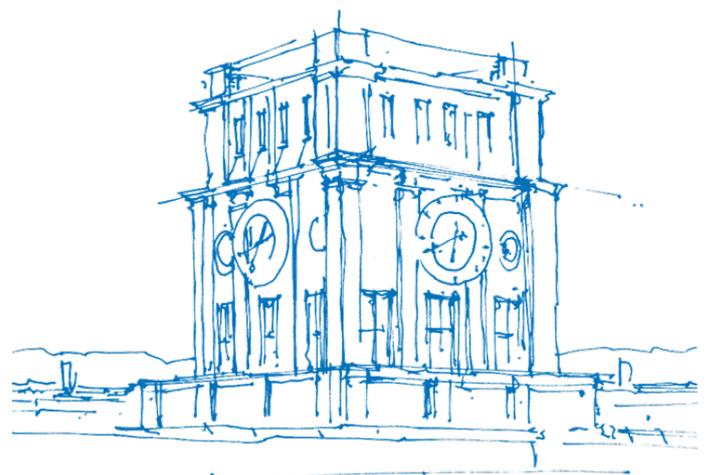


Online-Parameteridentifikation zur technischen Diagnose elektrischer Antriebsysteme

Martin Nachtsheim



TUM Uhrenturm

Online-Parameteridentifikation zur technischen Diagnose elektrischer Antriebsysteme

Martin Nachtsheim

Online-Parameteridentifikation zur technischen Diagnose elektrischer Antriebsysteme

Martin Nachtsheim

Vollständiger Abdruck der von der TUM School of Engineering and Design der Technischen Universität München zur Erlangung eines

Doktors der Ingenieurwissenschaften (Dr.-Ing.)

genehmigten Dissertation.

Vorsitz:

Prof. Dr. Norman Weik

Prüfende der Dissertation:

1. Univ.- Prof. Dr. -Ing. Dr. h. c. Ralph Kennel
2. Prof. Dr. -Ing. Christian Endisch

Die Dissertation wurde am 13.11.2023 bei der Technischen Universität München eingereicht und durch die TUM School of Engineering and Design am 21.05.2024 angenommen.

Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Innovative Mobilität in der Forschungsgruppe Elektromobilität und lernfähige Systeme an der Technischen Hochschule Ingolstadt im Rahmen eines Kooperationsprojekts mit der Audi AG.

In besonderem Maße danke ich dem Leiter des Instituts und der Forschungsgruppe Prof. Dr.-Ing. Christian Endisch. Für die vertrauensvolle Zusammenarbeit, die wissenschaftlichen Freiheiten sowie die fachliche Unterstützung und die motivierenden Worte möchte ich mich herzlich bei dir bedanken.

Ein herzliches Dankeschön gebührt Univ.- Prof. Dr.-Ing. Dr. h. c. Ralph Kennel für das Interesse an dieser Arbeit und die Übernahme des Prüfungsreferats.

Des Weiteren bedanke ich mich bei allen beteiligten Personen des Projektpartners Audi AG für den wertvollen fachlichen Austausch. Mein besonderer Dank an dieser Stelle gilt Dr.-Ing. Andreas Jörg. Im internen Austausch hast du mir stets den Rücken freigehalten und durch deine fachliche Expertise in zahlreichen Diskussionen maßgeblich zum Fortschritt der Arbeit beigetragen. Von entscheidender Bedeutung für den erfolgreichen Abschluss war auch das Arbeitsklima und die Unterstützung der Kolleginnen und Kollegen im Umfeld der Hochschule. In diesem Sinne gebührt mein aufrichtiger Dank Markus Kohler, Julia Stöttner, Christoph Hartmann, Dr. Meinert Lewerenz, Simon Diehl, Markus Hölzle, Dominik Schneider, Andreas Frey, Christoph Terbrack, Christian Hanzl, Bernhard Liebhart, Michael Schmid, Michael Okon, Sebastian Mayer, Pablo Morales Torricos, Dr. Lidiya Komsiyaska, Katja Joenssen und vielen mehr. Ihr habt meinen Arbeitsalltag in vielerlei Hinsicht bereichert.

In besonderem Maße danke ich auch den zahlreichen Studierenden für ihr Interesse. Ihr habt durch eure wissenschaftlichen Beiträge mit Enthusiasmus und Fleiß wesentlich zum Erfolg dieser Arbeit beigetragen.

Abschließend gebührt mein Dank meiner Familie sowie meinen Freundinnen und Freunden, die mich bei all meinen Vorhaben stets unterstützt haben und immer für mich da sind. Besonders hervorheben möchte ich meine Partnerin Saskia. Du hast in den letzten Jahren so manche Abstriche gemacht und trotz der Umstände immer hinter mir gestanden. Ich freue mich auf den neuen Lebensabschnitt und die kommende Zeit mit unserer gemeinsamen Tochter Felina. Euch widme ich diese Arbeit von Herzen.

München, im Juli 2024

Martin Nachtsheim

Kurzfassung

Im Kontext der Energiewende und der damit verbundenen Entwicklung neuer elektrifizierter Antriebskonzepte steigt das Interesse an Maßnahmen zur Online-Diagnose aufgrund von Sicherheitsaspekten, aber auch aus Gründen der Nutzerzufriedenheit zunehmend. Bezüglich der Umsetzung in Automobilen sind im Vergleich zu bestehenden Anwendungen in beispielsweise Produktions- oder Kraftwerksanlagen die unterschiedlichen Rahmenbedingungen von entscheidender Bedeutung. Das dynamische Betriebsumfeld sowie die stark limitierten Rechenressourcen erfordern eine Analyse existierender und die Ableitung neuer Ansätze zur Online-Diagnose. Die vorliegende Arbeit beschäftigt sich mit der Entwicklung echtzeitfähiger und parameterbasierter Diagnosekonzepte für elektrische Antriebssysteme in Automobilen. Dazu erfolgt eine Analyse etablierter Ansätze zur Online-Identifikation von Parametern beziehungsweise Systemzuständen und deren Modifikation für den Einsatz im betrachteten Betriebsumfeld. Ziel dabei ist eine robuste Online-Parameteridentifikation zur direkten Anomaliedetektion beziehungsweise Gewinnung von Merkmalen zur Fehlerklassifikation. Basierend darauf werden verschiedene Diagnosekonzepte in Betracht der limitierten Rechenressourcen abgeleitet. Im Fokus steht dabei die Entwicklung einer möglichst zuverlässigen Diagnose bei gegebener Echtzeithardware.

Abstract

In the context of the energy transition and the development of new electrified drive concepts, interest in providing online diagnosis is increasingly growing due to safety aspects, but also for reasons of user satisfaction. Regarding the implementation in automotive applications, the different general conditions are of crucial importance compared to existing applications in, for example, production or power plants. The dynamic operating environment as well as the strongly limited computational resources require an analysis of existing methods and the derivation of new approaches for online diagnosis. This thesis deals with the development of real-time capable and parameter-based diagnosis concepts for electric drive systems in automotive applications. For this purpose, established approaches for the online identification of parameters or system states are analyzed and modified for use in the considered operating environment. The goal is a robust online parameter identification for direct anomaly detection or the extraction of features for failure classification. Based on this, different diagnostic concepts are derived considering the limited computational resources. The focus is on the development of a reliable diagnosis with given real-time hardware.

Inhaltsverzeichnis

1	Einführung	1
1.1	Zustands- und parameterbasierte Diagnosekonzepte für elektrische Antriebssysteme im Automobil	2
1.1.1	Zustands- und Parameterschätzung zur Merkmalsgenerierung	3
1.1.2	Diagnosekonzepte	4
1.2	Ausgangspunkt und Ziele der Arbeit	4
1.3	Aufbau der Arbeit	6
2	Grundlagen	9
2.1	Least-Squares Verfahren zur Parameteridentifikation physikalischer Systeme	9
2.1.1	Modellbildung physikalischer Systeme	10
2.1.2	Offline-Parameteridentifikation mit dem Least-Squares Verfahren	11
2.1.3	Online-Parameteridentifikation mit dem Recursive-Least-Squares Algorithmus	14
2.1.4	Erweiterte RLS-Algorithmen zur Online-Identifikation dynamischer Parameteränderungen	17
2.1.5	Systemidentifikation mit dem diskreten Kalman-Filter	26
2.1.6	Online-Parameteridentifikation mit erweitertem Kalman-Filter	33
2.2	Digitale Signalverarbeitung und Differentiation	38
2.3	Grundlagen der Asynchronmaschine	41
2.3.1	Analytische Modellierung der Asynchronmaschine	41
2.3.2	Parameteränderungen der Asynchronmaschine	46
3	Aufbau der Testumgebung	49
3.1	Experimenteller Aufbau	49
3.1.1	Hardwarekomponenten	49
3.1.2	Aufbau der implementierten Echtzeitsoftware	52
3.2	Aufbau Simulationsmodell	54
4	Online-Parameteridentifikation mittels RLS-Algorithmus	57
4.1	Stand der Technik RLS-Algorithmus	58
4.1.1	Offline-Parameteridentifikation	58
4.1.2	Online-Parameteridentifikation	58
4.2	Identifikationsmodelle	62
4.2.1	Stationäre Regressionsmodelle	64
4.2.2	Dynamisches Regressionsmodell	67
4.3	Konditionierung und Sensitivität des Least Squares Problems	74
4.3.1	Konditionierung des Least Squares Problems	74
4.3.2	Sensitivitätsanalyse	77

4.4	Implementierung und Analyse	80
4.4.1	Implementierung und Konfiguration des Savitzky-Golay-Filters	81
4.4.2	Implementierung und Konfiguration des RLS-Algorithmus	83
4.4.3	Simulative Analyse	85
4.4.4	Experimentelle Analyse	95
4.4.5	Zusammenfassung und Diskussion	104
5	Online-Parameteridentifikation mittels erweitertem Kalman-Filter	109
5.1	Stand der Technik beobachterbasierte Verfahren	109
5.2	Identifikationsmodelle Kalman-Filter	115
5.3	Beobachtbarkeitsanalyse	117
5.4	Implementierung und Analyse	125
5.4.1	Implementierung der erweiterten Kalman-Filter	127
5.4.2	Simulative Analyse	129
5.4.3	Experimentelle Analyse	139
5.4.4	Zusammenfassung und Diskussion	147
6	Ableitung von Diagnosekonzepten	151
6.1	Stand der Technik zur Diagnose von Asynchronmaschinen	152
6.1.1	Methoden mit heuristischem Modell	152
6.1.2	Methoden mit analytischem Modell	156
6.1.3	Zusammenfassung Stand der Technik	159
6.2	Online-Identifikation von Parameterabweichungen zur Anomaliedetektion	160
6.2.1	Modifikation der Identifikationsmodelle und Algorithmen	160
6.2.2	Simulative Analyse	162
6.2.3	Experimentelle Analyse	168
6.2.4	Zusammenfassung	171
6.3	Online-Parameteridentifikation zur Fehlerdiagnose durch echtzeitfähige Klassifikatoren	172
6.3.1	Erzeugung der Trainingsdaten	173
6.3.2	Validierung der Trainingsdaten	177
6.3.3	Merkmale zur Klassifikation	179
6.3.4	Auswahl und Training der Klassifikatoren	182
6.3.5	Performanz der Klassifikatoren im dynamischen Betrieb	189
6.3.6	Zusammenfassung und Ausblick	193
6.4	Datenbasierte Referenzmodellierung zur echtzeitfähigen Residuenanalyse	196
6.4.1	Vorstrukturiertes Neuronales Netz	197
6.4.2	Trainingsprozess und Strukturoptimierung	202
6.4.3	Zusammenfassung und Ausblick	205
7	Fazit und Ausblick	209

A	Testumgebung	213
A.1	Fahrzeugparameter	213
A.2	Datenbasierte Modellierung der Leistungselektronik	213
B	Online-Parameteridentifikation mittels RLS Algorithmus	217
B.1	Identifikationsmodelle	217
B.2	Konfigurationen RLS-Algorithmus Simulative und Experimentelle Analysen .	226
B.3	Vergleich erweiterte Recursive-Least-Squares (RLS)-Algorithmen	230
C	Online-Parameteridentifikation mittels erweitertem Kalman-Filter	233
C.1	Konfigurationen der erweiterten Kalman-Filter der simulativen und experimentelle Analysen	233
D	Ableitung von Diagnosekonzepten	237
D.1	Konfigurationen von RLS-Algorithmus und Erweiterte-Kalman-Filter (EKF) bei Online-Identifikation der Abweichung	237
D.2	Konfigurationen des RLS-Algorithmus zur parameterbasierten Fehlerklassifikation	238
D.3	Performanz der Klassifikatoren zur echtzeitfähigen Diagnose	239
	Abkürzungsverzeichnis	243
	Symbolverzeichnis	247
	Literaturverzeichnis	253

1 Einführung

Aufgrund der angestrebten Energiewende findet in der Automobilbranche ein Umbruch mit Fokus auf der Entwicklung elektrifizierter Antriebskonzepte statt. Zur Versorgung der Fahrzeuge stehen neben der Batterie weitere Energieträger wie zum Beispiel Wasserstoff zur Diskussion. Unabhängig vom genutzten Energieträger ist die Umsetzung der Regelungs- und Diagnosesoftware des elektrischen Antriebs ein wesentlicher Faktor für einen effizienten und sicheren Betrieb. Dabei erfordert der Einsatz in elektrifizierten Automobilen im Vergleich zu anderen Anwendungsgebieten elektrischer Maschinen komplexere Strategien, da der Betrieb in einem stark dynamischen Umfeld stattfindet. Demgegenüber steht die herausfordernde Echtzeitimplementierung der entsprechenden Software, da die zur Verfügung stehenden Rechen- und Speicherkapazitäten aus Kostengründen streng limitiert sind.

Neben der Effizienzsteigerung durch hochentwickelte Regelungssoftware elektrischer Antriebssysteme für Automobile rückt auch die Entwicklung innovativer Konzepte zur Online-Diagnose zunehmend in den Fokus. Ausgesprochenes Ziel ist dabei eine Erhöhung der Zuverlässigkeit und damit der Ausfallsicherheit. Zusätzlich verhindert ein prädiktives Diagnosekonzept, je nach Art der auftretenden Anomalie, einen Effizienz- beziehungsweise Komfortverlust. Des Weiteren lassen sich im Extremfall Gefahrensituationen für Insassen vermeiden. Bei den meisten nach Stand der Technik existierenden Diagnoseansätzen ist die Echtzeitfähigkeit keine zentrale Anforderung, weswegen diese zu komplex und rechenintensiv für den Einsatz im hier betrachteten System sind. Diese Tatsache trifft vor allem für auf heuristischen Modellen basierende Diagnoseansätze zu, da zur Merkmalsextraktion oft signalbasierte Spektralanalysen während des laufenden Betriebs, wie zum Beispiel eine Fourier-Transformation, notwendig sind. Außerdem ist deren Modellstruktur häufig zu komplex. Alternativ eignen sich Verfahren zur Online-Identifikation von Zustandsgrößen oder Parametern, die auf analytischen Modellen basieren. Diese kommen häufig in adaptiven Regelungssystemen zum Einsatz und sind daher für gewöhnlich echtzeitfähig. Daher sind diese Verfahren prädestiniert für die Entwicklung alternativer, zustands- oder parameterbasierter Diagnosekonzepte. Eine generelle Einschränkung bestehender Ansätze ist jedoch die nicht erprobte Validität in einem dynamischen, automotiven Betriebsumfeld.

Für den Einsatz im Automobilbereich sind spezielle hochausgenutzte Maschinenkonzepte erforderlich, da ein direkter Zusammenhang zu Gewicht, Bauraum und Kosten der Maschine besteht. Dadurch treten betriebsbedingte Änderungen der Maschinenparameter besonders in Erscheinung, wobei in Bezug auf die Online-Identifikation vor allem das stark nichtlineare

Sättigungsverhalten der Maschine von Bedeutung ist. Neben der permanent- und fremderregten Synchronmaschine wird, unter anderem aufgrund ihres einfachen und robusten Aufbaus und dem Verzicht auf seltene Erden, auch die Asynchronmaschine (ASM) zum Antrieb elektrischer Fahrzeuge eingesetzt. Aufgrund der komplexeren Modellierung des Rotorverhaltens erfolgen die Untersuchungen in dieser Arbeit anhand einer ASM. Alle grundsätzlichen Erkenntnisse bezüglich der Online-Parameteridentifikation (OPI) im automotiven Betriebsumfeld sind jedoch nach Anpassung der zugrundeliegenden mathematischen Modelle auch auf anderen Arten von Maschinen übertragbar.

Bezüglich der strikten Echtzeitanforderung und dem dynamischen Betriebsumfeld im Anwendungsgebiet dieser Arbeit erfolgt die Entwicklung kompatibler, zustands- und parameterbasierter Diagnosekonzepte am Beispiel der ASM als Antriebsmaschine.

1.1 Zustands- und parameterbasierte Diagnosekonzepte für elektrische Antriebssysteme im Automobil

Zur Einführung erfolgt zunächst eine Einordnung der Problemstellung in das hier betrachtete Umfeld und eine schematische Erläuterung der entwickelten Diagnosekonzepte anhand Abb. 1.1. Darin zeigt der grau hinterlegte Teil den Aufbau der Zustands- und Parameterschätzung zur Merkmalsgenerierung. Daneben illustriert der blau hinterlegte Teil die grundsätzliche Struktur der Diagnose.

Für die Umsetzung im Automobil ergeben sich, aufgrund der hinsichtlich ihrer Leistungsfähigkeit festgelegten Hardware, systemspezifische Anforderungen. Zur Merkmalsgenerierung für die Diagnose stehen als Messwerte lediglich die Phasenströme und die Rotorgeschwindigkeit im Taktraaster des Echtzeitsystems zur Verfügung. Zusätzlich steht die Phasenspannung als Stellgröße des Stromreglers zur Verfügung, deren absoluter Wert jedoch aufgrund der Leistungselektronik fehlerbehaftet ist, siehe Abs. 3.1.2. Die Nutzung weiterer Sensorik im Fahrzeug ist aus Kostengründen ausgeschlossen.

Des Weiteren ist die Hardware des Echtzeitsteuergeräts vorgegeben, weswegen sowohl die Rechenkapazität als auch der zur Verfügung stehende Speicherplatz stark limitierende Faktoren sind. Diesbezüglich sei erwähnt, dass das gesamte Regelungssystem höher priorisiert neben der Diagnoseroutine mit den zur Verfügung stehenden Ressourcen betreibbar sein muss. Der Rechen- und Speicheraufwand ist daher möglichst gering zu halten, sodass die Diagnose möglichst dauerhaft aktiv sein kann.

1.1.1 Zustands- und Parameterschätzung zur Merkmalsgenerierung

Zur echtzeitfähigen Umsetzung der Schätzalgorithmen existieren verschiedenste Ansätze. Im Kern basieren diese auf der Berechnung eines Residuums $e = y - \hat{y}$ aus dem Parallelbetrieb der realen Maschine und einem Modell des Systems.

Im einfachsten Fall schätzt ein nicht adaptives Referenzmodell die messbaren Zustandsgrößen des realen Systems. Die Diagnose basiert somit ausschließlich auf dem Verlauf des Residuums. Das Referenzmodell kann eine frei wählbare Struktur annehmen und somit sowohl analytisch als auch heuristisch sein. Einerseits ist dadurch eine sehr flexible Modellgestaltung möglich. Andererseits ist die fehlende Adaptionmöglichkeit unter Umständen nachteilhaft.

Die Rückführung des Residuums durch ein Adaptionsgesetz ermöglicht eine Schätzung von Parametern oder nicht messbaren Systemzuständen, wie die gestrichelte Linie in Abb. 1.1 andeutet. Dieses erweiterte Prinzip dient als Grundlage für verschiedene etablierte Verfahren zur echtzeitfähigen Parameter- und Zustandsadaption in Regelsystemen:

- Ein weit verbreiteter Ansatz ist das Model-Reference-Adaptive-System (MRAS) [1]–[9]. Die Modellstruktur besteht dabei aus einem nicht adaptiven Referenzmodell und einem zusätzlichen adaptiven Modell. Das adaptive Modell kann dabei einen veränderlichen Parameter oder eine Zustandsgröße abbilden, die während des Betriebs durch ein Adaptionsgesetz angepasst wird. Jedoch überzeugten die dynamischen Eigenschaften dieser Struktur während zahlreicher Voruntersuchungen nicht, weswegen der Ansatz für diese Arbeit ungeeignet ist.
- Im Vergleich zum nicht adaptiven Luenberger-Beobachter besitzt ein Erweiterter-Luenberger-Beobachter eine adaptive Verstärkungsmatrix, weswegen auch von einem Sliding-Mode-Beobachter gesprochen wird [10]–[16]. Ein Erweiterter-Luenberger-Beobachter (ELB) ermöglicht daher die Beobachtung veränderlicher Zustände und Parameter eines Zustandsraummodell (ZRM). Im Bereich elektrischer Maschinen findet diese Erweiterung vergleichsweise selten Anwendung. In Bezug auf das Betriebsumfeld in dieser Arbeit offenbarte sich durch Voruntersuchungen vor allem eine geringe Robustheit durch schlechtes dynamisches Verhalten als Nachteil. Aus diesem Grund findet dieser Ansatz hier keine Berücksichtigung.
- Am weitesten verbreitet sind der Recursive-Least-Squares (RLS)-Algorithmus in unterschiedlichen Ausprägungen sowie adaptierte Kalman-Filter (KF) wie das Erweiterte-Kalman-Filter (EKF) und das Unscented-Kalman-Filter (UKF). Im Fall des RLS-Algorithmus optimiert das Adaptionsgesetz den quadratischen Fehler eines linearen analytischen Regressionsmodells durch Anpassung der Modellparameter. Die Schätzung von Zuständen ist mit diesem Ansatz nicht möglich, da hierfür ein Systemmodell

in der Zustandsraumdarstellung erforderlich ist. Adaptierte Formen des KF identifizieren sowohl Parameter als auch Zustände des nichtlinearen ZRM durch eine adaptive Filterstruktur. Der RLS-Algorithmus und adaptierte KF gelten in Bezug auf die Anforderungen im hier betrachteten Betriebsumfeld als die vielversprechendsten Ansätze. Ein wesentlicher Teil dieser Arbeit analysiert daher beide Ansätze zur OPI elektrischer Antriebsysteme im Automobil anhand verschiedener Konfigurationen. Eine zugehörige Aufarbeitung des Stands der Technik findet sich in Kap. 4.1 und 5.1.

1.1.2 Diagnosekonzepte

Voraussetzung für eine zuverlässige Diagnoseroutine sind aussagekräftige und unkorrelierte Merkmale. Nach dem in Abb. 1.1 beschriebenen Schema stehen zur Gewinnung geeigneter Merkmale neben den gemessenen Zustandsgrößen zusätzlich die Ergebnisse der Online-Identifikation zur Verfügung. Zunächst werden die identifizierten Größen aufbereitet und aus den absoluten Werten weitere statistische Merkmale gewonnen. Basierend darauf erfolgt im nächsten Schritt eine Fehlerklassifikation, wobei das überwachte Lernen zum Training aufgrund der beschränkten Rechenkapazität unabhängig vom gewählten Klassifikator nur offline möglich ist. Die Prädiktion des Maschinenzustands ist im einfachsten Fall direkt aus den identifizierten Zustandsgrößen beziehungsweise Parameterwerten durch eine Treshold-Logik möglich. Die Nutzung von Klassifikatoren ermöglicht zusätzlich eine nichtlineare Modellierung des Fehlerverhaltens in weiteren Dimensionen. Zur Erhöhung der Zuverlässigkeit empfiehlt sich jedoch die Auslösung einer Fehlermeldung nicht basierend auf einem einzelnen prädierten Fehler durchzuführen. Beispielsweise kommt die Nutzung von Histogrammen oder empirischen Faktoren zur Gruppierung von Fehlerereignissen in Frage mit dem Ziel Fehlprädiktionen zu reduzieren und somit die Robustheit zu erhöhen.

Aufgrund der begrenzten Rechen- und Speicherkapazitäten sind keine beliebig komplexen Klassifikatoren und Auswertungslogiken implementierbar. Das Ziel lautet daher mit gegebenen Mitteln eine höchstmögliche Zuverlässigkeit zu erzielen.

1.2 Ausgangspunkt und Ziele der Arbeit

Bestehende Verfahren zur OPI der ASM sind vor allem für stationäre Betriebspunkte ausgelegt. Das dynamische Parameter- oder Betriebsverhalten wird daher wenn überhaupt sehr einseitig und anhand einmaliger sprunghaftiger Änderungen betrachtet. Eine transparente Darstellung der Performanz anhand von Messergebnissen aus realitätsnahen Testprofilen existiert daher nicht. Vorhandene Diagnoseansätze sind aufgrund der Art der Signalverarbeitung und der Struktur oft zu komplex für eine echtzeitfähige Umsetzung im hier betrachteten Betriebsumfeld. Übergeordnetes Ziel dieser Arbeit ist die Entwicklung echtzeitfähiger

parameterbasierter Diagnosekonzepte für den Einsatz in einem dynamischen automotiven Betriebsumfeld. Für die Anwendung in realen Fahrzeugen sollen direkt implementierbare Diagnosealgorithmen entstehen. Die Schwierigkeiten im Umgang mit den Algorithmen zur OPI werden durch detaillierte Analysen verschiedener Ansätze herausgearbeitet und basierend darauf konkrete und realistische Handlungsempfehlungen ausgesprochen. Diese Erkenntnisse dienen als Grundlage für die Ableitung unterschiedlicher Diagnosekonzepte. Ein wesentlicher Teil der Arbeit beschäftigt sich mit der OPI der Asynchronmaschine mittels RLS-Algorithmus und erweitertem KF in einem dynamischen automotiven Betriebsumfeld. Daraus lässt sich folgende Forschungsfrage ableiten:

1. Forschungsfrage

Eignen sich etablierte echtzeitfähige Verfahren zur Online-Parameteridentifikation von Asynchronmaschinen für den Einsatz in einem dynamischen automotiven Betriebsumfeld, beziehungsweise welche Modifikationen sind für eine zuverlässige Performanz erforderlich?

Diesbezüglich leistet die vorliegende Arbeit verschiedene Beiträge zum Stand der Forschung:

- Komplexitätsreduktion der Regressionsmodelle für den RLS-Algorithmus und des Zustandsraummodells für erweiterte KF durch Nutzung des vereinfachten Γ -inversen Ersatzschaltbilds der ASM (siehe Abs. 2.3.1, 4.2, 5.2)
- Analyse der dynamischen Eigenschaften stationärer und dynamischer Regressionsmodelle bei Nutzung verschiedener Konfigurationen des RLS-Algorithmus in einem automotiven Betriebsumfeld (siehe Abs. 4.4) [17]
- Modifikation des RLS-Algorithmus durch die Einführung mehrfacher variabler Vergessensfaktoren zur OPI veränderlicher Parameter der ASM (siehe Abs. 2.1.4, 4.4) [17]
- Analyse des Einflusses der betriebspunktabhängigen Eisenverluste auf die OPI anhand des RLS-Algorithmus durch Herleitung erweiterter Regressionsmodelle (siehe Abs. 4.2, 2.1.4, 4.4) [17]
- Analyse des Einflusses des leistungselektronischen Spannungsfehlers auf die OPI anhand des RLS-Algorithmus mit Hilfe eines datenbasierten Modells zur betriebspunktabhängigen Prädiktion (siehe Abs. 4.4) [17]
- Beobachtbarkeitsanalyse des nichtlinearen Zustandsraummodells der ASM bei Nutzung unterschiedlicher Konfigurationen in einem automotiven Betriebsumfeld (siehe Abs. 5.3) [18]

- Analyse der dynamischen Eigenschaften verschiedener Konfigurationen von EKF und UKF in einem automotiven Betriebsumfeld (siehe Abs. 5.4)

Der letzte Teil der vorliegenden Arbeit befasst sich mit der Ableitung unterschiedlicher echtzeitfähiger Diagnoseansätze basierend auf dem in Abb. 1.1 dargestellten Schema. Die Formulierung der zugehörigen Forschungsfrage lautet:

2. Forschungsfrage

Welche Konzepte zur echtzeitfähigen Diagnose elektrischer Fahrzeugantriebe in einem dynamischen Betriebsumfeld ergeben sich basierend auf modifizierten Ansätzen zur Online-Zustands- und Parameteridentifikation?

Aus dieser Fragestellung werden im Rahmen dieser Arbeit drei konkrete Diagnoseansätze abgeleitet:

- Online-Identifikation von Parameterabweichungen zur Anomaliedetektion durch Nutzung des RLS- und EKF-Algorithmus mit modifizierten Regressions- und Zustandsraummodellen (siehe Abs. 6.2) [19]
- Online-Parameteridentifikation mittels RLS-Algorithmus zur Fehlerdiagnose durch echtzeitfähige Klassifikatoren (siehe Abs. 6.3)
- Datenbasierte Referenzmodellierung zur echtzeitfähigen Residuenanalyse (siehe Abs. 6.4) [20]

1.3 Aufbau der Arbeit

Kapitel 2 führt die zum Verständnis der Arbeit erforderlichen Grundlagen auf. Zunächst erfolgt die Herleitung des RLS-Algorithmus inklusive der genutzten Erweiterungen zum Umgang mit dynamischen Parameteränderungen und den Algorithmen des EKF und des UKF. Nach einer Erläuterung der Savitzky-Golay-Glättung zur Diskretisierung und Filterung der Messwerte zeigt der dritte Abschnitt zum Verständnis erforderliche Grundlagen der ASM. Das nächste Kap. 3 beschreibt den Aufbau der experimentellen Testumgebung und die genutzten Hardwarekomponenten. Es folgt eine Beschreibung des entwickelten Simulationsmodells der ASM und der simulativen Testumgebung.

Kapitel 4 und 5 führen detaillierte Untersuchungen zum Vergleich der OPI mittels RLS-Algorithmus und EKF beziehungsweise UKF durch. Der grundsätzliche Aufbau der beiden Kapitel ist dabei identisch: Nach der Erfassung des Stands der Technik erfolgt zunächst die Herleitung der genutzten Identifikationsmodelle. Es folgt jeweils eine theoretische Betrachtung der Konditionierung des Identifikationsproblems. Die anschließende Implementierung

und Analyse vergleicht verschiedene Identifikationsmodelle und Algorithmen anhand simulativer und experimenteller Ergebnisse entlang dynamischer Testprofile. Abschließend ergibt sich aus der besten Konfiguration eine Handlungsempfehlung für reale Anwendungen.

Nach einer detaillierten Erfassung des Stands der Technik werden in Kap. 6 entsprechend der Anforderungen im hier betrachteten System unterschiedliche Diagnosekonzepte abgeleitet. Der in Abs. 6.2 vorgestellte Ansatz nutzt eine modifizierte Form des RLS-Algorithmus zur direkten Identifikation von durch Anomalien verursachten Parameterabweichungen. Hingegen nutzt das in Abs. 6.3 vorgestellte Konzept die Ergebnisse der OPI als Merkmale zur Klassifikation von Fehlverhalten mittels einfacher echtzeitfähiger Klassifikatoren. Der in Abs. 6.4 untersuchte Ansatz stellt eine Möglichkeit zur Residuenanalyse mittels eines datenbasierten, echtzeitfähigen Referenzmodells dar. Das Training des Modells erfolgt dabei offline mit großen Datenmengen, weswegen im Online-Betrieb keine Adaption der Modellparameter möglich ist.

Zum Schluss fasst Kap. 7 die Erkenntnisse zur Beantwortung der Forschungsfragen zusammen und gibt einen Ausblick für zukünftige Forschungsprojekte.

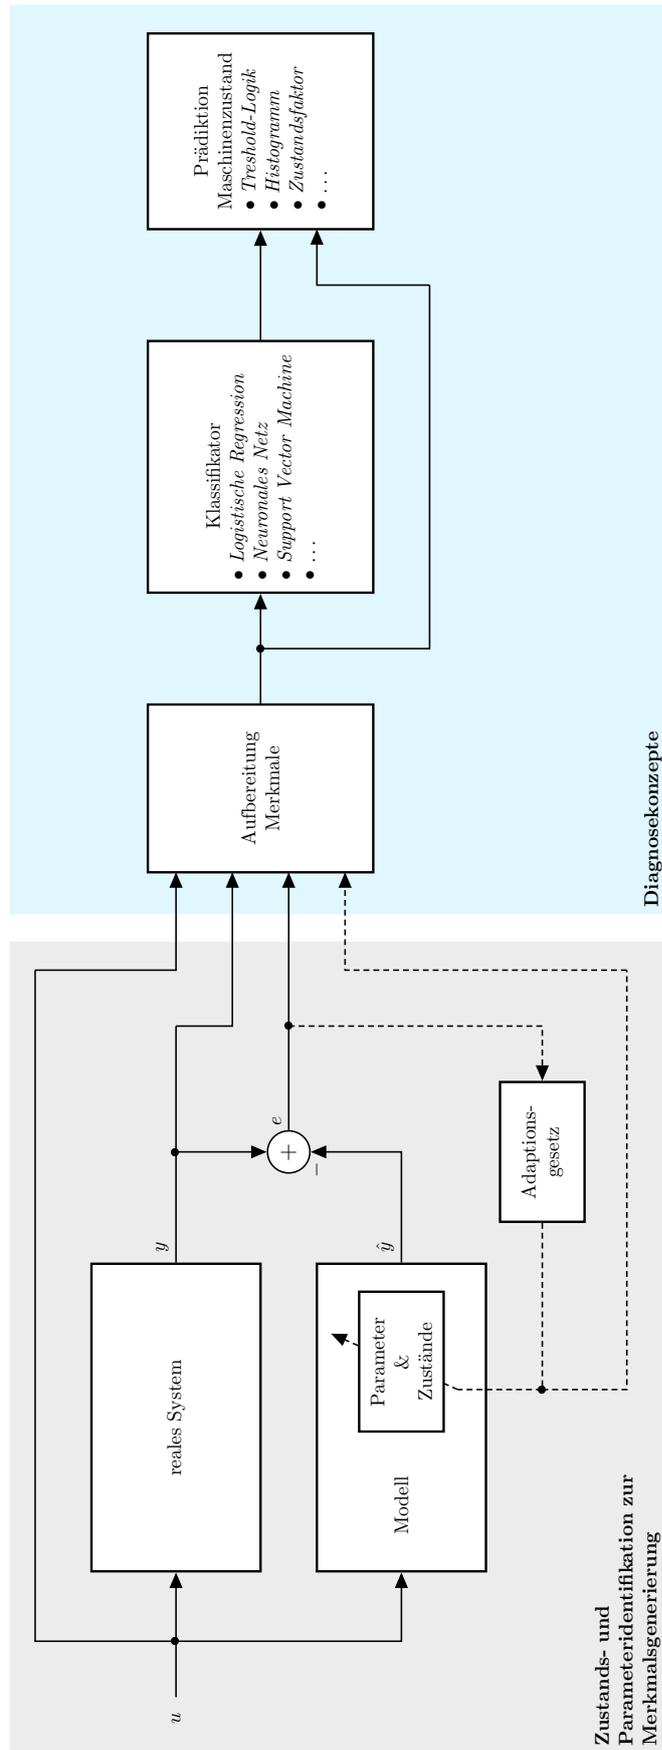


Abbildung 1.1: Schematischer Aufbau der in dieser Arbeit entwickelten Diagnosekonzepte.

2 Grundlagen

Dieses Kapitel erläutert die zum Verständnis dieser Arbeit erforderlichen Grundlagen. Zunächst erfolgt eine Erläuterung der Theorie des Least-Squares (LS)-Verfahrens und die Herleitung der darauf basierenden Identifikationsalgorithmen, die in dieser Arbeit Anwendung finden. Es folgt eine Darstellung der Grundlagen zur analytischen Modellierung der Asynchronmaschine als zu identifizierendes System. In Bezug auf die OPI thematisiert der letzte Abschnitt die elektrischen Parameter sowie die Auswirkungen von Alterung und Fehlverhalten.

2.1 Least-Squares Verfahren zur Parameteridentifikation physikalischer Systeme

Zur Parameteridentifikation physikalischer Systeme existieren zahlreiche Ansätze mit verschiedensten Anwendungsfällen [21]–[23]. Dabei finden je nach notwendiger Detailtiefe sowohl lineare als auch nichtlineare Verfahren Verwendung. Außerdem wird zwischen Offline- und Online-Anwendungen unterschieden. Bei der Offline-Anwendung werden die Systemparameter außerhalb des regulären Betriebs ermittelt. In Bezug auf elektrische Maschinen besteht die wohl bekannteste Versuchsreihe aus Leerlauf- und Kurzschlussversuch [24]. Diese ermittelt grundlegende Maschinenparameter zur Bedatung des zugehörigen Regelsystems. Daneben gibt es jedoch auch Verfahren, die detaillierte Parametersätze im Stillstand oder während spezieller Kommissionierungsläufe ermitteln. Dabei werden nicht selten erweiterte Modellstrukturen oder spezielle Injektionssignale genutzt. Bei der Online-Anwendung hingegen werden die Parameter während des regulären Betriebs der Maschine identifiziert. Aufgrund der häufig geforderten Echtzeitfähigkeit gilt es dabei einen Kompromiss aus Genauigkeit und Laufzeit der Algorithmen zu finden. Unter anderem ist der Umgang mit Messsignalen aus einer unter Umständen stark verrauschten Umgebung eine große Herausforderung. Aufgrund der Relevanz von Parameteränderungen für die Effizienz eines Regelsystems existieren in der Literatur zahlreiche Ansätze zur Lösung dieses Problems. Viele Verfahren basieren auf dem RLS-Verfahren, bei dem im Kern eine lineare Regression zur Parameteroptimierung rekursiv durchgeführt wird. Neben dem klassischen RLS-Algorithmus ist das EKF ein etabliertes Verfahren. Während der RLS-Algorithmus auf einem linearen Systemmodell basiert, nutzt das EKF ein nichtlineares Zustandsraummodell, das zur Identifikation iterativ linearisiert wird.

In Bezug auf die Zielstellung dieser Arbeit sind beide Verfahren aufgrund ihrer dynamischen Eigenschaften und der guten Implementierbarkeit vielversprechende Ansätze.

In diesem Abschnitt wird zunächst die Modellierung physikalischer Systeme mit Bezug auf die angewendeten Methoden erläutert. Zum allgemeinen Verständnis wird die Offline-Anwendung des LS-Verfahrens beschrieben, bevor daraus die Online-Algorithmen zur rekursiven Parameteridentifikation (PI) mittels RLS-Algorithmus und EKF hergeleitet werden. Die Inhalte basieren maßgeblich auf der Grundlagenliteratur von [21], [22]. Detaillierte Herleitungen sowie tiefgreifende systemtheoretische Analysen der Verfahren sind darin nachvollziehbar.

2.1.1 Modellbildung physikalischer Systeme

Die mathematische Beschreibung eines physikalischen Systems erfordert eine Modellvorstellung, welche eine Relation zwischen Ein- und Ausgang herstellt. Laut Iserman et al. lassen sich diese Modelle in zwei Gruppen unterteilen [22]:

1. **Nicht-parametrische Modelle** benötigen keine festgelegte Struktur. Die Beziehung von Ein- und Ausgang wird durch datenbasierte Zusammenhänge repräsentiert. Sie bestehen im einfachsten Fall aus Tabellen, können jedoch auch durch gefittete Funktionen abgebildet werden.
2. **Parametrische Modelle** hingegen nutzen eine mathematische Struktur mit einer festen Anzahl an Parametern und definierten physikalischen Zuständen. Daher sind diese der Kategorie der White-Box-Modelle zuzuordnen. Die Modellstruktur weist dabei einen linearen Zusammenhang zwischen physikalischen Zuständen und Parametern auf.

Eine weitere Unterscheidung erfolgt zwischen linearen und nichtlinearen Modellen. Das LS-Verfahren erfordert eine lineare dynamische Modellvorstellung des zu betrachteten Systems. Zur Parameteridentifikation mit dem LS-Verfahren sind parametrische Modelle erforderlich. Dazu zählen sowohl Übertragungsfunktionen als auch einfache Differentialgleichungen sowie Differentialgleichungssysteme in Form von Zustandsraummodellen. Das physikalische Differentialgleichungsmodell der ASM lässt sich generell als Multiple-Input-Multiple-Output (MIMO) Modell in Form des linearen ZRM beschreiben:

$$\dot{\mathbf{x}} = \mathbf{A} \cdot \mathbf{x} + \mathbf{B} \cdot \mathbf{u} \quad (2.1a)$$

$$\mathbf{y} = \mathbf{C} \cdot \mathbf{x} + \mathbf{D} \cdot \mathbf{u} . \quad (2.1b)$$

Darin definiert \mathbf{u} die Modelleingänge und \mathbf{y} die Modellausgänge. \mathbf{x} enthält als Zustandsvektor die festgelegten physikalischen Zustandsvariablen des Systems. Die Systemmatrix \mathbf{A}

besteht aus den Koeffizienten der Zustandsvariablen, die zu großen Teilen aus den Parametern des Systems bestehen. Die Eingangsparameter finden sich in \mathbf{B} . Die Ausgangsmatrix \mathbf{C} legt die Ausgangsvariablen des Modells fest, während \mathbf{D} die Modellierung eines eventuellen direkten Durchgriffs ermöglicht. Die in Abs. 2.1.6 beschriebene OPI durch Nutzung des EKF-Algorithmus erfordert die Darstellung des zu identifizierenden Systems als MIMO-Modell. Zur OPI mit Hilfe des RLS-Algorithmus wird hingegen ein Identifikationsmodell in Form eines Multiple-Input-Single-Output (MISO) Modells benötigt. Das zuvor beschriebene MIMO Modell lässt sich dazu in mehrere MISO Modelle zerteilen wodurch folgende Form entsteht:

$$y = \mathbf{\Phi}^T \hat{\boldsymbol{\theta}} = \begin{bmatrix} \Phi_1 & \dots & \Phi_m \end{bmatrix} \begin{bmatrix} \theta_1 \\ \vdots \\ \theta_m \end{bmatrix}. \quad (2.2)$$

Darin ist $\mathbf{\Phi}$ die Regressionsmatrix und y der Modellausgang. Die zu identifizierenden Systemparameter finden sich im Parametervektor $\hat{\boldsymbol{\theta}}$, wobei deren Anzahl m die Dimension des Modells vorgibt.

2.1.2 Offline-Parameteridentifikation mit dem Least-Squares Verfahren

Die Parameteridentifikation mit dem LS-Verfahren wird nachfolgend basierend auf [21], [22] erläutert. Dieses erfordert die Darstellung des zu identifizierenden Systems als physikalisches MISO-Modell, das linear in den zu identifizierenden Parametern ist. Die Formulierung des Optimierungsproblems erfolgt dann mit der folgenden Regressionsgleichung in Anlehnung an (2.2):

$$y[k] = \mathbf{\Phi}^T[k] \hat{\boldsymbol{\theta}} + \Delta y[k]. \quad (2.3)$$

Darin besteht der Modellausgang $y[k]$ und die Regressionsmatrix $\mathbf{\Phi}[k]$ aus Messgrößen zu unterschiedlichen Zeitpunkten k bzw. vordefinierten Systemparametern, die von der Identifikation ausgeschlossen sind. Der Parametervektor $\hat{\boldsymbol{\theta}}$ enthält die zu identifizierenden Systemparameter. Hinzu kommt ein Term $\Delta y[k]$, der das Messrauschen des realen Systems abbildet

$$\mathbf{y} = \begin{bmatrix} y[0] \\ y[1] \\ \dots \\ y[N-1] \end{bmatrix}, \quad \mathbf{\Phi} = \begin{bmatrix} \mathbf{\Phi}[0] \\ \mathbf{\Phi}[1] \\ \dots \\ \mathbf{\Phi}[N-1] \end{bmatrix}, \quad \Delta \mathbf{y} = \begin{bmatrix} \Delta y[0] \\ \Delta y[1] \\ \dots \\ \Delta y[N-1] \end{bmatrix}. \quad (2.4)$$

Nach [21], [22] muss zur validen Anwendung des LS-Verfahrens die Annahme getroffen werden, dass es sich bei Δy um weißes und mittelwertfreies Rauschen handelt. Die Identifikation erfolgt basierend auf einem vorhandenen, zuvor aufgenommenen Messdatensatz. Um ein

lösbares Gleichungssystem zu erhalten, muss dabei die Anzahl der Messungen N mindestens der Anzahl der Identifikationsparameter m , d.h. ($N - 1 \geq m$), entsprechen. Ziel der LS-Methode ist die Optimierung des Parametervektors $\hat{\boldsymbol{\theta}}$, sodass das Residuum des Identifikationsfehlers \mathbf{e} minimiert wird:

$$\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \Phi^T \hat{\boldsymbol{\theta}} \stackrel{!}{=} \mathbf{0}. \quad (2.5)$$

Zur Optimierung der Parameter wird das weit verbreitete Gütekriterium der Summe der kleinsten Fehlerquadrate (engl. Least-Squares) nach Gauß herangezogen:

$$J = (\mathbf{y} - \Phi \hat{\boldsymbol{\theta}})^T (\mathbf{y} - \Phi \hat{\boldsymbol{\theta}}) = \sum_{k=0}^{N-1} e^2[k]. \quad (2.6)$$

Die Wahrscheinlichkeit einer optimalen Schätzung ist durch Minimierung dieser Fehlerquadratsumme J am größten. Die notwendige Bedingung für ein Minimum ergibt sich demnach am minimalen Punkt des Gradienten nach den zu identifizierenden Parametern:

$$\nabla_{\hat{\boldsymbol{\theta}}} J = \left[\frac{\partial J}{\partial \hat{\theta}_1} \dots \frac{\partial J}{\partial \hat{\theta}_m} \right]^T = -2 \cdot \Phi^T \mathbf{y} + 2 \cdot \Phi^T \Phi \hat{\boldsymbol{\theta}} \stackrel{!}{=} \mathbf{0}. \quad (2.7)$$

Die algebraische Umformung nach $\hat{\boldsymbol{\theta}}$ ergibt schließlich die Schätzgleichung als Basis für die Parameteridentifikation:

$$\hat{\boldsymbol{\theta}} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{y} = \Phi^+ \mathbf{y}. \quad (2.8)$$

Darin wird Φ^+ als Pseudoinverse der Regressionsmatrix bezeichnet.

Die hinreichende Bedingung für ein Minimum wird durch die Hesse-Matrix überprüft. Es handelt sich nach dem Gütemaß (2.6) um ein Minimum der Schätzparameter $\hat{\boldsymbol{\theta}}$, wenn die zweite Ableitung positiv definit ist.

$$\mathbf{H}(\hat{\boldsymbol{\theta}}) = \left(\frac{\partial^2 J}{\partial \hat{\theta}_i \partial \hat{\theta}_j} \right)_{i,j=1,\dots,m} = \nabla_{\hat{\boldsymbol{\theta}}}^2 J = 2 \cdot \Phi^T \Phi \quad (2.9)$$

Konvergenzverhalten des Least-Squares Verfahrens

Zum Verständnis des Konvergenzverhaltens des LS-Verfahrens lohnt es sich, die statistischen Zusammenhänge während des Identifikationsprozesses zu betrachten. Das Messrauschen $\Delta \mathbf{y}$ tritt als stochastische Größe in Erscheinung und ist repräsentativ für die Ungenauigkeit des Identifikationsmodells. Daher ergibt sich ein stochastischer Zusammenhang zur Konfidenz der Parameteridentifikation, die mit Hilfe der Kovarianz bemessen wird. Die Kovarianz entspricht dem Erwartungswert $E\{\Delta \boldsymbol{\theta}\}$ des Parameterfehlers $\Delta \boldsymbol{\theta} = \hat{\boldsymbol{\theta}} - \boldsymbol{\theta}$ und ergibt sich durch

Berechnung der zugehörigen Kovarianzmatrix:

$$\text{cov}(\Delta\boldsymbol{\theta}) = \text{E} \left\{ (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}) (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \right\}. \quad (2.10)$$

Maßgeblich für die Berechnung der Kovarianz in (2.10) ist demnach der Erwartungswert des geschätzten Parametervektors $\text{E} \{ \hat{\boldsymbol{\theta}} \}$. Dieser ergibt sich, indem der Modellausgang in (2.8) mit Hilfe des Residuums (2.5) substituiert wird. Da die tatsächlichen Parameter $\boldsymbol{\theta}$ des Systems statistisch betrachtet unbekannt sind, gilt dabei die Annahme $\hat{\boldsymbol{\theta}} = \boldsymbol{\theta}$:

$$\text{E} \{ \hat{\boldsymbol{\theta}} \} = \text{E} \left\{ (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{y} \right\} = \text{E} \left\{ (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T (\boldsymbol{\Phi} \boldsymbol{\theta} + \mathbf{e}) \right\}. \quad (2.11)$$

Durch diverse algebraische Umformungen ergibt sich der Erwartungswert zu [22, S.230]:

$$\Rightarrow \text{E} \{ \hat{\boldsymbol{\theta}} \} = \boldsymbol{\theta} + \underbrace{\text{E} \left\{ (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{e} \right\}}_{\mathbf{b}}. \quad (2.12)$$

Daraus ist ersichtlich, dass sich der Erwartungswert aus den realen Parametern $\boldsymbol{\theta}$ und einem Bias \mathbf{b} zusammensetzt. Eine biasfreie Schätzung ergibt sich demnach unter der Voraussetzung, dass die Regressionsmatrix und das Residuum unkorreliert sind und für den Erwartungswert der Residuen $\text{E} \{ \mathbf{e} \} = 0$ gilt [22, S.230]. Unter der Annahme der Unkorreliertheit von $\boldsymbol{\Phi}$ und \mathbf{e} ergibt sich die Kovarianzmatrix durch Substitution von (2.12) in (2.10):

$$\text{cov}(\Delta\hat{\boldsymbol{\theta}}) = \text{E} \left\{ (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{e} \mathbf{e}^T \boldsymbol{\Phi} (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \right\}. \quad (2.13)$$

Ist das Residuum zusätzlich unkorreliert, gilt

$$\text{E} \{ \mathbf{e} \mathbf{e}^T \} = \sigma_e^2 \mathbf{I}. \quad (2.14)$$

Der Faktor σ_e beschreibt darin die Standardabweichung des Residuums. Durch Einsetzen von (2.14) in (2.13) ergibt sich für die Kovarianz folgender Ausdruck:

$$\text{cov}(\Delta\hat{\boldsymbol{\theta}}) = \sigma_e^2 \text{E} \left\{ (\boldsymbol{\Phi}^T \boldsymbol{\Phi})^{-1} \right\} = \sigma_e^2 \text{E} \{ \mathbf{P} \}. \quad (2.15)$$

Da σ_e in der Realität unbekannt ist, wird in der Regel \mathbf{P} als Kovarianzmatrix bezeichnet. Anhand von (2.15) zeigt sich jedoch, dass die Unsicherheit der Parameterschätzung proportional zur Höhe des Messrauschens σ_e ist. Neben der Verringerung von σ_e lässt sich die Kovarianz durch eine Erhöhung der Anzahl der Messpunkte verringern [22].

Die in diesem Abschnitt beschriebene Offline-Anwendung des LS-Verfahrens benötigt unter Umständen große Messdatensätze. Folglich ist dadurch insbesondere die durchzuführende Matrixinversion sehr rechenintensiv. Der dafür erforderliche Speicherplatz und die Rechen-

kapazität zur Verarbeitung sind auf eingebetteten Echtzeitsystemen jedoch nur sehr begrenzt verfügbar, weswegen eine Echtzeitanwendung nicht möglich ist. Die vorgestellte Theorie dient jedoch als Grundlage für die Herleitung rekursiver Methoden in den folgenden Abschnitten.

2.1.3 Online-Parameteridentifikation mit dem Recursive-Least-Squares Algorithmus

Zur echtzeitfähigen Implementierung des LS-Verfahrens wird eine rekursive Form der Schätzgleichung (2.8) benötigt. Diese ermöglicht die Prädiktion eines neuen Parameterwertes in jedem diskreten Zeitschritt des Systems.

Ausgehend von (2.8) und unter Berücksichtigung von (2.15) lässt sich der Momentanwert des geschätzten Parametervektors zum Zeitpunkt k wie folgt beschreiben,

$$\hat{\boldsymbol{\theta}}[k] = \mathbf{P}[k] \boldsymbol{\Phi}^T[k] \mathbf{y}[k] \quad (2.16)$$

wobei

$$\mathbf{P}[k] = (\boldsymbol{\Phi}^T[k] \boldsymbol{\Phi}[k])^{-1} \quad (2.17)$$

gilt. $\hat{\boldsymbol{\theta}}[k]$ besteht aus allen bis zu diesem Zeitpunkt aufgetretenen Messdaten:

$$\mathbf{y}[k] = \begin{bmatrix} y[1] \\ \vdots \\ y[k] \end{bmatrix}, \quad \boldsymbol{\Phi}[k] = \begin{bmatrix} \boldsymbol{\Phi}^T[1] \\ \vdots \\ \boldsymbol{\Phi}^T[k] \end{bmatrix}. \quad (2.18)$$

Zur Herleitung einer rekursiven Berechnungsvorschrift muss eine Verbindung zwischen dem aktuellen Schätzvektor $\hat{\boldsymbol{\theta}}[k]$ und allen vergangenen Schätzwerten $\hat{\boldsymbol{\theta}}[k-1]$ hergestellt werden. Daher wird (2.16) in diese beiden Komponenten zerlegt:

$$\begin{aligned} \hat{\boldsymbol{\theta}}[k] &= \mathbf{P}[k] \begin{bmatrix} \boldsymbol{\Phi}^T[k-1] \\ \boldsymbol{\Phi}^T[k] \end{bmatrix}^T \begin{bmatrix} \mathbf{y}[k-1] \\ y[k] \end{bmatrix} \\ &= \mathbf{P}[k] (\boldsymbol{\Phi}^T[k-1] \mathbf{y}[k-1] + \boldsymbol{\Phi}^T[k] y[k]). \end{aligned} \quad (2.19)$$

Durch Umformung von (2.16) nach

$$\boldsymbol{\Phi}^T[k-1] \mathbf{y}[k-1] = \mathbf{P}^{-1}[k-1] \hat{\boldsymbol{\theta}}[k-1] \quad (2.20)$$

lassen sich die aus Messdaten der vorherigen Schritte bestehende Regressions- und Ausgangsmatrix in (2.19) substituieren. Durch die Erweiterung mit $\hat{\boldsymbol{\theta}}[k-1] - \hat{\boldsymbol{\theta}}[k-1]$ ergibt sich eine

Beschreibung des Zusammenhangs der aktuellen und vorherigen Schätzwerte:

$$\begin{aligned}
\hat{\boldsymbol{\theta}}[k] &= \mathbf{P}[k] \left(\mathbf{P}^{-1}[k-1] \hat{\boldsymbol{\theta}}[k-1] + \boldsymbol{\Phi} y[k] \right) \\
&= \mathbf{P}[k] \mathbf{P}^{-1}[k-1] \hat{\boldsymbol{\theta}}[k-1] + \mathbf{P}[k] \boldsymbol{\Phi} y[k] \\
&= \hat{\boldsymbol{\theta}}[k-1] - \hat{\boldsymbol{\theta}}[k-1] + \mathbf{P}[k] \mathbf{P}^{-1}[k-1] \hat{\boldsymbol{\theta}}[k-1] + \mathbf{P}[k] \boldsymbol{\Phi} y[k] \\
&= \hat{\boldsymbol{\theta}}[k-1] + \left(\mathbf{P}[k] \mathbf{P}^{-1}[k-1] - \mathbf{I} \right) \hat{\boldsymbol{\theta}}[k-1] + \mathbf{P}[k] \boldsymbol{\Phi} y[k].
\end{aligned} \tag{2.21}$$

Jedoch ist auch in dieser Gleichung die Berechnung der inversen Kovarianzmatrix \mathbf{P}^{-1} besonders rechenintensiv und nicht echtzeitfähig. Zur Lösung wird auch (2.17) in vorherige und aktuelle Werte zerlegt:

$$\begin{aligned}
\mathbf{P}[k] &= \left(\boldsymbol{\Phi}^T[k] \boldsymbol{\Phi}[k] \right)^{-1} \\
&= \left(\begin{bmatrix} \boldsymbol{\Phi}[k-1] \\ \boldsymbol{\Phi}[k] \end{bmatrix}^T \begin{bmatrix} \boldsymbol{\Phi}[k-1] \\ \boldsymbol{\Phi}[k] \end{bmatrix} \right)^{-1} \\
&= \left(\boldsymbol{\Phi}^T[k-1] \boldsymbol{\Phi}[k-1] + \boldsymbol{\Phi}[k] \boldsymbol{\Phi}^T[k] \right)^{-1} \\
&= \left(\mathbf{P}^{-1}[k-1] + \boldsymbol{\Phi}[k] \boldsymbol{\Phi}^T[k] \right)^{-1}.
\end{aligned} \tag{2.22}$$

Durch Invertierung und Umformung von (2.22) nach $\mathbf{P}^{-1}[k-1]$ ergibt sich der Ausdruck,

$$\mathbf{P}^{-1}[k-1] = \mathbf{P}^{-1}[k] - \boldsymbol{\Phi}[k] \boldsymbol{\Phi}^T[k]. \tag{2.23}$$

der wiederum in (2.21) eingesetzt wird. Dadurch entsteht die rekursive Form der Schätzgleichung:

$$\hat{\boldsymbol{\theta}}[k] = \hat{\boldsymbol{\theta}}[k-1] + \underbrace{\mathbf{P}[k] \boldsymbol{\Phi}[k]}_{\gamma[k]} \underbrace{\left(y[k] - \boldsymbol{\Phi}^T[k] \hat{\boldsymbol{\theta}}[k-1] \right)}_{e[k]}. \tag{2.24}$$

Ein neuer Schätzvektor $\hat{\boldsymbol{\theta}}[k]$ ergibt sich demnach aus dem Schätzvektor der vorherigen Iteration $\hat{\boldsymbol{\theta}}[k-1]$ und einem Korrekturterm. Letzterer errechnet sich aus dem aktuellen Prädiktionsfehler $e[k]$ auf Basis des alten Parametervektors und einem Korrekturfaktor $\gamma[k]$ beeinflusst von der Kovarianz. Der absolute Wert des Korrekturterms ist also proportional zum verbleibenden Schätzfehler.

Wie in (2.24) ersichtlich, muss auch die Kovarianzmatrix rekursiv berechnet werden. Gleichung (2.22) offenbart, dass auch dazu eine Matrixinversion von Nöten ist. Diese Inversion lässt sich jedoch durch das von Isermann et al. in [22, Abschnitt A.4] präsentierte Matrixinversions-Lemma verhindern. Durch die Anwendung des Lemmas auf (2.22) ergibt

sich folgende rekursive Berechnungsvorschrift:

$$\begin{aligned} \mathbf{P}[k] &= \left(\mathbf{P}^{-1}[k-1] + \Phi[k]\Phi^T[k] \right)^{-1} \\ &= \mathbf{P}[k-1] - \mathbf{P}[k-1]\Phi[k] \left(\Phi^T[k]\mathbf{P}[k-1]\Phi[k] + 1 \right)^{-1} \Phi^T[k]\mathbf{P}[k-1]. \end{aligned} \quad (2.25)$$

Der darin verbleibende zu invertierende Term ist eine skalare Größe, weswegen sich (2.25) als Bruch formulieren lässt. Des Weiteren ergibt sich durch die Erweiterung mit $\Phi[k]$ der in (2.24) dargestellte Korrekturfaktor:

$$\gamma[k] = \mathbf{P}[k]\Phi[k] = \frac{\mathbf{P}[k-1]\Phi[k]}{\Phi^T[k]\mathbf{P}[k-1]\Phi[k] + 1}. \quad (2.26)$$

Substituiert in (2.25) eignet sich (2.26) wiederum zur vereinfachten Darstellung der rekursiven Kovarianz:

$$\mathbf{P}[k] = \mathbf{P}[k-1] - \gamma[k]\Phi^T[k]\mathbf{P}[k-1] = \left(\mathbf{I} - \gamma[k]\Phi^T[k] \right) \mathbf{P}[k-1]. \quad (2.27)$$

Aus den hergeleiteten Berechnungsvorschriften ergibt sich der Recursive-Least-Squares (RLS) Algorithmus 2.1.

Zum Start des Algorithmus werden Initialwerte für die Kovarianzmatrix $\mathbf{P}[0]$ und den Parametervektor benötigt. Diesbezüglich werden von Isermann et al. in [22, S.272] drei verschiedene Herangehensweisen vorgestellt:

1. Start mit dem nicht rekursiven LS-Verfahren:

Ein Vorschlag ist die Initialisierung durch eine nicht rekursive Schätzung mit mindestens $2m$ Messpunkten $\rightarrow k = [1 \dots 2m] = [1 \dots k']$. Die sich daraus ergebenden Endwerte $\hat{\boldsymbol{\theta}}[k']$, $\boldsymbol{\theta}[k']$ zum Zeitpunkt $k = k'$ werden nachfolgend als Initialwerte genutzt.

2. Nutzung von a priori Wissen

Wenn a priori geschätzte Werte der Parameter, der Kovarianz und der Varianz des Residuums vorliegen, sind diese prädestiniert zur Initialisierung von $\hat{\boldsymbol{\theta}}[0]$ und $\mathbf{P}[0]$ nach (2.15). Beyer schlägt in [25, S.141 ff.] ein Verfahren vor, mit dem Initialwerte für die Diagonale der Kovarianzmatrix anhand der maximalen Parameteränderungen abschätzbar sind. Ausgehend von physikalischen Parametergrenzen lässt sich die maximale Streuung des jeweiligen Parameters bestimmen:

$$\theta_{\max,j} - \theta_{\min,j} = \mu(\Delta\theta_j) + 3\sigma_{\Delta\theta_j}. \quad (2.28)$$

Unter Annahme einer mittelwertfreien $\mu(\Delta\theta_j) = 0$ und normalverteilten Schätzung liegen die identifizierten Parameter mit einer Wahrscheinlichkeit von 99,7% im Bereich

Algorithmus 2.1 RLS-Algorithmus

-
- 1: **Initialize:**
 $\mathbf{P}[0], \hat{\boldsymbol{\theta}}[0]$ \triangleright *Verschiedene Ansätze möglich*
 - 2: **Inputs:**
 $y[k], \Phi^T[k]$ \triangleright *gefilterte Messdaten*
 - 3: **while** enabled **do**
 - 4: $e[k] = y[k] - \Phi^T[k]\hat{\boldsymbol{\theta}}[k-1]$ \triangleright *Berechnung Prädiktionsfehler (2.5)*
 - 5: $\gamma[k] = \frac{\mathbf{P}[k-1]\Phi[k]}{\Phi^T[k]\mathbf{P}[k-1]\Phi[k] + 1}$ \triangleright *Berechnung Korrekturfaktor (2.26)*
 - 6: $\hat{\boldsymbol{\theta}}[k] = \hat{\boldsymbol{\theta}}[k-1] + \gamma[k]e[k]$ \triangleright *Update Schätzparameter (2.24)*
 - 7: $\mathbf{P}[k] = (\mathbf{I} - \gamma[k]\Phi^T[k])\mathbf{P}[k-1]$ \triangleright *Update Kovarianzmatrix (2.27)*
 - 8: **return** $\mathbf{P}[k], \hat{\boldsymbol{\theta}}[k]$
-

$\mu \pm 3\sigma_{\Delta\theta_j}$, wenn $\sigma_{\Delta\theta_j}$ der jeweiligen Standardabweichung entspricht. In Verbindung mit (2.15) ergeben sich entsprechend die initialen Diagonaleinträge der Kovarianzmatrix:

$$p_{jj}[0] = \frac{1}{\sigma_e^2} \left(\frac{\theta_{\max,j} - \theta_{\min,j}}{3} \right)^2. \quad (2.29)$$

3. Annahme geeigneter Initialwerte

Ohne die Nutzung von Vorwissen stellt sich vor allem die Frage, wie die Kovarianzmatrix initialisiert wird. Dieses Problem beschreiben Isermann et al. in [22] durch einen Initialisierungsfaktor α :

$$\mathbf{P}(0) = \alpha \mathbf{I}. \quad (2.30)$$

Die Wahl eines großen Wertes für α geht von einer großen Varianz des Parameterfehlers zu Beginn der Identifikation aus. Wird davon ausgegangen, dass keine Informationen über die Parameter bekannt sind, bietet sich an, diese mit $\hat{\boldsymbol{\theta}}[0] = \mathbf{0}$ zu initialisieren. Der Startwert für $\mathbf{P}[0]$ bzw. α kann in Abhängigkeit der Anregung durch die Messgrößen variiert werden. Je höher die Signaländerung und damit der Informationsgehalt zu Beginn der Identifikation sind, desto kleiner kann die Varianz und damit α gewählt werden. Isermann et al. empfehlen für den Praxiseinsatz in [22] Werte zwischen $\alpha = [10 \dots 10^5]$.

2.1.4 Erweiterte RLS-Algorithmen zur Online-Identifikation dynamischer Parameteränderungen

Die Nutzung des im vorherigen Abschnitt hergeleiteten RLS-Algorithmus zur validen Parameteridentifikation in einem realen physikalischen System unterliegt verschiedenen Annahmen. Die maßgebenden Voraussetzungen beziehen sich auf das Rauschverhalten des zu

identifizierenden Systems und damit auf die stochastischen Gegebenheiten während der Identifikation. Eine biasfreie Schätzung ergibt sich mit der Forderung nach einem gänzlich unkorrelierten Residuum e . Voraussetzung dafür ist die Störung des Systems durch ein mittelwertfreies und weißes Rauschen. Da diese Gegebenheiten in einem realen System nur bedingt erfüllt sind, ist auch eine vollkommen biasfreie Schätzung ausgeschlossen. Um diesem Problem entgegen zu treten sind erläutern Iserman et al. und Ljung et al. diverse Erweiterungen des RLS-Algorithmus [21], [22]. Die vorgestellten Methoden nutzen meist zusätzliche Freiheitsgrade oder Annahmen zur erweiterten Modellierung der Rauschkomponenten.

Der Generalized-Least-Squares (GLS)-Algorithmus ermöglicht eine erweiterte Modellierung des Rauschverhaltens durch die Integration zusätzlicher Freiheitsgrade, wodurch allerdings mehr Systemparameter entstehen [22, S.291 ff.]. Das Extended-Recursive-Least-Squares-Verfahren berücksichtigt den als weißes Rauschen angenommenen Fehler als zusätzlichen rekursiven Schätzparameter [22, S.295]. Der Total-Least-Squares (TLS)-Algorithmus nimmt neben dem verrauschten Modellausgang $y[k]$ auch ein Rauschen in der Regressionmatrix $\Phi[k]$ an [22, S.297 ff.]. Die Methode der Biaskorrektur ist ein sehr pragmatischer Ansatz, der im Voraus vermessene Werte zur Korrektur des Bias während der Schätzung einsetzt. Der experimentelle Aufwand ist jedoch erheblich [22, S.296]. Bei der Instrument-Variablen Methode wird die Schätzgleichung auf beiden Seiten um eine Instrument-Variablen-Matrix erweitert [22, S.302 ff.]. Nachteilig ist dabei, dass viele Informationen über das System und den Punkt, in dem die Schätzung stattfindet, bekannt sein müssen. Methoden der stochastischen Approximation nutzen Funktionen zur Beschreibung des stochastischen Verhaltens [22, S.306 f.]. Dabei gelten viele Annahmen für das Rauschen und die Parametrierung ist aufwendig.

Die zuvor beschriebenen Modifikationen des RLS-Algorithmus beziehen sich auf eine Verbesserung des Schätzverhaltens hin zu einer biasfreien Parameteridentifikation. Bei vielen ist der Modellierungs- und Parametrierungsaufwand jedoch erheblich. Der GLS- und TLS-Algorithmus werden in der Literatur in stark verrauschten Systemen oder in Verbindung mit Modellen hoher Ordnung genutzt [22], [26], [27]. Probleme mit dem Messrauschen ergeben sich vor allem durch mehrfach zu differenzierende Eingangsgrößen in Verbindung mit einer hohen Modellordnung. Aus Gründen limitierter Rechenkapazitäten und dem Ziel einer robusten Parameteridentifikation fokussiert diese Arbeit einfache Modelle niedriger Ordnung. Außerdem wird die Echtzeitfilterung der zur Identifikation genutzten Messwerte aufgrund etablierter Filtermethoden nicht als Problem angesehen. Zu Beginn der Untersuchungen durchgeführte Versuche zur Nutzung erweiterter RLS-Algorithmen mit optimiertem Biasverhalten zeigten keine Verbesserung der Ergebnisse. Der Fokus in dieser Arbeit hinsichtlich des übergeordneten Ziels einer parameterbasierten Diagnose erfordert außerdem nicht unbedingt eine vollständig biasfreie Schätzung. Für die Theorie der zuvor genannten Erweiterungen des RLS-Algorithmus wird daher auf einschlägige Literatur verwiesen [21], [22].

Das in dieser Arbeit fokussierte Betriebsumfeld der ASM erfordert ein besonderes Augenmerk

auf dem dynamischen Verhalten der verwendeten Schätzalgorithmen. Daher existieren neben den zuvor beschriebenen Algorithmen auch Erweiterungen der RLS-Methode, die eine Identifikation schneller dynamischer Parameteränderungen während des Betriebs ermöglichen. Die klassische Form des RLS-Algorithmus berücksichtigt stets die gesamte Historie aller aufgetretenen Messdaten im Zeitfenster $1 \dots k$ gleichermaßen. Die dynamische Änderung eines oder mehrerer Parameter während dieses Intervalls kann dabei nicht ermittelt werden beziehungsweise führt zu einem invaliden und biasbehafteten Ergebnis. Um eine Reaktion des Algorithmus auf diese Änderungen zu ermöglichen werden Vergessensfaktoren eingesetzt, die eine stärkere Gewichtung aktueller Messpunkte bewirken. Die entsprechenden Erweiterungen des RLS-Algorithmus werden nachfolgend erläutert. Zusätzliche Erweiterungen finden sich beispielsweise in [22].

RLS-Algorithmus mit exponentiellem Vergessen

Die bekannteste Erweiterung ist die Einführung eines einfachen exponentiellen Vergessensfaktors λ . Dieser führt zu einem gleichwertigen Vergessen aller vergangenen Messpunkte bei fortlaufender Identifikation, was Iserman et al. in [22] als abklingendes Gedächtnis bezeichnen. Die Berücksichtigung des Vergessensfaktors kommt einer Gewichtung der einzelnen Terme des Regressionsmodells gleich. Die Herleitung wird nachfolgend basierend auf dem Weighted-Least-Squares (WLS)-Verfahren erläutert [22, S.279, 281].

Die Gewichtung einer Messung zu einem beliebigen Zeitpunkt k erfolgt nach:

$$w[k] = \lambda^{N-k}, \quad 0 < \lambda \leq 1. \quad (2.31)$$

Bei Betrachtung der Historie einer Identifikation im Intervall $k = 0 \dots N$ ergibt sich daraus eine Gewichtungsmatrix $\mathbf{W}[k]$:

$$\mathbf{W}[k] = \begin{bmatrix} \lambda^N & 0 & \dots & \dots & \dots & 0 \\ \vdots & \lambda^{N-1} & & & & \vdots \\ \vdots & & \ddots & & & \vdots \\ \vdots & & & \lambda^2 & & \vdots \\ \vdots & & & & \lambda & 0 \\ 0 & \dots & \dots & \dots & 0 & 1 \end{bmatrix} = \begin{bmatrix} \lambda \mathbf{W}[k-1] & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix}. \quad (2.32)$$

Darin ist ersichtlich, dass die aktuelle Messung zum Zeitpunkt $k = N$ voll gewichtet wird, während der Einfluss der vorhergehenden Messungen exponentiell sinkt. Mit der Einführung der Gewichtsmatrix \mathbf{W} wird die Schätzgleichung (2.8) wie folgt erweitert:

$$\hat{\boldsymbol{\theta}} = (\boldsymbol{\Phi}^T \mathbf{W} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^T \mathbf{W} \mathbf{y} = \mathbf{P}_\lambda \boldsymbol{\Phi}^T \mathbf{W} \mathbf{y}. \quad (2.33)$$

Das RLS-Verfahren mit exponentiellem Vergessens (RLSEVs) lässt sich durch eine Erweiterung des in Abs. 2.1.3 beschriebenen Ansatzes herleiten. Dazu wird (2.19) um die zerlegte Gewichtungsmatrix (2.32) ergänzt:

$$\begin{aligned}\hat{\boldsymbol{\theta}}[k] &= \mathbf{P}_\lambda[k] \begin{bmatrix} \boldsymbol{\Phi}[k-1] \\ \boldsymbol{\Phi}[k] \end{bmatrix}^T \begin{bmatrix} \lambda \mathbf{W}[k-1] & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix} \begin{bmatrix} \mathbf{y}[k-1] \\ y[k] \end{bmatrix} \\ &= \mathbf{P}_\lambda[k] \left(\lambda \boldsymbol{\Phi}^T[k-1] \mathbf{W}[k-1] \mathbf{y}[k-1] + \boldsymbol{\Phi}[k] y[k] \right).\end{aligned}\quad (2.34)$$

Analog zu (2.20) wird auch hier zur Herleitung der rekursiven Form die diskrete Schätzgleichung

$$\boldsymbol{\Phi}^T[k-1] \mathbf{W}[k-1] \mathbf{y}[k-1] = \mathbf{P}_\lambda[k-1] \hat{\boldsymbol{\theta}}[k-1] \quad (2.35)$$

substituiert und mit $\hat{\boldsymbol{\theta}}[k-1] - \hat{\boldsymbol{\theta}}[k-1]$ erweitert:

$$\begin{aligned}\hat{\boldsymbol{\theta}}[k] &= \mathbf{P}_\lambda[k] \left(\lambda \mathbf{P}_\lambda^{-1} \hat{\boldsymbol{\theta}}[k-1] + \boldsymbol{\Phi}[k] y[k] \right) \\ &= \hat{\boldsymbol{\theta}}[k-1] - \hat{\boldsymbol{\theta}}[k-1] \mathbf{P}_\lambda[k] \left(\lambda \mathbf{P}_\lambda^{-1} \hat{\boldsymbol{\theta}}[k-1] + \boldsymbol{\Phi}[k] y[k] \right) \\ &= \hat{\boldsymbol{\theta}}[k-1] + \left(\lambda \mathbf{P}_\lambda[k] \mathbf{P}_\lambda^{-1}[k-1] - \mathbf{I} \right) \hat{\boldsymbol{\theta}}[k-1] + \mathbf{P}_\lambda[k] \boldsymbol{\Phi}[k] y[k].\end{aligned}\quad (2.36)$$

Zur rekursiven Berechnung der Kovarianzmatrix wird analog der Ausdruck für \mathbf{P}_λ aus (2.33) in die aktuellen und vergangenen Messpunkte zerlegt:

$$\begin{aligned}\mathbf{P}_\lambda[k] &= \left(\boldsymbol{\Phi}^T[k] \boldsymbol{\Phi}[k] \right)^{-1} \\ &= \left(\begin{bmatrix} \boldsymbol{\Phi}[k-1] \\ \boldsymbol{\Phi}[k] \end{bmatrix}^T \begin{bmatrix} \lambda \mathbf{W}[k-1] & \mathbf{0} \\ \mathbf{0}^T & 1 \end{bmatrix} \begin{bmatrix} \boldsymbol{\Phi}[k-1] \\ \boldsymbol{\Phi}[k] \end{bmatrix} \right)^{-1} \\ &= \left(\lambda \mathbf{P}_\lambda^{-1}[k-1] + \boldsymbol{\Phi}[k] \boldsymbol{\Phi}^T[k] \right)^{-1}.\end{aligned}\quad (2.37)$$

Die Gleichung wird wie folgt umgeformt

$$\lambda \mathbf{P}_\lambda^{-1}[k-1] = \mathbf{P}_\lambda^{-1}[k] - \boldsymbol{\Phi}[k] \boldsymbol{\Phi}^T[k] \quad (2.38)$$

und in (2.36) eingesetzt, wodurch sich nach algebraischen Umformungen die erweiterte rekursive Schätzgleichung ergibt:

$$\begin{aligned}\hat{\boldsymbol{\theta}}[k] &= \hat{\boldsymbol{\theta}}[k-1] + \left(\mathbf{P}_\lambda[k] \left(\mathbf{P}_\lambda^{-1}[k] - \boldsymbol{\Phi}[k] \boldsymbol{\Phi}^T[k] \right) - \mathbf{I} \right) \hat{\boldsymbol{\theta}}[k-1] + \mathbf{P}_\lambda[k] \boldsymbol{\Phi}[k] y[k] \\ &= \hat{\boldsymbol{\theta}}[k-1] + \underbrace{\mathbf{P}_\lambda[k] \boldsymbol{\Phi}[k]}_{\boldsymbol{\gamma}[k]} \underbrace{\left(y[k] - \boldsymbol{\Phi}^T[k] \hat{\boldsymbol{\theta}}[k-1] \right)}_{e[k]}.\end{aligned}\quad (2.39)$$

Wie in (2.37) erfordert die rekursive Berechnung der Kovarianzmatrix eine Invertierung von \mathbf{P}_λ , die analog zu (2.25) mit dem von Isermann et al. in [22, Abschnitt A.4] beschriebenen

Matrixinversions-Lemma umgangen wird:

$$\begin{aligned} \mathbf{P}_\lambda[k] &= \frac{1}{\lambda} \mathbf{P}_\lambda[k-1] \\ &\quad - \frac{1}{\lambda} \mathbf{P}_\lambda[k-1] \Phi[k] \left(\Phi^T[k] \frac{1}{\lambda} \mathbf{P}_\lambda[k-1] \Phi[k] + 1 \right)^{-1} \Phi^T[k] \frac{1}{\lambda} \mathbf{P}_\lambda[k-1]. \end{aligned} \quad (2.40)$$

Durch die anschließende Erweiterung mit $\Phi[k]$ ergibt sich die zur Lösung von (2.39) erforderliche Berechnungsvorschrift des Korrekturfaktors:

$$\gamma[k] = \mathbf{P}_\lambda[k] \Phi[k] = \frac{\mathbf{P}[k-1] \Phi[k]}{\lambda + \Phi^T[k] \mathbf{P}[k-1] \Phi[k]}. \quad (2.41)$$

Dieser Ausdruck wird wiederum in der ursprünglichen Gleichung (2.40) substituiert, um eine vereinfachte rekursive Beschreibung der Kovarianz zu erhalten:

$$\mathbf{P}_\lambda[k] = \left(\mathbf{I} - \gamma[k] \Phi^T[k] \right) \mathbf{P}_\lambda[k-1] \frac{1}{\lambda}. \quad (2.42)$$

Die rekursiven Berechnungsvorschriften des RLSEV-Algorithmus sind in Alg. 2.2 zusammengefasst.

Die Wirkungsweise des Vergessensfaktors wird durch Betrachtung von (2.38) und (2.39) verdeutlicht. Mit einem Vergessensfaktor von $\lambda = 1$ ergibt sich eine ungewichtete Berechnung der Kovarianzmatrix wie in (2.15), wobei $\mathbf{P} = \mathbf{P}_\lambda$ gilt. Durch die Wahl von $\lambda < 1$ werden die aktuellen Messwerte mit 1 gewertet, während sich die Kovarianz der vergangenen Messungen zunehmend vergrößert, was gleichbedeutend mit einer zunehmenden Unsicherheit ist. Mit der Wahl eines niedrigen Vergessensfaktors reagiert die Schätzung sehr schnell auf Änderungen der Parameter, ist jedoch auch sehr sensitiv gegenüber Messausreißern. Hingegen wird mit der Erhöhung des Vergessensfaktors die Schätzung träger aber auch robuster. Für den Einsatz in der Praxis stellt sich die Frage, nach welchem Kriterium der einzustellende absolute Wert des Vergessensfaktor gewählt wird. Eine allgemeingültige Aussage darüber ist aufgrund der Vielfalt verschiedener Identifikationsprobleme nicht möglich. Iserman et al. schlagen in [22, S.283] einen Wertebereich von $0,9 < \lambda < 0,995$ vor. Die in Alg. 2.2 integrierte Abbildung stellt zur Einschätzung die Gewichtung von 50 Messpunkten für drei verschiedene Vergessensfaktoren dar. Darin ist ersichtlich, dass der letzte Messpunkt bereits im Falle von $\lambda_3 = 0,9$ nahezu keine Berücksichtigung mehr findet.

Ein wesentlicher Nachteil des exponentiellen Vergessens ist das Auftreten eines Windup-Effekts der Kovarianz in Phasen schwacher Anregung, in denen näherungsweise $\Phi[k] \approx 0$ gilt. Bei Betrachtung von (2.42) ergibt sich unter dieser Annahme folgendes Verhalten der Kovarianzmatrix:

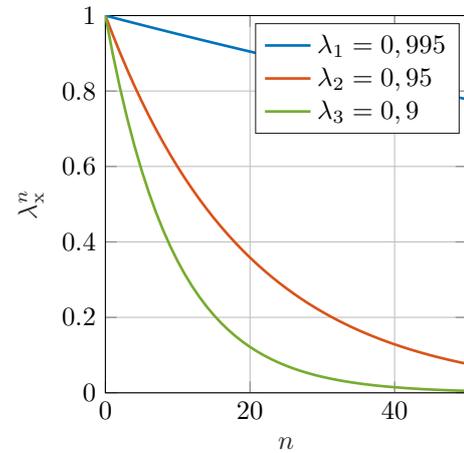
$$\mathbf{P}_\lambda[k] = \left(\underbrace{\mathbf{I} - \gamma[k] \Phi^T[k]}_{\approx 0} \right) \mathbf{P}_\lambda[k-1] \frac{1}{\lambda} \quad (2.43)$$

Algorithmus 2.2 RLS-Algorithmus mit exponentiellem Vergessen

```

1: Initialize:
    $\mathbf{P}_\lambda[0], \hat{\boldsymbol{\theta}}[0], \lambda$ 
2: Inputs:
    $y[k], \Phi^T[k]$ 
3: while enabled do
4:    $e[k] = y[k] - \Phi^T[k]\hat{\boldsymbol{\theta}}[k-1]$ 
5:    $\gamma[k] = \frac{\mathbf{P}_\lambda[k-1]\Phi[k]}{\lambda + \Phi^T[k]\mathbf{P}_\lambda[k-1]\Phi[k]}$ 
6:    $\hat{\boldsymbol{\theta}}[k] = \hat{\boldsymbol{\theta}}[k-1] + \gamma[k]e[k]$ 
7:    $\mathbf{P}_\lambda[k] = (\mathbf{I} - \gamma[k]\Phi^T[k])\mathbf{P}_\lambda[k-1]\frac{1}{\lambda} + \boldsymbol{\kappa}[k]$ 
8: return  $\mathbf{P}[k], \hat{\boldsymbol{\theta}}[k]$ 

```



$$\rightarrow \lim_{\Phi \rightarrow 0} \mathbf{P}_\lambda[k+n] \stackrel{0 < \lambda < 1}{=} \infty.$$

Da $0 < \lambda < 1$ gilt, läuft die Kovarianzmatrix bei ausbleibender Anregung gegen unendlich. Dieses exponentielle Anwachsen wird als Windup-Effekt der Kovarianz bezeichnet. In der Literatur finden sich diverse Maßnahmen, die eine schnelle Nachführung dynamischer Parameteränderungen bei gleichzeitiger Unterdrückung des Windup-Effekts ermöglichen. Diese werden nachfolgend beschrieben.

RLS-Algorithmus mit variablem exponentiellem Vergessen

Eine Option zur Verhinderung des Windup-Effekts ist die Anpassung des Vergessensfaktors in Phasen schwacher Anregung. Dabei variiert λ zwischen einer unteren Grenze $\lambda = \lambda_0$ bei guter Anregung und $\lambda = 1$ bei schlechter Anregung. Als Kriterium zur Variation des Vergessensfaktors existieren verschiedene Ansätze:

- **Kriterium Prädiktionsfehler**

Iserman et al. ziehen in [22, S.340] den a posteriori Fehler als Kriterium heran. Bei kleinem Fehler $e[k]$ wird angenommen, dass die Schätzung eine hohe Genauigkeit aufweist oder die Anregung schwach ist, weswegen sich $\lambda = 1$ als sinnvoll erweist. Wenn sich der Fehler vergrößert, muss $\lambda < 1$ reduziert werden, damit eine Reaktion auf die Veränderung des Systems erfolgen kann. Alternativ varrieren Fortescue et al. den Vergessensfaktors basierend auf der gewichteten Summe des Prädiktionsfehlers [28]:

$$\Sigma[k] = \lambda[k]\Sigma[k-1] + (1 - \Phi\gamma^T[k-1])e^2[k] \quad (2.44)$$

Für die Variation von $\lambda = \lambda_0 \dots 1$ wird eine untere Grenze λ_0 festgelegt und λ so variiert, dass der Prädiktionsfehler während der Identifikation stets konstant bleibt

$\Sigma[k] = \Sigma[k-1] = \Sigma_0[k]$. Aus (2.44) lässt sich somit folgende Funktion ableiten:

$$\lambda[k] = 1 - \frac{1}{\Sigma_0} (1 - \Phi^T[k] \gamma[k]) e^2[k]. \quad (2.45)$$

Isermann et al. schlagen die Festlegung von Σ_0 basierend auf der Varianz des Messrauschens σ_n^2 vor [22]:

$$\begin{aligned} \Sigma_0 &= \sigma_n^2 N_0 \\ N_0 &= \frac{1}{1 - \lambda_0}. \end{aligned} \quad (2.46)$$

- **Kriterium Kovarianz**

Alternativ bietet sich die Änderung der Kovarianzmatrix als Kriterium an, da ein direkter Zusammenhang zwischen der Kovarianz und dem Windup-Effekt besteht. Daher schlagen Krus et al. vor, den Vergessensfaktor abhängig von der Spur (engl. trace, $\text{tr}(\mathbf{P}_\lambda)$) der Kovarianz zu variieren [29]:

$$\lambda[k] = 1 - (1 - \lambda_0) \left(1 - \frac{\text{tr}(\mathbf{P}_\lambda[k])}{\text{tr}(\mathbf{P}_{\lambda, \max})} \right). \quad (2.47)$$

Die Variation des Vergessensfaktors eignet sich am besten für langsame beziehungsweise träge Parameteränderungen. Grund dafür ist die Abhängigkeit des Korrekturfaktors $\gamma[k]$ von der Kovarianz, die sich nur begrenzt schnell ändern kann, siehe (2.26) und (2.27) [22]. Da dies im Anwendungsfall dieser Arbeit nicht zwangsläufig gegeben ist, wird im nächsten Abschnitt eine alternative Form zur Erweiterung des RLS-Algorithmus vorgestellt.

RLS-Algorithmus mit Manipulation der Kovarianzmatrix

Kommt es zu schnellem transienten Parameterverhalten mit hohen oder sprunghaften Änderungen der absoluten Werte, ist die Variation des Vergessensfaktors eine zu träge Methode. Eine alternative oder zusätzliche Möglichkeit ergibt sich durch direkte Adaption der Kovarianzmatrix. Die Umsetzung wird nachfolgend anhand von zwei Varianten vorgestellt:

- **Adaption durch Fehlerschwellwert**

Auch hierzu zeigen Iserman et al. in [22, S.241] eine Methode, bei der in Abhängigkeit definierter Schwellwerte ϵ_1, ϵ_2 ein vielfaches der Einheitsmatrix $\kappa[k]$ auf die Kovarianzmatrix addiert wird:

$$\begin{aligned} \mathbf{P}_\lambda[k] &= \left(\mathbf{I} - \gamma[k] \Phi^T[k] \right) \mathbf{P}_\lambda[k-1] \frac{1}{\lambda} + \kappa[k] \\ \kappa[k] &= \begin{cases} \beta \frac{e^2[k]}{\hat{\sigma}_e^2} \mathbf{I}, & \text{für } \hat{\sigma}_e^2[k] \geq \epsilon_1 \quad \wedge \quad |\hat{\sigma}_e^2[k] - \hat{\sigma}_e^2[k-1]| \geq \epsilon_2 \\ 0, & \text{für } \hat{\sigma}_e^2[k] < \epsilon_1 \quad \wedge \quad |\hat{\sigma}_e^2[k] - \hat{\sigma}_e^2[k-1]| < \epsilon_2. \end{cases} \end{aligned} \quad (2.48)$$

In Abhängigkeit der absoluten Varianz $\hat{\sigma}_e^2$ und der Änderung der Varianz wird die Kovarianzmatrix adaptiert. Je nach Höhe des gewählten Wertes für $\beta > 0$, veranlasst die Methode im Extremfall einen Neustart des RLS-Algorithmus. Nachteilig ist hierbei, dass für jeden Parameter die Kovarianzmatrix gleichermaßen beeinflusst wird. Diese Tatsache kann gerade bei stark unterschiedlichen absoluten Parameterwerten Konvergenzprobleme verursachen.

- **Adaption der Spur**

Eine alternative Methode nach [30] nimmt eine forlaufende Skalierung der Spur der Kovarianzmatrix mit dem Faktor $c_1 > 0$ vor, sodass diese konstant bleibt. Dadurch wird ein exponentielles Wachsen von \mathbf{P}_λ aktiv vermieden:

$$\mathbf{P}_\lambda[k] = c_1 \frac{\mathbf{P}'_\lambda[k]}{\text{tr}(\mathbf{P}'_\lambda[k])} + c_2 \mathbf{I}. \quad (2.49)$$

Unter Berücksichtigung des Faktors $c_2 > 0$ lässt sich die zuvor dargestellte Methode mit der Skalierung der Spur kombinieren. Dadurch ist eine beliebige Einstellung von $\mathbf{P}_\lambda[k]$ möglich.

RLS-Algorithmus mit mehrfachem exponentiellen Vergessen

Im betrachteten System dieser Arbeit sind nicht nur die absoluten Werte der unterschiedlichen Parametertypen stark verschieden. Auch die Ursache und vor allem die Zeitkonstante des transienten Parameterverhaltens haben unterschiedliche Größenordnungen. Für diese Fälle ist es unter Umständen sinnvoll für jeden zu identifizierenden Parameter einen eigenen Vergessensfaktor zu vergeben. Diese Option bietet der im vorherigen Abschnitt hergeleitete Alg. 2.2 jedoch nicht. Die Autoren in [31] leiten daher ein RLS-Verfahren mit mehrfachem exponentiellen Vergessen (RLSMV) her. Darin werden die einzelnen Parameter entkoppelt identifiziert und in einem Vektor zusammengefasst, was die Vergabe unterschiedlicher Vergessensfaktoren ermöglicht. Für eine übersichtliche Darstellung wird nachfolgend der RLSMV-Algorithmus für zwei zu identifizierende Parameter laut [31] in vereinfachter Form hergeleitet. Zunächst wird die Kostenfunktion (2.6) in n Terme aufgeteilt, wobei fortlaufend $n = 2$ gilt:

$$\begin{aligned} J(\hat{\theta}_1, \hat{\theta}_2, k) &= \frac{1}{2} \sum_{i=1}^k \Lambda_1^{k-i} \left(y[i] - \Phi_1[i] \hat{\theta}_1[i] - \Phi_2[i] \hat{\theta}_2[i] \right)^2 \\ &+ \frac{1}{2} \sum_{i=1}^k \Lambda_2^{k-i} \left(y[i] - \Phi_1[i] \hat{\theta}_1[i] - \Phi_2[i] \hat{\theta}_2[i] \right)^2. \end{aligned} \quad (2.50)$$

Die Minimierung erfolgt nun je Parameter durch die Berechnung des jeweiligen Gradienten nach (2.7). Beispielhaft ergibt sich aus (2.50) für Parameter $\hat{\theta}_1$ die folgende Optimierungs-

vorschrift:

$$\frac{\partial J}{\partial \hat{\theta}_1[k]} = 0 \rightarrow \sum_{i=1}^k \Lambda_1^{k-i} (-\Phi_1[i]) (y[i] - \Phi_1[i] \hat{\theta}_1[i] - \Phi_2[i] \hat{\theta}_2[i]) = 0. \quad (2.51)$$

Diese Gleichung wird nun nach dem jeweils gesuchten Parameter umgeformt:

$$\begin{aligned} \hat{\theta}_1[k] &= \left(\sum_{i=1}^k \Lambda_1^{k-i} \Phi_1^2[i] \right)^{-1} \left(\sum_{i=1}^k \Lambda_1^{k-i} (y[i] - \Phi_2[i] \hat{\theta}_2[i]) \right) \\ \hat{\theta}_2[k] &= \left(\sum_{i=1}^k \Lambda_2^{k-i} \Phi_2^2[i] \right)^{-1} \left(\sum_{i=1}^k \Lambda_2^{k-i} (y[i] - \Phi_1[i] \hat{\theta}_1[i]) \right). \end{aligned} \quad (2.52)$$

Trotz der enthaltenen Summen ergibt sich so eine Schätzgleichung je Parameter, die eine Analogie zu (2.8) aufweist. Jedoch ist ersichtlich, dass die Parameter nicht parallel in einer Gleichung sondern getrennt voneinander identifiziert werden. Analog zum in den vorherigen Abschnitten angewendeten Ansatz, lässt sich daraus eine rekursive Schätzgleichung für $\hat{\theta}_1$ und $\hat{\theta}_2$ herleiten. Für eine detaillierte Herleitung wird an dieser Stelle auf [31] verwiesen.

$$\begin{aligned} \hat{\theta}_1[k] &= \hat{\theta}_1[k-1] + \gamma_1[k] (y[k] - \Phi_1[k] \hat{\theta}_1[k-1] - \Phi_2[k] \hat{\theta}_2[k-1]) \\ \hat{\theta}_2[k] &= \hat{\theta}_2[k-1] + \gamma_2[k] (y[k] - \Phi_1[k] \hat{\theta}_1[k-1] - \Phi_2[k] \hat{\theta}_2[k-1]) \end{aligned} \quad (2.53)$$

Die zugehörigen rekursiven Berechnungsvorschriften ergeben sich ebenfalls nach dem bereits bekannten Schema. Durch die Herleitung der rekursiven Kovarianzberechnung ergeben sich die Korrekturfaktoren wie folgt:

$$\begin{aligned} \gamma_1[k] &= \frac{P_{\Lambda,11}[k-1] \Phi_1}{\Lambda_1 + P_{\Lambda,11}[k-1] \Phi_1^2[k] + P_{\Lambda,22}[k-1] \Phi_2^2[k]} \\ \gamma_2[k] &= \frac{P_{\Lambda,22}[k-1] \Phi_2}{\Lambda_2 + P_{\Lambda,11}[k-1] \Phi_1^2[k] + P_{\Lambda,22}[k-1] \Phi_2^2[k]}. \end{aligned} \quad (2.54)$$

Auch diese werden entkoppelt voneinander für jeden zu identifizierenden Parameter ermittelt. Darin entsprechen $P_{\Lambda,11}$ dem ersten und $P_{\Lambda,22}$ dem zweiten Diagonaleintrag der Kovarianzmatrix \mathbf{P}_Λ . Die Elemente auf den Nebendiagonalen von \mathbf{P}_Λ werden in diesem Fall nicht berücksichtigt. Die rekursive Berechnungsvorschrift für $P_{\Lambda,11}$ und $P_{\Lambda,22}$ ergibt sich wie folgt:

$$\begin{aligned} P_{\Lambda,11}[k] &= (1 - \gamma_1[k] \Phi_1[k]) P_{\Lambda,11}[k-1] \frac{1}{\Lambda_1} \\ P_{\Lambda,22}[k] &= (1 - \gamma_2[k] \Phi_2[k]) P_{\Lambda,22}[k-1] \frac{1}{\Lambda_2}. \end{aligned} \quad (2.55)$$

Eine allgemeine Form für n Parameter des von [31] entwickelten Algorithmus wird in [32] und [33] dargestellt. Dieser ergibt sich aus den zuvor gezeigten rekursiven Gleichungen (2.53), (2.54) und (2.55) und ist in Alg. 2.3 zusammengefasst.

Algorithmus 2.3 RLS-Algorithmus mit mehrfachem exponentiellen Vergessen

1: **Initialize:**

$$P_{\Lambda}[0], \hat{\theta}[0], \Lambda$$

2: **Inputs:**

$$y[k], \Phi^T[k]$$

3: **while** enabled **do**

$$4: \quad e[k] = y[k] - \Phi^T[k] \hat{\theta}[k-1]$$

$$5: \quad \gamma_i[k] = \frac{(P_{\Lambda,ii}[k-1] \Phi_i[k]) / \Lambda_i}{1 + (\sum_{i=1}^n P_{\Lambda,ii}[k-1] \Phi_i^2[k]) / \Lambda_i}$$

$$6: \quad \hat{\theta}[k] = \hat{\theta}[k-1] + \gamma[k] e[k]$$

$$7: \quad P_{\Lambda,ii}[k] = (1 - \gamma_i[k] \phi_i[k]) P_{\Lambda,ii}[k-1] \frac{1}{\Lambda_i}$$

8: **return** $P[k], \hat{\theta}[k]$

Allgemein besteht für keine der Erweiterungen des RLS-Algorithmus mit Vergessensfaktor ein mathematischer Beweis [31]–[33]. Die Methoden sind jedoch weit verbreitet und haben sich für Identifikationsprobleme in unterschiedlichen Fachgebieten etabliert. Je nach Problemstellung bietet sich an, die Methoden mit variablem Vergessensfaktors in den RLSMV-Algorithmus zu integrieren, wie der weitere Verlauf dieser Arbeit zeigt.

2.1.5 Systemidentifikation mit dem diskreten Kalman-Filter

Eine weitere etablierte und auf dem LS-Verfahren basierende Methode zur Systemidentifikation ist das von R.E. Kalman in [34] publizierte Kalman-Filter. Dieses wird in der ursprünglichen Form zur Prädiktion von physikalischen Systemzuständen in dynamischen Zustandsraummodellen mit zeitinvarianten Parametern genutzt. Unter den Bedingungen, dass das System linear in den zu schätzenden Zuständen ist und die Wahrscheinlichkeitsverteilung aller vorkommenden Größen einer gaußschen Normalverteilung folgt, liefert das KF optimale Ergebnisse nach dem Kriterium der Summe der kleinsten Fehlerquadrate [35]. Dabei wird die Annahme getroffen, dass zur Schätzung der wahren Wahrscheinlichkeitsverteilung lediglich das erste und zweite mathematische Moment, das heißt der Mittelwert μ und die Varianz σ_{std}^2 , benötigt werden [36, S.7]. Da die angenommene gaußsche Normalverteilung

$$\mathcal{N}(\mu, \sigma_{\text{std}}^2) \sim \frac{1}{\sqrt{2\pi\sigma_{\text{std}}^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma_{\text{std}}^2}\right) \quad (2.56)$$

durch μ und σ_{std}^2 eindeutig bestimmt ist, gehen bei der Schätzung keine Informationen verloren und es wird von einer optimalen Schätzung gesprochen.

Die Theorie des KF ist in zahlreichen Werken mit unterschiedlicher Detailtiefe dargelegt, z.B. [21], [22], [34], [35], [37]–[40]. Zur Implementierung in einem eingebetteten System ist der KF-Algorithmus in diskreter Form erforderlich. Im Verlauf dieses Kapitels erfolgt die

Herleitung des diskreten KF-Algorithmus hauptsächlich basierend auf [21], [22], [40].

Grundlage für das KF ist die diskrete Zustandsraumbeschreibung in Form eines MIMO-Modells (2.1). Für die Identifikation werden die Rauscheigenschaften des Systems gezielt genutzt. Daher werden beide Gleichungen des ZRM, analog zum linearen Modell im Fall des RLS-Algorithmus (2.16), um jeweils einen Rauschterm erweitert:

$$\mathbf{x}[k+1] = \mathbf{A} \cdot \mathbf{x}[k] + \mathbf{B} \cdot \mathbf{u}[k] + \mathbf{Z}_d \cdot \mathbf{z}[k] \quad (2.57a)$$

$$\mathbf{y}[k] = \mathbf{C} \cdot \mathbf{x}[k] + \mathbf{D} \cdot \mathbf{u}[k] + \mathbf{v}[k]. \quad (2.57b)$$

Darin wird $\mathbf{v}[k]$ als Messrauschen und $\mathbf{z}[k]$ als Prozess- bzw. Systemrauschen mit der Matrix \mathbf{Z}_d bezeichnet. Für die Zustandsschätzung mittels KF müssen die Rauschgrößen folgende Voraussetzungen erfüllen [40]:

- Der Schätzfehler $\tilde{\mathbf{e}}[k] = \tilde{\mathbf{x}}[k] - \mathbf{x}[k]$ und das Prozessrauschen $\mathbf{z}[k]$ sind unkorreliert:

$$\text{cov}(\tilde{\mathbf{e}}[k], \mathbf{z}[k]) = 0.$$

- Der Schätzfehler $\hat{\mathbf{e}}[k] = \mathbf{x}[k] - \hat{\mathbf{x}}[k]$ und das Messrauschen $\mathbf{v}[k]$ sind unkorreliert:

$$\text{cov}(\hat{\mathbf{e}}[k], \mathbf{v}[k]) = 0.$$

- Der Schätzfehler $\hat{\mathbf{e}}[k]$ und das Messrauschen $\mathbf{v}[k]$ sind mittelwertfrei, weswegen für die Erwartungswerte folgendes gilt:

$$\text{E}\{\hat{\mathbf{e}}[k]\} = 0 \quad \wedge \quad \text{E}\{\mathbf{v}[k]\} = 0.$$

Ziel ist nun die Definition eines linearen Filters wie in Abb. 2.1, das die Zustände des Modells mit kleinstmöglichem Fehler prädiziert. In der Literatur finden sich verschiedene Ansätze zur Herleitung des KF-Algorithmus.

Allgemein erfolgt die Zustandsschätzung mittels KF durch zwei wesentliche Schritte, die in Abb. 2.1 grau hinterlegt dargestellt sind:

1. Prädiktion

Im Prädiktionsschritt werden mit Hilfe des aktuellen Systemeingangsvektors $\mathbf{u}[k]$ und des diskreten ZRM die Systemzustände $\hat{\mathbf{x}}[k+1]$ geschätzt.

2. Korrektur

Zu Beginn des Korrekturschritts wird der prädizierte Systemausgang $\hat{\mathbf{y}}[k]$ basierend auf $\hat{\mathbf{x}}[k]$ berechnet. Zur Bestimmung des Prädiktionsfehlers $\Delta\hat{\mathbf{y}}[k]$ wird die Differenz zwischen gemessenem $\mathbf{y}[k]$ und prädiziertem Systemausgang $\hat{\mathbf{y}}[k]$ gebildet. Der Prädik-

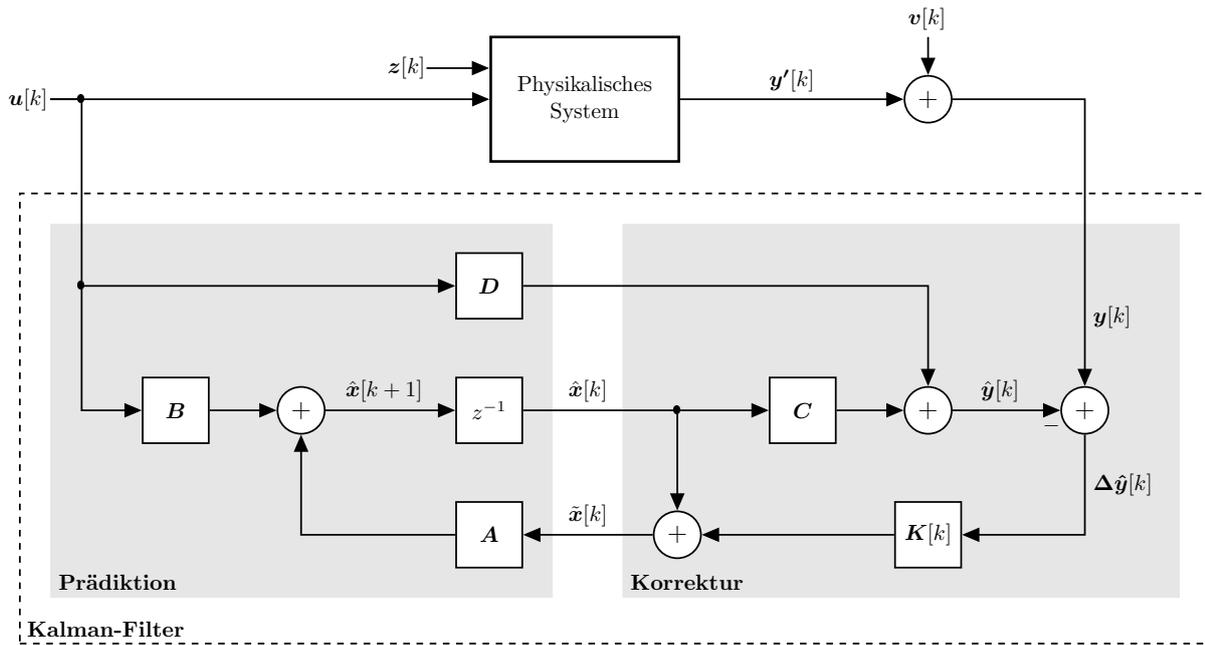


Abbildung 2.1: Blockschaltbild des Kalman-Filters.

tionsfehler $\Delta \hat{\mathbf{y}}[k]$ wird mit der Kalman-Verstärkung $\mathbf{K}[k]$ gewichtet und zur Korrektur des prädizierten Zustandsvektors $\hat{\mathbf{x}}[k]$ genutzt, wodurch $\tilde{\mathbf{x}}[k]$ entsteht.

Die Verbindung zwischen Prädiktions- und Korrekturschritt stellt die Kalman-Verstärkung dar. Diese ergibt sich basierend auf der Kovarianz der Zustandsschätzung. Damit besteht ein enger Zusammenhang zwischen den beiden in (2.57) auftretenden Rauschtermen $\mathbf{v}[k]$, $\mathbf{z}[k]$ und der Konvergenz der Zustandsschätzung. Dieser Zusammenhang wird nachfolgend hergeleitet und daraus der KF-Algorithmus abgeleitet. Als Basis für die Herleitung dient das ZRM eines verrauschten physikalischen Systems (2.57) und das Blockschaltbild des KF, siehe Abb. 2.1. Die Gleichungen zur Berechnung des prädizierten und korrigierten Zustandsvektors ergeben sich direkt aus Abb. 2.1 und lauten wie folgt:

$$\hat{\mathbf{x}}[k+1] = \mathbf{A} \cdot \tilde{\mathbf{x}}[k] + \mathbf{B} \cdot \mathbf{u}[k] \quad (2.58)$$

$$\tilde{\mathbf{x}}[k] = \hat{\mathbf{x}}[k] + \mathbf{K}[k] \cdot (\mathbf{y}[k] - \mathbf{C} \cdot \hat{\mathbf{x}}[k] - \mathbf{D} \cdot \mathbf{u}[k]). \quad (2.59)$$

Kovarianz der Prädiktion

Die Formulierung der Kovarianz ergibt sich durch die Verbindung zwischen wahrem und geschätztem Zustandsvektor über den Schätzfehler zum Zeitpunkt $k+1$:

$$\hat{\mathbf{e}}[k+1] = \mathbf{x}[k+1] - \hat{\mathbf{x}}[k+1]. \quad (2.60)$$

Durch Einsetzen der beiden Zustandsgleichungen (2.57a) und (2.58) resultiert,

$$\begin{aligned}\hat{\boldsymbol{e}}[k+1] &= \mathbf{A} \cdot \boldsymbol{x}[k] + \mathbf{B} \cdot \boldsymbol{u}[k] + \mathbf{Z}_d \cdot \boldsymbol{z}[k] - \mathbf{A} \cdot \tilde{\boldsymbol{x}}[k] + \mathbf{B} \cdot \boldsymbol{u}[k] \\ &= \mathbf{A} \cdot (\boldsymbol{x}[k] - \tilde{\boldsymbol{x}}[k]) + \mathbf{Z}_d \cdot \boldsymbol{z}[k] \\ &= \mathbf{A} \cdot \tilde{\boldsymbol{e}}[k] + \mathbf{Z}_d \cdot \boldsymbol{z}[k]\end{aligned}\tag{2.61}$$

wobei $\tilde{\boldsymbol{e}}$ den Fehler zwischen wahren und korrigiertem Zustandsvektor beschreibt. Die Berechnung der Kovarianz des Schätzfehlers erfolgt folglich basierend auf (2.61):

$$\begin{aligned}\hat{\mathbf{P}}[k+1] &= \text{cov}(\hat{\boldsymbol{e}}[k+1], \hat{\boldsymbol{e}}[k+1]) \\ &= \text{var}(\hat{\boldsymbol{e}}[k+1]) \\ &= \text{var}(\mathbf{A} \cdot \tilde{\boldsymbol{e}}[k] + \mathbf{Z}_d \cdot \boldsymbol{z}[k]) \\ &= \text{var}(\mathbf{A} \cdot \tilde{\boldsymbol{e}}[k]) + \text{var}(\mathbf{Z}_d \cdot \boldsymbol{z}[k]) + 2 \cdot \text{cov}(\mathbf{A} \cdot \tilde{\boldsymbol{e}}[k] + \mathbf{Z}_d \cdot \boldsymbol{z}[k]) \\ &= \mathbf{A} \cdot \text{var}(\tilde{\boldsymbol{e}}[k]) \cdot \mathbf{A}^T + \mathbf{Z}_d \cdot \text{var}(\boldsymbol{z}[k]) \cdot \mathbf{Z}_d^T + 2 \cdot \underbrace{\text{cov}(\mathbf{A} \cdot \tilde{\boldsymbol{e}}[k], \mathbf{Z}_d \cdot \boldsymbol{z}[k])}_{=0}.\end{aligned}\tag{2.62}$$

Unter der oben genannten Voraussetzung, dass der Schätzfehler $\tilde{\boldsymbol{e}}[k]$ und das Prozessrauschen $\boldsymbol{z}[k]$ unkorreliert sind, ergibt sich aus (2.62) die folgende Berechnungsvorschrift:

$$\hat{\mathbf{P}}[k+1] = \mathbf{A} \cdot \tilde{\mathbf{P}}[k] \cdot \mathbf{A}^T + \mathbf{Z}_d \cdot \mathbf{Q}[k] \cdot \mathbf{Z}_d^T.\tag{2.63}$$

Darin beschreibt $\tilde{\mathbf{P}}$ die Kovarianz der korrigierten Schätzung und \mathbf{Q} die Varianz des Prozessrauschens.

Korrekturschritt

Zur Berechnung der Kovarianz des prädizierten Schätzfehlers $\hat{\mathbf{P}}[k+1]$ durch (2.63) im Prädiktionsschritt ist die Kovarianz der korrigierten Schätzung $\tilde{\mathbf{P}}[k]$ erforderlich. Diese ergibt sich wiederum durch die Kalman-Verstärkung $\mathbf{K}[k]$ im Korrekturschritt. Die zugehörigen Berechnungsvorschriften werden nachfolgend hergeleitet.

