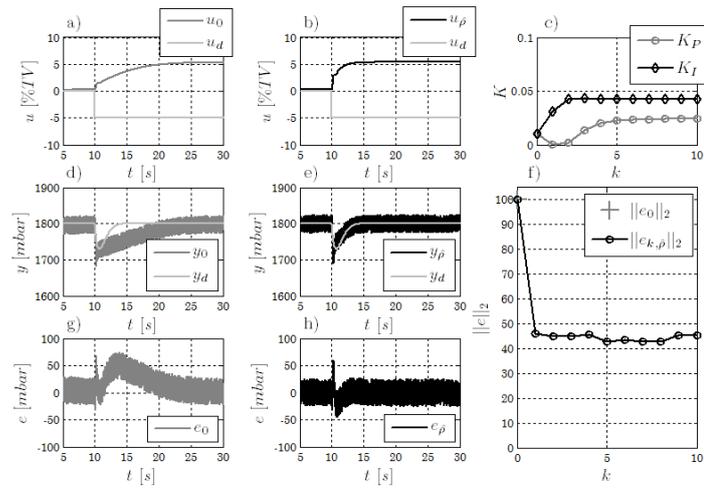


Abbildung B.12. Simulationsergebnis der Variante II für den Regler (AP1, mit Messrauschen)

Einstellung des PI-Reglers der Ladedruckregelung bei geändertem Arbeitspunkt und zusätzlichem Messrauschen

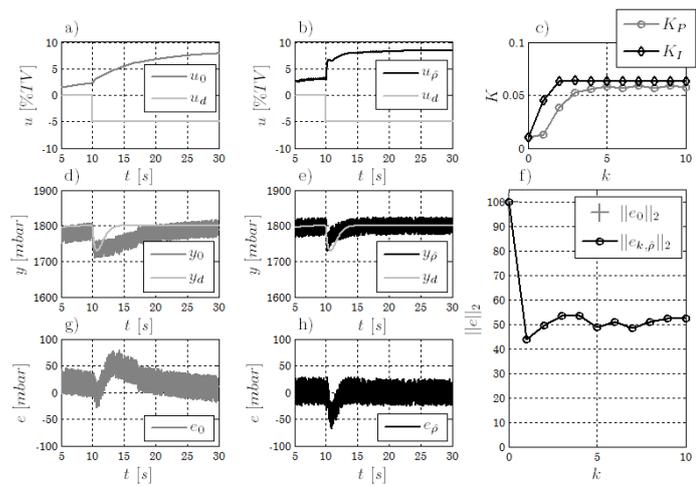


Abbildung B.13. Simulationsergebnis der Variante II für den Regler (AP2, mit Messrauschen)

# Literaturverzeichnis

- [2002/358/EG, 2002] 2002/358/EG (2002). Entscheidung des Rates vom 25. April 2002 über die Genehmigung des Protokolls von Kyoto zum Rahmenübereinkommen der Vereinten Nationen über Klimaänderungen im Namen der Europäischen Gemeinschaft sowie die gemeinsame Erfüllung der daraus erwachsenden Verpflichtungen. Amtsblatt Nr. L 130.
- [94/69/EG, 1994] 94/69/EG (1994). Beschluß des Rates vom 15. Dezember 1993 über den Abschluß des Rahmenübereinkommens der Vereinten Nationen über Klimaänderungen. Amtsblatt Nr. L033.
- [Adamy, 2009] Adamy, J. (2009). *Nichtlineare Regelungen*. Springer Verlag.
- [Ahn et al., 2007a] Ahn, H.-S., Chen, Y., and Moore, K. L. (2007a). Iterative learning control: brief survey and categorization. *IEEE Transactions on Systems Man and Cybernetics: Part C Applikations and Reviews*, 37.6:1099–1121.
- [Ahn et al., 2007b] Ahn, H.-S., Moore, K. L., and Chen, Y. Q. (2007b). *Iterative Learning Control Robustness and Monotonic Convergence for Interval Systems*. Springer Verlag.
- [Amann et al., 1994] Amann, N., Owens, D. H., and Rogers, E. (1994). 2d systems theory applied to learning control systems. In *Conference on Decision and Control*.
- [Andres et al., 2002] Andres, D., Hengen, H., and Pandit, M. (2002). Optimierend iterativ lernende Regelungen. *at-Automatisierungstechnik*, 50:112–118.
- [Arimoto et al., 1984] Arimoto, S., Kawamura, S., and Miyazaki, F. (1984). Bettering operation of dynamic systems by learning: A new control theory for servomechanism or mechatronics systems. In *Conference on Decision and Control*.
- [Aström, 1995] Aström, K. J. (1995). *PID Controllers. Theory, Design and Tuning*. ISA: The Instrumentation, Systems and Automation Society.
- [Aström and Wittenmark, 1994] Aström, K. J. and Wittenmark, B. (1994). *Adaptive Control*. Prentice Hall.
- [Böcker et al., 1986] Böcker, J., Hartmann, I., and Zwanzig, C. (1986). *Nichtlineare und adaptive Regelungssysteme*. Springer Verlag.
- [Beckmann, 2014] Beckmann, R. (2014). *Beitrag zur zur exakten Füllungssteuerung am aufgeladenen Ottomotor*. PhD thesis, Universität Rostock.
- [BMUB, 2008] BMUB (2008). Bundesministerium für Umwelt, Naturschutz, Bau und Reaktorsicherheit: Die EU-Verordnung zur Verminderung der CO<sub>2</sub>-Emissionen von Personenkraftwagen. Webseite.

