



TECHNISCHE UNIVERSITÄT MÜNCHEN
TUM School of Engineering and Design

Optimierte Schätzverfahren für intelligente Batteriesysteme

Dominik Schneider

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.-Ing. Andreas Jossen

Prüfende der Dissertation:

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

Die Dissertation wurde am 7. Juni 2023 bei der Technischen Universität München eingereicht und durch die TUM School of Engineering and Design am 25. Dezember 2023 angenommen.

Vorwort

Diese Arbeit entstand im Rahmen meiner Tätigkeit als wissenschaftlicher Mitarbeiter an der Technischen Hochschule Ingolstadt in der Forschungsgruppe Elektromobilität und lernfähige Systeme. Dort arbeitete ich in einem Forschungsprojekt zum Thema „Intelligente Batteriesysteme“ in Kooperation mit der Abteilung für die Entwicklung von Hochvolt-Batteriesystemen der AUDI AG in Ingolstadt.

Zunächst möchte ich mich bei meinem Doktorvater Prof. Christian Endisch, der Leiter der Forschungsgruppe Elektromobilität und lernfähige System an der Technischen Hochschule Ingolstadt ist, für die wissenschaftliche Betreuung bedanken. Weiterhin geht mein Dank an Prof. Ralph Kennel vom Lehrstuhl für elektrische Antriebssysteme und Leistungselektronik der Technischen Universität München für die gewährte wissenschaftliche Freiheit und die wertvolle Unterstützung des Projekts. Er hat mein Promotionsprojekt von Seiten der TU München betreut.

Mein Dank gilt außerdem Dr. Michael Hinterberger, der das Forschungsprojekt von Seiten der AUDI AG betreut hat. Sein visionäres Denken hat das Forschungsprojekt zu intelligenten Batteriesystemen erst ermöglicht und entscheidend geprägt. Der AUDI AG selbst danke ich für die langjährige Unterstützung der Forschungsgruppe allgemein und des Forschungsprojekts im Speziellen.

Ganz herzlich möchte ich mich bei allen Kollegen der Forschungsgruppe bedanken, mit denen ich in den vergangenen Jahren zusammengearbeitet habe. Die hilfsbereite Arbeitsatmosphäre, das kollegiale Miteinander und die fachlichen Diskussionen haben meine Forschung entscheidend vorangebracht. Insbesondere bedanke ich mich für die Vorarbeiten beim Aufbau der Laborinfrastruktur und Prototypen, ohne die meine Arbeit nicht hätte verwirklicht werden können. Die Gemeinschaft und den Forschergeist in einem großen Forschungsprojekt mit Kollegen aus unterschiedlichen Disziplinen der Ingenieurs- und Naturwissenschaften habe ich als sehr bereichernd erlebt. Insbesondere bedanken möchte ich mich bei Dr. Lidiya Komsijska und Dr.-Ing. Jan Kleiner für die Durchsicht und Korrektur dieser Arbeit. Außerdem danke ich Moritz Ehrensberger, Andreas Kühne, Lena Riester, Dominic Schober und Michael Theiler für deren Mitarbeit in meinem Forschungsprojekt durch ihre Studienarbeiten.

Mein letzter und wichtigster Dank gilt meiner Frau Teresa sowie meinen Eltern für die fortwährende Unterstützung – nicht nur, aber besonders während meiner Forschungstätigkeit der letzten Jahre.

Georgensmünd, April 2024

Kurzfassung

Der Traktionsbatterie kommt als wichtiger Komponente des elektrischen Antriebsstrangs eine große Bedeutung bei der Entwicklung moderner Fahrzeuge für die emissionsfreie Mobilität zu. Die vorliegende Arbeit untersucht Schätzverfahren für die Anwendung im Batteriemanagementsystem von Elektrofahrzeugen, wobei ein Fokus auf dem Potenzial und den Besonderheiten intelligenter Batteriesysteme liegt. Für die Zustandsschätzung des Ladezustands, des Innenwiderstands sowie weiterer Parameter des Batterie-Ersatzschaltbildmodells werden Kalman-Filter eingesetzt und entsprechend der spezifischen Anforderungen modifiziert. Das zugrunde liegende Modell der Batteriezellen muss zuvor durch Identifikationsverfahren parametrisiert werden. Neben der Analyse der Beobachtbarkeit verschiedener Systemordnungen liegt ein Schwerpunkt dieser Arbeit auf der optimalen Parametrierung des Kalman-Filters. Hierfür kommt eine Mehrziel-Optimierung mithilfe des genetischen Algorithmus zur Anwendung. Inwiefern durch Schaltoperationen eines rekonfigurierbaren Batteriesystems die Systemanregung erhöht und dadurch die Parameterschätzung weiter verbessert werden kann, ist ebenfalls eine Forschungsfrage dieser Arbeit.

Die adaptive Bestimmung der Zustände und Parameter des Batteriemodells erlaubt die Anwendung einer modellbasierten Sensordatenfusion, mit welcher die Signale der Zellstrom- und Zellspannungssensoren miteinander kombiniert werden. Das Ziel der Sensordatenfusion ist eine Reduktion der Messunsicherheit bei einer gleichzeitig erhöhten Robustheit des Messsystems. Grundlage des Verfahrens ist eine robuste Innenwiderstandsschätzung, welche mithilfe eines modifizierten Dual-Kalman-Filters realisiert wird. Die Sensordatenfusion wird schließlich ergänzt um eine Schätzmethode für die Varianz des Sensorrauschens, wodurch die Sensormesswerte in der Sensordatenfusion adaptiv gewichtet werden.

Abstract

The battery of an electric vehicle is an important component of the powertrain. Thus, it is of major significance for the development of modern vehicles for emission-free mobility. In this work, state and parameter estimation for the application in the battery management system of electric vehicles is investigated. A special focus is on the potential and characteristics of intelligent battery systems. For the estimation of the state of charge, the ohmic resistance and other parameters of the battery equivalent circuit model, Kalman filters are applied and optimized regarding the specific requirements of this application. The underlying battery model is parameterized by characterization tests in advance. Furthermore, the observability for different numbers of system orders is analyzed, and the Kalman filter is tuned optimally with the help of a multi-objective optimization based on the genetic algorithm. A further research question of this work is, how system excitation of a reconfigurable battery system is increased by switching operation and how parameter estimation is thereby improved.

The adaptive identification of the battery model's states and parameters enables the application of a model-based sensor data fusion, which combines cells' current and voltage measurement. The goal of the sensor data fusion is to decrease the measurement uncertainty and to enhance the measurement system's overall robustness. The approach is based on a robust estimation of the cells' ohmic resistances, which is obtained by an optimized dual Kalman filter. Finally, the sensor data fusion is supplemented by an estimation method for the sensor noise variance. Thereby, the sensor measurements are weighted adaptively in the sensor data fusion algorithm.