Zur Bestimmung der Kovarianz $\tilde{\mathbf{P}}[k]$ wird der zugehörige Schätzfehler des korrigierten Zustandsvektors zum Zeitpunkt k

$$\tilde{\boldsymbol{e}}[k] = \boldsymbol{x}[k] - \tilde{\boldsymbol{x}}[k]\tag{2.64}$$

herangezogen. Durch Substitution der verrauschten Ausgangsgleichung (2.57b) und des korrigierten Zustandsvektors (2.59) ergibt sich $\tilde{\boldsymbol{e}}[k]$ wie folgt:

$$\begin{aligned}
\tilde{\mathbf{e}}[k] &= \mathbf{x}[k] - \hat{\mathbf{x}}[k] - \mathbf{K}[k] \cdot (\mathbf{y}[k] - \mathbf{C} \cdot \hat{\mathbf{x}}[k] - \mathbf{D} \cdot \mathbf{u}[k]) \\
&= \mathbf{x}[k] - (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \hat{\mathbf{x}}[k] - \mathbf{K}[k] \cdot \mathbf{y}[k] + \mathbf{K}[k] \cdot \mathbf{D} \cdot \mathbf{u}[k] \\
&= \mathbf{x}[k] - (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \hat{\mathbf{x}}[k] - \mathbf{K}[k] \cdot \mathbf{C} \cdot \mathbf{x}[k] - \mathbf{K}[k] \cdot \mathbf{v}[k] \\
&= (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot (\mathbf{x}[k] - \hat{\mathbf{x}}[k]) - \mathbf{K}[k] \cdot \mathbf{v}[k] \\
&= (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \tilde{\mathbf{e}}[k] - \mathbf{K}[k] \cdot \mathbf{v}[k].
\end{aligned} \tag{2.65}$$

Analog zu (2.62) wird auch hier die Kovarianz von $\tilde{\mathbf{e}}[k]$ unter Annahme der Unkorreliertheit von $\tilde{\mathbf{e}}[k]$ und $\mathbf{v}[k]$ ermittelt:

$$\begin{aligned}
\tilde{\mathbf{P}}[k] &= \text{cov}(\tilde{\mathbf{e}}[k], \tilde{\mathbf{e}}[k]) \\
&= \text{var}(\tilde{\mathbf{e}}[k]) \\
&= \text{var}((\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \tilde{\mathbf{e}}[k] - \mathbf{K}[k] \cdot \mathbf{v}[k]) \\
&= \text{var}((\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \tilde{\mathbf{e}}[k]) + \text{var}(-\mathbf{K}[k] \cdot \mathbf{v}[k]) \\
&\quad + 2 \cdot \underbrace{\text{cov}((\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \tilde{\mathbf{e}}[k], (-\mathbf{K}[k] \cdot \mathbf{v}[k]))}_{=0} \\
&= (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \hat{\mathbf{P}}[k] \cdot (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C})^T + \mathbf{K}[k] \cdot \mathbf{R}[k] \cdot \mathbf{K}[k]^T.
\end{aligned} \tag{2.66}$$

Zur optimalen Zustandschätzung $\tilde{\mathbf{x}}[k]$ muss die Kalman-Verstärkung $\mathbf{K}[k]$ so gewählt werden, dass die Minimierung der Kovarianz $\tilde{\mathbf{P}}[k]$ erfolgt. Da die Spur von $\tilde{\mathbf{P}}[k]$ die Varianzen der zu schätzenden Zustände enthält, wird diese zur Ermittlung des Optimums nach $\mathbf{K}[k]$ abgeleitet,

$$\frac{\partial}{\partial \mathbf{K}} \text{tr}(\tilde{\mathbf{P}}) \stackrel{!}{=} 0 \tag{2.67}$$

woraus sich der folgende Ausdruck ergibt:

$$\hat{\mathbf{P}}[k] \cdot \mathbf{C}^T = \mathbf{K}[k] \cdot (\mathbf{C} \cdot \hat{\mathbf{P}}[k] \cdot \mathbf{C}^T + \mathbf{R}[k]) \tag{2.68}$$

$$\rightarrow \mathbf{K}[k] = \hat{\mathbf{P}}[k] \cdot \mathbf{C}^T \cdot (\mathbf{C} \cdot \hat{\mathbf{P}}[k] \cdot \mathbf{C}^T + \mathbf{R}[k])^{-1}. \tag{2.69}$$

Dass die hinreichende Bedingung für ein Minimum gegeben ist, lässt sich auch hier durch die positive Definitheit der Hesse-Matrix überprüfen:

$$\frac{\partial^2}{\partial^2 \mathbf{K}} \text{tr}(\tilde{\mathbf{P}}) = 2 \cdot (\mathbf{C} \cdot \hat{\mathbf{P}}[k] \cdot \mathbf{C}^T + \mathbf{R}[k])^T. \tag{2.70}$$

Durch Substitution von (2.68) in (2.66) ergibt sich eine vereinfachte Berechnungsvorschrift der Kovarianzmatrix $\tilde{\mathbf{P}}[k]$ zur Implementierung:

$$\tilde{\mathbf{P}}[k] = (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{C}) \cdot \hat{\mathbf{P}}[k]. \tag{2.71}$$

Algorithmus 2.4 Klassischer Kalman-Filter Algorithmus

```

1: Initialize:
    $\hat{\mathbf{x}}_0, \mathbf{P}_0, \mathbf{R}, \mathbf{Q}$  ▷ Verschiedene Ansätze
2: Inputs:
    $\mathbf{u}_k, \mathbf{y}_k$ 
3: while enabled do
4:    $\hat{\mathbf{x}}_{k|k-1} = \mathbf{A}\tilde{\mathbf{x}}_{k-1|k-1} + \mathbf{B}\mathbf{u}_{k-1}$  ▷ Zustandsprädiktion (2.58)
5:    $\hat{\mathbf{P}}_{k|k-1} = \mathbf{A}\tilde{\mathbf{P}}_{k-1|k-1}\mathbf{A}^T + \mathbf{Z}_d\mathbf{Q}\mathbf{Z}_d^T$  ▷ Kovarianz Zustandsprädiktion (2.63)
6:    $\mathbf{K}_k = \hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T(\mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T + \mathbf{R})^{-1}$  ▷ Kalman-Verstärkung (2.69)
7:    $\tilde{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k(\mathbf{y}_k - \mathbf{C}\hat{\mathbf{x}}_{k|k-1} - \mathbf{D}\mathbf{u}_k)$  ▷ Korrektur Zustandsvektor (2.59)
8:    $\tilde{\mathbf{P}}_{k|k} = (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{P}}_{k|k-1}$  ▷ Korrektur Kovarianzmatrix (2.71)
9: return  $\mathbf{P}_k, \hat{\mathbf{x}}_k$ 

```

Die zuvor hergeleiteten Gleichungen sind in Alg. 2.4 zusammengefasst.

Da der Durchgriff \mathbf{D} im hier betrachteten System nicht vorhanden ist, wird auf dessen Darstellung verzichtet. Außerdem sind die Kovarianzmatrizen der Rauschgrößen im Fall des nicht adaptiven KF konstant, weswegen $\mathbf{Q}[k] = \mathbf{Q}$ und $\mathbf{R}[k] = \mathbf{R}$ gilt.

Initialisierung des Kalman-Filters

Wie in Alg. 2.4 ersichtlich, muss auch das KF geeignet initialisiert werden. Im Vergleich zum RLS-Algorithmus müssen hier neben den initialen Schätzwerten $\hat{\mathbf{x}}[0]$ und der Kovarianzmatrix $\mathbf{P}[0]$ zusätzlich die Kovarianzen des Prozess- \mathbf{Q} und des Messrauschens \mathbf{R} initialisiert werden. Die Festlegung der Rauschgrößen ist von signifikanter Bedeutung für das Konvergenzverhalten des KF-Algorithmus. Allgemein wird durch die Wahl der Initialwerte das transiente Verhalten aber auch die Robustheit des Filters festgelegt. Daher werden nachfolgend die Auswirkungen der Initialwerte auf das Verhalten des KF erläutert:

- **Initialwerte der Systemzustände** $\rightarrow \hat{\mathbf{x}}[0] = \mathbf{E}\{\hat{\mathbf{x}}_0\}$

Mit der Wahl der initialen Systemzustände wird die Konvergenzzeit maßgeblich beeinflusst. Wird zur Initialisierung a priori Wissen aus vorherigen oder offline durchgeführten Identifikationen berücksichtigt, befinden sich die geschätzten Werte ab der ersten Iteration im Bereich der wahren Werte, was zu einer schnellen Konvergenz führt. Ist dieses Wissen nicht vorhanden, ist die Initialisierung mit dem Nullvektor geeignet. Hingegen kann eine Vorgabe von um Größenordnungen verschiedenen Initialwerten zur Divergenz des Algorithmus führen.

- **Initialwerte der Fehlerkovarianzmatrix**

$$\rightarrow \mathbf{P}[0] = \mathbf{E}\left\{(\hat{\mathbf{x}}_0 - \mathbf{E}\{\hat{\mathbf{x}}_0\})(\hat{\mathbf{x}}_0 - \mathbf{E}\{\hat{\mathbf{x}}_0\})^T\right\}$$

Die Fehlerkovarianzmatrix wird auf ihrer Hauptdiagonalen mit den Varianzen der Systemzustände initialisiert. Dabei besteht ein Zusammenhang zu den zuvor beschriebenen

nen Initialisierungswerten $\hat{\mathbf{x}}[0]$. Liegen die initialen Systemzustände in der Nähe der wahren Werte, ergibt sich daraus eine geringe Unsicherheit und damit eine kleine zu initialisierende Varianz. Erfolgt die Wahl von $\mathbf{P}[0]$ jedoch mit zu kleinen Werten, besteht die Gefahr einer *inkonsistenten Schätzung* nach [36, S.39]. Dabei wird die Spur der geschätzten Werte kleiner als die der wahren Werte angenommen. Dadurch wird die Sensibilität des KF eingeschränkt und es erfolgt keine oder eine zu geringe Reaktion auf Zustandsänderungen. Folglich ergeben sich biasbehaftete oder gar divergierende Zustandsschätzungen. Zu groß initialisierte Varianzen hingegen suggerieren eine hohe Unsicherheit der Zustandsschätzung und fördern damit instabiles Filterverhalten.

- **Kovarianzmatrix des Prozessrauschens** $\rightarrow \mathbf{Q} = \text{E} \{ \mathbf{z} \cdot \mathbf{z}^T \}$

Die Kovarianzmatrix des Prozessrauschens berücksichtigt die Unsicherheit des zugrundegelegten ZRM gegenüber dem realen physikalischen System. Daher ist die Initialisierung von \mathbf{Q} in Abhängigkeit des Abstraktionsgrads des Modells durchzuführen. Im Fall der ASM führen beispielweise die Vernachlässigung der Eisenverluste, Sättigungseffekte oder Stromverdrängung zu Prozessrauschen. Aber auch Diskretisierungsfehler sowie Messrauschen von ausschließlich in der Systemmatrix auftretenden Messgrößen sind von Bedeutung.

Die Betrachtung von (2.63) und (2.69) zeigt einen direkten Zusammenhang von \mathbf{Q} und der Kalman-Verstärkung $\mathbf{K}[k]$. Daher wird auch durch die Wahl der Kovarianz des Prozessrauschens die Dynamik des KF beeinflusst. Hohe Werte für \mathbf{Q} führen zu einer großen Kalman-Verstärkung und somit zu einer potenziell schnelleren Konvergenz. Jedoch führt auch eine zu hohe Kalman-Verstärkung zur Divergenz des KF-Algorithmus. Durch die Wahl zu kleiner Werte für \mathbf{Q} wird auch $\mathbf{K}[k]$ klein und es erfolgt keine Reaktion auf dynamische Zustandsänderungen. Gängige Praxis ist die heuristische Einstellung von \mathbf{Q} durch praktische Versuche. Allerdings existieren auch Methoden zur iterativen Adaption von \mathbf{Q} , wie zum Beispiel das ROSE-Filter in [40]. Aufgrund der eingeschränkten Rechenkapazität im hier betrachteten Echtzeitsystem wird dieser Ansatz jedoch nicht weiter verfolgt.

- **Kovarianzmatrix des Messrauschens** $\rightarrow \mathbf{R} = \text{E} \{ \mathbf{v} \cdot \mathbf{v}^T \}$

Die Kovarianzmatrix \mathbf{R} berücksichtigt die durch das Messrauschen von Sensoren verursachten Unsicherheiten. Außerdem repräsentiert \mathbf{R} Quantisierungsfehler, die durch Messfilter und Diskretisierung entstehen.

Auch durch die Initialisierung von \mathbf{R} wird die Kalman-Verstärkung (2.69) und damit das dynamische Verhalten des KF beeinflusst. Im Vergleich zu \mathbf{Q} ist die zu initialisierende Varianz in \mathbf{R} durch eine betriebspunktabhängige Analyse des Messrauschens der genutzten Sensorik abschätzbar.

2.1.6 Online-Parameteridentifikation mit erweitertem Kalman-Filter

Viele physikalische Systeme bzw. Identifikationsprobleme lassen sich nur durch nichtlineare ZRM der folgenden Form beschreiben:

$$\mathbf{x}[k+1] = \mathbf{f}(\mathbf{x}[k], \mathbf{u}[k]) + \mathbf{Z}_d \cdot \mathbf{z}[k] \quad (2.72a)$$

$$\mathbf{y}[k] = \mathbf{g}(\mathbf{x}[k]) + \mathbf{v}[k]. \quad (2.72b)$$

Zur Identifikation solcher Systeme existieren adaptierte Formen des KF wie das EKF oder das UKF. Neben der Zustandsprädiktion eignen sich die erweiterten Methoden zur zeitgleichen Schätzung zeitvarianter Systemparameter und damit zur OPI. Im Verlauf dieses Abschnitts erfolgt die Herleitung des EKF-Algorithmus basierend auf [22]. Des Weiteren werden die Besonderheiten zur Parameteridentifikation mittels EKF erläutert.

Algorithmus des Erweiterten Kalman-Filters

Die Prädiktion des Zustandsvektors erfolgt beim EKF analog zum diskreten KF auf Basis der nichtlinearen Zustandsgleichung:

$$\hat{\mathbf{x}}[k+1] = \mathbf{f}(\hat{\mathbf{x}}[k], \mathbf{u}[k]). \quad (2.73)$$

Für die Prädiktion der Fehlerkovarianz ist jedoch die Linearisierung des ZRM erforderlich. Dazu werden (2.72a) und (2.72b) durch eine Taylor-Reihe erster Ordnung in jedem Zeitschritt k approximiert. Dazu ist wiederum die Berechnung der Jacobimatrix der beiden nichtlinearen Funktionen von Nöten:

$$\mathbf{F}[k] = \left. \frac{\partial \mathbf{f}(\mathbf{x}, \mathbf{u})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}, \mathbf{u}=\mathbf{u}[k]} \quad (2.74)$$

$$\mathbf{G}[k] = \left. \frac{\partial \mathbf{g}(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}}. \quad (2.75)$$

Grundsätzlich ist auch eine Taylorreihenentwicklung höherer Ordnung denkbar. Der dadurch zusätzlich benötigte Rechenaufwand ist jedoch mit der strikten Echtzeitanforderung in dieser Arbeit nicht vereinbar.

Durch die Taylorapproximation der Eingangsfunktion (2.74) ergibt sich die modifizierte Gleichung zur Prädiktion der Fehlerkovarianz, indem die Systemmatrix \mathbf{A} und die Eingangsmatrix \mathbf{B} in (2.63) substituiert werden:

$$\hat{\mathbf{P}}[k+1] = \mathbf{F} \cdot \tilde{\mathbf{P}}[k] \cdot \mathbf{F}^T + \mathbf{Z}_d \cdot \mathbf{Q} \cdot \mathbf{Z}_d^T. \quad (2.76)$$

Analog ergeben sich die angepassten Gleichungen des Korrekturschrittes indem die Ausgangsmatrix \mathbf{C} durch (2.75) substituiert wird:

$$\mathbf{K}[k] = \hat{\mathbf{P}}[k] \cdot \mathbf{G}^T \cdot (\mathbf{G} \cdot \hat{\mathbf{P}}[k] \cdot \mathbf{G}^T + \mathbf{R})^{-1} \quad (2.77)$$

$$\tilde{\mathbf{x}}[k] = \hat{\mathbf{x}}[k] + \mathbf{K}[k] \cdot (\mathbf{y}[k] - \mathbf{g}(\hat{\mathbf{x}}[k])) \quad (2.78)$$

$$\tilde{\mathbf{P}}[k] = (\mathbf{I} - \mathbf{K}[k] \cdot \mathbf{G}) \cdot \hat{\mathbf{P}}[k]. \quad (2.79)$$

Der Algorithmus des EKF ist in Alg. 2.5 zusammengefasst.

Im Vergleich zum KF muss an dieser Stelle erwähnt werden, dass das EKF im statistischen Sinne keine optimalen Ergebnisse liefert. Durch die nichtlineare Transformation im EKF verändert sich die Verteilung der Wahrscheinlichkeitsgrößen, sodass keine Gaußverteilung nach (2.56) mehr vorliegt. Daher weist das EKF eine hohe Sensitivität gegenüber Abweichungen durch die Linearisierung auf, die zur Divergenz des Algorithmus führen können.[22, S.548] Grundsätzlich gelten die in Abs. 2.1.5 dargestellten Aspekte zur Initialisierung auch für die Nutzung des EKF. Jedoch steigt durch die Linearisierung des nichtlinearen ZRM die Sensitivität gegenüber fehlerhaft initialisierten Systemzuständen. Gerade bei stark nichtlinearen Systemen steigt die Dominanz der Terme höherer Ordnung in der Taylorreihe. Das EKF ist dann besonders anfällig für Divergenzen, da fehlerhafte Initialwerte des Zustandsvektors zu einer unter Umständen deutlich verfälschten Annahme der a priori Verteilungsdichte führen.[41]

Algorithmus des Unscented Kalman-Filters

Durch die Taylorapproximation im EKF-Algorithmus können bei stark nichtlinearen Systemen bedingt durch die Linearisierung Probleme auftreten. Diese resultieren aus den sich ergebenden Ungenauigkeiten für Nichtlinearitäten höherer Ordnung. Um diesen Fehlerquellen entgegen zu treten, existiert das UKF als alternatives adaptiertes KF.

Anstatt der Linearisierung approximiert das UKF den statistischen Verlauf der Zufallsvariablen durch Nutzung der tatsächlichen nichtlinearen Modellgleichungen. Die Eigenschaften der Wahrscheinlichkeitsverteilung sind dabei durch deterministisch gewählte Punkte spezifiziert [42]. Diese Punkte müssen den Mittelwert und die Kovarianz der Wahrscheinlichkeitsverteilung nach der Propagierung durch das wahre nichtlineare System möglichst genau beschreiben. Dabei umfasst das UKF laut [43] für gaußverteilte Zufallsvariablen mit beliebiger Nichtlinearität eine genaue posteriore Abbildung des Mittelwertes und der Kovarianz bis zur dritten Taylorapproximation. Der zuvor beschriebene Prozess ist als Unscented-Transformation (UT) bekannt und wird nachfolgend in Anlehnung an [43] erläutert.

Die UT ermöglicht die Berechnung statistischer Eigenschaften einer nichtlinear transformierten Zufallsvariable [43]. Angenommen bei $\mathbf{x} \sim \mathcal{N}(\mu_x, \mathbf{P}_x)$ handelt es sich um eine L -dimensionale gaußverteilte Zufallsvariable mit dem Mittelwert $\mu_x = \mathbb{E}\{x\}$ und der Kovarianz

Algorithmus 2.5 Erweiterter Kalman-Filter Algorithmus

```

1: Initialize:
    $\hat{\mathbf{x}}_0, \mathbf{P}_0, \mathbf{R}, \mathbf{Q}$ 
2: Inputs:
    $\mathbf{u}_k, \mathbf{y}_k$ 
3: while enabled do
4:   Prädiktion:
5:    $\hat{\mathbf{x}}_{k|k-1} = \mathbf{f}(\tilde{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1})$  ▷ Zustandsprädiktion (2.73)
6:    $\mathbf{F}_k = \left. \frac{\partial \mathbf{f}(\mathbf{x}, \mathbf{u})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\tilde{\mathbf{x}}_{k-1|k-1}, \mathbf{u}=\mathbf{u}_{k-1}}$  ▷ Linearisierung Zustandsgleichung (2.74)
7:    $\mathbf{G}_k = \left. \frac{\partial \mathbf{g}(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}}$  ▷ Linearisierung Ausgangsgleichung (2.75)
8:    $\hat{\mathbf{P}}_{k|k-1} = \mathbf{F}_k \tilde{\mathbf{P}}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{Z}_d \mathbf{Q} \mathbf{Z}_d^T$  ▷ Kovarianz Zustandsprädiktion (2.76)
9:   Korrektur:
10:   $\mathbf{K}_k = \hat{\mathbf{P}}_{k|k-1} \mathbf{G}_k^T (\mathbf{G}_k \hat{\mathbf{P}}_{k|k-1} \mathbf{G}_k^T + \mathbf{R})^{-1}$  ▷ Kalman-Verstärkung (2.77)
11:   $\tilde{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \mathbf{g}(\hat{\mathbf{x}}_{k|k-1}))$  ▷ Korrektur Zustandsvektor (2.78)
12:   $\tilde{\mathbf{P}}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{G}_k) \hat{\mathbf{P}}_{k|k-1}$  ▷ Korrektur Kovarianzmatrix (2.79)
13: return  $\mathbf{P}_k, \hat{\mathbf{x}}_k$ 

```

\mathbf{P}_x . Diese Zufallsvariable wird durch eine nichtlineare Funktion $y = g(\mathbf{x})$ propagiert. Zur Beschreibung der statistischen Eigenschaften von y mittels der UT dient eine Matrix \mathcal{X} , die aus $2L + 1$ Sigma-Vektoren \mathcal{X}_i und entsprechenden Gewichten w_i besteht. Diese setzen sich wie folgt zusammen [43]:

$$\begin{aligned}
\mathcal{X}_0 &= \mu_x \\
\mathcal{X}_i &= \mu_x + \left(\sqrt{(L + \lambda) \mathbf{P}_x} \right)_i \quad i = 1, \dots, L \\
\mathcal{X}_i &= \mu_x - \left(\sqrt{(L + \lambda) \mathbf{P}_x} \right)_{i-L} \quad i = L + 1, \dots, 2L \\
w_0^{(m)} &= \frac{\lambda}{L + \lambda} \\
w_0^{(c)} &= \frac{\lambda}{L + \lambda} + (1 - \alpha^2 + \beta) \\
w_i^{(m)} &= w_i^{(c)} = \frac{1}{2(L + \lambda)} \quad i = 1, \dots, 2L.
\end{aligned} \tag{2.80}$$

Darin ist λ ein festzulegender Skalierungsfaktor

$$\lambda = \alpha^2 (L + \kappa) - L \tag{2.81}$$

und α bestimmt wiederum die Ausbreitung der Sigma-Punkte um den Mittelwert μ . Der Wertebereich ist mit $\alpha = 0 \dots 1$ festgelegt und α entspricht in der Regel einem kleinen Wert

im Bereich 10^3 [43]. Zur Berechnung der Quadratwurzel der Kovarianzmatrix $\sqrt{(L + \lambda) \mathbf{P}}$ ist die Cholesky-Faktorisierung nach [44] am effizientesten, für die allerdings die positive Semidefinitheit der Kovarianzmatrix Voraussetzung ist. Diese stellt der Faktor $\kappa \geq 0$ in (2.83) sicher, wobei gewöhnlich kein spezifischer von null verschiedener Wert erforderlich ist. Der Faktor β ermöglicht die Berücksichtigung von Kenntnissen über Momente höherer Ordnung der Wahrscheinlichkeitsverteilung. Für gaußverteilte Zufallsvariablen hat sich laut [43] ein Wert von $\beta = 2$ etabliert.

Nach der UT werden die zuvor berechneten Sigma-Punkte durch die nichtlineare Funktion propagiert:

$$\mathcal{Y}_i = g(\mathcal{X}_i). \quad (2.82)$$

Die approximierte Verteilung der durch die nichtlineare Funktion propagierten Zufallsvariable ergibt sich durch eine gewichtete Approximation des Mittelwerts $\mu_y = E\{y\}$ und der Kovarianz \mathbf{P}_y der posterioren Sigma-Punkte

$$\begin{aligned} \mu_y &\approx \sum_{i=0}^{2L} \mathbf{w}_i^{(m)} \mathcal{Y}_i \\ \mathbf{P}_y &\approx \sum_{i=0}^{2L} \mathbf{w}_i^{(c)} \{\mathcal{Y}_i - \mu_y\} \{\mathcal{Y}_i - \mu_y\}^T. \end{aligned} \quad (2.83)$$

und entspricht einer Gaußverteilung der Form $\mathcal{N}(\mu_y, \mathbf{P}_y)$.

Der Algorithmus des UKF ergibt sich durch die rekursive Schätzung der Zufallsvariablen und damit die rekursive Ausführung der UT in einem Prädiktions- und Korrekturschritt analog zum EKF. Es existiert eine klassische Form, in der Prozess- und Messrauschen als zu schätzende Zufallsvariablen integriert sind, siehe [43]. Für den Fall, dass die Rauschgrößen als additive nicht zu schätzende Größen vorliegen ergibt sich eine vereinfachte Form. Da diese Vorgabe auf die in dieser Arbeit betrachtete Anwendung zutrifft, zeigt Alg. 2.6 den UKF-Algorithmus nach [45].

Parameteridentifikation mit adaptierten Kalman-Filter-Algorithmen

Eine entscheidende Besonderheit adaptierter KF gegenüber anderen Methoden ist die Möglichkeit der gleichzeitigen rekursiven Identifikation von Systemzuständen und Parametern. Für Identifikationsprobleme dieser Art existieren zwei unterschiedliche Ansätze zur Anwendung erweiterter KF:

- **Joint-Filterung:**

Bei der Joint-Filterung wird der ursprüngliche Zustandsvektor in (2.72) um die zu identifizierenden Parameter erweitert, wodurch sich ein höherdimensionaler Zustands-

Algorithmus 2.6 Unscented Kalman-Filter Algorithmus

```

1: Initialize:
    $\hat{\mathbf{x}}_0, \mathbf{P}_0, \mathbf{R}, \mathbf{Q}$ 
2: Inputs:
    $\mathbf{u}_k, \mathbf{y}_k$ 
3: while enabled do
4:   Prädiktion:
5:    $\mathcal{X}_{k-1} = \left[ \hat{\mathbf{x}}_{k-1}, \hat{\mathbf{x}}_{k-1} \pm \sqrt{(L + \lambda) \hat{\mathbf{P}}_{k-1}} \right]$ 
6:    $\mathcal{X}_{k|k-1}^* = f(\mathcal{X}_{k-1})$ 
7:    $\hat{\mathbf{x}}_{k|k-1} = \sum_{i=0}^{2L} w_i^{(m)} \mathcal{X}_{i,k|k-1}^*$ 
8:    $\hat{\mathbf{P}}_{k|k-1} = \sum_{i=0}^{2L} w_i^{(c)} \{ \mathcal{X}_{i,k|k-1}^* - \hat{\mathbf{x}}_{k|k-1} \} \{ \mathcal{X}_{i,k|k-1}^* - \hat{\mathbf{x}}_{k|k-1} \}^T + \mathbf{Z}_d \mathbf{Q} \mathbf{Z}_d^T$ 
9:    $\mathcal{X}_{k|k-1} = \left[ \hat{\mathbf{x}}_{k|k-1}, \hat{\mathbf{x}}_{k|k-1} \pm \sqrt{(L + \lambda) \hat{\mathbf{P}}_{k|k-1}} \right]$ 
10:   $\mathcal{Y}_{k|k-1} = g(\mathcal{X}_{k|k-1})$ 
11:   $\hat{\mathbf{y}}_{k|k-1} = \sum_{i=0}^{2L} w_i^{(m)} \mathcal{Y}_{i,k|k-1}^*$ 
12:  Korrektur:
13:   $\hat{\mathbf{P}}_{yy,k} = \sum_{i=0}^{2L} w_i^{(c)} \{ \mathcal{Y}_{i,k|k-1}^* - \hat{\mathbf{y}}_{k|k-1} \} \{ \mathcal{Y}_{i,k|k-1}^* - \hat{\mathbf{y}}_{k|k-1} \}^T + \mathbf{R}$ 
14:   $\hat{\mathbf{P}}_{xy,k} = \sum_{i=0}^{2L} w_i^{(c)} \{ \mathcal{X}_{i,k|k-1}^* - \hat{\mathbf{x}}_{k|k-1} \} \{ \mathcal{Y}_{i,k|k-1}^* - \hat{\mathbf{y}}_{k|k-1} \}^T$ 
15:   $\mathbf{K}_k = \hat{\mathbf{P}}_{xy,k} \hat{\mathbf{P}}_{yy,k}^{-1}$ 
16:   $\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{y}_k - \hat{\mathbf{y}}_{k|k-1})$ 
17:   $\hat{\mathbf{P}}_k = \hat{\mathbf{P}}_{k|k-1} - \mathbf{K}_k \hat{\mathbf{P}}_{yy,k} \mathbf{K}_k^T$ 
18: return  $\hat{\mathbf{P}}_k, \hat{\mathbf{x}}_k$ 

```

vektor ergibt [46]:

$$\hat{\mathbf{x}}_{\text{ext}}[k+1] = \begin{bmatrix} \hat{\mathbf{x}}[k+1] \\ \hat{\boldsymbol{\theta}}[k+1] \end{bmatrix} = \begin{bmatrix} \mathbf{f}(\hat{\mathbf{x}}[k], \mathbf{u}[k], \hat{\boldsymbol{\theta}}[k]) \\ \hat{\boldsymbol{\theta}}[k] \end{bmatrix} + \begin{bmatrix} \mathbf{Z}_d \cdot \mathbf{z}[k] \\ \boldsymbol{\xi}[k] \end{bmatrix} \quad (2.84a)$$

$$\mathbf{y}[k] = \mathbf{g}(\hat{\mathbf{x}}_{\text{ext}}[k]) + \mathbf{v}[k]. \quad (2.84b)$$

Darin wird auch die Unsicherheit der geschätzten Parameter $\boldsymbol{\xi}[k]$ mit einem zusätzlichen Term für das Prozessrauschen berücksichtigt. Auch für $\boldsymbol{\xi}[k]$ gelten die generell getroffenen statistischen Annahmen, weswegen dem Identifikationsproblem des mehrdimensionalen Zustandsvektors eine multivariate Gaußverteilung zugeordnet wird [46]:

$$\hat{\mathbf{x}}_{\text{ext}} = \begin{bmatrix} \hat{\mathbf{x}} \\ \hat{\boldsymbol{\theta}} \end{bmatrix} \sim \mathcal{N} \left(\begin{bmatrix} \boldsymbol{\mu}_x \\ \boldsymbol{\mu}_\theta \end{bmatrix}, \begin{bmatrix} \mathbf{P}_x & \mathbf{P}_{x\theta} \\ \mathbf{P}_{\theta x} & \mathbf{P}_\theta \end{bmatrix} \right). \quad (2.85)$$

Die Struktur von (2.84) und (2.85) ermöglicht durch Anwendung des EKF-Algorithmus 2.5 eine simultane Zustands- und Parameterschätzung des nichtlinearen ZRM.

Auch bei der Initialisierung der Parameteridentifikation muss nun folglich die Erweiterung des Rauschmodells in (2.84) berücksichtigt werden. Durch den zusätzlichen Rauschterm $\xi[k]$ ergibt sich auch eine erweiterte Form der Kovarianzmatrix des Prozessrauschens:

$$\mathbf{Q} = \begin{bmatrix} \mathbf{Q}_x & 0 \\ 0 & \mathbf{Q}_\theta \end{bmatrix}. \quad (2.86)$$

Bei konstanten Systemparametern empfiehlt sich die Kovarianz des Parameterrauschens \mathbf{Q}_θ mit null zu initialisieren. Bei aktiver Parameterschätzung müssen jedoch - je nach Applikation - passende Initialisierungswerte ermittelt werden.

- **Duale Filterung:**

Bei der dualen Filterung wird das Identifikationsproblem der Zustands- und Parameterschätzung anhand zwei paralleler KF gelöst. Beide KF nutzen dabei die gleichen Eingangsgrößen und tauschen die geschätzten Systemzustände bzw. Parameter iterativ aus. Dadurch ergeben sich unter Umständen Vorteile für die Identifikation langsamer Parameteränderungen, da beide Filter mit unterschiedlichen Abtastzeiten betrieben werden können. Im Vergleich zur Joint-Filterung ist hier ein individuell auf die Problemstellung angepasstes ZRM notwendig [36]:

$$\hat{\boldsymbol{\theta}}[k+1] = \hat{\boldsymbol{\theta}}[k] + \mathbf{z}[k] \quad (2.87a)$$

$$\mathbf{y}[k] = \mathbf{g} \left(\mathbf{f} \left(\mathbf{x}[k-1], \mathbf{u}[k-1], \hat{\boldsymbol{\theta}}[k] \right) \right) + \mathbf{v}[k]. \quad (2.87b)$$

Hierbei gilt die Annahme, dass die Parameter im jeweiligen Schritt konstant sind und die Übergangsfunktion der beiden Teilmodelle einer Einheitsmatrix entspricht. Da die aktuellen Parameter nicht als Messgrößen vorliegen, ergibt sich der Ausgang $\mathbf{y}[k]$ durch eine verschachtelte Funktion aus \mathbf{g} und \mathbf{f} . Dadurch werden die Parameteränderungen zuerst auf die Zustände und anschließend auf den Ausgang des Systems projiziert.

2.2 Digitale Signalverarbeitung und Differentiation

Generell erfordert die praktische Anwendung der OPI auf eingebetteten Systemen digital aufbereitete Eingangssignale. Im hier betrachteten System steht die gestellte Statorspannung u_s als Ausgangswert des Stromreglers zur Verfügung und wird daher nicht gemessen. Die Phasenströme i_a, i_b, i_c und die mechanische Drehzahl der Maschine ω_m werden durch Sensoren erfasst und stehen als Analogwerte am Eingang des eingebetteten Systems zur Verfügung. Insbesondere die Messsignale des Stroms sind dabei oft von starkem Rauschen überlagert. Im Fall des RLS-Algorithmus sind neben den digitalisierten Eingangssignalen je nach Modellordnung Ableitungen höherer Ordnung von Spannung, Strom und Drehzahl erforderlich. Eine herkömmliche numerische Differentiation der Eingangssignale führt jedoch zu einer

signifikanten Verstärkung des Rauschens, siehe Abb. 2.2. Diese Tatsache führt gerade bei Ableitungen höherer Ordnung zu Problemen, da hohe absolute Werte eine ausgeprägte Sensitivität gegenüber dem Identifikationsmodell aufweisen. Um diesem Problem entgegen zu treten, ist eine digitale Filterung zur Diskretisierung der Messsignale erforderlich. Zur Umsetzung sind verschiedene Ansätze denkbar. In Bezug auf die in dieser Arbeit durchgeführte Literaturrecherche existieren drei in bestehenden Arbeiten bereits implementierte Verfahren:

- **Butterworth-Filter:**

Als klassisches digitales Filter nutzen Hu et al. in [47] ein Butterworth-Filter dritter Ordnung. Die Filtergleichungen werden dabei als Zustandsraummodell in der kanonischen Normalform implementiert. In dieser Form enthält der Zustandsvektor das geglättete Signal, sowie die erste und zweite Ableitung. Die Berechnung des Zustandsraummodells erfolgt dabei numerisch mit Hilfe der herkömmlichen Euler-Methode. Dadurch ergeben sich die diskretisierten Werte der Eingangssignale. Nachteilig ist dabei, dass in letzter Konsequenz wieder eine numerische Berechnung der Ableitungen durchgeführt wird.

- **Blackman-Fenster:**

Das Filterdesign durch ein Blackman-Fenster (BF) wurde in [48]–[50] umgesetzt. Es vermeidet die direkte Differentiation des Messsignals durch die Faltung mit einer differenzierbaren Cosinus-Funktion. Dabei muss die Faltung beider Seiten der Modellgleichung mit der gleichen Modulationsfunktion erfolgen. Das Messsignal wird bei diesem Ansatz nicht eindeutig rekonstruiert, weswegen die absoluten Ausgangswerte deutlich höher als die ursprünglichen Signale sind. Nachteilig ist, dass die gefilterten Größen nicht mehr deutbar sind und die Berechnung der Cosinus-Funktionen zur Faltung einen vergleichsweise hohen Rechenaufwand verursachen.

- **Savitzky-Golay-Glättung:**

Die Savitzky-Golay (SG)-Glättung wurde in den Arbeiten [25], [51] implementiert und basiert auf einer Faltung mit einer Polynomfunktion. Durch Voruntersuchungen des hier betrachteten Systems hat sich diese Methode als vorteilhaft zur Echtzeitimplementierung herausgestellt und wird daher im folgenden Verlauf dieser Arbeit genutzt.

Savitzky-Golay-Glättung

Das SG-Filter approximiert das Eingangssignal mit einer Polynomfunktion der Ordnung p_f durch Nutzung einer diskreten Faltung in einem Fenster der Breite k_f . Zur Berechnung der Ableitungen werden die approximierten Polynomwerte differenziert. Dadurch ergeben sich geglättete Werte für die Ableitung des Eingangssignals ohne eine numerische Differentiation durchführen zu müssen. Das Design des SG-Filters erfolgt nach der Form eines Filters

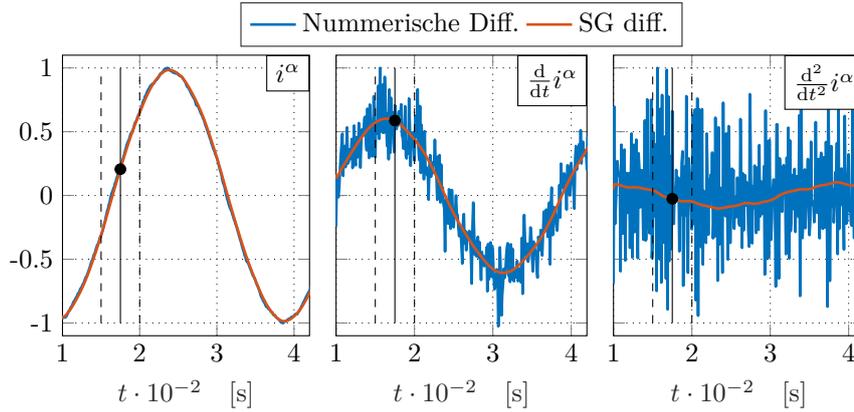


Abbildung 2.2: Numerische Differentiation vs. Differentiation mittels Savitzky-Golay-Filter.[17]

mit endlicher Impulsantwort (engl. finite impulse response (FIR)-Filter) und wurde in [52] entwickelt. Danach ergibt sich die diskrete Filterfunktion wie folgt:

$$\hat{y}[k] = \sum_{i=-(k_f-1)/2}^{(k_f-1)/2} c_{0,i} \cdot y[k+i]. \quad (2.88)$$

Die Breite des Glättungsfensters wird durch die Wahl k_f festgelegt und $c_{0,i}$ enthält die Filterkoeffizienten. Der Ausgang des Filters $\hat{y}[k]$ ergibt sich zu jedem Zeitschritt k in der Mitte des Fensters und ist daher um $t_{\text{del}} = \frac{k_f}{2} \Delta t$ verzögert. Dieser Zusammenhang ist in Abb. 2.2 für alle Ausgangsgrößen angedeutet. Eine Ableitung von $\hat{y}[k]$ beliebiger Ordnung lässt sich wie folgt bestimmen:

$$\frac{d^m}{dt^m} \hat{y}[k] = \frac{m!}{\Delta t^m} \sum_{i=-(k_f-1)/2}^{(k_f-1)/2} c_{m,i} \cdot y[k+i]. \quad (2.89)$$

Darin bezeichnet $m \in \mathbb{N}^*$ die Ordnung der jeweiligen Ableitung und Δt die Abtastzeit. Die erweiterten Filterkoeffizienten c_m ergeben sich zu,

$$\mathbf{z} = \left[\frac{1-k_f}{2} \quad \dots \quad \frac{k_f-1}{2} \right] \quad (2.90a)$$

$$\mathbf{Z} = \left[\mathbf{z}^0 \quad \mathbf{z}^1 \quad \dots \quad \mathbf{z}^{p_f} \right] \quad (2.90b)$$

$$\mathbf{C} = \left[\mathbf{c}_0 \quad \mathbf{c}_1 \quad \dots \quad \mathbf{c}_{p_f} \right]^T = (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \quad (2.90c)$$

wobei p_f die Ordnung der Polynomfunktion beziffert. Die eigentlichen Filterkoeffizienten \mathbf{C} werden durch Optimierung nach dem LS-Verfahren analog zu (2.8) initial berechnet. In Abb. 2.2 ist beispielhaft eine Signalsequenz des Phasenstroms i_α dargestellt. Durch eine numerische Differentiation wird das Messrauschen signifikant verstärkt. Bereits die Berechnung der zweiten Ableitung ergibt ein für die Parameteridentifikation unbrauchbares Signal. Bei Betrachtung der vom SG-Filter berechneten Ableitung wird deutlich, dass selbst bei höheren

Ableitungen die sinusförmige Signalcharakteristik erhalten bleibt.

Zur Festlegung der Charakteristik des SG-Filters ergibt sich die Knickfrequenz $f_{c,sg}$ in Abhängigkeit der Fensterbreite k_f und der Abtastzeit des eingebetteten Systems Δt :

$$f_{c,sg} = \frac{1}{T_{sg}} = \frac{1}{k_f \cdot \Delta t}. \quad (2.91)$$

Im Vergleich zu kontinuierlichen Filtern verursachen FIR-Filter keine Phasenverschiebung der Signale. Aufgrund der erwähnten zeitlichen Verschiebung gilt dies jedoch nur solange alle genutzten Signale mit der gleichen Konfiguration gefiltert werden.

2.3 Grundlagen der Asynchronmaschine

Dieser Abschnitt erläutert die Grundlagen der ASM, die zum Verständnis der Implementierungen und Analysen dieser Arbeit erforderlich sind. Zunächst wird die analytische Modellbildung zur Ableitung der genutzten Identifikationsmodelle betrachtet. Es folgt eine Beschreibung der ASM Parameter und deren Verhalten mit Bezug auf das automobilen Anwendungsgebiet.

2.3.1 Analytische Modellierung der Asynchronmaschine

Als Grundlage für die OPI in Echtzeitanwendungen wird eine meist lineare Modellvorstellung des zu identifizierenden Systems benötigt. Diese basiert in der Regel auf einem linearen Ersatzschaltbild (ESB). Je nach Anwendungsfall existieren diverse ESB der ASM, aus denen wiederum unterschiedlich komplexe Identifikationsmodelle ableitbar sind.

Ersatzschaltbilder der Asynchronmaschine

Das meist genutzte lineare Modell der ASM ist das auf dem T-ESB basierende Grundwellenmodell, siehe Abb. 2.3 [53]–[55]. Darin wird ein vollständig symmetrischer Aufbau des Stators und ein rein sinusförmiger bzw. Oberschwingungsfreier Luftspaltfluss angenommen. Außerdem werden der Skin¹- und Proximityeffekt², sowie die Eisenverluste vernachlässigt. R_s und R_r sind jeweils die ohmschen Widerstände des Stators und des Rotors. Die Hauptinduktivität ist mit L'_m bezeichnet, während L'_{σ_s} und L'_{σ_r} die Streuinduktivitäten im Stator- und Rotorkreis beschreiben. Somit sind die Stator- bzw. Rotorinduktivität als $L'_s = L'_{\sigma_s} + L'_m$ und $L'_r = L'_{\sigma_r} + L'_m$ spezifiziert. Das Modell des T-ESB stellt ein überbestimmtes Gleichungssystem dar. Diese Überbestimmtheit lässt sich zur Parameteridentifikation durch die Annahme

¹Der Skineffekt beschreibt das Phänomen der frequenzabhängig unterschiedlichen Stromdichteverteilung über die Fläche eines elektrischen Leiters durch den Effekt der Stromverdrängung [56].

²Der Proximityeffekt beschreibt die Wechselwirkung nebeneinander liegender und in der gleichen Richtung mit Wechselstrom durchflossener Leiter durch deren strombedingt erzeugte Magnetfelder [57].

gleicher Streuinduktivitäten $L'_{\sigma_s} = L'_{\sigma_r}$ im Stator- und Rotorkreis aufheben. Im Hinblick auf die OPI enthalten die resultierenden Identifikationsmodelle jedoch unnötige Details und damit Komplexitäten. Alternativ werden daher das Γ - und Γ -inverse (Γ i)-ESB genutzt, welche jeweils die Streuinduktivität L_σ in einem Term konzentriert berücksichtigen. Ersteres kommt oft in Regelungsapplikationen mit konstantem Fluss zum Einsatz. Daneben eignet sich das Γ i-ESB besonders für die rotorflussorientierte Vektorregelung im d/q-Koordinatensystem (KOS) mit Fokus auf veränderlichen Drehmomentanforderungen [58]. Aufgrund der geringeren Komplexität dient das Γ i-ESB in dieser Arbeit als Basis für die Herleitung der Identifikationsmodelle, siehe Abb. 2.4. Der optionale Eisenverlustwiderstand R_{fe} ist in Abb. 2.4 blau gekennzeichnet.

Die mathematische Modellierung elektrischer Drehfeldmaschinen ist grundsätzlich in unterschiedlich orientierten Koordinatensystemen möglich. Für Regelungsanwendungen haben sich weitestgehend flussorientierte d/q-KOS durchgesetzt, jedoch ist die OPI auch im rotierenden statorfesten α/β -KOS möglich. Das aus Abb. 2.4 abgeleitete Differentialgleichungssystem unter Vernachlässigung des Eisenverlustwiderstands im α/β -KOS (hochgestellt S) lautet wie folgt [58],

$$\mathbf{u}_s^S = R_s \mathbf{i}_s^S + \frac{d}{dt} \Psi_s^S \quad (2.92a)$$

$$\mathbf{u}_r^S = R_r \mathbf{i}_r^S + \frac{d}{dt} \Psi_r^S - \mathbf{J} n_p \omega_m \Psi_r^S = 0 \quad (2.92b)$$

$$\Psi_s^S = L_s \mathbf{i}_s^S + L_m \mathbf{i}_r^S \quad (2.92c)$$

$$\Psi_r^S = L_m (\mathbf{i}_s^S + \mathbf{i}_r^S) \quad (2.92d)$$

wobei $L_s = L_\sigma + L_m$ gilt. Darin ist ω_m die mechanische Drehzahl und n_p die Polpaarzahl der Statorwicklung. Die Zustandsvariablen Spannung u , Strom i und Fluss Ψ bestehen dabei aus zwei komplexen Komponenten, die sich aus den Größen des dreiphasigen Systems durch die Clarke-Transformation³ ergeben:

$$\mathbf{x}^S = \begin{bmatrix} x^\alpha \\ x^\beta \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & \frac{-1}{2} & \frac{-1}{2} \\ 0 & \frac{\sqrt{3}}{2} & \frac{-\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} x^a \\ x^b \\ x^c \end{bmatrix}. \quad (2.93)$$

Diese befinden sich im statorfesten α/β -KOS und sind über die imaginäre Einheit \mathbf{J} miteinander gekoppelt:

$$\mathbf{J} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}. \quad (2.94)$$

³Die Clarke-Transformation dient der Transformation eines mehrphasigen Systems mit mehreren Vektoren in ein komplexes KOS mit zwei Achsen und wurde nach Edith Clarke benannt [59]. Sie wird oft in Verbindung mit der Park-Transformation genutzt.

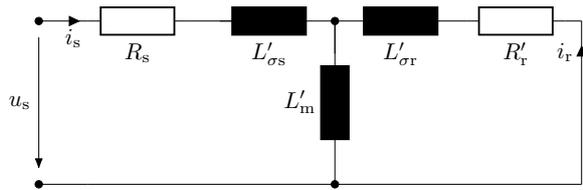
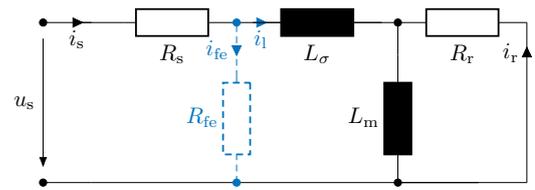


Abbildung 2.3: T Ersatzschaltbild der Asynchronmaschine.

Abbildung 2.4: Γ inverses Ersatzschaltbild der Asynchronmaschine.

Die Transformation in das rotorflussorientierte d/q-KOS ermöglicht die Park-Transformation⁴ mit Hilfe des Rotorflusswinkels Θ_r :

$$\begin{bmatrix} x^d \\ x^q \end{bmatrix} = \begin{bmatrix} \cos(\Theta_r) & \sin(\Theta_r) \\ -\sin(\Theta_r) & \cos(\Theta_r) \end{bmatrix} \begin{bmatrix} x^\alpha \\ x^\beta \end{bmatrix}. \quad (2.95)$$

Die Parameter des T-ESB sind durch die Annahme $L'_{\sigma s} = L'_{\sigma r}$ mit trivialen Vorschriften in die des Γ i-ESB transformierbar. Mit dem bekannten Streukoeffizienten nach Blondel (siehe exemplarisch [54]),

$$\sigma = 1 - \frac{L'_m{}^2}{L'_{\sigma s} \cdot L'_{\sigma r}} \quad (2.96)$$

ergeben sich die Transformationsvorschriften laut [58]:

$$L_m = (1 - \sigma)L'_s, \quad L_\sigma = \sigma L'_s, \quad R_r = \left(\frac{L'_m}{L'_r}\right)^2 R'_r. \quad (2.97)$$

⁴Die Park-Transformation dient der Umrechnung eines mehrphasigen Systems in ein zweiachsiges, mit einer beliebigen Winkelgeschwindigkeit rotierendes, KOS und wurde nach Robert H. Park benannt [60]. Diese Transformationsvorschrift ist ein essenzielles Werkzeug zur Regelung von Drehfeldmaschinen und ermöglicht die Regelung stationärer Größen im jeweiligen KOS. Sie wird oft in Verbindung mit der Clark-Transformation genutzt.

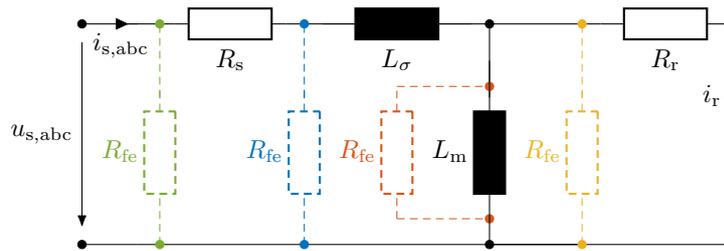


Abbildung 2.5: Γ -inverses Ersatzschaltbild der Asynchronmaschine mit verschiedenen Optionen zur Berücksichtigung der Eisenverluste.

Berücksichtigung der Eisenverluste

In Rahmen dieser Arbeit wird untersucht, inwiefern die transienten Eisenverluste die Genauigkeit der OPI beeinflussen. Diese lassen sich durch einen zusätzlichen Eisenverlustwiderstand R_{fe} im Modell berücksichtigen. Zur Strukturierung dieses erweiterten Modells schlägt die Literatur verschiedene Ansätze vor, wobei jedoch kein eindeutiger Konsens über eine favorisierte Methode existiert. Eine Auswahl verschiedener Ansätze in Verbindung mit dem Γ -ESB ist in Abb. 2.5 dargestellt.

Am meisten verbreitet ist die Positionierung des Eisenverlustwiderstands R_{fe} direkt parallel zur Hauptinduktivität L_m , wie bekannte Basisliteratur und zahlreiche Anwendungen belegen [53]–[55], [58], [61]–[69]. Diese Variante bietet sich an, wenn die Statorinduktivität klar in Streu- und Hauptinduktivität unterteilbar ist. Eine vereinfachte Version sieht vor, den Eisenverlustwiderstand R_{fe} parallel zur Statorinduktivität zu verschalten [55], [58], [67], [70], [71]. Auch diese hat sich etabliert, da sie einen guten Kompromiss zwischen Komplexität und realitätsnaher Modellierung verspricht. Für eine stark vereinfachte bzw. reine Leistungsbetrachtung ist es möglicherweise sinnvoll, den Einfluss der Eisenverluste pauschal zu betrachten und daher R_{fe} im Eingang des ESB zu platzieren [54]. Komplexere Modelle sehen vor einen zusätzlichen Eisenverlustwiderstand R_{fe} im Rotor zu berücksichtigen [72]. Des Weiteren existieren analytische Ansätze, die eine Teilung von R_{fe} in komplexe Komponenten [73] oder ein zusätzliches Oberschwingungsmodell der Eisenverluste vorsehen [74].

Je nach Wahl des ESB ändert sich die Komplexität des Identifikationsmodells signifikant. Dies beeinflusst wiederum die Performanz der gesamten OPI. Ein Vergleich der beiden meist genutzten Ansätze zeigt, dass die Parallelschaltung von R_{fe} zu L_m ein deutlich komplexeres Identifikationsmodell ergibt als die Parallelschaltung von R_{fe} zu L_s . Außerdem zeigte ein simulativer Vergleich, dass die Modelle sich hinsichtlich der sich im Betrieb ergebenden Drehmomente und Verlustströme wenig voneinander unterscheiden. Zusätzlich basiert der in Abs. 3 genannte Parametersatz des Maschinenherstellers auf dem vereinfachten Ansatz, den auch Abb. 2.4 zeigt. In dieser Arbeit erfolgt die Herleitung der entsprechenden Identifikationsmodelle daher basierend auf diesem Ansatz. Daraus ergibt sich die erweiterte Form des

Gleichungssystems (2.92) wie folgt:

$$\mathbf{u}_s^S = R_s \mathbf{i}_s^S + \frac{d\mathbf{\Psi}_s^S}{dt} \quad (2.98a)$$

$$\mathbf{u}_r^S = R_r \mathbf{i}_r^S + \frac{d}{dt} \mathbf{\Psi}_r^S - \mathbf{J} n_p \omega_m \mathbf{\Psi}_r^S = 0 \quad (2.98b)$$

$$\mathbf{\Psi}_s^S = L_s \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S \right) \right) + L_m \cdot \mathbf{i}_r^S \quad (2.98c)$$

$$\mathbf{\Psi}_r^S = L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S \right) \right) + L_m \cdot \mathbf{i}_r^S. \quad (2.98d)$$

Zustandsraumdarstellung der Asynchronmaschine

Die Nutzung des einfachen Kalman-Filters als Zustandsbeobachter sowie erweiterter Kalman-Filter Strukturen zur OPI erfordern ein Modell in der Zustandsraumdarstellung des zu identifizierenden Systems:

$$\dot{\mathbf{x}} = \mathbf{A} \cdot \mathbf{x} + \mathbf{B} \cdot \mathbf{u} \quad (2.99a)$$

$$\mathbf{y} = \mathbf{C} \cdot \mathbf{x} + \mathbf{D} \cdot \mathbf{u}. \quad (2.99b)$$

Der Eingangsvektor \mathbf{u} sowie der Zustandsvektor \mathbf{x} sind grundsätzlich frei wählbar. Im Fall einer umrichtergespeisten elektrischen Maschine ergibt sich jedoch zwangsläufig die Statorspannung u_s als sinnvoller Eingangsvektor. Der Phasenstrom \mathbf{i}_s als resultierende Messgröße des Systems wird daher als Ausgang festgelegt und muss zusätzlich im Zustandsvektor des Modells enthalten sein. Zur geschlossenen Darstellung der Modellgleichungen (2.92) ist die Aufnahme einer der beiden Flussvariablen oder des Rotorstroms in den Zustandsvektor erforderlich. Da die genaue Schätzung des Rotorflusses $\mathbf{\Psi}_r$ essenziell für die effiziente rotorflussorientierte Regelung einer ASM ist, bietet sich an, $\mathbf{\Psi}_r$ als zusätzlichen Systemzustand festzulegen:

$$\mathbf{x} = \left[i_s^\alpha \quad i_s^\beta \quad \Psi_r^\alpha \quad \Psi_r^\beta \right]^T$$

$$\mathbf{u} = \left[u_s^\alpha \quad u_s^\beta \right]^T.$$

Durch entsprechende Umformungen des Differentialgleichungssystems (2.92) ergibt sich folglich nach dem Schema von (2.99) das zugehörige Zustandsraummodell des Γ -ESB:

$$\begin{bmatrix} \dot{i}_s^\alpha \\ \dot{i}_s^\beta \\ \dot{\Psi}_r^\alpha \\ \dot{\Psi}_r^\beta \end{bmatrix} = \begin{bmatrix} -\frac{R_s+R_r}{L_\sigma} & 0 & \frac{R_r}{L_\sigma L_m} & \omega_{el} \cdot \frac{1}{L_\sigma} \\ 0 & -\frac{R_s+R_r}{L_\sigma} & -\omega_{el} \cdot \frac{1}{L_\sigma} & \frac{R_r}{L_\sigma L_m} \\ R_r & 0 & -\frac{R_r}{L_m} & -\omega_{el} \\ 0 & R_r & \omega_{el} & -\frac{R_r}{L_m} \end{bmatrix} \cdot \begin{bmatrix} i_s^\alpha \\ i_s^\beta \\ \Psi_r^\alpha \\ \Psi_r^\beta \end{bmatrix} + \begin{bmatrix} \frac{1}{L_\sigma} & 0 \\ 0 & \frac{1}{L_\sigma} \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} u_s^\alpha \\ u_s^\beta \\ 0 \\ 0 \end{bmatrix} \quad (2.101a)$$

$$\begin{bmatrix} i_s^\alpha \\ i_s^\beta \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} i_s^\alpha \\ i_s^\beta \\ \Psi_r^\alpha \\ \Psi_r^\beta \end{bmatrix}. \quad (2.101b)$$

Darin entspricht $\omega_{el} = n_p \omega_m$ der um die Polpaarzahl korrigierten mechanischen Drehzahl. Der Durchgriff \mathbf{D} ist irrelevant, da in diesem System kein direkter Einfluss auf den Ausgang möglich ist.

2.3.2 Parameteränderungen der Asynchronmaschine

Die automobilen Anwendung stellt für elektrische Maschinen ein hochdynamisches Betriebsfeld dar. Der Betrieb erfolgt dabei in einem sehr großen Drehzahl- und Drehmomentbereich. Aufgrund von Kostendruck und begrenztem Bauraum im Fahrzeug werden hochausgenutzte Maschinentopologien entwickelt, woraus ein stark nichtlineares Maschinenverhalten resultiert. Bedingt durch veränderliche Zustandsgrößen wie Strom, Temperatur und Frequenz des Systems kommt es zu transientem Parameterverhalten über den gesamten Betriebsbereich. Eine zentrale Fragestellung dieser Arbeit ist die Performanz der Algorithmen zur OPI in diesem speziellen Umfeld. Aufgrund der Echtzeitanforderung ist die zulässige Modellkomplexität begrenzt. Entsprechend ist das transiente Parameterverhalten nur auf Basis der zuvor beschriebenen analytischen Modelle identifizierbar. Nachfolgend werden die jeweiligen betriebspunktabhängigen Parameteränderungen in vereinfachter Form beschrieben.

Ohmsche Widerstände

Der während des Betriebs auftretende Stromfluss in der Maschine ruft eine temperaturabhängige Änderung der ohmschen Widerstände hervor. Aus verschiedenen Gründen bestehen die Statorwicklung R_s und die Rotorstäbe R_r oft aus unterschiedlichen Materialien. Bei hohen Effizienzansprüchen werden die zugrundeliegenden Parameter des Regelungssystems mit analytischen Temperaturmodellen adaptiert. Diese müssen jedoch offline aufwendig bedacht werden. Eine detaillierte betriebspunktabhängige Temperaturverteilung in der Maschine lässt sich nur mit numerischen Modellen abbilden. Die Untersuchungen in dieser Arbeit beziehen sich lediglich auf die temperaturbedingte Änderung der ESB Parameter, weswegen eine vereinfachte Betrachtung erfolgt. Allgemein verbreitet ist die Nutzung der folgenden linearen Approximationsfunktion [75, S.3]:

$$R_{\vartheta^\circ\text{C}} = R_{20^\circ\text{C}} \left(1 + \alpha_{\text{Cu/Al}} \cdot \Delta T \right). \quad (2.102)$$

Diese geht von einem offline vermessenen Basiswert des Widerstands $R_{20^\circ\text{C}}$ bei Raumtemperatur aus. Mit Hilfe eines materialspezifischen Temperaturkoeffizienten $\alpha_{\text{Cu/Al}}$ lässt sich

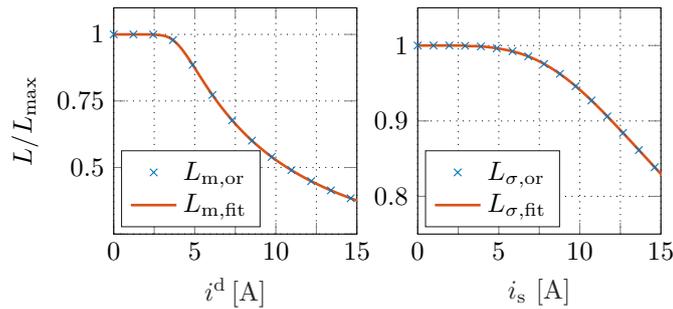


Abbildung 2.6: Normierte Sättigungskurve der Hauptinduktivität L_m in Abhängigkeit der flussbildenden Stromkomponente i^d und der Streuinduktivität L_σ in Abhängigkeit des Statorstroms i_s .

damit der Widerstandswert $R_{\vartheta^\circ\text{C}}$ nach einer Temperaturänderung ΔT linear approximieren. Durch den Effekt der Stromverdrängung im Rotor fließen die Rotorströme nur in einer dünnen Schicht am Rand des jeweiligen Rotorstabs. Dadurch ergibt sich eine frequenzabhängige Änderung der ohmschen Widerstände, die auch als Skin-Effekt bekannt ist [54]. Dieser Effekt tritt in den hier betrachteten Maschinen nur sehr bedingt auf und wird daher aus Gründen der Modellkomplexität vernachlässigt.

Induktive Parameter

Durch die physikalischen Eigenschaften des Eisenkerns der Maschine kommt es während des Betriebs zu einer stromabhängigen Sättigung des Magnetfelds. Dabei wird sowohl der magnetische Fluss in der Hauptinduktivität L_m als auch der Streufluss in L_σ gesättigt [55]. Abbildung 2.6 zeigt die vom Hersteller der genutzten ASM zur Verfügung gestellten Induktivitätsverläufe des Γ -ESB in normierter Form. Es zeigt sich, dass der Verlauf der Hauptinduktivität lediglich von der flussbildenden Komponente des Statorstroms i_d abhängt, während die Sättigung der Streuinduktivität durch den Betrag des Statorstroms i_s erfolgt. Aus Gründen der Modellkomplexität ist in Bezug auf das Γ -ESB in Abb. 2.4 lediglich eine stark vereinfachte Betrachtung der magnetischen Eigenschaften der Maschine möglich. Detaillierte numerische Modelle werden in der Regel nur zur Auslegung und zum Design der Maschine genutzt.

Eisenverlustwiderstand

Neben der Fragestellung wie der Eisenverlustwiderstand in das ESB integriert wird, stellt sich auch die Frage, wie das frequenzabhängige transiente Verhalten während des Betriebs abgebildet werden kann. Weit verbreitet ist der Ansatz von Bertotti [76], der die Eisenverluste in Hystereseverluste und Wirbelstromverluste aufteilt:

$$P_{\text{fe}} = P_{\text{h}} + P_{\text{w}} = k_{\text{h}} \cdot f \cdot \hat{B}^\beta + k_{\text{w}} \cdot (f \cdot \hat{B})^2 + k_{\text{a}} \cdot (f \cdot \hat{B})^{\frac{3}{2}}. \quad (2.103)$$

Darin sind die nichtlinearen betriebspunktabhängigen Änderungen in Abhängigkeit der Frequenz f und der magnetischen Flussdichte \hat{B} klar ersichtlich. Die empirischen Koeffizienten k_n , k_w und k_a müssen jedoch experimentell ermittelt werden. Eine detaillierte Ermittlung der einzelnen Terme ist jedoch für die Betrachtungen in dieser Arbeit nicht erforderlich. Als Alternative stellt der Hersteller der in dieser Arbeit genutzten ASM eine direkte lineare Approximationsfunktion des Eisenverlustwiderstands in Anlehnung an das erweiterte Γ -ESB in Abb. 2.4 zur Verfügung:

$$R_{\text{fe}} = \frac{3\pi f_n \Psi_n^2}{P_{\text{fe},n}} \cdot \omega_s. \quad (2.104)$$

Mit Hilfe der zur Verfügung gestellten Nennwerte f_n , Ψ_n und $P_{\text{fe},n}$ ist dadurch eine vereinfachte, von der Statorfrequenz ω_s abhängige, Approximation möglich.

3 Aufbau der Testumgebung

Im Fokus dieser Arbeit steht die Echtzeitanwendung der untersuchten Algorithmen in einem automotiven Betriebsumfeld. Das automotiv Anwendungsbereich steht für ein hoch dynamisches Betriebsumfeld mit einem großen Drehzahl- und Drehmomentbereich. Im Vergleich zu anderen Anwendungsgebieten ergeben sich dadurch vor allem betriebspunktabhängige Parameteränderungen aufgrund der nichtlinearen Sättigungskurve. Aber auch temperatur- und frequenzbedingte Änderungen der ohmschen Parameter beziehungsweise der Eisenverluste treten auf. Zur Abbildung der genannten Eigenschaften ist eine geeignete Testumgebung erforderlich, die sowohl simulative als auch experimentelle Analysen ermöglicht. Nachfolgend wird zunächst der entwickelte Prüfaufbau und anschließend die genutzte Simulationsumgebung beschrieben.

3.1 Experimenteller Aufbau

Der experimentelle Prüfaufbau basiert auf der Back-to-Back-Topologie. Dabei ist der Prüfling mechanisch mit einer drehzahlgeregelten Lastmaschine gekoppelt. Beide Maschinen nutzen den gleichen Spannungszwischenkreis, sodass lediglich die entstehende Verlustleistung aus dem Netz bezogen wird. Die mechanische Drehzahl der Welle ist frei wählbar und durch den Drehzahlregler und abhängig vom Lastpunkt des Prüflings festgelegt. In Bezug auf das System Automobil lässt sich dadurch eine vom mechanischen Einfluss des Fahrwerks entkoppelte Betrachtung der Antriebsmaschine realisieren. Die Hardwarekomponenten sowie die implementierte Echtzeitsoftware zur Regelung des Aufbaus sind nachfolgend erläutert. Zur Orientierung zeigt Abb. 3.1 eine schematische Übersicht des experimentellen Testaufbaus.

3.1.1 Hardwarekomponenten

Ein Abbild der Hardwarekomponenten des Laboraufbaus zeigt Abb. 3.2. Eine entsprechende Geräteliste findet sich in Tab. 3.2.

Der Antriebssatz der Lastmaschine besteht aus einem industriellen Umrichter mit integrierter Drehzahlregelung sowie einer permanenterregten Synchronmaschine, die den Drehzahl- und Drehmomentbereich des Prüflings abdeckt.

Die charakteristischen Daten der ASM zeigt Tab. 3.1. Bei der ausgewählten Maschine handelt

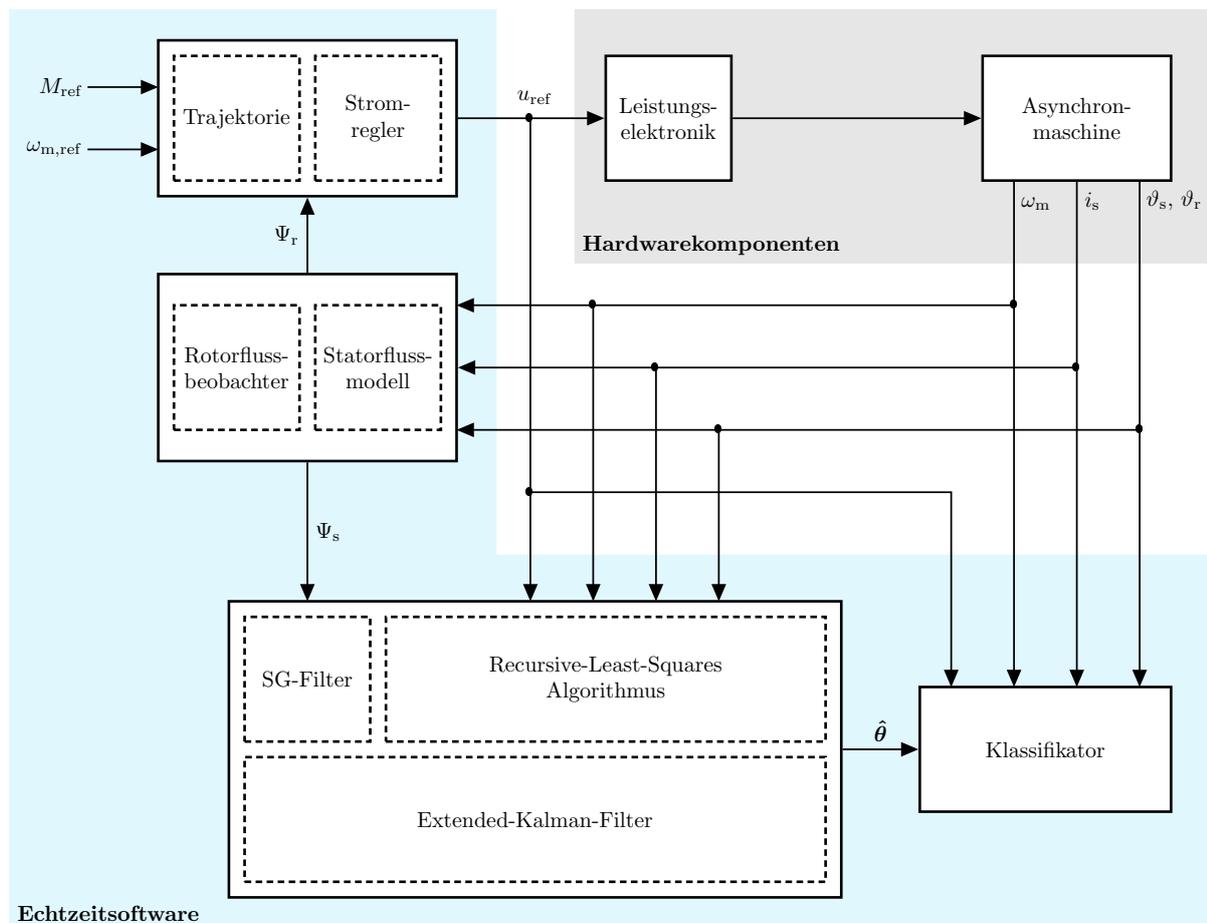


Abbildung 3.1: Übersicht der genutzten Testumgebung mit Kennzeichnung der Hardware- und Echtzeitsoftware-Komponenten.

es sich um eine Servomaschine, die aufgrund ihrer stark nichtlinearen Sättigungscharakteristik (siehe Abb. 2.6) ein gutes Abbild der im realen Fahrzeug verbauten Antriebsmaschine verkörpert. Zusätzlich sind zur Validierung der untersuchten OPI-Algorithmen genaue Parametersätze vorhanden. Aus Sicherheitsgründen ist die Drehzahl des Aufbaus auf einen nutzbaren Bereich von $n = \pm 0 \dots 3000 \text{ min}^{-1}$ beschränkt. Die ASM wird mit einem modifizierten Umrichter betrieben, der im Vergleich zur Lastmaschine die selbe Leistungselektronikhardware nutzt. Jedoch besitzt dieser keine Steuerungshardware, weswegen die Gates der Leistungshalbleiter als Hardwareingänge zur Verfügung stehen. Die Regelungssoftware wird daher auf einem externen Echtzeit-Interface (engl. Real Time Interface (RTI)) betrieben, vgl. Abs. 3.1.2. Dadurch ist der Regelungsalgorithmus vollständig transparent und individuell implementierbar. Zeitgleich stellt die zertifizierte Leistungselektronik den Betrieb in einer abgesicherten Hardwareumgebung sicher.

Zur Umsetzung der Regelung und für die im Rahmen dieser Arbeit durchgeführten Analysen der OPI-Algorithmen enthält der Testaufbau unterschiedliche Sensorik- und Messtechnik. Die zur Stromregelung der Asynchronmaschine erforderlichen Momentanwerte der

Tabelle 3.1: Charakteristische Daten der Asynchronmaschine DRL132S4.

Elektrisch			Mechanisch		
Leistung	P_{el}	10,1 kW	Leistung	P_m	7,21 kW
Strom	i_s	10,36 A	Drehmoment	M_m	32,8 Nm
Spannung	u_s	329 V Δ	Polpaarzahl	n_p	2
Frequenz	f_k	71 Hz	Drehzahl	n_m	2100 min ⁻¹
Frequenzbereich			Drehzahlbereich		
$f_k = 0 \dots 200$ Hz			$n_m = 0 \dots 5000$ min ⁻¹		

Phasenströme erfasst die im modifizierten Umrichter integrierte Stromsensorik. Zur analogen Aufbereitung der Strommessung ist zusätzlich ein PT1-Filter integriert. Die mechanische Drehzahl der Maschinen steht durch einen Inkrementalgeber mit 1024 Inkrementen in ausreichender Genauigkeit zur Verfügung. Die vorhandene Strom- und Drehzahlsensorik ist analog zu der im realen Fahrzeug verbauten, weswegen die Messwerte zeitgleich für die OPI genutzt werden. Zur Validierung der Funktion des Regelalgorithmus steht neben einer Drehmomentmesswelle zusätzlich ein performantes Leistungsmessgerät zur Verfügung. Dieses ermöglicht eine breit aufgestellte Leistungs- und Oberschwingungsanalyse und zeichnet dazu die Phasenspannungen und -ströme in hoher Auflösung auf. Dadurch lassen sich auch Trainingsdaten zur datenbasierten Modellbildung mit hoher Genauigkeit aufzeichnen. Daneben enthält der modifizierte Umrichter einen Spannungssensor zur Erfassung der Zwischenkreisspannung. Dieser ist gerade für die spätere Implementierung des datenbasierten Leistungselektronikmodells von großer Bedeutung. Zur Adaption der ohmschen Widerstände des ESB-Modells ist eine Infrarotsensorik zur Erfassung der Stator- und Rotortemperatur in den Aufbau integriert. Diese ist besonders für die Auswertung der implementierten OPI-Algorithmen entscheidend.

Die Steuerung und Regelung des Aufbaus erfolgt mit Hilfe einer Rapid-Prototyping-Plattform als RTI. Diese stellt ein Pendant zum Steuergerät im Fahrzeug dar, sodass bereits im Labor realitätsnahe Hardware mit limitierter Rechen- und Speicherkapazität zur Verfügung steht. An dieser Stelle sei darauf hingewiesen, dass der Testaufbau keine in Bezug auf die Elektromagnetische Verträglichkeit (EMV) optimierte Betriebsumgebung darstellt. In diesem Zusammenhang ist vor allem die Länge der Verbindungsleitung zwischen ASM und Umrichter als negativ zu erwähnen. Im realen Fahrzeug liegt eine weitestgehend EMV-optimierte Betriebsumgebung vor. Aufgrund der dadurch verbesserten Rauschverhältnisse dürften auch die Systemeigenschaften in Bezug auf die OPI vorteilhafter sein.

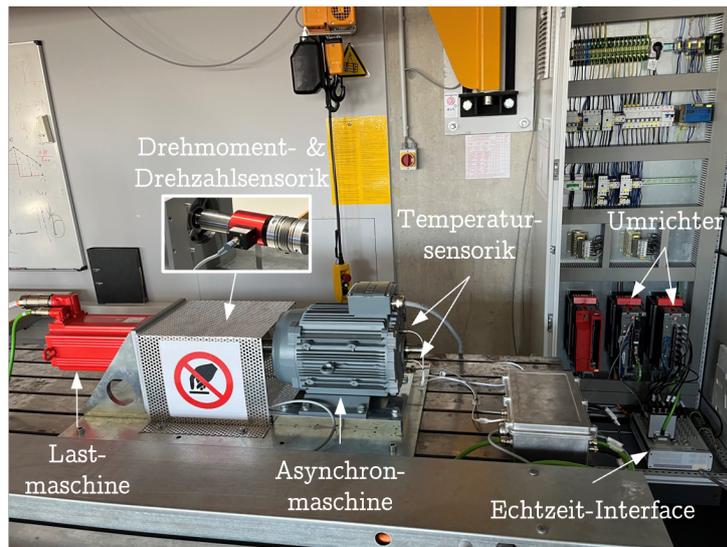


Abbildung 3.2: Übersicht der Hardwarekomponenten des Laboraufbaus.

Tabelle 3.2: Geräteliste des Testaufbaus.

Gerät	Hersteller	Typenbezeichnung
Lastmaschine	SEW-EURODRIVE	CMP80L
Umrichter Lastmaschine	SEW-EURODRIVE	MDX60A0110-5A3-4-00
Asynchronmaschine (Prüfling)	SEW-EURODRIVE	DRL132S4
Umrichter ASM	SEW-EURODRIVE	MDX61B-5A3-4-00
Rapid Prototyping Plattform RTI	dSpace	MicroLabBox
Drehmomentmesswelle	KTR-Group	DATAFLEX 32/100
Leistungsmessgerät	ZES Zimmer	LMG671
Stromsensorik Leistungsmessgerät	DANISENSE (ZES)	PCT200

3.1.2 Aufbau der implementierten Echtzeitsoftware

Die Implementierung der Software erfolgt modellbasiert mit Hilfe des Simulationstools *Matlab/Simulink*. Ein Automatismus erzeugt den echtzeitfähigen C-Code durch einen Compiler direkt aus dem implementierten Modell und führt anschließend den Flashvorgang auf dem RTI aus. Die Entwicklungsumgebung ist dabei stets mit dem RTI verbunden und die Echtzeitfähigkeit von getätigten Anpassungen wird während des Prozesses automatisch überprüft. Zur Bedienung des Aufbaus stellt der Hersteller des RTI eine passende Software (*dSpace Control Desk*) zur Verfügung. Basierend auf der Struktur des modellbasierten Echtzeitcodes ermöglicht diese Software die Steuerung und Überwachung aller enthaltenen Systemgrößen. Diese Funktion ist neben der Kalibrierung des Regelsystems für die Analyse der OPI-Algorithmen von zentraler Bedeutung.

Die Struktur der Steuerungs- und Regelungssoftware wird zum besseren Verständnis der durchgeführten Testläufe anhand der schematischen Darstellung in Abb. 3.1 erläutert. Für

die Regelung von Asynchronmaschinen mit veränderlichen Drehmomentanforderungen ist die Vektorregelung im rotorflussorientierten d/q-KOS weit verbreitet [58]. Dadurch lassen sich Fluss und Drehmoment der Maschine entkoppelt voneinander mit zwei separaten Strompfaden regeln. Für eine effiziente Regelung im gesamten Betriebsbereich bedarf es einer optimierten Trajektorienplanung zur Vorgabe der Sollströme i_d und i_q . Die weit verbreitete Maximum Torque Per Ampere (MTPA) Strategie für den Grunddrehzahlbereich und entsprechende Feldschwächtrajektorien orientieren sich an einer betriebspunktabhängigen Maximierung des Drehmoments [55]. Implizit ergibt sich damit auch eine Minimierung des Schlupfes, weswegen während der Testzyklen lediglich marginale Schlupfänderungen auftreten. Die absoluten Werte liegen stets im Bereich weniger Prozent, weswegen eine Betrachtung der Schlupfabhängigkeit bei den durchgeführten Untersuchungen obsolet ist. Die Umsetzung der Trajektorienplanung erfolgt unter der Annahme, dass es sich bei der genutzten ASM um die Antriebsmaschine eines leichten Fahrzeugs handelt, siehe Anh. A.1. Basierend auf den geometrischen Abmessungen dieses Fahrzeugs lässt sich somit die erforderliche Zugkraft und daraus drehzahlabhängige Drehmomentanforderungen zur Durchführung eines Testzyklus bestimmen. Abbildung 3.3(b) zeigt die entsprechende Stromtrajektorie am Beispiel des Worldwide Harmonized Light Vehicles Test Procedure (WLTP)-Zyklus. Die Betrachtung von Abbildung 3.3(c) verdeutlicht, repräsentiert durch L_s , die betriebspunktabhängige Sättigung der Hauptinduktivität, die in Bezug auf die durchgeführten Analysen der OPI-Algorithmen von Bedeutung ist.

Die realen Phasenspannungen an den Maschinenklemmen entsprechen aufgrund von Verlusten bei der leistungselektronischen Spannungswandlung nicht den vom Stromregler berechneten Sollspannungen. Zur besseren Ausnutzung des Antriebssystems existieren verschiedene Ansätze zur Kompensation dieser Verluststrecke. In dieser Arbeit werden die Verluste zunächst durch die von Wiedemann et al. in [77] vorgeschlagene Methode identifiziert. Anschließend erfolgt eine datenbasierte Modellierung durch ein einfaches echtzeitfähiges künstliches neuronales Netz (KNN) in Anlehnung an [78]. Dieses ermöglicht die Kompensation der Spannungsverluste innerhalb des Regelkreises und Analysen zur Beeinflussung der OPI durch den Spannungsfehler. Zusätzlich dient das Verlustmodell zur betriebspunktabhängigen Abbildung des Spannungsfehlers in simulativen Untersuchungen. Für die Umsetzung der Methode wird auf Anh. A.2 verwiesen.

Neben einem optimierten Stromregler ist für eine effiziente Regelung der ASM die Implementierung eines über den gesamten Betriebsbereich robust agierenden Rotorflussbeobachters erforderlich. Die zeitdiskrete Umsetzung erfolgt anhand des von West et al. in [79] vorgeschlagenen *Gopinath* Beobachters. Das Statorflussmodell ist in dieser Arbeit für die OPI erforderlich und wird in Anlehnung an Arnold implementiert [49].

Ein stabiles Stromregelsystem ist Voraussetzung für die in dieser Arbeit durchgeführten Untersuchungen. Das Hauptaugenmerk liegt jedoch auf der Echtzeitleistung der OPI-Algorithmen und den genutzten Klassifikatoren, die an den entsprechenden Stellen detailliert

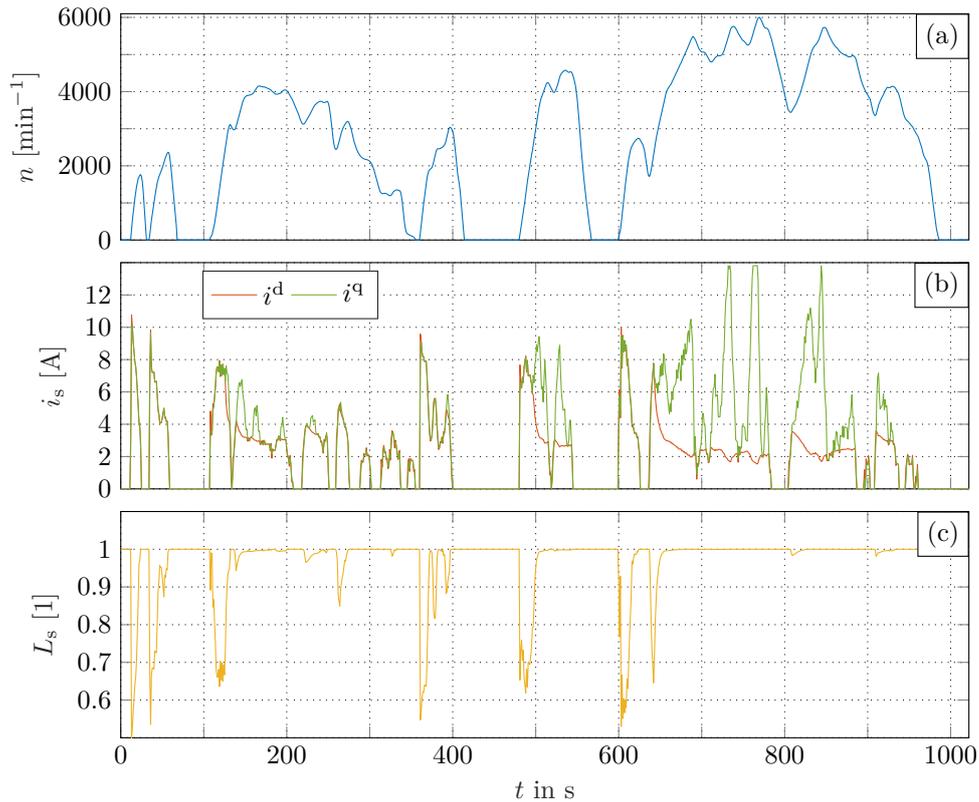


Abbildung 3.3: (a) WLTP-Zyklus Class1 skaliert auf den genutzten Drehzahlbereich der DRL132S4. (b) Stromtrajektorie entsprechend des skalierten Drehmomentbereichs. (c) Normalisiertes Sättigungsverhalten in Bezug auf (b).

beschrieben wird.

Ein Aspekt in Bezug auf die Ausführung der implementierten Funktionen sei an dieser Stelle bereits erwähnt: Die echtzeitfähige Ausführung der Regelungsfunktionen muss für einen sicheren Betrieb des Testaufbaus zwingend zu jedem Zeitpunkt gegeben sein. Daher erfolgt die Berechnung der Funktionen aufgeteilt in verschiedene Softwaretasks. Dabei wird dem Regelungstask aus Sicherheitsgründen die höchste Priorität zugesprochen. Während der Ausführung kann es demnach zu Softwarezyklen kommen, in denen die OPI nicht ausgeführt wird.

3.2 Aufbau Simulationsmodell

Die grundsätzliche Funktion der OPI-Algorithmen und der Regelungssoftware lässt sich durch die modellbasierte Softwareentwicklung ohne Zusatzaufwand simulativ validieren. Jedoch sind dazu Simulationsmodelle der in Abb. 3.1 dargestellten Hardwarekomponenten erforderlich.

Die Leistungselektronik wird wie bereits angedeutet quantitativ durch den reversen Betrieb des datenbasierten Verlustmodells simuliert, siehe Anh. A.2.

Das Messrauschen hat signifikante Auswirkungen auf die Robustheit und die absoluten Ergebnisse der OPI. Die im realen System auftretenden Rauscheigenschaften der Strom- und Drehzahlsensorik wurden daher im Voraus analysiert. Da die betriebspunktabhängige Änderung der Varianz des Messrauschens unwesentlich ist, ist dessen Berücksichtigung im Simulationsmodell als konstantes weißes Rauschen sinnvoll. Die Leistungsdichte des Rauschens orientiert sich dabei am Mittelwert der aus allen Betriebspunkten gemessenen Varianz, der sich zu $\bar{v} = 9 \cdot 10^4$ ergibt.

Modellierung der Asynchronmaschine

An die Modellierung der ASM ergeben sich aufgrund des Einsatzzweckes der OPI zur Fehlerdiagnose spezielle Anforderungen. Erstens ist die Berücksichtigung betriebsbedingter Parameteränderungen durch die nichtlineare Sättigung der Induktivitäten sowie die Temperaturbeziehungsweise Frequenzabhängigkeit der ohmschen Widerstände und Eisenverluste erforderlich. Außerdem ist die Modellierung des asymmetrischen Maschinenverhaltens zur Simulation von Defekten oder Alterung notwendig. Diese Aspekte werden in der Regel durch detaillierte numerische Modelle abgebildet. Jedoch ist diese Art von Modellen sehr rechenintensiv und aufgrund des hohen Detaillierungsgrads aufwendig zu entwickeln. Aus diesem Grund erfolgt in dieser Arbeit eine vereinfachte analytische Modellierung der genannten Aspekte mit Hilfe eines erweiterten dreiphasigen Maschinenmodells.

Die analytische Modellierung der ASM in unterschiedlichen Formen ist in einschlägiger Literatur rege vertreten [54], [80]–[84], wobei sich detailliertere Informationen in [54], [81] finden. Daraus werden Modelle zur Regelung von Antriebssystemen abgeleitet, siehe exemplarisch [53], [55], [85]–[87]. Erweiterungen zur Modellierung des nichtlinearen Sättigungsverhaltens und der Eisenverluste zeigen Slemon et al. in [58]. Dreiphasige Modelle adressieren [54], [85], [88], wobei Binder [54] zusätzlich eine Möglichkeit zur expliziten analytischen Modellierung von Rotorstäben vorstellt und Liu et al. [88] die Eisenverluste modellieren. Jedoch berücksichtigt keine dem Autor bekannte Referenz die Polpaarzahl der Statorwicklungen in einem dreiphasigen analytischen Modell. Diese Tatsache ist womöglich auf die voranschreitende Bedeutung und Genauigkeit numerischer Simulationen zurückzuführen, die wie bereits erwähnt für diese Arbeit aus Komplexitätsgründen nicht umsetzbar sind.

Für die simulativen Untersuchungen wurde im Rahmen dieser Arbeit ein Ansatz zur vereinfachten analytischen Modellierung von ASM mit beliebigen Polpaarzahlen entwickelt [89]. Der Ansatz ist im Kern als einfache Erweiterung des etablierten dreiphasigen Modells zu betrachten. Die Schwierigkeit besteht dabei in der Modellierung des Feldverlaufs an der Übergangsstelle zweier Pole. Bei Umsetzung strikter theoretischer Verläufe kommt es an diesen Punkten zu numerischen Interferenzen aufgrund sprunghafter Magnetfeldänderungen. Zur Lösung des Problems wird vereinfacht eine Approximationsfunktion genutzt, deren Superposition zum gewünschten Feldverlauf führt. Die explizite Modellierung der Rotorstäbe

und die Modellierung der Eisenverluste erfolgt nach Stand der Technik mit Verweis auf [54] und [88].

Mit Hilfe des entwickelten Modells ergibt sich eine vereinfachte Möglichkeit zur Modellierung von Anomalien, da Parameter einzelner Statorstränge, einzelne Rotorstäbe oder die gesamte Maschine manipulierbar sind.

Betrieb des Simulationsmodells

Bei jeder Simulation stellt sich zunächst die Frage nach der Abtastung des Modells. Aufgrund der Echtzeitanwendung ist eine zeitdiskrete Abtastung des Simulationsmodells mit einer festen Schrittweite erforderlich. Basierend auf eigenen Untersuchungen empfiehlt sich, das genutzte dreiphasige Modell für maximale Genauigkeit mit einer Schrittweite von höchstens $t_s = 10^{-5}$ s abzutasten [89]. Die Abtastzeit des Echtzeitsystem ist jedoch durch die Frequenz der Pulsweitenmodulation (PWM) von $f_{\text{pwm}} = 10$ kHz auf eine Taktzeit von $t_{\text{pwm}} = 10^{-4}$ s festgelegt. Damit ist auch die Taktzeit der OPI-Algorithmen bei realen Anwendungen nach unten begrenzt. Zur Gewährleistung einer möglichst realitätsnahen Simulation sollte die Abtastzeit der Echtzeitsoftware daher nicht reduziert werden. Für grundlegende Untersuchungen ist das gesamte Simulationsmodell mit einer Abtastzeit von $t_s = 10^{-5}$ s betreibbar. Dies macht sich vor allem in Bezug auf die benötigte Simulationszeit bemerkbar. Für erweiterte Untersuchungen bietet sich hingegen an, das Simulationsmodell aufzuteilen, sodass die Modellierung der ASM bei einer geringeren Taktzeit erfolgt.

Wegen der klein gewählten Schrittweiten bei zeitdiskreter Abtastung stellt sich das Lösungsverfahren erster Ordnung, durch Nutzung der vorwärtsgerichteten Euler-Formel, als hinreichend genau heraus.

4 Online-Parameteridentifikation mittels RLS-Algorithmus

Die Verwendung des RLS-Algorithmus für die Parameteridentifikation der ASM ist weit verbreitet. Aufgrund verschiedener Anwendungszwecke existieren dabei Verfahren zur Offline- und Online-Parameteridentifikation. Bei der Offline-Parameteridentifikation werden die Parameter außerhalb des geregelten Betriebs und meist mit speziellen Testläufen oder Anregungssignalen identifiziert. Der Fokus liegt dabei in der Regel auf der Ermittlung von Parametersätzen zur Bedatung des Regelsystems. Daher ist die Echtzeitfähigkeit der verwendeten Routinen eher von untergeordneter Bedeutung. Die OPI dient der Adaption veränderlicher Systemparameter und wird daher während des geregelten Betriebs der Maschine durchgeführt. Die meisten existierenden Anwendungen streben damit eine Effizienzsteigerung des Regelsystems und damit des gesamten Antriebssystems an. Daneben eignet sich die OPI mittels RLS-Algorithmus jedoch auch zur Online-Diagnose, wie die Ergebnisse im Verlauf dieser Arbeit zeigen.

Im Vergleich zu alternativen OPI-Algorithmen, wie zum Beispiel erweiterten KF, zeichnet sich der RLS-Algorithmus durch seine einfache Struktur und damit einfache Implementierbarkeit aus. Je nach Anwendung erfordert die Methode jedoch mehr oder weniger komplexe Regressionsmodelle deren Herleitung unter Umständen aufwendig ist. Eine Unterscheidung erfolgt in Modelle die nur in stationären oder auch in dynamischen Betriebspunkten valide sind. Je nach Anwendung basieren die Regressionsmodelle auf Differentialgleichungen im rotorflussorientierten d/q-KOS oder im rotierenden α/β -KOS. Die Anzahl und Konfiguration der zu identifizierenden Parameter ist durch die individuelle Struktur der hergeleiteten Modelle festgelegt.

Des Weiteren sind für dynamische Anwendungen Modifikationen des RLS-Algorithmus durch Vergessensfaktoren unterschiedlicher Ausprägungen erforderlich. Diese führen zu verschiedenen Konfigurationen und damit Hyperparametern, deren Einstellung bei veränderlichen Betriebspunkten herausfordernd ist. Die Performanz des RLS-Algorithmus hängt maßgeblich von der genutzten Konfiguration und der Optimierung der Hyperparameter ab.

Zusätzlich ist eine Aufbereitung durch diskrete Filterung der zur Identifikation genutzten Messgrößen erforderlich. Auch der genutzte Filteransatz sowie dessen Konfiguration beeinflussen die Qualität der Ergebnisse maßgeblich.

Im Verlauf des Kapitels wird zunächst der Stand der Technik zur OPI mittels

RLS-Algorithmus in Bezug auf die Anwendung in dieser Arbeit erfasst. Es folgt die Herleitung von Regressionsmodellen mit unterschiedlicher Detailtiefe. Anschließende theoretische Analysen adressieren die Konditionierung des vorliegenden Identifikationsproblems und die Sensitivität unterschiedlicher Parameterarten zur OPI im betrachteten Betriebsumfeld dieser Arbeit. Im Anschluss erfolgt zunächst die Implementierung unterschiedlicher Konfigurationen des RLS-Algorithmus sowie der diskreten Filterung. Abschließend wird die Performanz anhand verschiedener Testzyklen und Vergleiche sowohl simulativ als auch experimentell analysiert. Die Inhalte dieses Kapitels wurden in Teilen bereits in [17] publiziert.

4.1 Stand der Technik RLS-Algorithmus

In der nachfolgenden Übersicht werden in Bezug auf die Problemstellung dieser Arbeit bestehende Verfahren zur Online-Parameteridentifikation fokussiert. Bestehende Offline-Verfahren werden daher nur oberflächlich und beispielhaft referenziert. Allgemein liegt das Augenmerk auf Ansätzen zur Ermittlung der elektrischen Maschinenparameter.

4.1.1 Offline-Parameteridentifikation

Neben dem bekannten Leerlauf- und Kurzschlussversuch (siehe bspw. [24]) gibt es zahlreiche nicht rekursive Methoden zur Offline-Parameteridentifikation der ASM. Des Weiteren ist die rekursive Parameteridentifikation im Stillstand oder während spezifischer Inbetriebnahme-läufe eine gängige Methode zur Bestimmung detaillierter Parametersätze für die Maschinenregelung. Nachfolgend werden beispielhaft verschiedene rekursive Offline-Ansätze aufgezeigt. In [48], [90], [91] werden alle Ersatzschaltbildparameter schrittweise unter Verwendung vorgegebener Anregungssignale ermittelt. Unter zusätzlicher Berücksichtigung der Eisenverluste nutzen Siddavatam et al. in [92] ein diskretes Zustandsraummodell zur Ermittlung aller ESB Parameter. Besonderes Augenmerk auf die detaillierte Identifikation der Eisenverluste legen Boglietti et al. [93] und Chatterjee [94]. In [95] setzen Kouhi et al. einen nichtlinearen RLS-Algorithmus mit Fokus auf die Identifikation der Magnetisierungskurve ein. Aufgrund des erforderlichen Stillstands der Maschine oder zusätzlicher Anregungssignale sind diese Ansätze jedoch nicht mit den Anforderungen dieser Arbeit zu vereinbaren.

4.1.2 Online-Parameteridentifikation

Ziel dieser Arbeit ist die rekursive Parameteridentifikation während des dynamisch geregelten Betriebs zum Einsatz in der technischen Diagnose. Die existierenden Ansätze zur OPI während des geregelten Betriebs werden nachfolgend in sinnvolle Kategorien unterteilt dargestellt.

Online-Adaption des Rotorflussmodells

Für die indirekte feldorientierte Regelung der ASM ist ein Rotorflussmodell erforderlich. Für die Genauigkeit dieses Flussmodells sind die Rotorparameter von hoher Relevanz. Aus diesem Grund betrachten [96], [97], [98] die Identifikation der Rotorzeitkonstante während des Betriebs mit konstanter Drehzahl. Boussak et al. verwenden in [96] ein Modell im statorfesten KOS und einen RLS-Algorithmus mit einem variablen Vergessensfaktor. Telford et al. [97] und Wang et al. [98] nutzen zur Verbesserung der Reglereffizienz ein Identifikationsmodell im rotorflussorientierten d/q-KOS. Die vorherigen Ansätze fokussieren dabei das transiente Verhalten der Rotorzeitkonstante aufgrund von Temperaturänderungen bei konstanter Drehzahl. Der Betrieb in dynamischen Drehzahl- und Drehmomentbetriebspunkten bleibt bei den Untersuchungen jedoch außen vor. Ronchero-Sánchez et al. zeigen in [99] einen Ansatz zur Online-Identifikation des Rotorwiderstands R_r , während sie das System mit Drehzahl- und Drehmomentsprüngen beaufschlagen. Zur Identifikation wird dabei ein drehmomentunabhängiges Blindleistungsmodell genutzt. Ziel der genannten Ansätze ist jedoch eher die Steigerung der Reglereffizienz. Nachteilig ist dabei, dass eine genaue Offline-Identifikation des induktiven Verhaltens oder ein zusätzliches Anregungssignal erforderlich ist.

Online-Parameteridentifikation im stationären Betrieb

Zahlreiche Autoren schlagen verschiedene Ansätze für die OPI von ASM in stationären Betriebspunkten vor [26], [27], [47], [51], [100]–[107]. Unter Verwendung des T-ESB werden sowohl Modelle im rotorflussorientierten d/q-KOS als auch im statorfesten α/β -KOS eingesetzt.

Die Parameteridentifikation im d/q-KOS bietet bei Nutzung stationärer Modelle Vorteile, da keine Ableitung der Eingangszustandsgrößen erforderlich ist. Cirrincione et al. stellen die Performanz des ursprünglichen RLS-Algorithmus und des TLS-Algorithmus in [26] gegenüber. Dabei liegt der Fokus auf den Vorteilen des TLS-Algorithmus im Umgang mit stark verrauschten Eingangsgrößen. Die Autoren weisen auf das Problem eines verzerrten Spannungswertes im Fall von Wechselrichtern im Vergleich zu Netzanwendungen hin. In [102] berücksichtigen die gleichen Autoren zusätzlich den Einfluss der magnetischen Sättigung. Beide Ansätze zeigen überzeugende experimentelle Ergebnisse.

Um mit transientem Parameterverhalten zwischen stationären Betriebspunkten umgehen zu können, verwenden Huynh et al. in [103] RLS-Algorithmen mit einfachen und mehrfachen Vergessensfaktoren. Es werden jedoch nur mäßig überzeugende Simulationsergebnisse präsentiert.

Stephan et al. weisen in [100] auf die Überparametrisierung des T-ESB Modells hin. Dieses Problem lässt sich durch die Vorgabe oder Festlegung bestimmter Parameter während der Identifizierung eliminieren. Die dadurch resultierenden positiven Auswirkungen auf die Simulations- und Versuchsergebnisse werden dargestellt.

Ein wesentliches Problem der Parameteridentifikation basierend auf Modellen im d/q-KOS erläutern Cecconi et al. in [108]. Zur Transformation in rotorflussorientierte Koordinaten ist eine Schätzung des Rotorflusswinkels erforderlich. Die dafür verwendeten Modelle weisen jedoch selbst eine Sensitivität gegenüber den zu identifizierenden Parametern auf. Entsprechend ist die Genauigkeit der identifizierten Parameter nicht nur vom Algorithmus selbst abhängig, sondern auch von der Qualität des Transformationswinkels.

Aus diesem Grund ist das auf dem T-ESB im α/β -KOS basierende Modell vorteilhaft. Velez-Reyes et al. schlagen in [101] einen Ansatz vor, der alle Parameter des T-ESB identifiziert. Dabei liegt der Schwerpunkt auf der sensorlosen Drehzahlregelung, weswegen eine zusätzliche Schätzung der Rotordrehzahl erfolgt. Hu et al. identifizieren die Parameter in [47] hingegen schrittweise mit einzelnen Modellen reduzierter Ordnung. Zur Berechnung gefilterter Ableitungen der Eingangssignale wird ein Butterworth-Filter dritter Ordnung verwendet. Dynamische Betriebspunkte mit transientem Parameterverhalten finden in [101] und [47] keine wirkliche Berücksichtigung.

Mehrere andere Autoren befassen sich mit unterschiedlichen Problemstellungen und präsentieren experimentelle Ergebnisse:

In [105] untersucht Koubaa den Vorteil der Vorgabe des Statorwiderstands und in [106] fokussiert der gleiche Autor zusätzlich die Echtzeitimplementierung.

Mohammed et al. analysieren in [107] die Performanz des Algorithmus mit Bezug auf verschiedene Referenzmodelle. Ein Drehmomentmodell mit einem zugehörigen Sensor sowie ein Strom- und Leistungsfaktormodell zeigen gute Ergebnisse bei der Verifizierung.

Die Auswirkung der Sättigung berücksichtigen Moons et al. in [27] unter Verwendung eines Modells mit Ableitungen höherer Ordnung. Nachteilig ist dabei das Auftreten mehrerer nichtlinearer Nebenbedingungen. Der damit verbundenen Problematik durch verrauschte Eingangsgrößen treten die Autoren mit einem GLS-Algorithmus entgegen. Durch eine Transformationsvorschrift erfolgt darin eine Beschränkung des zulässigen Raums zur Parameteroptimierung.

In [51] liegt der Fokus insbesondere auf der Online-Identifikation des Statorwiderstands. Zur Lösung des in stationären Betriebspunkten auftretenden Anregungsproblems überlagern Altmannshofer et al. die flussbildende Stromkomponente mit einem sinusförmigen Anregungssignal. Diese Maßnahme gewährleistet eine robuste Identifikation des Statorwiderstands. Darüber hinaus schlagen die Autoren zur Ableitungsberechnung des Eingangssignals die Nutzung des Savitzky-Golay Glättungsalgorithmus vor. Dieses Filter eignet sich besonders zur echtzeitfähigen Implementierung.

Die in diesem Abschnitt vorgestellten Ansätze eignen sich lediglich zur OPI in Betriebspunkten mit stationärer Drehzahl. In Bezug auf diese Arbeit gilt es zu bewerten, ob die Drehzahländerungen in den genutzten Profilen im Vergleich zur Änderung der übrigen Zustandsgrößen langsam genug erfolgen.

Online-Parameteridentifikation im dynamischen Betrieb

Nur wenige existierende Arbeiten befassen sich mit der Anwendung während des geregelten dynamischen Betriebs. Detaillierte Analysen und Ergebnisse stellt Arnold in [49] vor. Darin erfolgt ein Vergleich bei Verwendung von stationären und dynamischen Identifikationsmodellen auf Basis des T-ESB im α/β -KOS zur Identifikation von elektrischen und mechanischen Parametern. Die Ableitungen der Eingangssignale werden mittels eines FIR-Filters analog zu [48] berechnet. Unter Verwendung des dynamischen Modells muss der Statorfluss durch ein vereinfachtes und stabilisiertes Flussmodell bestimmt werden. Darüber hinaus weist Arnold auf den Vorteil der Verwendung beider komplexer Modellgleichungen hin, da dieses Vorgehen zur Kompensation von asymmetrischem Verhalten im dreiphasigen System beiträgt. Um eine fortlaufende Anregung zu gewährleisten, erfolgt die Identifikation während des reversiblen Maschinenbetriebs. Die experimentellen Ergebnisse validiert Arnold mit einer Drehzahl-schätzung sowie verschiedenen Spannungs- und Strommodellen. Zusätzlich zeigt sich, dass die Berücksichtigung der Eisenverluste in den Validierungsmodellen die tatsächlichen Ergebnisse in einigen Betriebspunkten verbessert.

Buchholz et al. führen die OPI in [50] basierend auf einer Übertragungsfunktion im α/β -KOS entlang eines Testprofils im gesamten Betriebsbereich der Maschine durch. Die potenzielle Nutzung des Γ -ESB wird erwähnt, jedoch erfolgt die Identifikation anhand des T-ESB. Die Autoren analysieren das Problem der fortlaufenden Anregung durch die komplexen Eigenwerte im Frequenzbereich. Hingegen gehen die Autoren dabei nicht auf die erforderliche Schätzung des Statorflusses ein. Buchholz et al. erwähnen den durch den Umrichter erzeugten Spannungsfehler, jedoch ohne dessen Einfluss auf die OPI zu berücksichtigen. Zur Berechnung der Ableitungen der Eingangssignale nutzen die Autoren das in [49] vorgeschlagene FIR-Filter. Die Validierung der implementierten OPI erfolgt ausschließlich simulativ.

Generell liegt der Fokus in der existierenden Literatur eher auf der OPI zur Verbesserung der Reglerdynamik bzw. -effizienz. Die Validierung erfolgt durch spezifische Testprofile, die keinen Bezug zu einem automobilen Fahrzyklus haben. Diese Arbeit fokussiert jedoch Diagnoseanwendungen in einer dynamischen automobilen Umgebung. Der Anspruch verlagert sich daher weg von einer sehr genauen Identifikation einzelner und für die Regelung relevanter Parameter in bestimmten Betriebspunkten, hin zu einer robusten OPI im gesamten dynamischen Betriebsumfeld der jeweiligen Maschine. Transiente Eisenverluste oder dynamisches Sättigungsverhalten aufgrund spezifischer Maschinentypen in einem dynamischen Umfeld sind in diesem Zusammenhang bisher nicht berücksichtigt worden. Darüber hinaus sind dem Autor keine Arbeiten bekannt, die den Einfluss des Spannungsabfalls über dem Wechselrichter und die Spannungsverzögerung durch die Echtzeitimplementierung berücksichtigen. Außerdem führt die übliche Verwendung des T-ESB zu einem überparametrisierten Identifikationsmodell. Im Hinblick auf die in dieser Arbeit betrachteten Diagnoseanwendun-

gen lässt sich die Komplexität jedoch durch Verwendung des vereinfachten Γ -inversen-ESB (Γ -EC) reduzieren.

In diesem Kapitel erfolgt daher die Entwicklung eines robusten RLS-Algorithmus zur OPI in einer dynamischen Automobilumgebung. Zur Berücksichtigung dynamischer Parameteränderungen der ASM basiert dieser modifizierte RLS-Algorithmus auf der Nutzung mehrerer variabler Vergessensfaktoren. Zusätzlich ermöglicht die Herleitung erweiterter dynamischer Regressionsmodelle die Berücksichtigung von Eisenverlusten in Abhängigkeit vom Betriebspunkt. Aus Komplexitätsgründen dient anstelle des T-ESB das Γ -ESB als Modellgrundlage. Der Nutzen der Modell- bzw. Algorithmusmodifikationen wird im Vergleich zu mehreren bestehenden Ansätzen anhand von Simulations- und Versuchsergebnissen validiert. Eine Analyse der Performanz der OPI bei transienten Parameteränderungen aufgrund von Sättigung und Frequenz erfolgt anhand entsprechender dynamischer Testzyklen. Zusätzlich wird der Einfluss des nichtlinearen Spannungsabfalls über dem Umrichter und der Spannungsverzögerung durch die Echtzeitimplementierung auf die OPI analysiert.

4.2 Identifikationsmodelle

Die Nutzung des RLS-Algorithmus zur OPI von Asynchronmaschinen erfordert ein MISO-Modell der Form $y = \Phi \cdot \hat{\theta}$ des zu identifizierenden Systems. Die Herleitung verschiedener Modelle erfolgt dabei jeweils basierend auf einem Ersatzschaltbild der ASM und dem zugehörigen Differentialgleichungssystem. Zur analytischen Modellierung der ASM existieren diverse ESB für unterschiedliche Einsatzzwecke, wie in Abs. 2.3.1 dargelegt. Darunter ist das T-ESB (Abb. 2.3) am weitesten verbreitet. Aufgrund der mathematischen Überbestimmtheit des T-ESB, müssen bei Identifikation aller elektrischen Parameter Annahmen bezüglich der Streuinduktivitäten getroffen werden. Letzlich weist dieses Modell daher eine unnötig komplexe Struktur auf, die sich durch Verwendung des Γ -ESB (Abb. 2.4) vermeiden lässt.

Aus den Differentialgleichungen des Γ -ESB (2.92) bzw. (2.98) lassen sich unterschiedlich detaillierte MISO-Modelle zur Parameteridentifikation herleiten. Zunächst werden einige grundlegende Aspekte für die Herleitung der verschiedenen Identifikationsmodelle aufgezählt:

- Die Anzahl der zu identifizierenden Parameter hat großen Einfluss auf die Performanz des RLS-Algorithmus. Die Vorgabe spezifischer Parameter kann die Modellkomplexität signifikant verringern, wobei zu wenige Freiheitsgrade zu einer Unteranpassung des Identifikationsmodells führen können. Mit zunehmender Modellordnung ergeben sich jedoch unter Umständen nichtlineare Nebenbedingungen, welche die Komplexität des Modells unnötig erhöhen. Die somit entstehenden zusätzlichen Freiheitsgrade haben einen direkten Einfluss auf die Robustheit und Qualität der OPI. Dieser Zusammenhang lässt sich theoretisch durch das Bias-Varianz-Dilemma ergründen. Auf

eine tiefgreifende Darstellung wird im Rahmen dieser Arbeit verzichtet und daher auf einschlägige Literatur verwiesen [25, S.50-61], [21, S.491-493], [22, S. 501–502]. Das Bestreben ist stets eine möglichst einfache Modellstruktur für das jeweilige Identifikationsproblem zu finden.

- Bei der Herleitung der Modelle wird stets die Eliminierung aller nicht messbaren Zustandsgrößen angestrebt.
- Aus den verschiedenen ESB sind grundsätzlich Herleitungen verschiedener Identifikationsmodelle möglich, die entweder nur für stationäre oder auch für dynamische Drehzahlbetriebspunkte gültig sind. In Bezug auf die OPI ist die fortlaufende Anregung eher in dynamischen Betriebspunkten gegeben.
- Die OPI ist sowohl mit Modellen im rotierenden α/β -KOS als auch im rotorflussorientierten d/q-KOS möglich. Im α/β -KOS bestehen die Eingangssignale aus sinusförmigen mit der Statorfrequenz ω_s rotierenden Größen. Alle vorgestellten Modelle lassen sich durch Anwendung der Park-Transformation (2.95) in flussorientierte Identifikationsmodelle im d/q-KOS transformieren. Die Eingangssignale bestehen in diesem Fall aus verrauschten Gleichgrößen. In stationären Betriebsphasen ergeben sich dadurch lediglich durch das Rauschen hervorgerufene Änderungen der transformierten Messgrößen und die Ableitungen der Zustandsgrößen sind näherungsweise null. Diese Faktoren haben negative Einflüsse auf die fortlaufende Anregung des Identifikationsproblems. Des Weiteren ruft das zur Schätzung des Rotorflusswinkels benötigte Modell eine zusätzliche Fehlerquelle hervor [108]. Die Modellierung im d/q-KOS eignet sich aufgrund der Gleichgrößen jedoch zur Darstellung von betriebspunktabhängigen Anregungsproblemen [51].
- Aufgrund der komplexen Komponenten der Zustandsgrößen in (2.92) und (2.98) besteht jede Modellgleichung aus zwei MISO-Modellen mit dem gleichen Parametervektor. Dadurch ergibt sich ein MISO-Modell in α - bzw. d-Richtung und ein weiteres in β - bzw. q-Richtung. Diese werden fortlaufend als α - und β -Modell beziehungsweise d- und q-Modell bezeichnet. Die Modelle sind unabhängig voneinander oder redundant nutzbar. Arnold et al. erhöhen die Konvergenzgeschwindigkeit des Algorithmus in [49] durch toggeln der beiden Modelle.
- Im automobilen Umfeld stellt sich die Frage, ob die transienten Eisenverluste aufgrund des hohen Drehzahlstellbereichs Auswirkungen auf die OPI haben. Daher werden entsprechende erweiterte Modelle hergeleitet und analysiert.

Dieser Abschnitt zeigt die Herleitung der für diese Arbeit relevanten Identifikationsmodelle. Es werden sowohl stationäre als auch dynamische Modelle unter Berücksichtigung der zuvor

genannten Kriterien zur OPI untersucht. Die Herleitung der Modelle erfolgt im statorfesten α/β -KOS basierend auf dem Gleichungssatz (2.92) des Γ -ESB.