- [Bobál et al., 2005] Bobál, V., Böhm, J., Fessl, J., and Macháček, J. (2005). *Digital Self-tuning Controllers*. Springer Verlag.
- [Bristow et al., 2007] Bristow, D. A., Alleyne, A., and Tharayil, M. (2007). A Time-Varying Q-Filter Design for Iterative Learning Control. In *American Control Conference*.
- [Byrnes and Isidori, 1991] Byrnes, C. I. and Isidori, A. (1991). Asymptotic stabilization of minimum phase nonlinear systems. *IEEE Transactions on Automatic Control*, 36.10:1122–1137.
- [Campi et al., 2000] Campi, M. C., Lecchini, A., and Savaresi, S. M. (2000). Virtual Reference Feedback Tuning (VRFT): a new direct approach to the design of feedback controllers. In *IEEE Decision and Control*.
- [Campi et al., 2002] Campi, M. C., Lecchini, A., and Savaresi, S. M. (2002). Virtual reference feedback tuning: a direct method for the design of feedback controllers. *Automatica*, 38.8:1337–1346.
- [Chen and Wen, 1999] Chen, Y. and Wen, C. (1999). *Iterative Learning Control Convergence, Robustness and Applications*. Springer Verlag.
- [Chen et al., 1996] Chen, Y., Xu, J.-X., and Lee, T. H. (1996). An Iterative Learning Controller Using Current Iteration Tracking Error Information and Initial State Learning. In *Conference on Decision and Control*.
- [Chen et al., 1997] Chen, Y., Xu, J.-X., and Lee, T. H. (1997). Current iteration tracking error assisted high-order iterative learning control of discrete-time uncertain nonlinear systems. In *Asian Control Conference*.
- [Chen and Moore, 2002] Chen, Y. Q. and Moore, K. L. (2002). An Optimal Design of PD-type Iterative Learning Control with Monotonic Convergence. In *IEEE International Symposium on Intelligent Control*.
- [Dambrosio et al., 2001] Dambrosio, L., Pascasio, G., Robertis, S. D., and Fortunato, B. (2001). VGT Turbocharger controlled by means of an Adaptive Control Technique. In *International Conference on Advanced Intelligent Mechatronics*.
- [Eichseder et al., 2008] Eichseder, H., Klütting, M., and Piock, W. F. (2008). *Grundlagen und Technologien des Ottomotors (Der Fahrzeugantrieb)*. Springer Verlag.
- [Föllinger et al., 1995] Föllinger, O., Dörrscheidt, F., and Klittich, M. (1995). *Regelungstechnik: Einführung in die Methoden und ihre Anwendung*. Hüthig Buch-Verlag.
- [Freeman et al., 2005] Freeman, C., Lewin, P., and Rogers, E. (2005). Discrete predictive optimal ilc implemented on a non-minimum phase experimental test-bed. In *American Control Conference*.
- [Fuchs et al., 1993] Fuchs, A., Varghese, M., and Mukundan, R. (1993). On Weak Relative Degree and the McGehee Transformation. *IEEE Transactions on Automatic Control*, 38.7:1147–1150.