Inhaltsverzeichnis

Inhaltsverzeichnis	5
1 Einleitung	8
1.1 Hintergrund und Motivation	8
1.2 Zielsetzung und Beiträge dieser Arbeit	11
1.3 Gliederung der Arbeit	12
2 Grundlagen zu Lithium-Ionen-Zellen und Batteriesystemen	14
2.1 Funktionsweise und Aufbau von Lithium-Ionen-Zellen	14
2.2 Batteriemangementsysteme	17
2.3 Batteriesysteme im Antriebsstrang von Elektrofahrzeugen	18
2.4 Intelligente Batteriesysteme	20
2.5 Definition wichtiger Begriffe	22
3 Modellierung von Lithium-Ionen-Zellen und -Batteriesystemen	25
3.1 Modelle von Batteriezellen und -systemen	25
3.1.1 Modellierungsansätze für Lithium-Ionen-Zellen	25
3.1.2 Elektrisches Ersatzschaltbildmodell der Lithium-Ionen-Zelle	27
3.1.3 Modellierung von Batteriesystemen	31
3.1.4 Einfluss von Parametervariationen	35
3.1.5 Modellierung von rekonfigurierbaren Batteriesystemen	37
3.2 Parameteridentifikation des Ersatzschaltbildmodells	41
3.2.1 Vorstellung der verwendeten Batteriezelle	43
3.2.2 Beschreibung der durchgeführten Versuche zur Parameteridentifikation	43
3.2.3 Ergebnisse der Parameteridentifikation	51
3.2.4 Schlussfolgerungen für die Online-Parameterschätzung	54
4 Zustands- und Parameterschätzung im Batteriemangementsystem	56
4.1 Modellbasierte Zustandsschätzverfahren	56
4.1.1 Luenberger-Beobachter	58
4.1.2 Lineares Kalman-Filter	60
4.1.3 Erweiterungen für nichtlineare Systeme	65
4.1.4 Dual-Kalman-Filter	69
4.1.5 Versuchsdurchführung und Methodik zur Beurteilung der Filtergüte	71
4.2 Untersuchung der Beobachtbarkeit	76
4.2.1 Strukturelle Beobachtbarkeit	77
4.2.2 Beobachtbarkeitskriterium von Kalman	79
4.2.3 Quantifizierung der Beobachtbarkeit durch den Beobachtbarkeitsindex	82

4.2.4	Beobachtbarkeit des Dual-Kalman-Filters	87
4.2.5	Schlussfolgerungen für die Anwendung	88
4.3	Methoden zur Parametrierung des Kalman-Filters	89
4.3.1	Stand der Wissenschaft zum Filter-Tuning	89
4.3.1.1	Analytische Abschätzung von Prozess- und Messrauschen	90
4.3.1.2	Klassische Verfahren des Filter-Tunings	91
4.3.1.3	Adaptive Kalman-Filter	94
4.3.1.4	Filter-Tuning als Optimierungsproblem	96
4.3.2	Multikriterielle Optimierung zur Bestimmung des Prozessrauschens	98
4.3.2.1	Vorstellung des Optimierungsalgorithmus	98
4.3.2.2	Ergebnisse und Bewertung	103
4.3.3	Fazit zum Filter-Tuning	108
4.4	Verbesserung der Zustands- und Parameterschätzung in Batteriesystemen	108
4.4.1	Berücksichtigung physikalischer Grenzen	109
4.4.2	Einbeziehen der Hysterese der Zellspannung	111
4.4.3	Stabilisierung der Schätzung durch Pseudo-Messwerte	113
4.4.4	Vernachlässigung unplausibler Kovarianzen	114
4.5	Ergebnisse der Zustands- und Parameterschätzung	115
4.6	Zusammenfassung der Zustands- und Parameterschätzung	122
5	Aktive Parameterschätzung in rekonfigurierbaren Batteriesystemen	123
5.1	Motivation für den Einsatz von Schaltoperationen	123
5.2	Schaltstrategie zur Erhöhung der Systemanregung	124
5.2.1	Schaltmuster zur Anregung relevanter Frequenzen	125
5.2.2	Situatives Schalten abhängig von der Anregung	126
5.3	Analyse der Schaltmuster und Fahrprofile im Frequenzbereich	128
5.3.1	Frequenzspektrum der Schaltmuster	128
5.3.2	Spektralanalyse der verwendeten Stromprofile	131
5.4	Validierung der aktiven Parameterschätzung	134
5.4.1	Validierung mit Simulationen und Experimenten	135
5.4.2	Einfluss der Schaltfrequenz und des Tastgrads	137
5.4.3	Einfluss des Schwellwerts für situatives Schalten	139
5.4.4	Diskussion des Einflusses von Schaltvorgängen auf die Zellalterung	142
5.5	Zusammenfassung der Ergebnisse	143
6	Sensordatenfusion in intelligenten Batteriesystemen	145
6.1	Motivation für eine Sensordatenfusion	145
6.2	Verfahren zur robusten Bestimmung des Innenwiderstands	146
6.2.1	Adaption eines Dual-Kalman-Filters	146
6.2.2	Erhöhung der Robustheit	150
6.2.2.1	Phasen mangelnder Systemanregung	150
6.2.2.2	Windup-Effekt des Schätzers	151
6.2.2.3	Stochastische Verteilung der Messwerte	154
6.2.3	Zusammenfassung der robusten Parameterschätzung	165
6.3	Modellbasierte Sensordatenfusion von Zellstrom und -spannung	166
6.3.1	Vorstellung der modellbasierten Sensordatenfusion	167

6.3.1.1	Sensordatenfusion der Strommessung	167
6.3.1.2	Sensordatenfusion der Spannungsmessung	168
6.3.2	Herleitung der erzielbaren Varianzreduktion	170
6.3.3	Erhöhung der Robustheit der Strommessung	171
6.3.4	Untersuchung der Sensordatenfusion in Simulationen und Experimenten .	174
6.3.4.1	Vergleich mit herkömmlicher Strommessung	175
6.3.4.2	Einfluss der Parametervariation aufgrund von Alterung	178
6.3.4.3	Einfluss der Anzahl an Zellen/Sensoren	180
6.3.4.4	Einfluss des Sensorrauschens	180
6.3.4.5	Einfluss von Schalthandlungen	182
6.3.5	Effiziente Implementierung durch Segmentierung der Messdaten	184
6.4	Methode zur adaptiven Varianzschätzung des Sensorrauschens	187
6.4.1	Stand der Wissenschaft	188
6.4.2	Varianzschätzung basierend auf der Sensordatenfusion	190
6.4.3	Vergleich des Verfahrens mit herkömmlichen Methoden	191
6.4.4	Optimierung der Adaptivität	193
6.4.5	Einfluss der Anzahl an Zellen/Sensoren	195
6.5	Zusammenfassung der Ergebnisse zur Sensordatenfusion	196
7	Zusammenfassung und Ausblick	197
A	Vorstellung der verwendeten Stromprofile	200
B	Vorstellung des Prüflings und Versuchsbeschreibung	204
B.1	Lithium-Ionen-Zellen und deren Charakterisierung	204
B.2	Prototypen intelligenter Batteriezellen und -module	206
B.3	Versuchsaufbau und Signalverarbeitung der Modulversuche	209
C	Stochastische Grundlagen	213
C.1	Momente einer Zufallsvariablen	213
C.2	Normalverteilung	214
C.3	Chi-Quadrat-Verteilung und Hypothesen-Test	215
C.4	Student-t-Verteilung	216
D	Weighted-Least-Squares-Verfahren	219
E	Zusätzliche Abbildungen und Diagramme	221
	Abkürzungsverzeichnis	226
	Symbolverzeichnis	229
	Literaturverzeichnis	234