4.2.1 Stationäre Regressionsmodelle

Eine in bestehenden Arbeiten [26], [27], [47], [51], [100]–[107] oft getätigte Annahme ist eine langsame Änderung der Maschinendrehzahl $\frac{d}{dt}\omega_m \approx 0$ im Vergleich zu den übrigen elektrischen Zustandsvariablen. Diese führt zu einer Reduktion der Modellkomplexität. Die Validität dieser Annahme in Bezug auf die betrachteten dynamischen Betriebspunkte wird im Laufe dieser Arbeit überprüft. Dieser Abschnitt zeigt die Herleitungen stationärer Identifikationsmodelle basierend auf dem Differentialgleichungssystem des Γ -ESB.

Stationäres Modell ohne Eisenverluste

Zunächst wird die Rotorflussgleichung (2.92d) nach der Zeit differenziert:

$$\frac{d}{dt}\Psi_r^S = L_m \frac{d}{dt}i_s^S + L_m \frac{d}{dt}i_r^S. \quad (4.1)$$

Anschließend erfolgt die Substitution von (2.92d) und deren Ableitung (4.1) in (2.92b):

$$0 = R_r i_r^S + L_m \frac{d}{dt}i_s^S + L_m \frac{d}{dt}i_r^S - \mathbf{J}n_p \omega_m (L_m i_s^S + L_m i_r^S). \quad (4.2)$$

Es folgt wiederum eine Differentiation nach der Zeit:

$$0 = R_r \frac{d}{dt}i_r^S + L_m \frac{d^2}{dt^2}i_s^S + L_m \frac{d^2}{dt^2}i_r^S - \underbrace{\mathbf{J}n_p \frac{d}{dt}\omega_m (L_m i_s^S + L_m i_r^S)}_{\approx 0, \text{ wenn } \frac{d}{dt}\omega_m \approx 0} - \mathbf{J}n_p \omega_m \left(L_m \frac{d}{dt}i_s^S + L_m \frac{d}{dt}i_r^S \right). \quad (4.3)$$

Bei genauer Betrachtung von (4.3) zeigt sich, dass eine vollständige Eliminierung der nicht messbaren Größen Ψ_s , Ψ_r und i_r nur unter Annahme einer konstanten Drehzahl möglich ist. Unter dieser Annahme lässt sich im nächsten Schritt der Rotorstrom in (4.3) substituieren, indem die Statorflussgleichung (2.92c) nach i_r^S aufgelöst und anschließend zweimal differenziert wird:

$$i_r^S = \frac{1}{L_m} \left(\Psi_s^S - (L_\sigma + L_m) i_s^S \right) \quad (4.4)$$

$$\frac{d}{dt}i_r^S = \frac{1}{L_m} \left(\frac{d}{dt}\Psi_s^S - (L_\sigma + L_m) \frac{d}{dt}i_s^S \right) \quad (4.5)$$

$$\frac{d^2}{dt^2}i_r^S = \frac{1}{L_m} \left(\frac{d^2}{dt^2}\Psi_s^S - (L_\sigma + L_m) \frac{d^2}{dt^2}i_s^S \right). \quad (4.6)$$

Die Ableitungen des Statorflusses in (4.5) und (4.6) sind wiederum durch die Statorspannungsgleichung (2.92a) und deren Ableitung ersetzbar:

$$\frac{d}{dt}i_r^S = \frac{1}{L_m} \left(u_s^S - R_s i_s^S - (L_\sigma + L_m) \frac{d}{dt}i_s^S \right) \quad (4.7)$$

$$\frac{d^2}{dt^2}i_r^S = \frac{1}{L_m} \left(\frac{d}{dt}u_s^S - R_s \frac{d}{dt}i_s^S - (L_\sigma + L_m) \frac{d^2}{dt^2}i_s^S \right). \quad (4.8)$$

Die finale Modellgleichung ergibt sich durch Einsetzen von (4.7) und (4.8) in (4.3):

$$\begin{aligned} 0 &= R_r \frac{1}{L_m} \left(u_s^S - R_s i_s^S - (L_\sigma + L_m) \frac{d}{dt}i_s^S \right) + L_m \frac{d^2}{dt^2}i_s^S \\ &+ L_m \frac{1}{L_m} \left(\frac{d}{dt}u_s^S - R_s \frac{d}{dt}i_s^S - (L_\sigma + L_m) \frac{d^2}{dt^2}i_s^S \right) \\ &- \mathbf{J}n_p \omega_m \left(L_m \frac{d}{dt}i_s^S + L_m \frac{1}{L_m} \left(u_s^S - R_s i_s^S - (L_\sigma + L_m) \frac{d}{dt}i_s^S \right) \right). \end{aligned} \quad (4.9)$$

Durch die Darstellung als Matrixgleichung und die Substitution von $L_s = L_\sigma + L_m$ resultiert aus (4.9) die Regressionsgleichung in der Form $y = \Phi \hat{\theta}$:

$$\underbrace{\frac{d}{dt}u_s^S - \mathbf{J}n_p \omega_m u_s^S}_y = \underbrace{\begin{bmatrix} -u_s^S \\ \frac{d}{dt}i_s^S \\ \frac{d^2}{dt^2}i_s^S - \mathbf{J}n_p \omega_m \frac{d}{dt}i_s^S \\ \frac{d}{dt}i_s^S - \mathbf{J}n_p \omega_m i_s^S \\ i_s^S \end{bmatrix}}_\Phi^T \underbrace{\begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} L_s \\ L_\sigma \\ R_s \\ \frac{R_r}{L_m} R_s \end{bmatrix}}_{\hat{\theta}}. \quad (4.10)$$

Das hergeleitete Modell (4.10) weist dieselbe Struktur wie jenes basierend auf dem T-ESB auf, wie zum Beispiel in [51] ersichtlich. Jedoch ist die Rotorinduktivität nicht als separater Parameter vertreten. Der Parametervektor $\hat{\theta}$ des Modells (4.10) weist bei vier unabhängigen elektrischen Systemparametern fünf zu identifizierende Parameter auf, wodurch sich eine nichtlineare Nebenbedingung $\hat{\theta}_5 = \hat{\theta}_1 \cdot \hat{\theta}_4$ ergibt. Da die zusätzlich zu identifizierende Parameterkombination keinen Mehrwert bietet und einen negativen Einfluss auf die Robustheit darstellt, ist deren Vorsteuerung sinnvoll. Dabei wird $\hat{\theta}_5[k]$ mit Hilfe von $\hat{\theta}_1[k-1]$ und $\hat{\theta}_4[k-1]$ der letzten Iteration berechnet und dem Modellausgang y zugeschrieben. Dadurch

ergibt sich aus (4.10) ein Modell mit reduzierter Parameteranzahl:

$$\frac{d}{dt}u_s^S - \mathbf{J}n_p\omega_m u_s^S - \hat{\theta}_1 \cdot \hat{\theta}_4 i_s^S = \begin{bmatrix} -u_s^S \\ \frac{d}{dt}i_s^S \\ \frac{d^2}{dt^2}i_s^S - \mathbf{J}n_p\omega_m \frac{d}{dt}i_s^S \\ \frac{d}{dt}i_s^S - \mathbf{J}n_p\omega_m i_s^S \end{bmatrix}^T \begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} L_s \\ L_\sigma \\ R_s \end{bmatrix}. \quad (4.11)$$

Mit Hilfe der Identifikationsparameter lassen sich daraus die physikalischen Parameter der ASM berechnen:

$$R_s = \hat{\theta}_4, \quad L_\sigma = \hat{\theta}_3, \quad L_m = \frac{\hat{\theta}_2}{\hat{\theta}_1} - \hat{\theta}_3, \quad R_r = \hat{\theta}_2 - \hat{\theta}_3 \cdot \hat{\theta}_1. \quad (4.12)$$

Stationäres Modell mit Vorgabe definierter Parameter

Die unterschiedliche physikalische Zusammensetzung der Parameter in $\hat{\theta}$ hat direkten Einfluss auf das Konvergenzverhalten und das Ergebnis der OPI, wie bereits in Abs. 2.3.2 erwähnt. Diese Aussage wird durch die Sensitivitätsanalyse in Abs. 4.3.2 gestützt. Aufgrund dieser Tatsache kann es von Vorteil sein, einzelne Parameter von der Identifikation auszuschließen und a priori als Modelleingang vorzugeben.

Als besonders förderlich stellt sich die Vorgabe des Statorwiderstands R_s heraus. Dieser nimmt je nach Art der Maschine verhältnismäßig sehr kleine Werte an. In Verbindung mit dem daraus resultierenden kleinen Spannungsabfall und daher dem niedrigen Absolutwert des Modellterms ergeben sich direkte Auswirkungen auf die Sensitivität. Außerdem lässt sich R_s außerhalb des regulären Betriebs mit einer einfachen Messung über die Klemmen der Maschine bestimmen. Die Adaption der temperaturbedingten Parameteränderungen während des Betriebs erfolgt dann durch die Sensorik zur Erfassung der Wicklungstemperatur.

Das entsprechende Identifikationsmodell reduzierter Ordnung ergibt sich direkt aus dem vollständigen Modell (4.10). Allgemein ist die Vorgabe jedes Modellparameters möglich. Die Vorgabe des Statorwiderstands führt zu einer deutlichen Vereinfachung des Modells. Nach der Umformung findet sich R_s im Modellausgang \mathbf{y} und in der Regressionsmatrix Φ als vorgegebener Wert wieder:

$$\begin{aligned} \mathbf{y} &= \frac{d}{dt}u_s^S - R_s \frac{d}{dt}i_s^S - \mathbf{J}n_p\omega_m (u_s^S - R_s i_s^S) \\ \Phi &= \begin{bmatrix} -u_s^S + R_s i_s^S & \frac{d}{dt}i_s^S & \frac{d^2}{dt^2}i_s^S - \mathbf{J}n_p\omega_m \frac{d}{dt}i_s^S \end{bmatrix} \\ \hat{\theta} &= \begin{bmatrix} \frac{R_r}{L_m} & \frac{R_r}{L_m} L_s & L_\sigma \end{bmatrix}^T. \end{aligned} \quad (4.13)$$

Demnach entfällt die nichtlineare Nebenbedingung und damit die Vorsteuerung der geschätzten Parameter der vorherigen Iteration.

4.2.2 Dynamisches Regressionsmodell

Das zuvor hergeleitete stationäre Modell gilt unter Vernachlässigung der Drehzahländerung. Die Korrektheit dieser Annahme in Bezug auf ein dynamisches Betriebsumfeld wird in den folgenden Teilen des Kapitels simulativ und experimentell untersucht. Arnold stellte in [49] erstmals ein dynamisches Identifikationsmodell basierend auf dem T-ESB vor, das auch während des transienten Drehzahlbetriebs Gültigkeit hat. Dadurch ergibt sich ein Identifikationsmodell indem der Statorfluss als nicht messbare Zustandsgröße verbleibt, da eine Eliminierung mathematisch nicht möglich ist. Als Pendant dazu lässt sich auch aus dem Γ -ESB ein dynamisches Regressionsmodell herleiten.

In dieser Arbeit wird zusätzlich der Einfluss der Eisenverluste auf die OPI untersucht. Daher ist die Herleitung eines erweiterten dynamischen Identifikationsmodells nach dem vollständigen Γ -ESB in Abb. 2.4 erforderlich. Zusätzlich werden Modelle mit reduzierter Parameterordnung durch Vorgabe definierter Parameter vorgestellt.

Dynamisches Modell ohne Eisenverluste

Die Herleitung des dynamischen Modells aus dem Γ -ESB verläuft analog zu Arnold und weist daher die gleiche Problematik auf [49]. Ausgehend von (4.3) ist der das Beschleunigungsverhalten beschreibende Term fortlaufend nicht mehr vernachlässigbar:

$$0 = R_r \frac{d}{dt} i_r^S + L_m \frac{d^2}{dt^2} i_s^S + L_m \frac{d^2}{dt^2} i_r^S - \underbrace{\mathbf{J} n_p \frac{d}{dt} \omega_m (L_m i_s^S + L_m i_r^S)}_{\neq 0} - \mathbf{J} n_p \omega_m \left(L_m \frac{d}{dt} i_s^S + L_m \frac{d}{dt} i_r^S \right). \quad (4.14)$$

Die finale Modellgleichung ergibt sich durch Einsetzen der zuvor bereits gewonnenen Ausdrücke für den Rotorstrom (4.4) und die zugehörigen Ableitungen (4.5), (4.6) in (4.14):

$$\frac{d^2}{dt^2} \Psi_s^S - \mathbf{J} n_p \left(\frac{d}{dt} \omega_m \Psi_s^S + \omega_m \frac{d}{dt} \Psi_s^S \right) = \begin{bmatrix} -u_s^S \\ \frac{d}{dt} i_s^S \\ \frac{d^2}{dt^2} i_s^S - \mathbf{J} n_p \left(\omega_m + \frac{d}{dt} \omega_m i_s^S \right) \\ i_s^S \end{bmatrix}^T \begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} L_s \\ L_\sigma \\ \frac{R_r}{L_m} R_s \end{bmatrix}. \quad (4.15)$$

Die resultierende Modellgleichung (4.15) enthält keine nichtlineare Nebenbedingung, jedoch lässt sich der Statorfluss nicht mehr vollständig eliminieren. Eine weitere Substitution der

Ableitung des Statorflusses durch (2.92a) ist grundsätzlich möglich:

$$\frac{d}{dt}u_s^S - \mathbf{J}n_p \left(\Psi_s^S \frac{d}{dt}\omega_m + \omega_m u_s^S \right) = \begin{bmatrix} -u_s^S \\ \frac{d}{dt}i_s^S \\ \frac{d^2}{dt^2}i_s^S - \mathbf{J}n_p \left(\omega_m + \frac{d}{dt}\omega_m i_s^S \right) \\ i_s^S \\ \frac{d}{dt}i_s^S - \mathbf{J}n_p \omega_m i_s^S \end{bmatrix}^T \begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} L_s \\ L_\sigma \\ \frac{R_r}{L_m} R_s \\ R_s \end{bmatrix}. \quad (4.16)$$

Jedoch ergibt sich dadurch eine nichtlineare Nebenbedingung aufgrund des zusätzlichen Identifikationsparameters $\hat{\theta}_5 = R_s = \hat{\theta}_4 / \hat{\theta}_1$. Der nicht eliminierbare und nicht messbare Statorfluss Ψ_s^S muss ohnehin durch ein zusätzliches Statorflussmodell bestimmt werden, weswegen nachfolgend die Modellgleichung (4.15) verwendet wird. Der in dieser Arbeit verwendete Ansatz zur Modellierung des Statorflusses wird nachfolgend erläutert.

Statorflussmodell

Generell ergibt sich bei der Berechnung des Statorflusses im Zusammenhang mit der OPI die Problematik, dass die genutzten Modelle selbst parametersensitiv sind. Die einfachste Möglichkeit zur Schätzung des Statorflusses ist die Nutzung der Statorflussgleichung (2.92a). Arnold präsentierte in [49] eine Gesamtlösung zur Statorflussschätzung basierend auf (2.92a), die in dieser Arbeit aufgegriffen wird, siehe Abb. 4.1. Der Schätzwert des Statorflussmodells dient dabei als direkter Eingang des RLS-Algorithmus. Als Systemparameter ist in (2.92a) lediglich der Statorwiderstand R_s enthalten. Bei vollständiger Identifikation auf Basis von (4.15) wird \hat{R}_s als geschätzter Parameter des RLS-Algorithmus an das Statorflussmodell zurückgeführt. Dabei entsteht eine Art zusätzlicher Regelkreis, der die Konvergenzzeit der OPI deutlich verlängert. Um ein robustes Verhalten sicherzustellen wird der zurückgeführte Statorwiderstand mit einer verhältnismäßig großen Zeitkonstante gefiltert. Bei Nutzung eines Identifikationsmodells mit reduzierter Parameteranzahl ist es möglich, R_s aus dem Parametervektor zu entfernen bzw. vorzusteuern, wodurch sich die Konvergenzzeit verringert und die Robustheit entsprechend erhöht.

Aus der Systemtheorie ist das Verhalten offener Integratoren in mathematischen Modellen in Verbindung mit verzerrten sinusförmigen Signalen als allgemeines Problem bekannt. Im Fall elektrischer Maschinen ergeben sich durch Oberwellen verzerrte Messsignale, die bei der Bildung von Ψ_s^S zu einem Phasenfehler führen. Durch die offene Integration ergibt sich dadurch ein unerwünschter Drift im Ausgangssignal, der zur Divergenz führen kann [49, S.24 ff.]. Zur Lösung dieses Problems führte Arnold in [49, S.24 ff.] eine Rückkopplung zur Kompensation des Phasenfehlers ein, wie in Abb. 4.1 grau hinterlegt. Dabei wird ein Korrekturterm berechnet, der den Phasenverschiebungswinkel auf $\gamma = 90^\circ$ stabilisiert. Die Operation $\arg()$

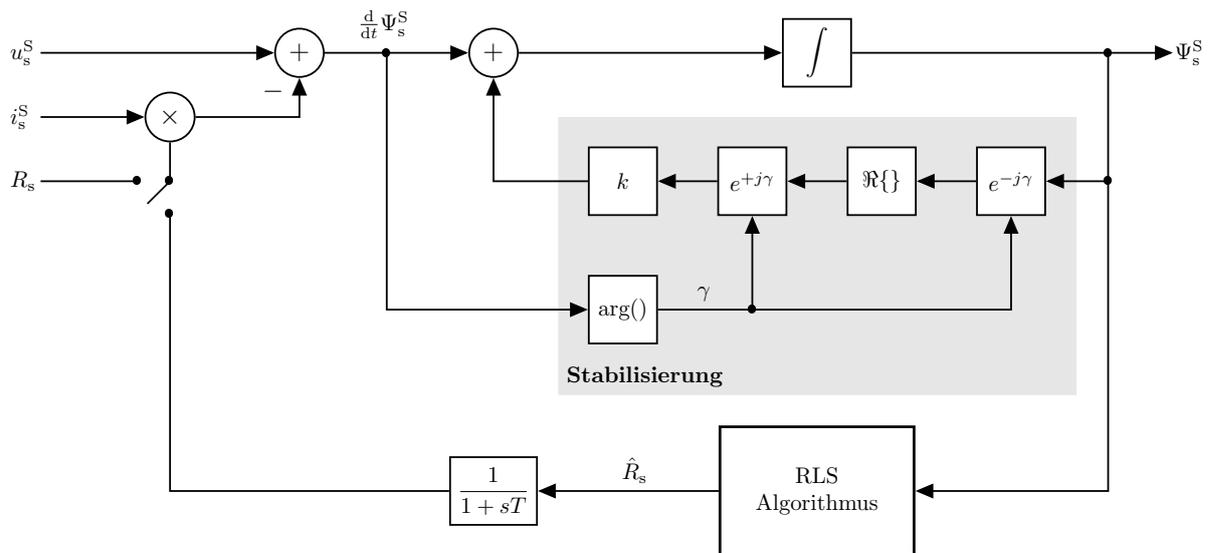


Abbildung 4.1: Blockschaltbild des Statorflussmodells mit Stabilisierung.

bestimmt darin den Winkel von Ψ_s^S und $\Re\{\}$ separiert den Realteil. Der Faktor k dient der systemspezifischen Konfiguration der Rückkopplung. Diverse experimentelle Untersuchungen bestätigen das Auftreten des Integrationsdrifts auch im Fall des in dieser Arbeit genutzten Systems. Daher wird die Stabilisierungsmaßnahme für den folgenden Verlauf aufgegriffen.

Dynamisches Modell mit Eisenverlusten

Nachfolgend wird basierend auf den um die Eisenverluste erweiterten Gleichungen (2.98c) und (2.98d) ein dynamisches Identifikationsmodell hergeleitet. Das Vorgehen ähnelt dabei den zuvor durchgeführten Herleitungen.

Zunächst wird die Rotorflussgleichung (2.98d) nach der Zeit differenziert:

$$\frac{d}{dt}\Psi_r^S = L_m \left(\frac{d}{dt}i_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt}u_s^S - R_s \frac{d}{dt}i_s^S \right) \right) + L_m \frac{d}{dt}i_r^S. \quad (4.17)$$

Die Rotorflussgleichung (2.98d) und deren Ableitung (4.17) werden in die Rotorspannungsgleichung (2.98b) eingesetzt

$$0 = R_r i_r^S + L_m \left(\frac{d}{dt}i_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt}u_s^S - R_s \frac{d}{dt}i_s^S \right) \right) + L_m \frac{d}{dt}i_r^S - \mathbf{J}n_p \omega_m \left(L_m \left(i_s^S - \frac{1}{R_{fe}} \left(u_s^S - R_s i_s^S \right) \right) + L_m i_r^S \right) \quad (4.18)$$

und anschließend nach der Zeit differenziert:

$$\begin{aligned}
0 = & R_r \frac{d}{dt} i_r^S + L_m \left(\frac{d^2}{dt^2} i_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} u_s^S - R_s \frac{d^2}{dt^2} i_s^S \right) \right) + L_m \frac{d^2}{dt^2} i_r^S \\
& - \underbrace{\mathbf{J} n_p \frac{d}{dt} \omega_m \left(L_m \left(i_s^S - \frac{1}{R_{fe}} (u_s^S - R_s i_s^S) \right) + L_m i_r^S \right)}_{\approx 0, \text{ wenn } \frac{d}{dt} \omega_m \approx 0} \\
& - \mathbf{J} n_p \omega_m \left(L_m \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} u_s^S - R_s \frac{d}{dt} i_s^S \right) \right) + L_m \frac{d}{dt} i_r^S \right).
\end{aligned} \tag{4.19}$$

Analog zum obigen Vorgehen mit Gleichung (4.3) lässt sich entweder ein stationäres Modell unter Annahme einer konstanten Drehzahl oder ein dynamisches Modell herleiten. Die Herleitung des stationären Modells findet sich in Anh. B.1. Zur Weiterführung der Herleitung des dynamischen Modells wird die Statorspannungsgleichung (2.98a) umgeformt, zweimal nach der Zeit differenziert

$$\frac{d}{dt} \Psi_s^S = u_s^S - R_s i_s^S \tag{4.20}$$

$$\frac{d^2}{dt^2} \Psi_s^S = \frac{d}{dt} u_s^S - R_s \frac{d}{dt} i_s^S \tag{4.21}$$

$$\frac{d^3}{dt^3} \Psi_s^S = \frac{d^2}{dt^2} u_s^S - R_s \frac{d^2}{dt^2} i_s^S \tag{4.22}$$

und anschließend in (4.19) substituiert:

$$\begin{aligned}
0 = & R_r \frac{d}{dt} i_r^S + L_m \left(\frac{d^2}{dt^2} i_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) + L_m \frac{d^2}{dt^2} i_r^S \\
& - \mathbf{J} n_p \frac{d}{dt} \omega_m \left(L_m \left(i_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + L_m i_r^S \right) \\
& - \mathbf{J} n_p \omega_m \left(L_m \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) + L_m \frac{d}{dt} i_r^S \right).
\end{aligned} \tag{4.23}$$

Außerdem wird die Statorflussgleichung (2.98c) nach dem Rotorstrom aufgelöst und zweimal nach der Zeit differenziert. Auch hier erfolgt die Substitution von (4.20):

$$i_r^S = \frac{1}{L_m} \left(\Psi_s^S - (L_\sigma + L_m) \left(i_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) \right) \tag{4.24}$$

$$\frac{d}{dt} i_r^S = \frac{1}{L_m} \left(\frac{d}{dt} \Psi_s^S - (L_\sigma + L_m) \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \right) \tag{4.25}$$

$$\frac{d^2}{dt^2} i_r^S = \frac{1}{L_m} \left(\frac{d^2}{dt^2} \Psi_s^S - (L_\sigma + L_m) \left(\frac{d^2}{dt^2} i_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) \right). \tag{4.26}$$

Mit Hilfe der gewonnenen Ausdrücke (4.24), (4.25) und (4.26) lassen sich der Rotorstrom

und seine Ableitungen in (4.23) substituieren:

$$\begin{aligned}
0 = & R_r \frac{1}{L_m} \left(\frac{d}{dt} \Psi_s^S - (L_\sigma + L_m) \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \right) \\
& + L_m \left(\frac{d^2}{dt^2} i_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) \\
& + \left(\frac{d^2}{dt^2} \Psi_s^S - (L_\sigma + L_m) \left(\frac{d^2}{dt^2} i_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) \right) \\
& - \mathbf{J}n_p \frac{d}{dt} \omega_m \left(L_m \left(i_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + \Psi_s^S - (L_\sigma + L_m) \left(i_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) \right) \\
& - \mathbf{J}n_p \omega_m \left(L_m \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) + \frac{d}{dt} \Psi_s^S - (L_\sigma + L_m) \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \right).
\end{aligned} \tag{4.27}$$

Durch diverse Umformungen und Vereinfachung durch (4.20) ergibt sich das vollständige dynamische Modell zu:

$$\begin{aligned}
\mathbf{y} = & \frac{d^2}{dt^2} - \mathbf{J}n_p \left(\omega_m \frac{d}{dt} \Psi_s^S + \frac{d}{dt} \omega_m \Psi_s^S \right) \\
\Phi = & \left[\begin{array}{c} -u_s^S \\ i_s^S \\ \frac{d}{dt} i_s^S \\ \frac{d^2}{dt^2} i_s^S - \mathbf{J}n_p \left(\omega_m \frac{d}{dt} i_s^S + \frac{d}{dt} \omega_m i_s^S \right) \\ -\frac{d^3}{dt^3} \Psi_s^S + \mathbf{J}n_p \left(\omega_m \frac{d^2}{dt^2} \Psi_s^S + \frac{d}{dt} \omega_m \frac{d}{dt} \Psi_s^S \right) \\ \frac{d^2}{dt^2} \Psi_s^S \end{array} \right]^T \\
\hat{\theta} = & \left[\begin{array}{cccccc} \frac{R_r}{L_m} & \frac{R_r}{L_m} R_s & \frac{R_r}{L_m} L_s & L_\sigma & \frac{L_\sigma}{R_{fe}} & \frac{R_r}{L_m R_{fe}} L_s \end{array} \right]^T.
\end{aligned} \tag{4.28}$$

Trotz der vergleichsweise komplexen Modellstruktur ist lediglich eine nichtlineare Nebenbedingung $\hat{\theta}_6 = \hat{\theta}_3 \hat{\theta}_5 / \hat{\theta}_4$ enthalten. Eine ausführliche Herleitung findet sich in Anh. B.1. Im Vergleich dazu stehen die in Anh. B.1 dargestellten stationären Modelle mit Eisenverlusten ((B.18), (B.19), (B.20)), die einen deutlich komplexeren Aufbau sowie mehrere nichtlineare Nebenbedingungen aufweisen. Ein Nachteil des dynamischen Modells (4.28) ist das Auftreten der dritten Ableitung des Statorflusses, die sich nur eingeschränkt genau bestimmen lässt. Außerdem ist die Anzahl der zu identifizierenden Modellparameter vergleichsweise hoch. Daher bietet sich auch für das dynamische Modell die Vorgabe definierter Parameter an, wodurch eine deutliche Reduzierung der Komplexität zu erreichen ist.

Dynamische Modelle mit Vorgabe definierter Parameter

Grundsätzlich kann die Vorgabe jedes Parameters in (4.15) bzw. (4.28) erfolgen. In der Praxis erweist sich die Vorgabe des Eisenverlustwiderstands und des Statorwiderstands aus Gründen der Sensitivität und Modellkomplexität als sinnvoll, weswegen nachfolgend die zugehörigen Modelle abgeleitet werden.

Vorgabe des Eisenverlustwiderstands: Aufgrund der betrieblichen Anforderungen und der Nutzung spezieller Maschinenstrukturen ist die Untersuchung des Einflusses der Eisenverluste auf die OPI in dieser Arbeit obligatorisch. Jedoch ist die Online-Identifikation von R_{fe} von untergeordneter Bedeutung, da die vereinfachte Approximation im ESB Abb. 2.4 nur spärliche Annahmen zur Diagnose zulässt. Des Weiteren ist die Sensitivität von R_{fe} gegenüber dem Modell vergleichsweise gering, was die OPI zusätzlich erschwert. Daher bietet sich die Berücksichtigung der Eisenverluste basierend auf einer Vorsteuerung des vordefinierten Parameterwertes nach (2.104) an. Durch algebraische Umformung des vollständigen Identifikationsmodells (4.28), siehe Anh. B.1, ergibt sich die reduzierte Modellstruktur wie folgt:

$$\begin{aligned}
 \mathbf{y} &= \frac{d^2}{dt^2} - \mathbf{J}n_p \left(\omega_m \frac{d}{dt} \Psi_s^S + \frac{d}{dt} \omega_m \Psi_s^S \right) \\
 \Phi &= \begin{bmatrix} -u_s^S \\ \frac{d}{dt} i_s^S + \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \\ \frac{d^2}{dt^2} i_s^S - \mathbf{J}n_p \left(\omega_m \frac{d}{dt} i_s^S + \frac{d}{dt} \omega_m i_s^S \right) - \frac{1}{R_{fe}} \left(\frac{d^3}{dt^3} \Psi_s^S - \mathbf{J}n_p \left(\omega_m \frac{d^2}{dt^2} \Psi_s^S + \frac{d}{dt} \omega_m \frac{d}{dt} \Psi_s^S \right) \right) \\ i_s^S \end{bmatrix}^T \\
 \hat{\theta} &= \begin{bmatrix} R_r & R_r & L_s & L_\sigma \\ L_m & L_m & L_s & R_s \end{bmatrix}^T.
 \end{aligned} \tag{4.29}$$

Durch die Vorgabe von R_{fe} entfällt die nichtlineare Nebenbedingung. Dadurch ist keine Vorsteuerung von geschätzten Parameterwerten aus der vorherigen Iteration notwendig, was sich positiv auf das Konvergenzverhalten und die Robustheit auswirkt. Außerdem sinkt die Komplexität des Parametervektors erheblich. Das Auftreten der dritten Ableitung des Statorflusses ist jedoch auch hier nicht zu vermeiden.

Vorgabe des Statorwiderstands: Analog zum stationären Modell ergibt sich auch hier durch die Vorgabe des Statorwiderstands eine signifikante Vereinfachung der Modellstruktur, wie bereits in [49] für das einfache T-ESB gezeigt. Die Beweggründe für die Vorgabe von R_s sind in Abs. 4.2.1 bereits erläutert. Zunächst wird das vereinfachte dynamische Modell ohne Eisenverluste hergeleitet. Ausgehend von (4.2) wird der Rotorstrom direkt durch (4.4) und (4.5) substituiert, ohne die Notwendigkeit einer weiteren Differentiation:

$$\begin{aligned}
\mathbf{y} &= \frac{d}{dt} \Psi_s^S - \mathbf{J} n_p \Psi_s^S \\
\Phi &= \begin{bmatrix} -\Psi_s^S \\ i_s^S \\ \frac{d}{dt} i_s^S - \mathbf{J} n_p \omega_m i_s^S \end{bmatrix}^T \\
\hat{\theta} &= \begin{bmatrix} R_r & R_r & L_m \\ L_m & L_m & L_\sigma \end{bmatrix}^T.
\end{aligned} \tag{4.30}$$

Dadurch tritt die zweite Ableitung im Vergleich zu allen zuvor vorgestellten Modellen ebenfalls nicht auf, wodurch sich die Filterproblematik höherer Ableitungen vollständig vermeiden lässt. Außerdem entfällt die Vorsteuerung des geschätzten Statorwiderstands, wobei dieser nach wie vor für die Parametrisierung des Statorflussmodells notwendig ist.

Vorgabe des Stator- und Eisenverlustwiderstands: Aufgrund der bereits erwähnten Problematik ist eine zusätzliche Vorgabe des Statorwiderstands im dynamischen Modell mit vorgegebenem R_{fe} sinnvoll. Ausgehend von (4.18) wird zunächst (4.20) und (4.21) ersetzt:

$$\begin{aligned}
0 &= R_r i_r^S + L_m \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) + L_m \frac{d}{dt} i_r^S \\
&\quad - \mathbf{J} n_p \omega_m \left(L_m \left(i_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + L_m i_r^S \right).
\end{aligned} \tag{4.31}$$

Durch Einsetzen von (4.24) und (4.25) und anschließende Vereinfachung ergibt sich:

$$\begin{aligned}
0 &= \frac{R_r}{L_m} \Psi_s^S - \frac{R_r}{L_m} (L_m + L_\sigma) \left(i_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) \\
&\quad + \frac{d}{dt} \Psi_s^S - L_\sigma \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \\
&\quad - \mathbf{J} n_p \omega_m \left(\Psi_s^S - L_\sigma \left(i_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) \right).
\end{aligned} \tag{4.32}$$

Aus der erhaltenen Modellgleichung lässt sich direkt ein dynamisches Regressionsmodell mit Vorgabe von R_s ableiten. Durch weitere algebraische Umformung ergibt sich das finale

dynamische Modell mit Vorgabe von R_s und R_{fe} :

$$\begin{aligned}
 \mathbf{y} &= \frac{d}{dt} \Psi_s^S - \mathbf{J} n_p \omega_m \Psi_s^S \\
 \Phi &= \begin{bmatrix} -\Psi_s^S \\ i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \\ \left[\frac{d}{dt} i_s^S - \mathbf{J} n_p \omega_m i_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \Psi_s^S - \mathbf{J} n_p \omega_m \frac{d}{dt} \Psi_s^S \right) \right] \end{bmatrix}^T \\
 \hat{\theta} &= \begin{bmatrix} R_r & R_r & L_s \\ L_m & L_m & L_\sigma \end{bmatrix}^T.
 \end{aligned} \tag{4.33}$$

Im Vergleich zu (4.29) entfällt auch für das dynamische Modell mit Eisenverlusten die dritte Ableitung des Statorflusses. Somit ergibt sich auch hier eine signifikante Reduzierung der Modellkomplexität durch die Vorgabe des Statorwiderstands R_s .

4.3 Konditionierung und Sensitivität des Least Squares Problems

Zur Anwendung von auf LS-Verfahren basierenden Algorithmen zur Parameteridentifikation werden grundsätzlich die in Abs. 2.1.2 beschriebenen statistischen Anforderungen an die gemessenen Ein- und Ausgangssignale gestellt. Daneben besteht die Möglichkeit, die Performanz der Parameteridentifikation anhand weiterer theoretischer Merkmale zu analysieren. Die betriebspunktabhängige Konditionierung des Identifikationsproblems lässt sich anhand der Absolutwerte der genutzten Messsignale bestimmen. Des Weiteren ist der Einfluss der genutzten Modellstruktur durch eine Sensitivitätsanalyse bewertbar. Nachfolgend wird zunächst die Konditionierung in quasi-stationären Betriebspunkten über den standardisierten dynamischen WLTP-Zyklus beschrieben. Anschließend erfolgt eine Analyse zur Parametersensitivität gegenüber den in Abs. 4.2 hergeleiteten Modellen.

4.3.1 Konditionierung des Least Squares Problems

Die Qualität der Parameterschätzung hängt maßgeblich von den Eigenschaften der genutzten Eingangssignale ab. Im Fall des klassischen LS-Verfahrens wird die Konditionierung anhand der Eigenschaften der Regressionmatrix Φ bzw. der Informationsmatrix \mathbf{R} in (2.8) bewertet:

$$\hat{\theta} = \underbrace{(\Phi^T \Phi)}_{\mathbf{R}}^{-1} \Phi^T \mathbf{y}. \tag{4.34}$$

Die Konditionierung des Identifikationsproblems lässt sich nach dem Kriterium der fort dauernden Anregung bewerten. Für eine sichere und konsistente Parameteridentifikation muss das Kriterium an eine fort dauernde Anregung von \mathbf{R} erfüllt sein [30]. Damit eine fort dauernde

de Anregung vorliegt, müssen die Eingangssignale nach [30] gewisse Eigenschaften aufweisen. Grundlegende Voraussetzung ist zunächst die Invertierbarkeit und damit die positive Definitheit der Informationsmatrix $\mathbf{R} = \mathbf{P}^{-1}$. Damit geht die Forderung einher, dass \mathbf{R} in jeder Iteration des Algorithmus vollen Rang aufweist. Diese Forderung ist mit folgender Gleichung beschreibbar [30, S.64]:

$$\rho_1 \mathbf{I} < \sum_{k=i}^{i+N} \Phi^T[k] \Phi[k] < \rho_2 \mathbf{I}, \quad \rho_1, \rho_2 > 0. \quad (4.35)$$

Eine Regressionmatrix der Ordnung n ist demnach fortdauernd angeregt, wenn (4.35) für jedes Summenelement $k = i \dots i + N$ erfüllt ist. Andernfalls weist die Matrix einen Rangabfall auf.

Die Forderung der positiven Definitheit von \mathbf{R} impliziert, dass alle Eigenwerte positiv sein müssen. Jedoch kann auch ein mit den übrigen Eigenwerten verglichen sehr kleiner Eigenwert dazu führen, dass die Bedingung (4.35) nicht erfüllt ist. Die Konditionierung des Identifikationsproblems lässt sich daher mit den Eigenwerten λ_{ev} der Informationsmatrix in Verbindung mit dem Kriterium nach fortdauernder Anregung (4.35) quantifizieren. Dabei wird eine Konditionierungszahl κ eingeführt, die sich durch das Verhältnis des kleinsten und größten Eigenwertes von \mathbf{R} berechnet:

$$\kappa(\mathbf{R}) = \frac{\lambda_{\text{ev,max}}}{\lambda_{\text{ev,min}}}. \quad (4.36)$$

Die Konditionierung verbessert sich demnach mit kleiner werdender Konditionierungszahl κ [51],[109, S.43].

Die Regressorwerte der Regressionsmatrix ergeben sich betriebspunktabhängig durch die zugrundeliegenden Messsignale. Daher ändern sich die Eigenwerte und damit die Konditionierungszahl über den dynamischen Betriebsbereich der elektrischen Maschine. Zusätzlich ergibt sich in Abhängigkeit des verwendeten Identifikationsmodells eine individuelle Struktur der Regressionsmatrix, die wiederum Auswirkungen auf κ hat. Bei Modellen mit Vorgabe einzelner Parameter wirkt sich gegebenenfalls auch die Parameteränderung auf die Konditionierungszahl aus. Zur betriebspunktabhängigen Untersuchung der Konditionierung in einem dynamischen automobilen Betriebsumfeld muss die Konditionierungszahl über einen geeigneten Fahrzyklus ermittelt werden.

Nachfolgend wird eine quasi-stationäre Berechnung der Eigenwerte der Informationsmatrix $\lambda_{\text{ev}}(\mathbf{R}[k])$ während des simulativen Betriebs über den WLTP-Zyklus durchgeführt. Dabei erfolgt die Skalierung des Zyklus auf den Betriebsbereich der elektrischen Maschine, wie im oberen Teil von Abb. 4.2 dargestellt. Die unteren beiden Subplots zeigen die nach (4.36) quasi-stationär berechneten Konditionierungszahlen aller in Abs. 4.2 vorgestellten Identifikationsmodelle.

Im mittleren Teil erfolgt zunächst ein Vergleich des stationären (4.11) (stat) und des dyna-

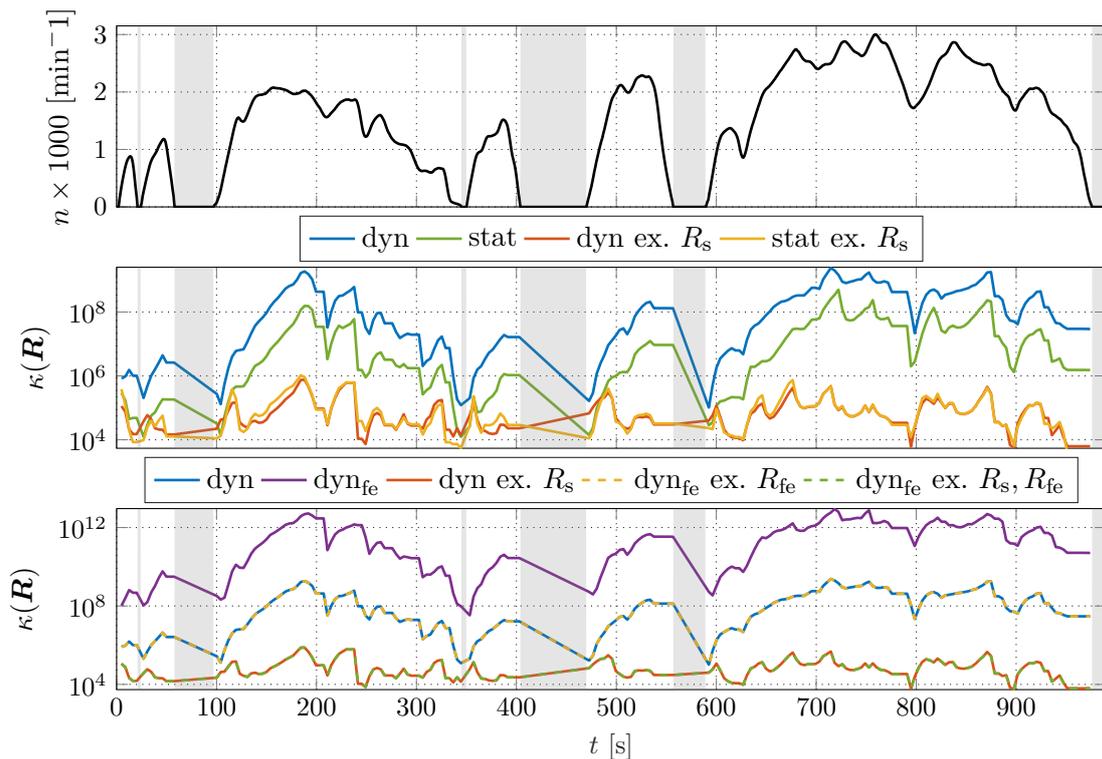


Abbildung 4.2: Betriebspunktabhängige Konditionierungszahl verschiedener Identifikationsmodelle über den WLTP-Zyklus.

mischen Modells (4.15) (dyn) ohne Berücksichtigung der Eisenverluste. Es ist zu erkennen, dass der etwas komplexere Aufbau der Regressionsmatrix des dynamischen Modells im gesamten Betriebsbereich in einer etwas schlechteren Konditionierung resultiert. Die Vorgabe des Statorwiderstands führt sowohl beim dynamischen (dyn ex. R_s) als auch beim stationären Modell (4.13) (stat ex. R_s) exklusive R_s zu einer signifikanten Verbesserung der Konditionierung. Für beide Modelle ergibt sich eine nahezu identische Konditionierungszahl über den gesamten Zyklus.

Im unteren Teil von Abb. 4.2 findet sich ein Vergleich aller dynamischen Modelle aus Abs. 4.2.2. Das vollständige Identifikationsmodell mit Eisenverlusten (dyn_{fe}) ist im Vergleich zu jenem ohne Eisenverluste (dyn) über den gesamten WLTP-Zyklus deutlich schlechter konditioniert. Diese Beobachtung ist durch die nicht unerhebliche Komplexitätssteigerung der Modellstruktur zu begründen. Hingegen ergibt sich durch Vorgabe von R_{fe} in der erweiterten Modellstruktur (dyn_{fe} ex. R_{fe}) eine identische Konditionierungszahl. In diesem Fall hat die teilweise komplexere Struktur der Regressionsmatrix keinen Einfluss auf κ , da sie offensichtlich identische Eigenwerte liefert. Auch im erweiterten Modell mit Eisenverlusten (dyn_{fe} ex. R_s, R_{fe}) führt die zusätzliche Vorgabe des Statorwiderstands zu einer signifikanten Verbesserung der Konditionierung. Jedoch ist κ auch hier im Vergleich zum Modell ohne Eisenverluste (dyn ex. R_s) identisch.

Im Sinne der theoretischen Konditionierung ist kein Nachteil durch die Berücksichtigung der

Eisenverluste ersichtlich. Allgemein führt die Vorgabe von R_s zu einer deutlichen Verbesserung von κ . Diese theoretischen Erkenntnisse erweisen sich im weiteren Verlauf der Arbeit als hilfreich zur Verbesserung der Genauigkeit der OPI. Die grau hinterlegten Bereiche in Abb. 4.2 kennzeichnen Intervalle, in denen sich die Maschine im Stillstand befindet. Allgemein sinkt bei $n_m = 0$ die Konditionierungszahl κ rapide. Diese theoretische Beobachtung ist konträr zu praktischen Erfahrungen, da keine Anregung des Identifikationsproblems erfolgt. Dieses Phänomen wird daher im späteren Verlauf der Arbeit nochmals aufgegriffen.

4.3.2 Sensitivitätsanalyse

Die Art der zu identifizierenden Parameter hat sowohl Auswirkungen auf die Qualität der Schätzergebnisse, als auch das Verhalten des Algorithmus. Zur Analyse des Einflusses der einzelnen Parameter auf den Verlauf der OPI bietet sich eine Sensitivitätsanalyse an. Dabei wird die Sensitivität der Parameter S_{θ_x} gegenüber dem jeweiligen Identifikationsmodell betrachtet. S_{θ_x} beschreibt durch Bildung des Gradienten wie stark die Änderung eines bestimmten Maschinen- oder Modellparameters den Modellausgang beeinflusst:

$$S_{\theta_x} = \frac{\partial y}{\partial \theta_x}. \quad (4.37)$$

Für eine performante Parameteridentifikation sollte die absoluten Sensitivitätswerte aller zu identifizierenden Parameter in der selben Größenordnung liegen.

Die Sensitivität ist sowohl im Zeit- als auch im Frequenzbereich analysierbar. Zweitens erfordert die partielle Ableitung der Übertragungsfunktion im Frequenzbereich, wodurch bei komplexen Modellstrukturen unübersichtliche Ausdrücke entstehen [110], [111], [112]. Vorteilhaft ist jedoch die Vergleichbarkeit der Parametersensitivität in unterschiedlichen Drehzahl- und Drehmomentbetriebspunkten. Außerdem zeigt diese Darstellung in welchen Frequenzbereichen die Parameter am besten zu identifizieren sind. Daraus lassen sich wiederum geeignete Frequenzen für Anregungssignale ableiten. Eine wesentliche Erkenntnis in Bezug auf die Identifikation des Statorwiderstands R_s ergibt sich nach Ribeiro et al. [112]. Demnach ist es nicht möglich R_s unter normalen Betriebsbedingungen zu identifizieren, da die Sensitivität bereits bei kleinen Statorfrequenzen sehr klein wird. Durch einen Gleichanteil im Anregungssignal oder eine überlagerte niederfrequente Komponente ist dieses Problem relativierbar, wie zum Beispiel Altmannshofer et al. in [51] erläutern. Da die Nutzung von zusätzlichen Anregungssignalen im Anwendungsfall dieser Arbeit nicht möglich ist, erfolgt die Sensitivitätsanalyse im Zeitbereich.

Eine anschauliche Möglichkeit die Sensitivität des Identifikationsmodells gegenüber einem Parameter zu untersuchen, besteht in der Nutzung der Fehlerfunktion:

$$J = \frac{1}{2}(y - \Phi\theta)^T(y - \Phi\theta). \quad (4.38)$$

In Abhängigkeit des verwendeten Modells ergibt sich die Definition der Regressionsmatrix Φ und des Modellausgangs y . Φ und y werden mit Messdaten des WLTP-Zyklus befüllt, vgl. Abb. 4.2. Entsprechen alle Parameter in θ den Sollwerten ist der quadratische Fehler nach (4.38) minimal. Im weiteren Verlauf ergibt sich die individuelle Sensitivität durch Verstimmung eines Parameterwertes in $\theta = \Delta\theta_x + \theta'$, während die übrigen Parameter konstant sind. Einen Vergleich der Parametersensitivitäten der unterschiedlichen Modelle aus Abs. 4.2 zeigt Abb. 4.3. Die zu identifizierenden Parameter $\theta_1 \dots \theta_3$ sind in allen Modellen identisch:

$$\theta_1 = \frac{R_r}{L_m}, \quad \theta_2 = \frac{R_r}{L_m} L_s, \quad \theta_3 = L_\sigma.$$

Der vierte Parameter θ_4 beinhaltet den Statorwiderstand und unterscheidet sich je nach Modell wie folgt:

$$\theta_4 = \begin{cases} R_s & \text{wenn, stat} \\ \frac{R_r}{L_m} R_s & \text{wenn, dyn} \vee \text{dyn}_{\text{fe}} \text{ ex. } R_{\text{fe}} \end{cases}.$$

Die Abb. 4.3(a),(b) zeigen die Sensitivität des vollständigen stationären Modells sowie des stationären Modells mit Vorgabe des Statorwiderstands. Die Sensitivität der verschiedenen dynamischen Modelle sind in Abb. 4.3(c)-(f) dargestellt. Auch hier ist das Identifikationsproblem am besten konditioniert, wenn die Sensitivität der einzelnen Parameter die gleiche Größenordnung aufweist. Unterscheidet sich die Sensitivität der einzelnen Parameter stark, ergibt sich unter Einfluss des Messrauschens Δy ein schlechtes Verhältnis zum Anregungssignal (engl. Signal-to-noise ratio (SNR)). Dies resultiert in einer schlechten Identifizierbarkeit der Parameter mit geringer Sensitivität. Da die ersten drei Parameter aller Modelle identisch sind, ändert sich die Sensitivität lediglich durch die im zugehörigen Term auftretenden Größen der Regressionsmatrix. Daher ergeben sich beim Vergleich der Modelle mit identifiziertem Statorwiderstand in Abb. 4.3(a),(c),(e) Sensitivitätswerte in der gleichen Größenordnung. Bei Betrachtung der einzelnen Parameter fällt auf, dass die Streuinduktivität repräsentiert durch $\theta_3 = L_\sigma$ eine vergleichsweise geringe Sensitivität aufweist. Jedoch ist noch eine leichte Krümmung der Kurve zu erkennen. Des Weiteren zeigt insbesondere der jeweils von R_s beeinflusste Parameter θ_4 eine signifikant geringere bis nicht vorhandene Sensitivität gegenüber dem jeweiligen Modell. Daher ist der Einfluss auf das Gütefunktional weniger stark, wodurch die korrekte Bestimmung des Optimums in Richtung dieser Parameter erschwert wird. Der untere Teil in Abb. 4.3 verdeutlicht diese Problematik dreidimensional anhand der Parameter θ_1 und θ_4 des dynamischen Modells (dyn). Durch die geringe Sensitivität in Verbindung mit dem in realen Systemen nicht unerheblichen Messrauschen folgt daraus eine schlechte SNR. Der Fehler des betroffenen Parameters ist damit irrelevant und die Dominanz des Messrauschens resultiert in einem negativen Einfluss auf die Parameteridentifikation. Von großer Bedeutung ist der positive Einfluss der Vorgabe von R_s in den dynamischen Modellen. Dieser ist durch die Betrachtung von Abb. 4.3(d) bzw. Abb. 4.3(f) ersichtlich. Die absoluten

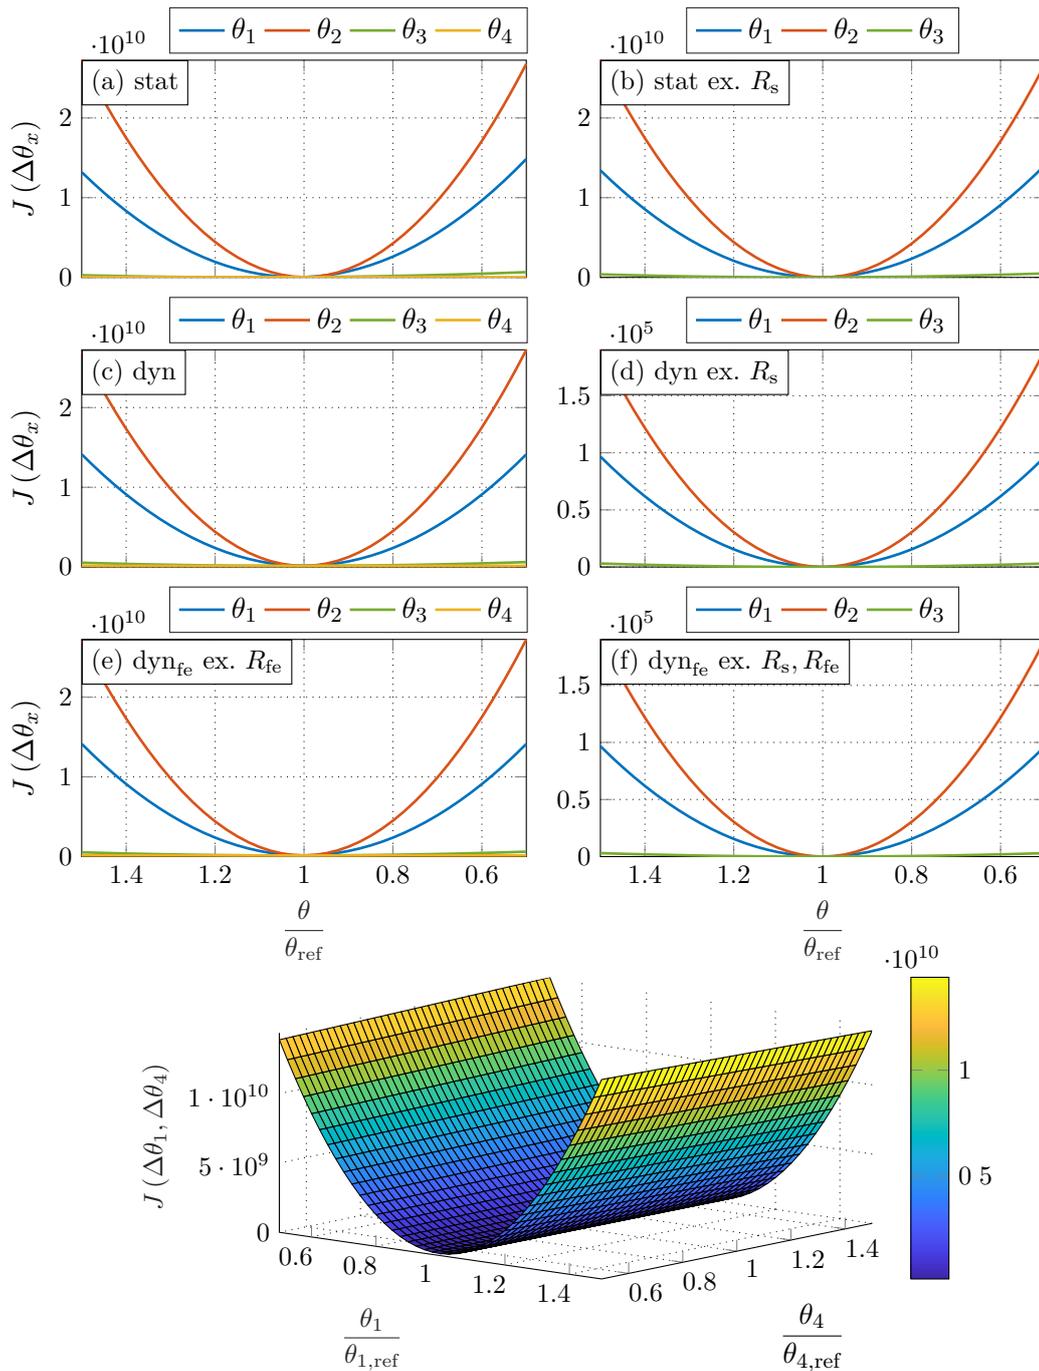


Abbildung 4.3: Sensitivitätsanalyse verschiedener Identifikationsmodelle.

Sensitivitätswerte der Parameter θ_1 und θ_2 sinken um einige Größenordnungen. Dadurch liegen die Sensitivitäten aller Parameter deutlich enger zusammen, was zu einer besseren Konditionierung des Identifikationsproblems führt.

Im Vergleich zur Sensitivitätsanalyse im Frequenzbereich ergibt sich demnach auch im Zeitbereich ein deutlicher theoretischer Vorteil durch die Vorgabe des Statorwiderstands. Im Vergleich mit dem stationären bietet das dynamische Modell nach der theoretischen Analyse

die besten Voraussetzungen für eine erfolgreiche OPI im betrachteten dynamischen Betriebsumfeld.

4.4 Implementierung und Analyse

Neben der Herleitung der Modelle ist die Implementierung des gesamten Identifikationssystems eine wesentliche Herausforderung. Dabei ist die Echtzeitfähigkeit zum Einsatz in eingebetteten Systemen mit streng limitierter Rechenkapazität eine zentrale Anforderung in der vorliegenden Arbeit. Die Struktur des implementierten Gesamtalgorithmus ist in Abb. 4.6 dargestellt. Für den Fall des RLS-Algorithmus fällt der Hauptanteil der Rechenleistung nicht für die Parameteridentifikation selbst an, sondern für die zwingend notwendige digitale Filterung und Differentiation der Eingangssignale durch das SG-Filter. Ferner ist zur erfolgreichen Identifikation eine Synchronisation der Filterlogik und des RLS-Algorithmus erforderlich. Diese wird in Verbindung mit einer taktgesteuerten Aktivierungslogik für den Identifikationsalgorithmus implementiert. Die Entwicklung der Echtzeitsoftware der Algorithmen erfolgt mit Hilfe der in Kap. 3 beschriebenen Test- und Entwicklungsumgebung.

In Bezug auf die eigentliche OPI stellt sich die Frage, welche Kombination aus Konfiguration des RLS-Algorithmus und Wahl des Identifikationsmodells die besten Ergebnisse in einem automotiven Umfeld liefert. Allgemein hängt die erfolgreiche OPI von folgenden wesentlichen Faktoren ab:

- Betrachtetes System und entsprechendes Identifikationsmodell
- Methode zur Filterung der Eingangssignale und deren Konfiguration
- Konfiguration des RLS-Algorithmus
- Initialisierung der Schätzwerte und Einstellung der Hyperparameter bzw. Vergessensfaktoren
- Betriebsumfeld und darauf abgestimmte Aktivierungslogik

Abbildung 4.4 fasst die Einflussfaktoren auf die OPI mittels RLS-Algorithmus illustrativ zusammen.

Nachfolgend wird zunächst die Umsetzung des SG-Filters und die Implementierung des RLS-Algorithmus anhand der zuvor genannten Kriterien beschrieben. Anschließend erfolgen simulative und experimentelle Untersuchungen zur Bewertung verschiedener Kombinationen aus Identifikationsmodell und RLS-Algorithmus. Das Konvergenzverhalten wird dabei anhand vereinfachter Rampenprofile analysiert. Die Analyse der Performanz in einem dynamischen automotiven Umfeld erfolgt beispielhaft anhand des WLTP-Zyklus als ein standardisierter Testzyklus für Elektrofahrzeuge.

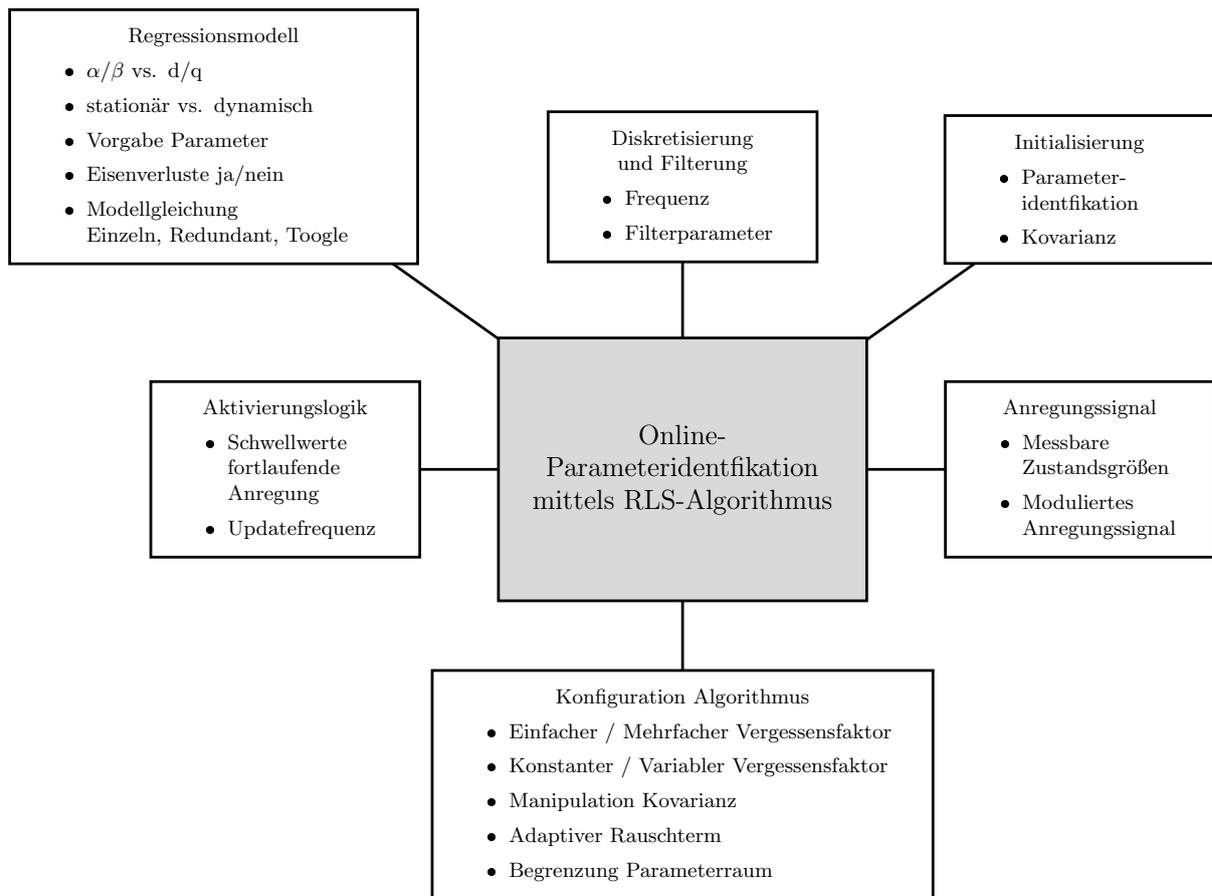


Abbildung 4.4: Einflussfaktoren auf die OPI mittels RLS-Algorithmus.

4.4.1 Implementierung und Konfiguration des Savitzky-Golay-Filters

In Bezug auf die Anwendung in dieser Arbeit stellt sich das SG-Filter als vorteilhafteres FIR-Filter im Vergleich zum BF-Filter heraus. Grund hierfür ist die Nutzung der kosinusförmigen Modulationsfunktion des BF-Filters, deren Implementierung komplexer und rechenintensiver auf eingebetteten Systemen ist. Ein genereller Vorteil bei der Implementierung von FIR-Filtern in Bezug auf die OPI ist die Möglichkeit einer verschachtelten Filterlogik, wie in [48] gezeigt. Der Rechenaufwand und gleichzeitig die fortlaufende Anregung des Identifizierungsproblems sind durch den diskontinuierlichen Betrieb des Filters steuerbar. Dazu wird lediglich eine reduzierte Anzahl von Werten \hat{y} in einem Fenster k_f berechnet, wodurch die mehrfache Nutzung gleicher Messwerte begrenzt ist. Die tatsächliche bestimmte Anzahl der gefilterten Werte ist dabei individuell für jedes Problem festzulegen.

Zur Vermeidung von unnötigem Rechenaufwand und zur Reduzierung des benötigten Speicherplatzes wird in dieser Arbeit nur ein Ausgangswert \hat{y} je Fensterbreite k_f berechnet, wie Abb. 4.5 verdeutlicht. Anstatt einer kontinuierlichen Filterung in jedem Abtastschritt i_{sg}

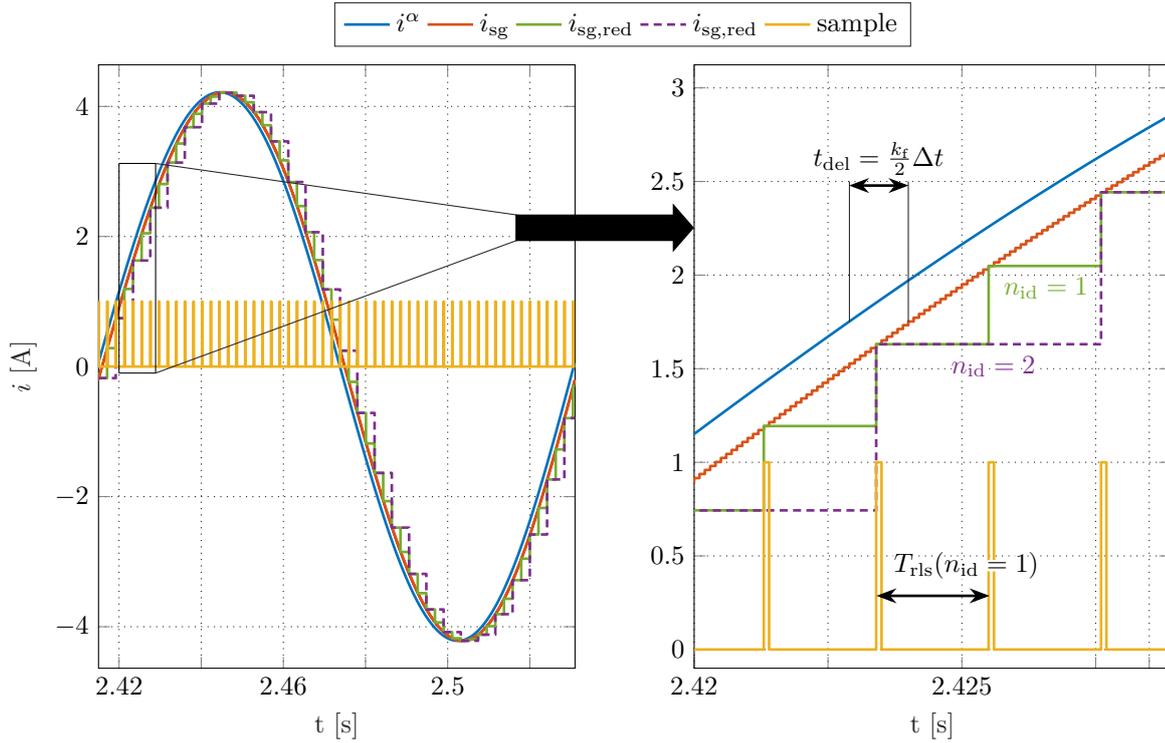


Abbildung 4.5: Kontinuierliche vs. diskontinuierliche Implementierung des Savitzky-Golay-Filters.

wird jeder gemessene Wert des Eingangssignals nur einmal genutzt $i_{\text{sg,red}}$ und die fortlaufende Anregung verbessert. Folglich sind auch die Eingangsdaten eines Glättungsfensters nur für eine Iteration des Algorithmus nutzbar. Die maximale Updatefrequenz des RLS-Algorithmus f_{rls} ergibt sich daher durch die Wahl von k_f nach (2.91), wie Abb. 4.5 anhand der Periodenzeit T_{rls} verdeutlicht. Unabhängig von der Wahl der Fensterbreite ist es möglich, die Updatefrequenz f_{rls} zu reduzieren, indem nur jedes n_{id} -te Ausgangssignal des Filters zur Identifikation genutzt wird. Zur Veranschaulichung zeigt Abb. 4.5 beispielhaft die gefilterten Stromsignale $i_{\text{sg,red}}$ für $n_{\text{id}} = 1$ und $n_{\text{id}} = 2$. Die Berechnungsvorschrift für die Updatefrequenz des RLS-Algorithmus ergibt sich daher wie folgt:

$$f_{\text{rls}} = \frac{1}{T_{\text{rls}}} = \frac{1}{k_f \cdot n_{\text{id}} \cdot \Delta t}, \quad (4.39)$$

wobei $n_{\text{id}} \in \mathbb{N}^*$ gilt. Durch entsprechendes Softwaredesign zur Abstufung der Filterung lässt sich eine signifikante Reduzierung der benötigten Rechenleistung realisieren. Durch Testimplementierungen auf realen Fahrzeugsteuergeräten an Hardware-in-the-loop (HIL) Prüfständen bestätigte sich die Notwendigkeit dieser Maßnahme. Bei gleichzeitiger Filterung aller im System auftretenden Zustandsgrößen ist eine kontinuierliche Ausführung nur unter Einschränkung anderer regelungstechnischer Funktionen möglich.

Die Wahl der Ordnung der Polynomfunktion p_f ergibt sich durch Betrachtung der sinusförmigen Eingangssignale. Zur Abbildung einer sinusförmigen Periode mit zwei Extremwerten

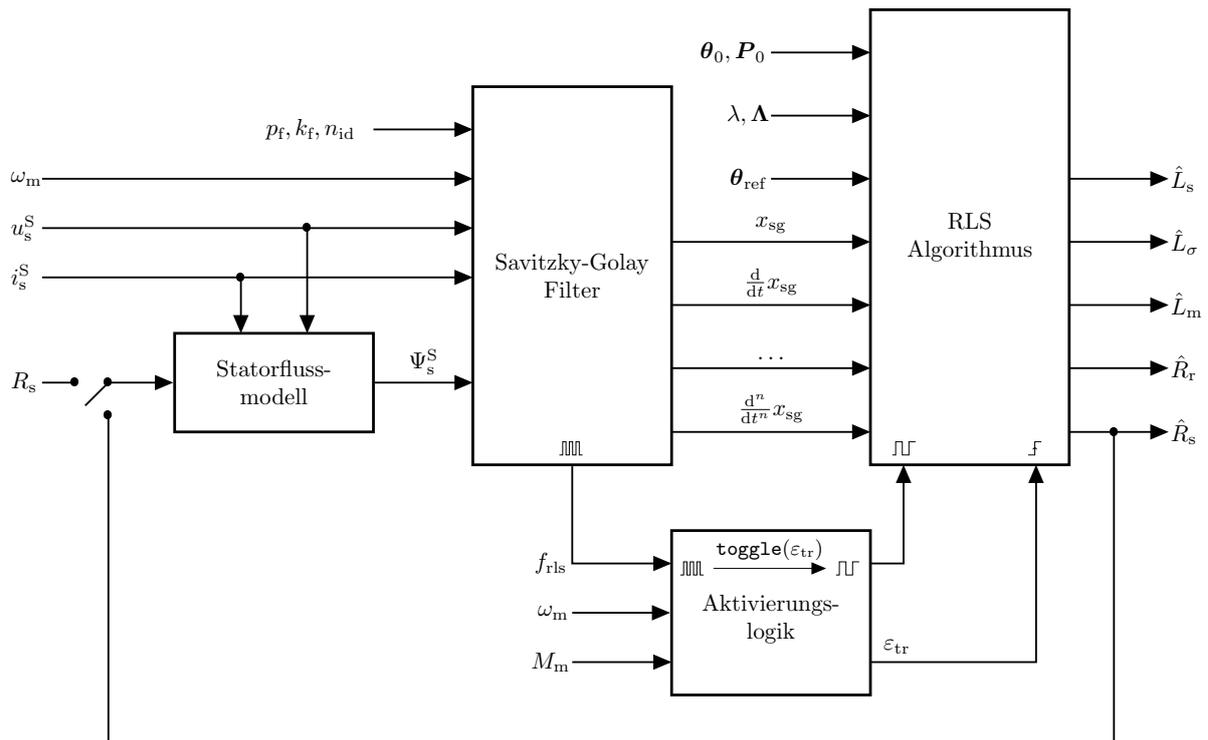


Abbildung 4.6: Übersicht zum Aufbau des vollständigen RLS-Algorithmus.

durch ein Polynom ist die minimal mögliche Ordnungszahl $p_f = 4$. Durch zahlreiche experimentelle Voruntersuchungen wurde diese Ordnungszahl als am besten für die Problemstellung dieser Arbeit geeignet identifiziert. Damit eine ausreichend genaue Glättung im gesamten Drehzahlstellbereich sichergestellt ist, muss durch die Wahl der Fensterbreite k_f bei maximaler Drehzahl die Abdeckung von mindestens einer Halbperiode des sinusförmigen Signals gewährleistet sein.

4.4.2 Implementierung und Konfiguration des RLS-Algorithmus

Die echtzeitfähige Implementierbarkeit der verschiedenen RLS-Algorithmen aus Abs. 2.1.3 und 2.1.4 ist rein durch die mathematische Struktur gegeben. Die Herausforderung besteht daher in der Umsetzung der Interaktion des eigentlichen Identifikationsalgorithmus mit den in Verbindung stehenden Komponenten in Abb. 4.6.

An den Eingängen des SG-Filters liegen die gemessenen Eingangssignale im Zeitraster der Taktfrequenz vor. Wie in Abs. 4.4.1 beschrieben, ergibt sich die maximal mögliche Updatefrequenz des RLS-Algorithmus f_{rls} nach (4.39) in Abhängigkeit der Abtastzeit, der Fensterbreite des SG-Filters sowie der Downsamplingrate. Ein mit f_{rls} pulsierendes Rechtecksignal dient als Grundlage für eine mit dem SG-Filter synchronisierte Aktivierungslogik. Zur Generierung des finalen Triggersignals ε_{tr} für den Identifikationsalgorithmus erfolgt eine logische

Verknüpfung an Betriebspunktabhängige Bedingungen:

$$\varepsilon'_{\text{tr}} = \begin{cases} 1 & \text{wenn } \omega_m > \omega_{\min} \wedge M_m(i_d, i_q) > M_{\min} \\ 0 & \text{sonst} \end{cases} \quad (4.40)$$

$$\varepsilon_{\text{tr}} = f_{\text{rls}} \wedge \varepsilon'_{\text{tr}}. \quad (4.41)$$

Dadurch lassen sich invalide Schätzergebnisse und divergentes Verhalten in Betriebspunkten mit nicht gegebener oder schwacher Anregung vermeiden. Als Kriterien dienen Grenzwerte für die Drehzahl ω_{\min} sowie für das Drehmoment M_{\min} repräsentativ für die Stromanregung. Für eine identifizierte Maschine bietet sich zusätzlich die Festlegung von individuellen Konfidenzintervallen durch die Aktivierungslogik an:

$$\varepsilon'_{\text{tr}} = \begin{cases} 1 & \text{wenn } \omega_{\min,1} < \omega_m < \omega_{\max,1} \wedge M_{\min,1} < M_m < M_{\max,1} \\ 1 & \text{wenn } \omega_{\min,2} < \omega_m < \omega_{\max,2} \wedge M_{\min,2} < M_m < M_{\max,2} \\ 1 & \text{wenn } \dots \\ 0 & \text{sonst} \end{cases} \quad (4.42)$$

Eine universelle Festlegung von Konfidenzintervallen ist nicht möglich, weswegen die zugehörigen Grenzwerte in Abhängigkeit der zu identifizierten ASM und des genutzten Identifikationsalgorithmus zu applizieren sind.

Wie in Abs. 4.2 ersichtlich, besteht jedes Identifikationsmodell aus einem α - und β -Modell. Diese beiden Modelle sind separat oder redundant nutzbar, da sie den gleichen Parametervektor nutzen. Unter Umständen wirkt sich der Toggle-Betrieb beider Modelle positiv auf das Konvergenzverhalten des Algorithmus aus, wie [49] zeigt. Durch diverse Voruntersuchungen hat sich der Toggle-Betrieb auch für diese Arbeit als vorteilhaft erwiesen, da er die Anregung zusätzlich verbessert. Mit Hilfe einer Toggle-Logik wird daher basierend auf ε_{tr} in jeder Iteration des RLS-Algorithmus zwischen α - und β -Modell gewechselt.

Die Initialisierung des Parametervektors $\boldsymbol{\theta}_0$ und der Kovarianzmatrix \mathbf{P}_0 , sowie die Einstellung der Vergessensfaktoren λ bzw. Λ erfolgt nur zu Beginn eines Identifikationslaufs. Auch hier ist keine universelle Festlegung möglich, weswegen die gewählten Werte individuell für jede Versuchsreihe heuristisch einzustellen sind. Zu den nachfolgend analysierten Versuchsreihen befindet sich in jeder Abbildungsunterschrift ein Verweis auf die jeweilige im Anhang aufgeführte Konfiguration.

Wie in Kap. 3 bereits erwähnt, werden die Referenzwerte der Schätzparameter $\boldsymbol{\theta}_{\text{ref}}$ betriebspunktabhängig adaptiert. Da die vorgegebenen Parameter direkten Einfluss auf das Schätzergebnis haben, erhöht die Adaption die Güte der OPI. Zusätzlich ermöglichen nachgeführte Referenzwerte eine betriebspunktunabhängige Vergleichbarkeit der Ergebnisse.

4.4.3 Simulative Analyse

Um die Performanz verschiedener Kombinationen aus Identifikationsmodellen und Erweiterungen des RLS-Algorithmus zu untersuchen, bietet sich vor experimentellen Versuchen eine ausführliche simulative Analyse an. Dabei hat der Ansatz der modellbasierten Softwareentwicklung entscheidende Vorteile, da die Entwicklung und Implementierung direkt in der Simulationsumgebung erfolgt. Die Erstellung der Echtzeitsoftware übernimmt ein optimierter Compiler. Dadurch lassen sich Implementierungsfehler und echtzeitkritische Pfade bereits simulativ diagnostizieren und somit für experimentelle Versuche nahezu ausschließen. Durch die Nutzung des in Abs. 3.2 beschriebenen Maschinenmodells in Verbindung mit dynamischen Testzyklen erfolgt eine realitätsnahe analytische Modellierung des zu identifizierenden Systems. Aufgrund des statistischen Einflusses auf die OPI, berücksichtigt das genutzte Simulationsmodell die Rauscheigenschaften der Strom- und Drehzahlsensorik. Nachfolgend werden verschiedene simulative Analysen durchgeführt, mit dem Ziel, die beste Konfiguration für die Anwendung im realen System zu finden. Der erste Schritt ist eine Analyse der grundsätzlichen Funktion verschiedener Modelle und Algorithmen anhand vereinfachter Testprofile. Im Anschluss wird die Performanz der unterschiedlichen Konfigurationen in einem dynamischen Umfeld entlang des WLTP-Zyklus bewertet.

Modellvergleich mit vereinfachten Testprofilen

Zunächst erfolgen grundlegende Untersuchungen stationärer und dynamischer Modelle zur OPI in dynamischen Betriebspunkten. Dabei wird die Eignung verschiedener Konfigurationen anhand eines vereinfachten Testprofils analysiert.

Stationäres vs. Dynamisches Identifikationsmodell: Für den Vergleich des stationären und dynamischen Modells ohne Berücksichtigung der Eisenverluste wird das in der oberen Zeile von Abb. 4.7 dargestellte Testprofil verwendet. Im ersten Intervall dreht sich die Maschine mit einer konstanten Drehzahl n . In dieser Phase erfolgt der Betrieb in verschiedenen Lastpunkten durch die Änderung der Ströme i_d und i_q , wodurch sich verschiedene Sättigungspunkte einstellen. Anschließend wird durch die Drehzahländerung zum Zeitpunkt $t = 3\text{ s}$ eine dynamische Beschleunigung forciert, während der Laststrom konstant bleibt. Um den Einfluss des Spannungsfehlers durch die Verluste im Inverter abzuschätzen, erfolgt, basierend auf Erfahrungswerten, eine pauschale Verstimmung der Spannungsmesswerte um $\Delta u = u_s \cdot 2\%$. Entlang dieses speziellen Testzyklus lassen sich Probleme bei der OPI bezüglich dynamischer Betriebspunkte in Verbindung mit unterschiedlichen Modellen illustrieren. Wie in der Beobachtbarkeits- und Sensitivitätsanalyse in Abs. 4.3 bereits theoretisch angedeutet, kommt es gerade in dynamischen Betriebspunkten zu Problemen mit der Identifikation von R_s . Daher werden neben dem vollständigen stationären (4.11) und dynamischen (4.15) Modell (stat, dyn) zusätzlich die Modelle mit vorgegebenem Statorwiderstand (stat ex. R_s ,

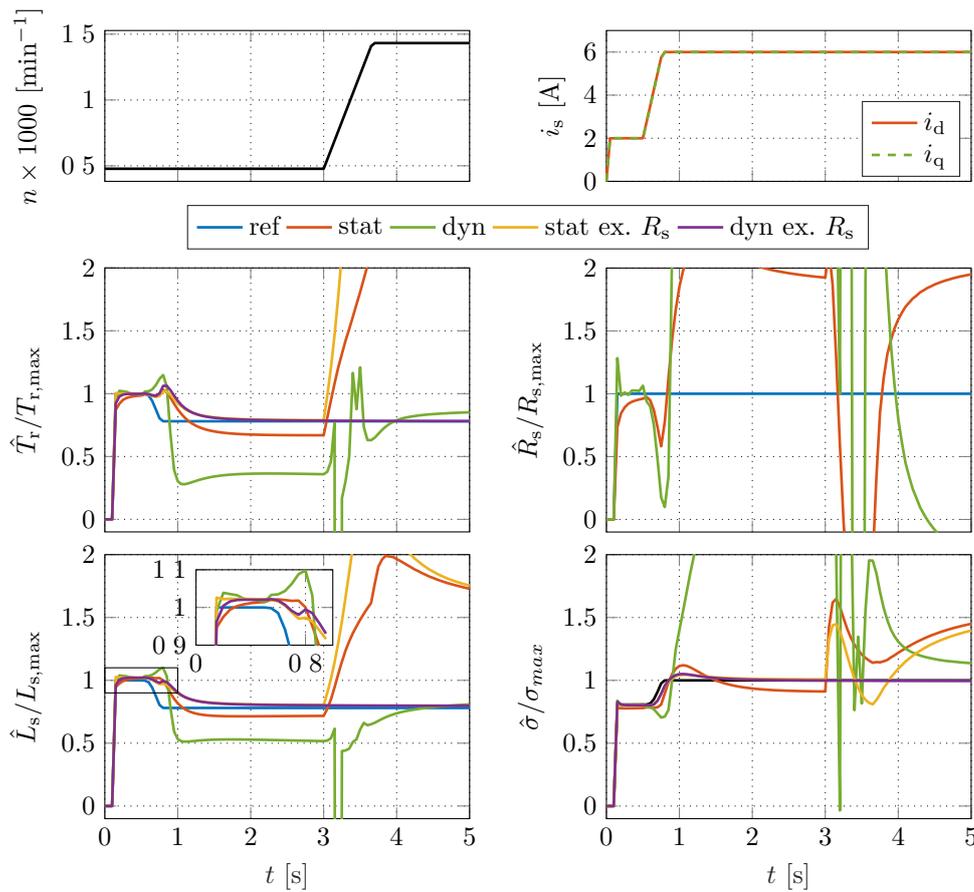


Abbildung 4.7: Simulativer Vergleich des stationären und dynamischen Modells mit und ohne Identifikation des Statorwiderstands R_s . - Konfiguration stat Tab. B.1, dyn Tab. B.3, stat ex. R_s Tab. B.2, dyn ex. R_s Tab. B.4.[17]

dyn ex. R_s) untersucht. Damit dynamische Parameteränderungen identifizierbar sind, ist ein RLS-Algorithmus mit Vergessensfaktor zwingend erforderlich. Um eine Vermischung verschiedener Problemstellungen zu vermeiden, erfolgt die OPI in dieser Darstellung zunächst mit dem RLS-Algorithmus 2.2 mit einfachem Vergessensfaktor. Bei funktionierenden Konfigurationen sind in der Simulation generell biasfreie Schätzergebnisse zu erwarten.

Die identifizierten Parameter sind zusammen mit dem Testprofil in den unteren Spalten von Abb. 4.7 dargestellt. Zur Analyse des Konvergenzverhaltens wird der Parametervektor mit $\hat{\theta} = 0$ initialisiert. Da die Anregung erst mit dem ersten Lastsprung beginnt, startet die Identifikation ab dem Zeitpunkt $t = 0,1$ s. Die Rotorzeitkonstante \hat{T}_r , die Statorinduktivität \hat{L}_s und der Streukoeffizient $\hat{\sigma}$ zeigen in jedem Fall eine schnelle Konvergenz. Trotz kleiner Unterschiede werden die jeweiligen Referenzwerte erreicht. Der Statorwiderstand \hat{R}_s konvergiert bei Nutzung des stationären Modells jedoch nur vergleichsweise langsam und oszilliert im Fall des dynamischen Modells leicht. Ein Blick auf den vergrößerten Ausschnitt im unteren linken Graphen zeigt den Einfluss des Spannungsfehlers Δu auf das Schätzergebnis des Parameters \hat{L}_s . Durch die pauschale Betrachtung ergibt sich bereits ein signifikanter Einfluss

auf den jeweils identifizierten Absolutwert \hat{L}_s . Daher sind erweiterte Untersuchungen über die Auswirkungen des nichtlinearen Spannungsfehlers des Inverters im realen System erforderlich. Diese werden in Abs. 4.4.4 durchgeführt.

Zum Zeitpunkt $t = 0,5\text{s}$ ändert sich durch einen dynamischen Lastpunktwechsel der magnetische Sättigungszustand und somit die induktiven Parameter der Maschine. Durch die auftretende Dynamik ergeben sich erstmals signifikante Unterschiede in der Performanz der unterschiedlichen Modelle. Ein Vergleich der Modelle zeigt, dass die fehlerhafte Identifikation von \hat{R}_s die übrigen Parameter erheblich beeinflusst. Obwohl die Modelle stat und dyn robust konvergieren, ergibt sich ein deutlich biasbehaftetes Schätzergebnis und der Referenzwert wird deutlich verfehlt. In diesem Bereich schneidet das dynamische Modell deutlich schlechter als das stationäre ab, was sich durch die zusätzliche Interaktion mit dem Statorflussmodell erklären lässt. Die Ergebnisse der beiden Modelle ohne Identifikation von R_s konvergieren dagegen zu den Referenzwerten.

Zum Zeitpunkt $t = 3\text{s}$ beschleunigt die Maschine und die Drehzahl ändert sich. Beide stationären Modelle sowie das vollständige dynamische Modell zeigen instantan drastische Änderungen der Schätzergebnisse. Nach Erreichen der veränderten stationären Drehzahl konvergieren die stationären Modelle langsam und zu deutlich biasbehafteten Endwerten. Die Parameter des dyn-Modells, mit Ausnahme von \hat{R}_s , konvergieren nach Verlassen des dynamischen Drehzahlbereichs zu robusten aber deutlich biasbehafteten und daher nicht überzeugenden Werten. Das dynamische Modell mit Vorgabe von \hat{R}_s zeigt als einziges Modell ausnahmslos robustes Verhalten gegenüber Drehzahl- und Lastpunktänderungen.

Trotz der geringen Sensitivität des Parameters selbst, hat der Fehler des Statorwiderstands offenbar einen signifikanten Einfluss auf die erfolgreiche Parameteridentifikation. Allgemein führt die Vorgabe von R_s und die damit verbundene Vermeidung der zweiten Stromableitung im Regressionsmodell zu einer deutlichen Steigerung der Robustheit. Zusammenfassend ergibt sich, dass die Wahl des Identifikationsmodells die Ergebnisse erheblich beeinflusst. Das dynamische Modell ohne \hat{R}_s liefert die besten Ergebnisse in Bezug auf das verwendete Testprofil und die Struktur des Algorithmus.

Berücksichtigung der Eisenverluste im Identifikationsmodell: Aufgrund des großen Drehzahlstellbereich im automotiven Betriebsumfeld stellt sich die Frage, ob das dynamische Verhalten der frequenzabhängigen Eisenverluste einen Einfluss auf die OPI hat. Wie in Abs. 4.2.2 bereits erwähnt, ist die Online-Identifikation des Eisenverlustwiderstands von untergeordneter Bedeutung für die Diagnose. Daher wird bei den hier durchgeführten Untersuchungen lediglich die Vorgabe von R_{fe} im Modell berücksichtigt. Zur grundlegenden simulativen Analyse dieser These bietet sich ein vereinfachtes Testprofil mit einer großen Drehzahländerung an, wie oben links in Abb. 4.8 dargestellt. Nach (2.104) ergibt sich damit eine proportionale Änderung des Eisenverlustwiderstands R_{fe} in Abhängigkeit der Statorfrequenz $\omega_s \sim n$, wie Abb. 4.8 zeigt. Der Lastpunkt der Maschine bleibt in diesem Simulationslauf

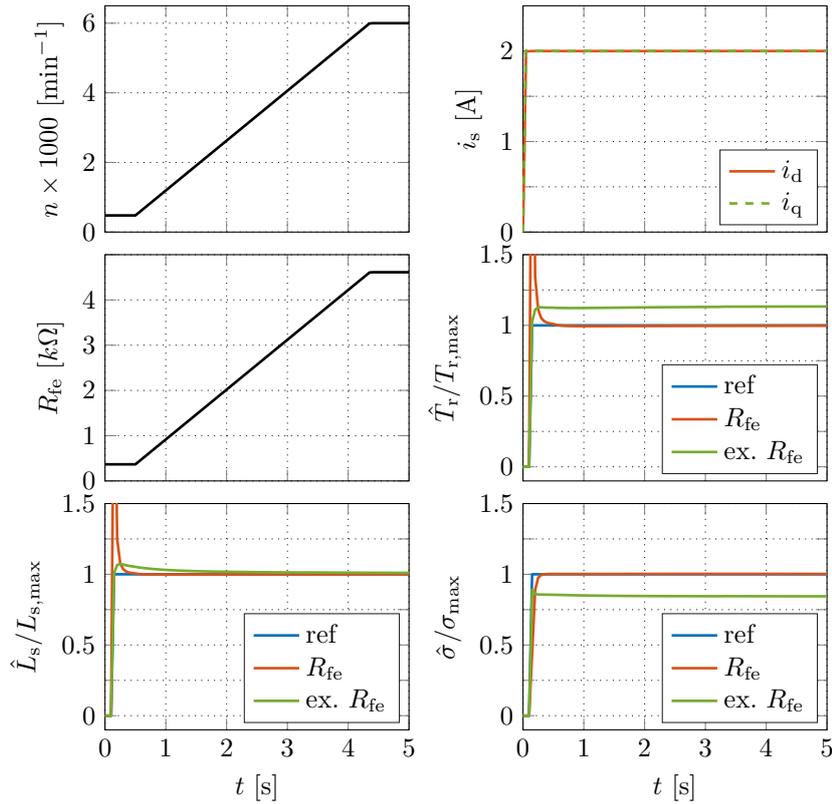


Abbildung 4.8: Simulative Analyse des Einflusses der Eisenverluste auf die OPI unter Nutzung des dynamischen Modells ohne Identifikation des Statorwiderstands R_s . - Konfiguration Tab. B.5.[17]

durch konstante Vorgabe der Ströme i_d und i_q gleich, um eine Vermischung unterschiedlicher Effekte zu vermeiden. Bezugnehmend auf die Erkenntnisse der Simulation des vorherigen Abschnitts wird für diese Untersuchung das dynamische Identifikationsmodell mit Vorgabe von R_s verwendet. Es folgt daher ein Vergleich des Identifikationsmodells (4.15) ohne und (4.33) mit Berücksichtigung der Eisenverluste.

Die Ergebnisse der OPI sind im unteren Teil von Abb. 4.8 zusammengetragen. Dabei sind jeweils die identifizierten Parameter \hat{T}_r , \hat{L}_s , $\hat{\sigma}$ des Modells ohne (ex. R_{fe}) und mit Berücksichtigung der Eisenverluste R_{fe} dargestellt. Die Betrachtung der Parameter \hat{T}_r und $\hat{\sigma}$ offenbart einen signifikanten Einfluss von R_{fe} auf das Schätzergebnis. Das Modell ohne Berücksichtigung der Eisenverluste zeigt stark biasbehaftete Schätzergebnisse, die um einen Fehler im Bereich von $e_{\hat{T}_r} \approx e_{\hat{\sigma}} \approx 10 \dots 15\%$ vom Referenzwert abweichen. Lediglich die Schätzung der Statorinduktivität \hat{L}_s liefert für beide Modelle eine biasfreie Schätzung, wobei sich durch Berücksichtigung von R_{fe} die Konvergenzzeit deutlich erhöht.

Die Implementierung des Eisenverlustwiderstands im verwendeten Simulationsmodell der Maschine in [89] ist identisch zum Identifikationsmodell. Daher muss die tatsächliche Auswirkung der Eisenverluste auf die OPI experimentell an realen Maschinen analysiert werden. Die simulativen Untersuchungen stützen jedoch die These, dass die Berücksichtigung von R_{fe} gerade in einem dynamischen Betriebsumfeld mit großem Drehzahlstellbereich nicht

vernachlässigbar ist.

Vergleich erweiterter RLS-Algorithmen mit vereinfachtem Testprofil

Die in Abs. 2.1.4 vorgestellten Erweiterungen des RLS-Algorithmus beeinflussen dessen Fähigkeit, auf dynamische Parameteränderungen zu reagieren. Im vorherigen Abs. 4.4.3 zeigen die durchgeführten Simulationen, dass die Erweiterung um einen einfachen konstanten Vergessensfaktor grundsätzlich eine OPI von dynamischem Parameterverhalten ermöglicht, siehe Abb. 4.7. Jedoch ist die Konvergenzgeschwindigkeit für ein hochdynamisches Betriebsumfeld unter Umständen nicht ausreichend. Daher werden im nächsten Schritt die Auswirkungen der Erweiterungsmöglichkeiten des RLS-Algorithmus aus Abs. 2.1.4 auf die OPI untersucht. Dabei bietet sich an, das aus Abb. 4.7 bekannte Stromprofil zu nutzen, um die Sättigung der Maschineninduktivitäten bei einer konstanten Drehzahl zu erzwingen. Die OPI erfolgt für diesen Vergleich aufgrund des robusten Verhaltens in verschiedenen Betriebspunkten basierend auf dem dynamischen Modell mit Vorgabe von R_s . Für eine übersichtliche Darstellung wird die Identifikation induktiver Parameter lediglich durch das jeweilige Ergebnis der Rotorzeitkonstante \hat{T}_r in der linken Spalte von Abb. 4.9 repräsentiert. Die rechte Spalte illustriert das Verhalten der Kovarianzmatrix bei unterschiedlichen Erweiterungen des RLS-Algorithmus.

Abbildung 4.9(a) zeigt die identifizierte Rotorzeitkonstante des RLS-Algorithmus 2.2 mit einfachem Vergessensfaktor. Die Sättigung der Induktivität zum Zeitpunkt $t = 0,5\text{ s}$ führt zunächst zu einem fehlerhaften Überschwingen von \hat{T}_r . Nach der dynamischen Parameteränderung konvergiert das Ergebnis jedoch schnell und biasfrei zum Referenzwert. Mit dem Wiedereintritt in den stationären Betriebsbereich nimmt die Anregung der OPI zunehmend ab. Dadurch tritt ab $t = 2\text{ s}$ der in Abs. 2.1.4 beschriebene Wind-up-Effekt auf. Durch die anhaltend fehlende Anregung steigt die Spur der Kovarianzmatrix $\text{tr}(\mathbf{P}_\lambda)$ drastisch an, was wiederum zu oszillierendem und langsam divergierendem Verhalten von \hat{T}_r führt. Je nach Dauer der Wind-up Phase erfolgt bei wiederkehrender Anregung eine sehr langsame Konvergenz oder eine vollständige Divergenz.

Ein variabler Vergessensfaktor verhindert das Wind-up der Kovarianzmatrix durch Anpassung von λ in Abhängigkeit von der Spur der Kovarianzmatrix nach (2.47), wie in Abb. 4.9(b) dargestellt. Sobald die Parameteränderung auftritt beginnt die Kovarianz und damit der variable Vergessensfaktor λ proportional zu $\text{tr}(\mathbf{P}_\lambda)$ zu steigen, wodurch sich das im vorherigen Fall auftretende Überschwingen vollständig vermeiden lässt. Jedoch wird der RLS-Algorithmus in einem Freiheitsgrad eingeschränkt. Aufgrund des bereits erfolgten Anstiegs des Vergessensfaktors erhöht sich die Konvergenzzeit im Vergleich deutlich. Dadurch ist die Reaktion auf Parameteränderungen eher träge, was in einem hochdynamischen Umfeld als nachteilig zu bewerten ist. Andererseits ist durch die stufenlose Änderung des Vergessensfaktors ein weicher Übergang zwischen verschiedenen Anregungsphasen gewährleistet, was einen

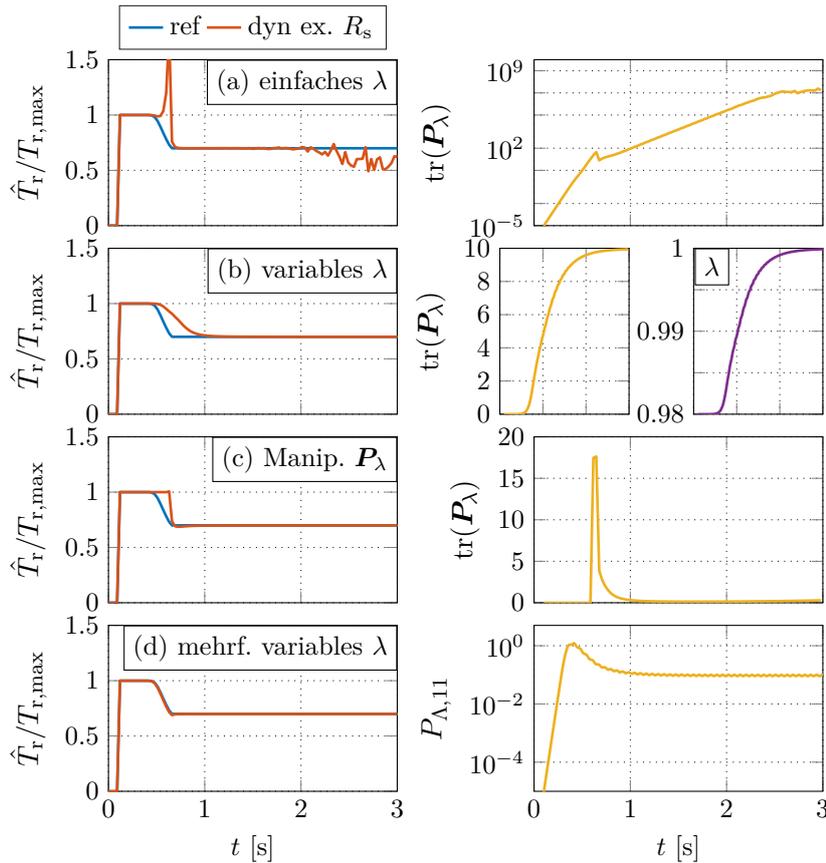


Abbildung 4.9: Simulativer Vergleich der verschiedenen Erweiterungen des RLS-Algorithmus unter Nutzung des dynamischen Modells ohne Identifikation des Statorwiderstands R_s . - Konfiguration (a) einfacher Vergessensfaktor λ Tab. B.6, (b) variabler Vergessensfaktor λ Tab. B.7, (c) Manipulation der Kovarianzmatrix P_λ Tab. B.8, (d) mehrfach variabler Vergessensfaktor Λ Tab. B.9.[17]

positiven Einfluss auf die Stabilität des Algorithmus hat. Aufgrund der fehlenden Anregung nach der Konvergenz steigt der Vergessensfaktor weiter an, bis er schließlich $\lambda = 1$ erreicht. Das Auftreten des Wind-up Effekts wird dadurch vollständig verhindert.

Eine Alternative zur Adaption des Vergessensfaktors bei Nutzung des RLS-Algorithmus 2.2 mit einfachem Vergessensfaktor ist die direkte Manipulation der Kovarianzmatrix nach (2.48), wie in Abb. 4.9(c) dargestellt. Bedingt durch die Parameteränderung erfolgt ein sofortiger Anstieg der Kovarianz und somit der Fehlervarianz $\hat{\sigma}_e^2$. Sobald die Änderung und der Absolutwert von $\hat{\sigma}_e^2$ die in (2.48) festgelegten Schwellwerte ϵ_1 und ϵ_2 überschreiten, erfolgt die Manipulation der Kovarianz mit dem Faktor κ . Diese Korrektur ist vergleichbar mit einem Neustart des Algorithmus, wie anhand des Spurverlaufs $\text{tr}(P_\lambda)$ in Abb. 4.9 deutlich zu erkennen ist. Nach Erreichen der Schwellwerte ist eine sehr schnelle Konvergenz von \hat{T}_r zum Referenzwert zu beobachten. Generell ist diese Methode nur für sehr schnelle Parameteränderungen geeignet. Sie ist jedoch auch mit einem Vergessensfaktor kombinierbar. Die Parametrisierung muss dann so vorgenommen werden, dass in Abhängigkeit der Geschwindigkeit der Parameteränderung die jeweils geeignete Methode greift. Die Einstellung

der Schwell- und Verstärkungswerte muss dabei individuell für verschiedene Konfigurationen und Betriebspunkte erfolgen, wodurch ein hoher Parametrisierungsaufwand entsteht. Die damit verbundene fehlende Generalisierungsfähigkeit und Flexibilität ist nachteilhaft für ein Betriebsumfeld mit stark variierender Dynamik.

Maximale Flexibilität erlaubt die Verwendung von individuellen Vergessensfaktoren für jeden zu identifizierenden Parameter des Modells. Bei der Wahl der Faktoren ist dadurch die Berücksichtigung verschiedener Parametereigenschaften möglich. Stark veränderlichen Parametern wird ein kleiner Vergessensfaktor $\Lambda_i \ll 1$ zugewiesen, während für kaum veränderliche Parameter $\Lambda_i \simeq 1$ festgelegt wird. Die Wahl von Λ muss daher individuell in Abhängigkeit des genutzten Identifikationsmodells erfolgen. Aufgrund des dominanten Sättigungsverhaltens der hier genutzten Maschine, verändern sich die Absolutwerte der Induktivitäten deutlich stärker als die der ohmschen Widerstände. In Bezug auf das in diesem Abschnitt vertiefte Beispiel setzt sich der Parametervektor wie folgt zusammen:

$$\hat{\theta} = \left[\frac{R_r}{L_m} \quad \frac{R_r}{L_m} L_s \quad L_\sigma \right]^T.$$

Darin erfährt der Parameter θ_1 eine starke Änderung aufgrund der Induktivität L_m . Hingegen ist die Auswirkung auf θ_2 eher gering, da sich der Einfluss der Induktivität im Nenner und im Zähler nahezu aufheben. θ_3 wiederum ändert sich proportional zu L_s . Basierend auf dieser Bewertung erfolgt die Wahl der Vergessensfaktoren:

$$\Lambda = [0,95 \quad 1 \quad 0,95].$$

Die Identifikation von \hat{T}_r durch den RLS-Algorithmus 2.3 mit mehrfachem Vergessen ist in Abb. 4.9(d) dargestellt. Der Algorithmus ist in jedem Schritt in der Lage der dynamischen Parameteränderung zu folgen. Lediglich während der Parameteränderung entsteht eine Art Schleppfehler dessen Betrag aber vergleichsweise irrelevant ist. Auch die übrigen Parameter werden biasfrei identifiziert. Die Betrachtung der parameterspezifischen Kovarianz $P_{\Lambda,11}$ zeigt nach einem moderaten Überschwingen aufgrund der Parameteränderung konvergentes Verhalten. Zur Vermeidung des Wind-up Effekts empfiehlt sich eine Implementierung des RLS-Algorithmus 2.3 mit einem mehrfachen variablen Vergessensfaktor.

Die zuvor präsentierten Ergebnisse geben einen Einblick in das grundsätzliche Verhalten der OPI bei Nutzung verschiedener Modelle und Erweiterungen des RLS-Algorithmus durch vereinfachte Testprofile. In weiteren Simulationsläufen wird nun die Performanz der verschiedenen Konfigurationen im dynamischen automotiven Betriebsumfeld fokussiert. Dazu eignet sich der Betrieb der Maschine entlang des WLTP-Zyklus. Da die Modellierung der Eisenverluste in Maschinen- und Regressionsmodell auf gleiche Weise erfolgt sind erweiterte simulative Untersuchungen mit Berücksichtigung von R_{fe} nicht repräsentativ.

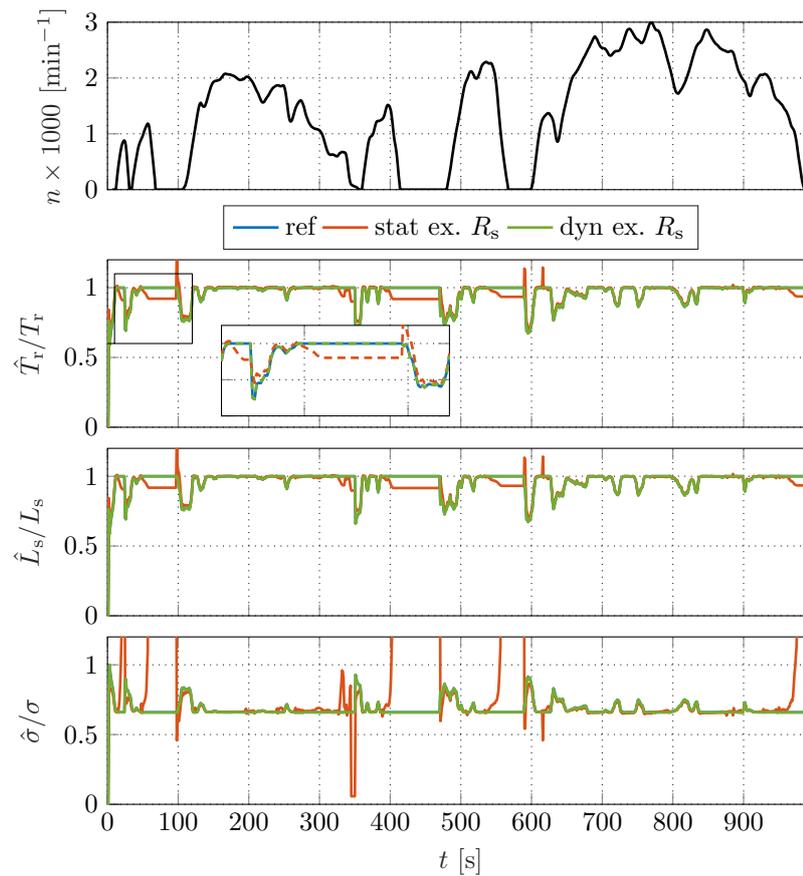


Abbildung 4.10: Simulativer Vergleich des stationären und dynamischen Modells ohne Identifikation des Statorwiderstands R_s unter Nutzung des RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen entlang des WLTP-Zyklus. - Konfiguration stat ex. R_s Tab. B.10, dyn ex. R_s Tab. B.11.[17]

Modellvergleich mit WLTP-Zyklus

Zunächst erfolgt ein Vergleich der verschiedenen Modelle entlang des dynamischen Testzyklus, siehe Abb. 4.10(a). Die Drehmoment- und Drehzahlanforderungen des WLTP-Zyklus werden dazu durch die in Abs. 3 beschriebene Trajektorie auf den zulässigen Betriebsbereich der Maschine skaliert. Da die maximal zulässige Drehzahl des experimentellen Aufbaus $n = 3000 \text{ min}^{-1}$ beträgt, ist die Implementierung der gleichen Grenze in der Simulation aus Gründen der Vergleichbarkeit sinnvoll. Während des Simulationslaufs gilt die Annahme einer konstanten Temperatur, sodass keine Änderung der ohmschen Parameter erfolgt. Aufgrund der zuvor gewonnenen Erkenntnisse, ist die Nutzung des RLS-Algorithmus 2.3 mit mehrfachem Vergessen zum Modellvergleich naheliegend. Generell sei darauf hingewiesen, dass im Stillstand der Maschine keine fortlaufende Anregung besteht und die Identifikation somit durch die Aktivierungslogik (4.40) deaktiviert ist.

Abbildung 4.10(b)-(d) zeigen beispielhaft die Schätzergebnisse basierend auf dem stationären und dynamischen Modell ohne Identifikation des Statorwiderstands. Die Ergebnisse des dynamischen Modells stimmen in nahezu jedem Punkt mit den Referenzwerten überein. Da-

durch bestätigt sich die überzeugende Performanz dieser Konfiguration aus den in Abb. 4.7 präsentierten Untersuchungen. Daneben zeigt das stationäre Modell in weiten Teilen gute Ergebnisse. Jedoch ergeben sich auch hier sichtbare Probleme mit der Identifikation dynamischer Parameteränderungen. Durch Betrachtung des vergrößerten Ausschnitts der Identifikation von \hat{T}_r wird deutlich, dass die Parameterdynamik durch das stationäre Modell nicht überzeugend verfolgbar ist, während das dynamische Modell biasfreie Ergebnisse liefert. Größere Probleme offenbart das stationäre Modell bei der Identifikation des Streukoeffizienten, da es bei starken Parameteränderungen zu hohem Überschwingen des Schätzwertes kommt. Aus Gründen der Übersichtlichkeit sind die Ergebnisse der übrigen Modelle in Abb. 4.7 nicht abgebildet. Stellvertretend eignet sich jedoch der mittlere Fehler als Kenngröße für die Performanz. Tab. 4.1 zeigt zum Vergleich den über den WLTP-Zyklus gemittelten Identifikationsfehler aller Parameter \bar{e}_{T_r} , \bar{e}_{L_s} , \bar{e}_σ , \bar{e}_{R_s} . Darin ist zunächst für jedes Modell und die entsprechenden Parameter der gesamte (ges) mittlere Fehler über den vollständigen Zyklus dargestellt. Aufgrund der ausbleibenden Anregung im Stillstand trägt der Fehler in diesen Phasen nicht zum konstruktiven Vergleich bei. Folglich enthält Tab. 4.1 zusätzlich einen um die Stillstandsphasen korrigierten (kor) mittleren Fehler.

Die Betrachtung der mittleren Fehler der Verläufe aus Abb. 4.10 in Tab. 4.1 bestätigt die zuvor getroffenen Aussagen. Das dynamische Modell ohne Identifikation von R_s liefert vollständig biasfreie Ergebnisse über den gesamten WLTP-Zyklus. Übrig bleiben lediglich unbedeutende Fehler durch numerische Interferenzen. Die gemittelten Fehler des stationären Modells ohne R_s bestätigen die überzeugenden Ergebnisse aus Abb. 4.10. Die Identifikation des Streukoeffizienten zeigt lediglich minimal schlechtere Ergebnisse, wobei die Korrektur des mittleren Identifikationsfehlers in Tab. 4.1 eine Schwäche zur Identifikation in Bereichen mit geringen Drehzahlen offenbart. Allgemein liefern alle Modelle gute Ergebnisse bei der Identifizierung von \hat{T}_r und \hat{L}_s . Jedoch ergeben sich bei Nutzung der vollständigen Modelle auch hier Probleme bei der Identifikation von \hat{R}_s . Aus diesem Grund werden zwei unterschiedliche Möglichkeiten zur Parametrisierung verglichen. Im Fall des stationären Modells erfolgt die Initialisierung von \hat{R}_s mit Hilfe des korrekten Referenzwerts. Der zugehörige Vergessensfaktor wird mit $\Lambda_{R_s} \simeq 1$ sehr groß gewählt, sodass seitens des RLS-Algorithmus keine Anpassung erfolgt. Als Alternative zur dauerhaften Vorgabe von \hat{R}_s führt dies zu robustem Schätzverhalten, wenngleich eine temperaturbedingte Änderung mit dieser Konfiguration nicht identifizierbar ist. Durch Verringern des Vergessensfaktors $\Lambda_{R_s} < 1$ schwindet die Steifigkeit. Dadurch ergibt sich ein instabiles und stark biasbehaftetes Ergebnis, das der hohe mittlere Identifikationsfehler in Tab. 4.1 verdeutlicht. Die simulative Identifikation des Statorwiderstands führt demnach auch entlang des WLTP-Zyklus zu hohen Fehlern. Gleichzeitig beeinflusst die hohe Abweichung von \hat{R}_s die Identifikation des Streukoeffizienten negativ. Während das stationäre Modell gute Ergebnisse für $\hat{\sigma}$ liefert, ergibt sich für das dynamische Modell ein nicht zu vernachlässigender Fehler.

Tabelle 4.1: Simulativer Vergleich des mittleren Identifikationsfehlers \bar{e} verschiedener Modelle unter Nutzung des RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen entlang des WLTP-Zyklus.

Modell	ges/kor	\bar{e}_{T_r} [%]	\bar{e}_{L_s} [%]	\bar{e}_σ [%]	\bar{e}_{R_s} [%]
stationäres Modell	ges	2,64	2,63	22,64	1,22
	kor	1,36	1,33	4,28	1,23
dynamisches Modell	ges	0,72	0,57	42,04	92,73
	kor	0,46	0,24	12,6	74,13
stationäres Modell ex. R_s	ges	2,54	2,45	54,0	-
	kor	1,56	1,38	5,33	-
dynamisches Modell ex. R_s	ges	0,02	0,02	0,10	-
	kor	0,02	0,02	0,08	-

Vergleich erweiterter RLS-Algorithmen mit WLTP-Zyklus

Zur Vervollständigung der simulativen Untersuchungen erfolgt in diesem Abschnitt ein Vergleich der verschiedenen in Abs. 2.1.4 vorgestellten Erweiterungen des RLS-Algorithmus entlang des WLTP-Zyklus. Der Vergleich wird aufgrund der bereits gewonnenen Erkenntnisse basierend auf dem dynamischen Modell ohne Berücksichtigung von R_s durchgeführt. Im Vergleich zur Identifikation mittels RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen in Abb. 4.10 bietet die Darstellung des detaillierten Identifikationsverlaufs der übrigen Erweiterungen keinen illustrativen Mehrwert, weswegen auf den Anhang Anh. B.3 verwiesen wird. Der Vergleich erfolgt auch hier tabellarisch nach dem Schema des vorherigen Abschnitts anhand des Mittelwerts des Identifikationsfehlers, siehe Tab. 4.2.