- [Golloch, 2005] Golloch, P. (2005). *Downsizing von Verbrennungsmotoren*. Springer Verlag.
- [Guhr et al., 2007] Guhr, C., Zellbeck, H., and Roß, T. (2007). Modellbasierte Regelung - Neue Konzepte für hochaufgeladene Motoren. In *12. Aufladetechnische Konferenz*.
- [Hengen, 2002] Hengen, H. (2002). *System- und signalorientierter Entwurf iterativ lernender Regelungen*. PhD thesis, Universität Kaiserslautern.
- [Hengen et al., 2004] Hengen, H., Breitel, T., and Pandit, M. (2004). Iterativ lernende Regelungen für Semi-Batchprozesse. *at-Automatisierungstechnik*, 52:526–535.
- [Hjalmarsson et al., 1998] Hjalmarsson, H., Gevers, M., Gunnarsson, S., and Lequin, O. (1998). Iterative feedback tuning: theory and applications. *IEEE Control Systems*, 18.4:26–41.
- [Hou and Jin, 2011] Hou, Z. and Jin, S. (2011). Data-Driven Model-Free Adaptive Control for a Class of MIMO Nonlinear Discrete-Time Systems. *IEEE Transactions on Neural Networks*, 22, no. 12:2173–2188.
- [Hou and Jin, 2014] Hou, Z. and Jin, S. (2014). *Model Free Adaptive Control, Theory and Applications*. Taylor & Francis Group.
- [Hou and Rong-Hu, 2007] Hou, Z. and Rong-Hu, C. (2007). Dual-stage Optimal Iterative Learning Control for Nonlinear Non-affine Discrete-time Systems. *Acta Automatica Sinica*, 33.10:1061–1065.
- [Ilchmann, 1993] Ilchmann, A. (1993). *Non-Identifier-Based High-Gain Adaptive Control*. Springer Verlag.
- [Ioannou and Fidan, 2006] Ioannou, P. and Fidan, B. (2006). *Adaptive Control Tutorial*. Society for Industrial and Applied Mathematics.
- [Ioannou and Sun, 1995] Ioannou, P. and Sun, J. (1995). *Robust Adaptive Control*. Prentice Hall.
- [Isermann, 1992a] Isermann, R. (1992a). *Identifikation dynamischer Systeme 1*. Springer Verlag.
- [Isermann, 1992b] Isermann, R. (1992b). *Identifikation dynamischer Systeme 2*. Springer Verlag.
- [Isermann, 2010] Isermann, R. (2010). *Elektronisches Management motorischer Fahrzeugantriebe - Elektronik, Modellbildung, Regelung und Diagnose für Verbrennungsmotoren, Getriebe und Elektroantriebe*. Vieweg Verlag.
- [Jelali, 2006] Jelali, M. (2006). Regelkreisüberwachung in der Metallindustrie Teil 1: Klassifikation und Beschreibung der Methoden. *at-Automatisierungstechnik*, 54.1:36.
- [Jelali, 2007] Jelali, M. (2007). Automatisches Reglertuning basierend auf Methoden des Control Performance Monitoring. *at-Automatisierungstechnik*, 55.1:10–19.