1 Einleitung

1.1 Hintergrund und Motivation

Der tiefgreifende Wandel des Verkehrssektors von auf Verbrennungsmotoren basierenden Fahrzeugen hin zur Elektromobilität ist eine für die Automobilindustrie maßgebliche Herausforderung des nächsten Jahrzehnts und darüber hinaus. Hybrid- und Elektrofahrzeuge mit Batteriespeichern und gegebenenfalls Brennstoffzellen versprechen eine Reduktion der CO₂-Bilanz über den Produktlebenszyklus durch den zunehmenden Verzicht auf fossile Brennstoffe. Weiterhin kann die Elektromobilität insbesondere in Städten die Belastung durch Lärm und Feinstaub reduzieren [1].

Dem Traktionsakkumulator kommt innerhalb des elektrischen Antriebsstrangs eine besondere Bedeutung zu, da er direkt Einfluss auf wichtige Fahrzeugeigenschaften wie Reichweite und Leistungsfähigkeit hat, aber auch Gewicht, Kosten und Langlebigkeit. Da insbesondere die verfügbare Reichweite heutiger Batterie-Elektrofahrzeuge (engl. *battery electric vehicles*, BEVs) als Hindernis für eine Substitution herkömmlicher Verbrenner-Fahrzeuge gesehen wird [2], steckt in der Optimierung des Batteriespeichers ein großes Potenzial für die Erhöhung der Kundenakzeptanz. Als Speichertechnologie haben sich Lithium-Ionen-Batterien fast vollständig durchgesetzt aufgrund ihrer Vorteile gegenüber anderen Speichertypen hinsichtlich Leistungs- und Energiedichte, Zyklenfestigkeit und einer geringen Selbstentladungsrate [3].

Lithium-Ionen-Batterien sind immer mit einem Batteriemanagementsystem (BMS) ausgestattet, welches unter anderem die Einhaltung der sicheren Betriebsgrenzen hinsichtlich Zellspannung und Temperatur überwacht [3]. Eine weitere wichtige Funktion des BMS ist die Ladezustandsbestimmung, auf der die Prognose der Restreichweite eines BEVs beruht. Beim Ladezustand handelt es sich um eine Größe, welche im Betrieb nicht auf triviale Art und Weise ermittelt werden kann. Es existiert eine Vielzahl an unterschiedlichen Verfahren zur Bestimmung des Ladezustands. Einen Überblick geben die Reviews von Waag et al. [4], Rivera-Barrera et al. [5] sowie Adaikkappan und Sathiyamoorthy [6]. Modellbasierte Verfahren mittels Kalman-Filter sind in der Literatur am weitesten verbreitet [7], auch wenn alternative Ansätze existieren wie beispielsweise Sliding-Mode-Observer [8, 9], H_∞-Filter [10, 11], künstliche neuronale Netze (engl. *artificial neural networks*, ANNs) [12] oder Support-Vector-Regression [13].

Da die nominelle Spannung einer einzelnen Lithium-Ionen-Zelle bei 3,2 V bis 3,7 V liegt und deren Kapazität begrenzt ist, bestehen die Hochvolt-Batteriesysteme in BEVs aus vielen Einzelzellen, welche zur Bereitstellung der geforderten Systemspannung in Reihe und zur Erhöhung der Leistung und Energiemenge bei gegebener Systemspannung parallel verschaltet werden. Die Anzahl an Zellen heutiger Batteriesysteme von BEVs kann von einigen Hundert bis zu mehreren Tausend reichen. Innerhalb eines Batteriesystems sind die Eigenschaften der Zellen inhomogen. So sind die Kapazitäten und Innenwiderstände beispielsweise für jede Zelle unterschiedlich. Dieses Phänomen ist auf Produktionsschwankungen bei der Zellfertigung zurückzuführen ebenso wie auf inhomogene Betriebsbedingungen, wenn beispielsweise ein Temperaturgradient innerhalb des

Batteriesystems vorhanden ist. Über die Lebensdauer können sich daher die Zelleigenschaften und somit auch die Inhomogenität des Gesamtsystems ändern [14, 15]. Für modellbasierte Funktionen des BMS, wie der Ladezustandsschätzung mittels Kalman-Filter, muss die Änderung der Zelleigenschaften im Betrieb überwacht werden, um eine gleichbleibende Modell- und damit Schätzgüte zu gewährleisten. Dies motiviert den Einsatz von Parameterschätzern im BMS.

Die modellbasierte Zustands- und Parameterschätzung beruht auf drei wichtigen Grundlagen, welche für gute Ergebnisse essentiell sind. Zunächst hängt die Güte der Schätzung immer von der Modellgenauigkeit ab. Die Wahl eines geeigneten Modells und seine korrekte Parametrierung sind daher notwendige Voraussetzungen. Zweitens muss das verwendete Verfahren für das Schätzproblem geeignet sein. Innerhalb der Familie der Kalman-Filter existiert eine Vielzahl von Varianten und Erweiterungen, welche das Filter für bestimmte Problemstellungen modifizieren. Hier gilt es, geeignete Methoden zu selektieren. Schließlich ist die Parametrierung des Filter-Algorithmus von großer Wichtigkeit, weil diese das Schätzergebnis maßgeblich beeinflusst. In der Literatur ist das händische Anpassen der Hyperparameter des Kalman-Filters durch Ausprobieren immer noch weit verbreitet. Damit hängt das Resultat aber vom Glück oder bestenfalls Geschick des Applikateurs ab. Von großem Interesse ist daher, eine fundierte Methode zur optimalen Parametrierung des Filters zu finden.

Grundlage jeder BMS-Funktion sind Messdaten, wofür entsprechende Sensoren vorgesehen sind. Üblicherweise ist in einem Batteriesystem jeder Parallelstrang von Zellen mit einer Spannungsüberwachung ausgestattet und die Temperatur wird an wenigen kritischen Punkten gemessen. Weiterhin wird der Gesamtstrom erfasst, welcher das Hochvolt-Batteriesystem durchfließt. Durch die begrenzte Anzahl an Sensoren ist jedoch das Wissen über die Zustände der Einzelzellen innerhalb des Batteriesystems begrenzt. Veränderungen der Eigenschaften einzelner Lithium-Ionen-Zellen können in der Regel nicht oder nur spät detektiert werden. Weiterhin führt die dauerhafte Verbindung mehrerer Batteriezellen zu einem System zu Einschränkungen. So ist dessen Leistungsfähigkeit und Kapazität durch die schwächste Zelle limitiert [16]. Daher sind Ladungsausgleichsschaltungen vorzusehen, um Differenzen der Ladezustände zwischen in Reihe geschalteten Zellen zu reduzieren [17]. Dies senkt jedoch die Effizienz des Gesamtsystems.