Der RLS-Algorithmus mit einfachem Vergessensfaktor zeigt die schlechtesten Ergebnisse. In Phasen mit stark dynamischem Parameterverhalten erfolgt keine Konvergenz, was in einem hohen mittleren Fehler aller drei identifizierten Parameter resultiert. Zusätzlich trägt der Wind-up-Effekt bei schwacher Anregung zur Divergenz des Algorithmus bei. Für die absoluten Ergebnisse wird auf den Anhang Abb. B.1 verwiesen.

Mit dem Einsatz eines variablen Vergessensfaktors wird das Wind-up der Kovarianz verhindert, wodurch der Algorithmus in Phasen mit kleinen Parameteränderungen zum jeweiligen Referenzwert konvergiert. Dennoch erfolgt keine zuverlässige Identifikation der dynamischen Parameteränderungen, weswegen die resultierenden Identifikationsfehler nicht überzeugen. Der zugehörige Identifikationsverlauf findet sich in Abb. B.2.

Die Erweiterung durch Manipulation der Kovarianzmatrix erweist sich als ungeeignet für das hier betrachtete Anwendungsgebiet, da die auftretenden Parameteränderungen kontinuierlich und langsam im Vergleich zur abrupt forcierten Änderung der Kovarianzen sind. Daher ist diese Anpassung eher für die Identifikation abrupterer Parameteränderungen geeignet. Zudem müssen die Schwellwerte für bestimmte Parameterdynamiken und Betriebspunkte individuell

Tabelle 4.2: Simulativer Vergleich des mittleren Identifikationsfehlers \bar{e} verschiedener Erweiterungen des RLS-Algorithmus unter Nutzung des dynamischen Modells ohne Identifikation des Statorwiderstands R_s entlang des WLTP-Zyklus.

RLS-Algorithmus	ges/kor	\bar{e}_{T_r} [%]	\bar{e}_{L_s} [%]	\bar{e}_σ [%]
einfaches Vergessen	ges	63,17	27,15	69,69
	kor	70,88	30,40	58,86
variables Vergessen	ges	36,39	15,86	32,35
	kor	43,42	18,92	38,46
Kovarianz Manipulation	ges	45,24	19,69	57,02
	kor	49,99	21,73	47,84
mehrfaches variables Vergessen	ges	0,02	0,02	0,10
	kor	0,02	0,02	0,08

festgelegt werden, was im hier betrachteten Betriebsumfeld herausfordernd und aufwendig ist. Entsprechend sind die resultierenden Identifikationsfehler in Tab. 4.2 deutlich zu hoch. Dies wird auch bei Betrachtung des Identifikationsverlaufs in Abb. B.3 deutlich.

Auch entlang des WLTP-Zyklus zeigt sich, dass der RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen eindeutig die besten Schätzergebnisse liefert. Die ermittelten Parameter konvergieren schnell und biasfrei und der Algorithmus ist in der Lage jeder spezifischen Parameteränderung zu folgen.

4.4.4 Experimentelle Analyse

Aufbauend auf den simulativen Ergebnissen in Abs. 4.4.3 wird die Funktion des Identifikationsalgorithmus in diesem Abschnitt experimentell untersucht. Die notwendige Echtzeitssoftware entsteht automatisiert aus den zuvor genutzten Simulationsmodellen und die Implementierung erfolgt auf der in Abs. 3 beschriebenen Echtzeithardware. Die Analyse der Performanz im dynamischen Maschinenbetrieb erfolgt auch hier anhand des WLTP-Zyklus mit der in Abs. 3 beschriebenen Trajektorie. Zusätzlich eignet sich die Untersuchung des Konvergenzverhaltens im stationären Betrieb zur Ermittlung systemspezifischer Konfidenzintervalle.

In Bezug auf die simulativen Ergebnisse ist der Einsatz des RLS-Algorithmus 2.2 mit einfachem Vergessensfaktor aufgrund der dynamischen Betriebsumgebung nicht zielführend. Auch die Erweiterung zur Kovarianzmanipulation liefert aufgrund des hohen Parametrisierungsaufwands in Verbindung mit der schlechten Generalisierbarkeit keine überzeugenden experimentellen Ergebnisse. Daher werden beide Ansätze für die nachfolgenden Untersuchungen nicht berücksichtigt.

Die besten Resultate ergeben sich mit variablem Vergessensfaktor, weswegen die folgenden Analysen basierend auf dem RLS-Algorithmus mit variablem bzw. mehrfach variablem Ver-

gessen durchgeführt werden. Obwohl der Parametrisierungsaufwand auch hier nicht gering ist, sind die variablen Vergessensfaktoren erforderlich, um den dynamischen Systemanforderungen gerecht zu werden. Analog zur simulativen Analyse erfolgt ein Vergleich der stationären und dynamischen Modelle, sowie die Berücksichtigung der Eisenverluste. Neben den genannten Modellierungsaspekten ist die Betrachtung weiterer Randbedingungen erforderlich.

Spannungsfehler durch Inverter und Taktverzögerung der Strommessung: Der Einsatz von Spannungszwischenkreisinvertern in elektrischen Antriebssystemen ist auch in der Automobilindustrie weit verbreitet. Die genaue Messung der Phasenspannungen mit kostengünstigen Sensortechniken ist in diesen Systemen eine Herausforderung und wird daher normalerweise vermieden. Für eine anspruchsvolle Regelung ist deren genaue Kenntnis jedoch entscheidend, weshalb die Phasenspannung alternativ durch entsprechende Modelle bestimmbar ist. In Bezug auf diese Arbeit stellt sich die Frage, ob der Spannungsfehler die Performanz der OPI beeinträchtigt. Daher wird das in Abs. 3 beschriebene Modell verwendet, um den Spannungsabfall über den Leistungshalbleitern in Abhängigkeit des momentanen Betriebspunktes zu kompensieren.

Ein weiteres Problem ist die Zeitverzögerung der Strommessung, die durch die diskrete Reglerimplementierung auf dem eingebetteten System entsteht. Nach der Einstellung eines neuen Spannungsvektors durch das Regelsystem steht die zugehörige Strommessung erst verzögert zur Verfügung. Damit die zusammengehörigen Messwerte für Strom und Spannung am Eingang der OPI zur Verfügung stehen, muss die Spannungsmessung demnach ebenfalls verzögert werden. Der Einfluss des Spannungsfehlers des Inverters sowie der Taktverzögerung der Strommessung auf die OPI wird nachfolgend experimentell analysiert.

Savitzky-Golay-Filter Konfiguration: Wie bereits in Abs. 4.4.1 erwähnt, hängt die Updatefrequenz des Algorithmus f_{rls} von der Fensterbreite k_f ab. Abhängig von der aktuellen Maschinendrehzahl bzw. Frequenz, sind unterschiedliche Filterkonfigurationen möglich. Allerdings ist die Berechnung der Filterkoeffizienten aufgrund der erforderlichen Matrixinversion nicht echtzeitfähig und deshalb lediglich offline durchführbar. Je nach System sind zur Abdeckung des gesamten Drehzahlstellbereichs mehrere Filterkonfigurationen notwendig, deren Koeffizienten zwangsläufig initial mit dem Systemstart berechnet werden müssen. Deren Speicherung erfordert Ressourcen des limitierten Echtzeitsystems, weswegen die Anzahl der notwendigen Datensätze sorgfältig abzuwägen ist. In dieser Arbeit hat es sich etabliert, einen einzigen Satz von Koeffizienten mit einer Fensterlänge von $k_f = 11$ entsprechend den in Abs. 4.4.1 genannten Anforderungen zu verwenden. Nach (4.39) ergibt sich bei einer

Tabelle 4.3: Experimenteller Vergleich des mittleren Identifikationsfehlers \bar{e} verschiedener Identifikationsmodelle unter Nutzung des RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessensfaktor entlang des WLTP-Zyklus.

Modell	\bar{e}_{T_r} [%]	\bar{e}_{L_s} [%]	\bar{e}_σ [%]	\bar{e}_{R_s} [%]
stationäres Modell ex. R_s	120	14,67	91,88	-
dynamisches Modell ex. R_s	13,69	7,76	92,81	-
dynamisches Modell ex. R_s, σ	6,86	3,88	-	-
dynamisches Modell ex. R_s, σ , in. R_{fe}	10,02	4,09	-	-

PWM-Frequenz von $f_{\text{pwm}} = 10$ kHz eine Updatefrequenz bzw. -zeit von:

$$f_{\text{rls}} = \frac{1}{n_{\text{id}}} \frac{1}{11 \cdot 100 \mu\text{s}} \approx \frac{1}{n_{\text{id}}} \cdot 910 \text{ Hz} \rightarrow T_{\text{rls}} \approx n_{\text{id}} \cdot 1 \text{ ms}. \quad (4.43)$$

Modellvergleich mit WLTP-Zyklus

Zunächst wird die Performanz der Identifikationsalgorithmen in Verbindung mit dem skalierten WLTP-Zyklus unter Verwendung verschiedener Konfigurationen analysiert. In Abs. 4.4.3 offenbaren die Simulationsergebnisse Schwierigkeiten im Zusammenhang mit der Identifikation des Statorwiderstands. Verschiedene Prüfstandsläufe bestätigen diese Probleme, weshalb sich keine überzeugenden Ergebnisse zur Identifikation von R_s erzielen lassen. Eine Forcierung der korrekten Identifikation von R_s durch Nutzung zusätzlicher Anregungssignale ist in dieser Arbeit aufgrund des Anwendungsgebiets nicht möglich. Der Statorwiderstand wird daher als Identifikationsparameter nicht berücksichtigt und ist bei der folgenden Prüfstandsanalyse stets vorgegeben. Wie bei der simulativen Analyse in Abs. 4.4.3, ist die Identifikation wegen der schwachen Anregung in Stillstandsphasen durch die Aktivierungslogik (4.40) inaktiv.

Stationäres vs. dynamisches Identifikationsmodell: Abbildung 4.11 zeigt einen Vergleich des stationären und des dynamischen Identifikationsmodells ohne Berücksichtigung der Eisenverluste. Die entsprechenden mittleren Identifikationsfehler \bar{e}_x sind in Tab. 4.3 zusammengefasst. Bei Betrachtung der Statorinduktivität \hat{L}_s zeigt sich, dass der Identifikationsfehler beider Modelle in der gleichen Größenordnung liegt. Das dynamische Modell weist über den gesamten Betriebsbereich robustes Verhalten auf und liefert mit einer mittleren Abweichung im einstelligen Prozentbereich gute Ergebnisse. Allgemein ist eine biasfreie Schätzung mit Bezug auf die genutzte Referenz im realen System, aufgrund von Modellierungsungenauigkeiten und fehlerhaften Referenzwerten nicht zu erwarten. Obwohl das mittlere Ergebnis des stationären Modells stabil erscheint weist es bereits eine bedeutend höhere Abweichung auf. Die absoluten Werte während der Beschleunigungs- und Abbrems-

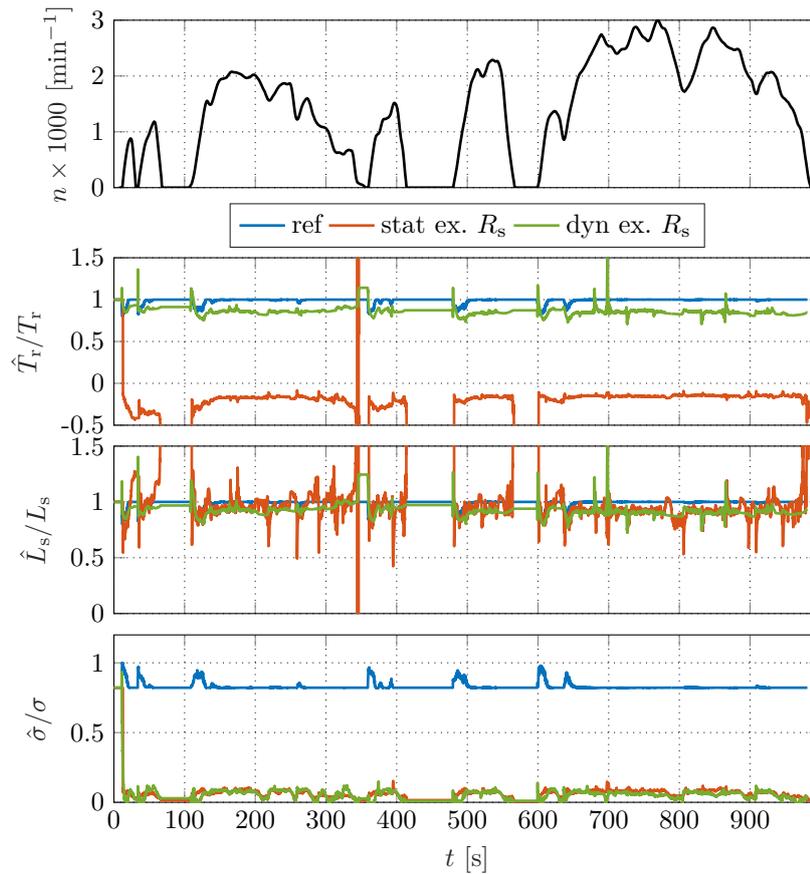


Abbildung 4.11: Experimenteller Vergleich des stationären und dynamischen Modells ohne Identifikation des Statorwiderstands R_s unter Nutzung des RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen entlang des WLTP-Zyklus. - Konfiguration stat ex. R_s Tab. B.12, dyn ex. R_s Tab. B.13.[17]

vorgänge enthalten hohe Spitzenwerte und der Verlauf ist teils instabil. Wie aufgrund der Kenntnisse aus der Simulation erwartet, ist das stationäre Modell für den Umgang mit dynamischen Drehzahländerungen ungeeignet. Die Identifizierung von $\hat{\sigma}$ ist für beide Modelle unzureichend. Ein Grund dafür ist die geringe Sensitivität dieses Parameters gegenüber dem jeweiligen Identifikationsmodell, die sich im Vergleich zur Simulation aufgrund der stärker verrauschten Messsignale bemerkbar macht. Diese Tatsache führt zu einer geringen SNR im realen System, was für die Parameteridentifikation nachteilig ist. Bei der Identifikation der Rotorzeitkonstante T_r ergibt sich ein deutlicher Unterschied zwischen den beiden Modellen. Während das stationäre Modell nicht in der Lage ist die dynamischen Änderungen zu identifizieren, liefert das dynamische Modell überzeugende Ergebnisse. Es verbleibt jedoch ein erheblicher Restfehler, da die Identifikation durch die hohe Abweichung e_σ zusätzlich verzerrt wird, vgl. Tab. 4.3. Dieses Problem wird im nächsten Unterabschnitt durch die Vordefinition des Streukoeffizienten adressiert.

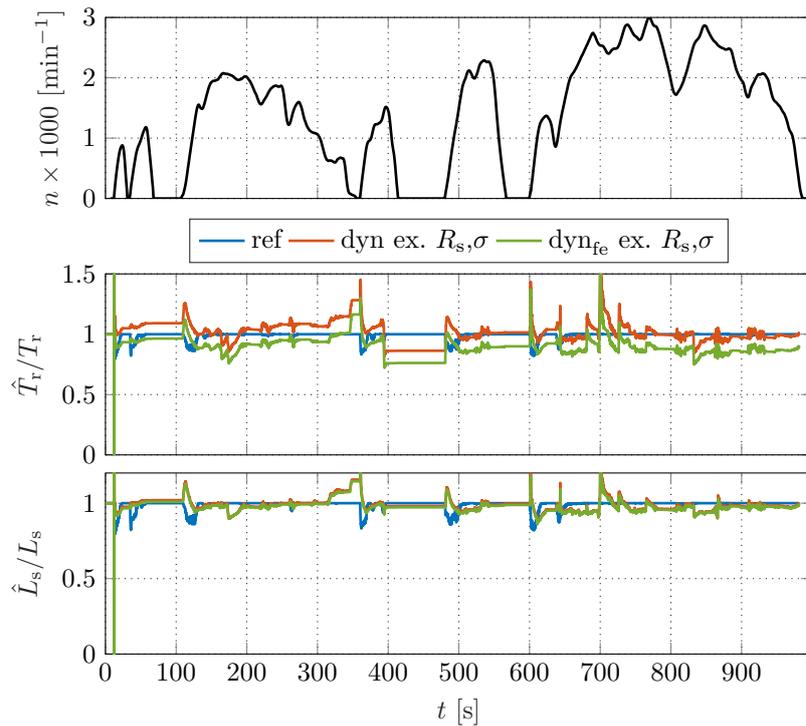


Abbildung 4.12: Experimenteller Vergleich des dynamischen Modells mit und ohne Berücksichtigung der Eisenverluste unter Nutzung des RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen entlang des WLTP-Zyklus. Der Statorwiderstand R_s und der Streukoeffizient σ werden vorgegeben. - Konfiguration Tab. B.14.[17]

Dynamisches Identifikationsmodell mit Vorgabe des Streukoeffizienten und Berücksichtigung der Eisenverluste: Zur Lösung der Probleme in Verbindung mit dem Streukoeffizienten und der verbleibenden Abweichung von T_r bietet sich ein dynamisches Modell mit zusätzlicher Vorgabe von σ an. Zusätzlich wird der Einfluss der Eisenverluste im realen System untersucht, da die simulativen Erkenntnisse eine Verbesserung der Identifikationsergebnisse versprechen. Die Ergebnisse sind in Abb. 4.12 dargestellt, und die entsprechenden mittleren Identifikationsfehler in Tab. 4.3 ergänzt. Die zusätzliche Vorgabe von σ hat einen signifikanten Einfluss auf die Identifikation der übrigen Parameter T_r und L_s . Die beiden durchschnittlichen Identifikationsfehler \bar{e}_{T_r} und \bar{e}_{L_s} [%] werden deutlich reduziert, es verbleibt jedoch ein geringer Bias, siehe Tab. 4.3. Gründe dafür sind Modellungenauigkeiten und Parameterunsicherheiten in den Referenzwerten aufgrund von Fertigungstoleranzen bzw. Offline-Identifikationsfehlern. Auf die dynamischen Eigenschaften der Parameter T_r und L_s hat die Vorgabe von σ allerdings einen eher negativen Einfluss, wie vor allem Messbereiche mit starker induktiver Sättigung offenbaren. Diese Tatsache ist auf den in dieser Konfiguration fehlenden Freiheitsgrad zurückzuführen. Die Berücksichtigung der Eisenverluste wirkt sich vor allem auf das Ergebnis der Rotorzeitkonstante aus. Ein Blick auf Abb. 4.12 offenbart, dass die tatsächliche Performanz beider Modelle vom Betriebspunkt der Maschine abhängt. Die Ergebnisse beider Modelle zeigen, dass die Verfolgung der schnellen dynamischen Sät-

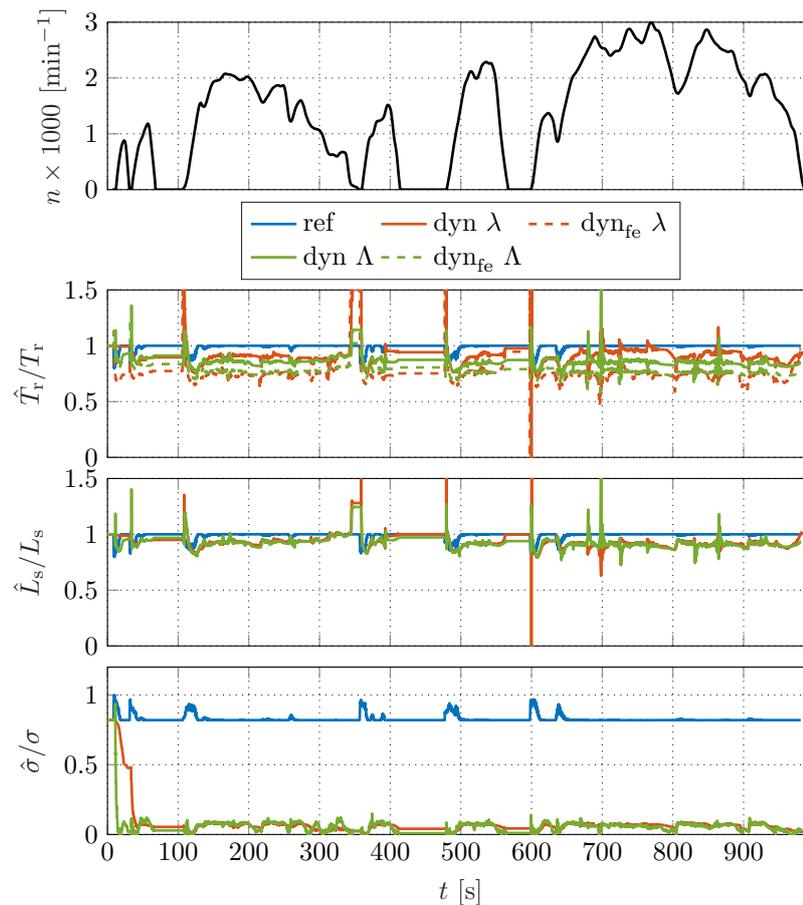


Abbildung 4.13: Experimenteller Vergleich der RLS-Algorithmen mit einfach variablem und mehrfach variablem Vergessensfaktor unter Nutzung des dynamischen Modells ohne Identifikation des Statorwiderstands R_s entlang des WLTP-Zyklus. - Konfiguration dyn Λ und dyn_{fe} Λ Tab. B.15, dyn λ und dyn_{fe} λ Tab. B.13.

tigung bei hoher Beschleunigungsbelastung eine Herausforderung darstellt. Ein Vergleich der mittleren Identifikationsfehler spricht in diesem Fall zunächst für das Modell ohne Berücksichtigung von R_{fe} . Jedoch zeigt das Modell mit Berücksichtigung der Eisenverluste im unteren Drehzahlbereich bessere Ergebnisse, während das Vergleichsmodell bei höheren Drehzahlen genauer ist. Nach (2.104) steigt der Eisenverlustwiderstand mit höherer Statorfrequenz, was folglich zu einem geringeren Stromfluss und Spannungsabfall über R_{fe} führt. In Bezug auf die dargestellten Verläufe lässt sich das beobachtete Verhalten anhand der vereinfachten Approximation (2.104) plausibilisieren. Es ist jedoch keine allgemeine Empfehlung für eines der beiden Modelle möglich. Die Konfiguration ist individuell im Hinblick auf das verwendete System und den betroffenen Betriebsbereich festzulegen.

Vergleich erweiterter RLS-Algorithmen mit WLTP-Zyklus

Analog zu den in Abs. 4.4.3 diskutierten Simulationsergebnissen erfolgt in diesem Abschnitt ein Vergleich verschiedener Erweiterungen des RLS-Algorithmus während des dynamischen Betriebs entlang des WLTP-Zyklus.

Der Einsatz des RLS-Algorithmus 2.2 mit einfachem Vergessensfaktor ist aufgrund der dynamischen Betriebsumgebung nicht zielführend. Durch diverse Voruntersuchungen ließ sich dieser Sachverhalt experimentell bestätigen. Durch den einfachen Vergessensfaktor zeigt der Algorithmus außerordentlich steifes Verhalten im Umgang mit dynamischen Parameteränderungen, weswegen die erzielten Schätzergebnisse nicht überzeugen.

Der RLS-Algorithmus 2.2 mit Kovarianzmanipulation ist eher für die Identifikation von Systemen mit einem kleinen dynamischen Betriebsbereich und abrupten Parameteränderungen geeignet. Wie die simulativen Ergebnisse bereits offenbaren, erweist sich die Parametrisierung dieser Methode als aufwendig und komplex, da für jeden dynamischen Betriebspunkt spezifische Manipulationsfaktoren erforderlich sind. Die Nutzung einer einheitlichen Parametrisierung für den gesamten Testzyklus liefert weder robuste noch überzeugende Ergebnisse. Aufgrund der zuvor beschriebenen Erkenntnisse wird nachfolgend lediglich die Performanz des RLS-Algorithmus mit einfachem und mehrfach variablen Vergessensfaktor verglichen. Um auch den Einfluss der Eisenverluste nicht außer Betracht zu lassen, erfolgt die Identifikation basierend auf dem dynamischen Modell mit und ohne Berücksichtigung von R_{fe} . Die entsprechenden Identifikationsergebnisse entlang des WLTP-Zyklus sind in Abb. 4.13 dargestellt. Wie bereits in Abs. 4.4.3 dargelegt, wirkt sich die Berücksichtigung der Eisenverluste lediglich auf die Identifikation der Rotorzeitkonstante aus. Daher sind in Abb. 4.13 aus Übersichtsgründen lediglich die auf dem Modell ohne Eisenverluste basierenden Ergebnisse für \hat{L}_s und $\hat{\sigma}$ dargestellt. Grundsätzlich bestätigen sich die simulativ ermittelten Stabilitätsprobleme bei Nutzung eines einfachen variablen Vergessensfaktors nicht. Die Begründung dafür liegt in der Schwächung des Wind-up-Effekts im realen System. Trotz Phasen schwacher Anregung wird durch die auftretende Verzerrung periodischer Zustandsgrößen und verrauschter Messsignale das Wind-up der Kovarianzmatrix verhindert.

Die stark biasbehaftete Identifikation der Streuinduktivität ergibt sich auch bei Nutzung des einfachen Vergessensfaktors, sodass die Identifikationsfehler beider Algorithmen annähernd identische Werte $\hat{\sigma}$ liefern, siehe auch Tab. 4.4. Die Ergebnisse für \hat{L}_s beider Algorithmen liegen dicht bei den Referenzwerten, sodass der Bias für alle Konfigurationen bei mittleren Identifikationsfehlern um $e_{L_s} \approx 7\%$ liegt. Unterschiede ergeben sich hingegen bei den Ergebnissen der Rotorzeitkonstante \hat{T}_r . Der Vergleich der Algorithmen bei Nutzung des dynamischen Modells ohne Eisenverluste zeigt geringere Fehler für den Fall eines einfachen variablen Vergessensfaktors. Dabei führen dynamische sättigungsbedingte Parameteränderungen jedoch zu teils starkem Überschwingen. Die Ergebnisse von \hat{T}_r bei Nutzung des dynamischen Modells mit Berücksichtigung der Eisenverluste zeigen ähnliche Identifikationsfehler, wobei hier der Algorithmus mit mehrfachen variablen Vergessen einen geringen Fehler aufweist. Generell sind die Verläufe stark von der Wahl der Vergessensfaktoren abhängig. Je niedriger deren Werte, desto stärker sind die Auswirkungen des Messrauschens und der momentanen Parameteränderungen ersichtlich. Gerade in Bezug auf unterschiedliche Parameteränderungen bietet der RLS-Algorithmus mit mehreren Vergessensfaktoren,

trotz des höheren Parametrisierungsaufwands, entscheidende Vorteile. Im Hinblick auf die Anwendung zur technischen Diagnose in Abs. 1.1 ist eine problemspezifische Anpassung des RLS-Algorithmus erforderlich. Daher wird fortlaufend auf den Algorithmus mit mehreren Vergessensfaktoren zurückgegriffen.

Vergleich mit vereinfachtem Testprofil

Im vorherigen Abschnitt 4.4.4 erzielt das dynamische Modell ohne Identifikation von R_s und σ in Verbindung mit dem RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen die besten Identifikationsergebnisse. Eine klare Entscheidung für oder gegen die Berücksichtigung der Eisenverluste ist basierend auf den Untersuchungen entlang des WLTP-Zyklus nicht möglich. Eine ergänzende Analyse erfolgt basierend auf einem Rampenprofil mit stationären und dynamischen Betriebspunkten. Dieser Testzyklus ermöglicht zusätzliche Untersuchungen des Konvergenzverhaltens in verschiedenen Sättigungspunkten der Maschine. Des Weiteren wird darauf aufbauend der Einfluss der Taktverzögerung der Strommessung sowie des Spannungsfehlers des Inverters untersucht. Der obere Teil von Abb. 4.14 zeigt das implementierte Rampenprofil. Um mit dem dargestellten Drehzahlprofil deutlich unterschiedliche Sättigungspunkte zu erreichen ist ein Betrieb im Feldschwäcbereich aufgrund der maximal zulässigen Phasenspannung nicht möglich. Aus diesem Grund geht die absolute Drehzahl in diesem Fall nicht über $n = 1200 \text{ min}^{-1}$ hinaus.

Einfluss der Eisenverluste im Identifikationsmodell: Die Schätzergebnisse des dynamischen Identifikationsmodells mit und ohne Berücksichtigung der Eisenverluste sind im unteren Teil von Abb. 4.14 dargestellt. Proportional zum Verlauf der flussbildenden Stromkomponente i_d ist der Sättigungseffekt und somit die Änderung der Maschineninduktivität sichtbar. Die Betrachtung der Verläufe zeigt, dass die dynamische Sättigung auch bei großen Parameteränderungen von beiden Modellen identifiziert wird. Zu Beginn der Identifikation ist die Anregung aufgrund der verhältnismäßig kleinen Ströme noch gering. Auch wegen der direkten Drehzahländerung zu Beginn ist die Konvergenzzeit in dieser Phase vergleichsweise lang. Mit der Änderung des Stromprofils erfolgt die direkte Konvergenz der Parameter in Richtung der Referenzwerte. Die Berücksichtigung der Eisenverluste hat auf die Identifikation von L_s lediglich einen sehr geringen Einfluss. Der Identifikationsfehler der Rotorzeitkonstante ist jedoch bei Berücksichtigung von R_{fe} deutlich geringer, während die Ergebnisse des Vergleichsmodells einen konstanten Bias aufweisen. Ein grafischer Vergleich anhand der mittleren Identifikationsfehler erfolgt im nachfolgenden Abschnitt. Wie zu erwarten, sorgt die geringere Dynamik des Rampenprofils im Vergleich zum WLTP-Zyklus für einen robusteren Verlauf der OPI in dynamischen Betriebspunkten. Außerdem sind die absoluten Identifikationsfehler sehr gering und liegen im Toleranzbereich der zur Verfügung stehenden Referenzwerte. Im Hinblick auf eine spätere Diagnoseanwendung im Fahrzeug ist in Abhän-

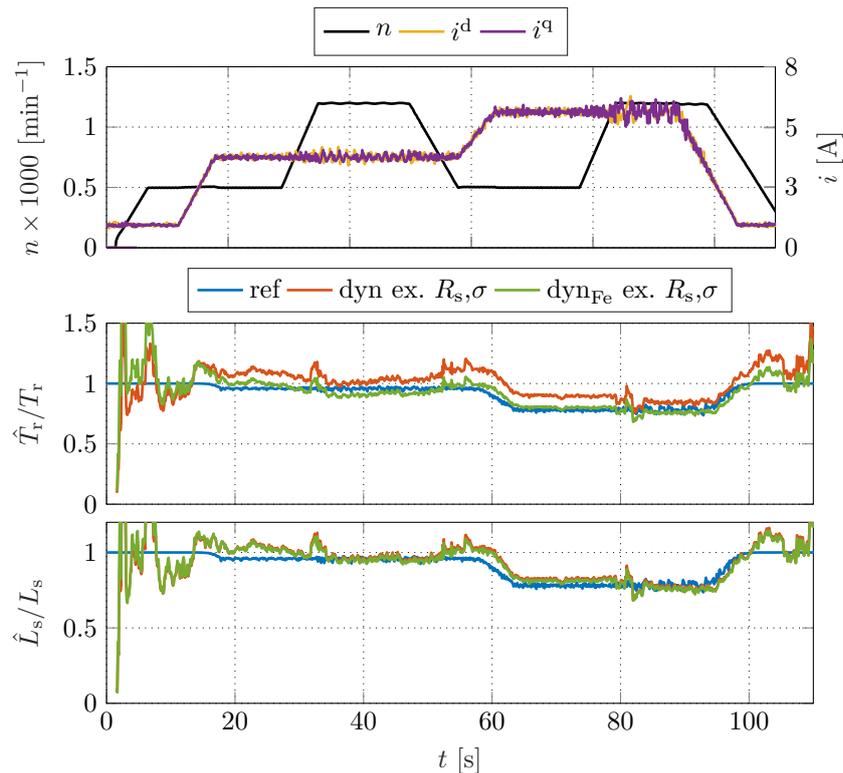


Abbildung 4.14: Experimenteller Vergleich des dynamischen Modells mit und ohne Berücksichtigung der Eisenverluste unter Nutzung des RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen entlang eines speziellen Rampenprofils. Der Statorwiderstand R_s und der Streukoeffizient σ werden vorgegeben. - Konfiguration Tab. B.16.[17]

gigkeit der Zielstellung abzuwägen, in welchem Betriebsbereich die OPI aktiv ist. Allgemein liefert der RLS-Algorithmus 2.3 mit mehrfachem variablen Vergessen bei hinreichend vorhandener Anregung im gesamten Betriebsbereich eine robuste Schätzung.

Auswirkungen der Eisenverluste und der Spannungsfehler: In diesem Abschnitt wird der mittlere Identifikationsfehler \bar{e}_x der in Abb. 4.14 dargestellten Schätzergebnisse in Kombination mit den auftretenden Abweichungen der Spannungswerte analysiert. Dabei stellt sich die Frage, ob die auftretenden Spannungsfehler einen entscheidenden Einfluss auf die Genauigkeit der OPI haben. Basierend auf dem Rampenprofil in Abb. 4.14 erfolgen vier Testläufe mit unterschiedlichen Konfigurationen zur Kompensation des Spannungsfehlers. Während jedes Durchlaufs wird der Algorithmus demnach mit unterschiedlichen Spannungssignalen gespeist. Abbildung 4.15 zeigt den mittleren Identifikationsfehler \bar{e}_x der einzelnen Parameter T_r und L_s bei Verwendung des Modells mit (dyn_{Fe}) bzw. ohne Berücksichtigung der Eisenverluste. Außerdem ist durch die schwarzen Fehlerbalken die Varianz des Identifikationsfehlers über den jeweiligen Lauf ersichtlich. Die Berücksichtigung der Spannungsverzögerung u_{del} und der Spannungsfehlerkorrektur u_{kor} ist auf der x-Achse durch boolesche Notation aufgetragen. Beispielsweise ist im Fall $\overline{u_{\text{del}}}, \overline{u_{\text{kor}}}$ weder die Korrektur der Spannungsverzögerung

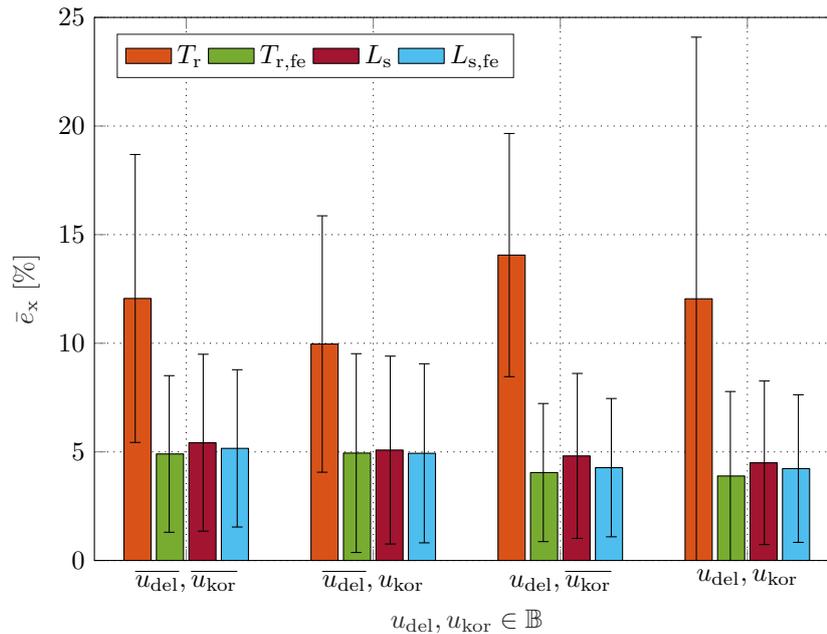


Abbildung 4.15: Einfluss der Verzögerungszeit des Spannungswertes... u_{del} und der Korrektur des Spannungsfehlers... u_{kor} auf den Mittelwert des Identifikationsfehlers \bar{e}_x . Der Einfluss von u_{del} und u_{kor} wird jeweils auf der x-Achse durch bool'sche Notation repräsentiert. - Konfiguration Tab. B.16.[17]

u_{del} noch die Spannungsfehlerkorrektur u_{kor} aktiv.

Bezogen auf Abb. 4.14 bestätigen die blauen und roten Balken, dass die Identifikation von L_s bei Berücksichtigung der Eisenverluste nur geringfügig besser verläuft. Der Vergleich der orangen und grünen Balken zeigt hingegen die signifikante Verbesserung bei der Identifikation der Rotorzeitkonstante durch die Modellierung von R_{fe} . Die Verzögerung u_{del} der Spannungsmessung führt insgesamt zu einer Verbesserung zwischen 1...2%. Die Spannungskorrektur u_{kor} führt in Kombination mit aktiver Spannungsverzögerung zu einem etwas besseren Ergebnis. Die absolute Auswirkung des nichtlinearen Spannungsfehlers hängt jedoch stark von der aktuellen Maschinendrehzahl ab. Besonders bei niedrigen Drehzahlen ist die Auswirkung aufgrund der kleinen absoluten Induktionsspannungen deutlich größer. Aus diesem Grund ist die Aktivierung beider Verfahren zur Spannungskorrektur auch in Bezug auf die OPI empfehlenswert.

4.4.5 Zusammenfassung und Diskussion

Abschließend erfolgt nun eine Zusammenfassung der Ergebnisse und Diskussion der gewonnenen Erkenntnisse. Tab. 4.4 zeigt dazu eine zusammengefasste Übersicht der mittleren Identifikationsfehler der zuvor präsentierten simulativen und experimentellen Testläufe. Allgemein fällt erwartungsgemäß auf, dass sich die experimentellen Ergebnisse deutlich von den simulativen unterscheiden.

Aufgrund der Gegebenheiten im realen System ergeben sich im Vergleich zur simulativen

Tabelle 4.4: Vergleich simulativer und experimenteller Ergebnisse entlang des WLTP-Zyklus anhand des mittleren Identifikationsfehlers \bar{e} verschiedener Konfigurationen von Identifikationsmodellen und Erweiterungen des RLS-Algorithmus.

Konfiguration	sim/meas	\bar{e}_{T_r} [%]	\bar{e}_{L_s} [%]	\bar{e}_σ [%]	\bar{e}_{R_s} [%]
stationäres Modell	sim	1,37	1,33	4,28	1,23
mehrf. variables λ	meas	44,87	73,74	94,13	757,70
stationäres Modell ex. R_s	sim	1,56	1,38	5,33	–
mehrf. variables λ	meas	120,00	14,66	91,88	–
dynamisches Modell	sim	0,46	0,24	12,61	74,13
mehrf. variables Λ	meas	102,40	37,55	92,58	2841
dynamisches Modell ex. R_s	sim	0,02	0,02	0,10	–
mehrf. variables Λ	meas	13,69	7,76	92,81	–
dynamisches Modell ex. R_s in. R_{fe}	sim	–	–	–	–
mehrf. variables Λ	meas	21,95	8,24	93,3	–
dynamisches Modell ex. R_s	sim	36,39	15,86	32,35	–
variables λ	meas	9,82	7,38	90,85	–
dynamisches Modell ex. R_s in. R_{fe}	sim	–	–	–	–
variables λ	meas	24,86	7,28	92,88	–
dynamisches Modell ex. R_s, σ	sim	–	–	–	–
mehrf. variables Λ	meas	6,86	3,88	–	–
dynamisches Modell ex. R_s, σ in. R_{fe}	sim	–	–	–	–
mehrf. variables Λ	meas	10,17	4,09	–	–

Betrachtung unterschiedliche Erkenntnisse in Bezug auf die Identifizierbarkeit einzelner Parameter. Wie mit Hilfe der Beobachtbarkeits- und Sensitivitätsanalyse in Abs. 4.3.1 mathematisch bestätigt, ist das System „Asynchronmaschine“ in jedem Punkt beobachtbar, sodass theoretisch alle Parameter identifizierbar sind. Die tatsächliche Identifikation valider Ergebnisse hängt jedoch von den Rahmenbedingungen und den Parameterverhältnissen der identifizierten Maschine ab. Dabei stellt sich gerade die Sensitivitätsanalyse im Zeitbereich als nützliches Werkzeug heraus, da sie die Identifizierbarkeit einzelner Parameter mit überschaubarem Aufwand bewertbar macht. In Bezug auf die in dieser Arbeit genutzte Maschine besteht ein eindeutiger Zusammenhang zwischen Parametern mit geringer Sensitivität und tatsächlich problematischer Identifizierbarkeit. Der Statorwiderstand R_s weist abgesehen vom Stillstandsbetrieb eine sehr geringe Sensitivität auf und ist sowohl simulativ als auch experimentell nicht valide identifizierbar. Die Identifikation der Streuinduktivität bzw. des Streukoeffizienten lässt sich trotz geringer Sensitivität zwar simulativ identifizieren. Experimentell ist jedoch durch die zusätzlich schlechtere SNR keine valide Identifikation möglich. Auffällig ist dabei, dass der Algorithmus bei der Identifikation von σ grundsätzlich

robustes Schätzverhalten, das Ergebnis jedoch einen starken Bias aufweist.

Auch die Wahl des RLS-Algorithmus hängt vom identifizierten System ab. Mit Hilfe der simulativen und experimentellen Untersuchungen lässt sich zeigen, dass ein variabler Vergessensfaktor zwingend erforderlich ist um Parameteränderungen in einem dynamischen Betriebsumfeld zu identifizieren. Die Nutzung eines mehrfachen variablen Vergessensfaktors erhöht die Flexibilität, da der RLS-Algorithmus individuell auf die sich ändernden Identifikationsparameter und den betrachteten Betriebsbereich konfigurierbar ist. In der Simulation ergeben sich generell signifikante Genauigkeitsunterschiede in dynamischen Testzyklen beim Vergleich der Algorithmen mit einfach und mehrfach variablem Vergessensfaktor. Im experimentellen Umfeld bestätigen sich diese Probleme jedoch aufgrund verschiedener Gegebenheiten nicht. Durch nicht sinusförmige, verrauschte Systemgrößen und Drehmomentwelligkeiten bedingt durch den mechanischen Aufbau sowie weitere äußere Einflüsse relativiert sich das Problem des Wind-up Effekts durch fehlende Anregung des Identifikationsproblems. Je nach zu identifizierendem System muss daher eine Abwägung zwischen höherem Parametrisierungsaufwand bei mehrfachem Vergessen und geringerer Flexibilität bei einfachem Vergessen erfolgen.

Zusammenfassend hängt die letztendliche Performanz der OPI stark von der Konfiguration und Parametrisierung des Algorithmus ab. Die durchgeführten Analysen ergeben, dass die Berücksichtigung transienter Drehzahländerungen in Form der dynamischen Identifikationsmodelle für eine valide OPI in einem dynamischen Umfeld unerlässlich ist. Die zusätzliche Berücksichtigung der Eisenverluste führt je nach Betriebspunkt und Anwendung zu einer signifikanten Verbesserung der Ergebnisse. Auch die betriebspunktabhängige Korrektur des durch das nichtlineare Inverterverhalten und die Echtzeitimplementierung auftretenden Spannungsfehlers erweist sich als wichtig. Daneben ist, wie durch die Beobachtbarkeitsanalyse prognostiziert, die Art und die Anzahl der zu identifizierenden Parameter entscheidend. Die OPI aller Parameter anhand eines Modells in einem realen Antriebssystem stellt sich als schwierig heraus. Daher liefert die Identifikation des gesamten Parametersatzes in der hier betrachteten dynamischen Umgebung keine überzeugenden Ergebnisse. Um den unterschiedlichen Parametertypen und dem transienten Verhalten gerecht zu werden, ergibt sich der RLS-Algorithmus mit mehrfachem variablen Vergessen als die beste Methode. Allgemein, jedoch besonders in der experimentellen Anwendung, erweist sich die Parametrisierung des SG-Filters und der Vergessensfaktoren als eine anspruchsvolle Aufgabe. Der Versuch die Parametrisierung simulativ zu optimieren, scheitert aufgrund der nur mit erheblichem Zusatzaufwand zu behebenden Modellgenauigkeiten im Vergleich zum realen System. In jedem Fall hängt auch die Einstellung der Hyperparameter des gesamten Schätzalgorithmus stark von der verwendeten Maschine, dem zugehörigen System, sowie dem Drehzahl- und Lastbereich ab. Zur Vermeidung divergenten Verhaltens aufgrund fehlender Anregung des Identifikationsproblems ist die implementierte Aktivierungslogik von entscheidender Bedeutung.

Zur Beurteilung des weiteren Optimierungspotentials lassen sich folgende allgemeine Fehlerquellen festlegen:

- Die Bewertung des entstehenden Identifikationsfehlers erfolgt basierend auf einem universellen Referenzdatensatz der genutzten ASM. Aufgrund von Produktionstoleranzen, Alterungseffekten und Fehlern bei der Ermittlung der Referenzparameter ist die Genauigkeit dieser Datensätze stets zu hinterfragen.
- Durch vernachlässigte Effekte ergeben sich Modellungenauigkeiten, die jedoch nur durch eine Erhöhung der Modellkomplexität kompensierbar sind.
- Die Filterung der Messsignale führt zwangsläufig zu fehlerbehafteten Eingangsgrößen. Daher muss die Konfiguration des Filteralgorithmus stets auf das identifizierte System abgestimmt sein. Unter Umständen ist aufgrund eines großen Drehzahlstellbereichs die Applikation mehrerer Filterkoeffizienten sinnvoll. Eine Optimierung der Berechnung der Filterkoeffizienten hinsichtlich einer Vermeidung der Matrixinversion würde den Einsatz eines variablen Glättungsfensters erheblich erleichtern.
- Die Optimierung der Aktivierungslogik ist neben der Einstellung der Hyperparameter des Algorithmus die wichtigste Einflussmöglichkeit zur systemspezifischen Applikation.

Allgemein muss die Konfiguration und die Parametrierung individuell für das betrachtete System erfolgen. Auch die genannten Möglichkeiten für eine weitere Optimierung sind in Bezug auf das jeweilige Identifikationsproblem abzuwägen. Als Alternative zum RLS-Algorithmus analysiert das nächste Kapitel zum Vergleich die Performanz der OPI mittels erweiterter KF.

5 Online-Parameteridentifikation mittels erweitertem Kalman-Filter

Auch beobachterbasierte Verfahren eignen sich neben der Zustands- und Parameterschätzung zur Effizienzsteigerung der Regelung für Diagnoseanwendungen in elektrischen Antriebssystemen. Als Basis für die Implementierung ist die Modellierung des zu identifizierenden Systems in der Zustandsraumdarstellung erforderlich. Zur Schätzung werden die im ZRM enthaltenen Zustandsgrößen mit den Ausgängen des realen Systems verglichen und iterativ durch eine Korrekturmatrix angepasst, wie in Abb. 2.1 ersichtlich. Dieses Kapitel analysiert erweiterte KF zur OPI als Alternative zum RLS-Algorithmus.

Im Vergleich zum RLS-Algorithmus entsteht der Implementierungsaufwand bei erweiterten KF maßgeblich aufgrund der komplexeren Strukturen der Algorithmen. Durch die Nutzung des in sich geschlossenen ZRM ist hingegen keine Herleitung verschiedener Modelle erforderlich und die Konfiguration und Anzahl der zu identifizierenden Parameter ist beliebig möglich. Das ZRM ist sowohl im flussorientierten d/q-KOS als auch im rotierenden α/β -KOS zur KF basierten OPI geeignet. Im Vergleich zum RLS-Algorithmus ist für die Performanz erweiterter KF nicht die Wahl der Hyperparameter, sondern die Initialisierung der Zustände und Kovarianzen sowie die Festlegung der Rauscheigenschaften entscheidend.

Zunächst erfolgt eine Erfassung des Stands der Technik zur Online-Systemidentifikation mittels beobachterbasierter Verfahren in Bezug auf die Problemstellung dieser Arbeit. Nach der Vorstellung der Identifikationsmodelle folgt eine theoretische Beobachtbarkeitsanalyse zur Bewertung der Konditionierung des Identifikationsproblems in einem dynamischen Betriebsumfeld. Der finale Teil beschreibt zunächst die Implementierung der betrachteten erweiterten KF-Algorithmen, bevor deren Performanz anhand verschiedener Testzyklen simulativ und experimentell evaluiert wird.

5.1 Stand der Technik beobachterbasierte Verfahren

Als grundlegendes beobachterbasiertes Verfahren zur Zustandsschätzung existiert der Luenberger-Beobachter. Aufbauend darauf nutzt das KF die identische Struktur. Der Unterschied dieser etablierten Verfahren besteht in der Umsetzung der Korrekturstrategie. Im Fall des Luenberger-Beobachters wird die gewünschte Systemdynamik initial und statisch durch die

Verstärkung der Korrekturmatrix festgelegt. Das KF hingegen nutzt eine dynamische Korrekturverstärkung und berechnet diese iterativ basierend auf den Eigenschaften des Mess- und Prozessrauschens. Mit Hilfe dieser Verfahren lassen sich die Zustandsgrößen eines linearen ZRM im laufenden Betrieb der Maschine rekursiv beobachten. Ein populäres Beispiel im Fall der ASM ist der Einsatz als Rotorflussbeobachter zur Vektorregelung, siehe zum Beispiel [113]. Aufgrund der Vielzahl an existierenden Publikationen und dem fehlenden Bezug zur Zielstellung dieser Arbeit wird auf eine detaillierte Erfassung verzichtet.

Die Nutzung adaptierter Beobachter- bzw. KF-Strukturen ermöglicht die Identifikation zusätzlicher Systemzustände. Zwangsläufig geht damit eine Erweiterung des Zustandsvektors und damit die Entstehung eines nichtlinearen ZRM einher. Weit verbreitete Anwendungen zur erweiterten Zustandsschätzung sind die sensorlose Drehzahlregelung der ASM oder die Integration eines Drehmomentmodells. Dabei wird der Zustandsvektor jeweils um die Drehzahl beziehungsweise das Drehmoment erweitert, um eine sensorlose Zustandsgrößen- erfassung zu ermöglichen. Die Umsetzung ist sowohl durch ELB [114], [115] als auch durch EKF [116], [117] oder UKF [118], [119] möglich, wie die angegebenen Referenzen stellvertretend für weitere Publikationen zeigen. Da die erweiterte Zustandsschätzung und die damit verbundenen Anwendungen ein eigenes Forschungsgebiet darstellen, wird auch hier auf eine detaillierte Erfassung des Forschungsstands verzichtet.

Durch die Erweiterung des Zustandsvektors des ZRM besteht ebenfalls die Möglichkeit einer zusätzlichen Parameteridentifikation mittels adaptierter Beobachter- bzw. KF-Strukturen. Diese werden im Rahmen dieser Arbeit als Alternative zur dynamischen OPI mittels RLS-Algorithmus analysiert. Die nachfolgende Übersicht stellt eine Zusammenfassung existierender Verfahren zur beobachterbasierten OPI dar. Dabei werden die in Bezug auf die Zielstellung dieser Arbeit nach Stand der Technik bisher nicht berücksichtigten Aspekte und Probleme herausgestellt.

Erweiterte Luenberger Beobachter

Der erweiterte Luenberger-Beobachter kommt im Bereich der elektrischen Antriebssysteme meist in der parameteradaptiven Zustandsidentifikation in Verbindung mit der Umsetzung adaptiver Regelverfahren zum Einsatz. Zur Kompensation von transientem Parameterverhalten bei der Rotorflussidentifikation stellen Hasan et al. in [11] einen Luenberger-Sliding-Mode Beobachter vor. Dieser ist in der Lage, die betriebsbedingten Parameteränderungen der Rotorzeitkonstante sowie des Statorwiderstands bei der Flusschätzung zu berücksichtigen. Mit dem selben Ziel präsentieren Stoicuta et al. in [16] einen ELB mit Fokus auf der Identifikation des ohmschen Stator- und Rotorwiderstands. Koupeny [14] und Yang et al. [15] nutzen eine verschaltete Struktur aus mehreren Beobachtern zur Parameteridentifikation. Die Integration zweier verschalteter Sliding-Mode Beobachter in ein MRAS führt in [15] zu einer komplexen Struktur zur Adaption der Hauptinduktivität und des Rotorwiderstands. Ziel ist

dabei ebenso die Verbesserung der Flussbeobachtung und damit der Reglerperformanz. Eine Kombination aus Stator- und Rotorflussbeobachter nutzen die Autoren in [14] zur Identifikation der ohmschen Widerstände sowie der Hauptinduktivität. Allerdings ist dazu eine Vorsteuerung der offline identifizierten Magnetisierungskurve erforderlich. Demnach gilt es kritisch zu hinterfragen, ob eine unabhängige Identifikation von L_m gegeben ist. Generell wird die Performanz in einem dynamischen Betriebsumfeld in den bestehenden Arbeiten nicht überzeugend thematisiert. Als Testszenarien für dynamisches Parameterverhalten dienen sprunghafte Änderungen einzelner Parameter oder Drehzahl- bzw. Drehmomentänderungen bei gleichbleibenden Parametern. Außerdem sind die komplex verschalteten Systeme nach erster Einschätzung schwer zu parametrisieren und aufeinander abzustimmen. Daraus ergibt sich die These, dass die initiale Bedatung der statischen Korrekturmatrix für den Einsatz in einem stark dynamischen Betriebsumfeld nicht ausreichend flexibel ist. Die aufgestellten Behauptungen bestätigen sich durch die simulative Analyse des Verfahrens von Koupeny [14] in Bezug auf die Zielstellung dieser Arbeit. Die zugehörigen Ergebnisse finden aus Gründen des Umfangs in dieser Arbeit keine Berücksichtigung. Die Weiterverfolgung des ELB ist für diese Arbeit daher nicht zielführend.

Erweiterte Kalman-Filter

Für eine effiziente rotorflussorientierte Vektorregelung ist eine möglichst genaue Ermittlung des Rotorflusswinkels zur Zustandsgrößentransformation entscheidend. Daher widmen sich zahlreiche Publikationen der parameteradaptiven Flussbeobachtung durch adaptierte KF. Das notwendige ZRM ergibt sich jeweils durch einfaches Hinzufügen der zu identifizierenden Parameter zum erweiterten Zustandsvektor, sodass die Art und Anzahl der Schätzparameter ohne individuelle Herleitung anpassbar ist.

Mit Fokus auf der rotorflussorientierten Regelung bietet sich die betriebspunktabhängige Schätzung der Rotorzeitkonstante im d/q-KOS an. Salvatore et al. integrieren den Rotorfluss in [120] daher in den Zustandsvektor. Die zusätzliche Identifikation der Rotorzeitkonstante durch den EKF-Algorithmus bewirkt eine gesteigerte Performanz der Rotorflussschätzung. Die Validierung erfolgt allerdings anhand eines Testprofils mit konstantem Lastpunkt, wodurch die Reaktion auf dynamisches Parameterverhalten vernachlässigt wird. Auch Zai et al. widmen sich in [121] der Adaption der Rotorzeitkonstante im d/q-KOS. Alternativ zum ZRM in [120] enthält der Zustandsvektor hier die Stator und Rotorstromkomponenten. Zusätzlich berücksichtigen die Autoren die Sättigung der Hauptinduktivität durch eine im erweiterten Leerlaufversuch ermittelte Kennlinie. Allerdings weist das genutzte Testprofil lediglich eine sehr langsame Drehzahländerung in einem konstanten Lastpunkt auf, weswegen der Sättigungspunkt der Maschine konstant bleibt. In beiden Anwendungen basieren die Modelle auf dem T-ESB im d/q-KOS, weswegen die Qualität des ermittelten Transformationswinkels einen entscheidenden Einfluss hat. Aufgrund der fehlenden Berücksichtigung des dynami-

schen Parameterverhaltens sind die angestellten Untersuchungen nicht repräsentativ für die Zielstellung dieser Arbeit.

Pena et. al. fokussieren in [122] die Schätzung des Rotorwiderstands und der Magnetisierungsinduktivität des T-ESB im d/q-KOS. Die Autoren zeigen jedoch lediglich simulative Ergebnisse im stationären Nennpunkt der Maschine, die hinsichtlich des dynamischen Betriebs in dieser Arbeit eher irrelevant sind. Von Bedeutung ist jedoch die Sensitivitätsanalyse in Bezug auf eine fehlerhafte Erfassung der Zustandsgrößen. So zeigt sich, dass die Identifikation des Rotorwiderstands sehr sensitiv auf eine minderwertige Drehzahlerfassung ist. Die vorgestellten Ergebnisse bezüglich der betriebspunktabhängigen Anregung werden im späteren Verlauf der Arbeit aufgegriffen.

Weitere Ansätze konzentrieren sich ausschließlich auf die OPI der ohmschen Widerstände der Maschine mit unterschiedlichen Absichten. Dadkah et. al. [123] identifizieren, zusätzlich zu Drehzahl und Drehmoment, den Statorwiderstand in Bezug auf große Änderungen in hohen Lastbereichen mit Fokus auf die Verbesserung einer sensorlosen Drehzahlregelung. Anhand von Testprofilen mit separaten Drehzahl- und Drehmomentänderungen präsentieren die Autoren lediglich simulative Ergebnisse. Währenddessen erfolgt die Simulation einer sprunghaften und sehr großen Änderung von R_s , die in Bezug auf reale Anwendungen unrealistisch erscheint. Das Modell zur OPI basiert auf dem T-ESB im α/β -KOS, wodurch der Winkelfehler irrelevant ist. Das gleiche Modell nutzen Demir et al. in [124] zur OPI des Stator- und Rotorwiderstands mit der Intension, die Performanz einer direkten Drehmomentregelung zu verbessern. Auch hier werden lediglich simulative Ergebnisse präsentiert und die sprunghaften Parameteränderungen sind mit Bezug auf reale Anwendungen kritisch zu bewerten. Zur Reduzierung der Rechenzeit schlagen Atkinson et al. in [125] die Nutzung eines ZRM reduzierter Ordnung basierend auf dem T-ESB im d/q-KOS zur OPI des Rotorwiderstands vor. Die Analysen entlang eines Testprofils mit alternierendem Drehzahlverlauf zeigen zwar gute Ergebnisse. Diese erlauben jedoch bezüglich der vorliegenden Arbeit keine Rückschlüsse auf reale Anwendungsprofile. Dennoch verdeutlicht das genutzte Profil, dass die gute Anregung in transienten Betriebspunkten zu einer schnelleren Konvergenz führt. Im Hinblick auf eine EKF basierte Maschinendiagnose präsentieren Rayyam et al. in [126] und Ameid et al. in [127] einen Ansatz zur OPI ohmscher Parameter basierend auf dem T-ESB im d/q-KOS vor. Während Rayyam et al. [126] die Parameteränderungen sprunghaft simulieren, analysieren Ameid et al. [127] die Performanz anhand eines mechanisch zerstörten Rotors. Die Identifikation ist sowohl in fehlerfreien als auch fehlerbehafteten Systemzuständen erfolgreich. Die Dynamik wird jedoch in beiden Fällen nur bedingt berücksichtigt, da das genutzte Testprofil lediglich einen Drehmomentsprung bei konstanter Drehzahl enthält. Auch die gleichzeitige OPI aller Modellparameter wird bereits in verschiedenen Arbeiten analysiert. In [128], [129], [130] dient die Modellierung laut T-ESB im d/q-KOS als Basis. Wie bereits Atkinson et al. in [125], nutzen Leite et al. in [128] ein Modell reduzierter Ordnung, in dem die Statorströme keine Berücksichtigung als Zustände finden. Skalierungsfaktoren

im erweiterten Zustandsvektor bewirken eine Normalisierung der zu schätzenden Parameter in identischen Größenordnungen. Ob diese Maßnahme positive Auswirkungen auf die absolute Performanz der OPI hat, ist kritisch zu bewerten, da dadurch auf den ersten Blick lediglich numerische Vorteile bei der Ausführung entstehen. Die dynamische Performanz wird lediglich anhand einer Sprungantwort bemessen. Zur Steigerung der Robustheit erfolgt eine Filterung der Eingangssignale, wodurch zusätzlicher Berechnungsaufwand entsteht. Lao-wanitwattana et. al. [130] integrieren Parametergrenzen in den EKF-Algorithmus. Bei der Verletzung physikalischer Grenzen lassen sich die Schätzwerte in einen validen Parameterraum korrigieren. Die Untersuchungen beschränken sich allerdings auch hier auf konstante Betriebspunkte.

Iwasaki et al. [131] und Laroche et al. [132] führen die OPI basierend auf dem Γ -ESB im α/β -KOS durch. Die in [131] präsentierten Ergebnisse offenbaren eine gute und schnelle Konvergenz, allerdings nur in einem stationären Betriebspunkt. Erwähnenswert ist die Ermittlung der initialen Rauschmatrizen durch ein stark vereinfachtes Verfahren. Dieses ist jedoch nur für blockgetaktete Spannungsformen gültig und daher nicht auf Antriebe mit modernen Umrichtern zu übertragen. Laroche et. al. entwickeln in [132] basierend auf einer Konditionierungszahl ein spezielles Testprofil mit alternierendem Drehzahlverlauf. Dieses ist jedoch eher für Konditionierungsläufe geeignet und repräsentiert keinen realen Betrieb der Maschine. Eine Untersuchung der OPI von dynamischem Parameterverhalten erfolgt hingegen nicht.

Auch auf dem T-ESB im α/β -KOS basierende Modelle werden in bestehender Literatur verwendet [133], [134], [135]. Loron identifiziert in [133] die direkten elektrischen Parameter bei Nennlast. Die Verbesserung der Anregung erfolgt durch den Betrieb entlang eines nicht realitätsnahen alternierenden Drehzahlprofils. Zusätzlich werden die Eingangssignale durch ein Bessel-Filter aufbereitet. Zur Reduzierung der Parameteranzahl ist jedoch die Annahme der Streuinduktivitäten von Nöten, was die Nutzung des T-ESB obsolet erscheinen lässt. Loron validiert die Ergebnisse schließlich unabhängig mit Hilfe eines zusätzlichen Drehmomentmodells, das jedoch in seiner einfachsten Form nicht alle zu identifizierenden Parameter enthält. Unter ähnlichen Bedingungen schlägt Jaramillo in [134] die Nutzung eines alternativen Modells vor, das nur die Stator- und Rotorflusskomponenten als Zustandgrößen enthält. Zur Filterung dient hierbei ein Butterworth-Filter erster Ordnung. Der Fokus liegt jedoch auf einer Nutzung als vollwertiger Flussbeobachter. Die Auswirkung der identifizierten Parameteranzahl auf die Performanz der OPI thematisieren Buchholz et al. in [135]. Dabei erfolgt ein Vergleich verschiedener Konfigurationen des Zustandsvektors. Es zeigt sich, dass die Art und Anzahl der Parameter erheblichen Einfluss auf die Performanz der OPI hat. Die experimentellen Ergebnisse erheben die Autoren jedoch anhand eines speziellen Testprofils, weswegen keine Analogie zu einer realen Anwendung gegeben ist.

Auch die Anwendung des UKF-Algorithmus zur Vermeidung von Linearisierungsproblemen untersuchen diverse Arbeiten [136], [137], [138]. Eine Besonderheit in [136] ist die Strategie

der Dual-Filterung. Dabei betreiben Lesic et al. im Gegensatz zu den zuvor aufgezählten Methoden der Joint-Filterung zwei separate KF parallel, um den Rechenaufwand mit Hilfe kleinerer Modellmatrizen zu reduzieren. Simulative und experimentelle Ergebnisse zeigen jedoch keinen wesentlichen quantitativen Unterschied des Fehlers im Vergleich zum EKF. Der benötigte Abstimmungsaufwand für die beiden parallelen Filter, sowie die Auswirkungen auf die Robustheit des Verfahrens in Echtzeitsystemen sind jedoch kritisch zu hinterfragen. Weitere Vergleiche von EKF und UKF liefern Yildiz et al. in [137] und Mansour et al. in [138]. Beide belegen die deutlich höhere Berechnungszeit des UKF-Algorithmus. In Bezug auf die Zustandschätzung zur sensorlosen Regelung liefern EKF und UKF auch nach Yildiz sehr ähnliche Ergebnisse [137]. Aufgrund der signifikanten Unterschiede in den Berechnungszeiten empfehlen die Autoren die Nutzung des EKF. Zum selben Schluss kommen Mansour et al. in [138] mit inkludierter OPI anhand einer simulativen Analyse. Dabei visualisieren sie die negativen Auswirkungen durch Erhöhung der Parameteranzahl anhand mehrerer Identifikationsläufe. Jedoch ist das Testprofil auch hier stark vereinfacht und weist keine wirkliche Dynamik auf.

Der erfasste Stand der Technik zeigt, dass die OPI anhand erweiterter KF sowohl zur Verbesserung von Beobachtereigenschaften als auch zur reinen Parameteridentifikation einsetzbar ist. In Bezug auf die Zielstellung der vorliegenden Arbeit sind die zur Validierung genutzten Testprofile jedoch nicht ausreichend aussagekräftig. In vielen Fällen erfolgt diese lediglich in einem stationären Betriebspunkt, in diversen weiteren basierend auf sprungförmigen Parameter bzw. Zustandsgrößenänderungen. Das dynamische Verhalten des Antriebs in einem automobilen Umfeld ist dadurch nicht abgebildet, weswegen die Performanz der Algorithmen hinsichtlich eines Einsatzes in solchen Systemen nicht bewertbar ist. Diese Untersuchungen sind jedoch gerade aufgrund der sensiblen Parametrisierung der Rauschgrößen des KF essenziell.

Darüber hinaus betrachten die meisten Arbeiten den Einfluss der magnetischen Sättigung nur spärlich, indem die induktiven Parameter durch offline identifizierte Datensätze bei der OPI vorgegeben sind. Die Fähigkeit der KF-Algorithmen, das dynamische Sättigungsverhalten zu identifizieren, ist daher im hier betrachteten Umfeld zu analysieren.

Gerade bei der Identifikation aller Parameter wird nach Stand der Technik oft eine zusätzliche Filterung der Messsignale implementiert. Aufgrund des ohnehin bereits größeren Rechenaufwands des EKF und UKF im Vergleich zum RLS-Algorithmus, ist die Implementierung des Filters im Hinblick auf die Echtzeitimplementierung bei knappen Rechenressourcen kritisch zu betrachten. Die durchgeführten Untersuchungen in der vorliegenden Arbeit erfolgen daher ohne Filterung der Messsignale.

Im Hinblick auf die angestrebte Diagnoseanwendung muss die Analyse von EKF und UKF nach den zuvor genannten Kriterien erweitert werden. Dazu erfolgt zunächst die Vorstellung möglicher Identifikationsmodelle und eine im Vergleich zu Abs. 4.3 ausgedehnte theoreti-

sche Beobachtbarkeitsanalyse für das nichtlineare ZRM. Analog zum Vorgehen im Fall des RLS-Algorithmus in Abs. 4.4 erfolgen nach der Implementierung detaillierte simulative und experimentelle Untersuchungen anhand verschiedener Testprofile. Zur Vergleichbarkeit mit den Ergebnissen des RLS-Algorithmus wird auch hierbei der nichtlineare Spannungsfehler des Umrichters berücksichtigt.

5.2 Identifikationsmodelle Kalman-Filter

Die Identifikationsmodelle für erweiterte KF ergeben sich direkt aus der Zustandsraumbeschreibung des zu identifizierenden Systems. Im Vergleich zu den aufwendigen Herleitungen der Modelle im Fall des RLS-Algorithmus muss hier lediglich eine Erweiterung des Zustandsvektors um die zu schätzenden Parameter erfolgen:

$$\begin{aligned}\hat{\mathbf{x}}_{\text{ext}} &= [\hat{\mathbf{x}} \quad \hat{\boldsymbol{\theta}}]^T \\ \hat{\boldsymbol{\theta}} &= [\hat{\theta}_1 \quad \dots \quad \hat{\theta}_n]^T.\end{aligned}$$

Das nichtlineare ZRM ergibt sich entsprechend zu:

$$\dot{\hat{\mathbf{x}}}_{\text{ext}} = \begin{bmatrix} \dot{\hat{\mathbf{x}}} \\ \dot{\hat{\boldsymbol{\theta}}} \end{bmatrix} = \begin{bmatrix} \mathbf{A}(\hat{\boldsymbol{\theta}}) & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \cdot \begin{bmatrix} \hat{\mathbf{x}} \\ \hat{\boldsymbol{\theta}} \end{bmatrix} + \begin{bmatrix} \mathbf{B}(\hat{\boldsymbol{\theta}}) \\ \mathbf{0} \end{bmatrix} \cdot \mathbf{u}. \quad (5.2)$$

Durch die geschlossene Form des ZRM und die fehlenden algebraischen Herleitungsschritte sind keine Annahmen bezüglich der Drehzahländerung erforderlich. Daher ist die Unterscheidung in stationäre und dynamische Identifikationsmodelle, wie in Abs. 4.2, nicht notwendig. Wie der Stand der Technik zeigt, ist die Zustands- und Parameteridentifikation im rotorflussorientierten d/q-KOS für optimierte Regelverfahren weit verbreitet. Um die bereits erwähnte Fehleranfälligkeit im Zusammenhang mit der Schätzung des Rotorflusswinkels zu verhindern, werden wie auch bei der Analyse des RLS-Algorithmus ausschließlich Modelle im α/β -KOS berücksichtigt.

Die Anzahl der Schätzparameter $\hat{\boldsymbol{\theta}}$ ist dabei theoretisch frei wählbar. Praktisch steigt der Rechenaufwand jedoch durch die wachsende Dimension der zu verarbeitenden Matrizen mit jedem zusätzlichen Parameter signifikant. Zusätzlich verschlechtert sich die Konditionierung und damit die Robustheit der Identifikation zunehmend. Um nichtlineare Nebenbedingungen wie im Fall des vollständigen Regressionsmodells in Abs. 4.2 zu verhindern, ist es sinnvoll, eine Überbestimmung des ZRM zu verhindern. Die Anzahl der Identifikationsparameter sollte daher höchstens der Parameteranzahl des zugehörigen ESB entsprechen. Die tatsächlich gewählte Art und Anzahl der zu identifizierenden Parameter ist in Betracht des individuellen Identifikationsproblems abzuwägen. Des Weiteren hat die Zusammensetzung der einzelnen Parameter in $\hat{\boldsymbol{\theta}}$ direkten Einfluss auf die nichtlineare Struktur des gesamten ZRM. Allgemein

ist die große Flexibilität bei der Modellwahl jedoch als Vorteil erweiterter KF-Strukturen gegenüber dem RLS-Algorithmus zu werten.

Zur Festlegung von $\hat{\boldsymbol{\theta}}$ lautet die Annahme zunächst, dass alle Parameter des ZRM (2.101) basierend auf dem Γ -ESB zu identifizieren sind. Dabei ergibt sich die intuitivste Konfiguration durch die direkte Identifikation der vier ESB Parameter:

$$\hat{\boldsymbol{\theta}}_{\text{dir}} = [\hat{\theta}_1 \quad \hat{\theta}_2 \quad \hat{\theta}_3 \quad \hat{\theta}_4]^T = [\hat{L}_\sigma \quad \hat{L}_m \quad \hat{R}_r \quad \hat{R}_s]^T. \quad (5.3)$$

Die nichtlineare Modellgleichung der ASM ergibt sich mit (5.3) und (2.101) nach dem Schema von (5.2) wie folgt:

$$\begin{bmatrix} \dot{i}_s^\alpha \\ \dot{i}_s^\beta \\ \dot{\Psi}_r^\alpha \\ \dot{\Psi}_r^\beta \\ \dot{\hat{\boldsymbol{\theta}}}_{\text{dir}} \end{bmatrix} = \begin{bmatrix} -\frac{\hat{\theta}_4 + \hat{\theta}_3}{\hat{\theta}_1} & 0 & \frac{\hat{\theta}_3}{\hat{\theta}_1 \hat{\theta}_2} & \omega_{\text{el}} \cdot \frac{1}{\hat{\theta}_1} \\ 0 & -\frac{\hat{\theta}_4 + \hat{\theta}_3}{\hat{\theta}_1} & -\omega_{\text{el}} \cdot \frac{1}{\hat{\theta}_1} & \frac{\hat{\theta}_3}{\hat{\theta}_1 \hat{\theta}_2} \\ \hat{\theta}_3 & 0 & -\frac{\hat{\theta}_3}{\hat{\theta}_2} & -\omega_{\text{el}} \\ 0 & \hat{\theta}_3 & \omega_{\text{el}} & -\frac{\hat{\theta}_3}{\hat{\theta}_2} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} \end{bmatrix} \cdot \begin{bmatrix} i_s^\alpha \\ i_s^\beta \\ \Psi_r^\alpha \\ \Psi_r^\beta \\ \hat{\boldsymbol{\theta}}_{\text{dir}} \end{bmatrix} + \begin{bmatrix} \frac{1}{\hat{\theta}_1} & 0 \\ 0 & \frac{1}{\hat{\theta}_1} \\ 0 & 0 \\ 0 & 0 \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \cdot \begin{bmatrix} u_s^\alpha \\ u_s^\beta \\ 0 \\ 0 \\ \mathbf{0} \end{bmatrix}. \quad (5.4)$$

Durch die direkte Identifikation der ESB Parameter weist (5.4) eine komplexe nichtlineare Parameterstruktur auf. Daher bietet es sich an, die Komplexität zu reduzieren, indem die Wahl der Schätzparameter auf die Struktur der Systemmatrix $\mathbf{A}(\hat{\boldsymbol{\theta}})$ angepasst wird. Eine wichtige Anforderung ist jedoch, dass die Berechnung der direkten Parameter des ESB aus den Identifikationsparametern ohne Nebenbedingung möglich ist. Mit Hilfe des optimierten Parametervektors

$$\hat{\boldsymbol{\theta}}_{\text{opt}} = [\hat{\theta}_1 \quad \hat{\theta}_2 \quad \hat{\theta}_3 \quad \hat{\theta}_4]^T = \left[\frac{1}{\hat{L}_\sigma} \quad \frac{\hat{R}_r}{\hat{L}_m} \quad \hat{R}_r \quad \hat{R}_s + \hat{R}_r \right]^T \quad (5.5)$$

lässt sich die Komplexität des nichtlinearen ZRM signifikant reduzieren:

$$\begin{bmatrix} \dot{i}_s^\alpha \\ \dot{i}_s^\beta \\ \dot{\Psi}_r^\alpha \\ \dot{\Psi}_r^\beta \\ \dot{\hat{\boldsymbol{\theta}}}_{\text{opt}} \end{bmatrix} = \begin{bmatrix} -\hat{\theta}_4 \cdot \hat{\theta}_1 & 0 & \hat{\theta}_2 \cdot \hat{\theta}_1 & \omega_{\text{el}} \cdot \hat{\theta}_1 \\ 0 & -\hat{\theta}_4 \cdot \hat{\theta}_1 & -\omega_{\text{el}} \cdot \hat{\theta}_1 & \hat{\theta}_2 \cdot \hat{\theta}_1 \\ \hat{\theta}_3 & 0 & -\hat{\theta}_2 & -\omega_{\text{el}} \\ 0 & \hat{\theta}_3 & \omega_{\text{el}} & -\hat{\theta}_2 \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} \end{bmatrix} \cdot \begin{bmatrix} i_s^\alpha \\ i_s^\beta \\ \Psi_r^\alpha \\ \Psi_r^\beta \\ \hat{\boldsymbol{\theta}}_{\text{opt}} \end{bmatrix} + \begin{bmatrix} \hat{\theta}_1 & 0 \\ 0 & \hat{\theta}_1 \\ 0 & 0 \\ 0 & 0 \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \cdot \begin{bmatrix} u_s^\alpha \\ u_s^\beta \\ 0 \\ 0 \\ \mathbf{0} \end{bmatrix}. \quad (5.6)$$

Aus den Elementen von $\hat{\boldsymbol{\theta}}_{\text{opt}}$ lassen sich die ESB Parameter ohne Nebenbedingung berechnen:

$$L_\sigma = \frac{1}{\hat{\theta}_1}, \quad L_m = \frac{\hat{\theta}_3}{\hat{\theta}_2}, \quad R_r = \hat{\theta}_3, \quad R_s = \hat{\theta}_4 - \hat{\theta}_3. \quad (5.7)$$

In den nachfolgenden Untersuchungen werden beide vorgestellten Identifikationsmodelle in Betracht gezogen und analysiert.

Diskretisierung des Zustandsraummodells

Zur Implementierung des KF-Algorithmus ist die Diskretisierung des kontinuierlichen ZRM erforderlich. Mit der numerischen Diskretisierung durch die herkömmliche Euler-Methode geht zur Sicherstellung der Stabilität laut Loron die Forderung nach sehr geringen Abtastzeiten einher [133]. Bei der Taylorreihenentwicklung zweiter Ordnung hingegen ist die Stabilität, aufgrund der genaueren Modellapproximation, bereits bei höheren Abtastzeiten gegeben. Da die Diskretisierung keinen Einfluss auf die erweiterte Modellstruktur hat, erfolgt diese basierend auf dem linearen ZRM (2.101). Das diskretisierte ZRM der Form

$$\mathbf{x}[k+1] = \mathbf{A}_d \cdot \mathbf{x}[k] + \mathbf{B}_d \cdot \mathbf{u}[k] \quad (5.8)$$

ergibt sich mit der Transitionsmatrix $e^{\mathbf{A} \cdot T}$ unter der Annahme, dass die Eingangsgrößen innerhalb einer Abtastperiode T unverändert bleiben. Die Taylorapproximation zweiter Ordnung der Zustands- und Systemmatrix errechnet sich dann mit Hilfe der folgenden Gleichungen [139]:

$$\mathbf{A}_d = e^{\mathbf{A} \cdot T} \approx \mathbf{I} + \mathbf{A} \cdot T + \frac{(\mathbf{A} \cdot T)^2}{2}, \quad (5.9a)$$

$$\mathbf{B}_d = \mathbf{A}^{-1} \cdot (\mathbf{A} - \mathbf{I}) \cdot \mathbf{B} \approx T \cdot \left(\mathbf{I} + \frac{\mathbf{A} \cdot T}{2} \right) \cdot \mathbf{B}. \quad (5.9b)$$

Auf die Darstellung des diskretisierten ZRM wird aus Übersichtsgründen verzichtet.

5.3 Beobachtbarkeitsanalyse

Die Möglichkeit einer vollständigen Systemidentifikation ist nicht unbedingt in jedem physikalischen System gegeben. Um die Zustände und Parameter mittels KF über den gesamten Betriebsbereich identifizieren zu können, muss das zugrundeliegende ZRM in jedem einzelnen Betriebspunkt beobachtbar sein. Analog zur Bewertung der Modelle in Abs. 4.3.1 anhand einer Konditionierungszahl der Regressionsmatrix, lässt sich die Konditionierung des Identifikationsproblems im Fall des KF mit Hilfe der Beobachtbarkeitsmatrix des ZRM bemessen. Dabei handelt es sich um ein rein theoretisches Kriterium, da die praktische Identifizierbarkeit von vielen weiteren, nicht von der Modellierung erfassten Aspekten abhängt. Die Inhalte dieses Abschnitts wurden bereits in [18] publiziert.

Die Theorie der Beobachtbarkeit findet sich in zahlreichen Werken für systemtheoretische Grundlagen, wie beispielsweise [21], [39], [40]. Im Allgemeinen ist ein System beobacht-

bar, wenn jeder Zustand des Systems in einem endlichen Zeitbereich aus der Kenntnis der Eingangs- und Ausgangsgrößen bestimmt werden kann. Die Beobachtbarkeit eines linearen Systems in der Zustandsraumdarstellung (2.99) mit der Systemmatrix $\mathbf{A} \in \mathbb{R}^{n \times n}$ und der Ausgangsmatrix $\mathbf{C} \in \mathbb{R}^{q \times n}$ ergibt sich mit Hilfe der folgenden Beobachtbarkeitsmatrix [21]:

$$\mathcal{O}_{\text{lin}} = \begin{bmatrix} \mathbf{C} \\ \mathbf{C} \cdot \mathbf{A} \\ \mathbf{C} \cdot \mathbf{A}^2 \\ \vdots \\ \mathbf{C} \cdot \mathbf{A}^{n-1} \end{bmatrix} \in \mathbb{R}^{n \cdot q \times n}. \quad (5.10)$$

Die theoretische Beobachtbarkeit des linearen ZRM ist gegeben, sofern die Matrix \mathcal{O}_{lin} vollen Rang aufweist [140]. Nur bei vollem Rang ist die eindeutige Rekonstruktion der nicht messbaren Systemzustände aus den Ein- und Ausgangsgrößen möglich. Ist dieses Kriterium nicht erfüllt, kommt es zu einem Rangabfall und das System ist nur teilweise oder gar nicht beobachtbar.

Die OPI mittels erweiterter KF basiert auf einem nichtlinearen ZRM nach dem Schema von (5.2). Darin zeigt die Systemmatrix $\mathbf{A}(\hat{\theta})$ eine Abhängigkeit vom Zustandsvektor $\hat{\mathbf{x}}_{\text{ext}}$, die wiederum mit der linearen Beobachtbarkeitsmatrix (5.10) nicht abbildbar ist. Daher zeigen Hermann et al. in [141] einen Ansatz zur Berechnung der Beobachtbarkeit eines nichtlinearen ZRM mit Hilfe von Lie-Ableitungen. Basierend darauf wird nachfolgend eine Beobachtbarkeitsanalyse über den dynamischen WLTP-Zyklus durchgeführt.

Die Beobachtbarkeitsanalyse eines nichtlinearen ZRM basierend auf Lie-Ableitungen erfolgte bereits in diversen Arbeiten: Zur Verbesserung der KF-Eigenschaften im Bereich Computer Vision [142], zur Bewertung der Beobachtbarkeit geschätzter Zustände oder einzelner Parameter bei der sensorlosen Regelung der ASM [143]–[145], zur Verbesserung der Anregung mittels zusätzlicher Anregungssignale [132] und zur Fehlerdiagnose bei Rotorstabbrüchen [146]. Die Indizierung erfolgte dabei in [143]–[145] basierend auf der Determinante bzw. in [146] auf den Singulärwerten der nichtlinearen Beobachtbarkeitsmatrix.

Aufgrund der ganzheitlichen und eindeutigen Bewertung des gesamten ZRM anhand eines Beobachtbarkeitsindex, ist der von Nakhaeinejad et al. in [146] gewählte Ansatz am besten für die in der vorliegenden Arbeit durchzuführenden Analysen geeignet. Ziel ist die Bewertbarkeit der theoretischen Konditionierung der OPI mittels erweiterter KF-Algorithmen in einem dynamischen Betriebsumfeld.

Nach Herman et al. [141], ist für ein nichtlineares System der Form

$$\begin{aligned} \dot{\mathbf{x}}_{\text{ext}} &= \mathbf{f}(\mathbf{x}_{\text{ext}}, \mathbf{u}) \\ \mathbf{y} &= \mathbf{g}(\mathbf{x}_{\text{ext}}) \end{aligned}$$

mit $\mathbf{x}_{\text{ext}} \in \mathbb{R}^n$ und $\mathbf{y} \in \mathbb{R}^q$, die lokale Beobachtbarkeitsmatrix $\mathcal{O}_{\text{nonlin}} \in \mathbb{R}^{q \times n}$ als Jacobi-matrix des Vektors \mathbf{L} definiert:

$$\mathcal{O}_{\text{nonlin}} = \frac{\partial \mathbf{L}}{\partial \mathbf{x}_{\text{ext}}}. \quad (5.12)$$

Der Vektor \mathbf{L} besteht aus den Lie-Ableitungen des nichtlinearen Systems:

$$\mathbf{L} = \begin{bmatrix} L_f^0 g \\ L_f^1 g \\ \vdots \\ L_f^{n-1} g \end{bmatrix} \rightarrow \begin{aligned} L_f^0 g &= g \\ L_f^1 g &= \frac{\partial g}{\partial \mathbf{x}_{\text{ext}}} \bullet \mathbf{f} \\ L_f^n g &= L_f \left(L_f^{n-1} g \right). \end{aligned} \quad (5.13)$$

Zum Vergleich der tatsächlichen Konditionierung des Identifikationsproblems in verschiedenen Betriebspunkten wird analog zum RLS-Algorithmus ein Beobachtbarkeitsindex eingeführt, wie bereits in [146] vorgeschlagen. Dieser Index ζ ist als das Verhältnis zwischen dem maximalen und minimalen Singulärwert von $\mathcal{O}_{\text{nonlin}}$ definiert,

$$\zeta = \frac{s_{\max}}{s_{\min}} \quad (5.14)$$

wobei s_{\max} und s_{\min} aus der Singulärwertzerlegung resultieren, siehe exemplarisch [139]. Die Singulärwerte sind vergleichbar mit den Eigenwerten des linearen Systems (2.99). Zur Singulärwertzerlegung wird die nichtlineare Beobachtbarkeitsmatrix wie folgt faktorisiert:

$$\mathcal{O}_{\text{nonlin}} = \mathbf{U} \cdot \mathbf{S} \cdot \mathbf{V}^T. \quad (5.15)$$

Darin bestehen \mathbf{U} und \mathbf{V}^T aus den linken bzw. rechten Singulärvektoren. Die eigentlichen Singulärwerte formen sich auf der Hauptdiagonale der Matrix \mathbf{S} . Wie im Fall des linearen ZRM ist die vollständige Beobachtbarkeit gegeben, sofern für alle Singulärwerte $s_1 \dots s_n > 0$ gilt. Auch hier ist das Identifikationsproblem am besten konditioniert, wenn alle Singulärwerte in der selben Größenordnung liegen und mit Blick auf (5.14) der Beobachtbarkeitsindex möglichst klein ist.

Der Vollständigkeit wegen erfolgt an dieser Stelle der Hinweis auf eine formelle Gegebenheit bezüglich der mathematischen Beweisführung. Während die Beobachtbarkeitsmatrix für ein lineares System einen globalen Beweis liefert, ist im Fall des nichtlinearen ZRM lediglich ein lokaler Beweis möglich [139]. Daher erfolgt die Berechnung von \mathbf{L} und ζ quasistatisch in jedem Abtastschritt.

Die Anzahl und Art der zu identifizierenden Parameter hat auch bei der OPI mittels erweitertem KF einen entscheidenden Einfluss auf die Performanz. Außerdem ändert sich der Beobachtbarkeitsindex in Abhängigkeit des aktuellen Betriebspunkts. Daher werden die nach-

folgenden Untersuchungen, analog zu Abs. 4.3.1, entlang des WLTP-Zyklus durchgeführt, siehe Abb. 5.1(a). Zur Simulation der sättigungsbedingten Parameteränderungen erfolgt der Betrieb basierend auf der in Abs. 3.2 beschriebenen Sollstromtrajektorie.

Um die Auswirkungen der zusätzlichen Parameteridentifikation isoliert zu betrachten, erfolgt zunächst die Berechnung eines Beobachtbarkeitsindex des nicht erweiterten linearen ZRM basierend auf dem Γ -ESB. In allen weiteren Simulationsläufen ist damit eine Normalisierung der Ergebnisse mit Bezug auf das lineare ZRM möglich. Dabei variiert die Modellkonfiguration durch die Änderung der Anzahl und Art der zu identifizierenden Parameter.

Beobachtbarkeit des Γ -ESB

Um die Änderung des Beobachtbarkeitsindex aufgrund des erweiterten Zustandsvektors zu fokussieren, ist zunächst die Beobachtbarkeit des linearen ZRM (2.101) zu untersuchen. Zusätzlich liefert diese Analyse Informationen über die allgemeine Beobachtbarkeit des Systems ohne Parameteridentifikation. Dazu erfolgt die Aufstellung der linearen Beobachtbarkeitsmatrix basierend auf der Systemmatrix \mathbf{A} und der Ausgangsmatrix \mathbf{C} nach (5.10):

$$\mathcal{O}_{\text{lin}} = \begin{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ -\frac{R_s+R_r}{L_\sigma} & \omega_k & \frac{R_r}{L_\sigma L_m} & \frac{\omega_{el}}{L_\sigma} \\ -\omega_k & -\frac{R_s+R_r}{L_\sigma} & -\frac{\omega_{el}}{L_\sigma} & \frac{R_r}{L_\sigma L_m} \end{bmatrix} \\ \mathbf{C} \cdot \mathbf{A}^2 \in \mathbb{R}^{2 \times 4} \\ \mathbf{C} \cdot \mathbf{A}^3 \in \mathbb{R}^{2 \times 4} \end{bmatrix}. \quad (5.16)$$

Da die Terme im unteren Teil der Matrix sehr komplexe Ausdrücke enthalten, wird auf deren ausführliche Darstellung verzichtet. Aufgrund der Matrixdimension von 8×4 beträgt der maximale Rang 4. Laut Papula entspricht der Rang einer Matrix der höchsten Ordnung aller von null verschiedenen Unterdeterminanten [147]. Daher lässt sich die globale Beobachtbarkeit anhand der in (5.16) hervorgehobenen Submatrix bestätigen:

$$\det(\mathcal{O}_{\text{lin,sub}}) = \frac{1}{(L_\sigma)^2} \left[\left(\frac{R_r}{L_m} \right)^2 + (\omega_{el})^2 \right] > 0. \quad (5.17)$$

Da die Maschinenparameter nur positive Werte annehmen, hat die Matrix \mathcal{O}_{lin} immer vollen Rang. Allerdings wird die Determinante mit abnehmender Geschwindigkeit sehr klein und nähert sich einem Rangabfall. Selbst bei einer Geschwindigkeit $\omega_{el} = 0$ bleibt das System jedoch beobachtbar. Der zugehörige Beobachtbarkeitsindex des linearen ZRM ζ_0 entlang des WLTP-Zyklus ist in Abb. 5.1(b) ersichtlich.

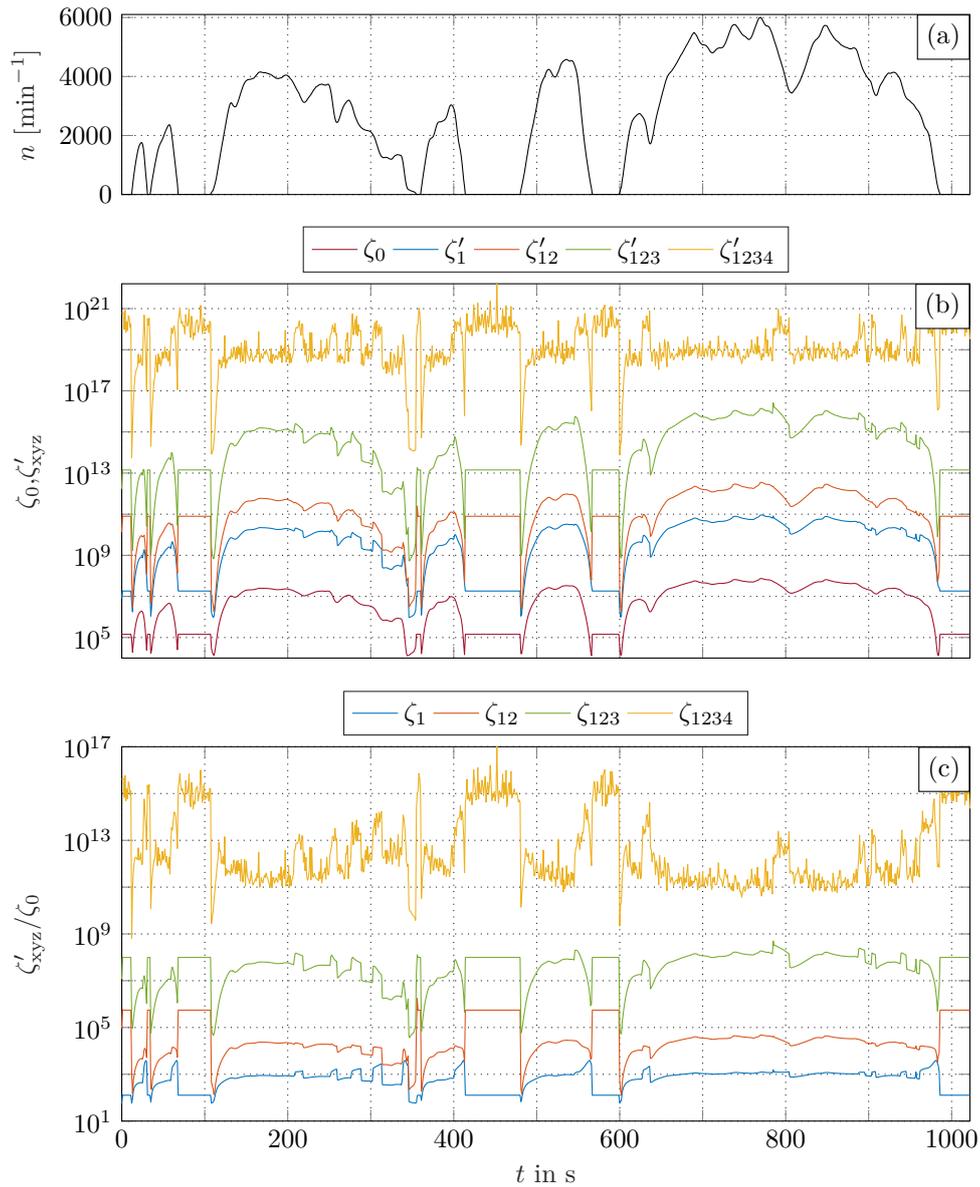


Abbildung 5.1: (a) WLTP-Zyklus Class1 skaliert auf den genutzten Drehzahlbereich der ASM. (b) Beobachtbarkeitsindex des linearen ZRM ζ_0 und des erweiterten nichtlinearen ZRM mit variierender Anzahl an Identifikationsparametern ζ' . (c) Beobachtbarkeitsindex des erweiterten nichtlinearen ZRM mit variierender Anzahl an Identifikationsparametern bezogen auf den Beobachtbarkeitsindex des linearen ZRM ζ_0 . [18]

Beobachtbarkeit der Γ -ESB basierten Identifikationsmodelle

Der nächste Schritt ist die Beobachtbarkeitsanalyse verschiedener Konfigurationen des nichtlinearen ZRM für die Parameteridentifikation mit erweiterten KF. Die Berechnung der nichtlinearen Beobachtbarkeitsmatrix (5.12) einschließlich der Lie-Ableitungen (5.13) erfolgt dazu in jedem Abtastschritt entlang des WLTP-Zyklus in Abb. 5.1(a). Daraus lassen sich die Singulärwerte \mathbf{S} mit (5.15) und der entsprechende Beobachtbarkeitsindex (5.14) bestimmen, wodurch sich ein quasistatischer Verlauf ergibt.

Zur Parameteridentifikation sind verschiedene Modellkonfigurationen denkbar, wobei theoretisch jede Kombination von Identifikationsparametern gültig ist. Aufgrund heuristischer Analysen ergeben sich die in Abs. 5.2 vorgestellten vollständigen Parametervektoren (5.3) und (5.5) als sinnvolle Konfigurationen. Die Arten der definierten Parameter haben unterschiedliche Sensitivitäten auf das Identifikationsmodell und damit andere Auswirkungen auf den Beobachtbarkeitsindex. Auch die Anzahl der Identifikationsparameter ist variierbar und hat einen entscheidenden Einfluss auf die Konditionierung des Identifikationsproblems. Um die Auswirkungen unterschiedlicher Modellkonfigurationen auf den Beobachtbarkeitsindex zu analysieren, erfolgt ein Vergleich aller möglichen Kombinationen des Parametervektors (5.5). Die Erkenntnisse aus der Untersuchung des alternativen Parametervektors (5.3) sind sehr ähnlich und daher aus Übersichtgründen nicht dargestellt. Der Index von ζ_{xyz} beschreibt die jeweils betrachtete Parameterkombination $\hat{\theta}$ aus (5.5).

Einfluss der Parameteranzahl: Die Anzahl der identifizierten Parameter beeinflusst den Beobachtbarkeitsindex signifikant, wie Abb. 5.1(b) zeigt. Im mittleren Teil sind die absoluten Werte des Beobachtbarkeitsindex für das lineare ZRM ζ_0 , sowie für jeweils ein nichtlineares ZRM zur OPI mit einem ζ'_1 , zwei ζ'_{12} , drei ζ'_{123} und vier ζ'_{1234} zu identifizierenden Parametern dargestellt. Erwartungsgemäß verschlechtert sich die Beobachtbarkeit mit zunehmender Parameteranzahl. Beginnend mit der OPI von nur einem Parameter, verändert sich ζ'_1 bereits um mehrere Größenordnungen, wie die logarithmisch geteilte Ordinate offenbart. Während der Abstand zwischen der Identifizierung eines ζ'_1 und zwei Parametern ζ'_{12} vergleichsweise gering ist, führt die Identifikation von drei Parametern ζ'_{123} zu einem deutlich schlechteren Beobachtbarkeitsindex. Im Fall von vier identifizierten Parametern steigt ζ'_{1234} nochmals um einige Größenordnungen und das Identifikationsproblem erweist sich als sehr schlecht konditioniert.

Um den Einfluss der zusätzlichen Parameteridentifikation auf den Beobachtbarkeitsindex unabhängig vom linearen ZRM zu untersuchen bietet sich an, die Indizes der nichtlinearen ZRM in Relation zu ζ_0 zu betrachten:

$$\zeta_{xyz} = \frac{\zeta'_{xyz}}{\zeta_0}. \quad (5.18)$$

Die entsprechenden Ergebnisse zeigt Abb. 5.1(c). Analog dazu werden alle nachfolgenden Ergebnisse in normalisierter Form nach (5.18) angegeben.

Einfluss verschiedener Parameterkombinationen: Neben der Anzahl beeinflussen auch die Kombinationen und Typen der identifizierten Parameter den Beobachtbarkeitsindex.

Abbildung 5.2(b) zeigt den Beobachtbarkeitsindex für verschiedene Modelle $\zeta_1 - \zeta_4$, die jeweils einen Parameter $\hat{\theta}_1 - \hat{\theta}_4$ aus (5.5) identifizieren. Dabei liegen die Beobachtbarkeitsindizes aller Modelle grundsätzlich in der gleichen Größenordnung. In Bereichen des Fahrbetriebs

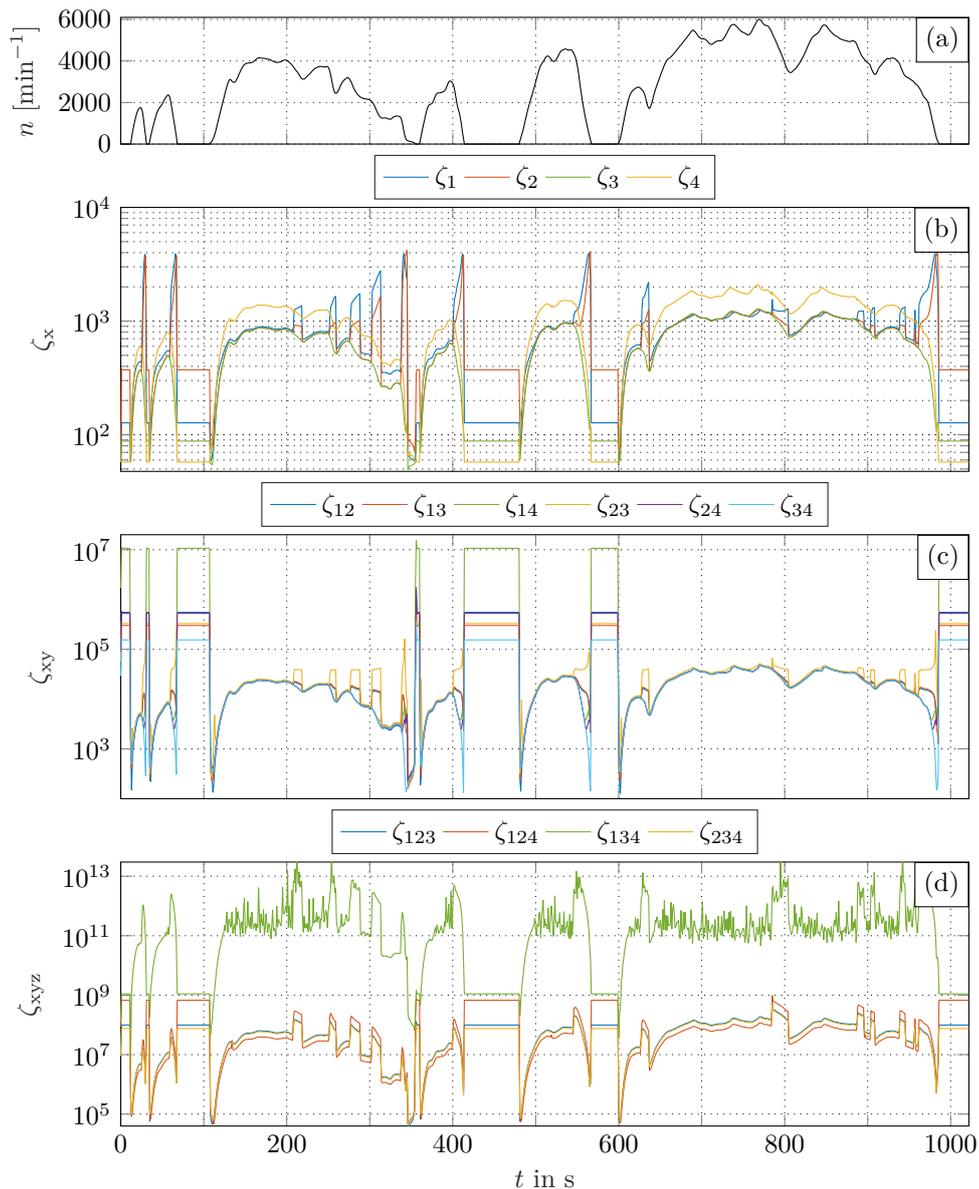


Abbildung 5.2: (a) WLTP-Class1 skaliert auf den Drehzahlbereich der ASM. (b) Beobachtbarkeitsindex des erweiterten nichtlinearen ZRMs mit einem identifizierten Parameter ζ_x . (c) Beobachtbarkeitsindex des erweiterten nichtlinearen ZRMs mit zwei identifizierten Parametern ζ_{xy} . (d) Beobachtbarkeitsindex des erweiterten nichtlinearen ZRMs mit drei identifizierten Parametern ζ_{xyz} . [18]

mit $n \neq 0$ ist das $\hat{\theta}_4$ -Modell am schlechtesten beobachtbar, während die Beobachtbarkeit der anderen Modelle annähernd gleich ist. Im Stillstandsbetrieb mit $n = 0$ ist das $\hat{\theta}_4$ -Modell hingegen am besten beobachtbar. Das $\hat{\theta}_3$ -Modell ist etwas schlechter, während die $\hat{\theta}_1$ - und $\hat{\theta}_2$ -Modelle am schlechtesten beobachtbar sind. Diese Feststellung lässt sich durch die Art der Parameter begründen. Die Sensitivität des Systems gegenüber rein ohmschen Parametern nimmt mit zunehmender Drehzahl ab und ist im Stillstand am höchsten, siehe ζ_4 für den Fall des Statorwiderstands R_s . Mit zunehmender Frequenz und damit der Drehzahl steigt die Sensitivität der induktiven Parameter, die in $\hat{\theta}_1$ und $\hat{\theta}_2$ enthalten sind. Der Ro-

torwiderstand ist in den vollständig ohmschen Identifikationsparametern $\hat{\theta}_3$ und $\hat{\theta}_4$, sowie im induktiven Parameter $\hat{\theta}_2$ enthalten. Daher liegt ζ_3 zwischen den Beobachtbarkeitsindizes der ZRM mit rein ohmschen bzw. induktiven Identifikationsparametern. Da der Rekuperationsbetrieb nicht berücksichtigt wird, sinkt der Statorstrom in den Verzögerungsphasen des WLTP-Zyklus rapide auf $i_s \approx 0$. Die dadurch nicht mehr vorhandene Anregung des Identifikationsproblems beeinflusst gerade die Beobachtbarkeitsindizes der induktiven Parameter. Die zugehörigen Verläufe ζ_1 und ζ_2 in Abb. 5.2(b) illustrieren diese Problematik durch deutlich sichtbare Ausschläge. Die Beobachtbarkeit der ohmschen Parameter ζ_3 und ζ_4 bleibt davon theoretisch unbeeinflusst. Mit Bezug auf Abb. 3.3(c) lässt sich kein sichtbarer Einfluss des Sättigungsverhaltens der Maschine auf den Beobachtbarkeitsindex feststellen.

Bei zwei identifizierten Parametern aus (5.5) ergeben sich sechs mögliche Modellkonfigurationen, deren jeweilige Beobachtbarkeitsindizes in Abb. 5.2(c) dargestellt sind. Im normalen Fahrbetrieb mit $n \neq 0$ und $i_s \neq 0$ unterscheidet sich die Beobachtbarkeit der ZRM nur unwesentlich. Allerdings zeigen sich einige Ausreißer in ζ_{23} in Betriebspunkten mit hoher Beschleunigung. Im Hinblick auf die Anwendung in realen Fahrzeugen kann dies zu einer sehr schlechten Konditionierung des Systems in Abhängigkeit vom Fahrverhalten des Fahrers führen, da gerade $\hat{\theta}_2 = \hat{R}_r / \hat{L}_m$ durch die Magnetisierungsinduktivität eine hohe Sensitivität gegenüber dem Modell hat. In Verzögerungsphasen mit $i_s = 0$ steigen die Beobachtbarkeitsindizes für die meisten Modellkonfigurationen mehr oder weniger stark. Auch hier sind die rein ohmschen Parameterkombinationen von dieser Veränderung ausgenommen, wie ζ_{34} zeigt. Im Stillstandsbetrieb verschlechtert sich die Beobachtbarkeit zum Teil signifikant. Aufgrund der Kombination verschiedener Parametertypen ist jedoch keine eindeutige physikalische Interpretation möglich.

Abbildung 5.2(d) illustriert die gleichzeitige Identifikation von drei Parametern. Hierbei führt die Kombination θ_{134} zu einem deutlich schlechteren Beobachtbarkeitsindex. Bei dieser Konfiguration wird die Magnetisierungsinduktivität L_m nicht identifiziert. Aufgrund der hohen Sensitivität dieses Parameters gegenüber dem ZRM führt die nichtberücksichtigte Dynamik bei der OPI zu einer Schwächung der Anregung. Die Beobachtbarkeitsindizes der übrigen Modelle liegen in der gleichen Größenordnung. Für einen Vergleich der Beobachtbarkeit zum ZRM basierend auf dem T-ESB sei auf [18] verwiesen.

Die Ergebnisse der Beobachtbarkeitsanalyse erlauben im nachfolgenden Verlauf des Kapitels eine Abschätzung über die Eignung bestimmter Kombinationen von Identifikationsparametern zur OPI. Außerdem lassen sich die Auswirkungen der Anzahl von identifizierten Parametern auf die Performanz der OPI abschätzen.

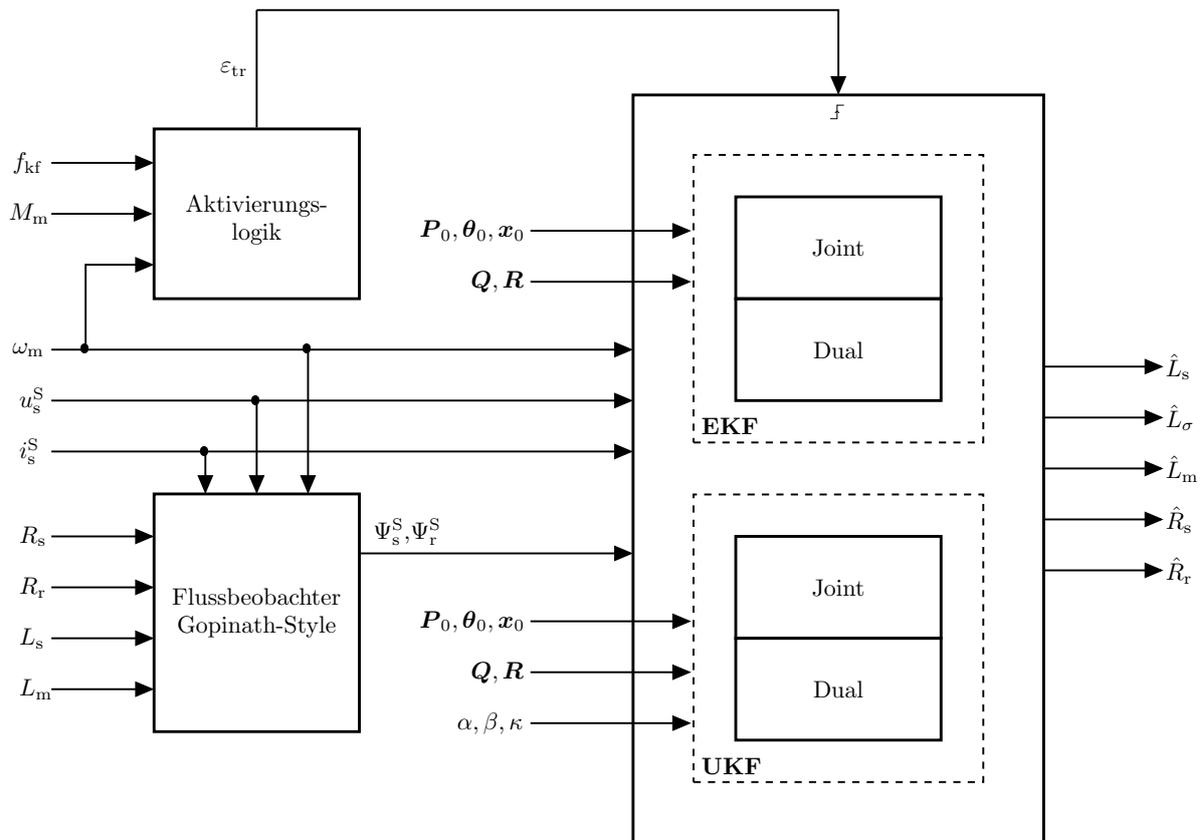


Abbildung 5.3: Übersicht zur Implementierung der erweiterten Kalman-Filter Algorithmen.

5.4 Implementierung und Analyse

Im Fall der erweiterten KF konzentrieren sich die Herausforderungen bei der Implementierung auf den Algorithmus selbst, siehe Abb. 5.3. Im Vergleich zum linearen RLS-Algorithmus ist die echtzeitfähige Umsetzung aufgrund der nichtlinearen Modellstruktur und den dadurch erforderlichen Linearisierungsschritten deutlich aufwendiger. Hingegen ist die Nutzung eines zusätzlichen Filters nicht zwingend erforderlich, da die Rauscheigenschaften der gemessenen Größen bei verhältnismäßiger SNR die Performanz des KF sogar begünstigen können. Außerdem ergeben sich durch die geschlossene Modellstruktur des ZRM im Vergleich zu den Regressionsmodellen des RLS-Algorithmus in Abs. 4.2 keine redundanten Modellgleichungen. Aufgrund dieser Aspekte ist keine Synchronisations- bzw. Umschaltlogik erforderlich. Die Aktivierungslogik basiert daher auf der in (4.40) und (4.41) bzw. (4.42) bereits implementierten Grenzwertlogik und der Steuerung der Updatefrequenz f_{kf} analog zu (4.39) mit $k_f = 1$.

Analog zum RLS-Algorithmus werden bei der Aufbereitung der Eingangs- und Messgrößen die Spannungsverzögerung sowie die Spannungsfehlerkorrektur berücksichtigt. Außerdem erfolgt zur Validierung auch hier die betriebspunktabhängige Nachführung der Referenzwerte.

Grundsätzlich lassen sich die in Abs. 2.1.6 beschriebenen Algorithmen erweiterter KF nach Stand der Technik implementieren. Das EKF nimmt eine Linearisierung des nichtlinearen ZRM in jedem Abtastschritt vor. Die dadurch auftretenden Fehler können bei stark nichtlinearen Systemen zur Divergenz des Algorithmus führen, weswegen das UKF die statistischen Merkmale der Zufallsvariablen direkt aus dem nichtlinearen ZRM bestimmt. Sowohl EKF als auch UKF sind in Form der Joint- und Dual-Filterung nutzbar.