- [Kaneko et al., 2005] Kaneko, O., Souma, S., and Fujii, T. (2005). A fictitious reference iterative tuning (FRIT) in the two-degree of freedom control scheme and its application to closed loop system identification. In *IFAC World Congress*.
- [Kiranyaz et al., 2014] Kiranyaz, S., Ince, T., and Gabbouj, M. (2014). *Multidimensional Particle Swarm Optimization for Machine Learning and Pattern Recognition*. Springer Verlag.
- [Laidig et al., 2014] Laidig, D., Seel, T., and Schauer, T. (2014). Entwicklung einer inertialsensorbasierten Eversionswinkelregelung für einen Peroneus-Stimulator. In *International Symposium on automatic control (AUTSYM)*.
- [Landau et al., 2011] Landau, I. D., Lozano, R., M'Saad, M., and Karimi, A. (2011). *Adaptive Control: Algorithms, Analysis and Applications*. Springer Verlag.
- [Lecchini et al., 2002] Lecchini, A., Campi, M. C., and Savaresi, S. M. (2002). Virtual reference feedback tuning for two degree of freedom controllers. *International Journal of Adaptive Control and Signal Processing*, 16.5:355–371.
- [Louis, 1989] Louis, A. K. (1989). *Inverse und schlecht gestellte Probleme*. B. G. Teubner Stuttgart.
- [Lunze, 2010] Lunze, J. (2010). *Regelungstechnik 1*. Springer Verlag.
- [Masuda, 2012] Masuda, S. (2012). PID controller tuning based on disturbance attenuation FRIT using one-shot experimental data due to a load change disturbance. In *IFAC Conference on Advances in PLO Control*.
- [Merker et al., 2006] Merker, G., Schwarz, C., Stiesch, G., and Otto, F. (2006). *Verbrennungsmotoren*. B. G. Teubner Verlag Wiesbaden.
- [Miyachi et al., 2006] Miyachi, M., Kaneko, O., and Fujii, T. (2006). A Parameter Identification Based on Tuning of a Controller with One-Shot Experimental data. In *SICE-ICASE International Joint Conference*.
- [Mollenhauer and Tschöke, 2007] Mollenhauer, K. and Tschöke, H. (2007). *Handbuch Dieselmotoren*. Springer Verlag.
- [Moore, 2001a] Moore, K. L. (2001a). *Applied and Computational Control, Signals and Circuits*. Birkhäuser Verlag.
- [Moore, 2001b] Moore, K. L. (2001b). An observation about monotonic convergence in discrete-time, P-type iterative learning control. In *IEEE International Symposium on Intelligent Control*.
- [Moore and Chen, 2002] Moore, K. L. and Chen, Y. (2002). On the monotonic convergence of high order iterative learning update laws. In *IFAC*.
- [Moore et al., 2006] Moore, K. L., Chen, Y., and Ahn, H.-S. (2006). Iterative Learning Control: A Tutorial and Big Picture View. In *IEEE Conference on Decision and Control*, page 6.

- [Moore and Chen, 2003] Moore, K. L. and Chen, Y. Q. (2003). A separative high-order framework for monotonic convergent iterative learning controller design. In *ACC*.
- [Mossberg et al., 2002] Mossberg, M., Gevers, M., and Lequin, O. (2002). A comparison of iterative feedback tuning and classical PID tuning schemes. In *WSEAS Int. Conf. on Signal Processing, Robotics and Automation*.
- [Nahrstaedt et al., 2008] Nahrstaedt, H., Schauer, T., Hesse, S., and Raisch, J. (2008). Iterativ Lernende Regelung einer Gang-Neuroprothese. *at-Automatisierungstechnik*, 56.9:494–501.
- [Nelder and Mead, 1965] Nelder, J. A. and Mead, R. (1965). A Simplex Method for Function Minimization. *The Computer Journal*, 7.4:308–313.
- [Norrlöf, 2000] Norrlöf, M. (2000). *Iterative Learning Control: Analysis, Design and Experiments*. PhD thesis, Universität Linköpings, Schweden.
- [Norrlöf and Gunnarsson, 2002] Norrlöf, M. and Gunnarsson, S. (2002). Time and frequency domain convergence properties in iterative learning control. *International Journal of Control*, 75.14:1114–1126.
- [Ortega and Spong, 1989] Ortega, R. and Spong, M. W. (1989). Adaptive motion control of rigid robots: a tutorial. *Automatica*, 25.6:877–888.
- [Papageorgiou, 2012] Papageorgiou, M. (2012). *Optimierung: Statische, Dynamische, Stochastische Verfahren*. Springer Verlag.
- [Plassmann and Schulz, 2013] Plassmann, W. and Schulz, D. (2013). *Handbuch Elektrotechnik: Grundlagen und Anwendungen für Elektrotechniker*. Springer Verlag.
- [Rockel and Konigorski, 2007] Rockel, H. and Konigorski, U. (2007). Iterativ Lernende Regelungen, Teil i: Ein parametrischer Rahmen. *at-Automatisierungstechnik*, 55:119–126.
- [Rogers et al., 2007] Rogers, E., Galkowski, K., and Owens, D. H. (2007). *Control Systems Theory and Applications for Linear Repetitive Processes*. Springer Verlag.
- [Rogers et al., 2010] Rogers, E., Owens, D. H., Werneer, H., Freeman, C. T., Lewin, P. L., Kichhoff, S., Schmidt, C., and Lichtenberg, G. (2010). Norm-Optimal Iterative Learning Control with Application to Problems in Accelerator-Based Free Electron Lasers and Rehabilitation Robotics. *European Journal of Control*, 16:497–522.
- [Roover et al., 2000] Roover, D. D., Bosgra, O. H., and Steinbuch, M. (2000). Internal-model-based design of repetitive and iterative learning controllers for linear multivariable systems. *International Journal of Control*, 73.10:914–929.
- [Saberri and Lin, 1994] Saberri, A. and Lin, Z. (1994). Simultaneous Stabilization of a Family of SISO Nonlinear Systems via Output Feedback. In *IEEE: American Control Conference*.