Die zuvor genannten Einschränkungen motivieren die Erforschung sogenannter intelligenter Batteriesysteme (IBSs), welche sich hinsichtlich dreier Aspekte von herkömmlichen Batteriesystemen unterscheiden [18]:

1. Jede einzelne Lithium-Ionen-Zelle ist mit Sensoren ausgestattet, welche Messgrößen wie Zellspannung, Zellstrom oder die Zelloberflächentemperatur ermitteln. Neuere Forschung untersucht auch den Einsatz von erweiterten Diagnosesystemen, wie der elektrochemischen Impedanzspektroskopie [19–21] oder integrierten Sensoren [22, 23]. Im Folgenden wird diese Charakteristik von IBSs als zellindividuelle Sensorik oder allgemeiner als Zellsensoren bezeichnet.
2. Der starre Verbund der Zellen zu einem Gesamtsystem wird aufgelöst, indem die Topologie zur Laufzeit reversibel geändert werden kann. Diese Rekonfigurierbarkeit wird durch Leistungshalbleiterschalter realisiert. Damit ist es beispielsweise möglich, einzelne Zellen aus dem Leistungspfad zu nehmen oder zu überbrücken. Man spricht dann auch von rekonfigurierbaren Batteriesystemen (RBSs) [24–26].

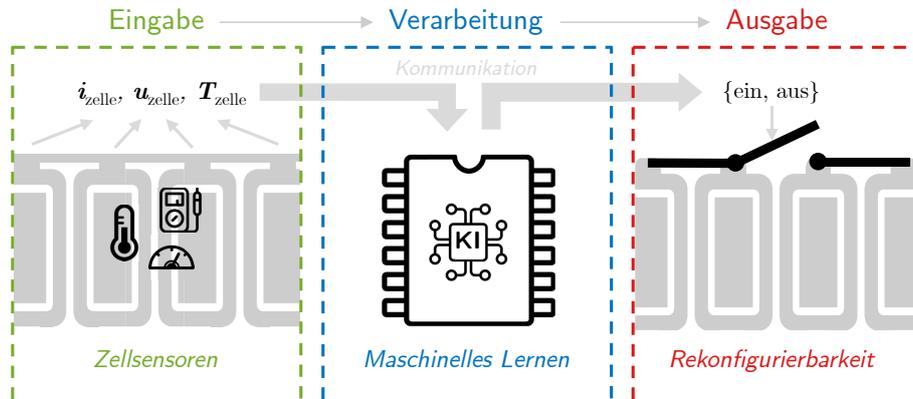


Abbildung 1.1: Visualisierung eines IBS als mechatrisches System.

3. Algorithmen und Methoden der künstlichen Intelligenz und des maschinellen Lernens werden zur Auswertung der Sensordaten und zur Anwendung von Betriebsstrategien eingesetzt (z. B. zur Fehlerdiagnose [27, 28] oder zum Ladungsausgleich [29]). Das IBS bildet auf diese Weise ein mechatrisches System (siehe Abb. 1.1).

Aus den beschriebenen Eigenschaften resultieren in der Anwendung weitere charakteristische Merkmale von IBSs. So ist es zielführend, jede Batteriezelle zur Auswertung der Sensoren und Ansteuerung der Schalter mit Rechenleistung beispielsweise in Form eines Mikrocontrollers auszustatten. Weiterhin folgt aus dieser Überlegung heraus der Bedarf an einem Kommunikationssystem zwischen den Zellen und dem zentralen BMS [18]. Durch die Rekonfigurierbarkeit bietet sich ein enormes Potenzial für die Anwendung von Betriebsstrategien im BMS, da eine mächtige Eingriffsmöglichkeit in die Systemstruktur besteht. Einen Überblick über verschiedene Aspekte von IBSs geben die Reviews von Wei et al. [30] sowie Komsijska et al. [18]. Wichtig ist der Hinweis, dass die aufgeführten Eigenschaften nicht in jedem IBS gleichermaßen umgesetzt sein müssen. Vielmehr kann die spezifische Anwendung den Einsatz von mehr oder weniger Modifikationen gegenüber herkömmlichen Batteriesystemen rechtfertigen und beispielsweise den Einsatz von zellindividueller Sensorik oder Rekonfigurierbarkeit motivieren.

Die Charakteristika von IBSs wirken sich auch auf die Schätzverfahren im BMS aus. So erlauben die Zellsensoren eine Zustandsschätzung einzelner Zellen, wohingegen in herkömmlichen Batteriesystemen das Batteriesystem häufig als eine Komponente betrachtet wird [31, 32]. Die Rekonfigurierbarkeit hat diverse Einflüsse auf die Zustandsschätzung. Zunächst müssen die zugrunde liegenden Modelle die Schalter berücksichtigen. Weiterhin führen die Schalthandlungen dazu, dass die Homogenität der Zellzustände innerhalb des Batteriesystems abnimmt. Dies motiviert den Einsatz zellindividueller Schätzverfahren, weil die in herkömmlichen Batteriesystemen getroffene Annahme, dass die Zustände der Batteriezellen vergleichbar sind, nicht mehr zutreffen muss. Gleichzeitig beeinflussen die Schalthandlungen von RBSs auch die Anregung der Zellen, indem der Stromfluss durch das System im Betrieb verändert wird. Ob dies zu einer Verbesserung der Zustands- und Parameterschätzung genutzt werden kann, ist eine offene Forschungsfrage.

Ein großer Nachteil von IBSs im Vergleich zu herkömmlichen Batteriesystemen sind die zunächst höheren Kosten aufgrund der zusätzlichen elektronischen Komponenten. Wird beispielsweise jede einzelne Batteriezelle mit Sensoren für Strom, Spannung und Temperatur ausgestattet,

können aufgrund der großen benötigten Anzahl keine teuren Sensoren verbaut werden. Die Idee der im Rahmen dieser Arbeit untersuchten Sensordatenfusion (SDF) ist es daher, die Vielzahl gleichartiger Sensoren für Zellstrom und -spannung miteinander zu korrelieren, um die Messgenauigkeit jedes Signals zu erhöhen. Dadurch können einfache und kostengünstige Sensoren eingesetzt und gleichzeitig die Anforderungen an die Messqualität erfüllt werden. Die SDF ist somit ein Schätzverfahren für stark verrauschte Sensordaten eines IBS. Zusammenfassend haben die spezifischen Eigenschaften von IBSs und insbesondere die Zellsensoren Auswirkungen auf die Verfügbarkeit und Verarbeitung von Sensordaten. Gleichzeitig müssen Schätzverfahren im BMS den Besonderheiten von RBSs Rechnung tragen.