Eine in anderen Anwendungsgebieten verbreitete Maßnahme ist die Begrenzung des zulässigen Bereichs der Schätzwerte durch a priori Informationen, wie [148]–[150] exemplarisch zeigen. Generell ist sowohl die Begrenzung der nicht messbaren Zustände, als auch der geschätzten Parameter möglich. Die Wahrscheinlichkeit einer Divergenz des Algorithmus lässt sich durch diese Maßnahme zwar verringern, jedoch erhöht sich durch das zusätzliche Optimierungsproblem gleichzeitig der Rechenaufwand. Bei ohnehin vergleichsweise hoher Berechnungszeit der KF-Algorithmen ist unter Umständen eine Erhöhung der Taktzeit erforderlich. Entsprechend eignen sich die Begrenzungsmaßnahmen nur bedingt zur Echtzeitemplementierung in eingebetteten Systemen mit stark limitierter Rechenkapazität. Die Funktion der Begrenzungsmaßnahmen wurde durch diverse Voruntersuchungen bestätigt, jedoch hatte deren Nutzung keinerlei Einfluss auf die stationären Ergebnisse der Schätzung. Die schnellere Konvergenzzeit muss demnach gegenüber dem höheren Rechenaufwand abgewägt werden. Im Fall der hier betrachteten elektrischen Maschine existieren in der Regel a priori bestimmte Parametersätze, die zur Initialisierung des KF geeignet sind. Die Identifikationsergebnisse befinden sich dadurch stets in plausiblen Bereichen, weswegen die Parameterbegrenzung nicht erforderlich ist. Ein Einsatz dieser Maßnahme wird daher nicht weiter verfolgt.

Für die nachfolgenden Untersuchungen stellt sich die Frage, wie sich die Performanz der unterschiedlichen Identifikationsmodelle und KF-Algorithmen im Vergleich darstellt. Die erfolgreiche OPI hängt dabei von folgenden Aspekten ab:

- Wahl des Identifikationsmodells und der Art des KF-Algorithmus
- Wahl der Hyperparameter im Fall des UKF
- Initialisierung der nicht messbaren Zustandsgrößen und der zu identifizierenden Parameter
- Genauigkeit des ermittelten Messrauschens und Initialisierung der Kovarianzmatrizen
- Taktfrequenz des Echtzeitsystems bzw. Updatefrequenz des Algorithmus
- Betriebsumfeld und darauf abgestimmte Aktivierungslogik

Im weiteren Verlauf dieses Abschnitts werden zunächst die wesentlichen Herausforderungen bei der Implementierung der erweiterten KF-Algorithmen thematisiert. Anschließend erfolgt sowohl eine simulative als auch experimentelle Analyse. Zur Vergleichbarkeit mit

dem RLS-Algorithmus erfolgt auch hier die Untersuchung des Konvergenzverhaltens anhand vereinfachter Testprofile. Weiterführend wird die Performanz in einem dynamischen Betriebsfeld mit Hilfe des WLTP-Zyklus analysiert.

5.4.1 Implementierung der erweiterten Kalman-Filter

Verglichen mit dem RLS-Algorithmus erweist sich die Implementierung erweiterter KF als besonders aufwendig. Die modellbasierte Softwareentwicklung mit anschließender Erzeugung des echtzeitfähigen Codes durch einen Compiler hat sich als gängige Praxis etabliert. In Bezug auf streng limitierte Rechenkapazität ist eine laufzeitoptimierte Codegenerierung jedoch unabdingbar. Die Modellbasis darf aus diesem Grund keine erweiterten Funktionsblöcke des jeweiligen Simulationstools enthalten. Die Implementierung muss also auf Basisberechnungen basieren. Da die Berechnungszeit im Vergleich zum RLS-Algorithmus höher ist, hängt die Durchführbarkeit der OPI in diesem Fall von den zusätzlich auf dem eingebetteten System implementierten Funktionen ab. Bei zu hoher Laufzeit besteht die Gefahr, dass Diagnosefunktionen aufgrund ihrer niedrigeren Priorisierung nicht ausgeführt werden.

Berechnung der Jacobi-Matrix für das EKF

Bei der Umsetzung des EKF-Algorithmus betrifft diese Einschränkung die erforderliche Berechnung der Jacobi-Matrix zur Linearisierung des ZRM, siehe Abs. 2.1.6. Das vollständige Identifikationsmodell enthält vier Zustände und weitere vier zu identifizierende Parameter. Dadurch ergibt sich eine Jacobi-Matrix mit 64 Elementen, deren Echtzeitberechnung durch eine nicht optimierte Funktion sehr aufwendig ist. Bei genauer Betrachtung offenbart sich jedoch erhebliches Optimierungspotential. Die Jacobi-Matrix des diskreten ZRM lässt sich in vier Teilmatrizen aufteilen:

$$\begin{aligned}
 \mathbf{J}_{\text{jcb}} &= \begin{bmatrix} \mathbf{J}_{\text{jcb},11} & \mathbf{J}_{\text{jcb},12} \\ \mathbf{J}_{\text{jcb},21} & \mathbf{J}_{\text{jcb},22} \end{bmatrix} \\
 \mathbf{J}_{\text{jcb},11} &= \mathbf{A}_d \\
 \mathbf{J}_{\text{jcb},12} &= \frac{\partial}{\partial \mathbf{x}} (\mathbf{A}_d \cdot \mathbf{x} + \mathbf{B}_d \cdot \mathbf{u}), \text{ mit } \mathbf{x} = \begin{bmatrix} i_s^S & \Psi_s^S \end{bmatrix}^T \\
 \mathbf{J}_{\text{jcb},21} &= \mathbf{0}_{4 \times 4} \\
 \mathbf{J}_{\text{jcb},22} &= \mathbf{I}_4.
 \end{aligned} \tag{5.19}$$

Die Teilmatrix $\mathbf{J}_{\text{jcb},11}$ entspricht exakt der diskreten Systemmatrix \mathbf{A}_d , weswegen ein Abgriff aus der ohnehin durchgeführten Berechnung des Maschinenmodells möglich ist. Für die Teilmatrizen $\mathbf{J}_{\text{jcb},21}$ und $\mathbf{J}_{\text{jcb},22}$ ergeben sich eine Nullmatrix und eine Einheitsmatrix. Somit muss lediglich die Berechnung der Teilmatrix $\mathbf{J}_{\text{jcb},12}$ erfolgen, was zu einer erheblichen Reduzierung des Berechnungsaufwands führt. Trotz der Reduzierung bleibt die Implementierung

der übrigen 4×4 -Teilmatrix aufwendig und komplex. Auf eine detaillierte Darstellung der Teilmatrix $\mathbf{J}_{\text{jcb},12}$ wird aus Übersichtsgründen verzichtet.

Berechnung der Cholesky-Faktorisierung für das UKF

Bei der Implementierung des UKF entfällt zwar die Berechnung der Jacobi-Matrix, jedoch ist Umsetzung der UT umso komplexer. Die Ermittlung der Sigma-Punkte zur Beschreibung der angenommenen Gaußschen Normalverteilung erfordert die Berechnung einer Matrixquadratwurzel, die wie in Abs. 2.1.6 beschrieben mit Hilfe der Cholesky-Faktorisierung realisierbar ist. Die Nutzung eines vorgefertigten Funktionsblocks ist auch hier nicht möglich. Alternativ lässt sich der von Bohm et al. in [151] beschriebene Algorithmus durch Basisberechnungen implementieren. Basierend auf dem Prinzip eines Koeffizientenvergleichs berechnet dieser Algorithmus für eine symmetrische, positiv-definite Matrix \mathbf{M} eine untere Dreiecksmatrix \mathbf{N} , für die folgendes gilt:

$$\mathbf{M} = \mathbf{N}\mathbf{N}^T \quad (5.20)$$

$$\rightarrow \mathbf{M} = \begin{pmatrix} m_{11} & m_{12} & \dots & m_{1n} \\ m_{21} & m_{22} & \dots & m_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ m_{n1} & m_{n2} & \dots & m_{nn} \end{pmatrix}, \quad \mathbf{N} = \begin{pmatrix} n_{11} & 0 & \dots & 0 \\ n_{21} & n_{22} & \dots & \vdots \\ \vdots & \vdots & \ddots & 0 \\ n_{n1} & n_{n2} & \dots & n_{nn} \end{pmatrix}.$$

Der Koeffizientenvergleich von \mathbf{M} und $\mathbf{N}\mathbf{N}^T$ ermöglicht nun durch

$$n_{jj} = \sqrt{m_{jj} - \sum_{k=1}^{j-1} n_{kj}^2} \quad (5.21)$$

$$n_{ij} = \frac{1}{n_{ii}} \left(m_{ij} - \sum_{k=1}^{i-1} n_{ki}n_{kj} \right)$$

die Ermittlung der Einträge der unteren Dreiecksmatrix \mathbf{N} . Die Cholesky-Zerlegung ist im UKF-Algorithmus zur Berechnung der gewichteten Fehlerkovarianzmatrix erforderlich. Bei der gleichzeitigen Identifikation aller vier ESB Parameter beträgt die Dimension dieser Matrix 8×8 , wodurch sich für die Dreiecksmatrix \mathbf{N} 36 von null verschiedene Elemente ergeben. Die Umsetzung erfolgt nun so, dass alle Elemente mit Hilfe der Gleichungen (5.21) bestimmbar sind. Die aufwendige Implementierung indiziert bereits an dieser Stelle einen deutlich erhöhten Rechenaufwand des UKF-Algorithmus im Vergleich zum EKF.

Initialisierung erweiterter Kalman-Filter

Bei der OPI mit erweitertem KF offenbart sich eine sehr ausgeprägte Sensitivität gegenüber den initialen Kovarianzmatrizen. Zusätzlich beeinflusst die Linearisierung das Konvergenzverhalten aufgrund der initialen Zustände und Parameter erheblich. Die Initialisierung der

KF-Algorithmen stellt sich im Vergleich zum RLS-Algorithmus als deutlich komplexer heraus.

Zur Initialisierung der Parameter $\hat{\boldsymbol{\theta}}_0$ stehen die genutzten Referenzwerte zur Verfügung. Dadurch ist es möglich, von Beginn an einen physikalisch sinnvollen Bereich der zu identifizierenden Parameter vorzugeben. Die Systemzustände $\hat{\boldsymbol{x}}$ in (5.5) bzw. (5.3) setzen sich aus den messbaren Komponenten des Statorstroms i_s^S und den zu schätzenden Rotorflussgrößen Ψ_r^S zusammen. Die Bereitstellung valider Initialwerte für die Komponenten des Rotorflusses ist, nicht zuletzt aufgrund der sinusförmigen Verläufe, von nicht zu unterschätzender Bedeutung. Das für die Regelung der ASM ohnehin notwendige Rotorflussmodell eignet sich bestens zur Schätzung der Momentanwerte von Ψ_r^S , siehe Abb. 5.3. An dieser Stelle profitiert die OPI von einem stabilen Regelungskonzept mit einem über den gesamten Betriebsbereich validen Rotorflussbeobachter. Daher erweist sich zur Initialisierung von Ψ_r^S der implementierte, in Abs. 3 beschriebene Gopinath-Beobachter nach [79] als vorteilhaft.

Deutlich herausfordernder ist hingegen die Initialisierung der Kovarianzmatrizen. Die Kovarianzmatrix des Messrauschens lässt sich in der Regel durch eine im Voraus durchgeführte Analyse der gemessenen Systemgrößen bedaten. Daher erfolgt eine Rauschanalyse der am Prüfstand genutzten Stromsensoren. Zur Überprüfung eventueller Änderungen der Rauschamplitude in Abhängigkeit des momentanen Betriebspunkts wird sowohl die Stromamplitude als auch die Drehzahl variiert. Für die hier verwendete Sensorik lässt sich jedoch keine signifikante Dynamik der Rauschverhältnisse bei sich ändernden Betriebspunkten feststellen. Basierend auf den Ergebnissen wird die Hauptdiagonale der Kovarianzmatrix in einem festen Bereich von $\text{diag}(\mathbf{R}) = 10^{-4}$ initialisiert. Die Kovarianz des Prozessrauschens \mathbf{Q} ist hingegen nicht messtechnisch erfassbar, weswegen deren Parametrisierung als anspruchsvoll gilt. Letztlich hängt das Konvergenzverhalten maßgeblich von der gewählten Einstellung ab. Bei Initialisierung der Parameterreferenzwerte und der bestimmten Momentanwerte der Systemzustände ist die Festlegung kleiner Varianzen sinnvoll. Dies führt allerdings dazu, dass im Fall einer Parameteränderung die Adaptionsfähigkeit des KF-Algorithmus eingeschränkt ist. Hingegen steigt bei Vorgabe größerer Varianzen, gerade bei dynamischen Schätzparametern, die Wahrscheinlichkeit einer Divergenz des Algorithmus. Ein universelles Vorgehen zur Initialisierung ist auch hier nicht festlegbar.

Bei Nutzung des UKF-Algorithmus sind zusätzlich die Hyperparameter zur Approximation der Wahrscheinlichkeitsverteilung festzulegen. Dadurch entsteht ein zusätzlicher beeinflussbarer Freiheitsgrad, der jedoch den Parametrisierungsaufwand weiter erhöht.

5.4.2 Simulative Analyse

Im ersten Schritt erfolgt eine simulative Analyse der erweiterten KF-Algorithmen zur OPI. Gerade aufgrund der komplexen Implementierung ist die Methode der modellbasierten Softwareentwicklung hier bestens geeignet. Zum einen sind Implementierungsfehler durch stück-

weise Inbetriebnahme mit verhältnismäßig geringem Aufwand behebbar, zum anderen lässt sich die Eignung der unterschiedlichen Algorithmen zur Nutzung im hier betrachteten Betriebsumfeld einschätzen. Zusätzlich ergeben sich durch die Simulation wertvolle Erfahrungswerte im Umgang mit der aufwendigen Initialisierung.

Zur Sicherstellung eines einheitlichen Vergleichs mit dem RLS-Algorithmus erfolgen die Untersuchungen auch hier mit der in Abs. 3.2 beschriebenen Simulationsumgebung und den Testprofilen analog zu Abs. 4.4.3. Der Simulation des Sensorrauschens kommt bei der Analyse der erweiterten KF aufgrund des statistischen Einflusses auf die Algorithmen eine besondere Bedeutung zu. Die Bewertung der verschiedenen KF-Algorithmen im Umgang mit dynamischen Parameteränderungen erfolgt zunächst anhand eines vereinfachten Testprofils. Ein Vergleich der unterschiedlichen Identifikationsmodelle (5.4) und (5.6) anhand des vereinfachten Testprofils erbrachte lediglich marginale Unterschiede, weswegen die Darstellung der zugehörigen Identifikationsergebnisse keinen illustrativen Mehrwert bietet. Im zweiten Teil werden ausgewählte Konfigurationen aus Algorithmen und Identifikationsmodellen mit unterschiedlicher Parameteranzahl hinsichtlich ihrer Performanz entlang des WLTP-Zyklus analysiert.

Vergleich der Algorithmen mit vereinfachtem Testprofil

Grundsätzlich eignen sich zur OPI die in Abs. 2.1.6 erläuterten Algorithmen des EKF und UKF jeweils in der Variante als Joint- oder Dual-Filter. Zunächst erfolgt daher ein Vergleich der verschiedenen KF-Algorithmen anhand eines vereinfachten Testprofils. Zur Simulation dynamischer Parameteränderungen eignet sich, analog zu den Untersuchungen des KF-Algorithmus, das in Abb. 5.4 dargestellte Stromprofil. Der dargestellte Lastsprung bei konstanter Drehzahl ermöglicht dabei die isolierte Betrachtung einer sättigungsbedingten Parameteränderung im Intervall von $t = 1 \dots 20$ s. Zusätzlich wird ab dem Zeitpunkt $t = 20$ s die Reaktion der Algorithmen auf eine dynamische Drehzahländerung bei gleichbleibender Last der Maschine untersucht. Da sich die Untersuchungen in diesem Abschnitt auf den Vergleich unterschiedlicher Algorithmen beschränken, erfolgt die Analyse exemplarisch basierend auf dem Identifikationsmodell mit optimiertem Parametervektor (5.6). Des Weiteren konzentrieren sich die Untersuchungen auf das Konvergenzverhalten bei vollständiger Identifikation aller ESB-Parameter. Analog zu Abb. 4.9 beschränkt sich die Darstellung der Parameter in Abb. 5.4 jedoch aus Übersichtsgründen exemplarisch auf den Vergleich der identifizierten Rotorzeitkonstante \hat{T}_r . Der zugehörige Verlauf der Spur der Kovarianzmatrix findet sich jeweils in der rechten Spalte. Die präsentierten Ergebnisse basieren auf einer optimierten Parametrisierung der Algorithmen nach vorhandenem Erkenntnisstand des Autors. Zur Illustration des Konvergenzverhalten wird die Identifikation auch hier bei allen Simulationsläufen mit Beginn des Testprofils gestartet. Zusätzlich erfolgt die Initialisierung der Systemzustände

mit $\hat{\mathbf{x}} = \mathbf{0}_{4 \times 1}$ und der Schätzparameter mit $\hat{\boldsymbol{\theta}} = \boldsymbol{\theta}_{\text{ref}} \cdot \frac{3}{2}$.

Abbildung 5.4(a) zeigt die Ergebnisse der Joint-Filterung mittels EKF. Da im Zeitbereich von $t = 0 \dots 1$ s die fortlaufende Anregung nicht gegeben ist, beginnt der Algorithmus zu divergieren. Mit dem Start der Drehzahl- bzw. Stromrampe folgt jedoch eine verhältnismäßig schnelle und biasfreie Konvergenz zum wahren Wert. Mit dem Auftreten des Lastsprungs bei $t = 5$ s beginnt die dynamische Änderung der sättigungsabhängigen Parameter. Während der Parameteränderung bewegt sich der identifizierte Wert von \hat{T}_r in inkorrekt Richtung hinweg vom Bereich des wahren Wertes. Nach dem Wiedereintritt in den stationären Zustand der Maschine, zeigt sich eine langsame Konvergenz hin zu einem deutlich fehlerbehafteten Identifikationsergebnis, was auch durch den konvergierenden Verlauf der Kovarianz verdeutlicht wird. Das Ergebnis entspricht hierbei nicht den Erwartungen, da aufgrund der idealisierten Simulation der elektrischen Maschine eine fehlerfreie Schätzung plausibel erscheint. Zum Zeitpunkt $t = 20$ s ändert sich die Drehzahl bei konstanter Last. Die dadurch eingetragene Anregung hat in diesem Fall positiven Einfluss auf das Ergebnis des EKF-Algorithmus, da sich der stationäre Identifikationsfehler verkleinert, wobei jedoch ein Restfehler bestehen bleibt. Allgemein zeigt die Reaktion auf die Drehzahländerung jedoch, dass der EKF-Algorithmus sensitiv auf Frequenzänderungen reagiert, was im Fall eines dynamischen Drehzahlbetriebs auch nachteilige Auswirkungen haben kann. Zusätzlich ist im Vergleich zum RLS-Algorithmus in Abb. 4.9 das betrachtete Zeitfenster des Testprofils zu beachten. Nach bereits erfolgter Konvergenz erweist sich das Konvergenzverhalten des EKF auf dynamische Parameteränderungen als deutlich langsamer. Anhand der zuvor beschriebenen Aspekte lassen sich vergleichsweise suboptimale dynamische Eigenschaften des EKF-Algorithmus beobachten.

Der Verlauf der Joint-Filterung mittels UKF ist in Abb. 5.4(b) dargestellt. Der Algorithmus konvergiert auch hier mit dem Start der Anregung in vergleichbarem Zeitrahmen zum EKF und biasfrei zum wahren Wert. Mit Eintritt der sättigungsbedingten Parameteränderung beginnt instantan die Konvergenz in den Bereich des geänderten Referenzwertes. Jedoch ist das Verhalten dabei trotz kleiner initialisierter Kovarianzen träger im Vergleich zum EKF und im Verhältnis zur Geschwindigkeit der Parameteränderung. Diese Trägheit verdeutlicht sich bei Betrachtung des Kovarianzverlaufs. Der Bereich des wahren Wertes wird jedoch mit fortschreitender Konvergenzzeit erreicht, wobei sich ein minimaler stationärer Schätzfehler einstellt. Auch die Reaktion auf die Drehzahländerung bei konstanter Last verläuft vergleichsweise träge, jedoch erfolgt auch hier eine nahezu fehlerfreie Konvergenz des Algorithmus. Gerade im Intervall von $t = 20 \dots 40$ s bestätigt sich bei Betrachtung der Spur der Kovarianzmatrix das träge Konvergenzverhalten. Zur besseren Übersicht wird auf die Darstellung des vollständigen Konvergenzintervalls verzichtet. Der verbleibende Schätzfehler im Fall des UKF weist eine deutliche Sensitivität gegenüber der Einstellung der initialen Kovarianz auf. Diese Tatsache führt in Verbindung mit der hohen Anzahl an Hyperparametern zu einem erheblichen Parametrisierungsaufwand zur Erreichung des dargestellten Identifika-

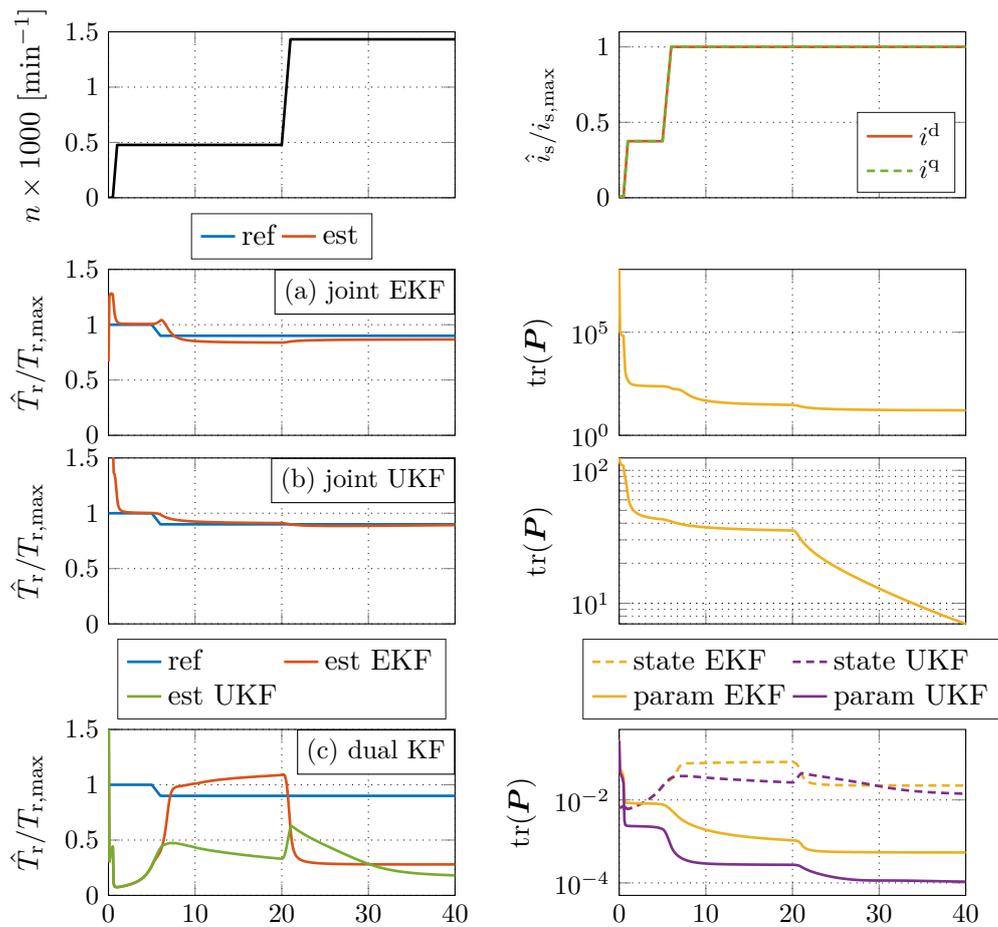


Abbildung 5.4: Simulativer Vergleich der verschiedenen Erweiterungen des KF-Algorithmus anhand eines dynamischen Testprofils. - Konfiguration (a) joint EKF Tab. C.1, (b) joint UKF Tab. C.2, (c) dual EKF Tab. C.3 und dual UKF Tab. C.4.

tionsergebnisses. Die fehlende Universalität der Parametrisierung ist im Hinblick auf einen Einsatz in einem hochdynamischen Betriebsumfeld daher kritisch zu hinterfragen. Ein weiterer Faktor, der aus der Darstellung nicht hervorgeht, ist der im Vergleich zum EKF nochmals höhere Rechenaufwand.

Die Ergebnisse der Dual-Filterung mittels EKF und UKF fasst Abb. 5.4(c) zusammen. Bereits ab Beginn der Anregung zeigt sich ein deutlicher Unterschied des Konvergenzverhaltens beider KF im Vergleich zur Joint-Filterung. Im ersten Lastpunkt zeigen sowohl EKF als auch UKF ein sehr träges Verhalten und erreichen keine stationären Zustände. Der Lastpunktwechsel führt bei beiden Algorithmen zu einer signifikanten Änderung, sodass sich ein langsam konvergierendes Verhalten einstellt. Jedoch weist der potentielle Endwert in beiden Fällen einen sehr hohen Schätzfehler auf, der die identifizierten Parameterwerte unbrauchbar macht. Auch die Änderung der Drehzahl ruft eine deutliche Anpassung hervor. Das EKF konvergiert schnell jedoch abermals zu einem deutlich veränderten und fehlerbehafteten stationären Ergebnis. Die Konvergenz des UKF verläuft auch hier sehr träge und zu einem unbrauchbaren Endwert. Allgemein lässt sich in Bezug auf dynamische Parameter- und Zu-

standsänderungen eine deutliche Sensitivität beider Algorithmen bis hin zu divergierendem Verhalten beobachten. Die übrigen in Abb. 5.4 nicht dargestellten Identifikationsparameter ergeben ebenfalls keine zufriedenstellenden Ergebnisse. Um eine Divergenz zu verhindern muss die initiale Kovarianz bereits sehr klein gewählt werden, was wiederum sehr nachteilhaft für die Reaktionsfähigkeit auf dynamisches Verhalten ist. Generell gestaltet sich die Parametrisierung bereits mit dem hier genutzten vereinfachten Testprofil komplex, wodurch die Festlegung universeller Initialwerte bzw. Hyperparameter schwer vorstellbar ist. Die schlechte Performanz ist auf Komplikationen bei der Abstimmung der zwei KF-Pfade bei schnellem dynamischem Systemverhalten in Verbindung mit einer hohen Anzahl an Identifikationsparametern zurückzuführen. Bei Betrachtung der einzelnen Kovarianzen stellt sich gerade die Konvergenz der dynamischen Zustandsschätzung für EKF sowie UKF als problematisch heraus. Eine Reduzierung der zu identifizierenden Parameteranzahl führt zwar zu einer Verbesserung der dynamischen Eigenschaften. Jedoch ist das allgemein langsame Konvergenzverhalten der Dual-Filter in Betracht der Anforderungen dieser Arbeit ein Ausschlusskriterium, weswegen dieser Ansatz nachfolgend nicht weiter berücksichtigt wird.

Allgemein zeigen sich im Vergleich zum RLS-Algorithmus Schwierigkeiten bei der Identifikation dynamischer Parameteränderungen aufgrund einer deutlich höheren Konvergenzzeit. Zudem lässt sich eine Abhängigkeit des Identifikationsfehlers vom momentanen Betriebspunkt, sowie eine starke Sensitivität gegenüber den Initialwerten bzw. Hyperparametern beobachten. Bei der Initialisierung der Kovarianzmatrizen gilt es, den Zielkonflikt zwischen hohen Werten zur Steigerung der Anpassungsfähigkeit und geringen Werten zur Verbesserung der Stabilität beziehungsweise Robustheit zu berücksichtigen. Aufgrund der genannten Aspekte ist eine universelle Parametrisierung in Bezug auf stark dynamische Betriebsbedingungen herausfordernd. Im Vergleich zum RLS-Algorithmus ergibt sich demnach ein hoher Parametrisierungsaufwand. Außerdem beeinträchtigt die betriebspunktabhängige Sensitivität die Robustheit und kann unter Umständen zur Divergenz führen.

Vergleich der Algorithmen mit WLTP-Zyklus

Aufbauend auf den Untersuchungen aus dem vorherigen Abschnitt erfolgt nun ein Vergleich des dynamischen Verhaltens der Algorithmen anhand des WLTP-Zyklus. Dabei wird aufgrund der unzureichenden Performanz der Dual-Filterung in unserem Anwendungsfall lediglich die Joint-Filterung mittels EKF und UKF verglichen. Die Analyse basiert auch hier exemplarisch auf dem Identifikationsmodell mit optimiertem Parametervektor (5.6). Die zugehörigen Ergebnisse der direkt aus (5.5) berechenbaren Schätzparameter zeigt Abb. 5.5.

Die Auswirkungen der betriebsbedingten Sättigung der Hauptinduktivität sind anhand der Rotorzeitkonstante \hat{T}_r deutlich zu erkennen. Die Identifikation der daraus resultierenden dynamischen Parameteränderungen ist durch beide Algorithmen grundsätzlich gegeben. Zu

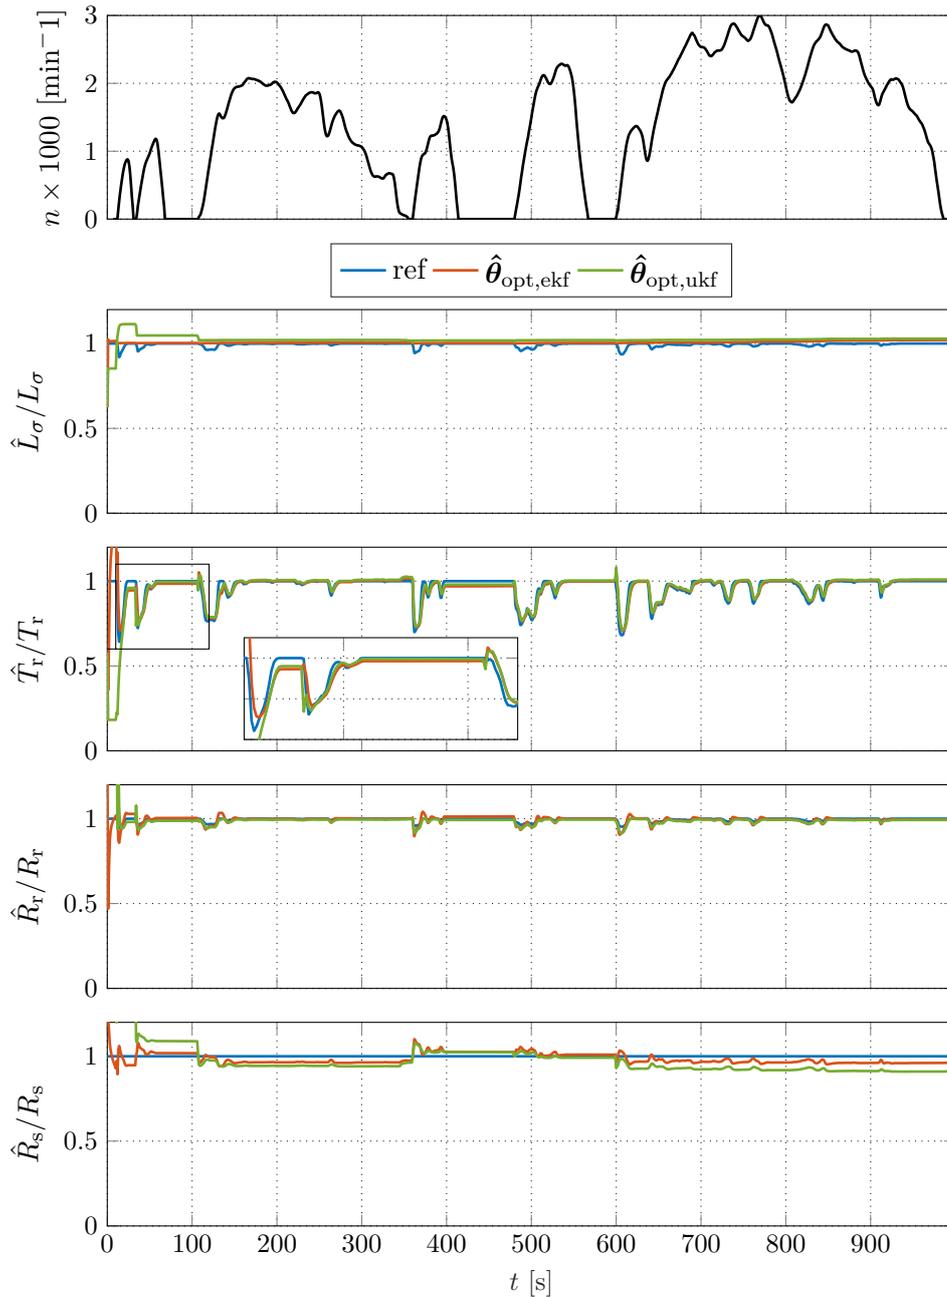


Abbildung 5.5: Simulativer Vergleich der verschiedenen Erweiterungen des KF-Algorithmus entlang des WLTP-Zyklus. - Konfiguration $\hat{\theta}_{\text{opt,ekf}}$ Tab. C.5, $\hat{\theta}_{\text{opt,ukf}}$ Tab. C.6.

Beginn des Zyklus macht sich die längere Konvergenzzeit des UKF bemerkbar. Während das UKF die erste Parameteränderung nicht identifiziert, erfolgt die Konvergenz des EKF etwas schneller. Jedoch ist der Fehler im Falle beider Algorithmen zunächst vergleichsweise hoch, sodass der wahre Wert verfehlt wird. Diese Beobachtung verdeutlicht der vergrößerte Ausschnitt in Abb. 5.5. Nach circa $t \approx 50$ s verbessert sich das Konvergenzverhalten trotz der auftretenden Dynamik. Im nachfolgenden Verlauf werden die dynamischen Parameteränderungen grundsätzlich mit geringem Fehler identifiziert. Dabei weisen beide Algorithmen

im Vergleich zum vereinfachten Testprofil in Abb. 5.4 entgegen den Erwartungen gutes dynamisches Verhalten auf. Diese Beobachtung ist auf die gute Anregung durch das deutlich dynamischere Testprofil zurückzuführen. Eine restlos fehlerfreie Identifikation wie im Fall des RLS-Algorithmus ist jedoch mit keinem der beiden Algorithmen möglich, wie der mittlere Fehler in Tab. 5.1 bestätigt. Generell weisen sowohl das EKF als auch das UKF für alle Parameter robustes und konvergentes Verhalten über den gesamten Zyklus auf, wobei die Genauigkeit der absoluten Ergebnisse variiert. Die Identifikation des Rotorwiderstands erfolgt über den gesamten Zyklus mit sehr geringem Restfehler. Die Dynamik der Streuinduktivität hingegen ist nicht identifizierbar, obwohl der absolute Fehler verhältnismäßig gering ist. Bei Betrachtung des gesamten Zyklus ist ein leichter Drift im Verlauf von \hat{L}_σ erkennbar, der bei sehr langen Laufzeiten zur Divergenz des Algorithmus führen kann. Im Vergleich zum RLS-Algorithmus erweist sich die Identifikation von \hat{R}_s als interessant, da die absoluten Identifikationsergebnisse robust im Bereich des wahren Wertes liegen. Da simulativ jedoch eine fehlerfreie Schätzung zu erwarten ist, lässt sich der verbleibende Schätzfehler als zu hoch einstufen. Eine Begründung für die bessere Identifizierbarkeit im Vergleich zum RLS-Algorithmus ist der Aufbau des Identifikationsmodells, da die ohmschen Identifikationsparameter im Parametervektor (5.5) unabhängig von der dominanten Hauptinduktivität enthalten sind.

Zusammengefasst zeigen beide Algorithmen eine vergleichbare Performanz. Aufgrund des höheren Berechnungsaufwands und der komplexeren Parametrisierung des UKF ergibt sich jedoch eine Tendenz zur Nutzung des EKF für die hier betrachtete Problemstellung. Die Vorteile des UKF im Umgang mit stark nichtlinearen Systemen sind für den Fall der elektrischen Maschine von untergeordneter Bedeutung. Diese Hypothese hat sich durch zahlreiche weitere Untersuchungen bestätigt, die jedoch aus Übersichtsgründen nicht dargestellt werden. Für die nachfolgenden Analysen beschränkt sich diese Arbeit auf die Nutzung des EKF.

Vergleich der Identifikationsmodelle mit WLTP-Zyklus

In diesem Abschnitt liegt der Fokus auf dem Vergleich der Identifikationsmodelle bzw. der Parametervektoren (5.5) und (5.3) entlang des WLTP-Zyklus. Basierend auf den gewonnenen Erkenntnissen aus den vorherigen Abschnitten beschränken sich die Untersuchungen auf die Nutzung des EKF-Algorithmus.

Die Ergebnisse sind in Abb. 5.6 dargestellt. Beginnend mit der Betrachtung der Rotorzeitkonstante \hat{T}_r zeigt der Vergleich der beiden Modelle eine deutlich höhere Genauigkeit für den Fall der direkten Parameteridentifikation mit $\hat{\theta}_{\text{dir}}$. Bei Betrachtung des vergrößerten Ausschnitts offenbart sich eine quasi fehlerfreie Schätzung der dynamischen Parameteränderungen. Auch die Identifikation der ohmschen Parameter R_r , R_s verläuft fehlerfrei und zeigt robustes Verhalten über den gesamten WLTP-Zyklus. Einzig die Identifikation der Streuinduktivität

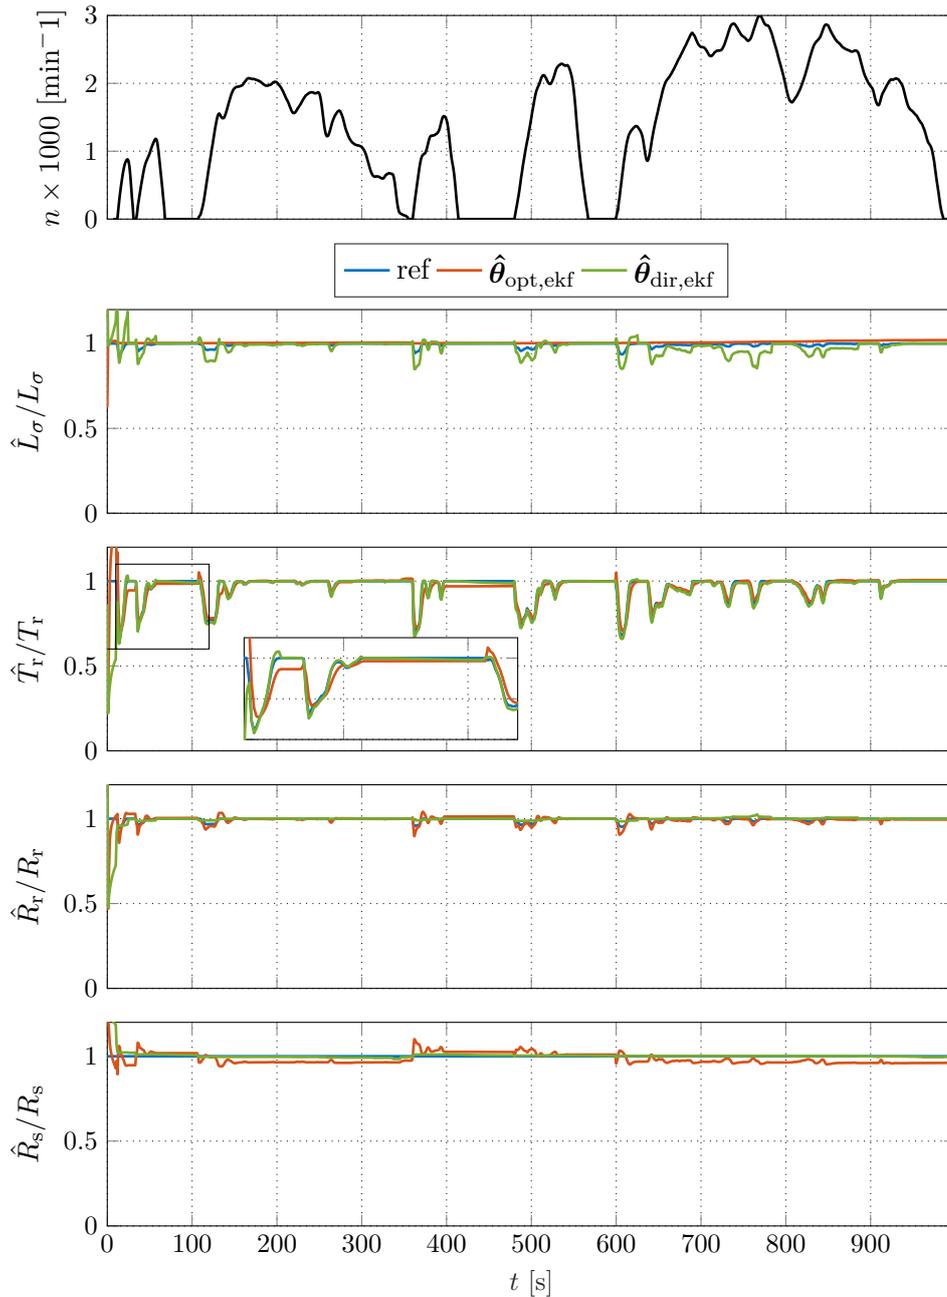


Abbildung 5.6: Simulativer Vergleich der verschiedenen Identifikationsmodelle mit optimiertem und direktem Parametervektor unter Nutzung des EKF-Algorithmus entlang des WLTP-Zyklus. - Konfiguration $\hat{\theta}_{\text{opt,ekf}}$ Tab. C.5, $\hat{\theta}_{\text{dir,ekf}}$ Tab. C.7.

verläuft in beiden Fällen problematisch. Wie bereits im vorherigen Abschnitt beobachtet, ist das dynamische Verhalten von L_σ mit dem optimierten Parametervektor nicht identifizierbar. Hingegen zeigt das Modell mit direktem Parametervektor deutlich überschwingendes Verhalten, sobald eine dynamische Parameteränderung auftritt. Obwohl daraus in diesem Fall kein divergentes Verhalten resultiert, ist es sinnvoll, diese Tatsache bei alternativen dynamischen Anwendungsfällen zu bedenken.

Die mittleren Identifikationsfehler finden sich zum Vergleich in Tab. 5.1. Aus dem Vergleich der Identifikationsmodelle geht hervor, dass die durch $\hat{\theta}_{\text{dir}}$ hervorgerufene komplexere nicht-lineare Struktur zumindest für den simulativen Vergleich nicht von Nachteil ist. Schwierigkeiten bei der Identifikation der Streuinduktivität offenbaren sich mit beiden Modellen. Eine genaue Betrachtung der Identifikationsmodelle (5.6) und (5.4) zeigt, dass L_σ als einziger zu identifizierender Parameter auch in der Eingangsmatrix auftaucht und somit den Grad der Nichtlinearität erhöht. Dadurch wird die Identifikation in Verbindung mit der geringen Sensitivität von L_σ auf das Modell erschwert. Ein allgemeiner begünstigender Faktor für Identifikationsfehler ist die Anzahl der zu identifizierenden Parameter. Dabei wird die Genauigkeit der Parameter mit geringer Sensitivität besonders beeinträchtigt.

Vergleich bei verschiedener Parameteranzahl mit WLTP-Zyklus

Aus den vorherigen Abschnitten geht hervor, dass sich auch im Fall der OPI mittels erweiterter KF Schwierigkeiten bei der Identifikation von L_σ und R_s ergeben. Aufgrund der Analogie zum RLS-Algorithmus lässt sich folgern, dass auch hier die Sensitivität der betroffenen Parameter einen entscheidenden Einfluss hat. Nachfolgend wird die Auswirkung der Vorgabe des Statorwiderstands und der Streuinduktivität anhand des EKF-Algorithmus und dem Identifikationsmodell mit optimiertem Parametervektor (5.6) entlang des WLTP-Zyklus untersucht.

Die entsprechenden Ergebnisse sind in Abb. 5.7 dargestellt. Der Verlauf der sättigungsbedingten Parameteränderungen, repräsentiert durch die Rotorzeitkonstante, lässt sich mit allen untersuchten Konfigurationen identifizieren. Die Mittelwerte der zugehörigen Identifikationsfehler unterscheiden sich nur unwesentlich, wie in Tab. 5.1 ersichtlich. Eine vollständig fehlerfreie Schätzung ist jedoch auch mit Vorgabe der Parameter nicht möglich. Am Anfang des Testzyklus hat die Parametervorgabe in beiden Fällen einen scheinbar negativen Einfluss auf das Konvergenzverhalten des EKF, wie der vergrößerte Ausschnitt zeigt. Die sättigungsbedingten Parameteränderungen resultieren in einem drastischen Ausschlag der identifizierten Rotorzeitkonstante. Jedoch ist im Anschluss eine instantane Konvergenz des Algorithmus zu beobachten und im weiteren Verlauf relativiert sich dieser Fehler. Daher ist dieses Verhalten auf numerische Interferenzen bei der Parametervorgabe zurückzuführen. Bei der Identifikation des Rotorwiderstands zeigen sich hingegen unterschiedliche Auswirkungen abhängig von der Konfiguration. Die Vorgabe von L_σ führt zu einer fehlerfreien Schätzung von R_r über den gesamten Testzyklus, siehe Tab. 5.1. Hingegen resultiert die Vorgabe von R_s in einer leichten Verschlechterung des mittleren Identifikationsfehlers. Im Vergleich zur Identifikation ohne Parametervorgabe wird der Verlauf jedoch sichtbar geglättet, ohne dass sich der Fehler signifikant erhöht. Die Vorgabe von R_s führt in Bezug auf die Identifikation von L_σ zu einer fehlerfreien Schätzung. Zusätzlich wird das latent divergente Verhalten im hinteren Teil des Zyklus positiv beeinflusst.

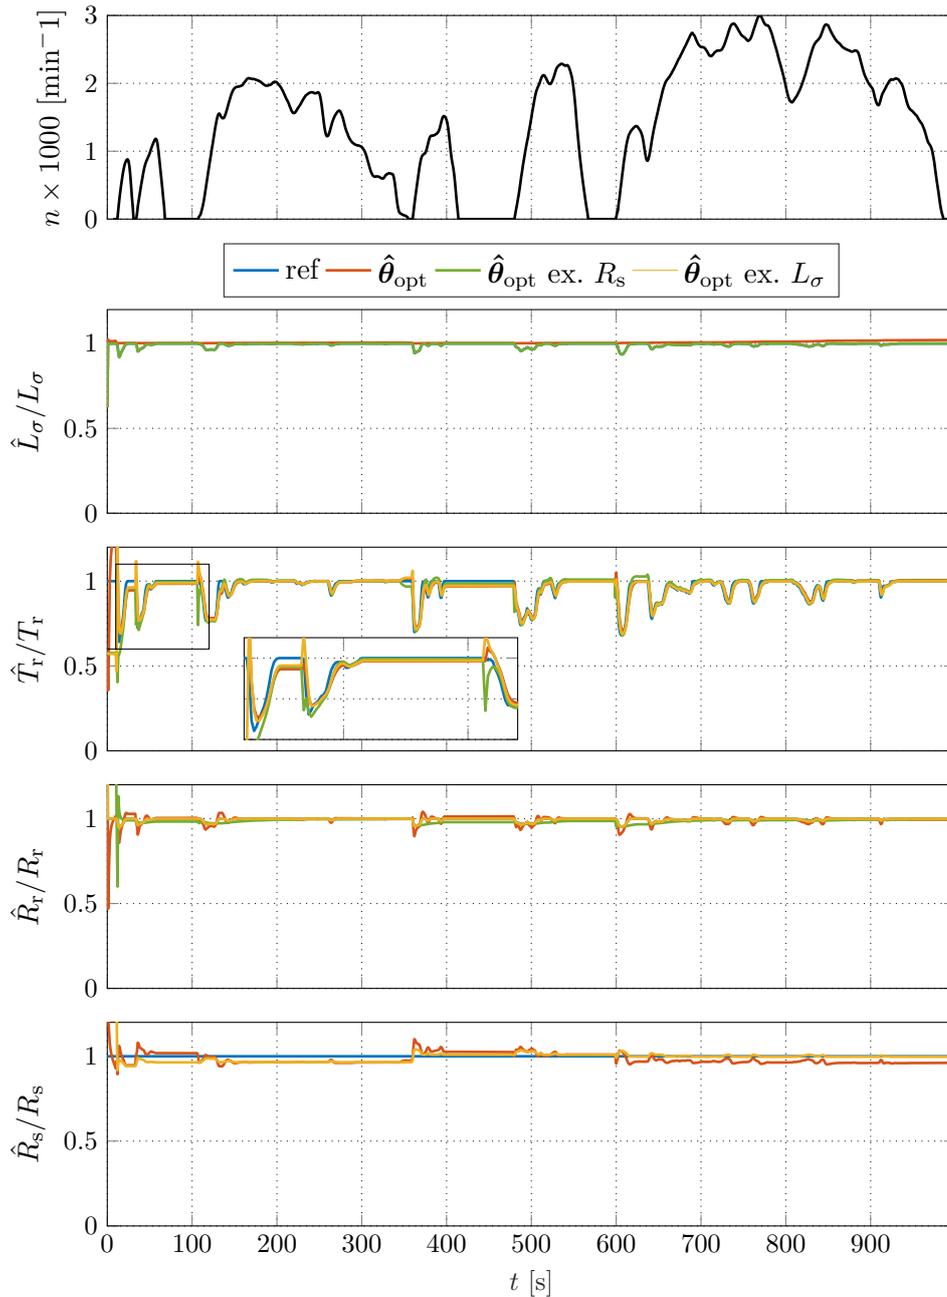


Abbildung 5.7: Simulativer Vergleich des Identifikationsmodells mit $\hat{\theta}_{opt}$ und Vorgabe verschiedener Parameter unter Nutzung des EKF-Algorithmus entlang des WLTP-Zyklus. - Konfiguration $\hat{\theta}_{opt}$ Tab. C.5. Zur Vorgabe einzelner Parameter bei den Versuchsläufen $\hat{\theta}_{opt}$ ex. R_s und $\hat{\theta}_{opt}$ ex. L_σ ist der jeweilige Referenzwert $\theta_{x,ref}$ vorzugeben und die Parameterunsicherheit in $Q_{xx,\theta}$ auf null zu setzen.

Durch die Vorgabe von L_σ erhöht sich wiederum die Genauigkeit der Identifikation von R_s . Dabei fällt vor allem das robuste Verhalten im letzten Teil des Zyklus auf. Die leichte Verbesserung ist auch anhand des mittleren Identifikationsfehlers in Tab. 5.1 ersichtlich.

Insgesamt bewirkt die Parametervorgabe eine Erhöhung der Genauigkeit. Jedoch ermöglicht die Vorgabe weiterhin keine fehlerfreie Schätzung. Die absolute Steigerung der Performanz

bezogen auf die Konfiguration ohne Parametervorgabe ist auch im Vergleich mit dem RLS-Algorithmus unwesentlich. Der tatsächliche Vorteil der Maßnahme ist demnach anhand der OPI im realen System zu bewerten.

5.4.3 Experimentelle Analyse

Aufbauend auf den simulativen Untersuchungen in Abs. 5.4.2 erfolgt in diesem Abschnitt eine experimentelle Analyse. Analog zum RLS-Algorithmus wird die Echtzeitsoftware aus den in Abs. 5.4.2 validierten Simulationsmodellen kompiliert und zur Analyse der dynamischen Performanz anhand des WLTP-Zyklus mit der in Abs. 3 beschriebenen Sollstromtrajektorie betrieben. Bei hohen Drehzahlen in Bezug auf den hier betrachteten Zyklus ist der Lastbereich durch die notwendige Feldschwächung zunehmend eingeschränkt. In der Folge bleibt die Induktivität der Maschine durch die ausbleibende Sättigung unverändert, wodurch sich keine zusätzlichen Erkenntnisse hinsichtlich der Identifikation dynamischer Parameteränderungen ergeben. Während diverser Voruntersuchungen zeigten alle untersuchten Konfigurationen stets stabiles Verhalten für den oberen Drehzahlbereich $n = 2200 \dots 3000 \text{ min}^{-1}$. Für die nachfolgende experimentelle Analyse der erweiterten KF wird der Drehzahlbereich aus Übersichtsgründen auf den unteren Drehzahlbereich beschränkt und der Testzyklus entsprechend angepasst. Aufgrund des stark betriebspunktabhängigen Konvergenzverhaltens der KF-Algorithmen werden zur Festlegung von Konfidenzintervallen zusätzliche Untersuchungen in stationären Lastpunkten im besagten angepassten Drehzahlbereich durchgeführt.

Die Vorteile des UKF bezüglich der OPI stark nichtlinearer Systeme und der Nutzung alternativer Wahrscheinlichkeitsverteilungen erweisen sich bereits anhand der Simulationen als nicht wesentlich für die Anwendung in der vorliegenden Arbeit. Zusätzlich erweist sich die aufwendige Optimierung der Hyperparameter gerade im realen System als große Herausforderung. Diverse Voruntersuchungen bestätigen die schlechten dynamischen Eigenschaften des UKF-Algorithmus. Nicht zuletzt wegen des hohen Rechenaufwands findet das UKF im folgenden Verlauf keine Anwendung mehr.

Die Vorgabe des Statorwiderstands ergibt bei der simulativen Analyse nur unwesentliche Auswirkungen. Hingegen führt sie bei der OPI im realen System zu einer deutlichen Verschlechterung der Ergebnisse bis hin zur Divergenz des Algorithmus. Die Ursache hierfür wurde im Rahmen der Untersuchungen dieser Arbeit nicht ermittelt, weswegen die Darstellung der zugehörigen Ergebnisse nicht zielführend ist.

Für die durchgeführten Experimente finden die folgenden Aspekte bezüglich der Initialisierung und der verwendeten Messgrößen Beachtung:

- **Initialisierung der Kovarianzmatrix des Messrauschens durch Rauschanalyse:** Die Initialisierung der Kovarianzen ist gerade bei der Nutzung im realen System ein wichtiger Faktor für die erfolgreiche OPI. Die Kovarianzmatrix \mathbf{R} enthält das Messrau-

schen der Sensorik zur Erfassung der messbaren Zustandsgrößen, wobei der Strommessung eine besondere Bedeutung zukommt. Durch eine betriebspunktabhängige Analyse des Messrauschens lassen sich geeignete Initialwerte für \mathbf{R} ermitteln und somit potentiell fehlerhafte Varianzen vermeiden. Eine empirische Abschätzung der Varianz ist unter der Voraussetzung einer geringfügigen zeitlichen Änderung des Messrauschens $v[k]$ mit folgender Gleichung möglich [40, S.64]:

$$\text{var}(v) = \frac{1}{n-1} \sum_{k=1}^n (v[k] - E\{v\})^2. \quad (5.22)$$

Daher erfolgt die Analyse des Messrauschens in verschiedenen stationären Betriebspunkten. Da sich die ermittelten Werte über den gesamten Betriebsbereich der Maschine nur geringfügig ändern, bietet sich eine Mittelwertbildung an, wodurch sich der nachfolgend genutzte Initialwert $\mathbf{R}_0 = \text{diag}(10^{-3})$ ergibt.

- **Initialisierung der Kovarianzmatrix des Prozessrauschens:** Bei der Umsetzung der OPI im realen System zeigt sich, dass selbst marginale Änderungen des initialen Prozessrauschens eine drastische Auswirkung auf das Identifikationsergebnis haben können. Die Initialisierung der Kovarianzmatrix des Prozessrauschens \mathbf{Q}_0 erfolgt daher heuristisch und bestimmt die finale Einstellung des Konvergenzverhaltens.
- **Initialisierung der Zustände und Parameter:** Die Initialisierung der Zustände erfolgt anhand der Momentanwerte des gemessenen Stroms und des geschätzten Rotorflusses. Für die zu identifizierenden Parameter ist es sinnvoll die nominalen Werte der ESB-Parameter zu initialisieren. Dadurch lässt sich das Risiko einer durch die Initialwerte verursachten Divergenz minimieren. Der initiale Systemzustandsvektor ergibt sich daher wie folgt:

$$\hat{\mathbf{x}}_0 = \left[i_{s,0}^\alpha \quad i_{s,0}^\beta \quad \Psi_{r,0}^\alpha \quad \Psi_{r,0}^\beta \quad \frac{1}{L_\sigma} \quad \frac{R_r}{L_m} \quad R_r \quad R_s + R_r \right]. \quad (5.23)$$

In diesem Fall müssen die Initialwerte der Fehlerkovarianzmatrix \mathbf{P}_0 vergleichsweise klein gewählt werden, da die Zustände und Parameter bereits im Bereich der wahren Werte liegen.

- **Spannungsfehler durch Inverter und Taktverzögerung der Strommessung:** Den Einfluss des Spannungsfehlers auf die OPI verdeutlichen die Untersuchungen anhand des RLS-Algorithmus in Abs. 4.4.4. Nicht zuletzt aufgrund der besseren Vergleichbarkeit kommt auch hier das in Abs. 3 beschriebene Umrichtermodell zum Einsatz, um den Spannungsabfall des Wechselrichters in Abhängigkeit des momentanen Betriebspunkts zu kompensieren. Auch die Taktverzögerung bei der Strommessung wird zur Bereitstellung passender Spannungswerte berücksichtigt.

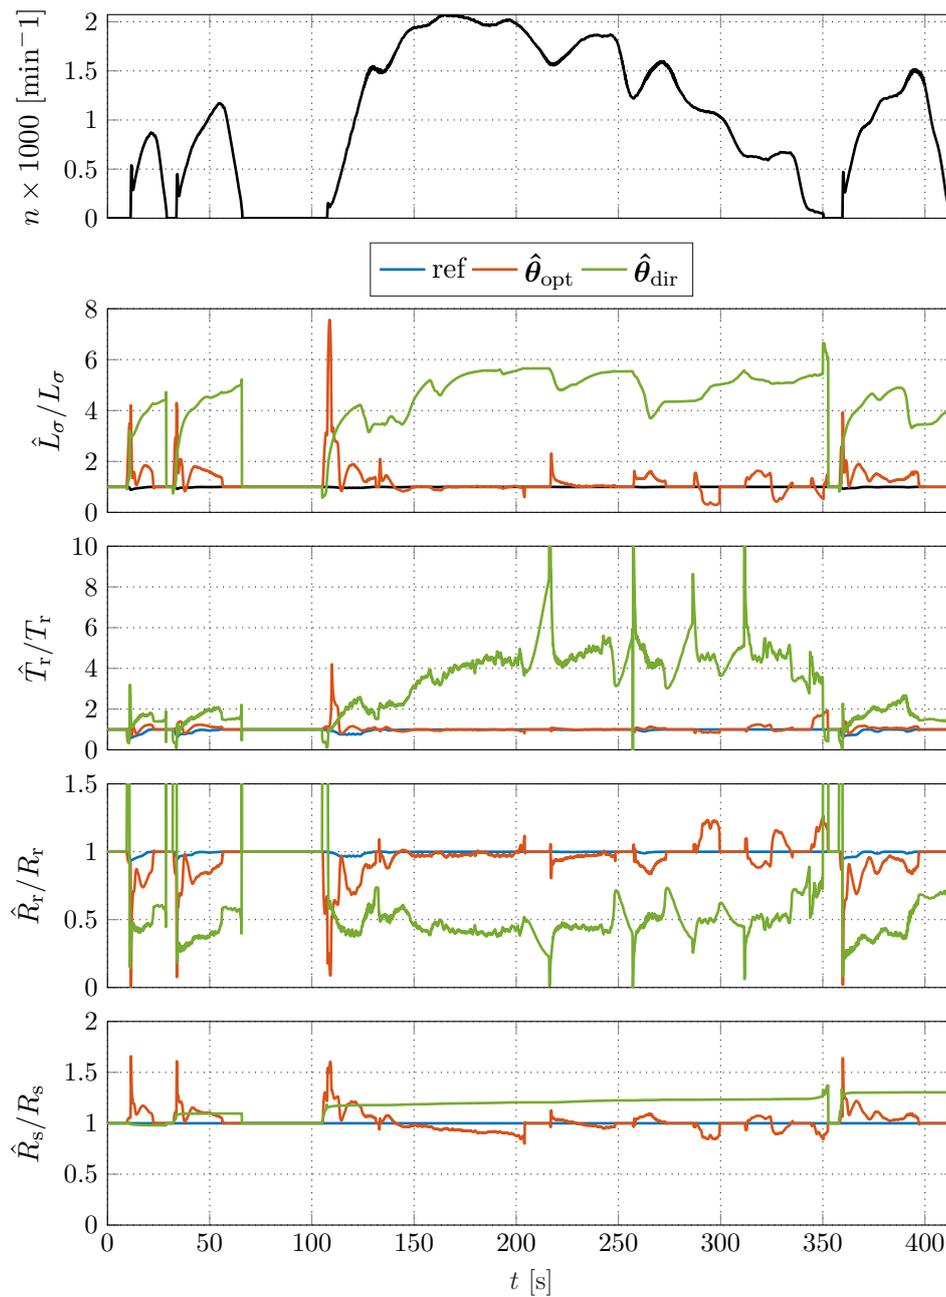


Abbildung 5.8: Experimenteller Vergleich der verschiedenen Identifikationsmodelle mit optimiertem und direktem Parametervektor unter Nutzung des EKF-Algorithmus entlang des WLTP-Zyklus. - Konfiguration $\hat{\theta}_{\text{opt,ekf}}$ Tab. C.8, $\hat{\theta}_{\text{dir,ekf}}$ Tab. C.9.

Vergleich der vollständigen Identifikationsmodelle entlang des WLTP-Zyklus

Die identifizierten Parameter zum Vergleich der vollständigen Identifikationsmodelle sind in Abb. 5.8 dargestellt. Das Modell mit direktem Parametervektor $\hat{\theta}_{\text{dir}}$ zeigt bei der OPI des realen Systems ungenügendes Verhalten und einen großen Schätzfehler für alle identifizierten Parameter. Bei der Identifikation des Statorwiderstands ergibt sich eine scheinbar stabile Schätzung, die jedoch mit steigender Drehzahl ein zunehmend divergierendes Verhalten hin-

weg vom wahren Wert aufweist. Die induktiven Parameter weisen trotz der Initialisierung nahe des wahren Wertes einen ungewöhnlich hohen Schätzfehler auf. Der tatsächliche Verlauf der Identifikation von \hat{L}_σ und \hat{T}_r offenbart, dass eine Konvergenz des Algorithmus zu keinem Zeitpunkt stattfindet, wodurch eine ausreichend flexible Reaktion auf dynamische Parameteränderungen nicht möglich ist. Eine Begründung hierfür ist die komplexe nichtlineare Struktur des ZRM (5.4) die sich im Vergleich zur simulativen Untersuchung im realen System durch zusätzliches Prozessrauschen bemerkbar macht. Im Identifikationsverlauf der Rotorzeitkonstante sind zusätzlich sehr hohe Ausschläge mit beginnender Entschleunigung der Maschine zu beobachten. Diese sind bedingt durch eine starke Änderung des Drehmoments und damit des Stroms, wodurch wiederum die Anregung entfällt. Bei wiederkehrender Beschleunigung bewegt sich \hat{T}_r umgehend in den Bereich des ursprünglichen Identifikationswertes zurück. Außerdem macht sich die Kopplung der Modellparameter θ_2 und θ_3 über R_r durch komplementäres Verhalten im Ergebnis von R_r bemerkbar. Trotz des instabilen Verhaltens tritt bedingt durch die fortlaufende Anregung keine Divergenz auf. Jedoch ist die Konfiguration aufgrund des allgemein hohen Schätzfehlers unbrauchbar.

Im Vergleich dazu zeigt das Identifikationsmodell mit optimiertem Parametervektor (5.6) deutlich agileres Verhalten und der Schätzfehler ist allgemein signifikant geringer. Auch mit dieser Konfiguration ergeben sich jedoch sichtbare Probleme bei der Identifikation von L_σ . Mit beginnender Beschleunigung zeigen sich ausgeprägte Ausschläge, wodurch sich die sättigungsbedingten Parameteränderungen in undefiniertem Verhalten des Algorithmus äußern. Da der Algorithmus nach der jeweiligen Laständerung wieder in den Bereich des wahren Wertes konvergiert, ist keine Divergenz zu erwarten. Die beobachteten Ausschläge äußern sich jedoch auch signifikant in der Identifikation der übrigen Parameter. Zur Kompensation nutzt der Algorithmus die rein ohmschen Identifikationsparameter, weswegen diese ähnliche Ausschläge aufweisen. Der Sättigungsverlauf der Hauptinduktivität, repräsentiert durch \hat{T}_r , ist bedingt durch die Kopplung mit \hat{R}_r ebenfalls nicht definiert identifizierbar. Trotz des verhältnismäßig geringen Schätzfehlers ist die erzielte Genauigkeit bei der Identifikation von \hat{T}_r nicht ausreichend.

Die OPI mit vollständigem Identifikationsmodell liefert mit keiner der beiden Konfigurationen überzeugende Ergebnisse im untersuchten dynamischen Betrieb, wie auch der mittlere Identifikationsfehler in Tab. 5.1 zeigt. Hierbei macht sich die langsame Konvergenz im Zusammenhang mit den schnellen dynamischen Parameteränderungen besonders bemerkbar. Im Vergleich zu den simulativen Ergebnissen in Abb. 5.6 ergeben sich gerade durch die Nutzung des Modells mit direktem Parametervektor im realen System besonders hohe Abweichungen. Allgemein ergeben sich auch experimentell Probleme bedingt durch die Identifikation von L_σ .

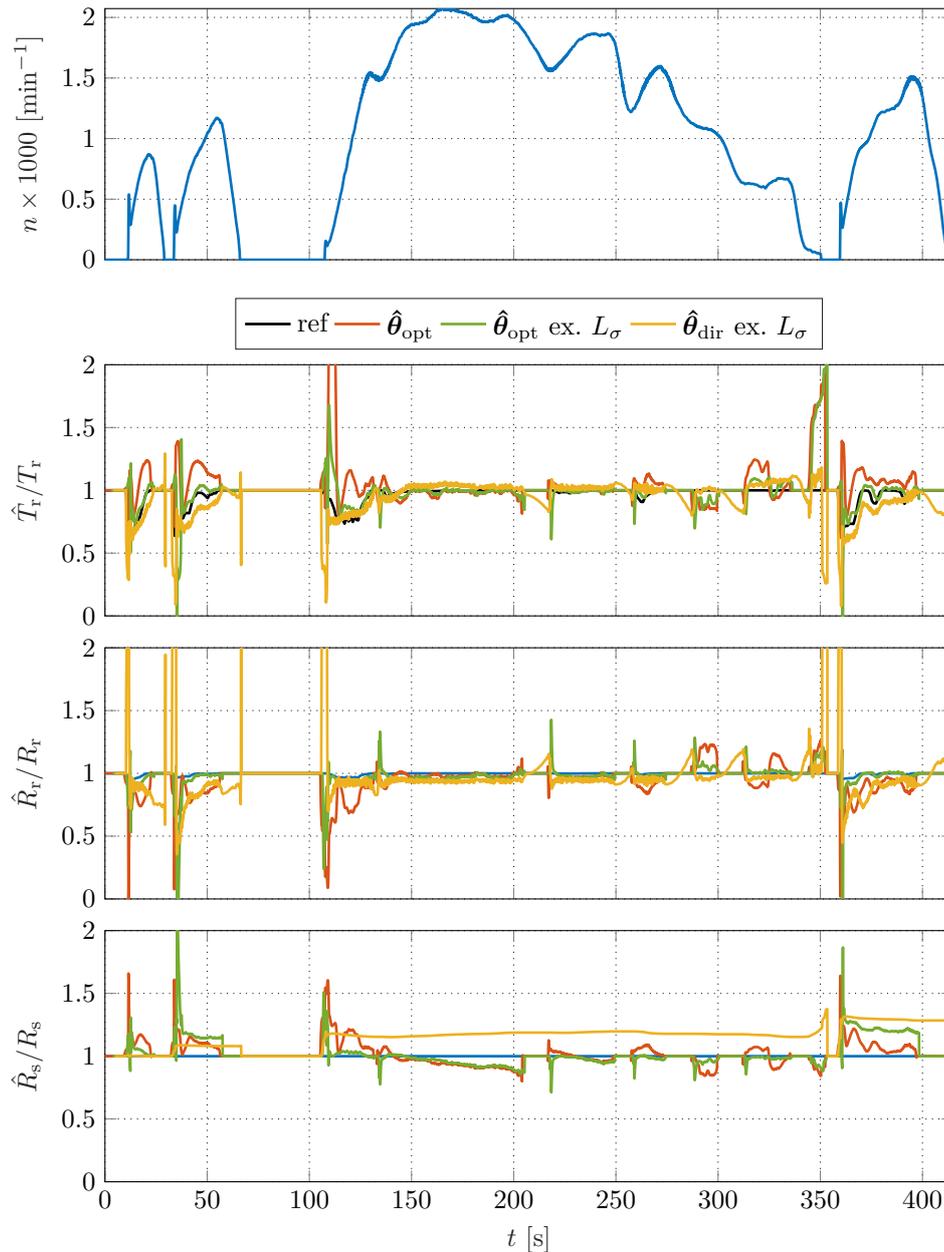


Abbildung 5.9: Experimenteller Vergleich der verschiedenen Identifikationsmodelle mit optimiertem und direktem Parametervektor und Vorgabe der Streuinduktivität L_σ unter Nutzung des EKF-Algorithmus entlang des WLTP-Zyklus. - Konfiguration $\hat{\theta}_{\text{opt,ekf}}$ Tab. C.8, $\hat{\theta}_{\text{dir,ekf}}$ Tab. C.9. Zur Vorgabe einzelner Parameter bei den Versuchsläufen $\hat{\theta}_{\text{opt ex. } L_\sigma}$ und $\hat{\theta}_{\text{dir ex. } L_\sigma}$ ist der jeweilige Referenzwert $\theta_{x,\text{ref}}$ vorzugeben und die Parameterunsicherheit in $Q_{xx,\theta}$ auf null zu setzen.

Vergleich der Identifikationsmodelle bei Vorgabe von L_σ entlang des WLTP-Zyklus

Aufgrund der unzureichenden Ergebnisse mit den vollständigen Identifikationsmodellen und der Kenntnisse aus den simulativen Untersuchungen in Abs. 5.4.2, erscheint es auch experimentell sinnvoll, die OPI mit reduziertem Parametervektor durchzuführen. Wie bereits erwähnt, bestätigt sich die Vorgabe des Statorwiderstands durch diverse Voruntersuchun-

gen als nicht zielführend. Daher wird nachfolgend die Performanz beider erweiterten ZRM (5.6),(5.4) unter Vorgabe der Streuinduktivität anhand des WLTP-Zyklus analysiert.

Die Betrachtung der Ergebnisse in Abb. 5.9 offenbart eine signifikante Verbesserung der Genauigkeit durch die Vorgabe von L_σ . Zum Vergleich zu den Ergebnissen aus dem vorherigen Abschnitt ist der Verlauf des vollständigen Identifikationsmodells zusätzlich abgebildet. Beginnend mit der Identifikation von \hat{T}_r zeigt sich, dass die sättigungsbedingten dynamischen Parameteränderungen durch beide Konfigurationen grundsätzlich identifizierbar sind. Zwar sind auch hier bedingt durch schnelle Laständerungen hohe Ausschläge ersichtlich, jedoch erfolgt anschließend umgehend die Konvergenz in den Bereich des wahren Wertes. Die Konfiguration mit direktem Parametervektor weist allgemein einen höheren Schätzfehler auf und reagiert zusätzlich sensibel auf entschleunigendes Verhalten der Maschine. Hingegen verläuft die Identifikation der sättigungsbedingten Parameteränderungen im Fall des optimierten Parametervektors zuverlässig, wobei eine leichte Latenz durch das träge Konvergenzverhalten des EKF-Algorithmus zu beobachten ist. Auch die Identifikation der rein ohmschen Parameter wird in beiden Fällen durch die schnellen Laständerungen beeinflusst. Der tatsächliche Verlauf von \hat{R}_r ist jedoch bei Nutzung des optimierten Parametervektors genauer und es stellt sich ein deutlich geringerer Schätzfehler ein. Auch das Ergebnis von \hat{R}_s zeigt bei Nutzung des optimierten ZRM einen geringeren mittleren Fehler. Jedoch ist der Verlauf des eigentlichen Parameters R_s von keiner der beiden Konfigurationen identifizierbar.

Grundsätzlich erweist sich das Modell mit optimiertem Parametervektor als überzeugendere Option zur Identifikation dynamischer Parameteränderungen, wie auch der mittlere Identifikationsfehler in Tab. 5.1 zeigt. Allerdings macht sich das träge Konvergenzverhalten trotz der Vorgabe von \hat{L}_σ in beiden Konfigurationen bemerkbar. Zusätzlich ist eine Abhängigkeit des Schätzfehlers vom momentanen Betriebspunkt der Maschine zu beobachten.

Analyse des Fehler- und Konvergenzverhaltens anhand stationärer Betriebspunkte

Die Sensitivität des Schätzfehlers und des Konvergenzverhaltens gegenüber Drehzahl- und Lastpunktänderungen birgt im Hinblick auf die geplante Diagnoseanwendung eine gewisse Unsicherheit. In diesem Abschnitt erfolgt daher eine betriebspunktabhängige Analyse der Konvergenz und des Schätzfehlers anhand eines Testprofils mit verschiedenen stationären Drehzahl- und Lastpunkten. Ziel ist dabei die Festlegung von Konfidenzintervallen innerhalb des Betriebsbereichs der Maschine. Aus den Untersuchungen der vorherigen Abschnitte geht das Identifikationsmodell mit optimiertem Parametervektor und Vorgabe der Streuinduktivität in Verbindung mit dem EKF-Algorithmus als beste Option hervor. Die Vorgabe von L_σ beeinflusst besonders die dynamischen Eigenschaften des EKF. Der Schätzfehler sinkt dagegen lediglich in geringem Maße, wie der mittlere Identifikationsfehler in Tab. 5.1 zeigt. Zur umfassenden Untersuchung der EKF Eigenschaften anhand des stationären Testprofils

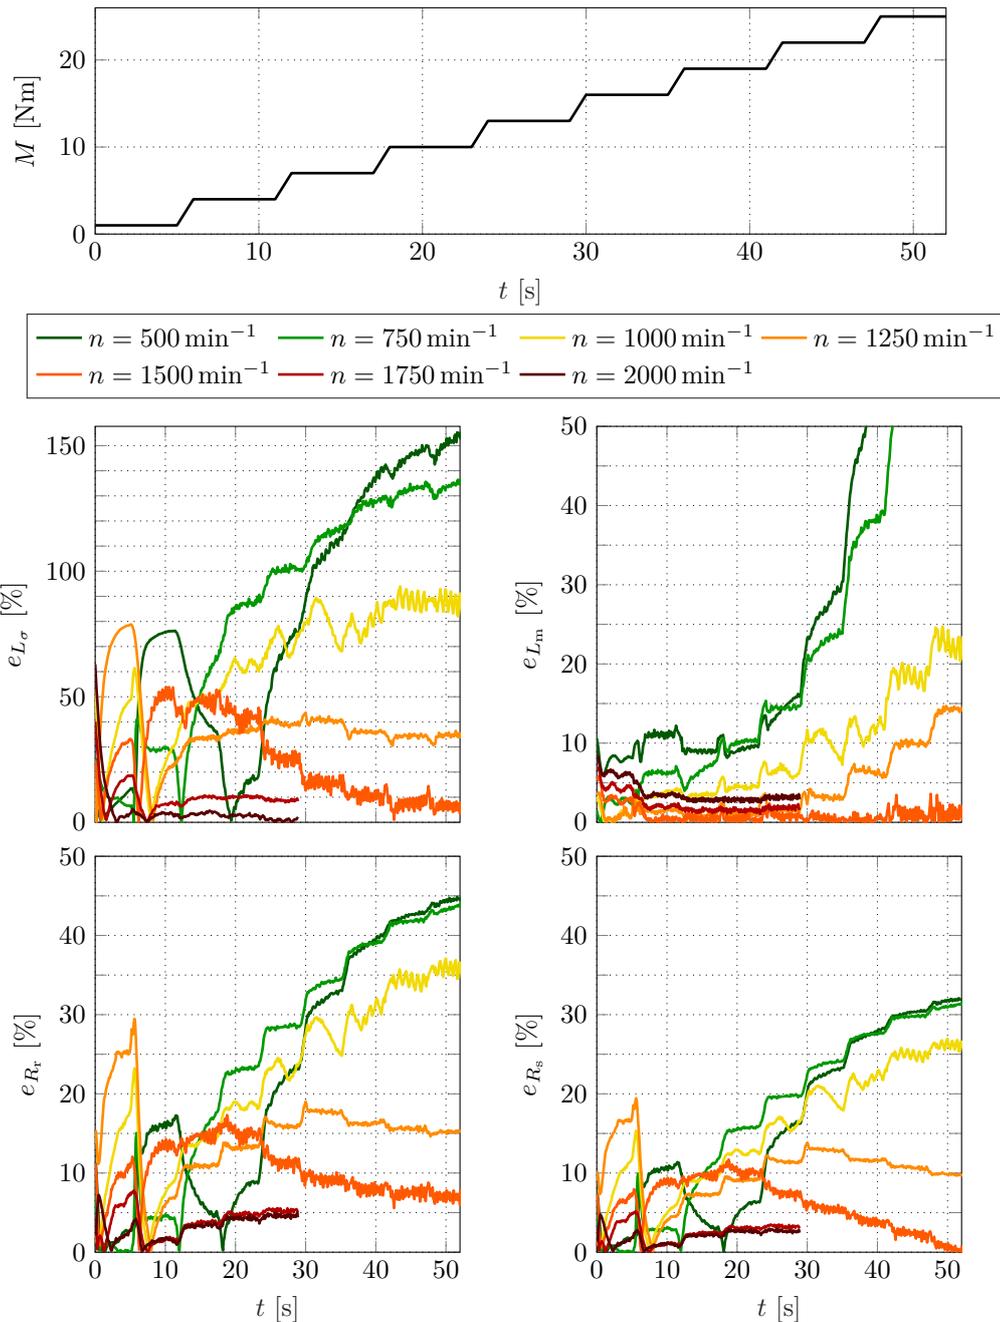


Abbildung 5.10: Experimenteller Vergleich der Performanz des EKF-Algorithmus über das gesamte Kennfeld in verschiedenen stationären Betriebspunkten unter Nutzung des Identifikationsmodells mit optimiertem Parametervektor. - Konfiguration $\hat{\theta}_{\text{opt,ekf}}$ Tab. C.8.

wird daher das vollständige Modell mit optimiertem Parametervektor genutzt. Dabei erfolgt die Belastung der Maschine bei mehreren konstanten Drehzahlen von $n = 500 \dots 2000 \text{ min}^{-1}$ mit dem im oberen Teil von Abb. 5.10 illustrierten Drehmomentprofil. Zur Einstellung variierender Sättigungspunkte bietet sich analog zum dynamischen Testprofil die Nutzung der in Abs. 3 beschriebenen Stromtrajektorie an.

Die Ergebnisse der identifizierten Parameter finden sich im unteren Teil von Abb. 5.10. Inge-

samt ist eine signifikante Änderung des jeweiligen Fehlers in Abhängigkeit des Betriebspunktes deutlich zu erkennen. Allgemein ist der Identifikationsfehler bei niedrigen Drehzahlen $n = 500 \dots 1000 \text{ min}^{-1}$ besonders hoch. Dieses Problem tritt bei Nutzung des dynamischen Zyklus in Abb. 5.9 nicht auf, da die niedrigen Drehzahlbereiche lediglich während der Beschleunigungsvorgänge durchfahren werden. Des Weiteren ist bei niedrigen Drehzahlen nur langsam konvergierendes Verhalten zu erkennen und im Fall einer konstanten Drehzahl von $n = 1000 \text{ min}^{-1}$ ist eine Tendenz zur Instabilität zu beobachten. Ab einer Drehzahl von $n = 1250 \text{ min}^{-1}$ beginnt der Schätzfehler drastisch zu sinken. Neben der Drehzahl hat auch der momentane Lastpunkt der Maschine einen Einfluss auf den Schätzfehler.

Wie aufgrund der vorherigen Untersuchungen zu erwarten, zeigt die Identifikation von \hat{L}_σ im Vergleich zu den übrigen Parametern in den meisten Betriebspunkten deutlich höhere Fehler. Mit zunehmender Drehzahl und Last ergibt sich eine höhere Genauigkeit. Im Drehzahlbereich $n = 1250 \dots 1500 \text{ min}^{-1}$ zeigt sich eine besonders hohe Abhängigkeit vom Lastpunkt, während sich bei höheren Drehzahlen unabhängig von der Last ein vergleichsweise niedriger, konstanter Fehler $e_{L_\sigma} \leq 10 [\%]$ einstellt. Auch die Identifikation der Hauptinduktivität L_m erfolgt bei hohen Drehzahlen $n = 1500 > \text{min}^{-1}$ konstant und zuverlässig mit geringem Fehler $e_{L_m} \leq 5 [\%]$. Im unteren Drehzahlbereich besteht jedoch eine starke Abhängigkeit vom Lastpunkt und der Schätzfehler ist unzureichend hoch. Gemäß der theoretischen Sensitivitätsanalyse lassen sich die induktiven Parameter auch experimentell bei höheren Drehzahlen am besten identifizieren. Der Vergleich von \hat{L}_σ und \hat{R}_r offenbart eine Korrelation im Verlauf der Identifikationsfehler, der sich auf die hohe Sensitivität der Hauptinduktivität \hat{L}_m im Fall der betrachteten Maschine zurückführen lässt. Die Betrachtung der ohmschen Identifikationsparameter zeigt, dass der jeweilige Schätzfehler bei hohen $n = 1500 > \text{min}^{-1}$ und niedrigen Drehzahlen $n = 1200 < \text{min}^{-1}$ teils stark mit der Last steigt, wohingegen der Fehler im mittleren Drehzahlbereich sinkt. Aufgrund der nichtlinearen Zusammenhänge in den erzielten Ergebnissen lässt sich dieses Verhalten nicht plausibilisieren. Ein konstantes Fehlerverhalten über den gesamten Lastbereich, wie es die induktiven Parameter im Bereich hoher Drehzahlen aufweisen, ist bei den ohmschen Parametern nicht zu beobachten.

Allgemein ist das Ziel einer robusten OPI über den gesamten Betriebsbereich als anspruchsvoll zu bewerten. Die robuste Identifikation der induktiven Parameter beschränkt sich auf bestimmte Betriebspunkte und ist lediglich für sehr spezifische Anwendungen einsetzbar. Bemerkenswert ist die steigende Genauigkeit der ohmschen Parameter mit der Drehzahl. Im Vergleich zu den Regressionsmodellen bei der OPI mit RLS-Algorithmus enthält das genutzte erweiterte ZRM (5.6) keine unabhängigen ohmschen Modellterme, weswegen sich die Problematik bezüglich der geringen Sensitivität relativiert. Dennoch ist bei der Identifikation von \hat{R}_s und \hat{R}_r kein definiertes Muster zur Beschreibung des Identifikationsfehlers zu erkennen. Nach den durchgeführten Untersuchungen ist eine ausreichend robuste Parameteridentifikation nur in einem eingeschränkten Drehzahlbereich $n = 1750 \dots 2000 \text{ min}^{-1}$ möglich. Aufgrund der allgemein stark Betriebspunktabhängigen absoluten Identifikations-

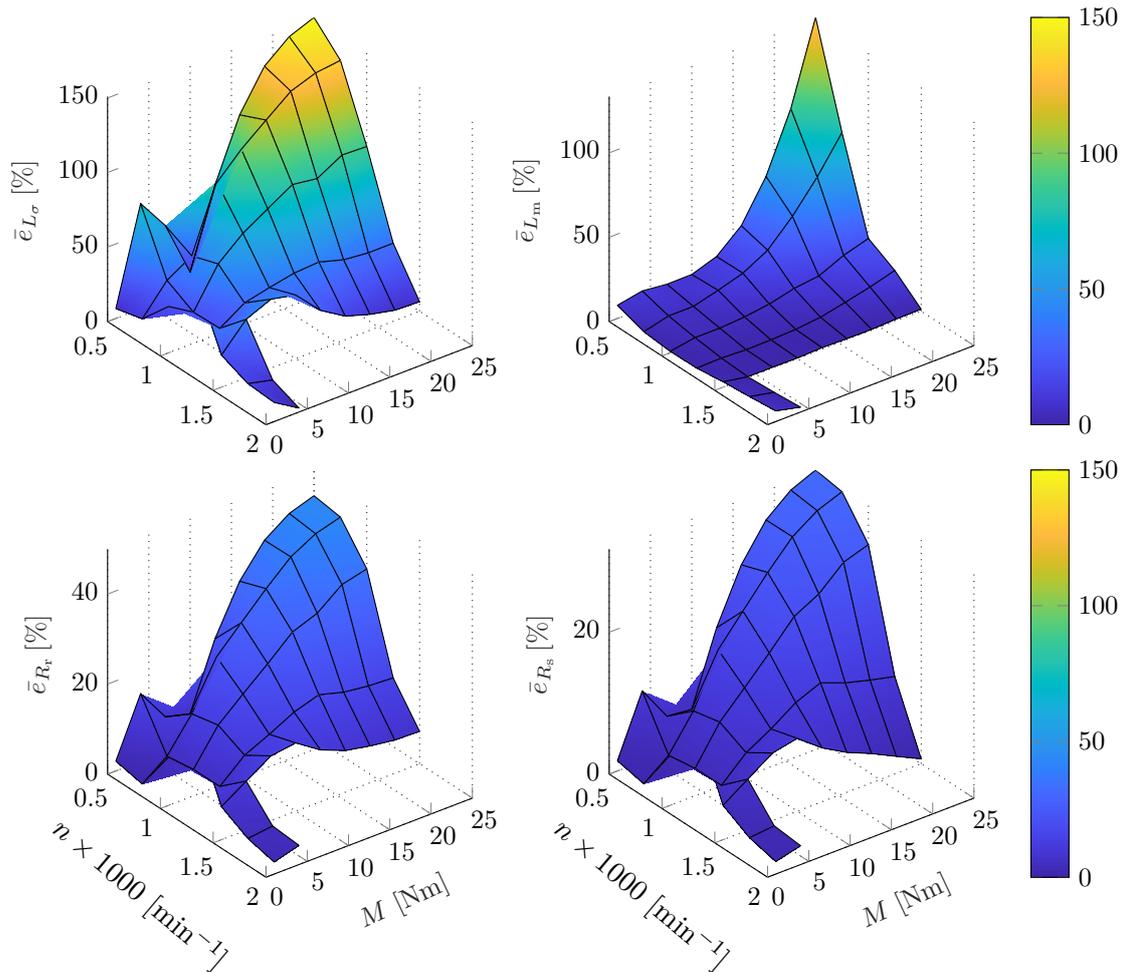


Abbildung 5.11: Experimenteller Vergleich der Performanz des EKF-Algorithmus über das gesamte Kennfeld in verschiedenen stationären Betriebspunkten unter Nutzung des Identifikationsmodells mit optimiertem Parametervektor. - Konfiguration $\hat{\theta}_{\text{opt,ekf}}$ Tab. C.8.

fehler ist kein wirkliches Verhaltensmuster des Schätzfehlers interpretierbar. Die Festlegung von Konfidenzintervallen im Hinblick auf eine technische Diagnose ist daher lediglich mit sehr definierten, engen Begrenzungen und für bestimmte Parameter möglich. Eine Übersicht über die mittleren Identifikationsfehler je untersuchtem stationären Betriebspunkt zeigt Abb. 5.11. Die starken betriebspunktabhängigen Änderungen der stationären Fehler werden durch diese Darstellung nochmals verdeutlicht. Auch das robustere Verhalten der identifizierten Hauptinduktivität \hat{L}_m im Vergleich zu den übrigen Parametern ist deutlich ersichtlich.

5.4.4 Zusammenfassung und Diskussion

Zur abschließenden Bewertung der OPI mittels erweiterter KF erfolgt eine Zusammenfassung und Diskussion der Ergebnisse. Eine Übersicht über die mittleren Identifikationsfehler aller simulativen und experimentellen Testzyklen zeigt Tab. 5.1. Erwartungsgemäß unterscheiden sich auch hier die simulativen deutlich von den experimentellen Resultaten.

Der simulative Vergleich der untersuchten KF-Algorithmen zeigt grundsätzlich, dass EKF und UKF zur OPI der ASM in einem dynamischen Umfeld geeignet sind. Der direkte Vergleich anhand des mittleren Identifikationsfehlers in Tab. 5.1 gibt jedoch erste Anzeichen auf eine bessere Eignung des EKF-Algorithmus. Das vergleichsweise träge Konvergenzverhalten und der höhere Schätzfehler in Verbindung mit dem zusätzlichen Parametrisierungsaufwand durch die Hyperparameter sowie der längeren Berechnungszeit sprechen gegen die Nutzung des UKF in Bezug auf das in dieser Arbeit zu identifizierende System. Weder die Festlegung einer individuellen Wahrscheinlichkeitsverteilung, noch der bessere Umgang mit stark nichtlinearen Systemen ergeben sich als relevante Vorteile für die dynamische OPI der ASM. Erste experimentelle Identifikationsläufe mit dem UKF-Algorithmus bestätigen die simulativ ermittelten Ergebnisse weswegen der Einsatz des EKF fokussiert wird.

Der Vergleich der beiden vollständigen Identifikationsmodelle ergibt deutliche Unterschiede zwischen simulativen und experimentellen Ergebnissen. Im simulativen Vergleich liefert das Modell mit direktem Parametervektor $\hat{\theta}_{\text{dir}}$ überzeugendere Ergebnisse. Obwohl der mittlere Fehler in Tab. 5.1 lediglich marginal kleiner ausfällt, ist die Genauigkeit bei der Identifikation dynamischer Parameteränderungen meist makellos im Vergleich zur Nutzung des optimierten Parametervektors $\hat{\theta}_{\text{opt}}$. Der experimentelle Vergleich hingegen offenbart signifikante Schwierigkeiten im Umgang mit $\hat{\theta}_{\text{dir}}$, sodass die vollständige Identifikation lediglich unbrauchbare Ergebnisse liefert. Dabei tritt besonders der hohe Schätzfehler von \hat{L}_σ in Erscheinung. Für die OPI des realen Systems kommt demnach der Nachteil durch die komplexere nichtlineare Modellstruktur zum tragen. Auch die experimentellen Ergebnisse der OPI mit Nutzung von $\hat{\theta}_{\text{opt}}$ ergeben Schwierigkeiten bei der Identifikation von \hat{L}_σ . Die Vorgabe von R_s führt simulativ zu einer deutlichen Verbesserung, während sie experimentell zur Instabilität und Divergenz des EKF führt. Hingegen ergibt sich durch die Vorgabe von L_σ experimentell eine deutliche Verbesserung der mittleren Identifikationsfehler beider Modelle. Schlussendlich ist jedoch bei Nutzung des optimierten Parametervektors die Genauigkeit bei der Identifikation dynamischer Parameteränderungen höher und das Konvergenzverhalten des EKF stabiler. Allgemein ist eine starke Sensitivität der erweiterten KF-Algorithmen gegenüber dem Betriebspunkt der Maschine zu beobachten. Zusätzlich hängt das Konvergenzverhalten und der Schätzfehler signifikant von der Wahl der Initialisierungswerte in Verbindung mit dem Startbetriebspunkt ab. Unter Umständen führen bereits kleine Änderungen zur Divergenz des Algorithmus. Die Parametrierung ist daher sehr aufwendig und ein universeller Datensatz ist im Anwendungsgebiet dieser Arbeit aufgrund unterschiedlichster Fahrprofile nicht umsetzbar. Erschwerend kommt hinzu, dass das genaue Prozessrauschen im Simulationsmodell nicht darstellbar ist. Daher unterscheiden sich die simulativ und experimentell festgelegten Initialisierungswerte deutlich, wodurch die Nutzung des Simulationsmodells zur Optimierung nicht möglich ist. Zur Beurteilung des Optimierungspotentials lassen sich folgende Fehlerquellen bei der OPI mit erweiterten KF-Algorithmen zusammenfassen:

- Die Bewertung des entstehenden Identifikationsfehlers erfolgt basierend auf einem universellen Referenzdatensatz der genutzten ASM. Aufgrund von Produktionstoleranzen, Alterungseffekten und Fehlern bei der Ermittlung der Referenzparameter ist die Genauigkeit dieser Datensätze stets zu hinterfragen.
- Fehler durch Modellungenauigkeiten treten bei der OPI mittels erweiterter KF durch Prozessrauschen in Erscheinung. Durch Erweiterung des zugrundeliegenden ZRM ist es möglich, die Unstimmigkeiten zwischen realem System und Modell zu verkleinern. Jedoch gilt es dabei, den Zielkonflikt zwischen Komplexität und Rechenzeit zu beachten.
- Die Art und Anzahl der identifizierten Parameter ist entscheidend für die Performanz der OPI. Die Dimension und Zusammensetzung des Parametervektors muss individuell für jedes Identifikationsproblem festgelegt werden. Eine theoretische Einschätzung zum Vergleich verschiedener Konfigurationen ist durch die Beobachtbarkeitsanalyse in Abs. 5.3 möglich.
- Die Initialisierung der nicht messbaren Zustände ist vor allem im realen System essenziell für die Konvergenz der KF. Die zur Schätzung dieser Zustände genutzten Modelle sind in der Regel selbst parametersensitiv. Ein optimiertes Schätzmodell mit Parameteradaption, wie das Rotorflussmodell im Fall dieser Arbeit, trägt entscheidend zu einer Verbesserung der Ergebnisse bei.
- Die Initialisierung der Kovarianzen ist wesentlich für valide Identifikationsergebnisse. Die Anpassung während des Betriebs durch adaptive KF birgt zwar Optimierungspotential, ist jedoch aus Komplexitätsgründen für die Anwendung in dieser Arbeit keine Option. Auch eine simulative Optimierung ist aufgrund der zwangsläufigen Modellungenauigkeiten und vielfältigen Fahrscenarien schwierig umsetzbar.

Abschließend erfolgt ein Vergleich der OPI mittels erweitertem KF- zum RLS-Algorithmus. Die Initialisierung und Parametrisierung der erweiterten KF-Algorithmus ist im Vergleich zum RLS-Algorithmus deutlich aufwendiger. Aufgrund des trägen Konvergenzverhaltens und der hohen Sensitivität gegenüber den Initialwerten und unterschiedlichen Betriebspunkten, lässt sich die Robustheit im untersuchten Anwendungsgebiet als vergleichsweise gering einstufen. Auch die Konvergenz nach dynamischen Parameteränderungen verläuft dadurch vergleichsweise langsam.

Als grundsätzlicher Vorteil gegenüber dem RLS-Algorithmus ist der flexible Aufbau des Identifikationsmodells durch die Nutzung des ZRM zu werten. Die Anzahl und Struktur der identifizierten Parameter ist darin im Vergleich zum Regressionsmodell frei wählbar, wodurch auch deren Sensitivität gegenüber dem Modell beeinflussbar ist. Aufgrund dieser Tatsache

Tabelle 5.1: Simulativer Vergleich des mittleren Identifikationsfehlers \bar{e} verschiedener KF-Algorithmen und Identifikationsmodelle entlang des WLTP-Zyklus.

Konfiguration	sim/meas	\bar{e}_{L_σ} [%]	\bar{e}_{T_r} [%]	\bar{e}_{R_r} [%]	\bar{e}_{R_s} [%]
UKF mit $\hat{\theta}_{\text{opt}}$	sim	3,26	2,44	1,16	4,36
	meas	-	-	-	-
EKF mit $\hat{\theta}_{\text{opt}}$	sim	1,29	1,83	0,90	1,93
	meas	26,02	9,18	6,59	5,43
EKF mit $\hat{\theta}_{\text{dir}}$	sim	1,83	1,08	0,89	0,74
	meas	305,40	219,60	48,15	17,26
EKF mit $\hat{\theta}_{\text{opt}}$ ex. R_s	sim	0,04	1,87	1,66	-
	meas	-	-	-	-
EKF mit $\hat{\theta}_{\text{opt}}$ ex. L_σ	sim	-	1,74	0,05	1,6
	meas	-	7,95	3,09	5,38
EKF mit $\hat{\theta}_{\text{dir}}$ ex. L_σ	sim	-	-	-	-
	meas	-	6,42	12,65	14,97

ist im Vergleich zum RLS-Algorithmus eine gleichzeitige und vergleichsweise robuste OPI aller ESB-Parameter möglich. Die im vorherigen Absatz beschriebene Problematik bezüglich des Schätzfehlers bei dynamischen Parameteränderungen bleibt jedoch bestehen. Daher ist dieser Vorteil in Bezug auf die Anwendung in dieser Arbeit irrelevant. Ein weiterer in dieser Arbeit lediglich peripher thematisierter Vorteil der erweiterten KF-Algorithmen ist die integrierte und parameteradaptive Schätzung nicht messbarer elektrischer Systemzustände, wie zum Beispiel des Rotorflusses. Diese bieten sich wiederum als Möglichkeit zur Validierung der identifizierten Parameter an. Dazu muss ein Vergleich zu einer durch ein Schätzmodell rekonstruierten Größe erfolgen, wodurch die Parametersensitivität der Referenzgröße in der Regel vernachlässigt wird. Das Vorgehen eignet sich jedoch für eine grundsätzliche Plausibilisierung. Zur Lösung des Problems bietet sich an, das ZRM um ein Drehmomentmodell zu erweitern, dessen Ausgang mit einer unabhängigen Drehmomentmessung vergleichbar ist. Eine Drehmomentmessung ist aber aus Kostengründen in vielen Systemen nicht vorgesehen, weswegen diese Option für den Online-Einsatz entfällt.

Basierend auf den durchgeführten simulativen und experimentellen Untersuchungen stellt sich der RLS-Algorithmus in Betracht der spezifischen Anforderungen dieser Arbeit als besser geeignet heraus. Nicht zuletzt wegen der geringeren Rechenzeit und der damit verbundenen Vorteile zur Echtzeitimplementierung, ergibt sich die OPI mittels RLS-Algorithmus als bevorzugte Lösung.

6 Ableitung von Diagnosekonzepten

Übergeordnetes Ziel dieser Arbeit ist die Ableitung geeigneter Diagnosekonzepte basierend auf der in den vorherigen Kapiteln untersuchten OPI. Dabei besteht auch hier die bekannte Echtzeitanforderung mit stark limitierter Rechenkapazität in Bezug auf das betrachtete automotiv Einsatzgebiet. Nachfolgend wird der Stand der Technik zur Online-Diagnose der ASM durch verschiedene Ansätze erweitert. Die durchgeführten Untersuchungen beziehen sich in diesem Kapitel auf simuliertes Fehlverhalten, da eine tatsächliche Manipulation realer Maschinen, nicht zuletzt aus Sicherheitsgründen, komplex ist und daher einer aufwendigen Planung und Durchführung bedarf.

Im Betrieb der ASM können verschiedene Fehler zu unerwünschtem Verhalten führen. Eine tabellarische Übersicht über unterschiedliche Fehlertypen zeigt [152, S.7]. Diese lassen sich grundsätzlich in mechanisch und elektrisch hervorgerufene Fehler unterscheiden und haben verschiedenste Auswirkungen auf das Antriebssystem beziehungsweise die Maschine. Ein Großteil der Fehler bei industriellem Einsatz trat, basierend auf Erhebungen aus 2008, laut [153] aufgrund von mechanischen Schäden an Lagern und am Aufbau auf. Ein deutlich geringerer Anteil ergab sich im Zusammenhang mit Beschädigungen an Stator und Rotor. Die Verteilung der auftretenden Fehler hängt jedoch in erheblichem Maße von der Betriebsart der Maschinen ab. Entsprechende Erhebungen zu Traktionsmaschinen in Automobilen existieren nach Stand der Technik nicht. Für die in dieser Arbeit untersuchten Methoden sind lediglich Fehler mit direktem Einfluss auf das elektrische Verhalten der Maschine relevant, da die verwendeten Systemmodelle keine mechanischen Zusammenhänge abbilden. Dazu zählen unter anderem Isolationsfehler, Windungsschlüsse und Kurzschlüsse in der Statorwicklung, sowie Brüche von Rotorstäben und des Kurzschlussrings. Zusätzlich beeinflussen etwaige Produktionsmängel und alternde Materialien die induktiven und ohmschen Parameter der Maschine. Der Grad der Materialalterung hängt von der thermischen Beanspruchung durch die Betriebsstrategie sowie von eventuellen Umwelteinflüssen ab [152]. Die im folgenden Verlauf des Kapitels dargestellten Ansätze fokussieren die Anomaliedetektion basierend auf Änderungen des Rotorwiderstands und der Hauptinduktivität. Die Diagnose im Statorkreis gestaltet sich aufgrund der in Kap. 4 und Kap. 5 beschriebenen geringen Modellsensitivität des Statorwiderstands im dynamischen Betrieb als herausfordernd. Hierzu bietet sich an auf alternative Diagnosekonzepte im Stillstand der Maschine zurückzugreifen, die im Rahmen dieser Arbeit nicht betrachtet werden.

In der Literatur existieren bereits unterschiedliche Ansätze zur Diagnose von ASM. In diesem

Kapitel wird zunächst der Stand der Technik in Anlehnung an die in [152] vorgenommene Unterteilung erfasst. In Bezug auf die Gegebenheiten im betrachteten Anwendungsgebiet dieser Arbeit ergeben sich die im weiteren Verlauf dieses Kapitels entwickelten Diagnoseansätze. Als Grundlage für erweiterte Methoden zur Diagnose basierend auf analytischen Modellen, dienen die in Kap. 4 und Kap. 5 analysierten OPI-Algorithmen. Des Weiteren ergeben sich neue Ansätze durch die Kombination mit datengetriebenen und heuristischen Modellen.

6.1 Stand der Technik zur Diagnose von Asynchronmaschinen

Gerade der steigende industrielle Einsatz der ASM motivierte die Entwicklung zahlreicher Diagnoseansätze zur Erhöhung der Ausfallsicherheit. Nach der in [152, S.10 ff.] vorgeschlagenen Aufteilung lassen sich diese anhand der genutzten Modelle in zwei Kategorien unterteilen, wie in Abb. 6.1 dargestellt. In der ersten Kategorie basiert die Diagnose auf analytischen Modellen, während Ansätze in der zweiten Kategorie datengetriebene beziehungsweise heuristische Modellansätze nutzen. Der aktuelle Stand der Technik wird nachfolgend basierend auf diesem Schema erfasst, um die Motivation für die in dieser Arbeit entwickelten Ansätze zu verdeutlichen.

6.1.1 Methoden mit heuristischem Modell

Methoden ohne analytisches Modell sind in der Fehlerdiagnose elektrischer Maschinen sehr weit verbreitet. Die einfachste Möglichkeit ist die direkte Nutzung von Zustandsgrößen oder aus deren Spektralanalyse generierten Features zur Anomaliedetektion. Erweiterte Ansätze machen von verschiedenen Algorithmen der Künstlichen Intelligenz (KI) Gebrauch. Für deren Training ist jedoch eine Vorstufe zur Bestimmung systemspezifischer Merkmale notwendig. Diese Merkmale stammen oft aus einer vorgelagerten Signalverarbeitung, wie der Pfeil in Abb. 6.1 andeutet. Die letztendliche Performanz der KI-basierten Methoden hängt daher in erheblichem Maße von der Qualität der Featureextraktion ab.

Signalverarbeitung

Die Analyse der messbaren Signale gilt als sehr mächtiger Ansatz zur Extraktion von Systeminformationen. Die Messgrößen des Systems enthalten unterschiedlichste physikalische und für jeden Fehler spezifische Merkmale. Daher existieren zahlreiche Methoden zur Fehleranalyse in Verbindung mit der Signalverarbeitung von Messgrößen. Diese beschränken sich im Anwendungsgebiet dieser Arbeit auf die von Sensoren erfassten Größen, also den Statorstrom und die Drehzahl. In weiteren Methoden stehen zusätzlich Messungen zum Beispiel durch den Einsatz von Spannungs- und Vibrationssensorik zur Verfügung. Diese werden jedoch

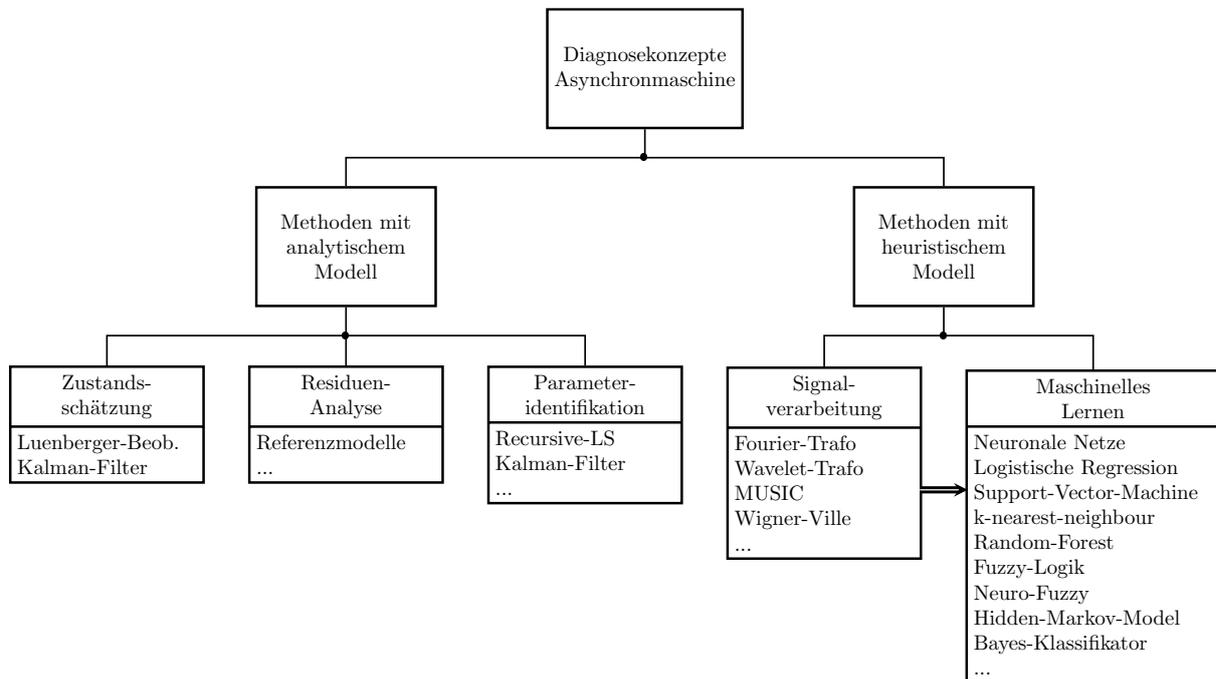


Abbildung 6.1: Übersicht zum Stand der Technik von Diagnosekonzepten für Asynchronmaschinen.

nachfolgend nicht aufgeführt.

Die meisten Ansätze nutzen eine Form der Spektralanalyse zur Extraktion von Fehlermerkmalen zum Beispiel durch Frequenz- beziehungsweise Zeit-Frequenz-Transformationen der gemessenen Signale. Am häufigsten tritt dabei der Statorstrom als Messgröße in Erscheinung, da er aus Regelungs- und Sicherheitsgründen ohnehin qualitativ hochwertig erfasst wird. Dessen Spektrum enthält je nach Vorliegen einer Anomalie Informationen zu mechanischen und elektrischen Fehlern, wie zum Beispiel Lagerschäden, Exzentrizitäten, Rotorstabbrüchen, Statorkurzschlüssen, etc.[154]–[163]. Zur Merkmalsextraktion kommen dabei verschiedene Formen der Spektralanalyse wie die Fourier-Transformation [158]–[161], Wavelet-Transformation [160], [162], [163], Multiple-Signal-Classification [155] oder Wigner-Ville-Verteilung [156] zum Einsatz. Die generierten Features eignen sich durch den Vergleich mit spezifischen Tresholds oder den Spektren fehlerfreier Systeme zur direkten Fehlerdiagnose. Ein allgemeiner Vorteil dieses Vorgehens ist die genaue Zuordnung spezifischer Spektrele zu den verursachenden Fehlern. Jedoch ist diese Aussage nur in Bezug auf die jeweils manipulierte Versuchsmaschine valide. In der Regel existiert keine umfassende Datengrundlage, die den Einfluss anderer Anomalien auf das betrachtete spektrale Merkmal statistisch ausschließt. Des Weiteren ist zur Ermittlung eines hoch aufgelösten Spektrums nach [152] ein breites stationäres Messfenster notwendig und es besteht eine hohe Sensitivität gegenüber der Qualität der Messwerte und der Abtastrate. In Anbetracht des in dieser Arbeit verwendeten limitieren Echtzeitsystems ist der dadurch bedingte hohe Speicher- und Rechenaufwand bei der Spektralanalyse ein bedeutender Nachteil. Zusätzlich ist die Beschränkung auf lange

stationäre Betriebspunkte für das hier berücksichtigte dynamische Anwendungsumfeld nicht förderlich.

Aufgrund des Rechenzeitproblems werden verschiedene Anpassungen bzw. vereinfachte Analyseformen vorgeschlagen [164]–[167]. Neben der Nutzung eines vorgeschalteten Bandpass-Filters in [164], zeigen die Autoren in [166] und [167] eine Möglichkeit den Rechenaufwand zu reduzieren, indem lediglich das Spektrum der Einhüllenden bzw. einer Phase des Statorstroms zur Diagnose dient. Außerdem basieren alternative Ansätze beispielsweise auf der Polynomtransformation [165] und der Hauptkomponentenanalyse [168].

Allgemein ist neben der schwierigen Generalisierbarkeit für den dynamischen Betrieb der Rechenaufwand hinsichtlich der Implementierung auf einem Echtzeitsystem als kritisch zu betrachten. Aufgrund des Einsatzes für Produktionsanlagen finden diese Aspekte in bestehenden Ansätzen keine Berücksichtigung.

Neben dem Einsatz der Spektralanalyse bietet der direkte Vergleich zeitlicher Größen wie zum Beispiel des Stromverlaufs eine ressourcenschonendere Diagnosemöglichkeit. Kral et al. [164] nutzen dazu den Verlauf verschiedener Leistungsgrößen und einen Phasenregelkreis. Für wechselnde dynamische Betriebspunkte ist dabei allerdings ebenfalls der hohe Speicherbedarf der Vergleichsdaten problematisch. Eine Möglichkeit zur Abhilfe bietet die Entwicklung offline-trainierter, datenbasierter Referenzmodelle in Form von echtzeitfähigen Black-Box-Modellen. Ein entsprechender Ansatz wird in Abs. 6.4 präsentiert.

Künstliche Intelligenz

In vielen erweiterten Ansätzen zur Fehlerdiagnose kommen unterschiedliche KI-Algorithmen zum Einsatz. Anhand der existierenden Literatur wird deren Performanz zur spezifischen Anomaliedetektion deutlich. Zur Gewinnung geeigneter Features impliziert der Einsatz von KI-Algorithmen in der Regel vorgeschaltete Methoden zur Signalverarbeitung, wie der Pfeil in Abb. 6.1 andeutet.

Zur Detektion von Inverter- und Rotorfehlern findet der k-nearest-neighbours-Algorithmus als einfacher Ansatz in [169] Anwendung. Dabei kommen sowohl Spektrale als auch direkt aus Zustandsgrößen abgeleitete Features zum Einsatz. Neben den bereits erwähnten Nachteilen bei der Spektralanalyse, ist die für eine zuverlässige Klassifizierung sehr hohe Datenmenge bei Onlineanwendungen nachteilig. Für die in dieser Arbeit verfolgte Zielsetzung ist der Algorithmus daher nicht geeignet.