- [Schafer, 2011] Schafer, R. W. (2011). What is a Savitzky-Golay filter? *Signal Processing Magazine*, 28.4:111–117.
- [Schöley, 2014] Schöley, A. (2014). Entwicklung und Testung eines Prüfstandssteuerungskonzepts an einem elektromotorischen Antriebsstrang-Modellaufbau. Master's thesis, Universität Rostock.
- [Schröder, 2010] Schröder, D. (2010). *Intelligente Verfahren - Identifikation und Regelung nichtlinearer Systeme*. Springer Verlag.
- [Schwarzmann, 2007] Schwarzmann, D. (2007). *Nonlinear Internal Model Control with Automotive Applications*. PhD thesis, Ruhr-Universität Bochum.
- [Sepulchre et al., 1997] Sepulchre, R., Jankovic, M., and Kokotovic, P. (1997). *Constructive Nonlinear Control*. Springer Verlag.
- [Skopil, 2007] Skopil, M. A. (2007). *Moderne Turboaufladung - Grundlagen der Aufladetechnik für Diesel- und Ottomotoren*. Expert Verlag.
- [Steinberg, 2010] Steinberg, S. (2010). Robuste nichtlinearere Zylinderfüllung eines DI-Ottomotors und flachheitsbasierte Turboladerregelung. Master's thesis, Technische Universität Berlin.
- [Sun and Wang, 2002] Sun, M. and Wang, D. (2002). Closed-loop iterative learning control for non-linear systems with initial shifts. *INTERNATIONAL JOURNAL OF ADAPTIVE CONTROL AND SIGNAL PROCESSING*, 16:515–538.
- [Tayebi and Zaremba, 2003] Tayebi, A. and Zaremba, M. B. (2003). Robust Iterative Learning Control Design is Straightforward for Uncertain LTI Systems Satisfying the Robust Performance Condition. In *IEEE TRANSACTIONS ON AUTOMATIC CONTROL*, volume 48.1, pages 101–106.
- [Unbehauen, 1993] Unbehauen, H. (1993). *Regelungstechnik III, Identifikation, Adaption, Optimierung*. Vieweg Verlag.
- [Unbehauen, 2007] Unbehauen, H. (2007). *Regelungstechnik II: Zustandsregelungen, digitale und nichtlineare Regelsysteme*. Vieweg Verlag.
- [Weinmann, 1991] Weinmann, A. (1991). *Uncertain Models and Robust Control*. Springer Verlag.

## Publikationsliste

- [NJSW15] René Noack, Torsten Jeinsch, Matthias Schultalbers, and Nick Weinhold. Datenbasierte Optimierung von Vorsteuerungsparametern - Eine ILR-basierte Methode. *atp edition*, 57(06):30–37, 2015.
- [NJW14a] René Noack, Torsten Jeinsch, and Nick Weinhold. Datengestützte selbst-einstellende Regelungen mittels Verfahren iterativ lernender Regelungen. In *AALE - Angewandte Automatisierungstechnik in Lehre und Entwicklung*, pages 51–59, Mai 2014. ISBN-13: 978-3-8356-7142-3.
- [NJW14b] René Noack, Torsten Jeinsch, and Nick Weinhold. Modellfreier, daten-basierter Ansatz zur Selbsteinstellung von Vorsteuerungen am Beispiel der Abgasturboladerregelung. In *Internationalen Wismarer Automatisierungssymposiums (AUTSYM)*, September 2014. ISBN: 978-3-942100-86-1.
- [NJWH14a] René Noack, Torsten Jeinsch, Nick Weinhold, and Adel Haghani. Data-Driven Self-Tuning Control by Iterative Learning Control with Application to Optimize the Control Parameter of Turbocharged Engines. In *IEEE - International Conference on Methods and Models in Automation and Robotics*, number 14 in 839-844, September 2014. ISBN: 978-1-4799-5082-9.
- [NJWH14b] René Noack, Torsten Jeinsch, Nick Weinhold, and Adel Haghani. Data-Driven Self-Tuning Feedforward Control by Iterative Learning Control. In *IEEE - International Symposium on Industrial Electronics*, number 14 in 2435-2440, Juni 2014. ISBN: 978-1-4799-2398-4.
- [Noa10] René Noack. Aufladung von Ottomotoren - Anforderungen an die Regelungstechnik. In *Wissenschaftstage der Hochschule Lausitz (FH)*, 2010.