1.2 Zielsetzung und Beiträge dieser Arbeit

Im Rahmen dieser Arbeit werden Kalman-Filter für die modellbasierte Zustands- und Parameterschätzverfahren für die Anwendung in BMSs und speziell in IBSs untersucht. Hierbei liegt der Fokus neben einer effizienten Modellierung der Batteriezellen und des Batteriesystems auch auf der Beobachtbarkeit der Modelle. Dieser Aspekt ist in vielen Arbeiten zur Parameterschätzung mittels Kalman-Filter unzureichend berücksichtigt. Darüber hinaus werden Verfahren zur Parametrierung des Kalman-Filters untersucht mit dem Ziel, die Kovarianzen des Prozess- und Messrauschens durch methodisches Vorgehen optimal zu bestimmen. Auch hier weisen viele wissenschaftliche Veröffentlichungen Defizite auf, wenn die Hyperparameter nach der Trial-and-Error-Methode bestimmt werden oder die Methodik zur Bestimmung nicht beschrieben ist.

Die Charakteristika von IBSs begründen eine Betrachtung dieses speziellen Anwendungsfalls in Abgrenzung zu herkömmlichen Batteriesystemen. So ermöglichen die Zellsensoren eine zellindividuelle Zustandsschätzung im Gegensatz zu dem sonst üblichen Vorgehen, das Batteriesystem oder zumindest parallel verschaltete Zellen als Einheit zu betrachten. Außerdem können Verfahren, die üblicherweise im Labor an Einzelzellen validiert werden, in IBSs auch im Fahrzeug eingesetzt werden. Aus der Breite der wissenschaftlichen Veröffentlichungen zu Schätzverfahren in BMSs werden für die konkrete Anwendung geeignete Verfahren selektiert, adaptiert und angewandt. Weiterhin verlangen die dem IBS eigenen Leistungsschalter und die darauf beruhende Rekonfigurierbarkeit der Topologie eine spezifische Betrachtung der Zustandsschätzung. Zum einen müssen die Schalter im Modell berücksichtigt werden, welches Grundlage des eingesetzten Kalman-Filters zur Zustandsschätzung ist. Zum anderen wird im Rahmen dieser Arbeit der Einfluss von Schaltoperationen im Betrieb auf das Filter untersucht.

Ein weiterer wichtiger Einflussfaktor auf die Güte der Zustands- und Parameterschätzung ist die Anregung des Systems. Insbesondere für nichtlineare Modelle kann eine mangelhafte Anregung zum Verlust der Beobachtbarkeit und zu divergenten Schätzungen führen. Eine Möglichkeit zur Erhöhung des Zellstroms und damit der Systemanregung bieten die Halbleiterschalter eines RBS. Durch Schaltoperationen mit einem definierten Muster kann das Leistungsdichtespektrum der Anregung in relevanten Frequenzbereichen gezielt erhöht werden. Der Einfluss des Schaltmusters und dessen Frequenz werden insbesondere untersucht.

Um das Potenzial der zellindividuellen Sensorik zu nutzen und den Einbau kostengünstiger Sensorik zu ermöglichen, wird im Rahmen dieser Arbeit eine Sensordatenfusion entwickelt

und untersucht, welche die Korrelation von Strom- und Spannungsmessungen nutzt, um die Messgenauigkeit jedes Signals zu erhöhen. Die Verknüpfung der Sensordaten miteinander erfolgt mithilfe eines Modells des Batteriesystems, da sich die Kopplung der elektrischen Größen gut durch physikalische Gesetze beschreiben lässt. Daher benötigt die SDF eine leistungsfähige Zustands- und Parameterschätzung, wie sie im Rahmen dieser Arbeit entwickelt wird, um das Batteriesystemmodell im Betrieb aktuell zu halten. Ein Fokus liegt hierbei auf dem Einsatz einer hohen Robustheit bei der Bestimmung des Zellinnenwiderstands. Als robust gelten hierbei Methoden, welche unempfindlich gegenüber Messrauschen oder Messausreißern sind. Wichtige Einflussgrößen auf die modellbasierte SDF werden untersucht, wie die Anzahl an Zellen im System, die Stärke des Sensorrauschens oder die Streuung der Zellparameter. Dies gilt auch für den Einfluss, den Schaltheftungen der Leistungsschalter auf die SDF haben können. Neben einer Reduktion der Messunsicherheiten bietet die Datenfusion einen weiteren Vorteil: Die Redundanz des gesamten Messsystems steigt, weil der Ausfall einzelner Sensoren durch die anderen Sensoren kompensiert werden kann. Dadurch steigt die Robustheit der Strom- und Spannungsmessung insgesamt.

Die SDF ist ein Schätzverfahren für die verrauschten Signale der Strom- und Spannungssensoren. Charakteristisch für das Verfahren ist, dass jedes Signal auch mithilfe einer Mess- bzw. Schätzunsicherheit beschrieben wird. Folglich ist es für die Datenfusion nützlich, wenn die Stärke des Sensorrauschens der Sensoren bekannt ist. Die SDF wird daher um eine Varianzschätzung des Sensorrauschens ergänzt. Sie beruht auf den fusionierten Signalen und dient gleichzeitig als Grundlage für eine korrekte Gewichtung der Sensoren im Fusionsprozess. Daher ist die Varianzschätzung eine hilfreiche Ergänzung im Konzept der SDF.

Insgesamt leistet die vorliegende Arbeit einen Beitrag, die Zustands- und Parameterschätzung, die Sensordatenerfassung im Speziellen sowie IBSs im Allgemeinen zu verbessern. Damit gibt sie dieser vielversprechenden Technologie ein wissenschaftlich gesichertes Fundament. Die Entwicklung und der Einsatz eines IBS in BEVs ist ein disruptiver Entwicklungsschritt des elektrischen Antriebsstrangs und bietet ein großes Potenzial. Diese Arbeit beleuchtet einen Teilbereich dessen.

1.3 Gliederung der Arbeit

Die vorliegende Arbeit lässt sich in drei Abschnitte unterteilen: Modellierung des Batteriesystems (Kapitel 3), Entwicklung von Online-Schätzverfahren für Zustände und Parameter (Kapitel 4 und 5) sowie die Entwicklung einer modellbasierten SDF für die Anwendung in IBSs (Kapitel 6).

Zunächst gibt Kapitel 2 einen Überblick über die Funktionsweise von Lithium-Ionen-Zellen, Batteriesystemen und dem Batteriemanagementsystem. Insbesondere werden Batteriesysteme betrachtet, welche Teil des elektrischen Antriebsstrangs von Elektrofahrzeugen sind. Ein besonderer Fokus liegt auf den intelligenten Batteriesystemen, welche den Schwerpunkt dieser Arbeit bilden.

Darauf aufbauend wird in Kapitel 3 die Modellierung von (intelligenten) Batteriezellen und -systemen vorgestellt und schließlich ein leistungsfähiges Ersatzschaltbildmodell für das elektrische Systemverhalten abgeleitet. Basierend auf umfangreichen Zellversuchen werden die Parameter

dieses Modells bestimmt. Das Batteriemodell wird schließlich anhand dynamischer Stromprofile validiert und dient als Grundlage für die weitere Arbeit.