Weit verbreitet ist der Einsatz künstlicher neuronaler Netze (KNN) zur Fehlerklassifikation. Der allgemeine Trend zur Nutzung verschiedener tiefer KNN-Strukturen ist dabei gerade bei Betrachtung der aktuellsten Referenzen sichtbar. In [170]–[173] kommen tiefe gefaltete- und rekurrente neuronale Netze zum Einsatz, deren Implementierung im betrachteten Umfeld dieser Arbeit zu komplex ist. Die erforderlichen Datenmengen zum überwachten Training sind dabei sehr hoch, wodurch sich bei allen vorgestellten Ansätzen eine außerordentlich

gute Performanz ergibt. Dagegen setzen Salles et al. in [174] und Zaman et al. in [175] Methoden des nicht bzw. teilweise überwachten Lernens ein, die jedoch ebenfalls nicht zur Echtzeitimplementierung geeignet sind. Martins et al. [176] trainieren ein KNN zur Online-Bestimmung der Hauptkomponenten und Sun et al. [177] nutzen ein gefaltetes neuronales Netz zur Generierung verschiedener Features. Beide Ansätze sind jedoch aufgrund der Komplexität nicht für die Echtzeitanwendung geeignet. Die Autoren in [178] und [179] hingegen zeigen echtzeitfähige Ansätze zur Online-Diagnose. Ince et al. [178] nutzen ein kleines gefaltetes neuronales Netz zur Echtzeiterkennung von Lagerschäden. Während des Betriebs ist keine separate Featuregenerierung notwendig. Trotz der einfachen Struktur des angewendeten KNN ist die Implementierung der Faltungsstruktur zu komplex für die in dieser Arbeit auftretenden Taktzeiten des Echtzeitsystems. Auf Basis des park-transformierten Statorstromvektors als Feature und einem einschichtigen Multi-Layer-Perzeptron (MLP) erkennen Nejjari et al. [179] Anomalien im Stator der Maschine. Dieser Ansatz entspricht aufgrund seiner Simplizität den Anforderungen dieser Arbeit. Für die Diagnose komplexerer Anomalien wie zum Beispiel Rotorfehlern sind jedoch zusätzliche Features notwendig, die über die einfache Analyse des Statorstromvektors hinaus gehen. Allgemein werden die meisten existierenden Ansätze zur Fehlerdiagnose in Produktionsanlagen eingesetzt. Dabei liegt die oberste Priorität auf der Ausfallsicherheit und die zur Verfügung stehende Rechenkapazität sowie der Speicherbedarf sind im Normalfall kein begrenzender Faktor. Zusätzlich ergeben sich quasi keine dynamischen Betriebspunktänderungen. Für das automotive Anwendungsgebiet ist daher eine Anpassung KNN-basierter Klassifikatoren erforderlich.

Auch die Support-Vector-Machine (SVM) eignet sich als überzeugender Klassifikator, wie [180]–[182] zeigen. Wie im zuvor genannten Absatz ist jedoch auch hier die Frage nach der Featureextraktion entscheidend. So nutzen Giantomassi et al. [180] die Hauptkomponenten und Pandarakone et al. [182] das Spektrum des Statorstroms als Klassifikationsmerkmale. Daneben ist die Nutzung nichtlinearer Kernel-Funktionen unter Umständen kritisch für die Echtzeitanwendung. Hingegen basiert die zuverlässige Detektion von Windungsschlüssen im Stator in [181] lediglich auf der Amplitude und der Phase des Statorstroms, wobei ausschließlich stationäre Lastpunkte im Bereich der nominalen Drehzahl betrachtet werden. Die gute Performanz der SVM zeigt sich für einfache Klassifikationsaufgaben bereits bei der Nutzung linearer Kernelfunktionen, was für die Umsetzung auf dem limitierten Echtzeitsystem dieser Arbeit vielversprechend ist.

Quiroz et al. [183] nutzen ein Random-Forest-Modell (RFM) zur Diagnose eines Rotorstabilitätsbruchs. Die Struktur des RFM entsteht aus einer Kombination verschiedener Entscheidungsbäume [184]. Die Klassifikation erfolgt ausschließlich basierend auf statistischen Features des Statorstroms im Zeitbereich. Im Vergleich mit der SVM und der logistischen Regression schneidet das RFM am besten ab. Da die Ergebnisse auf dem Einsatz in einer Produktionsanlage basieren, sind jedoch nur stationäre Betriebspunkte inbegriffen. Durch erste Versuche im Rahmen dieser Arbeit ließ sich die gute Performanz in einem dynamischen Betriebsfeld

nicht bestätigen. Des Weiteren erfordern komplexe Baumstrukturen einen hohen Speicherbedarf im Echtzeitsystem, weswegen sich die RFM-basierte Methode für diese Arbeit als nicht sinnvoll ergab. Hingegen ist die Implementierung der logistischen Regression sehr effizient, da sie der Implementierung eines KNN mit einem Neuron gleich kommt. Aufbauend auf [183] wird dieser Klassifikationsansatz in Abs. 6.3 aufgegriffen.

Deutlich komplexere Ansätze ergeben sich durch Nutzung der Fuzzy-Logik [185], [186] oder eines Hidden-Markov-Modells (HMMs) [187], [188]. Nicht selten werden Kombinationen aus verschiedenen heuristischen Modellen zur Featuregenerierung und anschließenden Klassifikation genutzt, wie zum Beispiel die Neuro-Fuzzy-Logik in [189]–[191], ein gefaltetes neuronales Netz zur Zerlegung der Hauptkomponenten in Verbindung mit SVM-Klassifikator in [177] oder ein HMM in Kombination mit einem komplexen Bayes-Klassifikator in [192]. Diese Ansätze ermöglichen eine genauen Klassifizierung über mehrere Fehlerklassen hinweg. Allerdings ist das Erstellen der notwendigen Trainingsdaten und die anschließende Strukturoptimierung nur mit erheblichem Aufwand möglich. Außerdem tritt durch die hohe Komplexität und die problemspezifische Modelloptimierung zwangsläufig das Problem der fehlenden Generalisierbarkeit auf. Für die Problemstellung dieser Arbeit sind diese Ansätze nicht zuletzt wegen des erhöhten Speicher- und Rechenbedarfs ungeeignet.

6.1.2 Methoden mit analytischem Modell

Zum Einsatz von Methoden mit analytischem Modell ist zwangsläufig Vorwissen über die physikalische Struktur des zu identifizierenden Systems erforderlich. Außerdem muss je nach Methode der physikalisch sinnvolle Bereich beziehungsweise unter Umständen sogar der Betriebspunktabhängige Verlauf der im Modell vertretenen Parameter bekannt sein. Nach Trigeassou lassen sich diese Methoden in drei Kategorien unterteilen, wie in Abb. 6.1 dargestellt [152].

Zustandsschätzung

Die Zustandsschätzung durch Beobachteralgorithmen ist vor allem in der Regelung elektrischer Antriebe gängige Praxis. Sie dient der Erfassung von Zustandsvariablen durch entsprechende Modelle, die entweder gar nicht oder nur durch teure Sensorik messbar sind [152]. Klassische Beispiele in Bezug auf die Regelung einer ASM sind die Beobachtung des Rotorflusses sowie die Schätzung der Drehzahl zur sensorlosen Drehzahlregelung, wie zum Beispiel in [193] umgesetzt. Beobachterstrukturen basieren in der Regel auf dem Luenberger-Beobachter (LB) [194] mit nicht adaptiver Verstärkungsmatrix oder dem Kalman-Filter [34] mit adaptiver Verstärkungsmatrix. Die Beobachtung von Zustandsvariablen zur Diagnose ermöglicht jedoch auch Aussagen über Fehlverhalten der Maschine [152, S.12 f.], [193], [195], [196]. Der Umgang mit nichtlinearen analytischen Modellen ist dabei ausschließlich durch

geeignete Adaptionen wie dem ELB oder dem EKF möglich. Allgemein beschränkt sich die Anwendung in existierenden Arbeiten auf weitestgehend stationäre Betriebspunkte. Der Einsatz in einem dynamischen Betriebsumfeld ist jedoch herausfordernd, wie die Analysen in Kap. 5 zeigen.

Residuenanalyse

Die Residuenanalyse liefert die Differenz zwischen dem realen System und einem Referenzmodell. Dadurch besteht ein Vergleichswert, der bei einem gut parametrisierten Modell Rückschlüsse auf Fehlverhalten zulässt. Darauf basierend zeigen Bachir et al. in [197] und Rodriguez-Blanco et al. in [198] beispielhafte Anwendungen zur Fehlerdiagnose. Bachir et al. [197] setzen unterschiedliche Fehlermodelle zur Schätzung spezifischer Fehlerparameter ein. Dazu ist jedoch ein hoher Speicherbedarf erforderlich, der im Hinblick auf den Einsatz in limitierten Echtzeitsystemen unvorteilhaft ist. Vorteilhaft ist jedoch die hohe Flexibilität durch fehlerspezifische Modelle. Alternativ entwickeln Rodriguez-Blanco et al. in [198] eine Paritätsgleichung zur Überwachung der Spannungsabweichung bedingt durch unterschiedliche Fehler. Diese basiert auf einem nichtlinearen dreiphasigen d/q-Modell der Maschine. Jedoch ist bei diesem Ansatz die Komplexität des genutzten Vergleichsmodells problematisch für Echtzeitanwendungen. Allgemein ist eine spezifische und gleichzeitig zuverlässige Fehlerdiagnose aufgrund der fehlenden Adaptionenmöglichkeit der Referenzmodelle kritisch zu bewerten. Jedoch kann auch eine binäre „gut-schlecht-Entscheidung“ über den Zustand der Maschine bereits hilfreich sein. Für den Einsatz der Residuenanalyse im Betriebsumfeld dieser Arbeit ist eine Komplexitätsreduktion unabdingbar. Daher leistet Abs. 6.4 einen Beitrag zur datenbasierten Referenzmodellierung mittels einfacher Black-Box-Modelle mit dem Ziel, den erforderlichen Speicherbedarf zu reduzieren.

Im Zusammenhang mit innovativen Produktionstechnologien und dem Begriff Industrie 4.0 tritt zunehmend auch die Anwendung digitaler Zwillinge in Erscheinung [199]. Neueste Diagnoseansätze nutzen diese Technologie zur Auslagerung komplexer Referenzmodelle [200], [201]. Dabei sind sowohl analytische als auch numerische Referenzmodelle einsetzbar. Aufgrund der fehlenden Infrastruktur ist dieser Ansatz für das hier betrachtete System jedoch noch ungeeignet.

Parameteridentifikation

Neben dem klassischen Einsatz zur Adaption in der Regelungstechnik, ist die OPI auch für den Einsatz in der Fehlerdiagnose geeignet. Im Vergleich zum vorherigen Abschnitt existiert bei diesem Vorgehen eine Rückführung des Residuums. Die Modellparameter lassen sich dann mit Hilfe eines Adaptionalgorithmus betriebspunktabhängig so identifizieren, dass der Fehler zwischen Modell- und Systemausgang minimiert wird, wie bereits in Abs. 2.1 erläutert. Der Einsatz zur Fehlerdiagnose bedingt die Annahme, dass sich die Modellparameter

bei Auftreten eines Fehlers ändern. Durch die Identifikation dieser Parameteränderungen lassen sich folglich Rückschlüsse auf Fehlverhalten ziehen [152], [202].

Grundsätzlich ist jede Methode der Parameteridentifikation zur Diagnose einsetzbar. Hinsichtlich eines Einsatzes zur Online-Diagnose im betrachteten Umfeld dieser Arbeit, bieten jedoch gerade echtzeitfähige Identifikationsalgorithmen einen wesentlichen Vorteil gegenüber den Ansätzen in Abs. 6.1.1. Ein großer Teil der existierenden Ansätze zur OPI basiert auf dem Optimierungskriterium des kleinsten quadratischen Fehlers, wie der RLS-Algorithmus, der ELB und das EKF bzw. UKF. Daher sind alle im Stand der Technik der vorherigen Kap. 4 und 5 erfassten, sowie die darin vorgeschlagenen erweiterten Methoden, grundsätzlich zur echtzeitfähigen und parameterbasierten Fehlerdiagnose der ASM einsetzbar. Die eigentliche Auswahl des Identifikationsalgorithmus ist individuell in Bezug auf das vorliegende System zu treffen. Außerdem ist eine Metrik zur Auswertung der identifizierten Parameter zu entwickeln, wobei wiederum verschiedene Herangehensweisen möglich sind.

Aufbauend auf der Residuenanalyse mit Fehlermodellen vergleichen Bachir et al. [197] die Anwendung eines ordinären RLS-Verfahrens mit einem nichtlinearen Optimierungsansatz. Dem RLS-Algorithmus schreiben die Autoren Nachteile aufgrund der biasbehafteten Schätzung zu. Der nichtlineare Algorithmus hingegen liefert überzeugendere Ergebnisse, wobei ein deutlich höherer Rechenaufwand erforderlich ist. Der Parametervektor des nichtlinearen Regressionsmodells enthält neun Identifikationsparameter, was nach dem Erfahrungsschatz aus Kap. 4 und 5 als eine nicht mehr sinnvolle Dimension zu bewerten ist. Einen quasi identischen Ansatz nutzen Coirault et al. in [203] zur Parameteridentifikation mit Hilfe des Levenberg-Marquardt-Algorithmus. In beiden Arbeiten erfolgt der Vergleich lediglich anhand eines stationären Betriebspunkts. Aufgrund der Komplexität ist dieser Ansatz mit den Echtzeitanforderungen im betrachteten Anwendungsgebiet dieser Arbeit nicht umsetzbar.

Einer der am häufigsten thematisierten Fehler beim Einsatz von ASM ist der Rotorstabbruch [152]. Dabei ist die Sensitivität des Rotorwiderstands R_r im Ersatzschaltbildmodell gegenüber Rotorstabbrüchen unumstritten. Von dieser Tatsache machen Arbeiten durch die Nutzung geschätzter Ausgangsfehler oder nichtlinearer Beobachter Gebrauch [152]. Am weitesten verbreitet ist der Einsatz adaptierter KF zur Diagnose gebrochener Rotorstäbe einer ASM, wie beispielsweise [127], [193], [204], [205] zeigen. Dabei kommen komplexe ZRM sowie verschiedene KF-Algorithmen, wie das EKF in [127], [193], [204], das UKF in [204], sowie ein modifiziertes Square-Root Transformed Cubature Quadrature KF [205] zum Einsatz. Die Echtzeitfähigkeit ist dabei nicht bei allen Ansätzen gegeben und die Manipulation bzw. Identifikation von R_r wird in einem stationären Betriebspunkt vorgenommen. Aufgrund der sich bereits in Kap. 5 ergebenden Herausforderungen durch die Parametrisierung adaptierter KF-Algorithmen, ist die Anwendung komplexer Erweiterungen in einem dynamischen Betriebsumfeld kritisch zu betrachten.

Auch laut Trigeassou ist der Einsatz von Verfahren basierend auf Parameteridentifikation hauptsächlich durch die fehlende Anregung in konstanten Betriebspunkten beschränkt [152].

Dieser Nachteil entsteht bei der Verwendung von RLS-Verfahren in besonderem Maße. Dadurch lässt sich die verhältnismäßig geringe Anzahl an existierender Literatur zum Einsatz in der Fehlerdiagnose erklären. In einem dynamischen Anwendungsgebiet rückt dieser Nachteil jedoch in den Hintergrund, weswegen die Anwendung des RLS-Algorithmus zur parameterbasierten Diagnose im Rahmen der nachfolgenden Untersuchungen betrachtet wird.

6.1.3 Zusammenfassung Stand der Technik

Der zuvor erfasste Stand der Technik zeigt die große Bandbreite unterschiedlicher Ansätze zur Diagnose von ASM. Methoden ohne analytisches Modell nutzen aus Zustandsgrößen und deren Spektrum gewonnene Merkmale. Die eigentliche Diagnose erfolgt basierend auf Metriken, die im einfachsten Fall aus Treshholds bestehen. Mit diesem Ansatz ist aufgrund der fehlenden Modelltiefe allerdings oft keine spezifische Fehlerdiagnose möglich. Aus diesem Grund werden Klassifikatoren basierend auf den extrahierten Merkmalen trainiert. Um die nötigen Details abzubilden scheint zunächst die Nutzung tiefer Modellstrukturen sinnvoll. Diese liefern in Bezug auf den genutzten Datensatz eine präzise Fehlerdiagnose, benötigen dafür jedoch hohe Speicher- und Rechenkapazitäten.

Methoden mit analytischem Modell bilden die physikalische Struktur des Systems ab und nutzen geschätzte Zustandsgrößen oder Systemparameter, um Rückschlüsse auf Fehlverhalten zu ziehen. Die Genauigkeit dieser Methoden hängt von der Qualität der identifizierten Parameter ab. Im Vergleich zur Nutzung heuristischer Modelle tritt bei den meisten existierenden Ansätzen die deutlich geringere Speicher- und Rechenkapazität in Erscheinung. Außerdem ist die Merkmalsextraktion durch Beobachter oder OPI in der Regel echtzeitfähig.

Für den Online-Einsatz in automobilen Antriebssystemen ist die Echtzeitfähigkeit bei streng limitierter Speicher- und Rechenkapazität eine wesentliche Anforderung. Daneben ist das robuste Verhalten in einem dynamischen Betriebsumfeld mit nichtlinearen Parameteränderungen von zentraler Bedeutung, jedoch gleichzeitig die größte Herausforderung. Die Kombination der genannten Anforderungen decken existierende Diagnosealgorithmen nicht ausreichend ab, weswegen die vorliegende Arbeit einen Beitrag zu geeigneten Diagnosekonzepten leistet. Die genannten Anforderungen lassen sich mit Hilfe der Erkenntnisse aus Kap. 4 und 5 und durch Kombination analytischer und modifizierter heuristischer Methoden erfüllen. Daraus werden in diesem Kapitel drei Diagnoseansätze abgeleitet:

1. Online-Identifikation von Parameterabweichungen zur Anomaliedetektion (Abs. 6.2).
2. Online-Parameteridentifikation zur Fehlerdiagnose mittels echtzeitfähiger Klassifikatoren (Abs. 6.3).
3. Datenbasierte Referenzmodellierung zur echtzeitfähigen Residuenanalyse (Abs. 6.4).

6.2 Online-Identifikation von Parameterabweichungen zur Anomaliedetektion

Gängige Ansätze zur OPI der ASM nach Stand der Technik identifizieren die absoluten Werte der Systemparameter. Zur Bemessung der Genauigkeit dienen dabei offline identifizierte Referenzdatensätze. Im Fall industriell gefertigter Großserien werden in der Regel repräsentative Maschinen vermessen, sodass auftretende Fertigungstoleranzen in diesen Datensätzen keine Berücksichtigung finden. Im Vergleich zur adaptiven Regelung ist der absolute Wert der jeweiligen Parameter für Diagnoseanwendungen irrelevant. Vielmehr sind die Abweichungen zu erwarteten Referenzwerten als Merkmale zur Anomaliedetektion von Interesse. Eine große Herausforderung zur robusten OPI in einem dynamischem Betriebsumfeld ist die Identifikation nichtlinearer Parameteränderungen, wie Kap. 4 und 5 zeigen. Diese treten bei Nutzung hochausgenutzter Maschinen vor allem durch das lastabhängige Sättigungsverhalten auf, siehe Abb. 2.6.

Der nachfolgend entwickelte Ansatz stellt eine Modifikationsmöglichkeit für OPI-Algorithmen zur parameterbasierten Diagnoseanwendung dar. Durch die Anpassung der zugrundeliegenden Identifikationsmodelle ermöglicht dieser eine direkte Identifikation von Parameterabweichungen. Dabei werden die Referenzwerte in jedem Betriebspunkt vorgegeben, sodass nichtlineare Parameteränderungen für den Algorithmus unsichtbar bleiben. Auftretende Anomalien sind dadurch direkt anhand der identifizierten Abweichungswerte ablesbar. Die Modifikation lässt sich gleichermaßen am Regressionsmodell und am ZRM vornehmen, sodass sowohl der RLS-Algorithmus als auch erweiterte KF nutzbar sind. Durch Bewertung der identifizierten Parameterabweichungen mittels spezifischer Metriken offenbart sich eine Möglichkeit zur Beobachtung alterungs- oder fehlerbedingter Parameteränderungen.

Im Verlauf des Abschnitts erfolgt zunächst die Anpassung der Identifikationsmodelle, bevor die Eignung zur Anomaliedetektion anhand geeigneter Testprofile analysiert wird. Analog zum Vorgehen in Kap. 4 und 5 dienen dazu sowohl vereinfachte Testprofile als auch der WLTP-Zyklus. Der Inhalt dieses Abschnitts wurde in Teilen bereits in [19] publiziert.

6.2.1 Modifikation der Identifikationsmodelle und Algorithmen

Aufgrund der Vielzahl an möglichen Konfigurationen bzw. Identifikationsmodellen dienen die aus den vorherigen Kapiteln erlangten Erkenntnisse als Ausgangspunkt für die nachfolgenden Modifikationen. Grundsätzlich gilt die Annahme, dass jeder zu identifizierende Parameter aus einem Referenzwert und einem additiven Abweichungsterm besteht:

$$\boldsymbol{\theta} = \boldsymbol{\theta}_{\text{ref}} + \boldsymbol{\Delta\theta} = \boldsymbol{\theta}_{\text{ref}} + \hat{\boldsymbol{\theta}}. \quad (6.1)$$

Das jeweilige Identifikationsmodell muss demnach so modifiziert werden, dass der Parametervektor $\hat{\boldsymbol{\theta}}$ ausschließlich die zu identifizierenden Parameterabweichungen $\Delta\boldsymbol{\theta}$ enthält.

Regressionsmodell und Recursive Least Squares Algorithmus

Aus Kap. 4 geht hervor, dass eine Identifikation des Statorwiderstands R_s mittels RLS-Algorithmus allgemein problematisch ist. Des Weiteren liefert die Anwendung der stationären Identifikationsmodelle schlechtere Ergebnisse. Daher bietet sich das dynamische Regressionsmodell (4.30) mit Vorgabe von R_s als Basis für den Aufbau des modifizierten Modells zur Identifikation der Abweichung an.

Bei der Umsetzung ergibt sich nach dem Schema von (6.1) aus (4.30) der modifizierte Parametervektor des Abweichungsmodells:

$$\hat{\boldsymbol{\theta}} = \begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \\ \hat{\theta}_3 \end{bmatrix} = \begin{bmatrix} R_r \\ L_m \\ R_r L_s \\ L_m \\ L_\sigma \end{bmatrix} \rightarrow \hat{\boldsymbol{\theta}} = \begin{bmatrix} \Delta \frac{R_r}{L_m} \\ \Delta \frac{R_r}{L_m} L_s \\ \Delta L_\sigma \end{bmatrix}, \quad (6.2)$$

mit

$$\Delta L_s = \frac{\hat{\theta}_2}{\hat{\theta}_1}, \quad \Delta L_m = \frac{\hat{\theta}_2}{\hat{\theta}_1} - \hat{\theta}_3, \quad \Delta R_r = \hat{\theta}_2 - \hat{\theta}_3 \cdot \hat{\theta}_1. \quad (6.3)$$

Folglich ist die Berechnungsvorschrift des Prädiktionsfehlers nach (2.5) des RLS-Algorithmus anzupassen:

$$e[k] = y[k] - \boldsymbol{\Phi}^T (\boldsymbol{\theta}_{\text{ref}} + \hat{\boldsymbol{\theta}}) [k-1]. \quad (6.4)$$

Zur entsprechenden Anpassung des RLS-Algorithmus wird (6.4) wie folgt umgeformt:

$$e[k] = y[k] - \underbrace{(\boldsymbol{\Phi}^T \cdot \boldsymbol{\theta}_{\text{ref}}[k-1])}_{y'[k]} - (\boldsymbol{\Phi}^T \cdot \hat{\boldsymbol{\theta}}[k-1]). \quad (6.5)$$

Die Identifikation der Parameterabweichung ist durch die angepasste Gleichung zur Berechnung des Prädiktionsfehlers (6.5) in jedem der RLS-Algorithmen 2.1, 2.2, 2.3 umsetzbar.

Zustandsraummodell und Kalman-Filter

Im Fall erweiterter KF ist keine Anpassung der Algorithmen von Nöten. Zusätzlich stellt sich bereits in Kap. 5 die flexible Wahl der Art und Anzahl der zu identifizierenden Parameter als wesentlicher Vorteil bei Nutzung des ZRM dar. Bei direkter Identifikation aller Parameterabweichungen setzt sich der erweiterte Zustandsvektor des ZRM (2.101) wie folgt zusammen:

$$\hat{\mathbf{x}}_{\text{ext}} = \begin{bmatrix} i_s^\alpha & i_s^\beta & \Psi_r^\alpha & \Psi_r^\beta & \hat{\boldsymbol{\theta}} \end{bmatrix}^T \quad (6.6a)$$

$$\rightarrow \hat{\boldsymbol{\theta}} = [\Delta L_\sigma \quad \Delta L_m \quad \Delta R_r \quad \Delta R_s]^T. \quad (6.6b)$$

Dementsprechend muss die Systemmatrix \mathbf{A} und die Eingangsmatrix \mathbf{B} um die zusätzlichen Parameter ergänzt werden:

$$\mathbf{A} = \begin{bmatrix} -\frac{(R_s+\Delta R_s)+(R_r+\Delta R_r)}{L_\sigma+\Delta L_\sigma} & 0 & \frac{(R_r+\Delta R_r)}{(L_\sigma+\Delta L_\sigma)(L_m+\Delta L_m)} & \omega_{el} \cdot \frac{1}{L_\sigma+\Delta L_\sigma} \\ 0 & -\frac{(R_s+\Delta R_s)+(R_r+\Delta R_r)}{L_\sigma+\Delta L_\sigma} & -\omega_{el} \cdot \frac{1}{L_\sigma+\Delta L_\sigma} & \frac{(R_r+\Delta R_r)}{(L_\sigma+\Delta L_\sigma)(L_m+\Delta L_m)} \\ R_r + \Delta R_r & 0 & -\frac{R_r+\Delta R_r}{L_m+\Delta L_m} & -\omega_{el} \\ 0 & R_r + \Delta R_r & \omega_{el} & -\frac{R_r+\Delta R_r}{L_m+\Delta L_m} \end{bmatrix}$$

$$\mathbf{B} = \begin{bmatrix} \frac{1}{L_\sigma+\Delta L_\sigma} & 0 \\ 0 & \frac{1}{L_\sigma+\Delta L_\sigma} \\ 0 & 0 \\ 0 & 0 \end{bmatrix}. \quad (6.7)$$

Das modifizierte Abweichungsmodell ist sowohl in Verbindung mit dem EKF als auch mit dem UKF einsetzbar. Aufgrund der gewonnen Erkenntnisse in Kap. 5 wird nachfolgend jedoch ausschließlich der EKF-Algorithmus genutzt.

6.2.2 Simulative Analyse

Bei der simulativen Analyse ist es mit Hilfe des in Abs. 3.2 beschriebenen Simulationsmodells möglich, die unterschiedlichen Parameter der Maschine gezielt zu manipulieren. Das Maschinenmodell selbst ist nach [89] mit einer maximalen Abtastzeit von $t_s = 10 \mu\text{s}$ zu betreiben. Hingegen ist die Taktzeit der Schätzalgorithmen an die PWM-Frequenz von $f_{\text{PWM}} = 10 \text{ kHz}$ und damit an eine Taktzeit von $t_s = 100 \mu\text{s}$ des Echtzeitsystems gekoppelt. Für eine realitätsnahe Simulation ist es daher sinnvoll, die beiden Komponenten mit unterschiedlicher Abtastzeit zu berechnen. Aufgrund der Umstände bei der Identifikation des Statorwiderstands und der Streuinduktivität in Kap. 4 beziehungsweise Kap. 5 beschränken sich die eingepägten Manipulationen auf die Hauptinduktivität und den Rotorwiderstand. Dadurch lassen sich exemplarisch zwei potenzielle Anomalien simulieren:

- Eine Verringerung der Hauptinduktivität steht für eine abnehmende Permeabilität der Eisenkomponenten der Maschine. Es wird angenommen, dass diese durch einen langsam voranschreitenden Alterungsprozess auftritt.
- Eine Erhöhung des Rotorwiderstands tritt potenziell durch Materialalterung oder einen Bruch im Rotoraufbau auf.

Die Fähigkeit der vorgestellten Algorithmen zur Detektion dieser Parameteränderungen wird nachfolgend zunächst anhand eines rampenförmigen Testprofils und anschließend basierend

auf dem WLTP-Zyklus analysiert. Aufgrund der fehlenden Repräsentativität der Eisenverluste bei simulativen Untersuchungen ist deren Berücksichtigung in diesem Abschnitt nicht sinnvoll.

Die Einstellung der Hyperparameter bei der Parametrisierung des RLS-Algorithmus, sowie die Wahl der initialen Kovarianzen im Fall des EKF ergeben sich auch hier als die größte Herausforderung. Zur heuristischen Optimierung dieser Werte erfolgte im Voraus eine umfassende Parameterstudie, deren Ergebnisse aus Übersichtsgründen nicht aufgeführt werden.

Simulation entlang des rampenförmigen Testprofils

Zur grundsätzlichen Analyse der Performanz des Abweichungsschätzers bietet sich das im oberen Teil von Abb. 6.2 gezeigte Rampenprofil mit dynamischen und stationären Betriebspunkten an. Basierend auf verschiedenen Testfällen lässt sich die Fähigkeit der Algorithmen zur Anomaliedetektion überprüfen. Die Nummerierungen der folgenden Testfälle finden sich in den einzelnen Teilgrafiken in Abb. 6.2 wieder.

- (a) keine Manipulation
- (b) Manipulation der Hauptinduktivität um $\Delta L_m = -5\%$ in den linken beiden Spalten und um $\Delta L_m = -10\%$ in den rechten beiden Spalten
- (c) Manipulation des Rotorwiderstands um $\Delta R_r = +5\%$ in den linken beiden Spalten und um $\Delta R_r = +10\%$ in den rechten beiden Spalten
- (d) Gleichzeitige Manipulation von Rotorwiderstand und Hauptinduktivität um $\Delta R_r = +5\%$, $\Delta L_m = -5\%$ in den linken beiden Spalten und um $\Delta R_r = +10\%$, $\Delta L_m = -10\%$ in den rechten beiden Spalten

Anhand von Testfall (a) lässt sich das betriebspunktabhängige Verhalten des Schätzfehlers beider Algorithmen bewerten. Da diese jeweils mit $\Delta\theta = 0$ initialisiert werden und keine Manipulationen vorliegen, liegt der Erwartungswert der Schätzung bei $E\{\Delta\theta\} = 0$. Aufgrund der unterschiedlichen Abtastzeiten und der herausfordernden Parametrisierung tritt jedoch ein betriebspunktabhängiger Schätzfehler auf, wie Abb. 6.2(a) zeigt. Während der Lastpunkt lediglich einen unbedeutenden Einfluss auf das Schätzergebnis hat, besteht wie in den vorherigen Kapiteln 4 und 5 bereits festgestellt eine Abhängigkeit zur Drehzahl der Maschine. Diese macht sich aufgrund der Frequenzabhängigkeit der induktiven Parameter gerade bei der Schätzung von ΔL_m bemerkbar. Damit ist auch für die folgenden Testläufe von einer nicht fehlerfreien Parameteridentifikation auszugehen.

Im zweiten Testlauf (b) wird zunächst nur die Hauptinduktivität manipuliert. Beide Algorithmen sind in der Lage, die Parameteränderungen zu identifizieren. Während der Schätzfehler von ΔL_m im Fall des RLS-Algorithmus in der selben Größenordnung wie in Testfall (a) ist, erhöht sich der Schätzfehler des EKF. Bei der Identifikation von ΔR_r durch den

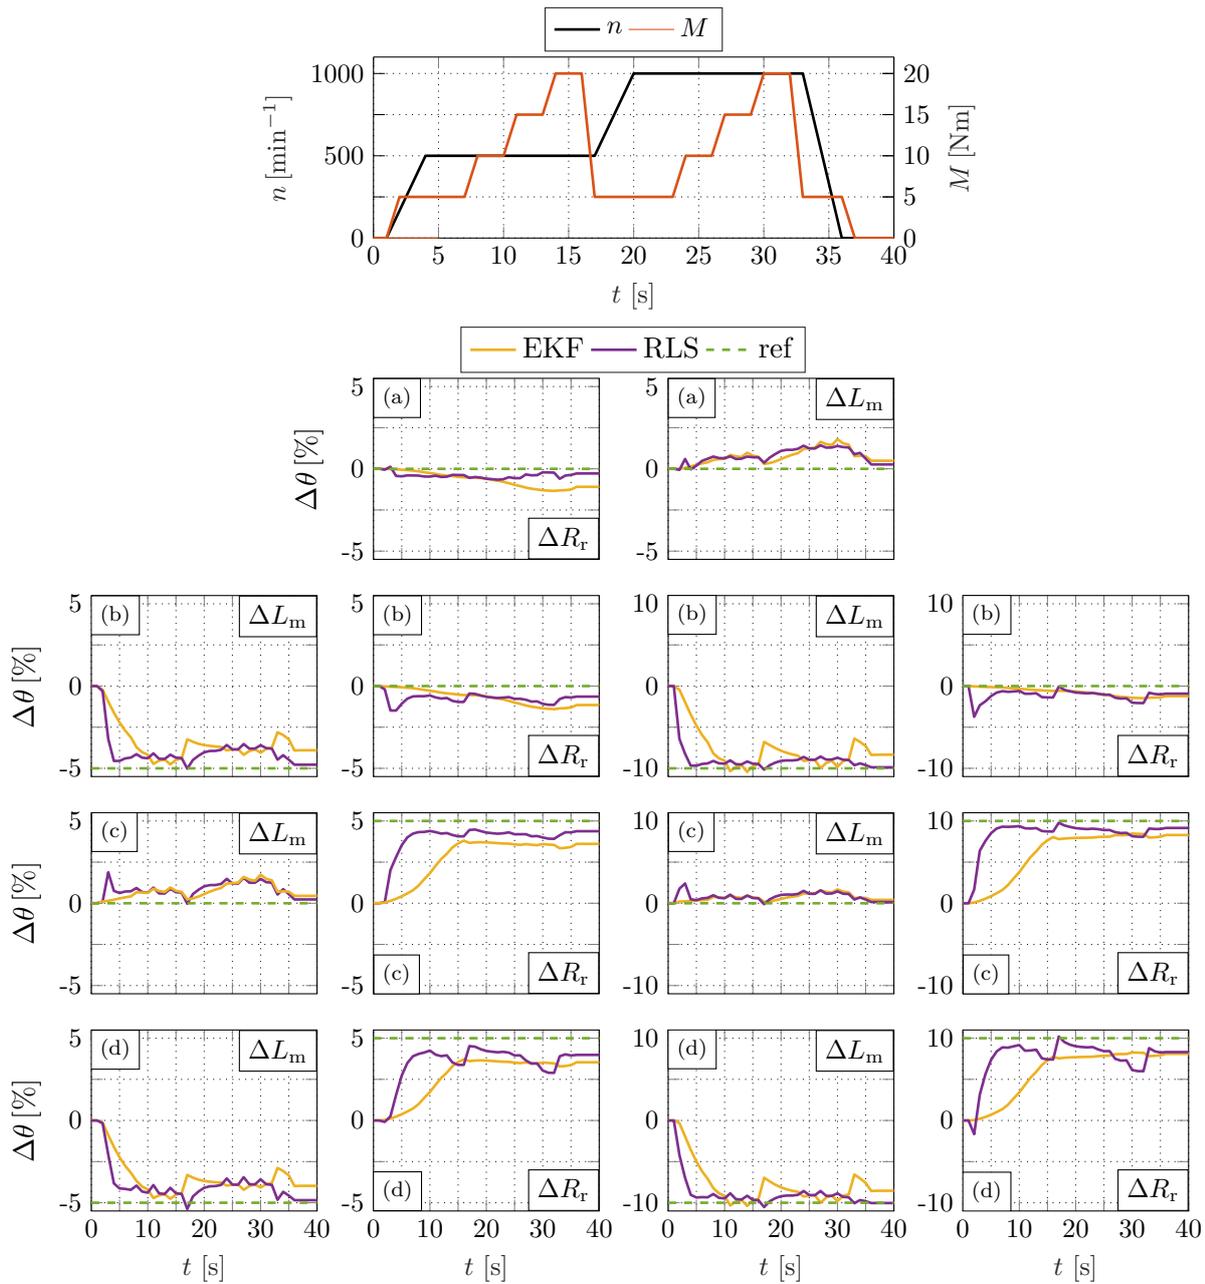


Abbildung 6.2: Simulativer Vergleich der Identifikation von Parameterabweichungen mittels RLS-Algorithmus und EKF bei Manipulation der Hauptinduktivität L_m und des Rotorwiderstands R_r entlang eines rampenförmigen Testzyklus. - Konfiguration RLS-Algorithmus Tab. D.1 und EKF Tab. D.3.

RLS-Algorithmus ist zu Beginn der ersten Beschleunigung ein Ausschlag zu erkennen. Dieser ergibt sich im Vergleich zum EKF aufgrund der eintretenden Sättigung in Verbindung mit der kohärenten Struktur des Parametervektors. Insgesamt ist der auftretende Schätzfehler beider Algorithmen jedoch ähnlich zu Testfall (a). Das signifikant schnellere Konvergenzverhalten des RLS-Algorithmus ist auch in diesem Testlauf deutlich ersichtlich.

Die Parameteränderung des Rotorwiderstands ΔR_r in Testfall (c) ist durch beide Algorithmen identifizierbar. Neben der schnelleren Konvergenz des RLS-Algorithmus ist in diesem

Tabelle 6.1: Vergleich des simulativen mittleren Identifikationsfehlers $\bar{e}_{\Delta\hat{\theta}}$ bei der Identifikation von Parameterabweichungen mittels RLS-Algorithmus und EKF bei Manipulation der Hauptinduktivität L_m und des Rotorwiderstands R_r entlang eines rampenförmigen Testzyklus.

Algorithmus	Parameter	$\bar{e}_{\Delta\hat{\theta}} [\%]$						
		$\Delta\theta = 0$	ΔL_m		ΔR_r		$\Delta L_m, \Delta R_r$	
			-5 %	-10 %	+5 %	+10 %	$\pm 5 \%$	$\pm 10 \%$
RLS	L_m	0,86	0,99	1,13	0,91	0,97	1,05	1,22
	R_r	0,43	0,80	1,25	1,04	1,70	1,48	2,84
EKF	L_m	0,81	1,50	2,19	0,79	0,78	1,46	2,08
	R_r	0,65	0,68	0,73	2,25	3,91	2,32	4,15

Testfall auch der Schätzfehler deutlich kleiner als der des EKF. Die Identifikation der unveränderten Hauptinduktivität verläuft nahezu identisch zu Testfall (a).

Die gleichzeitige Manipulation beider Parameter in Testfall (d) lässt sich ebenfalls durch beide Algorithmen identifizieren. Allerdings steigt der absolute Schätzfehler bei beiden Algorithmen. Bei Betrachtung der Ergebnisse des RLS-Algorithmus zeigt sich eine zunehmende Abhängigkeit vom Lastpunkt aufgrund des Sättigungsverhaltens in Verbindung mit der kohärenten Parameteränderung. Dennoch ist der mittlere Schätzfehler im Vergleich zum EKF kleiner und das Konvergenzverhalten deutlich schneller.

Eine Zusammenfassung der mittleren Schätzfehler zeigt Tab. 6.1. Der RLS-Algorithmus ergibt sich anhand dieses Vergleiches und nicht zuletzt wegen des schnelleren Konvergenzverhaltens und des geringeren Rechenaufwands als überzeugendere Alternative.

Simulation entlang des WLTP-Zyklus

Im nächsten Schritt erfolgt die Analyse in einem dynamischen Betriebsumfeld entlang des WLTP-Zyklus. Der genutzte Simulationsaufbau sowie die betrachteten Testfälle bleiben dabei unverändert. Den zugehörigen Drehzahl- und Drehmomentverlauf zeigt der obere Teil in Abb. 6.3. Aus den Untersuchungen des vorherigen Abschnitts in Abb. 6.2 geht hervor, dass die absolute Parameteränderung lediglich einen unbedeutenden Einfluss auf den prozentualen Schätzfehler hat. Daher beschränken sich die Analysen in diesem Abschnitt auf Parametermanipulationen von 5 %. Die prozentualen Schätzfehler der zugehörigen Ergebnisse von ΔL_m und ΔR_r zeigt der untere Teil von Abb. 6.3 getrennt für RLS-Algorithmus und EKF.

Analog zu Abb. 6.2 lässt sich auch in Abb. 6.3 das grundsätzliche Verhalten des Schätzfehlers zunächst anhand von Testfall (a) analysieren. Die Ergebnisse von ΔL_m unterscheiden sich bei Betrachtung der beiden Algorithmen lediglich marginal. Aufgrund des dynamischen Testprofils ist die Sensitivität gegenüber Drehzahländerungen besonders deutlich zu erkennen. Grundsätzlich liegen die Schätzfehler in einer zufriedenstellenden Größenordnung im

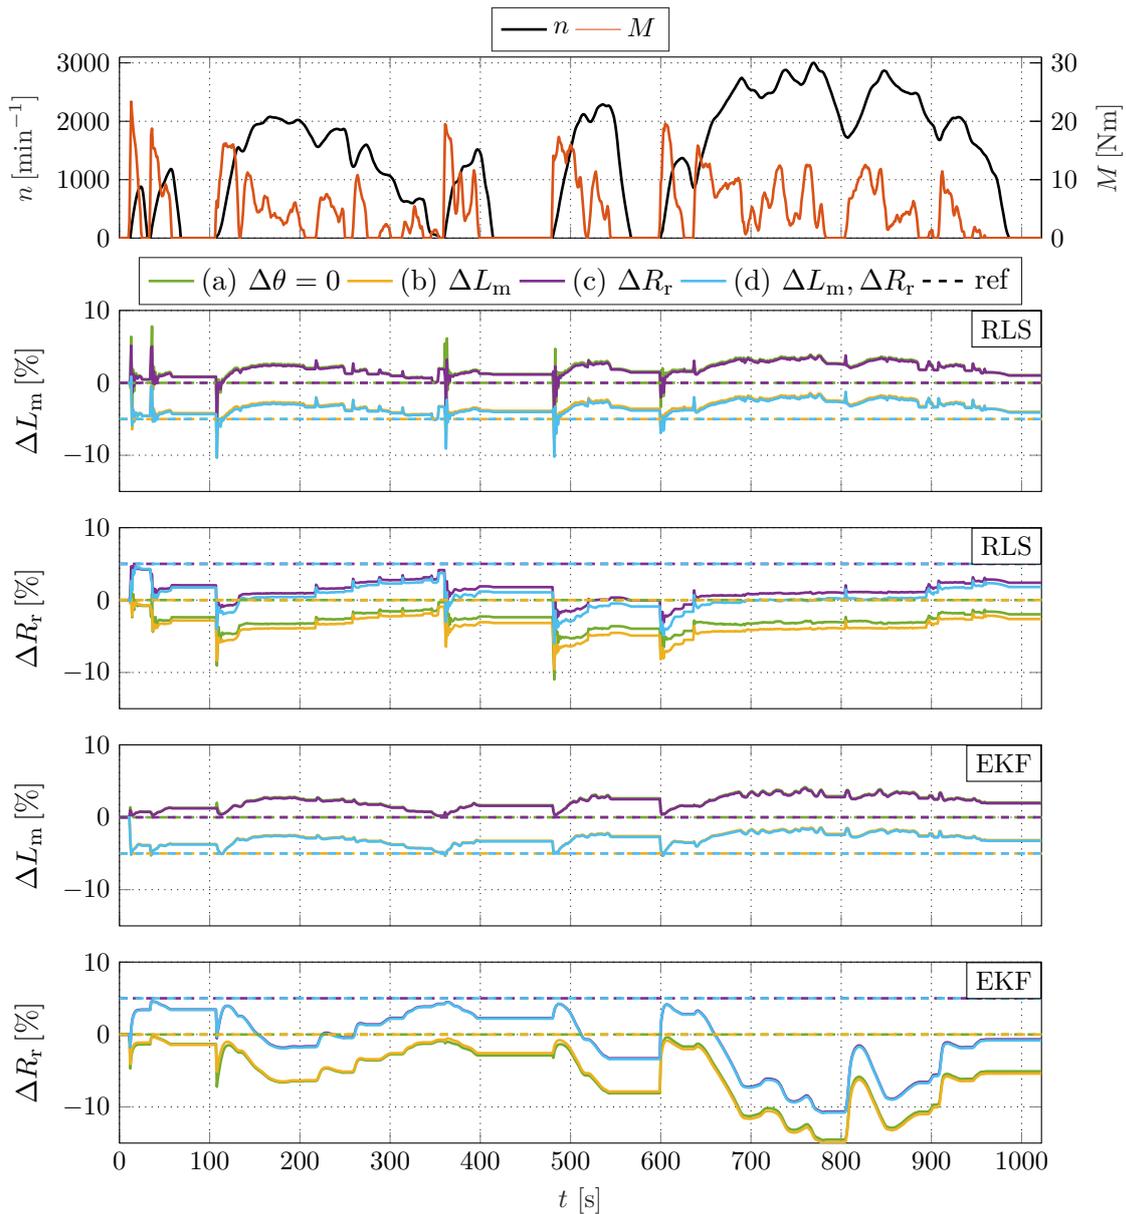


Abbildung 6.3: Simulativer Vergleich der Identifikation von Parameterabweichungen mittels RLS-Algorithmus und EKF bei Manipulation der Hauptinduktivität L_m und des Rotorwiderstands R_r entlang des WLTP-Zyklus. - Konfiguration RLS-Algorithmus Tab. D.1 und EKF Tab. D.3.

Vergleich zu den Erkenntnissen aus Kap. 4 und 5. Jedoch ergeben sich auch hier aufgrund der unterschiedlichen Abtastzeiten und der herausfordernden Parametrisierung keine bias-freien Simulationsergebnisse. Ein Vergleich der Algorithmen bei der Identifikation von ΔR_r offenbart deutlich unterschiedliche Ergebnisse. Bei Betrachtung des RLS-Algorithmus zeigt sich eine Abhängigkeit des absoluten Schätzfehlers vom Lastpunkt der Maschine. Dabei weist der Algorithmus ein robustes Verhalten über den gesamten Verlauf auf. Hingegen ergeben sich bei Verwendung des EKF nur in Einzelfällen stabile Schätzfehler. Dabei macht sich das deutlich langsamere Konvergenzverhalten des EKF im Vergleich zum RLS-Algorithmus

Tabelle 6.2: Vergleich des simulativen mittleren Identifikationsfehlers $\bar{e}_{\Delta\hat{\theta}}$ bei der Identifikation von Parameterabweichungen mittels RLS-Algorithmus und EKF bei Manipulation der Hauptinduktivität L_m und des Rotorwiderstands R_r entlang des WLTP-Zyklus.

Algorithmus	Parameter	$\bar{e}_{\Delta\hat{\theta}} [\%]$			
		$\Delta\theta = 0$	$\Delta L_m = -5 \%$	$\Delta R_r = +5 \%$	$\Delta L_m = -5 \%$ $\Delta R_r = +5 \%$
RLS	L_m	2,32	2,08	2,16	1,89
	R_r	3,19	3,90	3,99	4,80
EKF	L_m	2,32	2,17	2,22	2,08
	R_r	5,91	6,00	6,33	6,43

bemerkbar. Gerade hohen Drehzahlen resultieren in signifikanten Fehlern und einem nicht robusten Schätzverhalten.

Aufgrund des dynamischen Betriebsumfelds ist die Parametrisierung der Algorithmen herausfordernd. Die Einstellung der Vergessensfaktoren bzw. initialen Kovarianzen muss dabei so erfolgen, dass einerseits eine Reaktion auf die dynamischen Parameteränderungen möglich ist und andererseits ein robustes Verhalten über den gesamten Zyklus gewährleistet ist. Dieser Zielkonflikt ist gerade im Fall des EKF besonders herausfordernd, da die Wahl der initialen Kovarianzen den absoluten Schätzfehler signifikant beeinflusst. Bereits kleine Änderungen können dabei zur Divergenz führen. Bei Betrachtung des RLS-Algorithmus zeigt sich bei hohen Drehmomentänderungen kurzzeitig überschwingendes Verhalten, welches durch die sättigungsbedingten Parameteränderungen hervorgerufen wird. Dieses Schwingverhalten steht für eine instantane Reaktion auf Parameteränderungen und damit für flexible Eigenschaften des Algorithmus. Der tatsächliche Verlauf und damit die Reaktion auf dynamische Parameteränderungen lässt sich durch Änderung der Vergessensfaktoren beeinflussen.

Die Betrachtung der weiteren Testfälle (b), (c), (d) offenbart eine starke Ähnlichkeit der Verläufe. Die absoluten Schätzfehler ändern sich hingegen in Richtung der manipulierten Parameter, wie die Mittelwerte in Tab. 6.2 zeigen. Durch die Beobachtung dieser Mittelwerte ergeben sich daher grundsätzlich Merkmale zur Anomaliedetektion. Allerdings liegen die auftretenden Schätzfehler im Bereich der Parameteränderungen, was eine eindeutige Zuordnung zu einem spezifischen Fehler deutlich erschwert. Die Qualität der tatsächlichen Diagnose hängt also neben der Parametrisierung auch von der genutzten Metrik zur Bewertung des Maschinenzustands ab. Generell attestieren die durchgeführten Simulationen dem RLS-Algorithmus ein robusteres Verhalten sowie eine einfachere Parametrisierung.

6.2.3 Experimentelle Analyse

Aus Aufwands- und Sicherheitsgründen ist eine Manipulation realer Maschinen im Rahmen dieser Arbeit nicht möglich. Trotz dieser Tatsache ist ein Vergleich der beiden Algorithmen am Prüfstand zur Überprüfung der grundsätzlichen Funktion entscheidend für eventuelle weiterführende Arbeiten. Aufgrund der zu identifizierenden Parameterbereiche um den Nullpunkt kann es am realen Aufbau zu Problemen aufgrund des SNR kommen. Für eine Aussage zur grundsätzlichen Funktion gilt es daher, den Einfluss dieses Effekts zu überprüfen. In diesem Abschnitt wird die Performanz im nicht manipulierten Maschinenzustand analog zu den im vorherigen Abschnitt genutzten Testprofilen untersucht. Nach einem Vergleich von RLS-Algorithmus und EKF ist zusätzlich der Einfluss der Eisenverluste durch Nutzung des erweiterten Regressionsmodells zur OPI mittels RLS-Algorithmus interessant. Da die Konfiguration der Algorithmen bei der Implementierung am Prüfstand besonders entscheidend ist, erfolgt diese basierend auf den Erkenntnissen aus Kap. 4 und 5. Mit der Vorgabe von R_s und L_σ lieferte der RLS-Algorithmus die besten Ergebnisse, während im Fall des EKF lediglich L_σ vorzugeben ist. Diese Tatsache bestätigte sich bei der Abweichungsschätzung durch diverse Voruntersuchung, weswegen die Ergebnisse alternativer Konfigurationen nachfolgend nicht dargestellt sind.

Experimentelle Untersuchung anhand eines rampenförmigen Testprofils

Ein Vergleich des EKF und des RLS-Algorithmus anhand des rampenförmigen Testprofils zeigt Abb. 6.4. Auch hier stellt die Parametrierung des EKF eine große Herausforderung dar. Die Identifikation von ΔL_m erfolgt mit unzureichendem Schätzfehler, wobei der dargestellte Verlauf in Abb. 6.4 bereits optimierte Ergebnisse zeigt. Es besteht eine signifikante Abhängigkeit vom Lastpunkt und damit der Sättigung der Induktivität. Das Konvergenzverhalten erweist sich wie bereits erwähnt als zu träge für die hier betrachtete Anwendung heraus. Außerdem ergibt sich kein robuster Verlauf der Identifikation, was zu einem großen Spektrum des Schätzfehlers über das betrachtete Testprofil führt. Die Instabilität bestätigt sich bei der Betrachtung des identifizierten Rotorwiderstands. Selbst bei kleinen initialen Kovarianzen lässt sich das divergente Verhalten nicht vollständig verhindern. Zur Erreichung einer angemessenen Stabilität müssen die initialen Kovarianzen so klein gewählt werden, dass eine Reaktion auf auftretende Parameteränderungen im hier betrachteten Zeithorizont ausgeschlossen ist.

Die Ergebnisse des RLS-Algorithmus zeigen hingegen deutlich stabileres Verhalten. Zu Beginn des Testprofils ist jedoch ein ungewöhnlich träges Konvergenzverhalten zu beobachten. Außerdem ist auch hier die Abhängigkeit von der Drehzahl deutlich ersichtlich. Während im niedrigeren Drehzahlbereich ein zu hoher Schätzfehler auftritt, verläuft die Schätzung bei höherer Drehzahl stabiler und mit vergleichsweise geringem Bias. Auffällig ist jedoch die hohe Varianz, die lediglich bei der Vorgabe von L_σ im Regressionsmodell auftritt. Eine

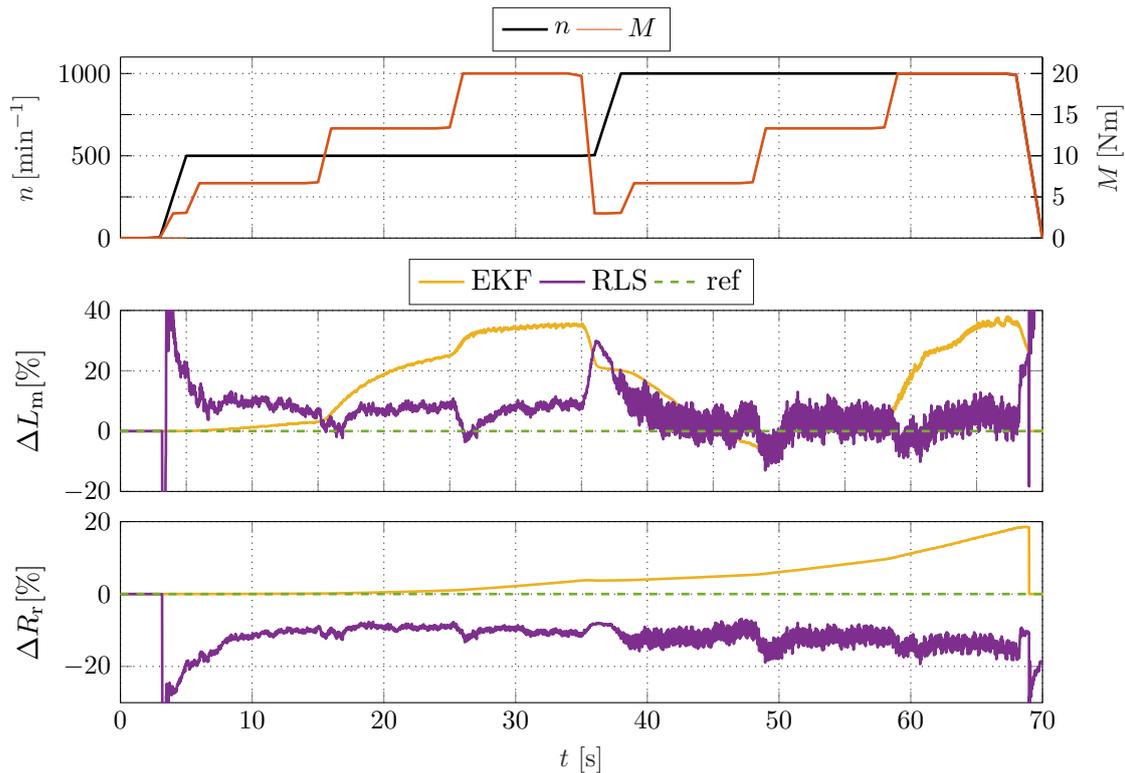


Abbildung 6.4: Experimenteller Vergleich von RLS-Algorithmus und EKF bei fehlerfreiem Maschinenbetrieb entlang eines rampenförmigen Testzyklus. - Konfiguration RLS-Algorithmus Tab. D.2 und EKF Tab. D.4.

Begründung dafür sind Parameterunsicherheiten, die im Vergleich zur direkten OPI durch die erhöhte Sensitivität der Streuinduktivität bei der Abweichungsschätzung einen größeren Einfluss auf das Regressionsmodell aufweisen. Auch die Identifikation des Rotorwiderstands verläuft über das gesamte Testprofil stabil. Trotz der geringen Abhängigkeit vom Betriebspunkt der Maschine ergibt sich dabei jedoch ein hoher konstanter Schätzfehler. Der auftretende Bias hängt auch im Fall des RLS-Algorithmus stark mit der Wahl der Hyperparameter zusammen. Diese muss auch hier individuell in Bezug auf die zu detektierende Parameterabweichung angepasst werden.

Experimentelle Untersuchung des Einflusses der Eisenverluste anhand eines rampenförmigen Testprofils

In Kap. 4 zeigt sich, dass die betriebspunktabhängige Berücksichtigung der Eisenverluste unter Umständen einen positiven Einfluss auf die Qualität der OPI mittels RLS-Algorithmus hat. Erwartungsgemäß ist diese Verbesserung auch im Fall der Abweichungsschätzung zu beobachten, wie Abb. 6.5 zeigt. Während sich die Identifikation der Hauptinduktivität lediglich geringfügig verbessert, kann der Schätzfehler des Rotorwiderstands signifikant reduziert werden. Diese Beobachtung gilt in konstantem Maße für den gesamten Testzyklus, wobei die geringe Abhängigkeit von der Maschinendrehzahl auch hier auftritt. Das verhältnismäßig

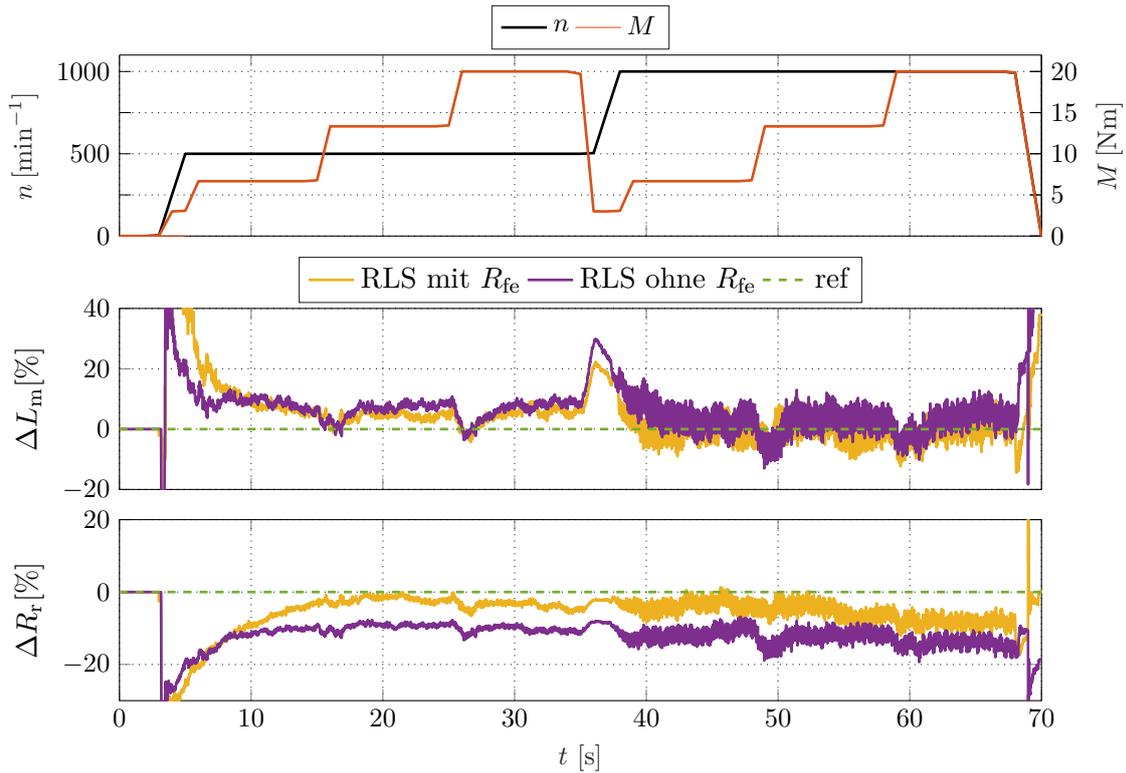


Abbildung 6.5: Experimentelle Analyse des Einflusses der Eisenverluste R_{fe} unter Nutzung des RLS-Algorithmus bei fehlerfreiem Maschinenbetrieb entlang eines rampenförmigen Testzyklus. - Konfiguration RLS-Algorithmus Tab. D.2.

langsame Konvergenzverhalten bleibt jedoch unverändert bestehen.

Experimentelle Untersuchung anhand des WLTP-Zyklus

Abschließend erfolgt ein Vergleich von RLS-Algorithmus und EKF im dynamischen Betriebsumfeld entlang des WLTP-Zyklus. Die entsprechenden Ergebnisse sind in Abb. 6.6 dargestellt. Angefangen mit der Analyse des EKF bestätigen sich die Herausforderungen hinsichtlich der Parametrisierung. Sowohl bei der Identifikation von ΔL_m als auch bei ΔR_r finden sich keine initialen Kovarianzen, die überzeugende Resultate erbringen. Die identifizierte Induktivität weist eine deutliche Abhängigkeit von der Drehzahl auf, wobei gerade bei hohen Drehzahlen lediglich unbrauchbare Ergebnisse erzielt werden. Beim Rotorwiderstand tritt im oberen Drehzahlbereich sogar ein Vorzeichenwechsel auf, der die Instabilität des Verfahrens im hier betrachteten Anwendungsgebiet bestätigt.

Erwartungsgemäß liefert der RLS-Algorithmus auch bei der Identifikation entlang des WLTP-Zyklus deutlich bessere Ergebnisse. Jedoch ist eine signifikante Sensitivität der identifizierten Hauptinduktivität gegenüber Änderungen des Sättigungspunktes zu beobachten, die sich durch Ausschläge mit hoher Amplitude bemerkbar macht. Instabiles Verhalten ist infolgedessen zwar nicht ersichtlich, jedoch führt diese Eigenschaft in Verbindung mit der zuvor bereits aufgetretenen langsamen Konvergenz zu einer dauerhaften Verzerrung und veränder-

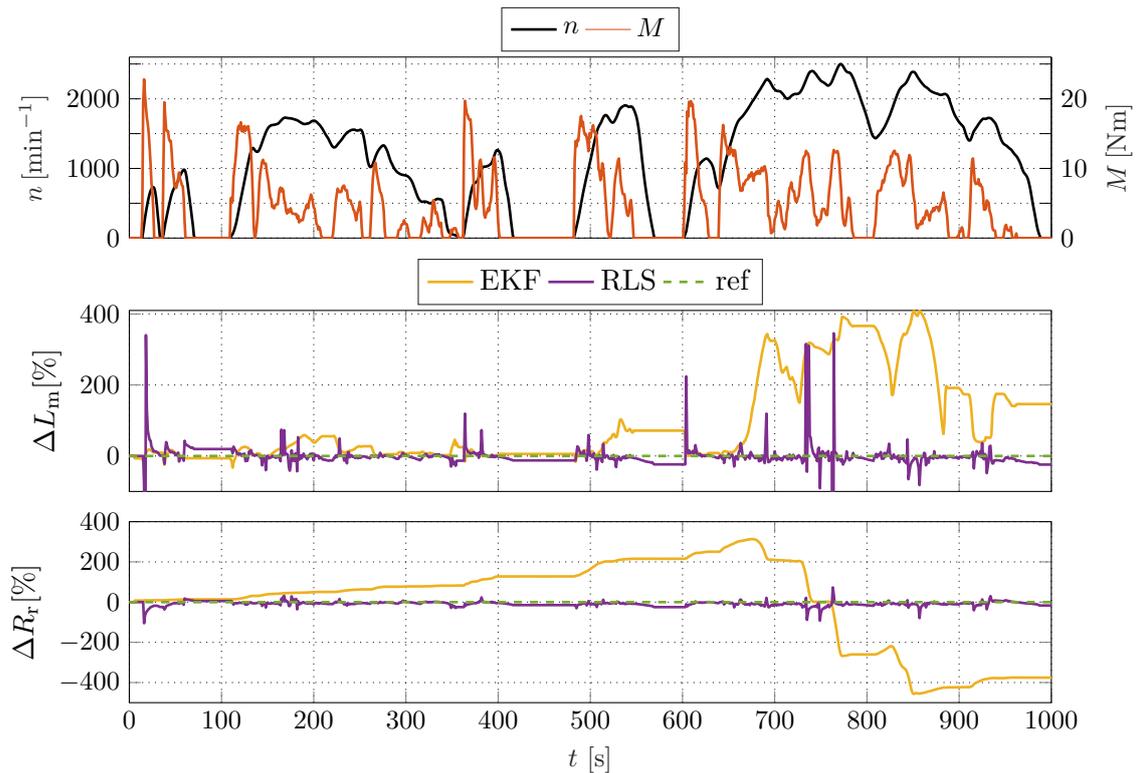


Abbildung 6.6: Experimenteller Vergleich von RLS-Algorithmus und EKF bei fehlerfreiem Maschinenbetrieb entlang des WLTP-Zyklus. - Konfiguration RLS-Algorithmus Tab. D.2 und EKF Tab. D.4.

Tabelle 6.3: Vergleich des simulativen und experimentellen mittleren Identifikationsfehlers $\bar{e}_{\Delta\hat{\theta}}$ bei der Identifikation von Parameterabweichungen mittels RLS-Algorithmus und EKF entlang des WLTP-Zyklus.

		$\bar{e}_{\Delta\hat{\theta}}$ [%]	
Algorithmus	Parameter	Simulation	Prüfstand
RLS	L_m	2,32	19,84
	R_r	3,19	10,60
EKF	L_m	2,32	109,00
	R_r	5,91	173,00

lichen Abweichung beider Identifikationsparameter. Dadurch weist gerade der Mittelwert der identifizierten Induktivität einen deutlichen Fehler auf, wie Tab. 6.3 zeigt.

6.2.4 Zusammenfassung

Zusammengefasst ergeben sich bei der Umsetzung und Analyse der Abweichungsschätzung folgende Erkenntnisse. Die simulativen Untersuchungen zeigen für beide Algorithmen im Mittel geringe Schätzfehler, siehe Tab. 6.3. Diese ergeben sich durch die Trennung der Modellstruktur und die damit verbundene Nutzung unterschiedlicher Abtastzeiten in Verbindung mit dem simulierten Messrauschen. Dadurch hat auch die Parametrisierung bereits in

der Simulation einen signifikanten Einfluss auf den letztendlichen Schätzfehler. Zur theoretischen Optimierung der Hyperparameter, beziehungsweise der initialen Kovarianzen, eignen sich in nächster Instanz statistische Verfahren, wie zum Beispiel Monte-Carlo-Ansätze. Allerdings geht aus den Untersuchungen zur OPI in Kap. 4 und 5 hervor, dass die in der Simulation optimierten Parametersätze unter Umständen deutliche Unterschiede zu den am Prüfstand eingesetzten aufweisen, weswegen statistische Optimierungsverfahren für die hier betrachtete Anwendung wenig vielversprechend sind. Die am Prüfstand erreichten Ergebnisse unterscheiden sich qualitativ deutlich von den simulativen, wie Tab. 6.3 zeigt. Während das EKF ausschließlich unzureichende Ergebnisse liefert, ist die Abweichungsschätzung mittels RLS-Algorithmus grundsätzlich für die Diagnose einsetzbar. Jedoch treten im Vergleich zur absoluten OPI in Kap. 4 Abhängigkeiten vom Lastpunkt auf, die sich gerade bei dynamischem Betrieb durch hohe sättigungsbedingte Verzerrungen bemerkbar machen. In der realen Anwendung tritt der gewünschte Effekt zur Entkopplung des nichtlinearen Parameterverhaltens daher nicht in Erscheinung. Zusätzlich ergeben sich am Prüfstand Auffälligkeiten bezüglich der verminderten SNR durch die Vorgabe der Streuinduktivität L_σ .

Grundsätzlich ist die Online-Identifikation zur Anomaliedetektion in einem dynamischen Umfeld geeignet. Zur tatsächlichen Bestätigung bei der Nutzung manipulierter Maschinen sind jedoch erweiterte Analysen von Nöten. In diesem Zusammenhang gilt es auch zu untersuchen, ob sich im Vergleich zur absoluten OPI tatsächlich Vorteile ergeben. Dabei ist vor allem das vergleichsweise langsame Konvergenzverhalten ein wesentlicher Faktor. Gerade bei Alterungseffekten tritt die Parameteränderung bedeutend langsamer auf als in der Simulation angenommen. Die Qualität der Diagnose hängt daher nicht zuletzt erheblich von der gewählten Metrik zur Auswertung der Merkmale ab.

6.3 Online-Parameteridentifikation zur Fehlerdiagnose durch echtzeitfähige Klassifikatoren

Der in Abs. 6.1 erfasste Stand der Technik zeigt eine klare Tendenz zur Nutzung von Methoden mit heuristischen Modellen bei der Fehlerdiagnose. Jedoch eignen sich die gewählten Ansätze aufgrund des erhöhten Speicher- und Rechenbedarfs bei der Merkmalsextraktion sowie der Implementierung der Klassifikatoren nicht für den Einsatz im hier betrachteten Betriebsumfeld. Hinsichtlich der genannten Restriktionen sind Methoden mit analytischem Modell prädestiniert, wobei sich die Frage nach der Metrik zur Klassifikation stellt. Die einfache Nutzung von Grenzwerten zur Überwachung von geschätzten Zustandsgrößen oder Parametern kann dabei aufgrund der auftretenden Dynamik herausfordernd sein. Daher wird nachfolgend ein Ansatz zur parameterbasierten Fehlerklassifikation präsentiert. Neben der Nutzung gemessener Zustandsgrößen ergeben sich die Merkmale dabei basierend auf einer echtzeitfähigen OPI. Die eigentliche Fehlerdetektion erfolgt mittels optimierter Klassifika-

toren zur Echtzeitimplementierung. Durch diese Kombination lassen sich die Vorteile von Methoden mit analytischen und heuristischen Modellen verbinden.

Belastbare Datenerhebungen zur Auftrittshäufigkeit bestimmter Fehler in elektrischen Antriebssystemen für Personenkraftwagen (PKW) sind dem Autor nach momentanem Stand der Technik nicht bekannt. Nach der in von Trigeassou in [152] präsentierten Übersicht treten Rotorstabbrüche in Industrieanlagen häufig auf. Außerdem hat der Bruch eines Rotorstabs unmittelbare Auswirkungen auf den Rotorwiderstand R_r des ESB-Modells und bietet sich daher als beispielhafter Fehler für die nachfolgend präsentierte Methode an. Die Detektion eines gebrochenen Rotorstabs lässt sich als prädiktive Diagnosemaßnahme einordnen, da der Betrieb der Maschine zunächst weiterhin möglich ist. Allerdings tritt dadurch eine Drehmomentwelligkeit auf, wie spätere Untersuchungen zeigen. Diese führt neben Komforteinbußen zu einer erhöhten Wahrscheinlichkeit von Folgefehlern und Systemausfällen.

Aus den durchgeführten Untersuchungen in Kap. 4 und 5 geht der RLS-Algorithmus als robusterer Ansatz zur OPI im betrachteten Umfeld hervor, weswegen dieser zur Merkmalsextraktion genutzt wird. Zur Entwicklung des beschriebenen Ansatzes sind zunächst geeignete Trainingsdaten zu erzeugen. Basierend darauf werden geeignete Merkmale und Klassifikatoren zur Detektion des Rotorstabbruchs festgelegt. Abschließend folgt die Implementierung und die simulative Auswertung.

6.3.1 Erzeugung der Trainingsdaten

Der für das Training des entwickelten Klassifikators erforderliche Datensatz wird mit Hilfe des in Abs. 3.2 beschriebenen Simulationsmodells erzeugt. Damit lassen sich sowohl einfache als auch mehrfache Rotorstabbrüche simulieren. Neben den messbaren Zustandsgrößen der Maschine dienen die von der OPI mittels RLS-Algorithmus identifizierten Parameter als zusätzliche Merkmale.

Festlegung der Datenstruktur

Damit die Fehlerklassifikation nach dem Trainingsprozess in allen Betriebspunkten einsetzbar ist, müssen die genutzten Simulationsdaten möglichst repräsentativ sein. Die Repräsentativität bezieht sich hierbei auf die Abdeckung des gesamten Betriebsspektrums. Dazu zählen neben dem Drehzahl- und Lastbereich auch die damit verbundenen betriebsbedingten Parameteränderungen durch Temperatur, magnetische Sättigung und Frequenz. Um eine große Varianz der Maschinenparameter im Trainingsdatensatz zu gewährleisten, sind zahlreiche Betriebspunktänderungen erforderlich. Die simulierten Drehzahl- und Drehmomentpunkte verteilen sich daher auf den aus vorherigen Kapiteln bekannten nutzbaren Bereich der Maschine von $n = 0 \dots 3000 \text{ min}^{-1}$ und $M = 0 \dots 35 \text{ Nm}$. Etwaige Betriebspunkte bei Nulllast oder im Stillstand der Maschine werden aufgrund der schlechten Anregung des Identifikationsproblems jedoch bewusst nicht berücksichtigt.

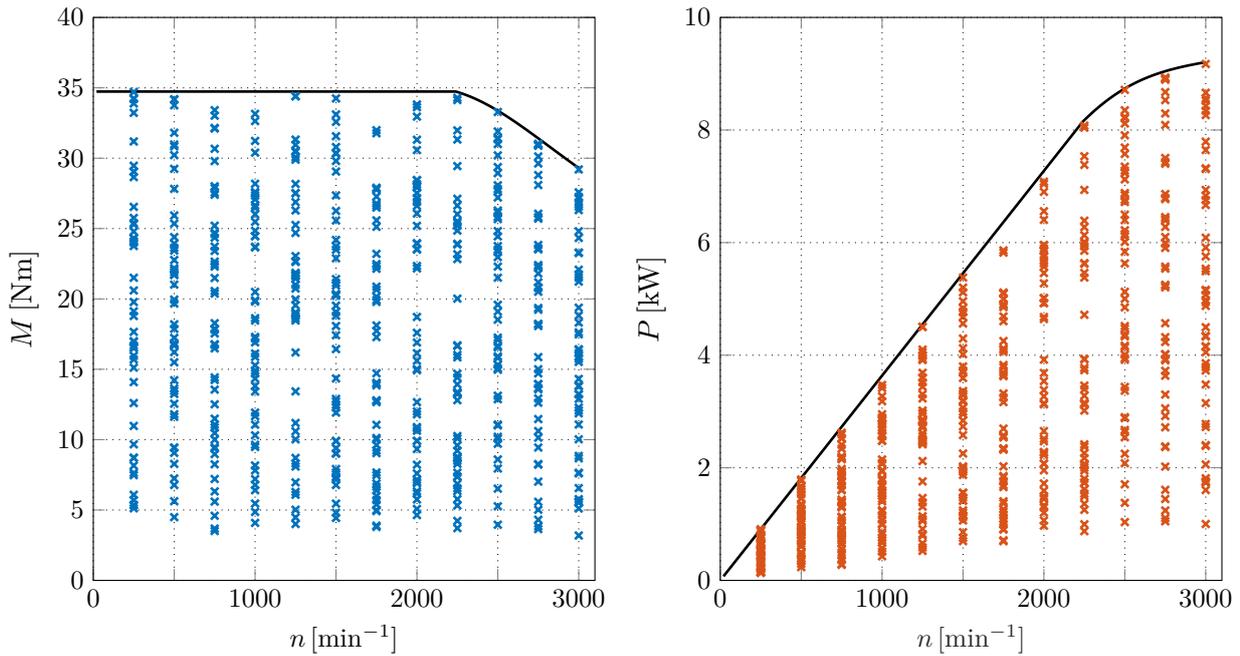


Abbildung 6.7: Übersicht der im Trainingsdatensatz enthaltenen Drehmoment- und Leistungsbetriebspunkte bei ausgewählten Drehzahlen.

Zur gleichwertigen Berücksichtigung des gesamten Betriebsbereichs besteht der erzeugte Trainingsdatensatz aus stationären Drehzahlpunkten mit gleichem Abstand im Bereich von $n = 250 \dots 3000 \text{ min}^{-1}$. Um einheitliche Muster im Datensatz zu verhindern, erfolgt die Verteilung der zugehörigen Lastpunkte zufällig gleichverteilt innerhalb eines festgelegten Bereichs von $M = 10 \dots 100\% \cdot M_{\max}$ also $M = 3,5 \dots 35 \text{ Nm}$. Nach diesem Schema werden jedem einzelnen Drehzahlpunkt vier konstante Lastpunkte zugewiesen. Gemessen an verschiedenen Voruntersuchungen führt diese optimierte Verteilung der Trainingsdaten zu einer besseren Repräsentation des Betriebsbereichs. Dadurch lässt sich die Performanz der trainierten Klassifikatoren wiederum deutlich steigern. Der Wechsel zwischen zwei stationären Betriebspunkten lässt sich beispielsweise durch eine Rampenform mit zufällig gewählter Steigung realistischer darstellen. Dadurch ergeben sich aufgrund der entstehenden Dynamik zusätzliche Informationen zur Ausweitung des Datensatzes. Voruntersuchungen lieferten jedoch keine Verbesserung durch die Nutzung dynamischer Betriebspunkte, weswegen der nachfolgend erzeugte Trainingsdatensatz ausschließlich auf stationären Betriebspunkten basiert. Die absolute Betriebszeit in einem stationären Punkt ist theoretisch frei wählbar. Jedoch wird der Informationsgehalt mit steigender Zeit nicht zwangsläufig größer. Daher orientiert sich das gewählte Zeitfenster an der Frequenz der durch den Rotorstabbruch verursachten Oszillationen. Anhand der Validierung der Trainingsdaten in Abs. 6.3.2 ergibt sich eine Simulationszeit von $t_{\text{stat}} = 2 \text{ s}$ in jedem Betriebspunkt als guter Kompromiss. Generell sei erwähnt, dass es sich um ein realistisches Profil handelt, das bei entsprechender Infrastruktur auch am Prüfstand zur Erzeugung von Trainingsdaten nutzbar ist.

Neben sättigungs- und frequenzabhängigen Parameteränderungen bieten sich zur Steigerung der Robustheit des trainierten Klassifikators gegenüber variierenden Umgebungsbedingungen zusätzlich Änderungen der Maschinentemperatur und der Zwischenkreisspannung an. Die Temperaturen befinden sich in Anlehnung an Binder [54] in einem Bereich von $\vartheta = 20..100\text{ }^{\circ}\text{C}$, weswegen im Datensatz ein Wechsel zwischen drei verschiedenen Betriebstemperaturen $\vartheta = [20\ 60\ 100]\text{ }^{\circ}\text{C}$ integriert ist. Die Variation der Zwischenkreisspannung in jedem Lastpunkt führt aufgrund der funktionsfähigen Kompensation des Spannungsfehlers lediglich zu korrelierten Trainingspaaren, weswegen die dadurch bedingte Erweiterung des Datensatzes als obsolet zu betrachten ist. Diese Erkenntnis stammt aus einer während Voruntersuchungen durchgeführten Korrelationsanalyse und lässt sich durch den Aufbau des Simulationsmodells erklären. Die Ergebnisse sind im Rahmen dieser Arbeit jedoch nicht enthalten.

Die in [89] beschriebene explizite Modellierung des Rotoraufbaus ermöglicht eine gezielte Manipulation einzelner Rotorstäbe. Der Bruch eines Rotorstabs kommt dabei einer Erhöhung des entsprechenden ohmschen Widerstands gleich. Dabei ist aufgrund des undefinierten Zustands der Bruchstelle auch eine Schwankung des Widerstandswertes möglich. In der existierenden Literatur finden sich keine eindeutigen Referenzen zu absoluten Widerstandsänderungen durch einen Rotorstabbruch. Zur Erzeugung des Trainingsdatensatzes wird daher vereinfacht eine Erhöhung des Rotorstabwiderstands um den Faktor 100 angenommen.

Basierend auf den zuvor genannten Rahmenbedingungen ergeben sich schließlich die geforderten Trainingsdaten. Bei der Festlegung der Struktur des Datensatzes ist die Aufteilung zwischen Gut- und Schadensdaten ein entscheidender Aspekt. Bezogen auf die gesamte Betriebszeit einer Maschine treten Schäden in der Realität vergleichsweise selten auf. Ausgehend von einer angenommenen Betriebszeit von $t_{\text{op}} = 7500\text{ h}$ entspricht das Auftreten eines Fehlers über $t_{\text{fail}} = 1\text{ h}$ einem prozentualen Anteil von 0,013%. Die unangepasste Berücksichtigung dieses Verhältnisses in Bezug auf jeden zuvor beschriebenen Betriebspunkt im Kennfeld der Maschine würde zwangsläufig zu einem nicht mehr sinnvollen Umfang des Trainingsdatensatzes führen. Der Anteil der Schadensdaten lässt sich jedoch durch das genutzte Simulationsmodell individuell anpassen. Ziel des entwickelten Diagnosealgorithmus ist die Unterscheidung in Gut- und Schadensdaten, wodurch sich hier ein binäres Klassifikationsproblem ergibt. Um den Lernprozess und die Qualität der Klassifikation zu optimieren ist eine ausgewogene Aufteilung der Trainingsdaten von jeweils 50% Gut- und Schadensdaten sinnvoll. Gleichzeitig birgt diese Aufteilung in Bezug auf die letztendliche Fehlerrate des Klassifikators auch Nachteile. Selbst bei einer geringen falsch positiven Fehlerrate von 1% werden nach der zuvor getätigten Annahme circa 75 mal so viele Schäden prädiziert wie in der Realität auftreten. Diese absolute Fehlerrate ist im Hinblick auf einen realen Nutzen und die Kundenzufriedenheit als eher kritisch zu betrachten. Die Herausforderung besteht daher in einer Optimierung der Modellstruktur und Kostenfunktion hin zur Minimierung der falsch positiven Fehlerrate. Mit dem Ziel einer robusten Mustererkennung erfolgt eine gleichmäßige

Tabelle 6.4: Ausschnitt aus dem Trainingsdatensatz zur Visualisierung des strukturellen Aufbaus.

Test ID	n [min ⁻¹]	M [Nm]	ϑ [°C]	x_{R_r}
⋮	⋮	⋮	⋮	⋮
25	500	4,5	20	1
26	500	24,4	20	100
27	500	17,9	60	1
28	500	30,2	60	100
29	500	9,4	100	1
30	500	7,2	100	100
⋮	⋮	⋮	⋮	⋮
43	500	25,9	20	1
44	500	13,6	20	100
⋮	⋮	⋮	⋮	⋮
55	750	32,1	20	1
56	750	16,7	20	100
⋮	⋮	⋮	⋮	⋮
73	1000	13,4	20	1
74	1000	23,7	20	100
⋮	⋮	⋮	⋮	⋮

Aufteilung der Daten mit und ohne Schaden. Bei zwei zu identifizierenden Fehlerklassen, „Schaden“ und „kein Schaden“ ergibt sich daraus ein Datensatz mit 288 Testläufen. Die eingestellten Lastpunkte und die sich ergebenden Leistungen sind in Abb. 6.7 über der Drehzahl aufgetragen. Zur besseren Nachvollziehbarkeit des Aufbaus zeigt Tab. 6.4 einen Auszug aus der Struktur des Trainingsdatensatzes. Der Faktor x_{R_r} ist darin der multiplikative Fehlerfaktor des Rotorwiderstands R_r zur Simulation des Rotorstabbruchs.

Simulation zur Datenerzeugung

Zur letztendlichen Datenerzeugung dient das in Abs. 3.2 beschriebene Simulationsmodell nach [89] in Verbindung mit dem RLS-Algorithmus zur OPI. Analog zu Abs. 6.2 wird das Maschinenmodell unter Einhaltung der in [89] vorgeschlagenen Abtastzeit von $t_s = 10 \mu\text{s}$ simuliert. Die Abtastung der simulierten OPI erfolgt hingegen mit einer Schrittweite von $t_s = 100 \mu\text{s}$ in Anlehnung an die Taktfrequenz von $f_{\text{pwm}} = 10 \text{ kHz}$ des realen Echtzeitsystems.

Die Zustandsgrößen des Trainingsdatensatzes ergeben sich durch die parallele Simulation des Maschinenmodells nach dem in Abb. 6.7 beschriebenen Profil. Nach den Gegebenheiten im realen Antriebssystem stehen zur späteren Merkmalsextraktion lediglich die in den vorheri-

gen Kapiteln bereits genutzten Größen u_s , i_s und ω_m zur Verfügung.

Daneben identifiziert der RLS-Algorithmus die Parameter des ESB-Modells zur späteren Generierung geeigneter Merkmale. Basierend auf den in Kap. 4 generierten Erkenntnissen bietet sich dabei die Nutzung des dynamischen Regressionsmodells in Kombination mit dem RLS-Algorithmus mit mehrfachem variablen Vergessensfaktor an. Die OPI identifiziert je nach Wahl des Parametervektors $\hat{\theta}$ den Verlauf der Rotorzeitkonstante T_r , des Rotorwiderstands R_r , der Statorinduktivität L_s , der Hauptinduktivität L_m und des Streukoeffizienten σ . Die Vorgabe des Statorwiderstands R_s ist für eine robuste OPI im dynamischen Betriebsfeld dieser Arbeit unabdingbar. Zusätzlich führt die Berücksichtigung des Eisenverlustwiderstands R_{fe} im genutzten Identifikationsmodell je nach Betriebspunkt zu einer erhöhten Genauigkeit.

6.3.2 Validierung der Trainingsdaten

Um die Eignung der generierten Testszenarien für den Trainingsprozess zu bestätigen, ist eine Validierung der simulierten Daten empfehlenswert. Neben der repräsentativen Abbildung des realen Verhaltens der Maschine müssen die Daten zusätzlich geeignete Merkmale zur Klassifizierung enthalten. Zur Hinterfragung der Repräsentativität eignet sich die Nutzung energiebezogener Zustandsgrößen wie dem Drehmoment und der Leistung der Maschine im Schadens- und Nicht-Schadens-Fall. Diese stehen in unmittelbarem Zusammenhang mit den gemessenen Zustandsgrößen und lassen sich anhand physikalischer Grundsätze plausibilisieren.

Die Klassifikation ist letztendlich durch die Erkennung von Mustern in den Trainingsdaten der jeweiligen Klassen möglich. Zur zweifelsfreien Erkennung dieser Muster müssen in den genutzten Systemgrößen spezifische Merkmale erkennbar sein, die nur einer bestimmten Klasse zuzuordnen sind. Ziel des entwickelten Ansatzes ist es, zur Erkennung dieser Muster vor allem die identifizierten Parameter des RLS-Algorithmus zu nutzen. Die Erwartungshaltung ist daher, dass der Rotorstabbruch zur Ausprägung bestimmter Merkmale im geschätzten Verlauf des Rotorwiderstands führt.

Plausibilisierung von Drehmoment und Leistung

Zur Vergleichbarkeit des Drehmomentverlaufs im Schaden- und Nicht-Schaden-Fall wird die Maschine, anders als im Trainingsdatensatz vorgesehen, mit dem gleichen Sollstromvektor und bei einer konstanten Drehzahl ($n = 1000 \text{ min}^{-1}$) betrieben. Daraus ergibt sich der im linken Teil von Abb. 6.8 dargestellte Verlauf. Durch den simulierten Rotorstabbruch bilden sich Pendelmomente in der Maschine aus, die sich im Vergleich zum Drehmoment der intakten Maschine im wesentlichen durch Oszillationen mit zwei definierten Frequenzen, $f_1 = 100 \text{ Hz}$ und $f_2 = 1,51 \text{ Hz}$, bemerkbar machen.

Die Frequenz f_1 ergibt sich durch die auftretende Asymmetrie des Rotorfelds. Während einer

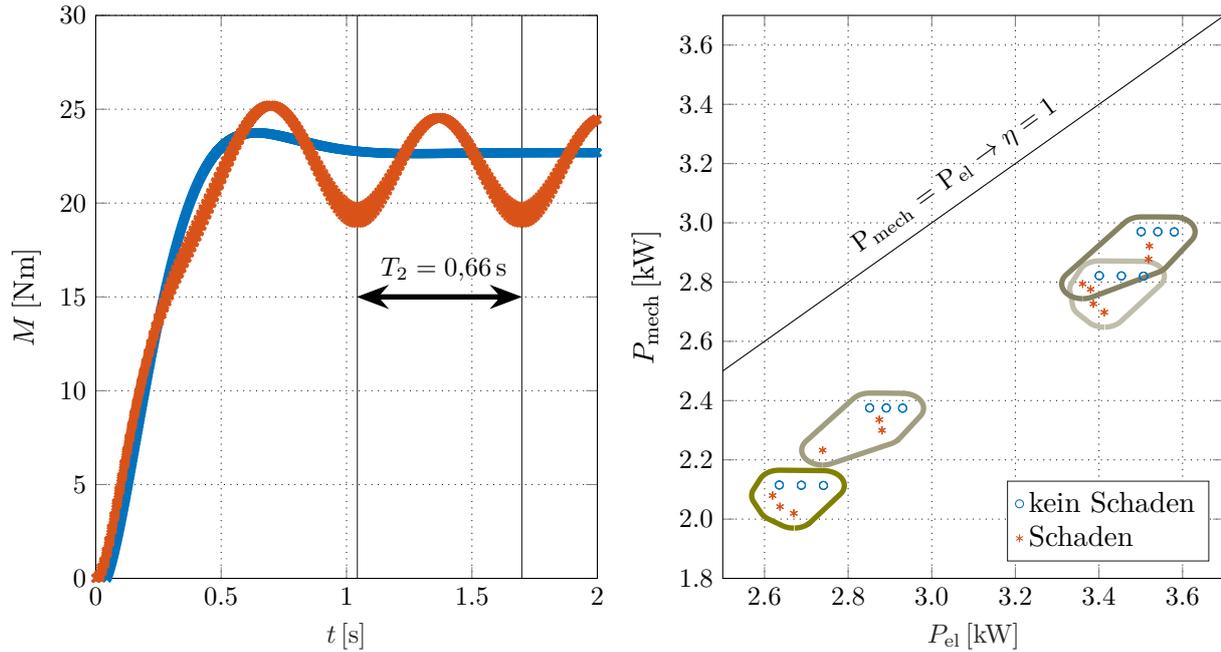


Abbildung 6.8: Darstellung beispielhafter Drehmoment- und Leistungsbetriebspunkte mit jeweils gleichem Sollstromvektor bei ausgewählten Drehzahlen.

Umdrehung des Rotors begegnet der defekte Rotorstab jeder Statorwicklung, wodurch die Induktionsspannung entsprechend sinkt. Die hier betrachtete Maschine hat drei Phasen im Stator $n_{\text{ph}} = 3$ und eine Polpaarzahl von $n_{\text{p}} = 2$. So interagiert der defekte Rotorstab mit 6 Statorspulen, wodurch sich die höherfrequente Oszillation ergibt:

$$f_1 = n_{\text{ph}} \cdot n_{\text{p}} \cdot n = 3 \cdot 2 \cdot \frac{1000 \text{ min}^{-1}}{60 \text{ s}^{-1}} = 100 \text{ Hz.} \quad (6.8)$$

Zusätzlich sinkt erwartungsgemäß der Mittelwert des an der Welle anliegenden Drehmoments.

Die niederfrequente Oszillation ergibt sich durch die Relativbewegung des defekten Rotorstabs zum drehmomentbildenden Magnetfeld. Bei zwei Polpaaren existieren insgesamt vier Maschinenpole pro Strang. Durch die Begegnung des defekten Rotorstabs mit einem Pol kommt es zu einer Erhöhung oder Verkleinerung des Magnetfelds, die sich mit vierfacher Schlupffrequenz im Drehmomentverlauf bemerkbar macht. Bei einer Statorfrequenz von $f_{\text{el}} = 34,1 \text{ Hz}$ ergibt sich die Störfrequenz wie folgt:

$$f_2 = 2 \cdot n_{\text{p}} \left(\frac{f_{\text{el}}}{n_{\text{p}}} - n \right) = 2 \cdot 2 \left(\frac{34,1 \text{ Hz}}{2} - \frac{1000 \text{ min}^{-1}}{60 \text{ s}^{-1}} \right) = 1,51 \text{ Hz.} \quad (6.9)$$

Die Periode $T_2 = 1/f_2 = 0,66 \text{ s}$ der niederfrequenten Störung findet sich entsprechend im Drehmomentverlauf in Abb. 6.8 wieder.

Die absolute Auswirkung des Defekts lässt sich zusätzlich anhand eines Torque Crest Faktors

nach [206] bestätigen:

$$X_{tc} = \frac{\max(\mathbf{M}_{ist}) - \min(\mathbf{M}_{ist})}{\frac{1}{k} \sum_{i=1}^k M_{i,ist}} \quad (6.10)$$

Dieser liegt für alle Simulationen ohne Schaden bei einem Wert von $X_{tc} \leq 3\%$. Durch das Auftreten des Rotorstabbruchs erhöht sich der mittlere Torque Crest Faktor deutlich auf $23,6\% \leq X_{tc} \leq 24,5\%$. Da das Drehmoment lediglich als modellierte und daher nicht gemessene Größe im System vorliegt, wird der Torque Crest Faktor nicht zur Generierung von Merkmalen genutzt.

Die Auswirkungen des defekten Rotorstabs auf die Zustandsgrößen lassen sich zusätzlich durch die Betrachtung der Leistungen im System plausibilisieren. Die rechte Seite von Abb. 6.8 zeigt das Verhältnis von mechanisch abgegebener und elektrisch umgesetzter Leistung beziehungsweise den effektiven Wirkungsgrad η . Exemplarisch sind die Leistungen in vier verschiedenen konstanten Betriebspunkten jeweils mit und ohne Schaden innerhalb einer Umrandung dargestellt. Dabei ist erwartungsgemäß zu erkennen, dass der Wirkungsgrad in jedem Punkt durch den defekten Rotorstabbruch sinkt.

Plausibilisierung des identifizierten Rotorwiderstands

Ein Einsatz des durch den RLS-Algorithmus identifizierten Rotorwiderstands zur Generierung von Klassifikationsmerkmalen bedingt eine Auswirkung des defekten Rotorstabs auf die Ergebnisse der OPI. Zur Plausibilisierung zeigt Abb. 6.9 exemplarisch den identifizierten Rotorwiderstand in verschiedenen konstanten Last- und Drehzahlpunkten. Für jeden Betriebspunkt wird jeweils der Identifikationsverlauf mit und ohne defekten Rotorstab gegenübergestellt. Generell ist die Ausprägung spezifischer Muster unabhängig vom Betriebspunkt deutlich zu erkennen. Während der Rotorwiderstand im Nicht-Schaden-Fall stets mit geringem Fehler und ohne Oszillationen identifiziert wird, stellt sich bei defektem Rotorstab im Mittel eine Abweichung mit einer definierten Oszillation ein. Deren Frequenz ist identisch zu der im Verlauf des Drehmoments in Abb. 6.8 beobachteten niederfrequenten Schwingung, wie der obere Teil von Abb. 6.9 beispielhaft zeigt. Die Box-Plots in der rechten Spalte verdeutlichen die unterschiedlichen statistischen Features der Verläufe mit und ohne Schaden. Neben der merklichen Erhöhung des Mittelwerts durch den defekten Rotorstab erhöht sich auch die Standardabweichung deutlich. Letztendlich bestätigen die beobachteten Verläufe das Potenzial zur Nutzung des identifizierten Rotorwiderstands zur Klassifikation.

6.3.3 Merkmale zur Klassifikation

Die Merkmale zur Klassifikation lassen sich sowohl aus den Zustandsgrößen, als auch aus den Ergebnissen der OPI gewinnen. Aufgrund der Gegebenheiten im betrachteten System stehen als Messwerte lediglich der Statorstrom und die Maschinendrehzahl zur Verfügung. Zusätzlich ist die vom Stromregler ausgegebene Phasenspannung nutzbar, die mit Hilfe des

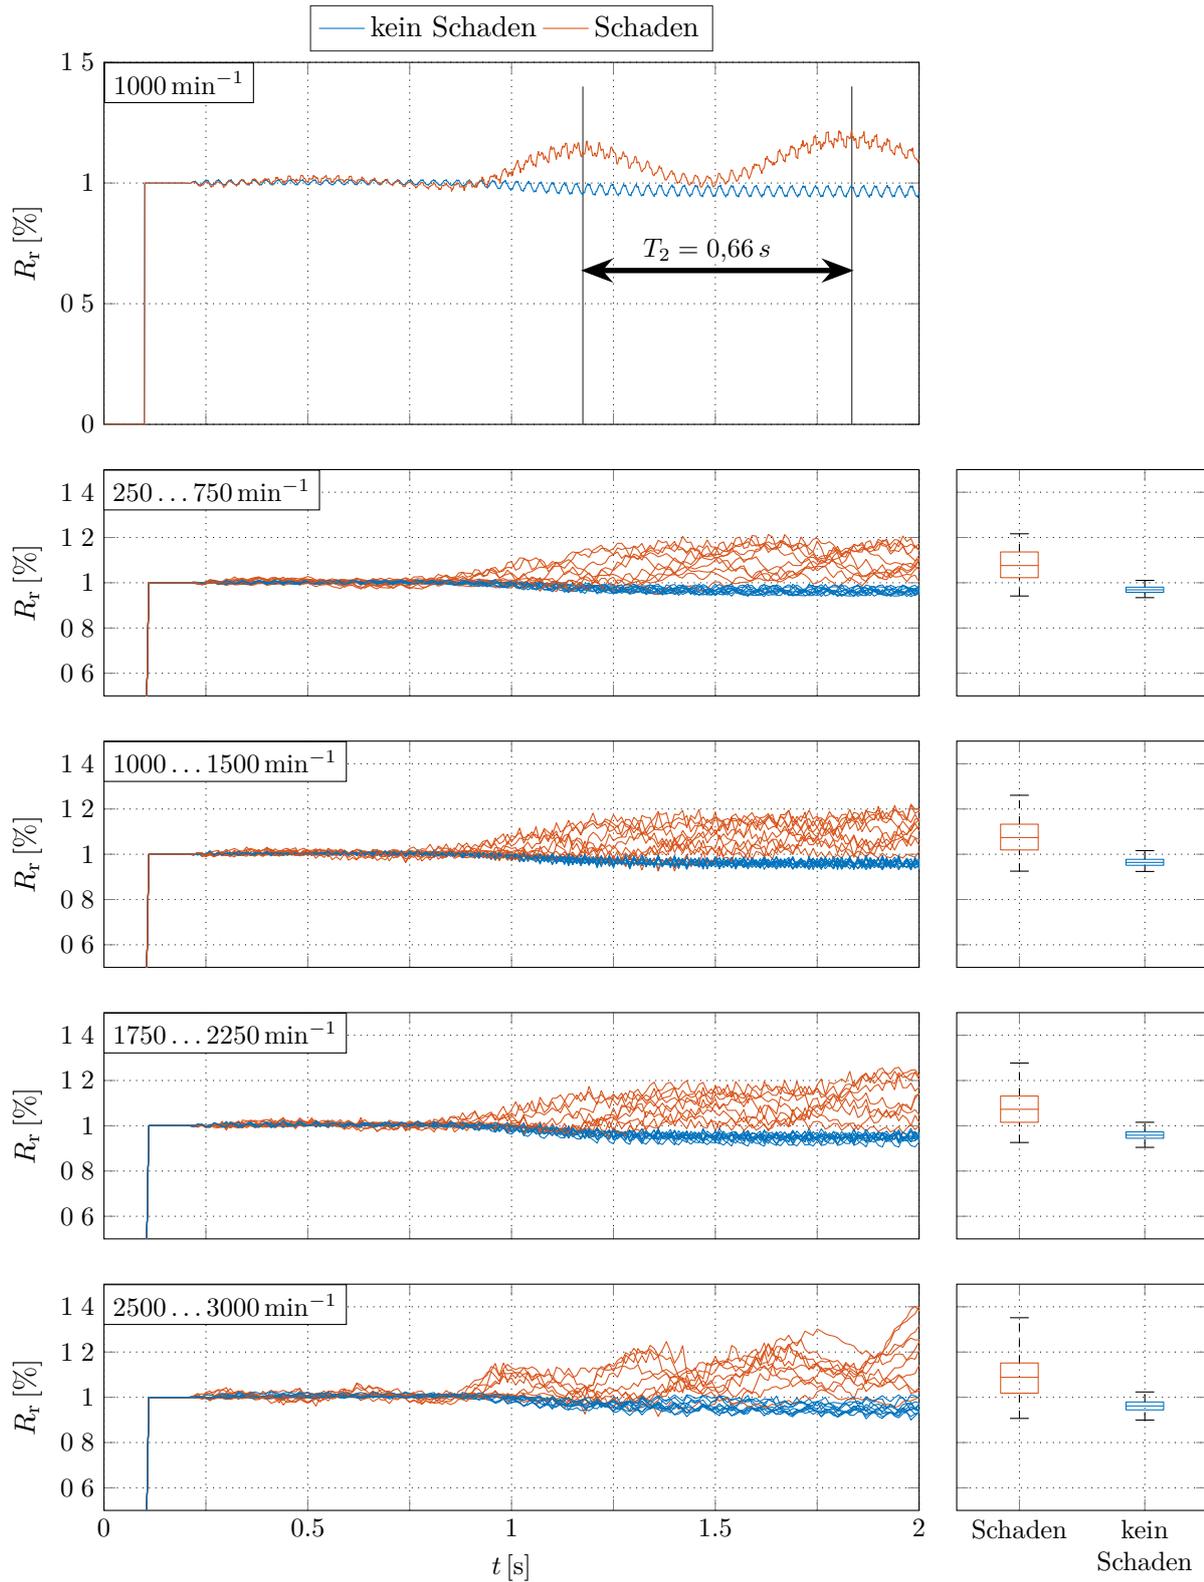


Abbildung 6.9: Exemplarische Darstellung des identifizierten Rotorwiderstands R_r in verschiedenen konstanten Last- und Drehzahlpunkten mit und ohne defektem Rotorstab. - Konfiguration Tab. D.5.

implementierten Leistungselektronikmodells um den auftretenden Verlust korrigierbar ist. Ferner lässt sich aus den genannten Zustandsgrößen die elektrische Wirkleistung bestimmen [54]:

$$P_{\text{el}} = \Re(i_{\alpha\beta} \cdot \overline{u_{\alpha\beta}}). \quad (6.11)$$

Diese impliziert die Winkelbeziehung zwischen Strom und Spannung und beinhaltet daher unter Umständen weitere Informationen.

Neben den Zustandsgrößen nutzt der vorgeschlagene Ansatz die Verläufe der identifizierten Parameter des ESB-Modells. Grundsätzlich können dabei alle Parameter des System von Interesse sein. Aufgrund der kohärenten Struktur des Regressionsmodells hängen die geschätzten Verläufe jedoch zusammen. Um eine einseitige Verteilung der Arten von Features zu vermeiden, kommen daher nur der Rotorwiderstand R_r und die Rotorzeitkonstante T_r zum Einsatz, da diese direkt vom defekten Rotorstab beeinflusst werden.

Wie im Stand der Technik bereits erläutert, sind Ansätze zur Spektralanalyse aufgrund der vorherrschenden Eigenschaften des Systems ungeeignet. Des Weiteren ist die Simulation des Oberschwingungsverhaltens der Maschine bei spezifischen Fehlern sehr aufwendig und im Detail nur numerisch abzubilden. Das hier genutzte Simulationsmodell bildet die dazu benötigten Details nicht ab. Auch ein Vergleich des vorgestellten Ansatzes mit Klassifikatoren die Spektralanalysen zur Merkmalsextraktion nutzen ist in der Folge nicht sinnvoll.

Basierend auf den Erkenntnissen aus der Validierung der Trainingsdaten eignet sich die Nutzung statistischer Features zusätzlich zu den ohnehin enthaltenen physikalischen Eigenschaften. Daher wird der Datensatz um folgende, die statistische Verteilung beschreibende, Eigenschaften der zur Verfügung stehenden Größen i_s , u_s , ω_m , P_{el} , R_r , T_r erweitert [139]:

- Mittelwert:

$$X_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N x_i \quad (6.12)$$

- Standardabweichung:

$$X_{\sigma} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - X_{\text{mean}})^2} \quad (6.13)$$

- Schiefe:

$$X_{\text{skew}} = \frac{1}{X_{\sigma}^3} \sum_{i=1}^N (x_i - X_{\text{mean}})^3 \quad (6.14)$$

- Kurtosis:

$$X_{\text{kurt}} = \frac{1}{X_{\sigma}^4} \sum_{i=1}^N (x_i - X_{\text{mean}})^4 \quad (6.15)$$

Dadurch ergeben sich insgesamt 24 Merkmale zur Fehlerklassifikation. In Betracht der limitierten Rechenkapazität ist der Merkmalsraum jedoch im Laufe des Trainingsprozesses zu reduzieren, sodass nur die wichtigsten Merkmale berücksichtigt werden.

6.3.4 Auswahl und Training der Klassifikatoren

Bei der Wahl des Klassifikators ist neben dem Rechenaufwand vor allem der Speicherbedarf auf dem eingebetteten System entscheidend. Viele nach Stand der Technik existierende Ansätze nutzen komplexe Modellstrukturen zur Mehrklassenklassifikation, die alleine wegen der Anzahl der zu speichernden Modellparameter im betrachteten System dieser Arbeit nicht umsetzbar sind. Die hier angestrebte Fehlerdiagnose ist als binäres Klassifikationsproblem einzuordnen. Dadurch liegt eine deutlich geringere Komplexität vor, weswegen auch die Komplexität der Klassifikationsmodelle reduzierbar ist. Der injizierte Fehler sollte trotzdem robust identifizierbar sein und dabei möglichst wenig falsch positive Prädiktionen erfolgen. Unter den genannten Gesichtspunkten erfolgt die Auswahl und das Training geeigneter Klassifikatoren. Dabei wird die Performanz einer logistischen Regression, eines künstlichen neuronalen Netzes und einer Support-Vector-Machine gegenübergestellt. Nach den Regeln guter Praxis empfiehlt sich generell eine vollständige Normierung des Trainingsdatensatzes, sowie eine Aufteilung in Trainings-, Test- und Validierungsdaten.

Metrik zur Bewertung der Klassifikatoren

Übliche Metriken zur Bewertung der Performanz der unterschiedlichen Klassifikatoren leiten sich aus der Wahrheitsmatrix in Tab. 6.5 ab, wie zum Beispiel nach Murphy ersichtlich [207]. Diese enthält folgende Quantifizierungen:

- Richtig Positiv (RP) → defekte Maschine, richtig als defekt klassifiziert
- Richtig Negativ (RN) → nicht defekte Maschine, richtig als nicht defekt klassifiziert
- Falsch Positiv (FP) → nicht defekte Maschine, falsch als defekt klassifiziert
- Falsch Negativ (FN) → defekte Maschine, falsch als nicht defekt klassifiziert

Mit Hilfe dieser Quantifizierungen lassen sich unterschiedliche Metriken zur Bewertung der Klassifikationsergebnisse ableiten. Die Genauigkeit gibt das Verhältnis der richtigen Prädiktionen bezogen auf die Gesamtanzahl an:

$$\text{Genauigkeit : } \frac{\text{RP} + \text{RN}}{\text{RP} + \text{FP} + \text{RN} + \text{FN}} \quad (6.16)$$

Die Spezifität hingegen gibt an wie zuverlässig die Prädiktion der nicht defekten Klassen erfolgt:

$$\text{Spezifität : } \frac{\text{RN}}{\text{RN} + \text{FP}} \quad (6.17)$$

Im Umkehrschluss ergibt sich mit steigender Anzahl falsch positiver Prädiktionen eine zunehmend schlechtere Spezifität. Bezogen auf das betrachtete Umfeld dieser Arbeit und den zugrundeliegenden Trainingsdatensatz mit jeweils 50% defekten und nicht defekten Daten

Tabelle 6.5: Darstellung der Wahrheitsmatrix zur Gegenüberstellung der prädizierten und echten Klassen in Anlehnung an [207].

		Prädizierte Klassen		Σ
		1	0	
Echte Klassen	1	RP	FN	$RP + FN$
	0	FP	RN	$FP + RN$
Σ		$RP + FP$	$FN + RN$	$RP + FP + RN + FN$

liegt der Idealwert der Spezifität bei 100 %. In diesem Fall werden ausschließlich Daten nicht defekter Maschinen als nicht defekt klassifiziert.

Logistische Regression

Als erster Klassifikator wird die Logistische Regression (LR) genutzt, siehe zum Beispiel [183], [208]. Die LR ist letztlich eine Erweiterung der linearen Regression. Die Modellstruktur entspricht einem neuronalen Netz mit einem Neuron. Jedes zur Klassifikation genutzte Merkmal bildet dabei einen Modelleingang x_i und geht mit einem separaten Gewicht w_i in die Berechnung des Modellausgangs y ein:

$$v = b + \sum_{i=1}^N x_i \cdot w_i \rightarrow v \in]-\infty, \infty[. \quad (6.18)$$

Unter Berücksichtigung des zusätzlichen Bias-Parameters b des Neurons ergeben sich bei N Features demnach $N + 1$ zu speichernde Gewichte.

Zur Klassifikation wird der Ausgang y mit Hilfe einer Sigmoidalfunktion $s(y)$ auf einen Wertebereich von 0 bis 1 skaliert:

$$y = s(v) = \frac{1}{1 + e^{-v}} \rightarrow y \in]0, 1[. \quad (6.19)$$

Somit erfolgt die Klassifikation in „Klasse 0“ und „Klasse 1“. Zur Formulierung der Kostenfunktion für die Optimierung der Gewichte existieren unterschiedliche Ansätze. Für die Anwendung in dieser Arbeit bietet sich die Nutzung der *Lasso Regression* an, da sie die Gewichte unwesentlicher Merkmale tendenziell zu null optimiert [209]:

$$L_j(v_j) = \log \left(1 + e^{-(K_j \cdot v_j)} \right) + \lambda \left(|b| + \sum_{i=1}^N |w_i| \right). \quad (6.20)$$

Darin ist der Parameter K_j für das Labeln der Daten zuständig ($K_j = 1 \rightarrow$ Klasse 0, $K_j = -1 \rightarrow$ Klasse 1) und λ macht den Einfluss der Gewichte auf den Lernprozess steuerbar. Ein großer Vorteil in Bezug auf die Anforderungen dieser Arbeit ist daher der vergleichsweise niedrige Speicherbedarf und die einfache Berechnung. Des Weiteren ist durch die einfache

Tabelle 6.6: Parameter der logistischen Regression nach abgeschlossenem Training bei Nutzung unterschiedlicher Zeitabschnitte der Trainingsdaten.

w	Zeitintervall			
	0–0,5 s	0,5–1 s	1–1,5 s	1,5–2 s
$i_{s,\text{mean}}$	-1,8	0,0	-0,8	0,0
$i_{s,\sigma}$	0,0	3,7	0,0	0,0
$u_{s,\text{mean}}$	1,1	-1,4	-1,0	0,0
$u_{s,\sigma}$	0,0	0,0	3,0	0,0
$R_{r,\text{mean}}$	0,0	3,5	3,7	3,5
$R_{r,\sigma}$	0,0	0,0	0,5	3,4
$R_{r,\text{kurt}}$	-13,3	-0,6	0,0	0,0
$T_{r,\sigma}$	-4,8	0,0	0,9	0,0
$T_{r,\text{kurt}}$	-0,9	1,4	0,0	0,0
$P_{el,\sigma}$	-5,5	0,0	0,0	0,0
$\omega_{m,\text{mean}}$	0,6	-1,3	0,0	0,0

Struktur die Gewichtung jedes einzelnen Merkmals sichtbar und dadurch die Entscheidung des Algorithmus eindeutig nachvollziehbar. Diese Tatsache ist besonders interessant, da so der Einfluss der zusätzlich identifizierten Parameter der OPI auf die Entscheidungsfindung bewertbar ist. Durch die fehlende Vernetzung der Eingänge sind jedoch keine Interaktionen zwischen den einzelnen Merkmalen abbildbar.

Zum Training der Modellparameter wird das stochastische Gradientenverfahren genutzt. Um den Einfluss der verwendeten Merkmale auf die Klassifikation direkt bewertbar zu machen und einen Vergleich zu anderen Klassifikatoren zu ermöglichen, ist zunächst eine vollständige Normierung des Trainingsdatensatzes durchzuführen. Das Zeitfenster zur Berechnung der statistischen Merkmale ist im Bereich eines Trainingspunktes von $t = 0 \dots 2 \text{ s}$ frei wählbar. Die Länge des gewählten Fensters ist jedoch direkt proportional zum benötigten Berechnungsaufwand, weswegen sie strategisch minimiert werden muss. Bei Betrachtung des beispielhaften Trainingspunktes in Abb. 6.8 beziehungsweise Abb. 6.9 sind unterschiedliche Phasen ersichtlich. Nach der Initialisierung des RLS-Algorithmus in Abb. 6.9 folgt eine Einschwingphase in der sich die Identifikation beider Klassen stark ähnelt. Ab einer Zeit von $t \approx 0,9 \text{ s}$ trennen sich beide Verläufe, sodass ein deutlicher Unterschied zu erkennen ist. Auch der Verlauf des Drehmoments in Abb. 6.8 ist in diesem Beispiel recht träge und schwingt erst nach einer Weile ein. Es lässt sich also vermuten, dass die genutzten Merkmale zur Klassifikation bei Reduzierung der Fensterlänge variieren.