# Thesen

1. Die Aufladung von Motoren ist eine Möglichkeit zur Abgasreduzierung und Verbrauchseinsparung, bei gleichzeitiger Reduzierung der Motorgröße (Downsizing). Durch die Aufladung lässt sich trotz verringerter Motorleistung die geforderte Fahrdynamik erreichen.
2. Die in dieser Arbeit entwickelten Selbsteinstellungsverfahren werden an der Regelung des Prozesses des Ladedruckaufbaus angewendet. Bei der hier betrachteten Version der Aufladung für Ottomotoren handelt es sich um einen Abgasturbolader mit pneumatischem Wastegate.
3. Bestehende Ladedruckregelungen setzen sich aus einem dominierenden Vorsteuerungsanteil und einem Regelungsanteil zusammen. Die Vorsteuerung ist modellbasiert und entspricht einem invertierten Modell des Ladedruckaufbaus. Durch die Verwendung von Kennlinien und Kennfeldern werden komplexe nichtlineare Zusammenhänge zwischen Motorgrößen (wie z.B. der Motordrehzahl, dem Ladedruck und dem Wastegate-Tastverhältnis) abgebildet. Die Herausforderung liegt in der Beschreibung dieser Kennfelder. Bei dem eingesetzten Ladedruckregler handelt es sich um einen arbeitspunktabhängigen PI-Regler.
4. Die Güte der modellbasierten Vorsteuerung der Ladedruckregelung ist abhängig von den gewählten Parametern und beruht teilweise auf dem Erfahrungsschatz der Applikationsingenieure. Ein automatisiertes Verfahren zur Selbsteinstellung dieser Parameter ist davon unabhängig und reduziert den Einarbeitungsaufwand bei Personalwechsel. Es liefert reproduzierbare Ergebnisse unabhängig vom Erfahrungsträger.
5. Bei dem zweiten betrachteten Anwendungsprozess „BLDC-Motorprüfstand“ handelt es sich um eine Regelstrecke ohne Ausgleich. Er benötigt einen aktiven Regler während der Selbsteinstellung. Das relevante Rauschen der Messsignale macht den Einsatz eines Q-Filters bei der verwendeten ILR-Strategie notwendig.
6. Die Grundvoraussetzung der entwickelten Selbsteinstellungsverfahren ist eine existierende und funktionierende Regelungsstruktur, die dazu geeignet ist, den Prozess zu regeln. Ist dies der Fall, können mit diesen Verfahren in wenigen Iterationen die optimalen Parameter ermittelt werden.
7. Die entwickelten Verfahren erweitern die Anwendung der ILR und vergrößern ihr

Anwendungspotential durch den Einsatz in selbstlernenden Verfahren. Damit lassen sich ILR-Verfahren bei Inbetriebnahmen zur Parameteroptimierung gegebener Regelungsstrukturen einsetzen.

8. Iterativ lernende Regelungen lassen sich so entwerfen, dass die Konvergenz in jeder Iteration gewährleistet ist. Dies stellt eine wichtige Eigenschaft der entwickelten Selbsteinstellungsverfahren dar.
9. Durch eine Parameteroptimierung gelingt es die ermittelten Trajektorien der iterativ lernenden Regelung durch die Parameter existierender Vorsteuerungen und Regelungen abzubilden.
10. Die Parameteroptimierung an den gelernten Stellgrößenverläufen der ILR ist vergleichbar mit dem Einsatz eines Filters in der ILR. Die Verwendung von Filtern bei der ILR beeinflusst die Lernrate, die erreichbare Genauigkeit und die Streuung der gelernten Trajektorie und damit die erreichbare Regelgüte der optimierten Parameter.

# Selbstständigkeitserklärung

Ich erkläre an Eides statt, dass ich die vorliegende Dissertation selbstständig und ohne fremde Hilfe verfasst, andere als die von mir angegebenen Quellen und Hilfsmittel nicht benutzt und die den benutzten Werken wörtlich oder inhaltlich entnommenen Stellen als solche kenntlich gemacht habe. Ein Verfahren zur Erlangung des akademischen Grades Doktor-Ingenieur (Dr.-Ing.) wurde bisher an keiner anderen Fakultät beantragt.

---

Ort, Datum

---

René Heinz Noack