In Kapitel 4 wird ausgehend von allgemeinen Grundlagen zur modellbasierten Zustands- und Parameterschätzung ein Kalman-Filter für den Einsatz im BMS von IBSs entwickelt. Ein Schwerpunkt des Kapitels liegt auf der Untersuchung der Beobachtbarkeit und Bestimmung der Kovarianzmatrizen, die das Kalman-Filter parametrieren. Es wird hierzu ein Verfahren vorgeschlagen, mit dessen Hilfe sich basierend auf Trainingsdaten ein multikriterielles Optimum für die Parameter des Kalman-Filters finden lässt. Schließlich werden ausgehend vom Stand der Wissenschaft Verfahren diskutiert, welche die Zustandsschätzung vor dem Hintergrund der konkreten Anwendung im BMS verbessern können. Die Vorstellung von Ergebnissen zur Zustandsschätzung runden das Kapitel ab.

Da insbesondere die Leistungsschalter von RBSs charakteristisch für innovative IBSs sind, wird der Einfluss von Schalthandlungen auf die Schätzverfahren als großer Einflussfaktor auf die Anregung besonders beleuchtet. Durch die Erhöhung der Systemanregung soll eine Verbesserung der Zustands- und Parameterschätzung erreicht werden. Hierzu werden in Kapitel 5 Analysen und Experimente vorgestellt.

Eine leistungsfähige und robuste Zustands- und Parameterschätzung ist die Grundlage, um schließlich in Kapitel 6 die beschriebene modellbasierte SDF für die Strom- und Spannungsmessung in IBSs umzusetzen. Hierfür wird ein kompaktes Dual-Kalman-Filter genutzt und modifiziert, welches insbesondere eine robuste Schätzung des Innenwiderstands ermöglicht. Die modellbasierte SDF wird in Kapitel 6.3 vorgestellt und mit herkömmlichen Verfahren zur Strom- und Spannungsmessung verglichen. Außerdem erfolgen Untersuchungen hinsichtlich wichtiger Einflussfaktoren auf das Verfahren wie die Anzahl an involvierten Zellen, die Stärke des Sensorrauschens etc. Schließlich wird eine auf der SDF fußende Methode präsentiert, mit dessen Hilfe sich die Varianz des Sensorrauschens abschätzen lässt. Dies ist insbesondere dafür hilfreich, eine optimale Gewichtung der Sensordaten in der SDF vorzunehmen. Damit ergänzt die Varianzschätzung die modellbasierte SDF vorteilhaft. Eine Zusammenfassung der Ergebnisse erfolgt schließlich in Kapitel 7.

2 Grundlagen zu Lithium-Ionen-Zellen und Batteriesystemen

2.1 Funktionsweise und Aufbau von Lithium-Ionen-Zellen

In heutigen Hybrid- und Elektrofahrzeugen haben sich Batteriesysteme basierend auf Lithium-Ionen-Zellen etabliert. Insbesondere hinsichtlich der für den Anwendungsfall wichtigen hohen Energie- und Leistungsdichte sind Lithium-Ionen-Systeme anderen Batterietechnologien überlegen. Weitere Vorteile, welche für den Einsatz in Elektrofahrzeugen sprechen, sind ein hoher Wirkungsgrad, eine geringe Selbstentladung sowie die Schnellladefähigkeit [33, S.14]. Die Erläuterung der elektrochemischen Funktionsweise von Lithium-Ionen-Zellen sowie der Aufbau von Batteriezellen und -systemen beschränkt sich im Folgenden auf die wichtigsten Grundlagen. Insbesondere sollen diejenigen Informationen in Kürze vermittelt werden, welche für das weitere Verständnis der Arbeit notwendig sind. Weitergehende Informationen können den Grundlagenwerken [33–36] entnommen werden, auf welchen der folgende Abschnitt beruht.

Lithium eignet sich aufgrund seines hohen negativen elektrochemischen Potentials $E^0 = -3,045 \text{ V}$ für den Einsatz in Energiespeichern, da Batteriezellen mit einer hohen Nennspannung und dadurch hohen Energiedichte realisierbar sind. Der schematische Aufbau einer Lithium-Ionen-Zelle ist in Abb. 2.1 dargestellt. Die Batterie besteht grundsätzlich aus Kathode und Anode, welche durch den Separator getrennt sind. Die Benennung der Elektroden richtet sich hierbei nach dem Entladefall. Während für die Kathode üblicherweise Mischoxide Verwendung finden, ist die Anode heutiger Batterien aus Graphit aufgebaut. Weiterhin können Silizium oder Lithium-Titanat-Oxid (LTO) als Material der Anode zum Einsatz kommen. Beide Elektroden weisen eine poröse Struktur auf, sodass ein Transport der Lithium-Ionen durch den Elektrolyten gewährleistet ist, welches auch den Separator durchtränkt. Zur elektrischen Anbindung der Elektroden kommen Stromableiter zum Einsatz, wobei auf der Anodenseite Kupferfolien und auf der Kathodenseite Aluminiumfolien verwendet werden. Diese haben gemäß ihrer Eigenschaften Einfluss auf die Leitfähigkeit der Batterie.

Im Ladefall wandern Lithium-Ionen zur Anode, rekombinieren mit dem von der Kathode bereitgestellten Elektron und werden im Kohlenstoffgitter des Graphits eingelagert. Dieser Prozess kehrt sich im Entladefall um, wobei die Lithium-Ionen zur Kathode wandern und dort im Metallgitter der Elektrode eingelagert werden. Durch die Ladungsdifferenz zwischen den Elektroden fließt ein elektrischer Strom, wenn die Stromableiter über eine elektrische Last miteinander verbunden werden.

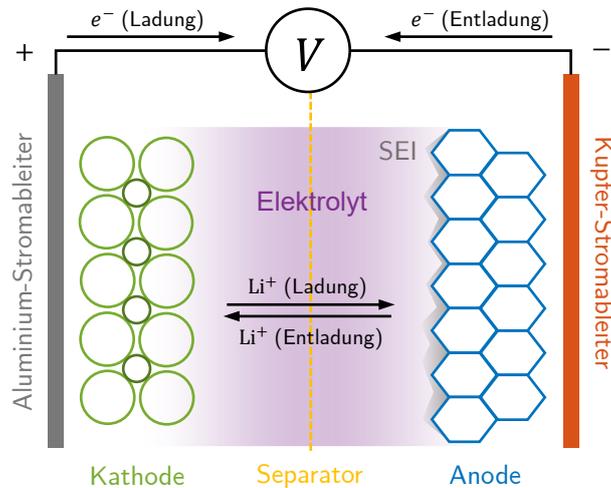


Abbildung 2.1: Schematische Darstellung der Funktionsweise einer Lithium-Ionen-Zelle angelehnt an Linden und Reddy [34, S. 35.5].