Zur Validierung wird das zur Verfügung stehende Zeitfenster in vier Abschnitte mit einer jeweiligen Länge von $t = 0,5 \text{ s}$ aufgeteilt. Die dominanten Gewichte der einzelnen Merkmale nach abgeschlossenem Training visualisiert Tab. 6.6. Dadurch ist ersichtlich, welche Merkmale in den unterschiedlichen Zeitabschnitten zur Entscheidungsfindung beigetragen haben.

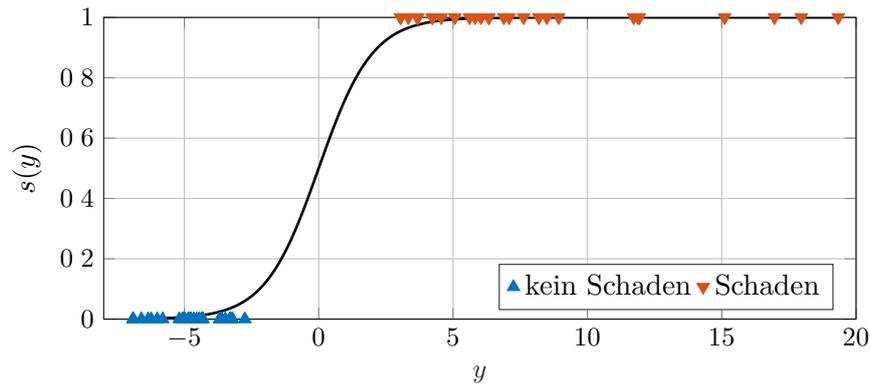


Abbildung 6.10: Visualisierung der Klassifikation durch die logistische Regression anhand der sigmoidalen Kostenfunktion.

Wichtig zu erwähnen ist, dass es auch hier bei allen genutzten Teildatensätze zu keiner Fehlprädiktion kommt. Eine Visualisierung der Prädiktionen der LR findet sich in Abb. 6.10. Die Genauigkeit und Spezifität liegen jeweils bei 100 %. Eine zentrale Beobachtung ist die Dominanz der statistischen Features des identifizierten Rotorwiderstands bei der Klassifikation in allen vier Teilabschnitten. Gerade im letzten Zeitabschnitt trifft der Klassifikator die Entscheidung allein basierend auf dem Verlauf des Rotorwiderstands, was bei Betrachtung von Abb. 6.9 plausibel erscheint. Vor allem aber bestätigt sich die Eignung der OPI zur Gewinnung von Merkmalen zur Fehlerklassifikation und somit eine wesentliche Hypothese dieser Arbeit. Ferner ist ersichtlich, dass der Klassifikator in den ersten drei Abschnitten deutlich mehr Merkmale zur Entscheidungsfindung benötigt als im letzten. Der potenzielle Wegfall der meisten Merkmale führt bei der späteren Implementierung zu einem deutlich geringeren Rechenaufwand.

Abschließend lässt sich sagen, dass die LR grundsätzlich zur Klassifikation des vorliegenden Diagnoseproblems geeignet ist. Die erreichten Genauigkeiten und Spezifitäten sind natürlich für reale Anwendungsfälle unrealistisch, was nicht zuletzt an den ausschließlich stationären Testpunkten liegt. In Abs. 6.3.5 erfolgen daher erweiterte Analysen im dynamischen Betrieb und ein Vergleich mit anderen trainierten Klassifikatoren.

Künstliches Neuronales Netz

Im Vergleich zur LR sind KNN in der Lage, Abhängigkeiten zwischen einzelnen Merkmalen abzubilden, wenngleich dazu deutlich mehr Parameter von Nöten sind. Außerdem ist die Entscheidungsfindung, beziehungsweise die letztendliche Gewichtung der Merkmale, dadurch nicht mehr einfach nachvollziehbar. Die Modelltiefe ist dabei beliebig auf die Komplexität des Klassifikationsproblems skalierbar. Rekurrente und gefaltete neuronale Netze eignen sich besonders zur spezifischen Klassifikation verschiedener Fehler und sind ferner zur Modellierung der Fehlerentstehung geeignet, vgl. beispielhaft [171]. Dazu sind jedoch tiefe Modellstrukturen mit vielen Parametern von Nöten, die wiederum einen hohen Speicher- und Re-

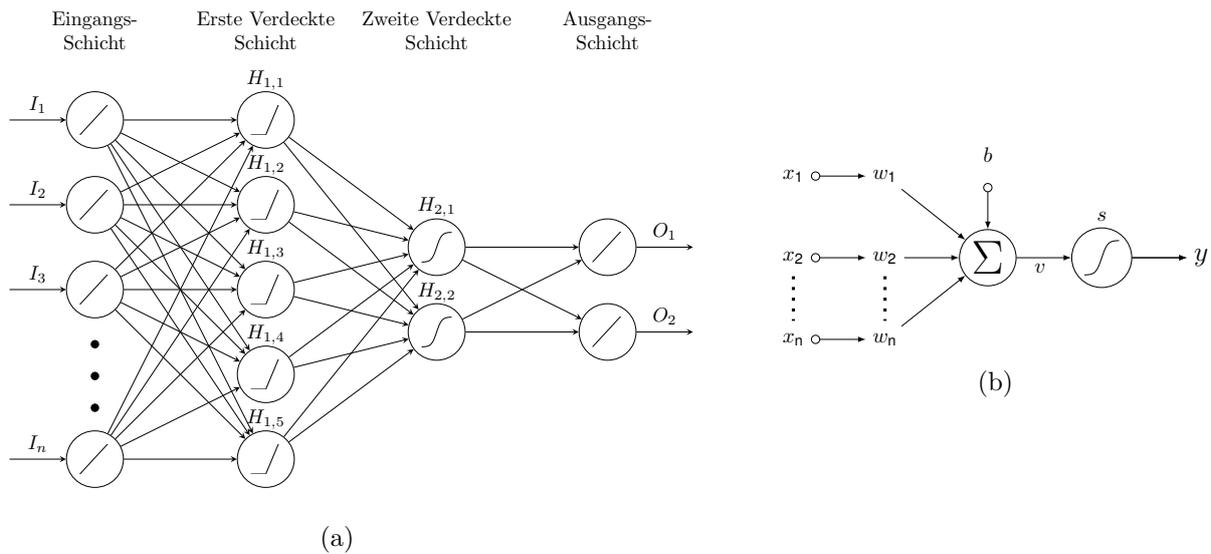


Abbildung 6.11: (a) Struktur des implementierten Multi-Layer-Perzeptrons (b) Aufbau eines einzelnen Neurons.

chenbedarf zur Folge haben. Außerdem sind zum Erreichen hoher Genauigkeiten sehr große Mengen an Fehlerdaten notwendig. Diese werden in der Regel durch bewusste Manipulation von Testmaschinen erzeugt, weswegen allgemein Zweifel gegenüber einer ausreichenden Generalisierungsfähigkeit bestehen. Vorteilhaft in Bezug auf die Systemanforderungen dieser Arbeit ist, dass auch bereits kleine und vorwärtsgerichtete neuronale Netze in Form eines MLP zur Modellierung mehrfach nichtlinearer Zusammenhänge geeignet sind. Für das hier betrachtete binäre Klassifikationsproblem ist ohnehin davon auszugehen, dass keine tieferen Modellstrukturen mit Rückkopplungen oder Faltungen notwendig sind. Nachfolgend wird daher ein MLP zur Detektion des defekten Rotorstabs entwickelt.

Zur Ermöglichung unabhängiger Validierungs- und Testläufe während des Trainings ist es nach den Regeln der guten Praxis unabdingbar, den Datensatz aufzuteilen. Aus diesem Grund werden nur etwa $\approx 70\%$ der 288 Testläufe für das eigentliche Training genutzt, während die übrigen als Validierungs- und Testdaten dienen. Die Aufteilung erfolgt zufällig und nach dem Schema:

- Trainingsdaten 196 Testläufe
- Validierungsdaten 34 Testläufe
- Testdaten 58 Testläufe

Mit Hilfe der gewonnenen Erkenntnisse durch die logistische Regression lässt sich die Anzahl der relevanten Features bereits im Voraus reduzieren. Daher erfolgt das Training des MLP basierend auf den elf in Tab. 6.6 dargestellten Merkmalen.

Zunächst ist die Struktur des verwendeten MLP festzulegen. Generell besteht gerade bei Ver-

wendung neuronaler Netze die Gefahr eines Overfittings der trainierten Gewichte. Eine Erhöhung der Anzahl der Neuronen und oder Schichten des MLP führt daher nicht zwangsläufig zu einem besseren Ergebnis. Nach erster Einschätzung ist für die binäre Klassifikation des genutzten Trainingsdatensatzes keine übermäßig tiefe Netzstruktur von Nöten. Außerdem sei an dieser Stelle nochmals auf die Anforderungen hinsichtlich Speicher- und Rechenaufwand hingewiesen. Die Optimierung der Netzstruktur erfolgt heuristisch anhand unterschiedlicher Versuche und wird aus Übersichtgründen nicht detailliert dargestellt. Gängige Praxis für kleine neuronale Netze ist eine Verdopplung der Anzahl der genutzten Eingänge zur Bestimmung der Neuronenanzahl in der ersten verdeckten Schicht [210]. Zur Reduzierung der Dimension hin zum Ausgang enthält die zweite verdeckte Schicht halb so viele Neuronen. Diese Struktur führte während Voruntersuchungen bereits zum Overfitting des Modells. Die Anzahl der Neuronen in beiden Schichten wurden daher sukzessive reduziert. Das beste Ergebnis zeigt sich bei fünf Neuronen in der ersten und zwei Neuronen in der zweiten verdeckten Schicht. Die Struktur des optimierten MLP ist in Abb. 6.11(a) dargestellt. Die Anzahl der Ausgänge entspricht stets der Anzahl der prädizierten Klassen und ist theoretisch flexibel anpassbar. In der Regel ist diese jedoch durch das jeweilige Klassifikationsproblem vorgeschrieben.

Die mathematische Definition eines Neurons nach [210] zeigen (6.18) und (6.19), wobei die Aktivierungsfunktion (6.19) variieren kann, siehe auch Abb. 6.11(a). Neben der im Fall der LR genutzten Sigmoidalfunktion existieren zahlreiche weitere Aktivierungsfunktionen, die einerseits das Verhalten, andererseits aber auch den Rechenaufwand jedes einzelnen Neurons beeinflussen. Eine gängige Alternative ist die Nutzung linearer oder stückweise linearer Aktivierungsfunktionen, deren Berechnungszeit deutlich geringer ist [211]. Diese werden häufig zur Komplexitätsreduktion in tiefen gefalteten neuronalen Netzen eingesetzt [212]. Im hier betrachteten MLP lässt sich der Rechenaufwand durch den Einsatz einer Rectified Linear Unit (ReLU) in der ersten verdeckten Schicht ohne Beeinträchtigung der Genauigkeit merklich reduzieren. Die Klassifikation in der zweiten verdeckten Schicht erfolgt mittels der Sigmoidalfunktion (6.19).

Das Training erfolgt mittels der von Matlab zur Verfügung gestellten *Deep Learning Toolbox*. Zum Training der Gewichte kleiner neuronaler Netze nutzt Matlab standardmäßig das optimierte *Limited-Memory Broyden-Fletcher-Goldfarb-Shannon Quasi-Newton*-Verfahren, siehe [210, S.312]. Der zugehörige Verlauf der Trainings- und Validierungskosten ist in Abb. 6.12 beispielhaft anhand der Daten aus dem vierten Zeitfenster $t = 1,5 - 2$ s dargestellt. Der Abbruch des Trainings erfolgt nach der 17ten Iteration, da im weiteren Verlauf keine signifikante Verbesserung zu erwarten ist. Die Validierungskosten bestätigen den stabilen Trainingsverlauf ohne Overfitting. Auch das MLP prädiziert die fehlerhaften Daten mit einer hohen Genauigkeit. Eine einzige Fehlprädiktion ergibt sich im ersten Zeitfenster $t = 0 - 1,5$ s. Aufgrund der geringen Repräsentativität dieses Abschnitts für die Nutzung im realen System ist das Ergebniss dennoch als sehr gut bewertbar.

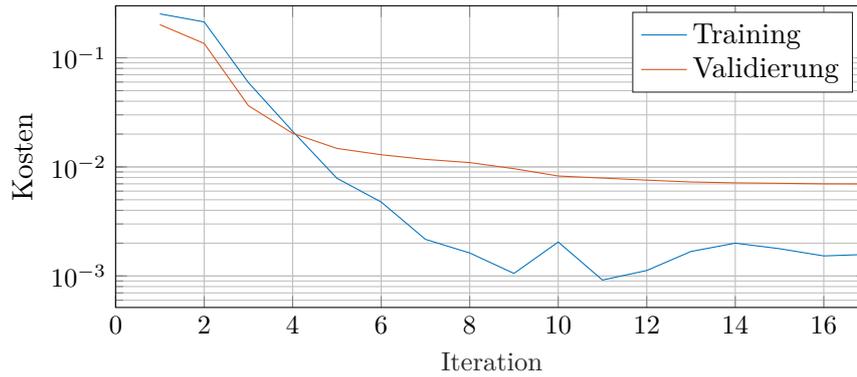


Abbildung 6.12: Trainingsverlauf des Multi-Layer-Perzeptrons mit dem *Limited-Memory Broyden-Fletcher-Goldfarb-Shanno Quasi-Newton*-Verfahren.

Support Vector Machine

Einschlägige Fachliteratur zum Thema SVM bieten Steinwart et al. [213]. Die nachfolgenden Informationen sind als grundsätzliche Erklärung basierend auf [213] zu verstehen. Bei Nutzung der SVM erfolgt die Klassifizierung der Datensätze durch Trennung mit geraden Hyperebenen. Dabei wird jeder Datensatz N als Vektor x_i betrachtet und seiner Klasse zugeordnet. Idealerweise existiert eine gerade Hyperebene, die eine eindeutige Trennung der Klassen erlaubt. In diesem Fall ergeben sich automatisch unendliche viele mögliche Trennebenen. Damit auch hinzukommende Daten valide klassifizierbar sind, wird beim Training der SVM jedoch genau die Ebene gesucht, bei der die Spanne (Hard-Margin) zwischen den zu trennenden Klassen maximal ist. Dabei bilden die Vektoren jeder Klasse die der Hyperebene am nächsten sind die Stützvektoren (Support-Vektoren). Angenommen es existiert eine gerade Hyperebene zur Trennung der N Muster x_i in die echten Klassen $C = 1$ und $C = -1$, so ist diese durch das Skalarprodukt des Normalenvektors w der Ebene und allen auf der Ebene liegenden Punkten x festgelegt:

$$w \cdot x + w_0 = 0. \quad (6.21)$$

$|w_0|$ ist darin der Abstand der Ebene zum Ursprung. Folglich beschreibt (6.21) die Support-Vektoren. Alle weiteren Punkte lassen sich durch die Gleichung

$$\hat{y}_i = \text{sgn}(w \cdot x_i + w_0) \quad (6.22)$$

den Klassen $C = 1$ und $C = -1$ zuordnen. Die Optimierung der Hyperebene erfolgt durch Minimierung der L2 Norm des Normalenvektors w mit der Nebenbedingung NB:

$$\min_{w, w_0} \frac{1}{2} \sum_{j=1}^N w_j^2 \quad (6.23)$$

$$\text{NB: } y_i(w \cdot x_i + w_0) \geq 1 \quad \forall i \in 1 \dots N.$$

In der Praxis existiert oft keine eindeutige Trennebene, sodass der Trainingsalgorithmus Fehlklassifikationen zulassen muss. Dieses Phänomen wird auch als Soft Margin bezeichnet und im Trainingsalgorithmus als Fehlerterm durch eine Schlupfvariable ξ_i und einen Kostenfaktor S berücksichtigt:

$$\min_{\mathbf{w}, w_0} \quad \frac{1}{2} \sum_{j=1}^N \mathbf{w}_j^2 + S \sum_{i=1}^N \xi_i \quad (6.24)$$

$$\text{NB1: } y_i(\mathbf{w} \cdot \mathbf{x}_i + w_0) \geq 1 \quad \forall i \in 1 \dots N$$

$$\text{NB2: } \xi_i \geq 0 \quad \forall i \in 1 \dots N.$$

In der Praxis liegen die Klassen oft nicht geordnet und kompakt im Merkmalsraum. Dadurch sind diese unter Umständen nicht durch eine lineare Hyperebene trennbar. In diesem Fall ist eine nichtlineare Transformation der Merkmalsvektoren $\mathbf{x} \mapsto \mathbf{Z}(\mathbf{x})$ in eine weitere Dimension erforderlich. In dieser neuen Dimension sind die Merkmale dann wiederum linear trennbar. Diese Transformation wird als Kernel-Trick bezeichnet. Die Herausforderung besteht dabei in der Wahl einer individuell geeigneten nichtlinearen Transformationsvorschrift (Kernel). Dieser zusätzliche Freiheitsgrad macht die SVM zu einem sehr mächtigen Klassifikationsansatz. Abbildung 6.13 zeigt beispielhaft die Transformation eines Datensatzes mit zwei zu trennenden Klassen. Die Transformation erfolgt in diesem Fall mittels einer Kreisgleichung. Das Training erfolgt auch hier mit Hilfe der von Matlab zur Verfügung gestellten *Deep Learning Toolbox* und dem standardmäßig genutzten *Limited-Memory Broyden-Fletcher-Goldfarb-Shanno Quasi-Newton-Verfahren*, siehe [210, S.312]. Die Anwendung eines nichtlinearen Kernels ist für die hier durchzuführende Klassifikation nicht notwendig, da das Training der Support-Vektoren mit einer einfachen Soft-Margin nach (6.24) bereits überzeugende Ergebnisse liefert. Wie im Fall des MLP ergibt sich auch bei der Klassifikation mittels SVM lediglich eine Fehlprädiktion im Zeitfenster $t = 0 - 1,5$ s. Bezüglich der vorherrschenden Echtzeitanforderungen ist die mögliche Anwendung des Kernel-Tricks individuell zu prüfen.

6.3.5 Performanz der Klassifikatoren im dynamischen Betrieb

Das Training der drei in Abs. 6.3.4 vorgestellten Klassifikatoren führt in allen Fällen zu einer überzeugenden Performanz. Zur Verringerung der Komplexität beinhalten die Trainingsdaten lediglich stationäre Betriebspunkte. Im Hinblick auf die Anwendung stellt sich nun die Frage nach der Performanz der trainierten Klassifikatoren zur Fehlerdiagnose im realen Betriebsfall. Analog zu Abs. 6.2 folgt daher eine Validierung im dynamischen Betrieb entlang des WLTP-Zyklus mit und ohne defektem Rotorstab. Bezugnehmend auf das durchgeführte Training ist die Diagnose in Zeitfenstern von 0,5 s durchzuführen. Daher bietet sich die Nutzung des in [214] nach Komfort und Energie optimierten WLTP-Zyklus an, siehe Abb. 6.14. Die gefahrene Distanz und die dafür benötigte Zeit bleiben hierbei identisch zum ursprünglichen WLTP-Zyklus. Zur Validierung liegen daher insgesamt 4088 Zeitabschnitte vor, von

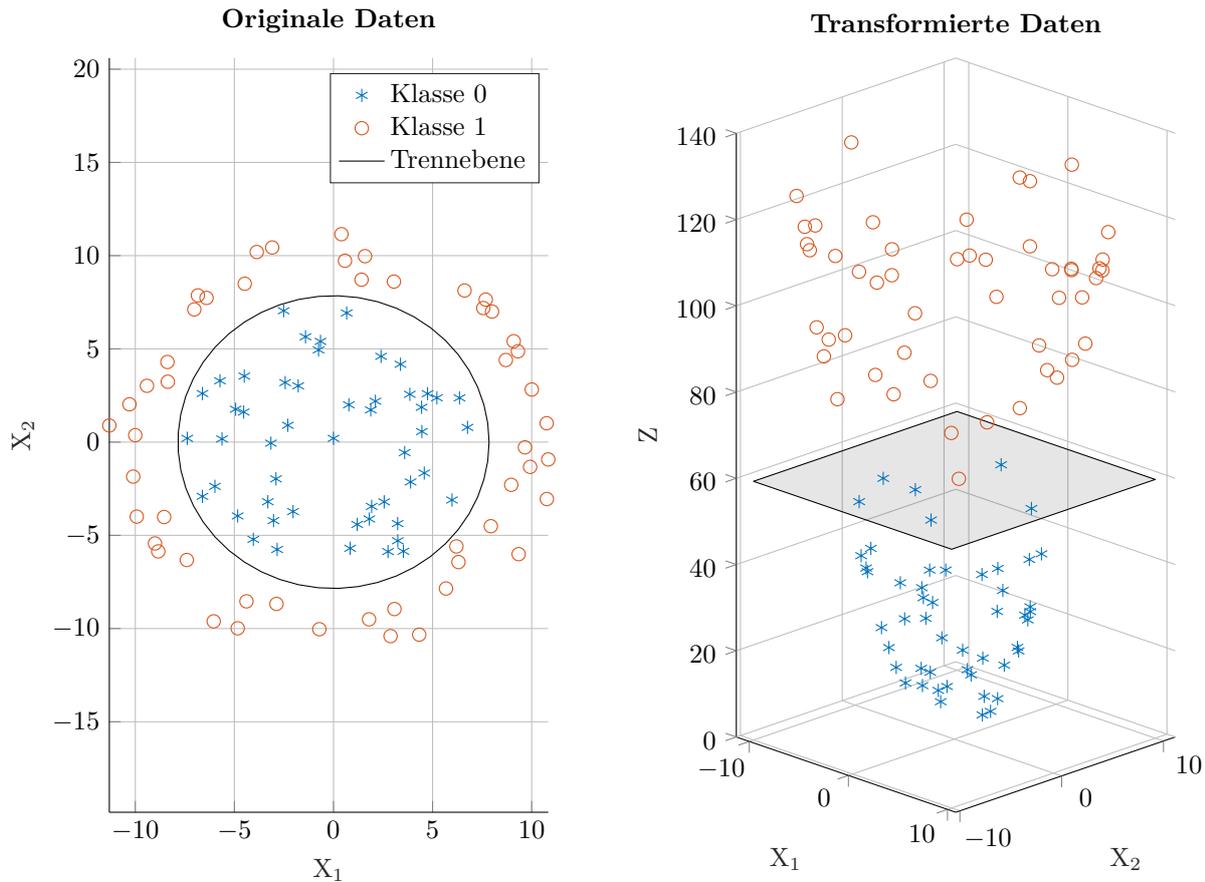


Abbildung 6.13: Transformation mittels Kernel-Trick am Beispiel eines Trainingsdatensatzes mit zwei zu trennenden Klassen

denen in 2044 Fällen eine defekter Rotorstab vorliegt. Zum Vergleich der Klassifikatoren dienen die aus der jeweiligen Wahrheitsmatrix abgeleiteten Genauigkeiten (6.16) und Spezifitäten (6.17). Bereits in Kap. 4 bestätigt sich die Notwendigkeit einer Aktivierungslogik, um in Phasen schwacher Anregung fehlerhafte Identifikationsergebnisse zu vermeiden. Die parameterbasierte Fehlerdiagnose erbt dieses Problem gewissermaßen. Zur Verdeutlichung wird nachfolgend zunächst eine uneingeschränkte Diagnose in allen Betriebspunkten durchgeführt. Anschließend erfolgt die Implementierung einer Aktivierungslogik zur Vermeidung von Fehlprädiktionen.

Performanz der Klassifikatoren im dynamischen Betrieb ohne Aktivierungslogik

Im ersten Schritt ist die Fehlerdiagnose durchgehend aktiv. Die erreichten Genauigkeiten und Spezifitäten der drei analysierten Klassifikatoren leiten sich aus der jeweiligen Wahrheitsmatrix in Tab. 6.7 ab. Mit den erreichten Prädiktionsgüten lässt sich für keinen der Klassifikatoren eine sinnvolle Diagnose in realen Fahrzeugen umsetzen. Die hohe Anzahl an falsch positiven Prädiktionen in Verbindung mit der geringen Auftrittshäufigkeit eines Scha-

Tabelle 6.7: Darstellung der Wahrheitsmatrix zur uneingeschränkt aktiven Fehlerdiagnose entlang des angepassten WLTP-Zyklus.

Logistische Regression		Prädizierte Klassen		
		Schaden	kein Schaden	Σ
Echte Klassen	Schaden	1555	489	2044
	kein Schaden	168	1876	2044
Σ		1723	2365	4088
Genauigkeit		83,9 %		
Spezifität		91,8 %		

Multi-Layer-Perceptron		Prädizierte Klassen		
		Schaden	kein Schaden	Σ
Echte Klassen	Schaden	1558	486	2044
	kein Schaden	242	1802	2044
Σ		1800	2288	4088
Genauigkeit		82,1 %		
Spezifität		88,2 %		

Support-Vector-Machine		Prädizierte Klassen		
		Schaden	kein Schaden	Σ
Echte Klassen	Schaden	1555	489	2044
	kein Schaden	293	1751	2044
Σ		1848	2240	4088
Genauigkeit		80,9 %		
Spezifität		85,7 %		

dens im realen System führt zu sehr vielen Schadensmeldungen, obwohl tatsächlich keine Fehler vorliegen. Daher ist es wichtig zu analysieren, in welchen Bereichen des Zyklus es hauptsächlich zu Fehlprädiktionen kommt.

Abbildung 6.14 zeigt exemplarisch die korrekten und falschen Prädiktionen der LR entlang des angepassten WLTP-Zyklus. Allgemein etabliert sich ein Muster, nach dem die Fehlprädiktionen bei fallenden Drehzahlen oder im Stillstand und den damit verbundenen niedrigen Drehmomentanforderungen besonders hoch sind. Zusätzlich kommt es bei besonders hohen Drehmomentänderungen beziehungsweise bei hoher Beschleunigung zu Fehlprädiktionen. Auf die analoge Darstellung zu Abb. 6.14 bei Nutzung des MLP beziehungsweise der SVM wird aus Übersichtsgründen verzichtet und daher auf Anh. D.3 verwiesen. Die Beobachtungen zu den auftretenden Fehlprädiktionen sind dabei ähnlich. Zusätzlich fällt jedoch auf, dass sowohl das MLP als auch die SVM deutlich sensitiver auf hohe Drehzahl- und Drehmomentänderungen reagieren. Hierdurch ergeben sich die im Vergleich zur LR geringe-

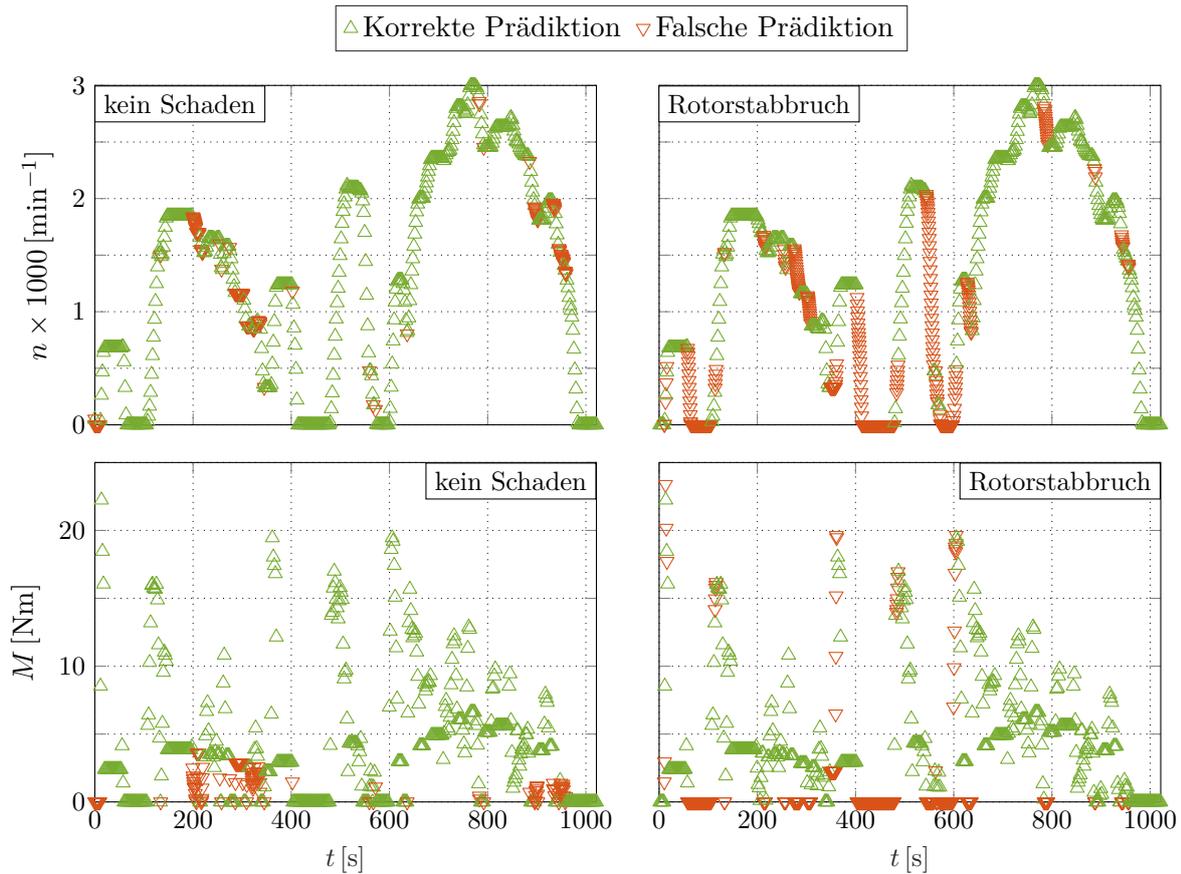


Abbildung 6.14: Validierung der Klassifikation mittels logistischer Regression entlang des angepassten WLTP-Zyklus ohne Aktivierungslogik.

ren Prädiktionsgüten. Anzumerken ist, dass das dynamische Verhalten durch den genutzten Trainingsdatensatz nicht abgedeckt ist. Da das MLP und die SVM im Vergleich zur LR auch in der Lage sind komplexere Strukturen zu interpretieren, kommt es gerade beim Einsatz dieser beiden Klassifikatoren zu derartigen Fehlprädiktionen.

Allgemein liefern alle Klassifikatoren über weite Bereich des Zyklus hohe Prädiktionsgüten. Die Fehlprädiktionen konzentrieren sich auf die besagten Bereiche, weswegen nachfolgend eine geeignete Aktivierungslogik für die Diagnosefunktion abgeleitet wird.

Performanz der Klassifikatoren im dynamischen Betrieb mit Aktivierungslogik

Um die hohe Anzahl an Fehlprädiktionen zu verhindern bietet sich die Entwicklung einer Aktivierungslogik an. Die Anforderungen weisen eine starke Ähnlichkeit zu der in Kap. 4 entwickelten Logik (4.40) auf und stellen daher letztendlich eine Erweiterung dar.

Basierend auf den Erkenntnissen der durchgehend aktiven Fehlerdiagnose werden folgende Bedingungen festgelegt:

- ε_1 : $M \geq M_{th}$

- ε_2 : $n \geq n_{\text{th}}$
- ε_3 : $\frac{dM}{dt} \leq \Delta M_{\text{th}}$
- ε_4 : $\frac{dn}{dt} \leq \Delta n_{\text{th}}$

Die ersten beiden Bedingungen stellen die ausreichende Anregung sicher während die dritte und vierte Bedingung die für die Klassifikation zugelassene Systemdynamik begrenzen. Die Aktivierungslogik für die Fehlerprädiktion ergibt sich aus diesen Bedingungen wie folgt:

$$\varepsilon_{\text{akt}} = \begin{cases} 1 & \text{if } \varepsilon_1 \wedge \varepsilon_2 \wedge \varepsilon_3 \wedge \varepsilon_4 \\ 0 & \text{else} \end{cases} . \quad (6.25)$$

Erwartungsgemäß kommt es durch die Implementierung der Aktivierungslogik zu einer signifikanten Reduzierung der Fehlprädiktionen. Die Prädiktionsgüte erhöht sich bei allen Klassifikatoren deutlich, wie die jeweilige Wahrheitsmatrix in Tab. 6.8 zeigt.

Als Vergleich zur Darstellung der Diagnose mittels LR ohne Aktivierungslogik in Abb. 6.14, zeigt Abb. 6.15 die Ergebnisse bei eingeschränkter Diagnose. Die durch die Aktivierungslogik ausgeschlossenen Betriebspunkte sind darin in schwarz gekennzeichnet. Die übrigen Fehlprädiktionen entstehen primär durch Oszillationen der zur Merkmalsextraktion genutzten Größen bei Lastwechseln, die durch die Aktivierungslogik nicht ausgeschlossen werden. Eine Möglichkeit zur Vermeidung ist die Berücksichtigung einer zusätzlichen Latenz in der Aktivierungslogik. Jedoch führt jede weitere Einschränkung auch zu einer Verringerung der Generalisierbarkeit. Zusätzliche Maßnahmen sind deswegen individuell für den jeweiligen Einsatz abzuwägen.

Bei einer ganzheitlichen Betrachtung der Prädiktionsgüten bestätigt sich nochmals die Sensitivität des MLP und der SVM gegenüber stark dynamischen Betriebspunkten. Durch die eingeschränkte Aktivierung der Diagnose steigt die Prädiktionsgüte deutlich über die der LR. Zwar treten die übrigen Fehlprädiktionen auch hier im Bereich von Lastpunktwechseln auf. Jedoch zeigt sich, dass sowohl durch das MLP als auch die SVM eine breitere Abbildung der Trainingsdaten möglich ist. Die Klassifikation mittels MLP erzielt dabei mit Abstand die beste Prädiktionsgüte.

6.3.6 Zusammenfassung und Ausblick

Tab. 6.9 zeigt einen zusammenfassenden Überblick der Prädiktionsgüten der analysierten Klassifikatoren im dynamischen Betrieb. Bei Nutzung der implementierten Aktivierungslogik liefert besonders die Klassifikation mittels MLP eine signifikant höhere Genauigkeit und Spezifität. Für die Anwendung im Automobilbereich lässt jedoch auch die erreichte Güte des

Tabelle 6.8: Darstellung der Wahrheitsmatrix zur Fehlerdiagnose entlang des angepassten WLTP-Zyklus mit Aktivierungslogik.

Logistische Regression		Prädizierte Klassen		
		Schaden	kein Schaden	Σ
Echte Klassen	Schaden	1104	15	1119
	kein Schaden	47	1072	1119
Σ		1151	1087	2238
Genauigkeit		97,2 %		
Spezifität		95,8 %		

Multi-Layer-Perceptron		Prädizierte Klassen		
		Schaden	kein Schaden	Σ
Echte Klassen	Schaden	1117	2	1119
	kein Schaden	6	1113	1119
Σ		1123	1115	2238
Genauigkeit		99,6 %		
Spezifität		99,5 %		

Support-Vector-Machine		Prädizierte Klassen		
		Schaden	kein Schaden	Σ
Echte Klassen	Schaden	1119	0	1119
	kein Schaden	39	1080	1119
Σ		1158	1080	2238
Genauigkeit		98,3 %		
Spezifität		96,5 %		

Tabelle 6.9: Vergleich der Genauigkeiten und Spezifitäten der verschiedenen Klassifikatoren entlang des angepassten WLTP-Zyklus bei uneingeschränkter Diagnose ($\overline{\text{akt}}$) und Nutzung der Aktivierungslogik (akt).

		Klassifikator					
		LR		MLP		SVM	
		$\overline{\text{akt}}$	akt	$\overline{\text{akt}}$	akt	$\overline{\text{akt}}$	akt
Genauigkeit	[%]	83,9	97,2	82,1	99,6	80,9	98,3
Spezifität	[%]	91,8	95,8	88,2	99,5	85,7	96,5

MLP noch Optimierungsspielraum. Nachfolgend werden daher Anmerkungen zur bestehenden Umsetzung und Maßnahmen zur weiteren Optimierung des vorgeschlagenen Ansatzes geschildert.

Die sich ergebenden Fehlprädiktionen treten auch nach der Implementierung der Aktivierungslogik zu großen Teilen bei Lastabwurf beziehungsweise Entschleunigung der Maschine

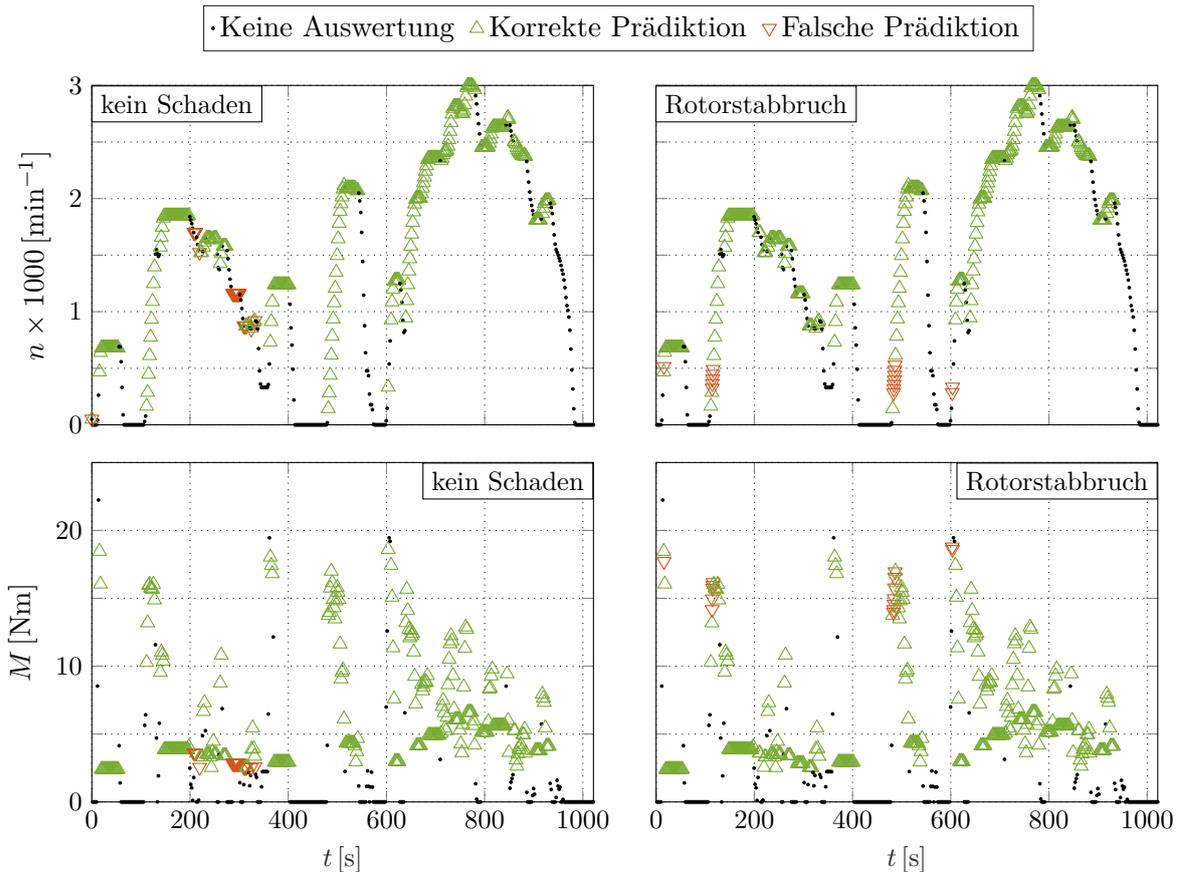


Abbildung 6.15: Validierung der Klassifikation mittels logistischer Regression entlang des angepassten WLTP-Zyklus mit Aktivierungslogik.

auf. An dieser Stelle sei nochmals erwähnt, dass in einem realen Elektrofahrzeug bei nahezu jedem Entschleunigungsvorgang eine Rekuperation der Bremsenergie angestrebt wird. Dadurch ist auch in diesen Betriebspunkten eine Anregung der OPI und der Klassifikation gegeben, die in den Untersuchungen dieser Arbeit nicht berücksichtigt sind.

Der bei der OPI mittels RLS-Algorithmus auftretende Bias wird im Zusammenhang mit einer darauffolgenden Diagnose in bestehenden Arbeiten oft als Nachteil erwähnt, wie zum Beispiel in [152, S.12 ff.]. Bei Nutzung der OPI zur Erzeugung von Klassifikationsmerkmalen und anschließender Klassifikation relativiert sich dieser Nachteil, da das absolute Identifikationsergebnis weniger bis gar nicht relevant ist.

Als Ausblick für weiterführende Arbeiten ergibt sich in Bezug auf den vorgeschlagenen Ansatz in diversen Punkten Optimierungspotential:

- Eine weitere Anpassung der bestehenden oder Erweiterung der genutzten Schwellwerte eignet sich zur Vermeidung von Fehlprädiktionen. Allerdings wird dadurch sowohl die mögliche Diagnosezeit als auch die Generalisierungsfähigkeit maßgeblich verringert.
- Die Berücksichtigung einer Latenz in besonders dynamischen Betriebspunkten vermeidet den Einfluss hoher Oszillationen, ohne den Betriebspunkt von der Diagnose

auszuschließen.

- Grundsätzlich ist zu empfehlen, den Trainingsdatensatz um dynamische Betriebspunkte zu erweitern um im Anschluss auch diese bei der Diagnose zu berücksichtigen. Dadurch erhöht sich gleichzeitig die zeitliche Abdeckung der Diagnose während des Betriebs. Während Voruntersuchungen ergaben sich jedoch durch die Berücksichtigung dynamischer Betriebspunkte keine Verbesserungen. Problematisch ist hierbei, dass eine drastische Vergrößerung des Datensatzes von Nöten ist, um das gesamte dynamische Spektrum abzudecken.
- Eine sehr vielversprechende Option ist die Nutzung erweiterter Metriken zur Auswertung des Gesundheitszustands der Maschine. Hierbei ist beispielsweise der Einsatz einer Mindestprädiktionszahl oder eines generellen Gesundheitsindex denkbar. Dadurch ergibt sich der Vorteil, dass die Auslösung einer Fehlermeldung nicht nur auf einer einzelnen Prädiktion basiert, die möglicherweise fehlerhaft durch einen Lastwechsel ausgelöst wurde.
- Generell ist auch eine Anpassung der Kostenfunktion ein möglicher Ansatz zur Optimierung. Da bei den angewandten Methoden überwachtetes Lernen zum Einsatz kommt, ist eine gezielte Erweiterung der Kostenfunktion möglich. Dadurch lassen sich individuelle Bestrafungsterme für bestimmte Arten von Fehlprädiktionen einführen.

Bei jeder der genannten Maßnahmen ergibt sich automatisch auch eine Individualisierung des Klassifikationsproblems auf den genutzten Trainingsdatensatz. Daher sollte alles Optimierungsschritte stets hinsichtlich ihrer Generalisierbarkeit hinterfragt werden.

Die vorgestellten Ergebnisse bestätigen die Eignung des präsentierten Ansatzes zur Fehlerdiagnose einer ASM am Beispiel des Rotorstabbruchs anhand simulierter Defekte. Grundsätzlich lässt sich das Vorgehen auf andere Fehlerarten ausweiten. Für den Einsatz in realen Fahrzeugen sind umfassende experimentelle Untersuchungen an manipulierten Maschinen von Nöten, die im Rahmen dieser Arbeit nicht umsetzbar sind.

6.4 Datenbasierte Referenzmodellierung zur echtzeitfähigen Residuenanalyse

Eine von der OPI unabhängige Diagnosemöglichkeit besteht in der Nutzung datenbasierter Referenzmodelle zur Anomaliedetektion mit Hilfe der Residuenanalyse. Vorteilhaft hierbei ist der mögliche Einsatz spezifischer Fehlermodelle und die damit verbundene Flexibilität. Für eine zuverlässige Fehlerdetektion ist nach existierenden Ansätzen jedoch eine hohe Modellkomplexität erforderlich, die zwangsläufig zu einem erhöhten Speicherbedarf und Rechenaufwand führt. Für Offline-Anwendungen in festen Wartungsintervallen oder eine aus-

gelagerte Fehlerdiagnose durch die Anwendung eines digitalen Zwillings ergibt sich dadurch ein mächtiger Ansatz, der großes Potential für weiterführende Arbeiten bietet. Zur Online-Anwendung für das in dieser Arbeit gegebene System ist diese Art der spezifischen Fehlerdiagnose aufgrund der vorherrschenden Echtzeitanforderung mit momentanem Hardwarestand nicht umsetzbar. Ansätze zur Online-Diagnose mittels echtzeitfähigen Referenzmodellen zur Residuenanalyse sind dem Autor nach Stand der Technik jedoch nicht bekannt. Eher verbreitet ist der Ansatz in der Regleroptimierung zum Beispiel durch das MRAS oder eine Modellprädiktive-Regelung (MPC). Am häufigsten kommen dabei vereinfachte analytische Referenzmodelle mit linearen Parametern zum Einsatz. Nichtlineare Parameteränderungen werden entweder vernachlässigt oder durch Look-up-Tabellen zur Verfügung gestellt. Die Genauigkeit des Modells hängt somit von der Größe der gespeicherten Tabellen ab, wodurch ein Zielkonflikt zwischen Genauigkeit und Speicherbedarf entsteht. Strukturell auftretende Nichtlinearitäten finden aus Komplexitätsgründen keine Beachtung. Bei der hier betrachteten Anwendung ist gerade die Berücksichtigung der sättigungsbedingten, nichtlinearen Parameteränderungen von Bedeutung. Daher bieten sich als alternativer Ansatz KNN zur Referenzmodellierung an, da sie sich exzellent für die Modellierung nichtlinearer Strukturen eignen. Zusätzlich bilden sie durch den Aufbau der Maschine auftretende Nichtlinearitäten implizit ab. Aufgrund der Echtzeitanforderung besteht auch hier ein Zielkonflikt zwischen der Modellkomplexität und dem auftretenden Speicher- beziehungsweise Berechnungsaufwand. Ein genereller Nachteil neuronaler Netze ist der Verlust der physikalischen Interpretierbarkeit aufgrund der Black-Box-Struktur. Diesem Problem entgegnet der nachfolgend entwickelte Ansatz mit Hilfe eines vorstrukturierten neuronalen Netzes, welches als Grey-Box interpretierbar ist. Grey-Box-Modelle nutzen sowohl theoretisches Wissen über die Struktur des zu identifizierenden Systems als auch experimentell ermittelte Daten für rein datenbasierte Teile des Modells [215].

Das entwickelte Referenzmodell eignet sich sowohl zur Diagnose mittels Residuenanalyse als auch zum Einsatz in etablierten Verfahren wie dem MRAS oder der MPC. Die Inhalte dieses Abschnitts wurden bereits in [20] veröffentlicht.

6.4.1 Vorstrukturiertes Neuronales Netz

In der Regel stellen KNN nach außen eine Black-Box dar. Bedingt durch diese Struktur geht bei der datenbasierten Modellierung physikalischer Systeme mittels KNN die physikalische Interpretierbarkeit verloren. Das finale KNN lässt also keinerlei strukturelle Rückschlüsse auf das modellierte System zu. Ein Vorstrukturiertes-Neuronales-Netz (VNN) ermöglicht die Berücksichtigung von theoretischem a priori Wissen über die physikalische Struktur des zu modellierenden Systems beim Aufbau des neuronalen Netzes. Dabei bleibt automatisch die mathematische Struktur und somit die physikalische Interpretierbarkeit interner Größen als Zustände und Parameter teilweise oder ganz erhalten. Ein weiterer Vorteil in Bezug auf die

Anwendung in dieser Arbeit ist die mögliche Isolierung nichtlinearer Modellkomponenten, wie zum Beispiel der Hauptfeldsättigung im Fall der ASM. Dadurch lässt sich eine gezielte Modellierung dieser Nichtlinearitäten vornehmen.

In englischsprachiger Literatur wird häufig von Physics-Informed-Neural-Networks gesprochen. Hierbei ist jedoch in der Regel das Einbringen von a priori Wissen in die Kostenfunktion zur Optimierung des KNN gemeint. Es handelt sich also um ein grundlegend anderes Vorgehen als nachfolgend angewendet.

Die erste dem Autor bekannte Vorstellung und eine theoretische Darstellung vorstrukturierter neuronaler Netze erfolgte in [216]. Als Beispiel wurde darin das Zeitverhalten eines physikalischen Systems mit Hilfe eines rekurrenten VNN modelliert. Die Konvergenz war jedoch von den initialen Systemzuständen abhängig, weswegen es häufig zu divergentem Modellverhalten kam. Dieses Problem lösten [33, S.177 ff.] durch die Integration des VNN in eine Beobachterstruktur. Eine weitere Anwendung modellierte die Reibkennlinie eines Zweimassensystems durch ein vorstrukturiertes *General-Dynamic-Neural-Network* [217, S.222 ff.]. Darin entstand der wesentliche Aufwand durch die Diskretisierung des zugrundeliegenden Differentialgleichungsmodells und die Integration des diskreten Signalfussplans in die Struktur des VNN.

In dieser Arbeit ist die quasi-stationäre Modellierung des Sättigungsverhaltens der Hauptinduktivität der ASM von primärer Bedeutung. Des Weiteren gilt auch hier eine strenge Echtzeitanforderung. Das zeitvariante Verhalten der Maschine wird daher zunächst nicht betrachtet und der Fokus liegt hauptsächlich auf einer möglichst speicher- und rechenzeitoptimierten Implementierung. Es sei darauf hingewiesen, dass die Umsetzung durch Nutzung rekurrenter Pfade im VNN analog zu [217, S.222 ff.] grundsätzlich auch bei der Modellierung der ASM möglich ist.

Implementierung eines vorstrukturierten neuronalen Netzes zur Modellierung des stationären Sättigungsverhaltens einer Asynchronmaschine

Der strukturelle Aufbau des VNN erfolgt basierend auf dem Grundwellenmodell der ASM (2.92). Da in diesem Fall zunächst das stationäre Verhalten von Bedeutung ist, bietet sich die Nutzung von Gleichgrößen zum Training des Modells an. Diese sind in Form der rotorflussorientierten Zustandsgrößen des Regelsystems im d/q-KOS ohnehin vorhanden. Außerdem zeigt sich das Training vorwärtsgerichteter neuronaler Netze ohne rekurrente Pfade mit oszillierenden Zustandsgrößen im α/β -KOS als herausfordernd.

Das Grundwellenmodell lässt sich durch die Park-Transformation (2.95) mit dem Rotorflusswinkel in das rotorflussorientierte d/q-KOS transformieren. Das hochgestellte K repräsentiert nachfolgend die Rotation mit der Winkelgeschwindigkeit ω_K . Die einfachste mathematische Beschreibung des Flussverhaltens der Maschine besteht in der transformierten Statorglei-

chung:

$$\mathbf{u}_s^K = R_s \mathbf{i}_s^K + j\omega_K \Psi_s^K + \underbrace{\frac{d}{dt} \Psi_s^K}_{=0, \text{ wenn } \frac{d}{dt}=0}. \quad (6.26)$$

Durch die Betrachtung stationärer Betriebspunkte entfällt hier der differentielle Flussterm. Das betriebspunktabhängige und nichtlineare Sättigungsverhalten der Maschine wird somit ausschließlich vom Statorfluss Ψ_s^K repräsentiert. Die übrigen Zustandsgrößen stehen als Messgrößen zur Verfügung und sind für das überwachte Lernen der Modellparameter nutzbar. Für die Sättigung der Hauptinduktivität ist die flussbildende Stromkomponente i_d verantwortlich, während die Streufeldsättigung durch beide Stromkomponenten beeinflusst wird, siehe Abb. 2.6. Die Induktionsspannung und der Schlupf haben ebenfalls Auswirkungen auf das Flussverhalten der ASM. Dieses Verhalten wird durch die bekannten Winkelgeschwindigkeiten von Stator ω_s und Rotor ω_m zusätzlich repräsentiert. Die nichtlineare Funktion des Statorflusses Ψ_s^K lässt sich demnach wie folgt formulieren:

$$\Psi_s^K = f(\mathbf{i}_s^K, \omega_s, \omega_m). \quad (6.27)$$

Da das betrachtete Modell lediglich Statorgrößen enthält wird nachfolgend auf die Notation im Index verzichtet. Die vollständige Darstellung des genutzten Sättigungsmodells ergibt sich durch die Aufteilung in d- und q-Komponenten:

$$\begin{bmatrix} u^d \\ u^q \end{bmatrix} = R_s \begin{bmatrix} i^d \\ i^q \end{bmatrix} + j\omega_K \begin{bmatrix} \Psi^d \\ \Psi^q \end{bmatrix}, \quad (6.28)$$

$$\begin{bmatrix} \Psi^d \\ \Psi^q \end{bmatrix} = \begin{bmatrix} f(i^d, i^q, \omega_K, \omega_m) \\ f(i^d, i^q, \omega_K, \omega_m) \end{bmatrix}. \quad (6.29)$$

Die Struktur des gesamten VNN entsteht nun in Anlehnung an die lineare algebraische Form des Flussmodells. Diese lässt sich mit Hilfe einzelner Neuronen in ein neuronales Netz überführen. Den nichtlinearen Statorfluss bildet ein integriertes MLP als Teil des VNN ab. Die allgemeine Form eines Neurons ist durch folgende Gleichung definiert [210]:

$$y = f_a(x_1, x_2, \dots, x_N) = s \left(\sum_{i=1}^N x_i \cdot w_i + b \right). \quad (6.30)$$

Additive Terme lassen sich durch die Nutzung von (6.30) implementieren. Die Anzahl der zu addierenden Terme entspricht dabei den Eingängen des Neurons. Bei Festlegung aller Gewichte zu $w_i = 1$ und des Bias zu $b = 0$ erfolgt die Addition durch Nutzung einer linearen Aktivierungsfunktion. Zur Implementierung von Multiplikationen ist eine triviale Anpassung

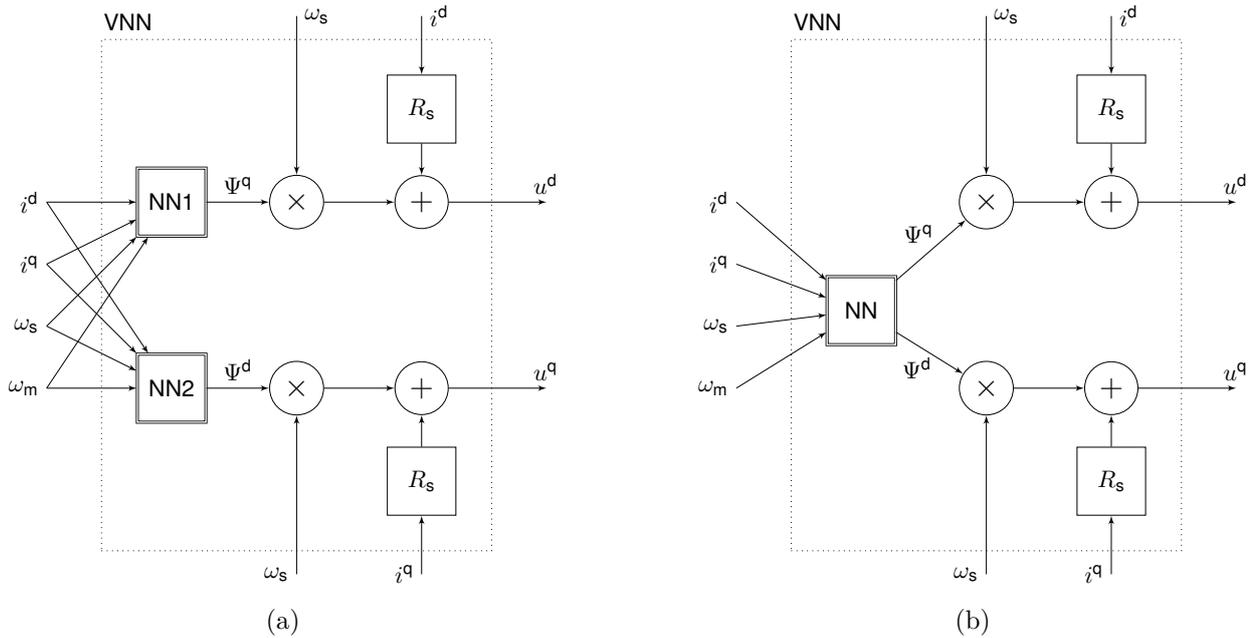


Abbildung 6.16: (a) Vorstrukturiertes neuronales Netz mit einzeln integrierten neuronalen Netzen. (b) Vorstrukturiertes neuronales Netz mit kombiniertem integrierten neuronalen Netz.[20]

von (6.30) erforderlich:

$$y = f_m(x_1, x_2, \dots, x_n) = s \left(\prod_{i=1}^n x_i \cdot w_i - b \right). \quad (6.31)$$

Dieses angepasste Neuron dient lediglich der Implementierung der algebraischen Form des physikalischen Modells. Die betroffenen Gewichte dieser Neuronen sind analog zur additiven Anwendung festgelegt und werden während des Trainings nicht angepasst.

Im nächsten Schritt wird die Struktur des VNN aus der Modellgleichung (6.28) abgeleitet. Aufgrund des bekannten qualitativen Verlaufs der Sättigungskurve ist davon auszugehen, dass dieser durch ein kleines MLP abbildbar ist. Durch die d und q Komponenten der Zustandsgrößen (6.28) ergeben sich grundsätzlich zwei Möglichkeiten zur Überführung der Modellgleichung in ein VNN. Die mathematisch intuitivste Variante ist die Darstellung von Ψ^d und Ψ^q analog zur Modellgleichung als separate Modellpfade, wie in Abb. 6.16(a) dargestellt. Eine weitere Möglichkeit ist die kombinierte Modellierung beider Pfade in einem integrierten neuronalen Netz mit jeweils einem Ausgang für Ψ^d und Ψ^q , siehe Abb. 6.16(b). Die integrierten neuronalen Netze bilden die Funktion (6.29) ab. Die Implementierung der additiven und multiplikativen Terme erfolgt mittels (6.30) und (6.31). Der Statorwiderstand R_s wird jeweils als zu trainierendes Gewicht in die Struktur des VNN integriert. In Bezug auf die speicher- und rechenzeitoptimierte Implementierung ist die einzelne Modellierung der Pfade (vgl. Abb. 6.16a) nachteilhaft, da die Anzahl der zu speichernden Hyperparameter und die Berechnungszeit tendenziell steigt. Während Voruntersuchungen zeigte sich außerdem, dass

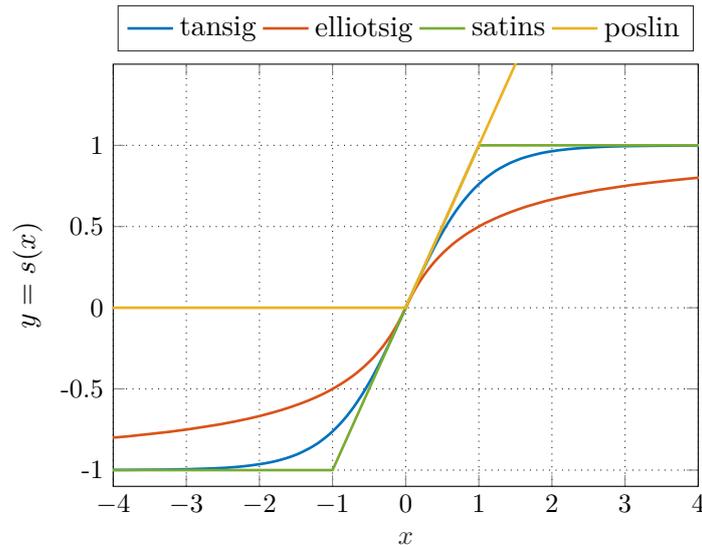


Abbildung 6.17: Übersicht der genutzten Aktivierungsfunktionen zum Training der VNN.[20]

sich durch die höhere Modelltiefe bei Trennung der d- und q-Komponenten keine besseren Resultate ergeben. Die Konfiguration in Abb. 6.16(a) wird daher nicht weiter verfolgt und für einen Vergleich auf [20] verwiesen.

Zur Modellierung des nichtlinearen Flussverlaufs dient ein MLP mit zwei verdeckten Schichten, da diese Konfiguration anhand heuristischer Analysen die besten Ergebnisse lieferte, vgl. Abb. 6.11(a). Die Aktivierungsfunktionen der verdeckten Schichten haben sowohl auf die Qualität der Ergebnisse als auch auf die Berechnungszeit des zu implementierenden VNN einen signifikanten Einfluss. Einen Überblick über in der Praxis angewendete Aktivierungsfunktionen gibt [211]. In kleinen neuronalen Netzen werden in der Regel Sigmoidalfunktionen genutzt um nichtlineare Zusammenhänge besser abbilden zu können. Die am häufigsten genutzte Aktivierungsfunktion ist der Tangens hyperbolicus:

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 = \frac{e^{-2x} - 1}{e^{-2x} + 1}. \quad (6.32)$$

Für die Echtzeitberechnung von (6.32) ist jedoch eine Taylor-Approximation erforderlich, die zu einer vergleichsweise hohen Berechnungszeit führt. Als gängige Alternative hat sich daher die Funktion

$$\text{elliot sig}(x) = \frac{x}{1 + |x|} \quad (6.33)$$

etabliert, die bei vergleichsweise geringer Berechnungszeit einen sehr ähnlichen monotonen Verlauf aufweist, wie Abb. 6.17 zeigt. Alternativ werden stückweise lineare Aktivierungsfunktionen vorsätzlich in tiefen rekurrenten oder gefalteten neuronalen Netzen genutzt. Diese führen zu einer deutlichen Komplexitätsreduktion und einer geringeren Berechnungszeit [211], [212]. Die Eignung dieser Art von Funktionen als Alternative zu Sigmoidalfunktionen

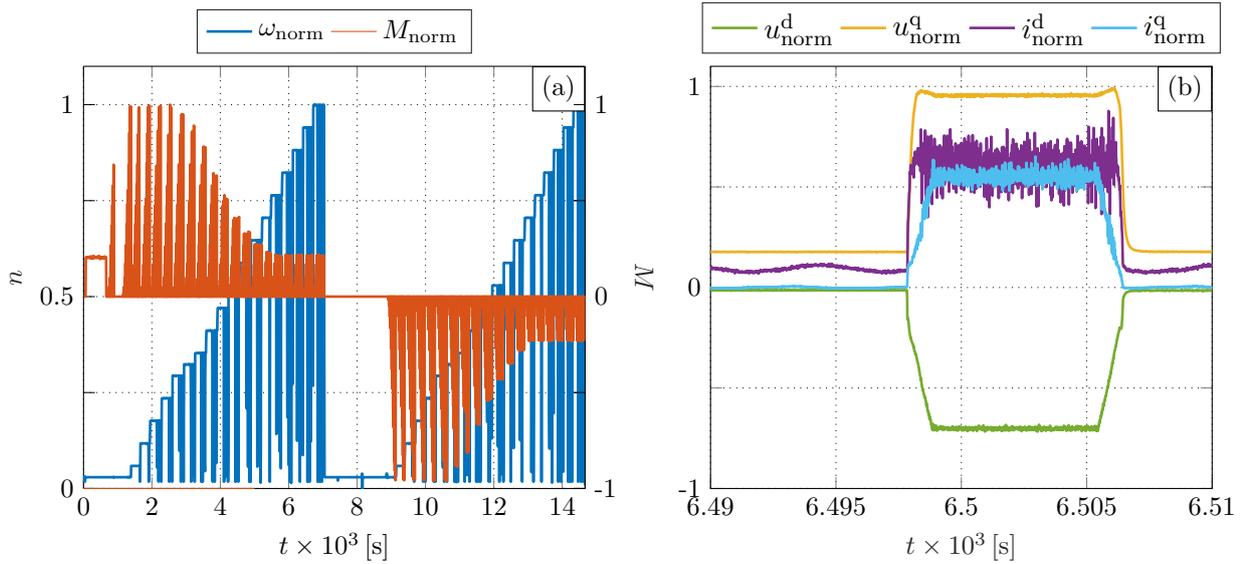


Abbildung 6.18: Übersicht des normierten Trainingsdatensatzes. (a) Darstellung der Drehzahl und Drehmomentbetriebspunkte. (b) Exemplarischer Ausschnitt der Spannungs- und Stromkomponenten in einem Betriebspunkt.[20]

wird nachfolgend exemplarisch anhand von

$$\text{satlins}(x) = \begin{cases} -1 & \text{if } x < -1, \\ x & \text{if } -1 \leq x \leq 1, \\ 1 & \text{if } x > 1 \end{cases} \quad (6.34)$$

und

$$\text{poslin}(x) = \max(0, x) \quad (6.35)$$

analysiert, vgl. Abb. 6.17.

Grundsätzlich sind die Anzahl der Neuronen und die genutzten Aktivierungsfunktionen in den integrierten MLP frei wählbar. Bezüglich der Echtzeitanforderung ist jedoch der Zielkonflikt zwischen Genauigkeit und Speicher- sowie Rechenaufwand bestmöglich zu bedienen.

6.4.2 Trainingsprozess und Strukturoptimierung

Zur Strukturoptimierung stellt der folgende Abschnitt die Performanz verschiedener Konfigurationen des integrierten neuronalen Netzes gegenüber. Da das Training des VNN offline stattfindet, ist die benötigte Rechenkapazität zur Optimierung der Modellparameter irrelevant. Aufgrund der höheren Genauigkeit für kleine neuronale Netze und der vergleichsweise schnellen Konvergenz ist die Nutzung eines Optimierungsverfahrens zweiter Ordnung vorteilhaft. Das Training erfolgt daher durch Anwendung des Levenberg-Marquart-Algorithmus [218], [219]. Als Kostenfunktion sind der mittlere quadratische Fehler sowie die Kreuzen-

tropie am weitesten verbreitet [210]. Aufgrund der einfachen Struktur des trainierten VNN stellt sich die Nutzung des mittleren quadratischen Fehlers als am geeignetsten heraus:

$$l = \frac{1}{N} \sum_{i=1}^N \|\hat{y}_{i,vnn} - y_{i,vnn}\|^2. \quad (6.36)$$

Da der Verlauf des Trainings maßgeblich von der Initialisierung der Gewichte abhängt, ist es sinnvoll, das Training je Konfiguration mit zufällig gewählten Initialwerten fünfmal zu wiederholen. Für die Dauer des Trainings ist, basierend auf heuristischen Versuchen, eine maximale Anzahl von 500 Epochen festgelegt, da ein längeres Training keine relevante Verbesserung erbringt. Um ein Overfitting des Modells zu vermeiden, wird der Early Stopping Ansatz verwendet. Demnach bricht das Training ab, wenn sich die Validierungskosten sechs Epochen in Folge nicht ändern [210].

Trainingsdatensatz

Das trainierte Modell soll das Sättigungsverhalten der Maschine im stationären Zustand im gesamten Betriebsbereich der Maschine darstellen. Der verwendete Trainingsdatensatz muss daher genügend Trainingspunkte enthalten, um das Flussverhalten in jedem Betriebspunkt zu repräsentieren. Als Trainingsdatensatz dient daher ein charakteristischer Messdatensatz einer realen Fahrzeugmaschine, siehe Abb. 6.18. Die Maschine wird bei konstanten Drehzahlen durch Drehmomentschritte mit einer Dauer von $t = 8$ s im gesamten Betriebsbereich belastet. Im Vergleich zum in Abs. 6.3 verwendeten Zyklus ist sowohl der Drehzahl- als auch der Lastbereich der hier verwendeten Maschine deutlich größer. Abbildung 6.18(b) zeigt exemplarisch die vom Stromregler ausgegebenen Spannungswerte u^d und u^a sowie die zugehörigen Stromkomponenten i^d und i^a . Zum Training des stationären Modells dienen ausschließlich die jeweiligen Ausschnitte bei eingeschwungenem Systemzustand. Da die Aufzeichnungen der Messdaten von einem prototypischen Aufbau stammen, sind die Stromregler nicht vollständig appliziert. Dadurch weisen die Stromverläufe deutliche Oberschwingungen auf, weswegen eine zusätzliche Filterung der Messdaten mittels einer gleitenden Mittelwertbildung erfolgt. Zuletzt wird eine Aufteilung des Datensatzes in Trainings- (70%), Validierungs- (15%) und Testdaten (15%) vorgenommen.

Da der Datensatz bereits in der verwendeten Form besteht, ist die Anzahl der Trainingspunkte sehr hoch. Die Größe ist daher für zukünftige spezifische Anwendungen drastisch reduzierbar. Für industrielle Anwendungen ist diese Maßnahme ohnehin zwingend notwendig.

Strukturoptimierung

Eine Erhöhung der Genauigkeit oder Verringerung der Berechnungszeit ist hauptsächlich durch eine Modifikation der Netzstruktur oder der Aktivierungsfunktion möglich. Die Aus-

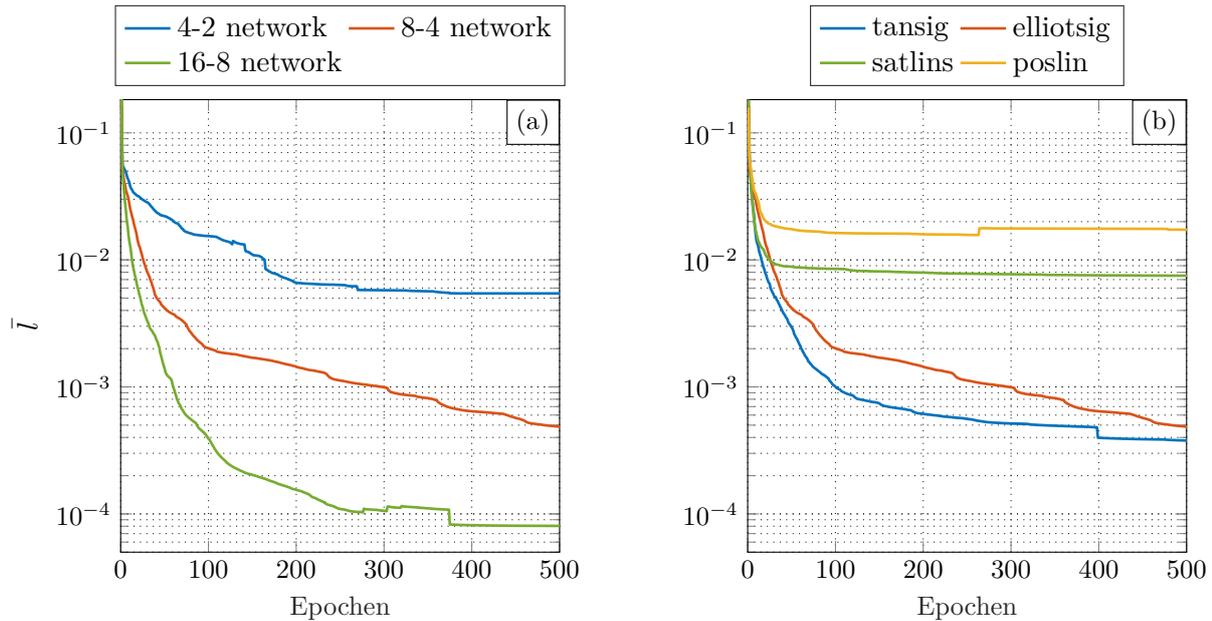


Abbildung 6.19: Übersicht des Trainingsverlaufs bei Anwendung verschiedener Neuronenanzahl und Aktivierungsfunktionen anhand des Kostenverlaufs. (a) Vergleich der Trainingskosten verschiedener Netzwerke bei Nutzung der Aktivierungsfunktion elliotstig. (b) Vergleich der Trainingskosten verschiedener Aktivierungsfunktionen bei Nutzung des 8-4-Netzwerks.[20]

gangsstruktur der verwendeten Netzstruktur basiert auf strategischen Überlegungen nach Regeln der guten Praxis und heuristischen Analysen. Aufgrund des Verhältnisses von Eingängen zu Ausgängen bietet sich die Nutzung eines zweischichtigen Netzes an. Zur Verbreiterung der Eingabeschicht werden die vier Eingänge durch die doppelte Anzahl an Neuronen auf die erste Schicht des Netzes abgebildet $H_1 = 8$. Zur Projektion auf die zweite verdeckte Schicht erfolgt eine Reduzierung der Neuronenanzahl um den Faktor zwei auf $H_2 = 4$.

Ausgehend von der zuvor beschriebenen Ausgangsstruktur wird im ersten Schritt der Einfluss der Neuronenanzahl auf die Performanz des Modells untersucht. Dazu erfolgt eine Verdopplung und Halbierung der Neuronenanzahl in beiden Schichten unter exemplarischer Nutzung der Aktivierungsfunktion elliotstig. Die zugehörigen Verläufe der Trainingskosten sind in Abb. 6.19(a) dargestellt. Als statistische Vergleichsgrößen dienen der Mittelwert \bar{l}_5 und die mittlere Varianz $\bar{\sigma}_5$ der Kosten sowie die durchschnittlich benötigten Trainingsepochen $\bar{n}_{tr,5}$ aller fünf Trainingsläufe, siehe Tab. 6.10. Repräsentativ für den Speicher- und Rechenaufwand steht die Anzahl der zu trainierenden Gewichte n_w .

Erwartungsgemäß zeigt das 16-8-Netzwerk die besten Ergebnisse, vgl. Tab. 6.10. Während die Varianz und der Mittelwert des 8-4-Netzwerks zwar schlechter sind aber noch in der selben Größenordnung liegen, schneidet das 4-2-Netzwerk bereits deutlich schlechter ab. Diese Beobachtung verdeutlicht die Darstellung der Kostenverläufe in Abb. 6.19(a). Mit dem 4-2-Netzwerk ist das Sättigungsverhalten für die angestrebte Anwendung nicht ausreichend genau abbildbar. Ein Vergleich der genutzten Gewichte in Tab. 6.10 verdeutlicht den nichtlinearen Anstieg des Speicheraufwands mit steigender Neuronenanzahl, der zwangsläufig auch

zu einer höheren Berechnungszeit führt. Bezüglich des Zielkonflikts zwischen Genauigkeit und Speicher- bzw. Rechenaufwand ergibt sich das 8-4-Netzwerk als bester Kompromiss der hier betrachteten Strukturen.

Ein weitere Untersuchung analysiert den Einfluss der genutzten Aktivierungsfunktion im integrierten neuronalen Netz auf die Performanz des VNN. Basierend auf den zuvor gewonnen Erkenntnissen dient dabei das 8-4-Netzwerk als Grundlage. Die Trainingsverläufe bei Nutzung der vier Aktivierungsfunktionen (6.32), (6.33), (6.34) und (6.35) illustriert Abb. 6.19(b). Die zugehörigen statistischen Auswertungen sind in Tab. 6.11 dargestellt. Offensichtlich zeigen die beiden Sigmoidalfunktionen weitaus überzeugendere Trainingsergebnisse. Bei Nutzung der stückweise linearen Aktivierungsfunktionen ist bereits bei deutlich unter 100 Trainingsepochen keine signifikante Verbesserung mehr zu verzeichnen. Zur Abbildung nichtlinearer Zusammenhänge mit Hilfe dieser Funktionen (6.34) und (6.35) sind tiefere Netzstrukturen von Nöten, die aus Gründen des Speicheraufwands im hier betrachteten Anwendungsgebiet nicht in Frage kommen. Die auftretende Varianz der Kosten bei Nutzung stückweise linearer Aktivierungsfunktionen ist beträchtlich höher und stellt somit die Eindeutigkeit der Lösung in Frage. Beim Vergleich der beiden Sigmoidalfunktionen bestätigt sich die Eignung von (6.33) als Alternative zur rechenaufwändigeren tangentialen Aktivierungsfunktion (6.32). Die Performanz zu Ende des Trainings sowie die statistischen Vergleichsgrößen sind nahezu identisch und im Vergleich zur Nutzung der stückweise linearen Aktivierungsfunktionen signifikant geringer.

Um einen Überblick der tatsächlich erforderlichen Rechenzeiten zu erlangen, werden alle zuvor analysierten VNN-Konfigurationen auf dem in Kap. 3 beschriebenen Echtzeitsystem implementiert und mit gleichen Eingangsgrößen betrieben. Durch Ausführung des Echtzeitcodes in verschiedenen Tasks lassen sich die jeweils benötigten Rechenzeiten beobachten, siehe Tab. 6.12. Neben dem offensichtlichen Anstieg der Rechenzeit mit der Größe des Netzes ist auch der Einfluss der genutzten Aktivierungsfunktion sichtbar. Die Ersatzfunktion *elliotsig* erfordert lediglich einen marginal höheren Rechenaufwand als die stückweise linearen Aktivierungsfunktionen. Daneben führt die Nutzung von *tansig* zu einer circa fünfmal so hohen Rechenzeit im Vergleich zu *elliotsig*. Es bestätigt sich also auch auf diesem Wege, dass in der Nutzung von *elliotsig* ein guter Kompromiss zur Bedienung des vorhandenen Zielkonflikts besteht.

6.4.3 Zusammenfassung und Ausblick

Die Validierung des trainierten Modells entlang eines realen Fahrprofils ist basierend auf den zur Verfügung stehenden Daten nicht möglich. Auch die Generierung zusätzlicher Daten beziehungsweise die Validierung im realen Antriebssystem ist aufgrund fehlender Prüfstandskapazitäten zum jetzigen Zeitpunkt ausgeschlossen.

Primärer Einsatzzweck des entwickelten Ansatzes ist die Nutzung als Referenzmodell bei

Tabelle 6.10: Vergleich der Trainingsergebnisse bei unterschiedlicher Anzahl von Neuronen in den verdeckten Schichten mit der Aktivierungsfunktion *elliotsig*.

$H_1 - H_2$	\bar{l}_5	$\bar{\sigma}_5$	$\bar{n}_{\text{tr},5}$	n_w
16 - 8	7,5e-5	1,0e-9	353	234
8 - 4	4,6e-4	5,8e-8	500	86
4 - 2	10,0e-3	4,5e-5	217	36

Tabelle 6.11: Vergleich der Trainingsergebnisse bei Nutzung unterschiedlicher Aktivierungsfunktionen im 8-4-Netzwerk.

$s(y)$	\bar{l}_5	$\bar{\sigma}_5$	$\bar{n}_{\text{tr},5}$
tansig	4,2e-4	5,3e-8	479
elliotsig	4,6e-4	5,8e-8	500
satlins	7,5e-3	5,7e-6	500
poslin	20,0e-3	9,3e-5	448

Tabelle 6.12: Vergleich der Rechenzeit aller im Echtzeitsystem implementierten Konfigurationen bei Nutzung unterschiedlicher Aktivierungsfunktionen und Netzwerkstrukturen.

	t_c [s]			
	tansig	elliotsig	satlins	poslin
16 - 8	5,68e-6	1,64e-6	1,20e-6	1,24e-6
8 - 4	2,46e-6	6,00e-7	4,80e-7	4,40e-7
4 - 2	1,28e-6	2,40e-7	2,00e-7	2,00e-7

der Residuenanalyse. Konkret ist damit die Prädiktion der erforderlichen Spannungswerte u^d, u^q für einen bestimmten Last- beziehungsweise Strombetriebspunkt i^d, i^q im gesunden Maschinenzustand möglich. Durch den Vergleich mit den tatsächlich vom Regler berechneten Spannungswerten lassen sich mit Hilfe der Residuenanalyse Änderungen im System durch beispielsweise voranschreitende Alterung oder auftretende Maschinendefekte detektieren. Diese Diagnosefunktion ist sowohl im Online-Betrieb als auch beispielsweise zur End-of-Line Prüfung einsetzbar.

Zusätzlich bietet sich das entwickelte Modell als Alternative zur herkömmlichen Speicherung von Flusskennfeldern als Look-up-Tabellen an. Bei hohen Genauigkeitsanforderungen müssen im Vergleich zu einer hohen Anzahl an zu speichernden Stützwerten lediglich wenige Gewichte des VNN gespeichert werden. Des Weiteren ist zur Berechnung von Zwischenwerten keine Interpolation notwendig. Implizit ergibt sich auch eine Einsatzmöglichkeit zur datenbasierten, modellprädiktiven Regelung.

Der vorgestellte Modellansatz weist jedoch in der hier dargestellten Form auch nicht berücksichtigte Aspekte auf:

- Bei den zum Training genutzten Spannungswerten handelt es sich um vom Stromregler gestellte Sollwerte. Der durch den Umrichter auftretende Spannungsverlust ist daher nicht explizit berücksichtigt.
- Da der Statorwiderstand als Gewicht in das Modell integriert ist, ist dessen temperaturbedingte Änderung nicht explizit modelliert.

- Die Modellierung des Flussverhaltens erfolgt als in sich geschlossener nichtlinearer Teil des Modells. Eine explizite Abbildung von Haupt- und Streufluss der Maschine erfolgt daher ebenfalls nicht.

Die genannten Effekte werden implizit durch das integrierte neuronale Netz abgebildet. Neben den zuvor genannten Erweiterungsmöglichkeiten ist in weiterführenden Arbeiten ebenfalls eine Berücksichtigung dynamischer Betriebspunkte durch rekurrente Modellpfade denkbar. Dadurch entstehende Vorteile müssen gegenüber der zwangsläufigen Komplexitätssteigerung abgewägt werden. Besteht in der Zukunft eine Möglichkeit zur Validierung in einem realen Antriebssystem, ist zusätzlich ein Vergleich mit anderen Klassifikatoren zur Abbildung des nichtlinearen Flussverhaltens sinnvoll.

7 Fazit und Ausblick

Übergeordnetes Ziel dieser Arbeit ist die Entwicklung echtzeitfähiger parameterbasierter Diagnosekonzepte für den Einsatz in einem dynamischen automotiven Betriebsumfeld. Bezugnehmend auf dieses formulierte Ziel ergeben sich im wesentlichen die beiden zu Beginn der Arbeit formulierten Forschungsfragen. Abschließend beantwortet dieses Kapitel die Fragestellungen durch eine Zusammenfassung der erzielten Ergebnisse und gibt einen Ausblick für zukünftige aufbauende Forschungsvorhaben.

1. Forschungsfrage

Eignen sich etablierte echtzeitfähige Verfahren zur Online-Parameteridentifikation von Asynchronmaschinen für den Einsatz in einem dynamischen automotiven Betriebsumfeld, beziehungsweise welche Modifikationen sind für eine überzeugende Performanz erforderlich?

Bezüglich der ersten Forschungsfrage stellt diese Arbeit den RLS-Algorithmus und erweiterte KF als die beiden nach Stand der Technik etabliertesten Ansätze zur OPI im betrachteten Umfeld gegenüber. Neben theoretischen Betrachtungen zur Konditionierung präsentieren Kap. 4 und 5 dazu detaillierte simulative und experimentelle Untersuchungen verschiedener Konfigurationen.

Die Eignung des RLS-Algorithmus zur robusten OPI veränderlicher Parameter bei dynamischen Betrieb bestätigt sich anhand der durchgeführten Analysen. Die Modifikation des Algorithmus hin zu variablen Vergessensfaktoren ist dabei essenziell, wobei mehrfache variable Vergessensfaktoren die Flexibilität deutlich erhöhen. Die Nutzung dynamischer Modelle ist im hier betrachteten Umfeld unabdingbar. Außerdem erweist sich die Berücksichtigung der veränderlichen Eisenverluste und des Spannungsfehlers je nach betrachtetem Betriebspunkt als signifikant. Die gleichzeitige Identifikation aller ESB-Parameter ist aufgrund der geringen Sensitivitäten des Statorwiderstands R_s und der Streuinduktivität L_σ sowie der daraus resultierenden geringen SNR gerade im realen Antriebssystem nicht möglich. Als größte Herausforderung offenbart sich, gerade im realen Antriebssystem, die geeignete Parametrisierung der Hyperparameter in Form der Vergessensfaktoren und der Parameter des SG-Filters. Allgemein überzeugt der RLS-Algorithmus durch sein robustes Verhalten sowie die vergleichsweise geringen Identifikationsfehler.

Der simulative Vergleich von EKF und UKF bestätigt die grundsätzliche Eignung erweiterter KF zur OPI der ASM in einem dynamischen Betriebsumfeld. Bei Nutzung des UKF erweisen sich das träge Konvergenzverhalten sowie der höhere Fehler in Verbindung mit dem zusätzlichen Parametrisierungs- und Rechenaufwand im Vergleich zum EKF als nachteilhaft. Diese Erkenntnisse bestätigen sich bei der Anwendung im realen System. Bei der OPI mittels EKF zeigt sich allgemein ein Vorteil durch die Anwendung der optimierten Struktur der Identifikationsparameter. Auch hier ist jedoch keine vollständige Identifikation aller ESB-Parameter möglich. Gerade bei experimentellen Untersuchungen offenbaren sich Divergenzprobleme im Zusammenhang mit der Streuinduktivität L_σ , weswegen die Vorgabe dieses Parameters zwingend erforderlich ist. Allgemein hängen die erreichten Genauigkeiten sowie das Konvergenzverhalten in erheblichem Maße von der Initialisierung der Kovarianzmatrizen und der Zustandsgrößen ab. Bereits kleine Anpassungen können dabei zur Divergenz des Algorithmus führen. Zusätzlich zeigt sich eine starke Sensitivität des Fehlers gegenüber dem Betriebspunkt der Maschine, was in Bezug auf das dynamische Betriebsumfeld problematisch ist. Allgemein sind die Robustheit und die erreichten Genauigkeiten im Vergleich zum RLS-Algorithmus als niedriger einzustufen.

Im Kollektiv zeigen sich bei der Parametrierung der Algorithmen eklatante Unterschiede zwischen den simulativ und experimentell optimierten Hyperparametern, was vor allem durch das Rauschverhalten des Aufbaus zu erklären ist. Eine Optimierung der Eigenschaften im Feld durch Nutzung des Simulationsmodells erweist sich daher als nicht sinnvoll. An dieser Stelle sei erwähnt, dass das signifikant bessere Rauschverhalten im realen Fahrzeug eine zuverlässigere OPI begünstigt, da die EMV des Systems deutlich besser abgestimmt ist. Ein wesentlicher Faktor ist dabei die nahe Platzierung der Leistungselektronik an den Maschinenklemmen. Das Problem der fortlaufenden Anregung erweist sich am Prüfstand bei dynamischem Betriebsverlauf als weniger problematisch. Allgemein ist dennoch eine abgestimmte Aktivierungslogik erforderlich, um zuverlässige Ergebnisse zu gewährleisten. Auf Basis der durchgeführten Untersuchungen stellt sich der RLS-Algorithmus bezüglich der spezifischen Anforderungen dieser Arbeit als bessere Alternative heraus. Zusätzlich überzeugt dieser durch die Vorteile bei der Echtzeitimplementierung und der geringeren Rechenzeit. Die durchgeführten Untersuchungen zeigen, dass sich etablierte echtzeitfähige Verfahren zur OPI grundsätzlich für den Einsatz in einem dynamischen automotiven Umfeld eignen. Gerade im Fall des RLS-Algorithmus sind dazu jedoch Modifikationen durch mehrfache Vergessensfaktoren notwendig. Allgemein offenbaren sich die Wahl der Hyperparameter sowie die Initialisierung als größte Herausforderungen. Für zuverlässige Ergebnisse ist die fortlaufende Anregung durch eine betriebspunktabhängige Aktivierungslogik sicherzustellen.

2. Forschungsfrage

Welche Konzepte zur echtzeitfähigen Diagnose elektrischer Fahrzeugantriebe in einem dynamischen Betriebsumfeld ergeben sich basierend auf modifizierten Ansätzen zur Online-Zustands- und Parameteridentifikation?

In Bezug auf die zweite Forschungsfrage ergeben sich in dieser Arbeit verschiedene Diagnosekonzepte. Neben den gewöhnlichen Ansätzen zur OPI in Kap. 4 und 5 eignet sich auch die in Abs. 6.2 vorgeschlagene Online-Identifikation der Parameterabweichungen. Die erwünschten Vorteile hinsichtlich der Identifikation nichtlinearer Parameteränderungen bleiben dabei jedoch aus. Außerdem erweist sich die dadurch entstehende Verringerung des SNR in experimentellen Versuchen als nachteilhaft. Auch das vergleichsweise langsame Konvergenzverhalten ist problematisch. Hinsichtlich einer Diagnose gilt daher abzuwägen, ob der modifizierte Ansatz vorteilhaft ist. Bei beiden Ansätzen hängt die Zuverlässigkeit ohnehin von der gewählten Metrik zur Prädiktion ab.

Der in Abs. 1.1 entwickelte Ansatz zur parameterbasierten Fehlerklassifizierung stellt sich als sehr vielversprechender Ansatz heraus. Die hohen Genauigkeiten und Spezifitäten durch die Klassifikation mittels MLP sind im Hinblick auf den Einsatz im realen Fahrzeug jedoch kritisch zu hinterfragen. Neben der genauen, systemspezifischen Applikation ist außerdem die Validierung basierend auf realen Fehlerdaten unabdingbar. Eine weitere Steigerung der Zuverlässigkeit ist durch die Anwendung realer Fehlerdaten für den Trainingsprozess zu erwarten.

Abschnitt 6.4 entwickelt ein vereinfachtes datenbasiertes Modell des Flussverhaltens der ASM. Durch die Nutzung eines vorstrukturierten MLP lässt sich der nichtlineare Teil der Statorflussgleichung durch eine Black-Box abbilden, während die physikalische Struktur des Maschinenmodells erhalten bleibt. Eine Optimierung der Struktur des VNN bedient den Zielkonflikt zwischen Genauigkeit und Rechen- sowie Speicheraufwand. Eingesetzt zur Residuenanalyse stellt dieses Modell ein einfaches Werkzeug zur Überprüfung des gestellten Spannungssollwerts dar. Durch Erweiterung des VNN um rekurrente Pfade ist potenziell eine Modellierung des dynamischen Flussverhaltens denkbar.

Zur echtzeitfähigen Diagnose elektrischer Fahrzeugantriebe im betrachteten Betriebsumfeld ergeben sich verschiedene Diagnosekonzepte. Die Ergebnisse der OPI sind im einfachsten Fall direkt zur Anomalidetektion geeignet. Des weiteren erweist sich die Nutzung der OPI-Ergebnisse zur Merkmalsextraktion zur Fehlerklassifikation als vielversprechendes Diagnosekonzept. Unabhängig von der OPI bietet sich eine Residuenanalyse basierend auf einfach datenbasierten Referenzmodellen als ergänzendes Konzept an.

Ausblick

Die vorgestellten Konzepte lassen sich grundsätzlich durch Anpassung der Modelle auf andere Fehlerarten und anderen Typen elektrischer Maschinen übertragen. Aufgrund der lückenhaften Datenlage bezüglich auftretender Fehler in Automobilen mit elektrischen Antrieben bleibt abzuwarten, auf welcher Art von Anomalien der Fokus zukünftig liegen sollte. Aus diesem Grund ist auch weiterhin zu hinterfragen, ob eine explizite Online-Fehlerdiagnose notwendig oder eine allgemeine Abbildung des Maschinenzustands zielführender ist. Alleine wegen der stets auftretenden Unsicherheiten bei prädizierten Anomalien ist eine parallele Nutzung mehrerer Diagnoseansätze mit anschließender Bündelung in einer Metrik zur Beschreibung des momentanen Maschinenzustands zu empfehlen. Diese Metrik kann zum Beispiel durch empirische Gleichungen oder einen weiteren Klassifikator abgebildet werden. Wichtig im Hinblick auf den Nutzen ist letztendlich die Vermeidung von Fehlprädiktionen und die Maximierung der Zuverlässigkeit. Mögliche Anwendung findet eine hochentwickelte Metrik zur Einleitung außerplanmäßiger Wartungen bei Auffälligkeiten während des Betriebs. Dies ermöglicht wiederum eine gezielte Durchführung fehlerspezifischer Diagnoseroutinen, bei denen die Echtzeitfähigkeit irrelevant ist. Die Erforschung geeigneter Metriken bietet daher großes Potenzial für nachfolgende Projekte und stellt bei Nutzung in realen Fahrzeugen einen klaren Mehrwert in Aussicht.

A Testumgebung

A.1 Fahrzeugparameter

Zur Berechnung einer realistischen Drehmomentanforderung im Betriebsbereich der genutzten Testmaschine werden die spezifischen Fahrzeugdaten eines Kleinstfahrzeugs herangezogen, siehe Tab. A.1. Aus diesen Daten lässt sich die benötigte Zugkraft und damit die betriebspunktabhängige Drehmomentanforderung zur Durchföhrung des WLTP-Zyklus bestimmen.

Tabelle A.1: Angenommene Fahrzeugparameter eines Kleinstfahrzeugs in Anlehnung an die Daten des Renault Twizy (Technische Daten des Renault Twizy).

Parameter	Formelzeichen	Wert
Masse	m	487 kg
Getriebeübersetzung	i_G	6,03
Stirnfläche	A_F	1,69 m ²
Luftwiderstandsbeiwert	c_W	0,24
Luftdichte	ρ_l	1,2 $\frac{\text{kg}}{\text{m}^3}$
Rollwiderstandsbeiwert	f_r	0,008

A.2 Datenbasierte Modellierung der Leistungselektronik

Zur Kompensation des durch die Leistungselektronik eingepprägten Spannungsfehlers schlagen Wiedemann et al. in den Arbeiten [77], [78] ein Verfahren zur Selbstkommissionierung und anschließenden Modellierung des Spannungsfehlers durch ein einfaches neuronales Netz vor. Das darin trainierte und implementierte datenbasierte Modell bildet die Abhängigkeit des Spannungsfehlers von der Taktfrequenz der PWM-Pulse f_{pwm} jedoch nicht ab. Da die in der vorliegenden Arbeit entwickelten OPI-Algorithmen perspektivisch in einem System mit veränderlich PWM-Frequenz eingesetzt werden, erfolgt hier eine zusätzliche Berücksichtigung des Momentanwertes von f_{pwm} . Durch die mehrfache Ausführung des in [77] beschriebenen Kommissionierungslaufs entsteht ein erweiterter Trainingsdatensatz des Spannungsfehlers

Δu_{err} bei unterschiedlichen PWM-Frequenzen

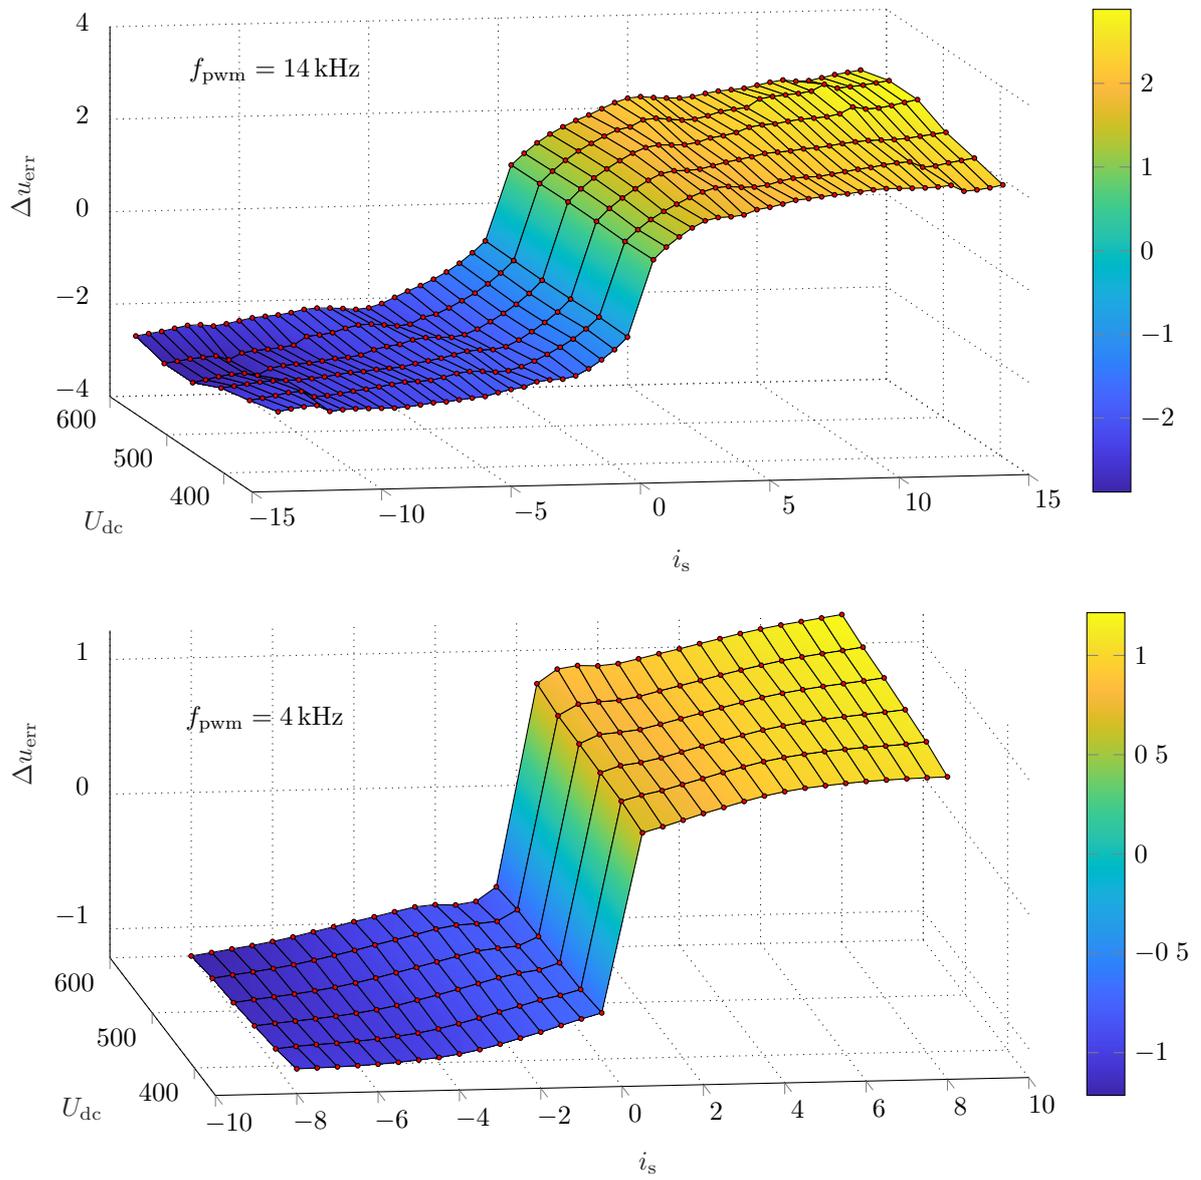
$$f_{\text{pwm}} = [4 \ 6 \ 8 \ 10 \ 12 \ 14] \text{ kHz}$$

und Zwischenkreisspannungen

$$U_{\text{dc}} = [350 \ 400 \ 450 \ 500 \ 550 \ 600] \text{ V}$$

in Abhängig des Strombetriebspunkts. Exemplarisch zeigt Abb. A.1 den entstehenden Spannungsfehler bei variabler Zwischenkreisspannung und zwei unterschiedlichen PWM-Frequenzen. Umgekehrt illustriert Abb. A.2 die Abhängigkeit des Spannungsfehlers bei variabler PWM-Frequenz und konstanter Zwischenkreisspannung.

Die Messreihen dienen im weiteren Verlauf als Trainingsdatensatz für ein kleines neuronales Netz zur echtzeitfähigen Korrektur des vom Regler gestellten Spannungswert in Abhängigkeit des Stroms, der Zwischenkreisspannung und der PWM-Frequenz.



(t!)

Abbildung A.1: Durch die Leistungselektronik verursachter Spannungsfehler bei variabler Zwischenkreisspannung U_{dc} und konstanter PWM-Frequenz f_{pwm} .

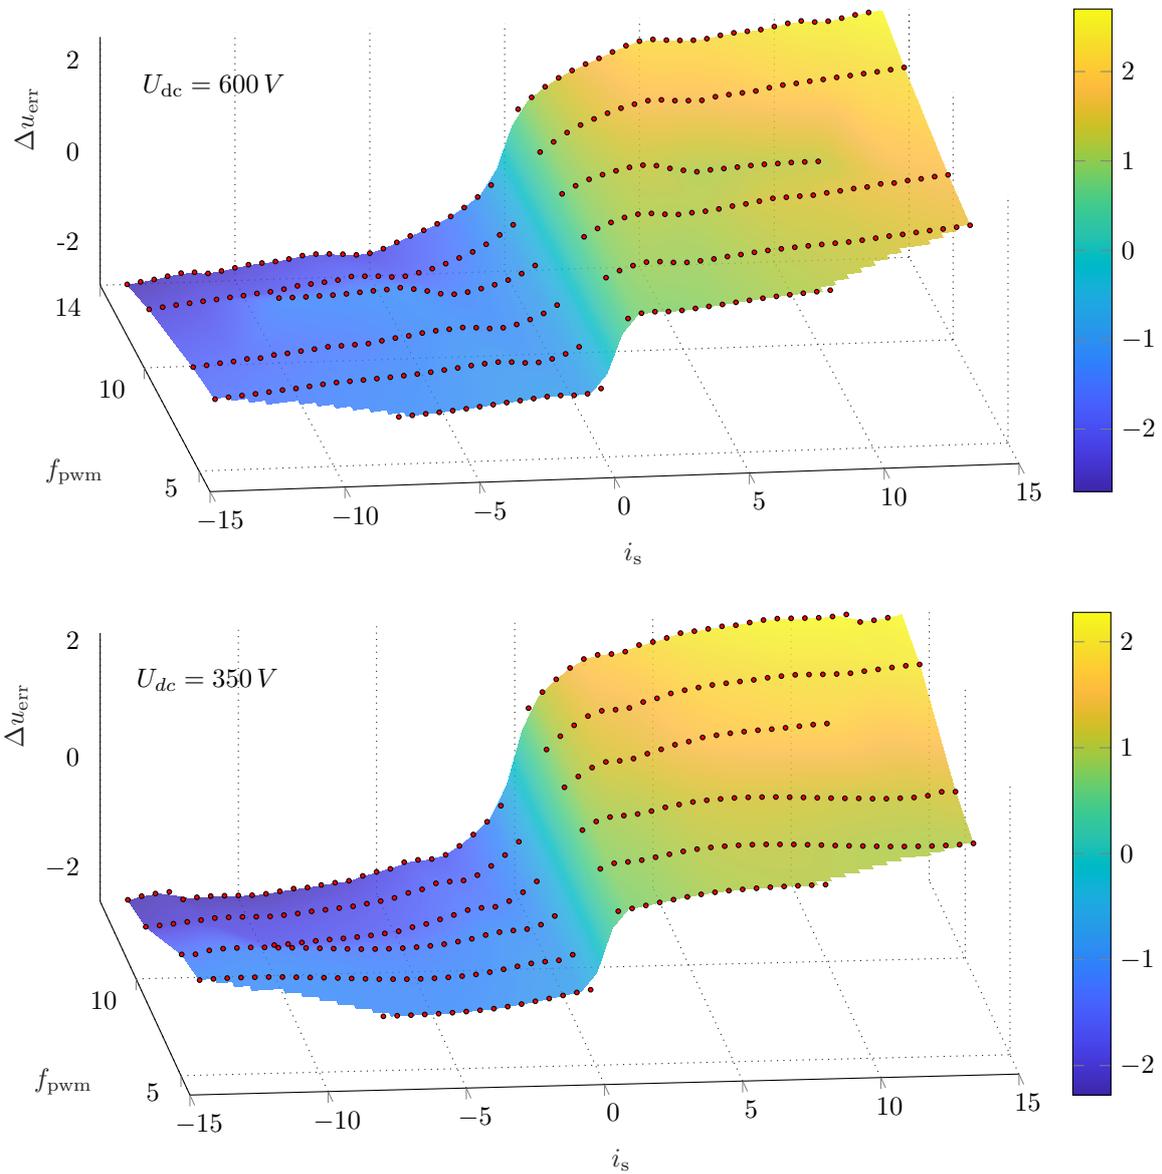


Abbildung A.2: Durch die Leistungselektronik verursachter Spannungsfehler bei variabler PWM-Frequenz f_{pwm} und konstanter Zwischenkreisspannung U_{dc} .