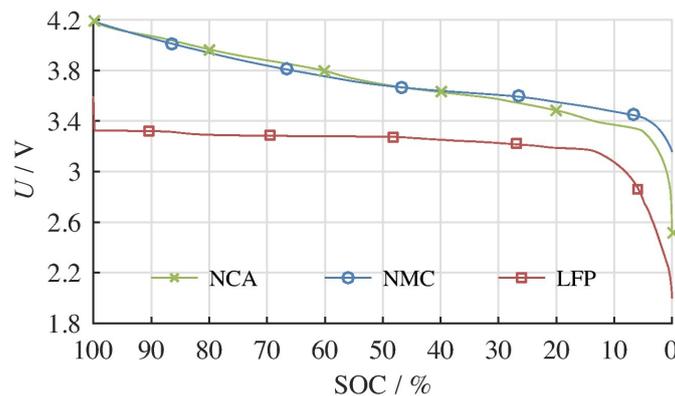
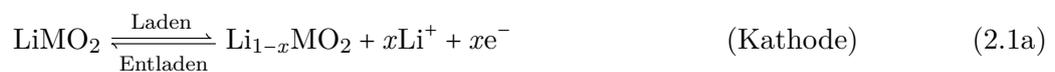


Abbildung 2.2: Verlauf der ladezustandsabhängigen OCV-Kurve für verschiedene Kathoden-Materialien. Die Anode besteht bei allen Batterien aus Graphit. Quelle: Campestrini et al. [38]

Es ergeben sich die Reaktionsgleichungen gemäß (2.1) an der Kathode bzw. Anode [34, S. 35.5].



Das Gleichgewichtspotenzial zwischen den beiden Elektroden variiert abhängig von deren Lithium-Konzentration. Es ergibt sich daher an den Stromableitern eine ladezustandsabhängige Spannung, die Leerlaufspannung (engl. *open circuit voltage*, OCV). Sie kann als Überlagerung der beiden Halbzellspannungen von Anode und Kathode aufgefasst werden und ist für verschiedene Zellchemien in Abb. 2.2 dargestellt. Der steile Abfall der OCV für niedrige Ladezustände ist auf das sich stark ändernde Potenzial der Anode zurückzuführen, wenn deren Lithiierungsgrad sinkt [37].

An der Kathode können verschiedene Materialien eingesetzt werden. Das zunächst meist eingesetzte Lithium-Cobaltoxid (LCO) weist Nachteile hinsichtlich der Verfügbarkeit des Cobaltoxids auf, dessen Abbau mit ökologischen und sozialen Problemen verknüpft ist. Alternative Kathodenmaterialien sind Nickel-Cobalt-Aluminium (NCA) oder Lithium-Eisenphosphat (LFP). Letzteres hat sich als sichere und kostengünstige Alternative etabliert, allerdings ist die erzielbare Zellspannung geringer als bei anderen Kathodenmaterialien, woraus eine geringe Energiedichte resultiert. Darüber hinaus stellt die geringe Veränderung der Leerlaufspannung bei mittleren Ladezuständen eine Herausforderung für die Ladezustandsschätzung dar. Dies ist in Abb. 2.2 ersichtlich. Lithium-Nickel-Mangan-Cobalt-Oxid (NMC) dahingegen bietet als Kathodenmaterial eine flexible Auslegung der Zelle im Hinblick auf die erzielte Energie- oder Leistungsdichte, indem das Verhältnis von Nickel, Mangan und Cobalt angepasst wird. Insbesondere die Reduktion des Cobaltanteils ist Gegenstand aktueller Forschung und Entwicklungsarbeit.

Der Separator ist üblicherweise als poröse Membran aus Polyethylen oder Polypropylen ausgeführt. Um einen hohen Ionentransport zu ermöglichen, wird eine möglichst dünne Foliendicke gewählt, was den Innenwiderstand der Batteriezelle senkt. Allerdings muss zu jedem Zeitpunkt die elektrische Isolationsfähigkeit erhalten bleiben. Zudem kann es bei mangelnder chemischer oder mechanischer Stabilität zu internen Kurzschlüssen kommen, wobei letztere beispielsweise durch Lithium-Dendriten verursacht werden, wenn aufgrund des Betriebs bei niedrigen Temperaturen und hohen Strömen metallisches Lithium entsteht. Deshalb gibt es Ansätze, den Separator als Keramik auszuführen oder mit einer keramischen Schicht zu überziehen, um dessen Stabilität zu erhöhen [39].

Der Elektrolyt soll den Ionenfluss zwischen den beiden Elektroden ermöglichen und beinhaltet deshalb Lithiumsalze, welche in organischen Lösemitteln gelöst sind. Üblicherweise sind dem Elektrolyten diverse weitere Additive zugesetzt, um eine gewünschte Viskosität zu erzielen oder die Bildung von Deckschichten an den Grenzflächen der Materialien zu beeinflussen. Diese Schicht (engl. *solid electrolyte interface*, SEI) bildet sich bei der ersten Formierung der Batteriezelle an der Oberfläche der Anode und leistet der Alterung Vorschub, wenn sie über die Lebensdauer der Lithium-Ionen-Zelle weiter anwächst.

Unabhängig von der eingesetzten Materialkombination können nach Schmidt [40] vier elektrochemische bzw. physikalische Vorgänge während des Ladens bzw. Entladens einer Lithium-Ionen-Zelle identifiziert werden: Ladungsdurchtritt, Festkörperdiffusion, Elektronenleitung und Ionenleitung im Elektrolyten.

Der Ladungsdurchtritt bezeichnet die Ein- bzw. Auslagerung des Lithiums in den Aktivmaterialien der Elektroden. Die Festkörperdiffusion tritt auf, wenn das interkalierte Lithium innerhalb des Aktivmaterials wandert, sobald sich durch die Lade- und Entladevorgänge Konzentrationsdifferenzen innerhalb der Elektroden bilden. Es entsteht dadurch eine elektrochemische Überspannung. Weiterhin findet die Elektronenleitung statt, wenn Elektronen über die Stromableiter in die Aktivmaterialien fließen müssen. Schließlich werden die Lithium-Ionen durch den Elektrolyten von einer Elektrode zur anderen transportiert. Diese Ionenleitung im Elektrolyten wird vom zwischen den Elektroden herrschenden elektrischen Feld getrieben. Elektronenleitung und Ionenleitung sind schnell ablaufende Prozesse und werden als Ohmscher Innenwiderstand gemessen.

Die erwähnten Prozesse unterliegen einer Temperaturabhängigkeit. Je höher die Zelltemperatur ist, desto schneller laufen die Redoxreaktionen in den Aktivmaterialien ab, was die Leistungsfähigkeit der Batterie entsprechend erhöht oder vermindert. Insbesondere steigt die Leitfähigkeit des Elektrolyten mit der Temperatur an, aber auch die Festkörperdiffusion beschleunigt sich [41]. Dadurch sinkt der Innenwiderstand der Lithium-Ionen-Zelle und das dynamische Zellverhalten ändert sich. Mit steigender Temperatur beschleunigen sich jedoch auch Alterungseffekte. Die Leerlaufspannung ist ebenfalls temperaturabhängig, da das elektrochemische Potenzial der Elektroden über den Entropiekoeffizienten mit der Temperatur verknüpft ist [42, S. 232].