B Online-Parameteridentifikation mittels RLS Algorithmus

B.1 Identifikationsmodelle

Stationäres Modell mit Eisenverlusten

Spannungs- und Flussgleichungen:

$$\mathbf{u}_s^S = R_s \cdot \mathbf{i}_s^S + \frac{d}{dt} \Psi_s^S \quad (\text{B.1})$$

$$\mathbf{u}_r^S = R_r \cdot \mathbf{i}_r^S + \frac{d}{dt} \Psi_r^S - \mathbf{J} n_p \omega_m \Psi_r^S \quad (\text{B.2})$$

$$\Psi_s^S = (L_m + L_\sigma) \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} (\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S) \right) + L_M \cdot \mathbf{i}_r^S \quad (\text{B.3})$$

$$\Psi_r^S = L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} (\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S) \right) + L_m \cdot \mathbf{i}_r^S \quad (\text{B.4})$$

Differentiation der Rotorflussgleichung (B.4) nach der Zeit:

$$\frac{d}{dt} \Psi_r^S = L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) + L_m \cdot \frac{d}{dt} \mathbf{i}_r^S \quad (\text{B.5})$$

Einsetzen von (B.4) und (B.5) in (B.2):

$$\begin{aligned} 0 &= R_r \cdot \mathbf{i}_r^S + L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) + L_m \cdot \frac{d}{dt} \mathbf{i}_r^S \\ &\quad - \mathbf{J} n_p \omega_m \left(L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} (\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S) \right) + L_m \cdot \mathbf{i}_r^S \right) \end{aligned} \quad (\text{B.6})$$

Gleichung (B.6) differenzieren:

$$\begin{aligned}
0 &= R_r \cdot \frac{d}{dt} \mathbf{i}_r^S + L_m \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{u}_s^S - R_s \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \right) \right) + L_m \cdot \frac{d^2}{dt^2} \mathbf{i}_r^S \\
&\quad - \mathbf{J} n_p \frac{d}{dt} \omega_m \left(L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S \right) \right) + L_m \cdot \mathbf{i}_r^S \right) \\
&\quad - \mathbf{J} n_p \omega_m \left(L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) + L_m \cdot \frac{d}{dt} \mathbf{i}_r^S \right)
\end{aligned} \tag{B.7}$$

Bedingung stationäres Modell $\frac{d}{dt} \omega_m = 0$:

$$\begin{aligned}
0 &= R_r \cdot \frac{d}{dt} \mathbf{i}_r^S + L_m \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{u}_s^S - R_s \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \right) \right) + L_m \cdot \frac{d^2}{dt^2} \mathbf{i}_r^S \\
&\quad - \mathbf{J} n_p \omega_m \left(L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) + L_m \cdot \frac{d}{dt} \mathbf{i}_r^S \right)
\end{aligned} \tag{B.8}$$

Gleichung (B.1) umstellen und differenzieren:

$$\frac{d}{dt} \Psi_s^S = \mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S \tag{B.9}$$

$$\frac{d^2}{dt^2} \Psi_s^S = \frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \tag{B.10}$$

Gleichung (B.3) umstellen und differenzieren:

$$\mathbf{i}_r^S = \frac{1}{L_m} \left(\Psi_s^S - (L_m + L_\sigma) \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S \right) \right) \right) \tag{B.11}$$

$$\frac{d}{dt} \mathbf{i}_r^S = \frac{1}{L_m} \left(\frac{d}{dt} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) \right) \tag{B.12}$$

$$\frac{d^2}{dt^2} \mathbf{i}_r^S = \frac{1}{L_m} \left(\frac{d^2}{dt^2} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{u}_s^S - R_s \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \right) \right) \right) \tag{B.13}$$

Gleichungen (B.9) und (B.10) in Gleichung (B.12)/(B.13) einsetzen:

$$\frac{d}{dt} \mathbf{i}_r^S = \frac{1}{L_m} \left(\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) \right) \tag{B.14}$$

$$\frac{d^2}{dt^2} \mathbf{i}_r^S = \frac{1}{L_m} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S - (L_m + L_\sigma) \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{u}_s^S - R_s \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \right) \right) \right) \tag{B.15}$$

Gleichungen (B.14) und (B.15) in Gleichung (B.8) einsetzen:

$$\begin{aligned}
0 = & R_r \cdot \left(\frac{1}{L_m} \left(\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) \right) \right) \\
& + L_m \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{u}_s^S - R_s \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \right) \right) \\
& + L_m \cdot \left(\frac{1}{L_m} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S - (L_m + L_\sigma) \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{u}_s^S - R_s \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \right) \right) \right) \right) \\
& - \mathbf{J} n_p \omega_m \left(L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) \right) \\
& + L_m \cdot \left(\frac{1}{L_m} \left(\mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \left(\frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \right) \right) \right) \right) \Big) \Big)
\end{aligned} \tag{B.16}$$

Gleichung (B.16) ausmultiplizieren und sortieren:

$$\begin{aligned}
-\frac{d}{dt} \mathbf{u}_s^S + \mathbf{J} n_p \omega_m \mathbf{u}_s^S = & \frac{R_r}{L_m} \cdot \mathbf{u}_s^S - \frac{R_r}{L_m} R_s \cdot \mathbf{i}_s^S - \frac{R_r}{L_m} (L_m + L_\sigma) \cdot \frac{d}{dt} \mathbf{i}_s^S \\
& + \frac{R_r}{L_m R_{fe}} (L_m + L_\sigma) \cdot \frac{d}{dt} \mathbf{u}_s^S - \frac{R_r R_s}{L_m R_{fe}} (L_m + L_\sigma) \cdot \frac{d}{dt} \mathbf{i}_s^S \\
& - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S - L_\sigma \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S + \frac{L_\sigma}{R_{fe}} \cdot \frac{d^2}{dt^2} \mathbf{u}_s^S - L_\sigma \frac{R_s}{R_{fe}} \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \\
& + R_s \cdot \mathbf{J} n_p \omega_m \mathbf{i}_s^S + L_\sigma \cdot \mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{i}_s^S \\
& - \frac{L_\sigma}{R_{fe}} \cdot \mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{u}_s^S + L_\sigma \frac{R_s}{R_{fe}} \cdot \mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{i}_s^S
\end{aligned} \tag{B.17}$$

Darstellung in Vektoren und Substitution von $L_\sigma + L_m = L_s$:

$$\frac{d}{dt} \mathbf{u}_s^S - \mathbf{J} n_p \omega_m \cdot \mathbf{u}_s^S = \begin{bmatrix} \frac{d^2}{dt^2} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \cdot \frac{d}{dt} \mathbf{i}_s^S \\ \frac{d}{dt} \mathbf{i}_s^S \\ -\mathbf{u}_s^S \\ \frac{d}{dt} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \cdot \mathbf{i}_s^S \\ \mathbf{i}_s^S \\ -\frac{d}{dt} \mathbf{u}_s^S \\ \frac{d}{dt} \mathbf{i}_s^S \\ \mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{u}_s^S - \frac{d^2}{dt^2} \mathbf{u}_s^S \\ \frac{d^2}{dt^2} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{i}_s^S \end{bmatrix}^\top \begin{bmatrix} L_\sigma \\ \frac{R_r}{L_m} L_s \\ \frac{R_r}{L_m} \\ R_s \\ \frac{R_r}{L_m} R_s \\ \frac{R_r}{L_m R_{fe}} L_s \\ \frac{R_r R_s}{L_m R_{fe}} L_s \\ \frac{L_\sigma}{R_{fe}} \\ L_\sigma \frac{R_s}{R_{fe}} \end{bmatrix} \tag{B.18}$$

Durch die Vorgabe von R_{fe} ergibt sich:

$$\frac{d}{dt} \mathbf{u}_s^S - \mathbf{J} n_p \omega_m \cdot \mathbf{u}_s^S = \begin{bmatrix} \frac{d^2}{dt^2} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \cdot \frac{d}{dt} \mathbf{i}_s^S + \frac{1}{R_{fe}} \left(\mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{u}_s^S - \frac{d^2}{dt^2} \mathbf{u}_s^S \right) \\ \frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \cdot \frac{d}{dt} \mathbf{u}_s^S \\ -\mathbf{u}_s^S \\ \frac{d}{dt} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \cdot \mathbf{i}_s^S \\ \mathbf{i}_s^S \\ \frac{1}{R_{fe}} \cdot \frac{d}{dt} \mathbf{i}_s^S \\ \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{i}_s^S \right) \end{bmatrix}^\top \begin{bmatrix} L_\sigma \\ \frac{R_r}{L_m} L_s \\ \frac{R_r}{L_m} \\ R_s \\ \frac{R_r}{L_m} R_s \\ \frac{R_r R_s}{L_m} L_s \\ L_\sigma R_s \end{bmatrix} \quad (\text{B.19})$$

Reduzierte Darstellung mit Nebenbedingungen:

$$y = \frac{d}{dt} \mathbf{u}_s^S - \mathbf{J} n_p \omega_m \cdot \mathbf{u}_s^S - \theta_4 \left(\theta_3 \cdot \mathbf{i}_s^S + \theta_2 \cdot \frac{1}{R_{fe}} \cdot \frac{d}{dt} \mathbf{i}_s^S + \theta_1 \cdot \frac{1}{R_{fe}} \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{i}_s^S \right) \right)$$

$$\Phi = \begin{bmatrix} \frac{d^2}{dt^2} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \cdot \frac{d}{dt} \mathbf{i}_s^S + \frac{1}{R_{fe}} \left(\mathbf{J} n_p \omega_m \frac{d}{dt} \mathbf{u}_s^S - \frac{d^2}{dt^2} \mathbf{u}_s^S \right) \\ \frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \cdot \frac{d}{dt} \mathbf{u}_s^S \\ -\mathbf{u}_s^S \\ \frac{d}{dt} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \cdot \mathbf{i}_s^S \end{bmatrix}$$

$$\theta = \begin{bmatrix} L_\sigma \\ \frac{R_r}{L_m} L_s \\ \frac{R_r}{L_m} \\ R_s \end{bmatrix} \quad (\text{B.20})$$

Dynamisches Modell mit Eisenverlusten

Umstellen und differenzieren von Gleichung (B.1):

$$\frac{d}{dt} \Psi_s^S = \mathbf{u}_s^S - R_s \cdot \mathbf{i}_s^S \quad (\text{B.21})$$

$$\frac{d^2}{dt^2} \Psi_s^S = \frac{d}{dt} \mathbf{u}_s^S - R_s \cdot \frac{d}{dt} \mathbf{i}_s^S \quad (\text{B.22})$$

$$\frac{d^3}{dt^3} \Psi_s^S = \frac{d^2}{dt^2} \mathbf{u}_s^S - R_s \cdot \frac{d^2}{dt^2} \mathbf{i}_s^S \quad (\text{B.23})$$

Gleichung (B.21) bis (B.23) in Gleichung (B.7) einsetzen:

$$\begin{aligned}
0 &= R_r \cdot \frac{d}{dt} \mathbf{i}_r^S + L_m \cdot \left(\frac{d^2}{dt^2} \Psi_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) + L_m \cdot \frac{d^2}{dt^2} \mathbf{i}_r^S \\
&\quad - \mathbf{J} n_p \frac{d}{dt} \omega_m \left(L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + L_m \cdot \mathbf{i}_r^S \right) \\
&\quad - \mathbf{J} n_p \omega_m \left(L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) + L_m \cdot \frac{d}{dt} \mathbf{i}_r^S \right)
\end{aligned} \tag{B.24}$$

Gleichung (B.21) in Gleichung (B.3) einsetzen und differenzieren:

$$\mathbf{i}_r^S = \frac{1}{L_m} \left(\Psi_s^S - (L_m + L_\sigma) \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) \right) \tag{B.25}$$

$$\frac{d}{dt} \mathbf{i}_r^S = \frac{1}{L_m} \left(\frac{d}{dt} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \right) \tag{B.26}$$

$$\frac{d^2}{dt^2} \mathbf{i}_r^S = \frac{1}{L_m} \left(\frac{d^2}{dt^2} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) \right) \tag{B.27}$$

Gleichungen (B.25) bis (B.27) in Gleichung (B.24) einsetzen:

$$\begin{aligned}
0 &= R_r \left(\frac{1}{L_m} \left(\frac{d}{dt} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \right) \right) \\
&\quad + L_m \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) \\
&\quad + L_m \cdot \left(\frac{1}{L_m} \left(\frac{d^2}{dt^2} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d^2}{dt^2} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^3}{dt^3} \Psi_s^S \right) \right) \right) \\
&\quad - \mathbf{J} n_p \frac{d}{dt} \omega_m \left(L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + L_m \cdot \left(\frac{1}{L_m} \left(\Psi_s^S - (L_m + L_\sigma) \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) \right) \right) \right) \\
&\quad - \mathbf{J} n_p \omega_m \left(L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \right) \\
&\quad + L_m \cdot \left(\frac{1}{L_m} \left(\frac{d}{dt} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \right) \right)
\end{aligned} \tag{B.28}$$

Gleichung (B.28) sortieren und Gleichung (B.21) einsetzen:

$$\begin{aligned}
\frac{d^2}{dt^2} \Psi_s^S - \mathbf{J}n_p \frac{d}{dt} \omega_m \cdot \Psi_s^S - \mathbf{J}n_p \omega_m \cdot \frac{d}{dt} \Psi_s^S &= -\frac{R_r}{L_m} \mathbf{u}_s^S + \frac{R_r}{L_m} R_s \cdot i_s^S \\
&+ \frac{R_r}{L_m} L_s \cdot \left(\frac{d}{dt} i_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) \\
&+ L_\sigma \cdot \left(+ \frac{d^2}{dt^2} i_s^S - \mathbf{J}n_p \frac{d}{dt} \omega_m \cdot i_s^S - \mathbf{J}n_p \omega_m \cdot \frac{d}{dt} i_s^S \right) \\
&+ L_\sigma \cdot \left(\frac{1}{R_{fe}} \left(- \frac{d^3}{dt^3} \Psi_s^S + \mathbf{J}n_p \frac{d}{dt} \omega_m \frac{d}{dt} \Psi_s^S + \mathbf{J}n_p \omega_m \frac{d^2}{dt^2} \Psi_s^S \right) \right)
\end{aligned} \tag{B.29}$$

Gleichung (B.29) sortieren:

$$\begin{aligned}
y &= \frac{d^2}{dt^2} \Psi_s^S - \mathbf{J}n_p \omega_m \frac{d}{dt} \Psi_s^S - \mathbf{J}n_p \frac{d}{dt} \omega_m \Psi_s^S \\
\Phi &= \begin{bmatrix} -\mathbf{u}_s^S \\ i_s^S \\ \frac{d}{dt} i_s^S \\ \frac{d^2}{dt^2} i_s^S - \mathbf{J}n_p \frac{d}{dt} \omega_m i_s^S - \mathbf{J}n_p \omega_m \frac{d}{dt} i_s^S \\ -\frac{d^3}{dt^3} \Psi_s^S + \mathbf{J}n_p \omega_m \frac{d^2}{dt^2} \Psi_s^S + \mathbf{J}n_p \frac{d}{dt} \omega_m \frac{d}{dt} \Psi_s^S \\ \frac{d^2}{dt^2} \Psi_s^S \end{bmatrix} \\
\theta &= \begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} R_s \\ \frac{R_r}{L_m} L_s \\ L_\sigma \\ \frac{L_\sigma}{R_{fe}} \\ \frac{R_r}{L_m R_{fe}} L_s \end{bmatrix}
\end{aligned} \tag{B.30}$$

R_{fe} vorgeben:

$$\begin{aligned}
 y &= \frac{d^2}{dt^2} \Psi_s^S - \mathbf{J}n_p \omega_m \frac{d}{dt} \Psi_s^S - \mathbf{J}n_p \frac{d}{dt} \omega_m \Psi_s^S \\
 \Phi &= \begin{bmatrix} -\mathbf{u}_s^S \\ \mathbf{i}_s^S \\ \frac{d}{dt} \mathbf{i}_s^S + \frac{1}{R_{fe}} \cdot \frac{d^2}{dt^2} \Psi_s^S \\ \frac{d^2}{dt^2} \mathbf{i}_s^S - \mathbf{J}n_p \frac{d}{dt} \omega_m \mathbf{i}_s^S - \mathbf{J}n_p \omega_m \frac{d}{dt} \mathbf{i}_s^S + \frac{1}{R_{fe}} \left(-\frac{d^3}{dt^3} \Psi_s^S + \mathbf{J}n_p \omega_m \frac{d^2}{dt^2} \Psi_s^S + \mathbf{J}n_p \frac{d}{dt} \omega_m \frac{d}{dt} \Psi_s^S \right) \end{bmatrix} \\
 \theta &= \begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} R_s \\ \frac{R_r}{L_m} L_s \\ L_\sigma \end{bmatrix}
 \end{aligned} \tag{B.31}$$

Dynamisches Modell mit Eisenverlusten und bekanntem R_s

Beginn der Herleitung mit Gleichung (B.6):

$$0 = R_r \cdot \mathbf{i}_r^S + L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) + L_m \cdot \frac{d}{dt} \mathbf{i}_r^S - \mathbf{J} n_p \omega_m (L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + L_m \cdot \mathbf{i}_r^S) \quad (\text{B.32})$$

Gleichung (B.25) und (B.26) in (B.32) einsetzen und vereinfachen:

$$0 = \frac{R_r}{L_m} \Psi_s^S - \frac{R_r}{L_m} (L_m + L_\sigma) \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + L_m \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) + \frac{d}{dt} \Psi_s^S - (L_m + L_\sigma) \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) - \mathbf{J} n_p \omega_m (L_m \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + \Psi_s^S - (L_m + L_\sigma) \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right)) \quad (\text{B.33})$$

Weiter vereinfachen:

$$0 = \frac{R_r}{L_m} \Psi_s^S - \frac{R_r}{L_m} (L_m + L_\sigma) \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right) + \frac{d}{dt} \Psi_s^S - L_\sigma \cdot \left(\frac{d}{dt} \mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d^2}{dt^2} \Psi_s^S \right) - \mathbf{J} n_p \omega_m (\Psi_s^S - L_\sigma \cdot \left(\mathbf{i}_s^S - \frac{1}{R_{fe}} \frac{d}{dt} \Psi_s^S \right)) \quad (\text{B.34})$$

Sortieren und durch Vektoren ausdrücken - Substitution von $L_\sigma + L_m = L_s$:

$$y = \frac{d}{dt} \Psi_s^S - \mathbf{J} n_p \omega_m \Psi_s^S$$

$$\Phi = \begin{bmatrix} -\Psi_s^S \\ \Psi_s^S \\ -\frac{d^2}{dt^2} \Psi_s^S \\ \frac{d}{dt} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \mathbf{i}_s^S \\ -\frac{d^2}{dt^2} \Psi_s^S + \mathbf{J} n_p \omega_m \frac{d}{dt} \Psi_s^S \end{bmatrix} \quad (\text{B.35})$$

$$\theta = \begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} L_s \\ \frac{R_r}{L_m \cdot R_{fe}} L_s \\ L_\sigma \\ \frac{L_\sigma}{R_{fe}} \end{bmatrix}$$

R_{fe} vorgeben:

$$\begin{aligned}
 y &= \frac{d}{dt} \Psi_s^S - \mathbf{J} n_p \omega_m \Psi_s^S \\
 \Phi &= \begin{bmatrix} -\Psi_s^S \\ \mathbf{i}_s^S - \frac{1}{R_{fe}} \cdot \frac{d^2}{dt^2} \Psi_s^S \\ \frac{d}{dt} \mathbf{i}_s^S - \mathbf{J} n_p \omega_m \mathbf{i}_s^S + \frac{1}{R_{fe}} \cdot \left(-\frac{d^2}{dt^2} \Psi_s^S + \mathbf{J} n_p \omega_m \frac{d}{dt} \Psi_s^S \right) \end{bmatrix} \\
 \theta &= \begin{bmatrix} \frac{R_r}{L_m} \\ \frac{R_r}{L_m} L_s \\ L_\sigma \end{bmatrix}
 \end{aligned} \tag{B.36}$$

B.2 Konfigurationen RLS-Algorithmus Simulative und Experimentelle Analysen

Tabelle B.1: Konfiguration Simulation stat Abb. 4.7.

Modell	Stationär
Parameter	T_r, R_s, L_s, σ
Algorithmus	RLS einf. Vergessen
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ	0,999
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.2: Konfiguration Simulation stat w. R_s Abb. 4.7.

Modell	Stationär
Parameter	T_r, L_s, σ
Algorithmus	RLS einf. Vergessen
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ	0,999
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.3: Konfiguration Simulation dyn Abb. 4.7.

Modell	Dynamisch
Parameter	T_r, R_s, L_s, σ
Algorithmus	RLS einf. Vergessen
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ	0,999
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.4: Konfiguration Simulation dyn w. R_s Abb. 4.7.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS einf. Vergessen
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ	0,999
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.5: Konfiguration Simulation Eisenverluste Abb. 4.8.

Modell	Dynamisch mit/ohne R_{fe}
Parameter	T_r, L_s, σ
Algorithmus	RLS einf. Vergessen
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ	0,999
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.6: Konfiguration Simulation Vergleich erweiterter RLS-Algorithmen Abb. 4.9.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS einf. Vergessen
Variables Verg.	inaktiv
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ	0,99
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.7: Konfiguration Simulation Vergleich erweiterter RLS-Algorithmen Abb. 4.9.

Modell	Dynamisch mit/ohne R_{fe}
Parameter	T_r, L_s, σ
Algorithmus	RLS einf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ_0	0,98
tr (P_{max})	10
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.8: Konfiguration Simulation Vergleich erweiterter RLS-Algorithmen Abb. 4.9.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS Kovarianz man.
Variables Verg.	inaktiv
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
λ	0,999
$\epsilon_1 / \epsilon_2 / \beta$	0,1 / 0,011 / 0,5
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.9: Konfiguration Simulation Vergleich erweiterter RLS-Algorithmen Abb. 4.9.

Modell	Dynamisch mit/ohne R_{fe}
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	inaktiv
Initialisierung θ_0	0
Initialisierung P_0	$10^3 \cdot I$
Λ	[0,95 1 0,9]
Sample Time t_s	10^{-5} s
Fensterlänge k_f	201
Update-Rate n_{id}	1

Tabelle B.10: Konfiguration Simulation Vergleich Modelle WLTP-Zyklus Abb. 4.10.

Modell	Stationär
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{ref}^2)$
Λ_0	[0,99 1 0,97]
tr (P_{max})	[0,01 0,05 0,005]
Sample Time t_s	10^{-5} s
Fensterlänge k_f	81
Update-Rate n_{id}	1

Tabelle B.11: Konfiguration Simulation Vergleich Modelle WLTP-Zyklus Abb. 4.10.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,95 \quad 1 \quad 0,9]$
$\text{tr}(P_{\text{max}})$	$[0,5 \quad 0,5 \quad 0,001]$
Sample Time t_s	10^{-5} s
Fensterlänge k_f	81
Update-Rate n_{id}	1

Tabelle B.12: Konfiguration Experiment Vergleich Modelle WLTP-Zyklus Abb. 4.11.

Modell	Stationär
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,9992 \quad 0,9999 \quad 0,9992]$
$\text{tr}(P_{\text{max}})$	$[0,001 \quad 0,001 \quad 0,03]$
f_{pwm}	10 kHz
Fensterlänge k_f	11
Update-Rate n_{id}	1

Tabelle B.13: Konfiguration Experiment Vergleich Modelle WLTP-Zyklus Abb. 4.11.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,9992 \quad 0,9999 \quad 0,9992]$
$\text{tr}(P_{\text{max}})$	$[0,03 \quad 0,001 \quad 0,05]$
f_{pwm}	10 kHz
Fensterlänge k_f	11
Update-Rate n_{id}	1

Tabelle B.14: Konfiguration Experiment Eisenverluste WLTP-Zyklus Abb. 4.12.

Modell	Dynamisch
Parameter	T_r, L_s
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,9996 \quad 0,9999]$
$\text{tr}(P_{\text{max}})$	$[0,5 \quad 0,5]$
f_{pwm}	10 kHz
Fensterlänge k_f	11
Update-Rate n_{id}	1

Tabelle B.15: Konfiguration Experiment Vergleich Modelle WLTP-Zyklus Abb. 4.11.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,9992 \ 0,9999 \ 0,9992]$
$\text{tr}(P_{\text{max}})$	$[0,03 \ 0,001 \ 0,05]$
f_{pwm}	10 kHz
Fensterlänge k_f	11
Update-Rate n_{id}	1

Tabelle B.16: Konfiguration Experiment Eisenverluste Rampenprofil Abb. 4.14.

Modell	Dynamisch
Parameter	T_r, L_s
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,999 \ 0,9998]$
$\text{tr}(P_{\text{max}})$	$[0,5 \ 0,5]$
f_{pwm}	10 kHz
Fensterlänge k_f	11
Update-Rate n_{id}	1

Tabelle B.17: Konfiguration Simulation RLS-Algorithmus mit einfachem Vergessensfaktor im WLTP-Zyklus Abb. B.1.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS einf. Vergessen
Variables Verg.	inaktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
λ	0,995
Sample Time t_s	10^{-5} s
Fensterlänge k_f	81
Update-Rate n_{id}	1

Tabelle B.18: Konfiguration Simulation RLS-Algorithmus mit variablen Vergessensfaktor im WLTP-Zyklus Abb. B.2.

Modell	Dynamisch
Parameter	T_r, L_s
Algorithmus	RLS einf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
λ_0	0,995
$\text{tr}(P_{\text{max}})$	2
Sample Time t_s	10^{-5} s
Fensterlänge k_f	81
Update-Rate n_{id}	1

Tabelle B.19: Konfiguration Simulation RLS-Algorithmus mit Manipulation der Kovarianzmatrix im WLTP-Zyklus Abb. B.3.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS Kovarianz man.
Variables Verg.	inaktiv
Initialisierung θ_0	θ_{ref}
Initialisierung P_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
λ	0,999
$\epsilon_1 / \epsilon_2 / \beta$	0,1 / 0,011 / 0,5
Sample Time t_s	10^{-5} s
Fensterlänge k_f	81
Update-Rate n_{id}	1

B.3 Vergleich erweiterte RLS-Algorithmen

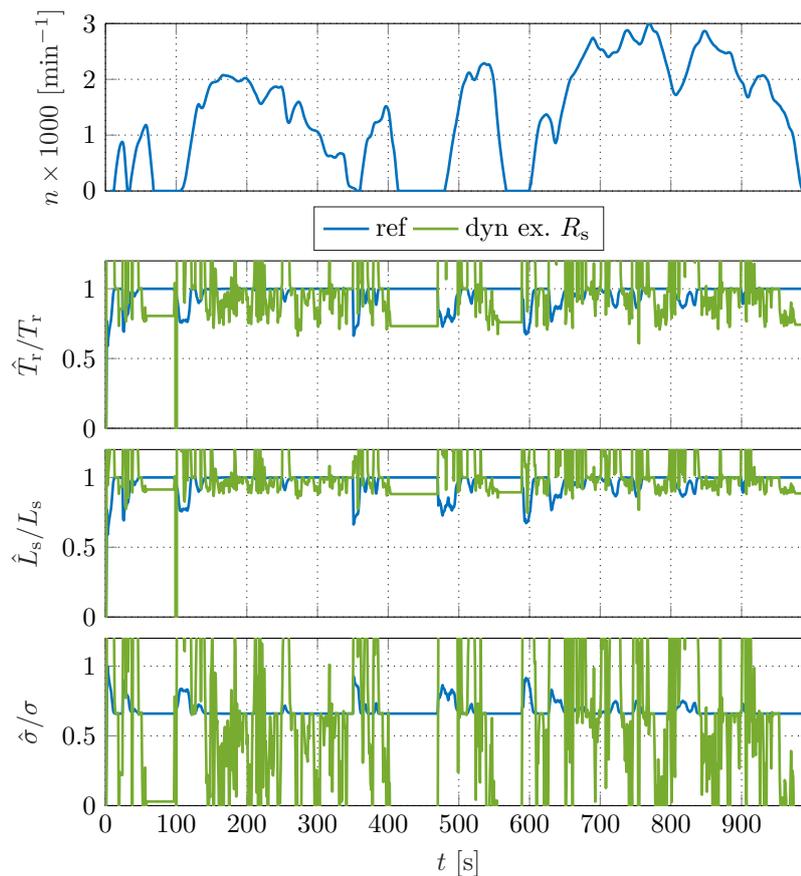


Abbildung B.1: Simulativer Verlauf der OPI mittels RLS-Algorithmus mit einfachem Vergessensfaktor entlang des WLTP-Zyklus. - Konfiguration Tab. B.17.

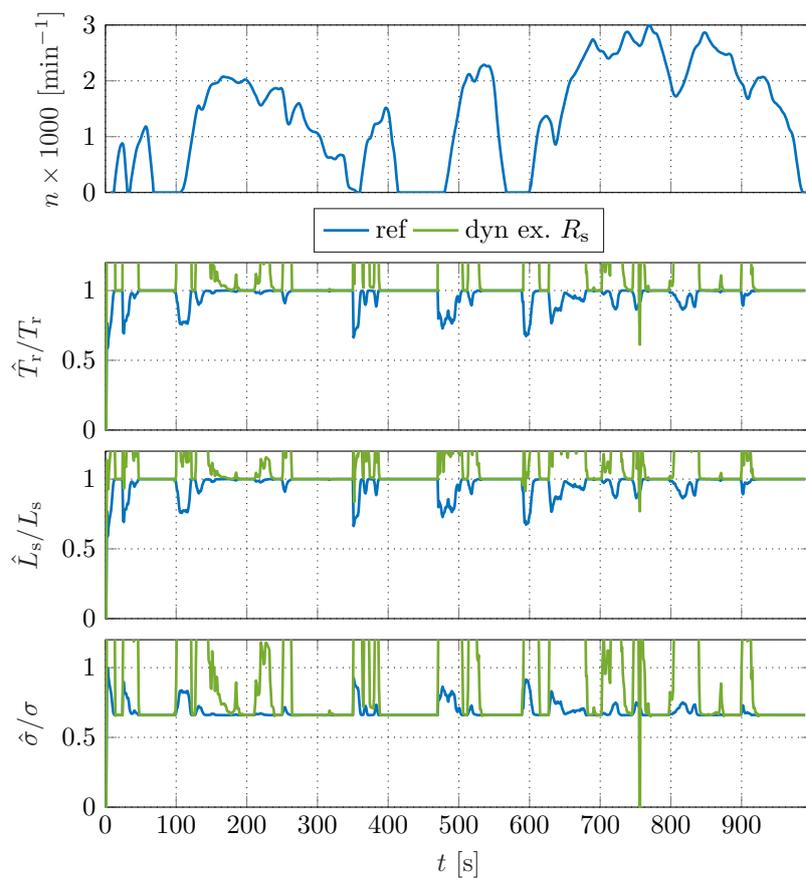


Abbildung B.2: Simulativer Verlauf der OPI mittels RLS-Algorithmus mit variablem Vergessensfaktor entlang des WLTP-Zyklus. - Konfiguration Tab. B.18.

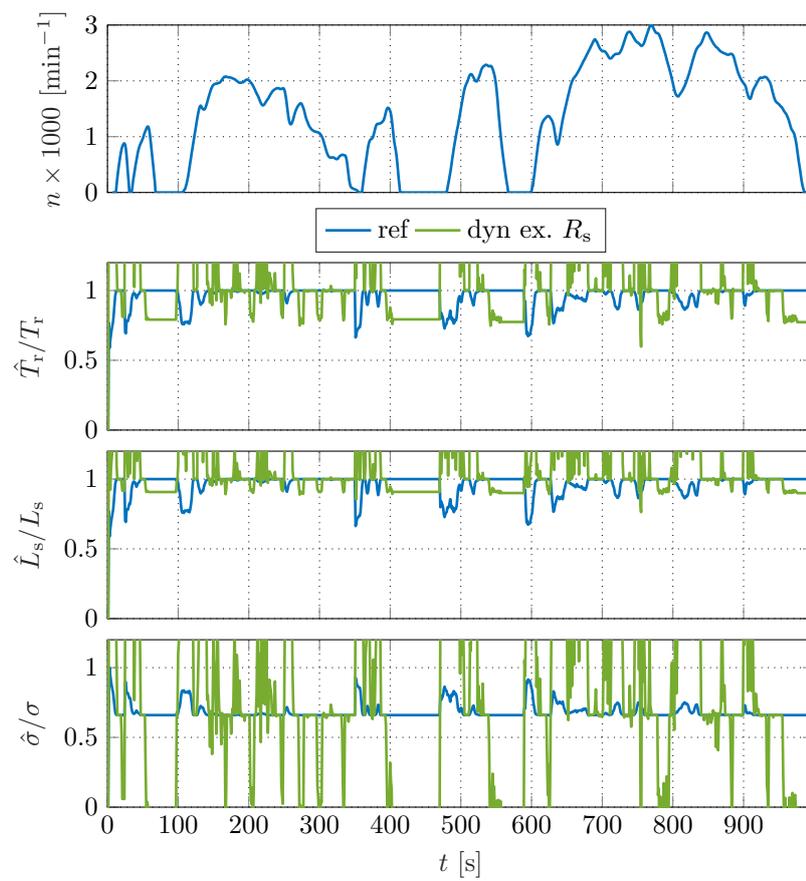


Abbildung B.3: Simulativer Verlauf der OPI mittels RLS-Algorithmus mit Manipulation der Kovarianzmatrix entlang des WLTP-Zyklus. - Konfiguration Tab. B.19.

C Online-Parameteridentifikation mittels erweitertem Kalman-Filter

C.1 Konfigurationen der erweiterten Kalman-Filter der simulativen und experimentelle Analysen

Tabelle C.1: Konfiguration Simulation Joint EKF Rampenprofil Abb. 5.4

$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 0_{4 \times 4} & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} 10^{-4} \cdot \mathbf{I}_4 & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} + \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} + \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = \begin{bmatrix} 10^6 & 0 & 0 & 0 \\ 0 & 10^7 & 0 & 0 \\ 0 & 0 & 10^8 & 0 \\ 0 & 0 & 0 & 10^4 \end{bmatrix}$	$\mathbf{R} = [10^{-8} \cdot \mathbf{I}_2]$

Tabelle C.2: Konfiguration Simulation Joint UKF Rampenprofil Abb. 5.4.

Parameter der Unscented-Transformation: $\alpha = 0,1$ $\beta = 2$ $\kappa = 1$		
$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 10^{-50} \cdot \mathbf{I}_4 & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} 10^{-4} \cdot \mathbf{I}_4 & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} + \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} + \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = \begin{bmatrix} 100 & 0 & 0 & 0 \\ 0 & 100 & 0 & 0 \\ 0 & 0 & 100 & 0 \\ 0 & 0 & 0 & 10 \end{bmatrix}$	$\mathbf{R} = [10^{-8} \cdot \mathbf{I}_2]$

Tabelle C.3: Konfiguration Simulation Dual EKF Rampenprofil Abb. 5.4.

EKF Zustände		
$\hat{\mathbf{x}}_0 = [0_{4 \times 1}]$	$\mathbf{P}_{0,x} = [0_{4 \times 4}]$	$\mathbf{Q}_x = [10^{-4} \cdot \mathbf{I}_4]$ $\mathbf{R}_x = [10^{-8} \cdot \mathbf{I}_2]$
EKF Parameter		
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} - \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} - \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\mathbf{Q}_\theta = [10^{-50} \cdot \mathbf{I}_4]$ $\mathbf{R}_\theta = [10^{-8} \cdot \mathbf{I}_2]$

Tabelle C.4: Konfiguration Simulation Dual UKF Rampenprofil Abb. 5.4.

Parameter der Unscented-Transformation: $\alpha = 10^{-3}$ $\beta = 2$ $\kappa = 1$		
UKF Zustände		
$\hat{\mathbf{x}}_0 = [0_{4 \times 1}]$	$\mathbf{P}_{0,x} = [0_{4 \times 4}]$	$\mathbf{Q}_x = [10^{-4} \cdot \mathbf{I}_4]$ $\mathbf{R}_x = [10^{-8} \cdot \mathbf{I}_2]$
UKF Parameter		
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} - \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = \begin{bmatrix} 10^{-3} & 0 & 0 & 0 \\ 0 & 0,2577 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0,0093 \end{bmatrix}$	$\mathbf{Q}_\theta = [10^{-50} \cdot \mathbf{I}_4]$ $\mathbf{R}_\theta = [10^{-8} \cdot \mathbf{I}_2]$

Tabelle C.5: Konfiguration Simulation Joint EKF $\hat{\boldsymbol{\theta}}_{\text{opt,ekf}}$ WLTP-Zyklus Abb. 5.5 / Abb. 5.6.

$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 0_{4 \times 4} & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} 10^{-4} \cdot \mathbf{I}_4 & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} + \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} + \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = [10 \cdot \mathbf{I}_4]$	$\mathbf{Q}_\theta = \text{diag}(10^{-4} \quad 10^{-4} \quad 10^{-8} \quad 10^{-8})$ $\mathbf{R} = [10^{-8} \cdot \mathbf{I}_2]$

Tabelle C.6: Konfiguration Simulation Joint UKF $\hat{\theta}_{\text{opt,ukf}}$ WLTP-Zyklus Abb. 5.5.

Parameter der Unscented-Transformation: $\alpha = 0,1$ $\beta = 2$ $\kappa = 1$		
$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 10^{-50} \cdot \mathbf{I}_4 & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} 10^{-4} \cdot \mathbf{I}_4 & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} + \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} + \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = [10 \cdot \mathbf{I}_4]$	$\mathbf{Q}_\theta = \text{diag}(10^{-4} \quad 10^{-4} \quad 10^{-8} \quad 10^{-8})$
		$\mathbf{R} = [10^{-8} \cdot \mathbf{I}_2]$

Tabelle C.7: Konfiguration Simulation Joint EKF $\hat{\theta}_{\text{dir,ekf}}$ WLTP-Zyklus Abb. 5.6.

$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 0_{4 \times 4} & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} 10^{-15} \cdot \mathbf{I}_4 & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} + \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} + \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = [10 \cdot \mathbf{I}_4]$	$\mathbf{Q}_\theta = [10^{-15} \cdot \mathbf{I}_4]$
		$\mathbf{R} = [10^{-8} \cdot \mathbf{I}_2]$

Tabelle C.8: Konfiguration Experiment Joint EKF $\hat{\theta}_{\text{opt,ekf}}$ bei WLTP-Zyklus Abb. 5.8 / Abb. 5.9 sowie bei Rampenprofil Abb. 5.10 und Abb. 5.11.

$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 0_{4 \times 4} & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} \mathbf{Q}_x & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} + \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} + \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = [0_{4 \times 4}]$	$\mathbf{Q}_x = \text{diag}(10^{-2} \quad 10^{-2} \quad 10^{-10} \quad 10^{-10})$
		$\mathbf{Q}_\theta = \text{diag}(10^{-3} \quad 10^{-6} \quad 10^{-7} \quad 10^{-10})$
		$\mathbf{R} = \text{diag}(14 \cdot 10^{-4} \quad 9 \cdot 10^{-4})$

Tabelle C.9: Konfiguration Experiment Joint EKF $\hat{\theta}_{\text{dir,ekf}}$ WLTP-Zyklus Abb. 5.8.

$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 0_{4 \times 4} & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} \mathbf{Q}_x & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} \theta_{1,\text{ref}} + \frac{\theta_{1,\text{ref}}}{2} \\ \theta_{2,\text{ref}} + \frac{\theta_{2,\text{ref}}}{2} \\ \theta_{3,\text{ref}} + \frac{\theta_{3,\text{ref}}}{2} \\ \theta_{4,\text{ref}} + \frac{\theta_{4,\text{ref}}}{2} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = [0_{4 \times 4}]$	$\mathbf{Q}_x = \text{diag}(10^{-9} \quad 10^{-9} \quad 10^{-8} \quad 10^{-8})$
		$\mathbf{Q}_\theta = \text{diag}(10^{-12} \quad 10^{-12} \quad 10^{-8} \quad 10^{-12})$
		$\mathbf{R} = \text{diag}(14 \cdot 10^{-4} \quad 9 \cdot 10^{-4})$

D Ableitung von Diagnosekonzepten

D.1 Konfigurationen von RLS-Algorithmus und EKF bei Online-Identifikation der Abweichung

Tabelle D.1: Konfiguration Simulation zur Identifikation der Abweichung mit RLS-Algorithmus im Rampenprofil Abb. 6.2 bzw. WLTP-Zyklus Abb. 6.3.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	$\mathbf{0}_{1 \times 3}$
Initialisierung \mathbf{P}_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,995 \quad 0,995 \quad 0,9992]$
$\text{tr}(\mathbf{P}_{\text{max}})$	$[0,03 \quad 0,001 \quad 0,05]$
Fensterlänge k_f	11
Update-Rate n_{id}	1

Tabelle D.2: Konfiguration Experiment zur Identifikation der Abweichung mit RLS-Algorithmus im Rampenprofil Abb. 6.4 / Abb. 6.5 bzw. WLTP-Zyklus Abb. 6.6.

Modell	Dynamisch
Parameter	T_r, L_s
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung θ_0	$\mathbf{0}_{1 \times 3}$
Initialisierung \mathbf{P}_0	$\frac{1}{900} \cdot \text{diag}(\theta_{\text{ref}}^2)$
Λ_0	$[0,999 \quad 0,999]$
$\text{tr}(\mathbf{P}_{\text{max}})$	$[0,03 \quad 0,001]$
Fensterlänge k_f	11
Update-Rate n_{id}	1

Tabelle D.3: Konfiguration Simulation zur Identifikation der Abweichung mit EKF im Rampenprofil Abb. 6.2 bzw. WLTP-Zyklus Abb. 6.3.

$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\theta}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 0_{4 \times 4} & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} \mathbf{Q}_x & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\theta}_0 = [0_{4 \times 1}]$	$\mathbf{P}_{0,\theta} = [0_{4 \times 4}]$	$\mathbf{Q}_x = \text{diag}(10^{-8} \quad 10^{-8} \quad 10^{-5} \quad 10^{-5})$
		$\mathbf{Q}_\theta = \text{diag}(10^{-12} \quad 10^{-8} \quad 10^{-8} \quad 10^{-12})$
		$\mathbf{R} = \text{diag}(14 \cdot 10^{-4} \quad 9 \cdot 10^{-4})$

Tabelle D.4: Konfiguration Experiment zur Identifikation der Abweichung mit EKF im Rampenprofil Abb. 6.4 bzw. WLTP-Zyklus Abb. 6.6.

$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0_{4 \times 1} \\ \hat{\boldsymbol{\theta}}_0 \end{bmatrix}$	$\mathbf{P}_0 = \begin{bmatrix} 0_{4 \times 4} & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{P}_{0,\theta} \end{bmatrix}$	$\mathbf{Q} = \begin{bmatrix} \mathbf{Q}_x & 0_{4 \times 4} \\ 0_{4 \times 4} & \mathbf{Q}_\theta \end{bmatrix}$
$\hat{\boldsymbol{\theta}}_0 = \begin{bmatrix} 0_{4 \times 1} \end{bmatrix}$	$\mathbf{P}_{0,\theta} = \begin{bmatrix} 0_{4 \times 4} \end{bmatrix}$	$\mathbf{Q}_x = \text{diag} (10^{-8} \quad 10^{-8} \quad 10^{-5} \quad 10^{-5})$
		$\mathbf{Q}_\theta = \text{diag} (10^{-12} \quad 10^{-8} \quad 10^{-8} \quad 10^{-12})$
		$\mathbf{R} = \text{diag} (14 \cdot 10^{-4} \quad 9 \cdot 10^{-4})$

D.2 Konfigurationen des RLS-Algorithmus zur parameterbasierten Fehlerklassifikation

Tabelle D.5: Konfiguration Simulation Vergleich Modelle WLTP-Zyklus Abb. 4.10.

Modell	Dynamisch
Parameter	T_r, L_s, σ
Algorithmus	RLS mehrf. Vergessen
Variables Verg.	aktiv
Initialisierung $\boldsymbol{\theta}_0$	$\mathbf{0}_{1 \times 3}$
Initialisierung \mathbf{P}_0	$\frac{1}{900} \cdot \text{diag} (\boldsymbol{\theta}_{\text{ref}}^2)$
Λ_0	$[0,85 \quad 0,98 \quad 0,99]$
$\text{tr} (\mathbf{P}_{\text{max}})$	$[0,5 \quad 0,5 \quad 0,001]$
Sample Time t_s	10^{-4} s
Fensterlänge k_f	11
Update-Rate n_{id}	1

D.3 Performanz der Klassifikatoren zur echtzeitfähigen Diagnose

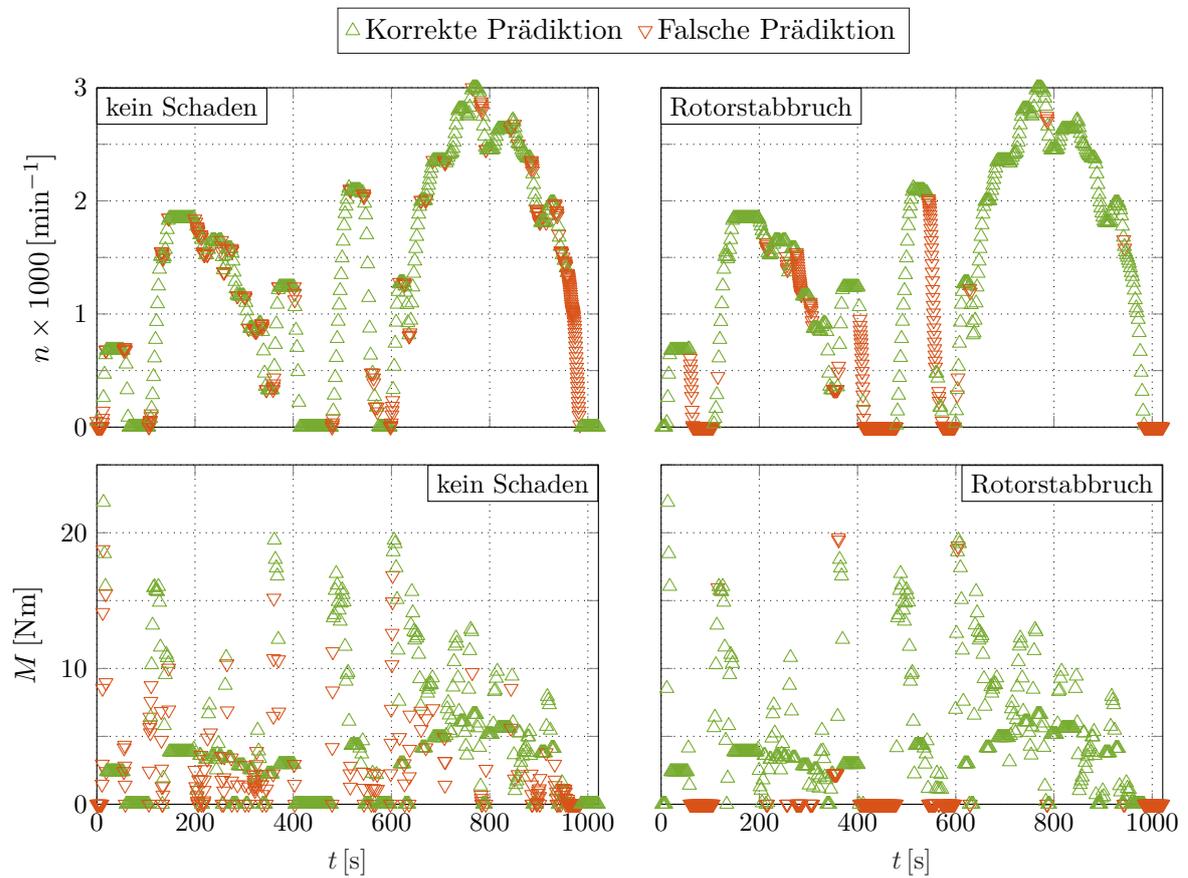


Abbildung D.1: Validierung der Klassifikation mittels neuronalem Netz entlang des angepassten WLTP-Zyklus ohne Aktivierungslogik.

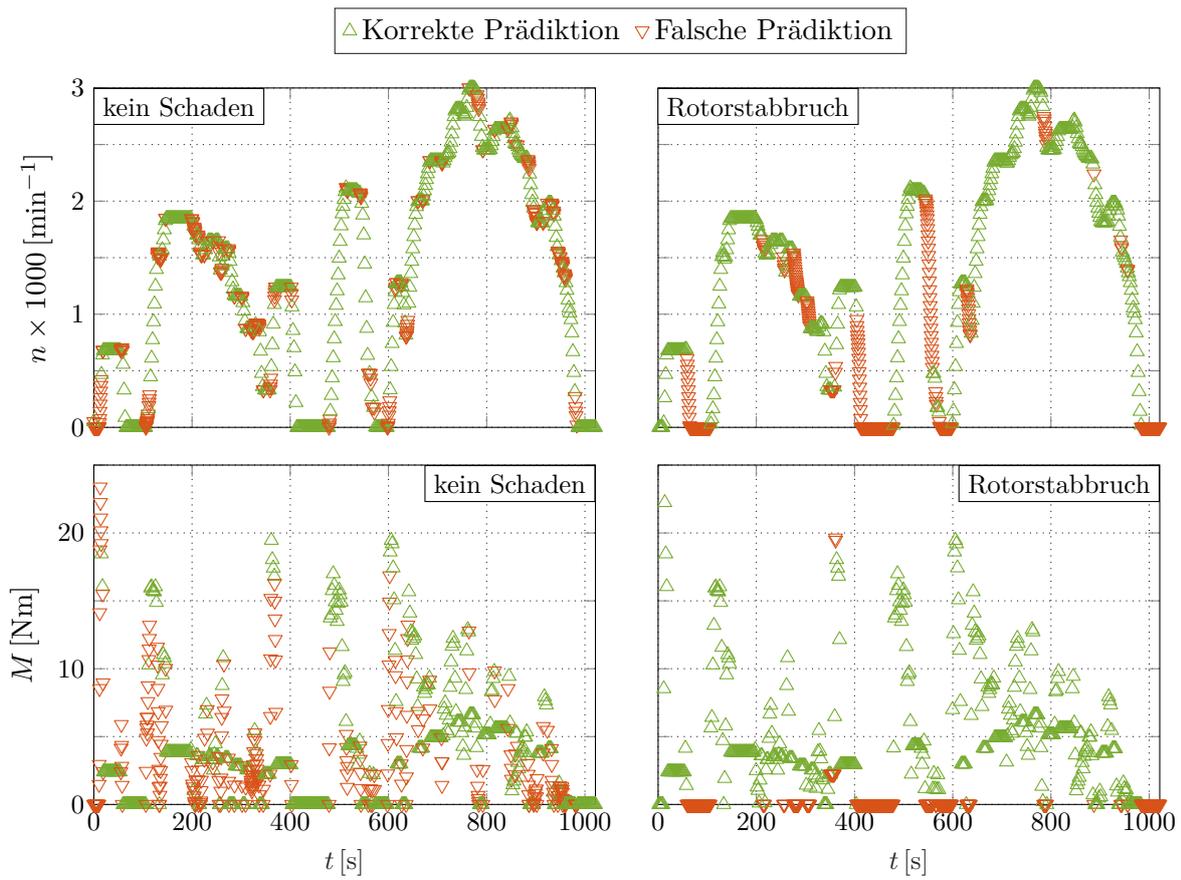


Abbildung D.2: Validierung der Klassifikation mittels Support-Vector-Machine entlang des angepassten WLTP-Zyklus ohne Aktivierungslogik.

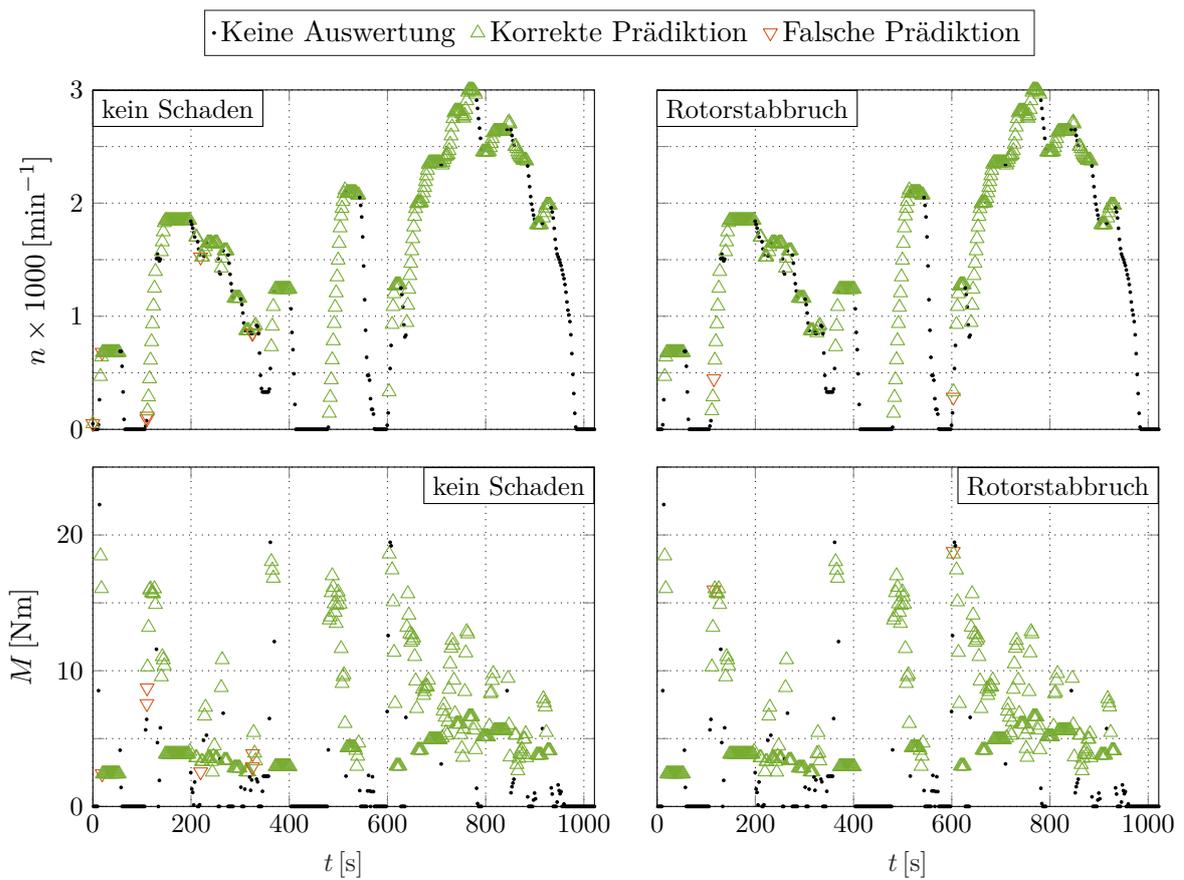


Abbildung D.3: Validierung der Klassifikation mittels neuronalem Netz entlang des angepassten WLTP-Zyklus mit Aktivierungslogik.

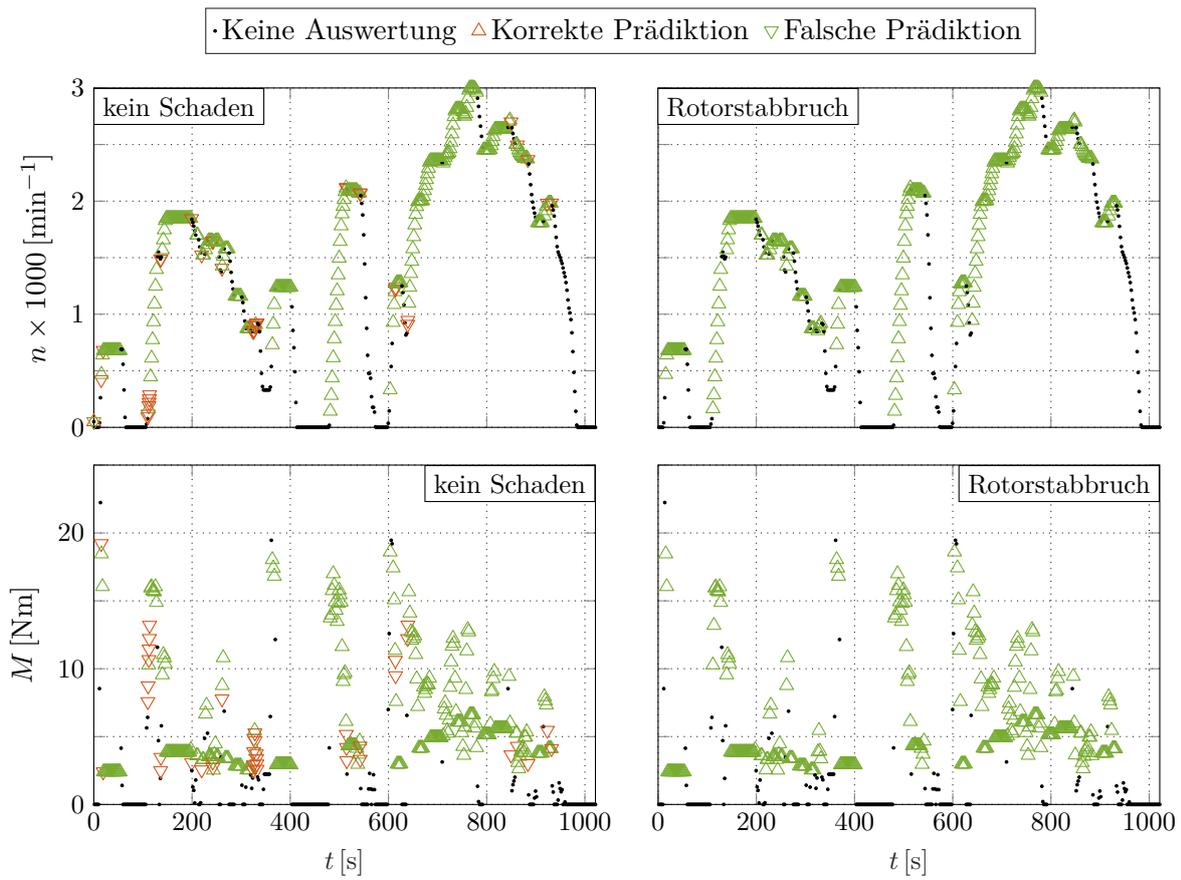


Abbildung D.4: Validierung der Klassifikation mittels Support-Vector-Machine entlang des angepassten WLTP-Zyklus mit Aktivierungslogik.

Abkürzungsverzeichnis

ASM Asynchronmaschine.

BF Blackman-Fenster.

EKF Erweiterte-Kalman-Filter.

ELB Erweiterter-Luenberger-Beobachter.

EMV Elektromagnetische Verträglichkeit.

ERLS Extended-Recursive-Least-Squares.

ESB Ersatzschaltbild.

FIR finite impulse response.

GLS Generalized-Least-Squares.

HIL Hardware-in-the-loop.

HMM Hidden-Markov-Modell.

HTML hypertext markup language.

KF Kalman-Filter.

KI Künstliche Intelligenz.

KNN künstliches neuronales Netz.

KOS Koordinatensystem.

LB Luenberger-Beobachter.

LR Logistische Regression.

LS Least-Squares.

- MIMO** Multiple-Input-Multiple-Output.
- MISO** Multiple-Input-Single-Output.
- MLP** Multi-Layer-Perzeptron.
- MPC** Modellprädiktive-Regelung.
- MRAS** Model-Reference-Adaptive-System.
- MTPA** Maximum Torque Per Ampere.
- OPI** Online-Parameteridentifikation.
- PI** Parameteridentifikation.
- PKW** Personenkraftwagen.
- PWM** Pulsweitenmodulation.
- ReLU** Rectified Linear Unit.
- RFM** Random-Forest-Modell.
- RLS** Recursive-Least-Squares.
- RLSEV** RLS-Verfahren mit exponentiellem Vergessen.
- RLSMV** RLS-Verfahren mit mehrfachem exponentiellen Vergessen.
- RTI** Real Time Interface.
- SG** Savitzky-Golay.
- SNR** Signal-to-noise ratio.
- SVM** Support-Vector-Machine.
- TLS** Total-Least-Squares.
- UKF** Unscented-Kalman-Filter.
- UT** Unscented-Transformation.
- VNN** Vorstrukturiertes-Neuronales-Netz.
- WLS** Weighted-Least-Squares.

WLTP Worldwide Harmonized Light Vehicles Test Procedure.

XML extensible markup language.

ZRM Zustandsraummodell.

Symbolverzeichnis

<i>A</i>	Systemmatrix des Zustandsraummodells
<i>B</i>	Eingangsmatrix des Zustandsraummodells
<i>C</i>	Ausgangsmatrix des Zustandsraummodells, Filterkoeffizienten der Savitzky-Golay Glättung
<i>D</i>	Durchgangsmatrix des Zustandsraummodells
<i>y</i>	Ausgangsvektor
<i>y</i>	Zustandsvektor
<i>e</i>	Residuum zwischen wahren und geschätztem Wert, Identifikationsfehler
Φ	Regressionsmatrix des Regressionsmodells
θ	Zustandsvektor
Δ	Abweichung
<i>J</i>	Gütekriterium zur Optimierung
<i>H</i>	Hessematrix
<i>P</i>	Kovarianzmatrix
σ	Standardabweichung, Blondelscher Streukoeffizient
<i>I</i>	Einheitsmatrix
<i>J</i>	imaginäre Kopplungsmatrix
γ	Korrekturfaktor
α	Initialisierungsfaktor, Skalierungsfaktor zur Ausbreitung der Sigma-Punkte bei der Unscented Transformation
<i>W</i>	Gewichtungsmatrix
<i>w</i>	Gewicht
λ	Einfacher Vergessensfaktor
Λ	Mehrfacher Vergessensfaktor
ϵ	Schwellwert
ε	Bedingung zur Aktivierung der Fehlerklassifikation
β	Adaptionsfaktor
κ	Korrekturmatrix zur Anpassung der Kovarianzmatrix

κ	KonditionierungszahlSkalierungsfaktor bei der Unscented Transformation
c	Korrekturfaktor zur Anpassung der Kovarianzmatrix
z	Prozessrauschen
Z	Skalierung der Matrix des Prozessrauschens
Q	Varianz des Prozessrauschens
v	Messrauschen
R	Varianz des Messrauschens, Informationsmatrix des Regressionsmodells
K	Kalman-Verstärkung
F	Jacobimatrix der Zustände des nichtlinearen Zustandsraummodells
G	Jacobimatrix der Ausgänge des nichtlinearen Zustandsraummodells
\mathcal{X}	Sigma-Vektor der Unscented Transformation
\mathcal{Y}	Propagierte Ausgangspunkte der Sigma-Punkte der Unscented Transformation
ξ	Prozessrauschen der geschätzten Parameter, Schlupfvariable der Support-Vector-Machine
f	Frequenz
T	Periodendauer
t	Zeit
n	Drehzahl, Anzahl
ω	Umdrehungsfrequenz
M	Drehmoment
i	Strom
u	Spannung
Ψ	magnetischer Fluss
B	magnetische Flussdichte
R	ohmscher Widerstand
L	Induktivität
P	Leistung
ϑ	Temperatur
L	Vektor mit Lie-Ableitungen
ζ	Beobachtbarkeitsindex des nichtlinearen Zustandsraummodells
U	linke Singulärvektoren des nichtlinearen Zustandsraummodells

\mathbf{V}	rechte Singulärvektoren des nichtlinearen Zustandsraummodells
\mathbf{S}	Matrix mit Singulärwerten des nichtlinearen Zustandsraummodells
b	Bias
l	Kosten des Trainingsverlaufs
H	Anzahl der Neuronen einer verdeckten Schicht
\hat{x}	Akzent: Schätzwert, Amplitudenwert
\dot{x}	Akzent: Ableitung nach der Zeit
\bar{x}	Akzent: Mittelwert
\tilde{x}	Akzent: Korrigierter Schätzwert
x^T	Hochindex: Transponierte Matrix
x^+	Hochindex: Pseudoinverse Matrix
x^{-1}	Hochindex: Inverse Matrix
x^d	Hochindex: d-Komponente der Zustandsgröße
x^q	Hochindex: q-Komponente der Zustandsgröße
x^α	Hochindex: α -Komponente der Zustandsgröße
x^β	Hochindex: β -Komponente der Zustandsgröße
x^S	Hochindex: Mathematische Zuordnung der Zustandsgröße zum statororientierten Koordinatensystem
x^R	Hochindex: Mathematische Zuordnung der Zustandsgröße zum rotororientierten Koordinatensystem
x^K	Hochindex: Mathematische Zuordnung der Zustandsgröße an einem frei gewählten Koordinatensystem
x_0	Index: Initialwert, Initialvektor
x_λ	Index: Änderung in Abhängigkeit eines einfachen Vergessensfaktors
x_Λ	Index: Änderung in Abhängigkeit eines mehrfachen Vergessensfaktors
x_f	Index: Bezug auf Savitzky-Golay Glättungsfenster
x_{rls}	Index: Bezug auf den RLS-Algorithmus
x_{kf}	Index: Bezug auf den KF-Algorithmus
x_f	Index: Bezug auf Savitzky-Golay Filter
x_n	Index: Nominalwert
x_m	Index: mechanische Maschinengröße, Kopplungsinduktivität (m utual)
x_{el}	Index: elektrische Maschinengröße
x_σ	Index: Streukomponente, Standardabweichung
x_{min}	Index: Minimalwert

x_{\max}	Index: Maximalwert
x_s	Index: Zuordnung der Zustandsgröße bzw. des Parameter zum Statorkreis der Maschine, Bezug auf Abtastschritt
x_r	Index: Zuordnung der Zustandsgröße bzw. des Parameter zum Rotorkreis der Maschine
x_{fe}	Index: Bezug auf die Eisenverluste der Maschine
x_{ref}	Index: Referenzwert
x_{pwm}	Index: Bezug auf die Frequenz der Pulsweitenmodulation des Antriebsumrichters
x_{del}	Index: Bezug auf Zeitverzögerung
x_d	Index: Bezug auf Diskretisierung des Modells
x_{kor}	Index: Bezug auf Korrektur
x_{ext}	Index: Bezug auf Erweiterung einer bestehenden Größe
x_{dir}	Index: Bezug auf Zustandsraummodell mit direkter Parameteridentifikation
x_{opt}	Index: Bezug auf Zustandsraummodell mit optimierter Parameteridentifikation
x_{mean}	Index: Mittelwert
x_{skew}	Index: Schiefe
x_{kurt}	Index: Kurtosis
ε_{tr}	Triggersignal für die Online-Parameteridentifikation
$f_{c,sg}$	Knickfrequenz Savitzky-Golay Filter
Θ_r	Rotorflusswinkel
$R_{\vartheta^\circ C}$	Temperaturabhängiger ohmscher Widerstand
$\alpha_{Cu/Al}$	Temperaturkoeffizient ohmscher Widerstand
n_p	Polpaarzahl der elektrischen Maschine
n_{ph}	Phasenanzahl der elektrischen Maschine
S_{θ_x}	Sensitivität des Parameter θ_x gegenüber dem Identifikationsmodell
n_{id}	Faktor zum Downsampling der Identifikationsalgorithmen
\mathcal{O}_{lin}	lineare Beobachtbarkeitsmatrix
\mathcal{O}_{nonlin}	nichtlineare Beobachtbarkeitsmatrix
\mathbf{J}_{jcb}	Jacobimatrix des diskretisierten nichtlinearen Zustandsraummodells
ε_{akt}	Finale Bedingung zur Aktivierung der Fehlerklassifikation

Literatur

- [1] T. M. Rowan, R. J. Kerkman und D. Leggate, „A simple on-line adaption for indirect field orientation of an induction machine - Industry Applications, IEEE Transactions on,“ *IEEE Transactions on Industry Applications*, Nr. 4, 1991.
- [2] A. V. Pavlov und A. T. Zaremba, „Real-Time Rotor and Stator Resistances Estimation of an Induction Motor,“ *IFAC Proceedings Volumes*, Jg. 34, Nr. 6, S. 1171–1176, 2001.
- [3] E. Levi und M. Wang, „Online identification of the mutual inductance for vector controlled induction motor drives,“ *IEEE Transactions on Energy Conversion*, Jg. 18, Nr. 2, S. 299–305, 2003.
- [4] H. Li, W. Xuhui und C. Guilan, „New General MRAS Adaptive Scheme to Estimate Stator and Rotor Resistance of Induction Motors,“ in *Conference Record of the 2006 IEEE Industry Applications Conference Forty-First IAS Annual Meeting*, IEEE, 2006, S. 1775–1780.
- [5] John Cortes-Romero, Carlos Garcia-Rodriguez, Alberto Luviano-Juarez, Hebertt Sira-Ramirez, *Algebraic Parameter Identification for Induction Motors: 37th Annual Conference of the IEEE Industrial Electronics Society, Crown Conference Centre, Melbourne, Australia, 07-10 November, 2011*. Piscataway, NJ: IEEE, 2011.
- [6] F.L. Mapelli, A. Bezzolato, D. Tarsitano, *A Rotor Resistance MRAS Estimator for Induction Motor Traction Drive for Electrical Vehicles: Marseille, France, 2-5 September 2012*. Piscataway NJ: IEEE, 2012.
- [7] G. Chowdhary, M. Mühlegg und E. Johnson, „Exponential Parameter and Tracking Error Convergence Guarantees for Adaptive Controllers without Persistency of Excitation,“ *International Journal of Control*, Nr. No.00, 2013.
- [8] P. Cao, X. Zhang und S. Yang, „A Unified-Model-Based Analysis of MRAS for Online Rotor Time Constant Estimation in an Induction Motor Drive,“ *IEEE Transactions on Industrial Electronics*, Jg. 64, Nr. 6, S. 4361–4371, 2017.
- [9] M. Basic, D. Vukadinovic, I. Grgic und M. Bubalo, „Speed-Sensorless Vector Control of an Induction Generator Including Stray Load and Iron Losses and Online Parameter Tuning,“ *IEEE Transactions on Energy Conversion*, Jg. 35, Nr. 2, S. 724–732, 2020.

- [10] G. Kenne, F. Floret, H. Nkwawo und F. Lamnabhi-Lagarrigue, „Parameter estimation methodology for nonlinear systems: Application to induction motor,“ *Journal of Systems Science and Systems Engineering*, Jg. 14, Nr. 2, S. 240–254, 2005.
- [11] S. M. N. Hasan und I. Husain, „A Luenberger–Sliding Mode Observer for Online Parameter Estimation and Adaptation in High-Performance Induction Motor Drives,“ *IEEE Transactions on Industry Applications*, Jg. 45, Nr. 2, S. 772–781, 2009.
- [12] J. Koupeny, „Observer-Based Online Parameter Estimation of Doubly Fed Induction Generators Based on the Gradient Descent Method: Die Energiewende - blueprints for the new energy age : date: 17-18 Nov. 2015,“ in *International ETG Congress 2015*.
- [13] J. Koupeny, S. Lucke und A. Mertens, „Observer-based online parameter estimation of squirrel-cage induction machines based on the gradient descent method,“ S. 1–10,
- [14] J. Koupený, *Online-Parameter-Identifikation von geregelten Antriebssystemen mit Umrichterspeisung: Dissertation*, 1. Auflage. 2017.
- [15] S. Yang, D. Ding, X. Li, Z. Xie, X. Zhang und L. Chang, „A Novel Online Parameter Estimation Method for Indirect Field Oriented Induction Motor Drives,“ *IEEE Transactions on Energy Conversion*, Jg. 32, Nr. 4, S. 1562–1573, 2017.
- [16] Nadia Stoicuta, Olimpiu Stoicuta und Teodor Pana, „On-line Electrical Parameters Estimation of an Induction Motor: October 4-6, 2018, Craiova, Romania : proceedings,“ in *2018 International Conference on Applied and Theoretical Electricity (ICATE)*.
- [17] M. Nachtsheim, J. Ernst, C. Endisch und R. Kennel, „Performance of Recursive Least Squares Algorithm Configurations for Online Parameter Identification of Induction Machines in an Automotive Environment,“ in Bd. 9, S. 4236–4254.
- [18] M. Nachtsheim, L. Korkmaz, M. Schmoelz und C. Endisch, „Observability Analysis for Parameter Identification of Induction Machines in Automotive Environment,“ in *2022 IEEE 31st International Symposium on Industrial Electronics (ISIE)*, IEEE, 2022, S. 206–213.
- [19] M. Nachtsheim, K. Grund, C. Endisch und R. Kennel, „Online Identification of Induction Machine Parameter Deviations for Aging Detection - A Comparative Study Using Recursive Least Squares Algorithm and Extended Kalman Filter,“ in *2023 IEEE Transportation Electrification Conference 2023*, S. 1–6.
- [20] M. Nachtsheim, T. Hartmann und C. Endisch, „Physically Inspired Neural Network for Modeling Induction Machine Nonlinear Magnetic Saturation,“ in *2022 IEEE Transportation Electrification Conference & Expo (ITEC)*, IEEE, 2022, S. 874–881.
- [21] L. Ljung, *System identification: Theory for the user* (Prentice Hall information and system sciences series), 2. ed. Upper Saddle River, NJ: Prentice Hall, 1999.

- [22] R. Isermann und M. Münchhof, *Identification of Dynamic Systems: An Introduction with Applications* (Advanced Textbooks in Control and Signal Processing). Berlin, Heidelberg: Springer Berlin Heidelberg und Springer-Verlag Berlin Heidelberg, 2011.
- [23] O. Nelles, *Nonlinear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models*. Berlin und Heidelberg: Springer-Verlag Berlin Heidelberg GmbH und Springer, 2001.
- [24] W. Nürnberg und R. Hanitsch, *Die Prüfung elektrischer Maschinen* (Klassiker der Technik), 7. Auflage. Berlin und Heidelberg: Springer, 2001.
- [25] S. Beyer, „Robuste Parameterschätzung für Elektrofahrzeuge,“ Dissertation, UNIVERSITÄT DER BUNDESWEHR MÜNCHEN, München, 3.07.2019.
- [26] M. Cirrincione, M. Pucci, G. Cirrincione und G.-A. Capolino, „A new experimental application of least-squares techniques for the estimation of the induction motor parameters,“ *IEEE Transactions on Industry Applications*, Jg. 39, Nr. 5, S. 1247–1256, 2003.
- [27] C. Moons und B. D. Moor, „Parameter identification of induction motor drives,“ *Automatica*, Jg. 31, Nr. 8, S. 1137–1147, 1995.
- [28] T. R. Fortescue, L. S. Kershenbaum und B. E. Ydstie, „Implementation of self-tuning regulators with variable forgetting factors,“ *Automatica*, Jg. 17, Nr. 6, S. 831–835, 1981.
- [29] P. Krus, S. Gunnarsson, *Adaptive control of a hydraulic crane using on-line identification*. 1993.
- [30] K. J. Åström, *Adaptive control*, 2. ed. Mineola, N.Y: Dover Publ, 2008.
- [31] A. Vahidi, A. Stefanopoulou und H. Peng, „Recursive least squares with forgetting for online estimation of vehicle mass and road grade: theory and experiments,“ *Vehicle System Dynamics*, Jg. 43, Nr. 1, S. 31–55, 2005.
- [32] S. Rhode und F. Gauterin, „Online estimation of vehicle driving resistance parameters with recursive least squares and recursive total least squares,“ in *2013 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, 2013, S. 269–276.
- [33] D. Schröder und M. Buss, *Intelligente Verfahren: Identifikation und Regelung Nichtlinearer Systeme*, 2nd ed. Berlin, Heidelberg: Springer Berlin Heidelberg und Vieweg, 2017.
- [34] R. E. Kalman, „A New Approach to Linear Filtering and Prediction Problems,“ *Journal of Basic Engineering*, Jg. 82, Nr. 1, S. 35–45, 1960.
- [35] S. M. Kay, *Fundamentals of statistical signal processing*, 20. pr//15. pr. Upper Saddle River, NJ: Prentice Hall PTR, 2013//2011.

- [36] R. van der Merwe, „Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models,“ Dissertation, University of Stellenbosch, 2004.
- [37] S. S. Haykin, Hrsg., *Kalman Filtering and Neural Networks* (Wiley series on adaptive and learning systems for signal processing, communications, and control). New York u. a.: Wiley, 2001.
- [38] C. K. Chui und G. Chen, *Kalman Filtering: With Real-Time Applications*, 4. Aufl. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009.
- [39] M. S. Grewal und A. P. Andrews, „Kalman Filtering,“ 2014.
- [40] R. Marchthaler und S. Dingler, *Kalman-Filter: Einführung in die Zustandsschätzung und ihre Anwendung für eingebettete Systeme* (Lehrbuch). Wiesbaden: Springer Fachmedien Wiesbaden und Springer Vieweg, 2017.
- [41] R. G. Brown und P. Y. C. Hwang, *Introduction to Random Signals and Applied Kalman Filtering: with MATLAB® Exercises: With MATLAB exercises*, 4th ed. Hoboken, NJ: J. Wiley & Sons, 2012.
- [42] Simon J. Julier und Jeffrey K. Uhlmann, „New extension of the Kalman filter to nonlinear systems.,“ *Signal Processing, Sensor Fusion, and Target Recognition VI*, Nr. 3068, S. 182–193, 1997.
- [43] E. A. Wan und R. van der Merwe, „The Unscented Kalman Filter for Nonlinear Estimation,“
- [44] W. H. Press, S. A. Teukolsky, W. T. Vetterling und B. P. Flannery, *Numerical recipes in C: The art of scientific computing*, 2. ed., reprinted with corr., this reprinting is corr. to software version 2.10. Cambridge: Cambridge Univ. Press, 2002.
- [45] Y. Hao, Z. Xiong, F. Sun und X. Wang, „Comparison of Unscented Kalman Filters: IEEE ICMA 2007] ; Harbin, China, 5 - 8 August 2007,“ in S. 895–899.
- [46] Alex Tremain Nelson, „Nonlinear estimation and modeling of noisy time-series by dual Kalman filtering methods,“ Dissertation, University of California, San Diego, 2000.
- [47] Z. Hu, G. Shu-juan und D. Zi-zhao, „On-line parameter identification of induction motor based On RLS algorithm,“ S. 2132–2137,
- [48] J. Kertzschner, *Ein Verfahren zur Identifikation der elektrischen Parameter von Asynchronmaschinen: Zugl.: Freiberg, Techn. Univ. Bergakad., Diss., 2002* (Tenea Wissenschaft), 1. Aufl. Berlin: Tenea, 2003.
- [49] H. Arnold, *Ein Beitrag zur Identifikation der Parameter der Asynchronmaschine im geregelten Betrieb: Zugl.: Freiberg (Sachsen), Techn. Univ., Diss., 2006*. Dresden: TUDpress, 2006.

- [50] O. Buchholz und J. Boeker, „Online-Identification of the Machine Parameters of an Induction Motor Drive,“ in *2018 IEEE 27th International Symposium on Industrial Electronics (ISIE)*, IEEE, 2018, S. 860–867.
- [51] S. Altmannshofer, C. Endisch und K. D. Trieu, „On-line identification and identifiability analysis of electrical and mechanical parameters of induction machines: 3-7 July 2017,“ in S. 577–583.
- [52] A. Savitzky und M. J. E. Golay, „Smoothing and Differentiation of Data by Simplified Least Squares Procedures,“ *Analytical Chemistry*, Jg. 36, Nr. 8, S. 1627–1639, 1964.
- [53] D. Schröder, *Elektrische Antriebe - Regelung von Antriebssystemen*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2015.
- [54] A. Binder, *Elektrische Maschinen und Antriebe*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2017.
- [55] S.-K. Sul, *Control of electric machine drive system* (IEEE Press series on power engineering). Hoboken N.J.: Wiley-IEEE, 2011, Bd. 55.
- [56] Horace Lamb, „XIII. On electrical motions in a spherical conductor,“ *Philosophical Transactions of the Royal Society of London*, Jg. 174, S. 519–549, 1883.
- [57] Frederick Emmons Terman, *Radio Engineers' Handbook*. New York und London: McGraw-Hill Book Company, Inc., 1943.
- [58] G. R. Slemon, „Modelling of induction machines for electric drives,“ *IEEE Transactions on Industry Applications*, Jg. 25, Nr. 6, S. 1126–1131, 1989.
- [59] E. Clarke, *Circuit Analysis of A-C Power Systems* (General Electric series). 1950.
- [60] R. H. Park, „Two-reaction theory of synchronous machines generalized method of analysis-part I,“ *Transactions of the American Institute of Electrical Engineers*, Jg. 48, Nr. 3, S. 716–727, 1929.
- [61] M. N. Uddin und S. W. Nam, „New Online Loss-Minimization-Based Control of an Induction Motor Drive,“ *IEEE Transactions on Power Electronics*, Jg. 23, Nr. 2, S. 926–933, 2008.
- [62] M. N. Uddin und S. W. Nam, „Development of a Nonlinear and Model-Based Online Loss Minimization Control of an IM Drive,“ *IEEE Transactions on Energy Conversion*, Jg. 23, Nr. 4, S. 1015–1024, 2008.
- [63] M. N. Uddin und S. W. Nam, „Development and Implementation of a Nonlinear-Controller-Based IM Drive Incorporating Iron Loss With Parameter Uncertainties,“ *IEEE Transactions on Industrial Electronics*, Jg. 56, Nr. 4, S. 1263–1272, 2009.

- [64] J.-W. Choi, D.-W. Chung und S.-K. Sul, „Implementation of Field Oriented Induction Machine Considering Iron Losses -, 1996. .,“ in *Applied Power Electronics Conference and Exposition*.
- [65] S. R. Eftekhari, S. A. Davari, P. Naderi, C. Garcia und J. Rodriguez, „Robust Loss Minimization for Predictive Direct Torque and Flux Control of an Induction Motor With Electrical Circuit Model,“ *IEEE Transactions on Power Electronics*, Jg. 35, Nr. 5, S. 5417–5426, 2020.
- [66] G. O. Garcia, J. A. Santisteban und S. D. Brignone, „Iron losses influence on a field-oriented controller,“ in *Proceedings of IECON'94 - 20th Annual Conference of IEEE Industrial Electronics*, IEEE, 1994, S. 633–638.
- [67] M. Hafner, M. Popescu, A. Boglietti und A. Cavagnino, „Analytic modeling of inverter-fed induction machines — A practical approach for matching measurement and simulation data,“ in *2014 International Conference on Electrical Machines (ICEM 2014)*, Piscataway, NJ: IEEE, 2014, S. 58–64.
- [68] O. Laldin, E. Djalala und A. Arkkio, „Circuit Models for Predicting Core Losses in the Stator and Rotor of a Caged Induction Machine With Sinusoidal Supplies,“ *IEEE Transactions on Magnetics*, Jg. 47, Nr. 5, S. 1054–1057, 2011.
- [69] E. Levi, A. Boglietti und M. Lazzari, „Comparative study of detuning effects in indirect rotor flux oriented induction machines due to iron core losses,“ in *Proceedings of 1995 International Conference on Power Electronics and Drive Systems. PEDS 95*, IEEE, 1995, S. 639–644.
- [70] D. M. Reed, H. F. Hofmann und J. Sun, „Offline Identification of Induction Machine Parameters With Core Loss Estimation Using the Stator Current Locus,“ *IEEE Transactions on Energy Conversion*, Jg. 31, Nr. 4, S. 1549–1558, 2016.
- [71] D. Hu, W. Xu, R. Dian und Y. Liu, „Loss Minimization Control Strategy for Linear Induction Machine in Urban Transit Considering Normal Force,“ *IEEE Transactions on Industry Applications*, Jg. 55, Nr. 2, S. 1536–1549, 2019.
- [72] W.-L. Chen, K.-M. Cheng und K.-F. Chen, „Derivation and verification of a vector controller for induction machines with consideration of stator and rotor core losses,“ *IET Electric Power Applications*, Jg. 12, Nr. 1, S. 1–11, 2018.
- [73] D. Buecherl und H.-G. Herzog, „Iron loss modeling by complex inductances for steady state simulation of electrical machines,“ in *SPEEDAM 2010*, IEEE, 2010, S. 878–883.
- [74] H. Neudorfer, E. Schmidt und F. Müllner, „Analytische Berechnung und messtechnischer Vergleich von Zusatzverlusten stromrichtergespeister Asynchron-Traktionsmaschinen,“ *e & i Elektrotechnik und Informationstechnik*, Jg. 128, Nr. 5, S. 142–150, 2011.

- [75] R. Kories und H. Schmidt-Walter, *Taschenbuch der Elektrotechnik: Grundlagen und Elektronik* (Edition Harri Deutsch), 10., korrigierte Auflage. Haan-Gruiten: Verlag Europa-Lehrmittel, 2013.
- [76] G. Bertotti, „General properties of power losses in soft ferromagnetic materials,“ *IEEE Transactions on Magnetics*, Jg. 24, Nr. 1, S. 621–630, 1988.
- [77] Wiedemann, Simon and Kennel, Ralph M., „Modelling of Inverter Nonlinear Effects: International Exhibition and Conference for Power Electronics, Intelligent Motion, Renewable Energy and Energy Management, Nuremberg, 5-7 June 2018 : proceedings,“ in *PCIM Europe 2018*.
- [78] Wiedemann, Simon and Kennel, Ralph M., „Accurate Self-identification of Inverter Nonlinear Effects in AC Drives: International Exhibition and Conference for Power Electronics, Intelligent Motion, Renewable Energy and Energy Management, Nuremberg, 5-7 June 2018 : proceedings,“ in.
- [79] N. T. West und R. D. Lorenz, „Digital Implementation of Stator and Rotor Flux-Linkage Observers and a Stator-Current Observer for Deadbeat Direct Torque Control of Induction Machines,“ *IEEE Transactions on Industry Applications*, Jg. 45, Nr. 2, S. 729–736, 2009.
- [80] G. Müller, K. Vogt und B. Ponick, *Berechnung elektrischer Maschinen* (Elektrische Maschinen), 6. completely new edited. Weinheim: Wiley-VCH Verlag GmbH & Co. KGaA, 2008, Bd. 2.
- [81] G. Müller, K. Vogt und B. Ponick, *Grundlagen elektrischer Maschinen* (Elektrische Maschinen), 6. completely new edited. Weinheim: Wiley-VCH, 2011, Bd. 2.
- [82] D. Schröder, *Elektrische Antriebe – Grundlagen*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2017.
- [83] R. Fischer, *Elektrische Maschinen* (Hanser-Fachbuch), 17. updated. München: Hanser, 2017.
- [84] E. Bolte, *Elektrische Maschinen*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018.
- [85] B. Robyns, B. Francois, P. Degobert und J. P. Hautier, *Vector Control of Induction Machines*. London: Springer London, 2012.
- [86] P. C. Krause, O. Wasynczuk, S. D. Sudhoff und S. Pekarek, *Analysis of electric machinery and drive systems* (IEEE Press series on power engineering), 3rd ed. Hoboken, NJ: Wiley, 2013, Bd. 37.
- [87] N. P. Quang und J.-A. Dittrich, *Vector Control of Three-Phase AC Machines*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2015.

- [88] Y. Liu und A. M. Bazzi, „A General Analytical Three-Phase Induction Machine Core Loss Model in the Arbitrary Reference Frame,“ *IEEE Transactions on Industry Applications*, Jg. 53, Nr. 5, S. 4210–4220, 2017.
- [89] M. Nachtsheim, M. Betz und C. Endisch, „Explicit Analytical Approach for Electromagnetic Modeling of Arbitrary Pole Pair Induction Machines,“ in *2022 12th International Conference on Power, Energy and Electrical Engineering (CPEEE 2022)*, S. 41–48.
- [90] C. B. Jacobina, J. Filho und A. Lima, „Estimating the parameters of induction machines at standstill,“ *IEEE Transactions on Energy Conversion*, Jg. 17, Nr. 1, S. 85–89, 2002.
- [91] A. Uphues, K. Notzold, R. Wegener und S. Soter, „Comparison of parameter identification approaches with linearised process models based on RLS for induction machines with $P > 100$ kW,“ S. 134–140,
- [92] R. P. Reddy Siddavatam und U. Loganathan, „Identification of Induction Machine parameters including Core Loss Resistance using Recursive Least Mean Square Algorithm: Convention Center, Lisbon, Portugal, 14-17 October, 2019 : proceedings: Identification of Induction Machine parameters,“ in S. 1095–1100.
- [93] A. Boglietti, R. Bojoi, A. Cavagnino und M. Lazzari, „Core loss estimation method for PWM inverter fed induction motors,“ in *IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society*, IEEE, 7.11.2010 - 10.11.2010, S. 811–816.
- [94] D. Chatterjee, „Impact of core losses on parameter identification of three-phase induction machines,“ *IET Power Electronics*, Jg. 7, Nr. 12, S. 3126–3136, 2014.
- [95] Y. Kouhi und J. Kertzscher, „An online nonlinear identification method for estimation of magnetizing curve and parameters of an induction motor,“ *IFAC-PapersOnLine*, Jg. 50, Nr. 1, S. 1577–1582, 2017.
- [96] M. Boussak und G. A. Capolino, „Recursive Least Squares Rotor Time Constant Identification for Vector Controlled Induction Machine,“ *Electric Machines & Power Systems*, Jg. 20, Nr. 2, S. 137–147, 1992.
- [97] D. Telford, M. W. Dunnigan und B. W. Williams, „Online identification of induction machine electrical parameters for vector control loop tuning,“ *IEEE Transactions on Industrial Electronics*, Jg. 50, Nr. 2, S. 253–261, 2003.
- [98] K. Wang, J. Chiasson, M. Bodson und L. M. Tolbert, „An Online Rotor Time Constant Estimator for the Induction Machine,“ *IEEE Transactions on Control Systems Technology*, Jg. 15, Nr. 2, S. 339–348, 2007.

- [99] P. Roncero-Sánchez, A. García-Cerrada und V. Feliu-Batlle, „Rotor-resistance estimation for induction machines with indirect-field orientation,“ *Control Engineering Practice*, Jg. 15, Nr. 9, S. 1119–1133, 2007.
- [100] J. Stephan, M. Bodson und J. Chiasson, „Real-time estimation of the parameters and fluxes of induction motors,“ *IEEE Transactions on Industry Applications*, Jg. 30, Nr. 3, S. 746–759, 1994.
- [101] M. Velez-Reyes, K. Minami und G. C. Verghese, „Recursive speed and parameter estimation for induction machines,“ *Conference Record of the IEEE Industry Applications Society Annual Meeting*, S. 607–611, 2002.
- [102] M. Cirrincione, M. Pucci, G. Cirrincione und G.-A. Capolino, „Constrained Minimization for Parameter Estimation of Induction Motors in Saturated and Unsaturated Conditions,“ *IEEE Transactions on Industrial Electronics*, Jg. 52, Nr. 5, S. 1391–1402, 2005.
- [103] D. C. Huynh, M. W. Dunnigan und S. J. Finney, „On-line parameter estimation of an induction machine using a recursive least-squares algorithm with multiple time-varying forgetting factors: Nov. 29, 2010 - Dec. 1, 2010, Kuala Lumpur, Malaysia,“ in S. 444–449.
- [104] A.-H. M. El-sayed und Y. S. Mohamed, „Online parameter estimation of an induction motor using recursive least squares method,“ *JES. Journal of Engineering Sciences*, Jg. 42, Nr. 1, S. 165–179, 2014.
- [105] Y. Koubaa, „Recursive identification of induction motor parameters,“ *Simulation Modelling Practice and Theory*, Jg. 12, Nr. 5, S. 363–381, 2004.
- [106] Y. Koubaa, „Asynchronous machine parameters estimation using recursive method,“ *Simulation Modelling Practice and Theory*, Jg. 14, Nr. 7, S. 1010–1021, 2006.
- [107] Y. S. Mohammed, B. M. Hasaneen, A. A. Elbaset und A. E. Hussein, „Recursive Least Square Algorithm for Estimating Parameters of an Induction Motor,“ *Journal of Engineering Sciences, Assiut University*, 2011.
- [108] V. Cecconi, M. Cirrincione und M. Pucci, *Guidelines for the Use of Different Least-Squares Techniques to the Identification of Induction Motors*, 2003.
- [109] J. Nocedal und S. J. Wright, *Numerical optimization* (Springer series in operations research), 2nd ed. New York: Springer, 2006.
- [110] M. Knudsen, „A Sensitivity Approach for Estimation of Physical Parameters,“ *IFAC Proceedings Volumes*, Jg. 27, Nr. 8, S. 533–538, 1994.
- [111] L. S. Ribeiro, C. B. Jacobina und A. Lima, „The influence of the slip and the speed in the parameter estimation of induction machines: 28th annual IEEE Power Electronics Specialists Conference,“ S. 1068–1074, 1997.

- [112] L. A. de Souza Ribeiro, C. B. Jacobina, A. Lima und A. C. Oliveira, „Real-time estimation of the electric parameters of an induction machine using sinusoidal PWM voltage waveforms,“ *IEEE Transactions on Industry Applications*, Jg. 36, Nr. 3, S. 743–754, 2000.
- [113] P. L. Jansen, R. D. Lorenz und D. W. Novotny, „Observer-based direct field orientation: analysis and comparison of alternative methods,“ *IEEE Transactions on Industry Applications*, Jg. 30, Nr. 4, S. 945–953, 1994.
- [114] V. Utkin, C. Jin und Z. Yan, „Sensorless sliding-mode control of induction motors,“ *IEEE Transactions on Industrial Electronics*, Jg. 47, Nr. 6, S. 1286–1297, 2000.
- [115] C. Lascu, I. Boldea und F. Blaabjerg, „A Class of Speed-Sensorless Sliding-Mode Observers for High-Performance Induction Motor Drives,“ *IEEE Transactions on Industrial Electronics*, Jg. 56, Nr. 9, S. 3394–3403, 2009.
- [116] K. L. Shi, T. F. Chan, Y. K. Wong und S. L. Ho, „Speed estimation of an induction motor drive using an optimized extended Kalman filter,“ *IEEE Transactions on Industrial Electronics*, Jg. 49, Nr. 1, S. 124–133, 2002.
- [117] M. Barut, S. Bogosyan und M. Gokasan, „Speed-Sensorless Estimation for Induction Motors Using Extended Kalman Filters,“ *IEEE Transactions on Industrial Electronics*, Jg. 54, Nr. 1, S. 272–280, 2007.
- [118] B. Akin, U. Orguner und A. Ersak, „State estimation of induction motor using unscented Kalman filter,“ in *Proceedings of 2003 IEEE Conference on Control Applications, 2003. CCA 2003*, IEEE, 2003, S. 915–919.
- [119] S. Jafarzadeh, C. Lascu und M. S. Fadali, „State Estimation of Induction Motor Drives Using the Unscented Kalman Filter,“ *IEEE Transactions on Industrial Electronics*, Jg. 59, Nr. 11, S. 4207–4216, 2012.
- [120] L. Salvatore, S. Stasi und L. Tarchioni, „A new EKF-based algorithm for flux estimation in induction machines,“ *IEEE Transactions on Industrial Electronics*, Jg. 40, Nr. 5, S. 496–504, 1993.
- [121] L.-C. Zai, C. L. DeMarco und T. A. Lipo, „An extended Kalman filter approach to rotor time constant measurement in PWM induction motor drives,“ *IEEE Transactions on Industry Applications*, Jg. 28, Nr. 1, S. 96–104, 1992.
- [122] R. S. Pena und G. M. Asher, „Parameter sensitivity studies for induction motor parameter identification using extended Kalman filters,“ *The European Power Electronics Association*, 1993.

- [123] R. Dadkhah, H. Givi und A. Mehdipour, „Parameter estimation of the induction motor using extended Kalman filter for wide range speed control,“ in *The 6th Power Electronics, Drive Systems & Technologies Conference (PEDSTC2015)*, IEEE, 2015, S. 137–142.
- [124] R. Demir, M. Barut, R. Yildiz, R. Inan und E. Zerdali, „EKF based rotor and stator resistance estimations for direct torque control of Induction Motors,“ in *2017 International Conference on Optimization of Electrical and Electronic Equipment (OPTIM) & 2017 Intl Aegean Conference on Electrical Machines and Power Electronics (ACEMP)*, IEEE, 25.05.2017 - 27.05.2017, S. 376–381.
- [125] D. J. Atkinson, P. P. Acarnley und J. W. Finch, „Observers for induction motor state and parameter estimation,“ *IEEE Transactions on Industry Applications*, Jg. 27, Nr. 6, S. 1119–1127, 1991.
- [126] M. Rayyam, M. Zazi, Y. Hajji und I. Chtouki, „Stator and rotor faults detection in Induction Motor (IM) using the Extended Kaman Filter (EKF),“ in *2016 International Conference on Electrical and Information Technologies (ICEIT)*, IEEE, 2016, S. 148–152.
- [127] T. Ameid, A. Menacer, H. Talhaoui und I. Harzelli, „Rotor resistance estimation using Extended Kalman filter and spectral analysis for rotor bar fault diagnosis of sensorless vector control induction motor,“ *Measurement*, Jg. 111, S. 243–259, 2017.
- [128] V. Leite, R. Araujo und D. Freitas, „Flux and parameters identification of vector-controlled induction motor in the rotor reference frame,“ S. 263–268, 2002.
- [129] S. AKSOY, A. Mühürçü und H. Kızmaz, „State and Parameter Estimation in Induction Motor Using the Extended Kalman Filtering Algorithm,“ in *Modern Electric Power Systems 2010*.
- [130] J. Laowanitwattana und S. Uatrongjit, „Estimation of induction motor states and parameters based on Extended Kalman Filter considering parameter constraints,“ in *2016 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*, Piscataway, NJ: IEEE, 2016, S. 755–760.
- [131] T. Iwasaki und T. Kataoka, „Application of an extended Kalman filter to parameter identification of an induction motor,“ *Industry Applications Society Annual Meeting*, 1989.
- [132] E. Laroche, E. Sedda und C. Durieu, „Methodological Insights for Online Estimation of Induction Motor Parameters,“ *IEEE Transactions on Control Systems Technology*, Jg. 16, Nr. 5, S. 1021–1028, 2008.

- [133] G. L. L. Loron, „Application of the extended Kalman filter to parameters estimation of induction motors,“ *Fifth European Conference on Power Electronics and Applications*, 1993.
- [134] R. Jaramillo, R. Alvarez, V. Urdenas und C. Nunez, „Identification of induction motor parameter using an extended Kalman filter,“ in *(ICEEE). 1st International Conference on Electrical and Electronics Engineering, 2004*, IEEE, 2004, S. 584–588.
- [135] O. Buchholz, J. Bocker und J. Bonifacio, „Online-Identification of the Induction Machine Parameters Using the Extended Kalman Filter,“ in *2018 XIII International Conference on Electrical Machines (ICEM)*, IEEE, 3.09.2018 - 06.09.2018, S. 1623–1629.
- [136] V. Lesic, M. Vasak, G. Stojicic, N. Peric, G. Joksimovic, T. M. Wolbank, *State and Parameter Estimation for Field-oriented Control of Induction Machine Based on Unscented Kalman Filter: 20 - 22 June 2012, Sorrento (Italy) ; proceedings*. Piscataway, NJ: IEEE, 2012.
- [137] R. Yildiz, M. Barut und E. Zerdali, „A Comprehensive Comparison of Extended and Unscented Kalman Filters for Speed-Sensorless Control Applications of Induction Motors,“ *IEEE Transactions on Industrial Informatics*, Jg. 16, Nr. 10, S. 6423–6432, 2020.
- [138] M. M. Mansouri, M. M. Mohamed-Seghir, H. N. Nounou, M. N. Nounou und H. A. Abu-Rub, „Bayesian methods for time-varying state and parameter estimation in induction machines,“ *International Journal of Adaptive Control and Signal Processing*, Jg. 29, Nr. 7, S. 905–924, 2015.
- [139] I. N. Bronshtein und K. A. Semendyayev, *Handbook of mathematics*, 3., completely rev. ed. Thun u. a.: Deutsch und VanNostrand Reinhold, 1985.
- [140] K. Ogata, *Modern control engineering*, 3. ed. Upper Saddle River, NJ und London: Prentice Hall und Prentice-Hall International, 1997.
- [141] R. Hermann und A. Krener, „Nonlinear controllability and observability,“ *IEEE Transactions on Automatic Control*, Jg. 22, Nr. 5, S. 728–740, 1977.
- [142] B. Southall, B. F. Buxton und J. A. Marchant, „Controllability and Observability: Tools for Kalman Filter Design,“ in *Proceedings of the British Machine Vision Conference 1998*, M. Nixon, P. Lewis und J. Carter, Hrsg., British Machine Vision Association, 1998, S. 17.1–17.10.
- [143] C. Canudas De Wit, A. Youssef, J. P. Barbot, P. Martin und F. Malrait, „Observability conditions of induction motors at low frequencies,“ in *Proceedings of the 39th IEEE Conference on Decision and Control (Cat. No.00CH37187)*, IEEE, 2000, S. 2044–2049.

- [144] G. Lefebvre, X. Lin-Shi, M. Nadri, J.-Y. Gauthier und A. Hijazi, „Observability measurement and control strategy for induction machine sensorless drive in traction applications,“ *IFAC-PapersOnLine*, Jg. 50, Nr. 1, S. 15 773–15 779, 2017.
- [145] P. Vaclavek, P. Blaha und I. Herman, „AC Drive Observability Analysis,“ *IEEE Transactions on Industrial Electronics*, Jg. 60, Nr. 8, S. 3047–3059, 2013.
- [146] M. Nakhaeinejad und M. D. Bryant, „Observability analysis for model-based fault detection and sensor selection in induction motors,“ *Measurement Science and Technology*, Jg. 22, Nr. 7, S. 075 202, 2011.
- [147] L. Papula, *Mathematische Formelsammlung*. Wiesbaden: Springer Fachmedien Wiesbaden, 2014.
- [148] Y.-T. Chiang, L.-S. Wang und F.-R. Chang, „Filtering method for nonlinear systems with constraints,“ *IEE Proceedings - Control Theory and Applications*, Jg. 149, Nr. 6, S. 525–531, 2002.
- [149] D. Simon und T. L. Chia, „Kalman filtering with state equality constraints,“ *IEEE Transactions on Aerospace and Electronic Systems*, Jg. 38, Nr. 1, S. 128–136, 2002.
- [150] G. Nachi, „Kalman Filtering in the Presence of State Space Equality Constraints,“ in *2007 Chinese Control Conference*, IEEE, 2006, S. 107–113.
- [151] W. Böhm und G. Gose, *Einführung in die Methoden der Numerischen Mathematik*. Wiesbaden: Vieweg+Teubner Verlag, 1977.
- [152] J.-C. Trigeassou, *Electrical machines diagnosis*. London und Hoboken, N.J: Wiley, 2011.
- [153] A. Bonnett und C. Yung, „Increased Efficiency Versus Increased Reliability,“ *IEEE Industry Applications Magazine*, Jg. 14, Nr. 1, S. 29–36, 2008.
- [154] M. El Hachemi Benbouzid, „A review of induction motors signature analysis as a medium for faults detection,“ *IEEE Transactions on Industrial Electronics*, Jg. 47, Nr. 5, S. 984–993, 2000.
- [155] S. H. Kia, H. Henao und G.-A. Capolino, „A High-Resolution Frequency Estimation Method for Three-Phase Induction Machine Fault Detection,“ *IEEE Transactions on Industrial Electronics*, Jg. 54, Nr. 4, S. 2305–2314, 2007.
- [156] G. Andria, M. Savino und A. Trotta, „Application of Wigner-Ville distribution to measurements on transient signals,“ *IEEE Transactions on Instrumentation and Measurement*, Jg. 43, Nr. 2, S. 187–193, 1994.
- [157] M. Benbouzid und G. B. Kliman, „What stator current processing-based technique to use for induction motor rotor faults diagnosis?“ *IEEE Transactions on Energy Conversion*, Jg. 18, Nr. 2, S. 238–244, 2003.

- [158] B. Mirafzal und N. Demerdash, „Induction Machine Broken-Bar Fault Diagnosis Using the Rotor Magnetic Field Space-Vector Orientation,“ *IEEE Transactions on Industry Applications*, Jg. 40, Nr. 2, S. 534–542, 2004.
- [159] M. Sahraoui, A. Ghogal, S. E. Zouzou und M. E. Benbouzid, „Dynamic eccentricity in squirrel cage induction motors – Simulation and analytical study of its spectral signatures on stator currents,“ *Simulation Modelling Practice and Theory*, Jg. 16, Nr. 9, S. 1503–1513, 2008.
- [160] I. P. Georgakopoulos, E. D. Mitronikas und A. N. Safacas, „Detection of Induction Motor Faults in Inverter Drives Using Inverter Input Current Analysis,“ *IEEE Transactions on Industrial Electronics*, Jg. 58, Nr. 9, S. 4365–4373, 2011.
- [161] P. M. de La Barrera, M. Otero, T. Schallschmidt, G. R. Bossio und R. Leidhold, „Active Broken Rotor Bar Diagnosis in Induction Motor Drives,“ *IEEE Transactions on Industrial Electronics*, Jg. 68, Nr. 8, S. 7556–7566, 2021.
- [162] J. Pons-Llinares, J. A. Antonino-Daviu, M. Riera-Guasp, M. Pineda-Sanchez und V. Climente-Alarcon, „Induction Motor Diagnosis Based on a Transient Current Analytic Wavelet Transform via Frequency B-Splines,“ *IEEE Transactions on Industrial Electronics*, Jg. 58, Nr. 5, S. 1530–1544, 2011.
- [163] M. Kang und J.-M. Kim, „Reliable Fault Diagnosis of Multiple Induction Motor Defects Using a 2-D Representation of Shannon Wavelets,“ *IEEE Transactions on Magnetics*, Jg. 50, Nr. 10, S. 1–13, 2014.
- [164] C. Kral, T. G. Habetler und R. G. Harley, „Detection of Mechanical Imbalances of Induction Machines Without Spectral Analysis of Time-Domain Signals,“ *IEEE Transactions on Industry Applications*, Jg. 40, Nr. 4, S. 1101–1106, 2004.
- [165] M. Pineda-Sanchez, M. Riera-Guasp, J. Roger-Folch, J. A. Antonino-Daviu, J. Perez-Cruz und R. Puche-Panadero, „Diagnosis of Induction Motor Faults in Time-Varying Conditions Using the Polynomial-Phase Transform of the Current,“ *IEEE Transactions on Industrial Electronics*, Jg. 58, Nr. 4, S. 1428–1439, 2011.
- [166] A. Sapena-Bano, M. Pineda-Sanchez, R. Puche-Panadero, J. Martinez-Roman und Z. Kanovic, „Low-Cost Diagnosis of Rotor Asymmetries in Induction Machines Working at a Very Low Slip Using the Reduced Envelope of the Stator Current,“ *IEEE Transactions on Energy Conversion*, Jg. 30, Nr. 4, S. 1409–1419, 2015.
- [167] A. Sapena-Bano, M. Pineda-Sanchez, R. Puche-Panadero, J. Martinez-Roman und D. Matic, „Fault Diagnosis of Rotating Electrical Machines in Transient Regime Using a Single Stator Current’s FFT,“ *IEEE Transactions on Instrumentation and Measurement*, Jg. 64, Nr. 11, S. 3137–3146, 2015.

- [168] M. Eftekhari, M. Moallem, S. Sadri und M.-F. Hsieh, „Online Detection of Induction Motor’s Stator Winding Short-Circuit Faults,“ *IEEE Systems Journal*, Jg. 8, Nr. 4, S. 1272–1282, 2014.
- [169] O. Ondel, G. Clerc, E. Boutleux und E. Blanco, „Fault Detection and Diagnosis in a Set “Inverter–Induction Machine” Through Multidimensional Membership Function and Pattern Recognition,“ *IEEE Transactions on Energy Conversion*, Jg. 24, Nr. 2, S. 431–441, 2009.
- [170] K. Kim und A. G. Parlos, „Induction motor fault diagnosis based on neuropredictors and wavelet signal processing,“ *IEEE/ASME Transactions on Mechatronics*, Jg. 7, Nr. 2, S. 201–219, 2002.
- [171] Ryad Zemouri und Rafael Gouriveau, „Towards Accurate and Reproducible Predictions for Prognostic: an Approach Combining a RRBf Network and an AutoRegressive Model,“ *IFAC Proceedings Volumes*, Jg. 43, Nr. 3, S. 140–145, 2010.
- [172] S. Shao, R. Yan, Y. Lu, P. Wang und R. X. Gao, „DCNN-Based Multi-Signal Induction Motor Fault Diagnosis,“ *IEEE Transactions on Instrumentation and Measurement*, Jg. 69, Nr. 6, S. 2658–2669, 2020.
- [173] Y. Tang, X. Zhang, G. Qin u. a., „Graph Cardinality Preserved Attention Network for Fault Diagnosis of Induction Motor Under Varying Speed and Load Condition,“ *IEEE Transactions on Industrial Informatics*, Jg. 18, Nr. 6, S. 3702–3712, 2022.
- [174] G. Salles, F. Filippetti, C. Tassoni, G. Crellet und G. Franceschini, „Monitoring of induction motor load by neural network techniques,“ *IEEE Transactions on Power Electronics*, Jg. 15, Nr. 4, S. 762–768, 2000.
- [175] S. M. K. Zaman und X. Liang, „An Effective Induction Motor Fault Diagnosis Approach Using Graph-Based Semi-Supervised Learning,“ *IEEE Access*, Jg. 9, S. 7471–7482, 2021.
- [176] J. F. Martins, V. F. Pires und A. J. Pires, „Unsupervised Neural-Network-Based Algorithm for an On-Line Diagnosis of Three-Phase Induction Motor Stator Fault,“ *IEEE Transactions on Industrial Electronics*, Jg. 54, Nr. 1, S. 259–264, 2007.
- [177] W. Sun, R. Zhao, R. Yan, S. Shao und X. Chen, „Convolutional Discriminative Feature Learning for Induction Motor Fault Diagnosis,“ *IEEE Transactions on Industrial Informatics*, Jg. 13, Nr. 3, S. 1350–1359, 2017.
- [178] T. Ince, S. Kiranyaz, L. Eren, M. Askar und M. Gabbouj, „Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks,“ *IEEE Transactions on Industrial Electronics*, Jg. 63, Nr. 11, S. 7067–7075, 2016.

- [179] H. Nejari und M. Benbouzid, „Monitoring and diagnosis of induction motors electrical faults using a current Park’s vector pattern learning approach,“ *IEEE Transactions on Industry Applications*, Jg. 36, Nr. 3, S. 730–735, 2000.
- [180] A. Giantomassi, F. Ferracuti, S. Iarlori, G. Ippoliti und S. Longhi, „Electric Motor Fault Detection and Diagnosis by Kernel Density Estimation and Kullback–Leibler Divergence Based on Stator Current Measurements,“ *IEEE Transactions on Industrial Electronics*, Jg. 62, Nr. 3, S. 1770–1780, 2015.
- [181] Y. Yagami, C. Araki, Y. Mizuno und H. Nakamura, „Turn-to-turn insulation failure diagnosis of stator winding of low voltage induction motor with the aid of support vector machine,“ *IEEE Transactions on Dielectrics and Electrical Insulation*, Jg. 22, Nr. 6, S. 3099–3106, 2015.
- [182] S. E. Pandarakone, Y. Mizuno und H. Nakamura, „Frequency spectrum investigation and analytical diagnosis method for turn-to-turn short-circuit insulation failure in stator winding of low voltage induction motor,“ *IEEE Transactions on Dielectrics and Electrical Insulation*, Jg. 23, Nr. 6, S. 3249–3255, 2016.
- [183] J. C. Quiroz, N. Mariun, M. R. Mehrjou, M. Izadi, N. Misron und M. A. Mohd Radzi, „Fault detection of broken rotor bar in LS-PMSM using random forests,“ *Measurement*, Jg. 116, S. 273–280, 2018.
- [184] A. Prinzie und D. van den Poel, „Random Multiclass Classification: Generalizing Random Forests to Random MNL and Random NB,“ *Lecture Notes in Computer Science*, Nr. 4653, S. 349–358, 2007.
- [185] F. Zidani, M. El Hachemi Benbouzid, D. Diallo und M. S. Nait-Said, „Induction motor stator faults diagnosis by a current concordia pattern-based fuzzy decision system,“ *IEEE Transactions on Energy Conversion*, Jg. 18, Nr. 4, S. 469–475, 2003.
- [186] F. Zidani, D. Diallo, M. E. H. Benbouzid und R. Nait-Said, „A Fuzzy-Based Approach for the Diagnosis of Fault Modes in a Voltage-Fed PWM Inverter Induction Motor Drive,“ *IEEE Transactions on Industrial Electronics*, Jg. 55, Nr. 2, S. 586–593, 2008.
- [187] Hasan Ocak und Kenneth Loparo, „Online tracking of bearing wear using wavelet packet decomposition and probabilistic modeling: A method for bearing prognostics,“ *Journal of Sound and Vibration*, 2007.
- [188] G. Georgoulas, M. O. Mustafa, I. P. Tsoumas u. a., „Principal Component Analysis of the start-up transient and Hidden Markov Modeling for broken rotor bar fault diagnosis in asynchronous machines,“ *Expert Systems with Applications*, Jg. 40, Nr. 17, S. 7024–7033, 2013.

- [189] S. Altug, M.-Y. Chen und H. J. Trussell, „Fuzzy inference systems implemented on neural architectures for motor fault detection and diagnosis,“ *IEEE Transactions on Industrial Electronics*, Jg. 46, Nr. 6, S. 1069–1079, 1999.
- [190] M. A. Awadallah und M. M. Morcos, „Application of AI tools in fault diagnosis of electrical machines and drives-an overview,“ *IEEE Transactions on Energy Conversion*, Jg. 18, Nr. 2, S. 245–251, 2003.
- [191] M. S. Ballal, Z. J. Khan, H. M. Suryawanshi und R. L. Sonolikar, „Adaptive Neural Fuzzy Inference System for the Detection of Inter-Turn Insulation and Bearing Wear Faults in Induction Motor,“ *IEEE Transactions on Industrial Electronics*, Jg. 54, Nr. 1, S. 250–258, 2007.
- [192] S. Yusuf, D. J. Brown, A. Mackinnon und R. Papanicolaou, „Fault classification improvement in industrial condition monitoring via Hidden Markov Models and Naïve Bayesian modeling,“ in *2013 IEEE Symposium on Industrial*, S. 75–80.
- [193] M. Said, M. Benbouzid und A. Benchaib, „Detection of broken bars in induction motors using an extended Kalman filter for rotor resistance sensorless estimation,“ *IEEE Transactions on Energy Conversion*, Jg. 15, Nr. 1, S. 66–70, 2000.
- [194] D. Luenberger, „An introduction to observers,“ *IEEE Transactions on Automatic Control*, Jg. 16, Nr. 6, S. 596–602, 1971.
- [195] S. Cruz, A. Stefani, F. Filippetti und A. Cardoso, „A New Model-Based Technique for the Diagnosis of Rotor Faults in RFOC Induction Motor Drives,“ *IEEE Transactions on Industrial Electronics*, Jg. 55, Nr. 12, S. 4218–4228, 2008.
- [196] R. Shahnazi, Q. Zhao, A. H. A. Sari und T. Jeinsch, „Dynamic nonlinear unknown input observer for fault detection of induction motors,“ in *2015 23rd Iranian Conference on Electrical Engineering*, IEEE, 2015, S. 823–828.
- [197] S. Bachir, S. Thani, J.-C. Trigeassou und G. Champenois, „Diagnosis by parameter estimation of stator and rotor faults occurring in induction machines,“ *IEEE Transactions on Industrial Electronics*, Jg. 53, Nr. 3, S. 963–973, 2006.
- [198] M. A. Rodriguez-Blanco, V. Golikov, R. Osorio-Sánchez u. a., „Fault Diagnosis of Induction Motor Using D-Q Simplified Model and Parity Equations,“ *Energies*, Jg. 15, Nr. 22, S. 8372, 2022.
- [199] A. Fuller, Z. Fan, C. Day und C. Barlow, „Digital Twin: Enabling Technologies, Challenges and Open Research,“ *IEEE Access*, Jg. 8, S. 108 952–108 971, 2020.
- [200] T. D. Lopes, A. Raizer und W. Valente Júnior, „The Use of Digital Twins in Finite Element for the Study of Induction Motors Faults,“ *Sensors (Basel, Switzerland)*, Jg. 21, Nr. 23, 2021.

- [201] A. Rassolkin, V. Rjabtsikov, V. Kuts u. a., „Interface Development for Digital Twin of an Electric Motor Based on Empirical Performance Model,“ *IEEE Access*, Jg. 10, S. 15 635–15 643, 2022.
- [202] R. Isermann, „Fault diagnosis of machines via parameter estimation and knowledge processing—Tutorial paper,“ *Automatica*, Jg. 29, Nr. 4, S. 815–835, 1993.
- [203] P. Coirault, J. C. Trigeassou, J. P. Gaubert und G. Champenois, „Parameter Identification of an Induction Machine for Diagnosis,“ *IFAC Proceedings Volumes*, Jg. 30, Nr. 18, S. 265–270, 1997.
- [204] F. Karami, J. Poshtan und M. Poshtan, „Detection of broken rotor bars in induction motors using nonlinear Kalman filters,“ *ISA transactions*, Jg. 49, Nr. 2, S. 189–195, 2010.
- [205] J. Zarei, E. Kowsari und R. Razavi-Far, „Induction Motors Fault Detection Using Square-Root Transformed Cubature Quadrature Kalman Filter,“ *IEEE Transactions on Energy Conversion*, Jg. 34, Nr. 2, S. 870–877, 2019.
- [206] I. Bejaoui, D. Bruneo und M. G. Xibilia, „Remaining Useful Life Prediction of Broken Rotor Bar Based on Data-Driven and Degradation Model,“ *Applied Sciences*, Jg. 11, Nr. 16, S. 7175, 2021.
- [207] K. P. Murphy, *Machine learning: A probabilistic perspective* (Adaptive computation and machine learning series). Cambridge MA: MIT Press, 2012.
- [208] P. Thosar, J. Patil, M. Singh, S. Thamke und S. Gonge, „Prediction of Motor Temperature using Linear Regression,“ in *Proceedings of the International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE 2020)*, S. K. Niranjana, Hrsg., Piscataway, NJ: IEEE, 2020, S. 7–12.
- [209] C. Negoita und M. Praisler, „Logistic regression classification model identifying drugs of abuse based on their ATR-FTIR spectra: Case study on LASSO and Ridge regularization methods,“ in *2019 6th International Symposium on Electrical and Electronics Engineering (ISEEE)*, 2019, S. 1–4.
- [210] I. Goodfellow, Y. Bengio und A. Courville, *Deep learning* (Adaptive computation and machine learning). Cambridge, Massachusetts und London, England: The MIT Press, 2016.
- [211] C. Nwankpa, W. Ijomah, A. Gachagan und S. Marshall, „Activation Functions: Comparison of trends in Practice and Research for Deep Learning,“ *arXiv:1811.03378*, 2018.
- [212] Xavier Glorot, Antoine Bordes und Yoshua Bengio, „Deep Sparse Rectifier Neural Networks,“ in *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, Bd. 15, S. 315–323.

-
- [213] I. Steinwart und A. Christmann, *Support vector machines* (Information science and statistics). New York, NY: Springer, 2008.
- [214] P. G. Anselma, „Optimization-Driven Powertrain-Oriented Adaptive Cruise Control to Improve Energy Saving and Passenger Comfort,“ *Energies*, Jg. 14, Nr. 10, S. 2897, 2021.
- [215] T. P. Bohlin, *Practical Grey-box Process Identification: Theory and Applications* (Advances in Industrial Control). Springer London, 2006.
- [216] T. Brychcy, *Modellierung dynamischer Systeme mit vorstrukturierten neuronalen Netzen: Zugl.: München, Techn. Univ., Diss, 1999* (DISKI, Dissertationen zur künstlichen Intelligenz). Berlin: Akad. Verl.-Ges. Aka, 2000, Bd. 229.
- [217] C. Endisch, „Optimierungsstrategien für die Identifikation mechatronischer Systeme,“ Dissertation, Technische Universität München, München, 2009.
- [218] K. Levenberg, „A method for the solution of certain non-linear problems in least squares,“ *Quarterly of Applied Mathematics*, Jg. 2, Nr. 2, S. 164–168, 1944.
- [219] D. W. Marquardt, „An Algorithm for Least-Squares Estimation of Nonlinear Parameters,“ *Journal of the Society for Industrial and Applied Mathematics*, Jg. 11, Nr. 2, S. 431–441, 1963.