Heutige Lithium-Ionen-Zellen werden in vier Bauformen kommerziell vertrieben. Während **Knopfzellen** nur eine geringe Ladekapazität aufweisen und sich vor allem für die Anwendung in mobilen elektronischen Geräten eignen, weisen **zylindrische Zellen** oder Rundzellen einen weiten Einsatzbereich auf. Die Stromableiter, Elektroden und der Separator sind gewickelt und das Format der Zellen üblicherweise standardisiert. Weit verbreitet ist das Format 18650 (18 mm Durchmesser, 65 mm Höhe), bei welchem eine Kapazität bis 3600 mAh erreicht werden kann. Die von außen zugänglichen Pole der Batterie befinden sich bei Rundzellen an den schmalen Stirnseiten. Aufgrund der zylindrischen Form fällt die Energiedichte von aus mehreren Zellen bestehenden Modulen meist gegenüber **prismatischen Zellen** ab. Bei diesem Zellformat ist das Zellgehäuse rechteckig und beinhaltet entweder einen Flachwickel oder mehrere gestapelte Schichten der Materialien. Prismatische Zellen können je nach Bauform Kapazitäten deutlich über 100 Ah erzielen. Gestapelte Zellen ohne festes Zellgehäuse werden als **Pouch-Zellen** bezeichnet. Herausfordernd ist deren große Volumenänderung, die sich aus der fehlenden mechanischen Einspannung durch ein Gehäuse ergibt. Dafür sind sehr hohe Energie- und Leistungsdichten auch auf Systemebene erzielbar.

2.2 Batteriemanagementsysteme

Werden Lithium-Ionen-Batterien außerhalb ihres spezifizierten Betriebsbereichs betrieben, kann von ihnen ein erhebliches Gefährdungspotenzial ausgehen. Insbesondere ist das sogenannte thermische Durchgehen (engl. *thermal runaway*) zu nennen, bei dem es zu einer unkontrollierten Freisetzung der in der Batterie gespeicherten chemischen und elektrischen Energie kommt. Auslöser dafür kann entweder eine zu starke Erhitzung der Batterie oder eine Überladung der Zelle sein. Auch interne Kurzschlüsse können ein thermisches Durchgehen verursachen. In der Folge kommt es zu einer exothermen Reaktion des Elektrolyten mit dem in der Anode vorhandenen Kohlenstoff, zu einer Zersetzung des Elektrolyten und schließlich auch des Kathodenmaterials. Je nach Zelle werden hierbei große Energiemengen und giftige Gase freigesetzt und es besteht die Gefahr innerhalb von Batteriesystemen, dass sich der Thermal-Runaway auf benachbarte Zellen ausbreitet und eine Kettenreaktion auslöst. Um solche gefährlichen Phänomene zu verhindern, müssen Lithium-Ionen-Batterien und -Systeme zwingend mit einem Batteriemanagementsystem (BMS) ausgestattet sein, welches den Betrieb der Zellen überwacht.

Nach Andrea [43, S. 16] muss ein BMS mehrere Hauptaufgaben erfüllen. Erstens überwacht es die Einhaltung der oberen und unteren Spannungsgrenze, wobei Lithium-Ionen-Zellen insbesondere gegenüber Überladung empfindlich reagieren können. Wird der sichere Spannungsbereich verlassen,

erzwingt das BMS ein Stoppen des Lade- bzw. Entladevorgangs. Zweitens muss sichergestellt sein, dass die Temperaturgrenzen jederzeit eingehalten werden, innerhalb derer die Lithium-Ionen-Zelle sicher betrieben werden kann. Eine Überhitzung der Batterie kann durch Abschalten des Stroms verhindert werden oder durch das Anfordern einer höheren Kühlleistung bei einem gegebenenfalls vorhandenen Kühlsystem. Man spricht hierbei vom Thermomanagement des Batteriesystems. Schließlich begrenzt das BMS auch die Lade- und Entladeströme gemäß der spezifizierten Grenzen, wobei insbesondere erstere zu einer Gefahr für den sicheren Betrieb der Zelle werden können, weil bei einem zu hohen Ladestrom das Lithium nicht schnell genug im Anodenmaterial eingelagert werden kann. Es kann zur Bildung von metallischem Lithium kommen, was die Lebensdauer der Batterie drastisch verringert und welches Ursache für einen internen Kurzschluss sein kann.

Um die aufgeführten Überwachungsaufgaben zu erfüllen, sind BMSs üblicherweise mit Sensoren zur Überwachung der Zellspannung und des Stroms sowie Temperatursensoren ausgestattet. Gegebenenfalls ermöglicht eine Kommunikationsschnittstelle den Austausch von Informationen mit externen Komponenten wie z. B. dem Kühlsystem [33, S.178 ff.].

Weitere Funktionen, welche häufig von einem BMS erfüllt werden, sind die Ladezustandsschätzung, die Fehlerdiagnose, die Bestimmung der fortschreitenden Alterung der Batterie und – im Falle von Batteriesystemen, in welchen Zellen seriell verschaltet sind – das Balancieren (engl. *balancing*) [33, S.178 ff.]. Auf diese Funktionen wird im nächsten Abschnitt näher eingegangen.

2.3 Batteriesysteme im Antriebsstrang von Elektrofahrzeugen

Der elektrische Antriebsstrang eines BEVs kann unter Vernachlässigung des Ladesystems und etwaiger Nebenverbraucher in wenige Hauptkomponenten gegliedert werden, wie in Abb. 2.3 schematisch dargestellt ist. Bei der elektrischen Maschine handelt es sich üblicherweise um eine Drehfeldmaschine, welche mit einem dreiphasigen Wechselstrom betrieben wird. Sie stellt die mechanische Leistung bereit, mit welcher das Fahrzeug angetrieben wird und rekuperiert im generatorischen Betrieb die Bremsenergie. Die Wandlung des Gleichstroms in Wechselstrom und umgekehrt erfolgt durch die Leistungselektronik, welche neben dem Zwischenkreiskondensator als Tiefpassfilter einen Wechselrichter beinhaltet. Dieser besteht wiederum aus drei Halbbrücken, wobei durch hochfrequente Schaltvorgänge und einer entsprechenden Ansteuerung der Wechselstrom aus dem Gleichstrom gebildet wird. Das Hochvolt-Batteriesystem stellt die für den Betrieb der elektrischen Maschine benötigte elektrische Energie und Leistung zur Verfügung. Die Anforderungen an den Energiespeicher eines BEVs unterscheidet sich stark von denen eines Hybridfahrzeugs, was die zu speichernde Energiemenge betrifft [33, S. 394 f.]. Da der Energiegehalt und die Spannung einer einzelnen Lithium-Ionen-Zelle begrenzt sind, werden viele Zellen im Batteriesystem miteinander verschaltet. Durch Serienschaltung kann eine Systemspannung von mehreren hundert Volt erreicht werden, was die resultierenden Ströme bei gegebener Leistung senkt. Die Parallelschaltung von Zellen senkt dahingegen den Gesamt-Innenwiderstand und erhöht damit die Leistungsfähigkeit und Kapazität bei gegebener Systemspannung. Gleichzeitig steigt auch die Kapazität des Gesamtsystems. Ein System von S seriellen Teilsystemen bestehend

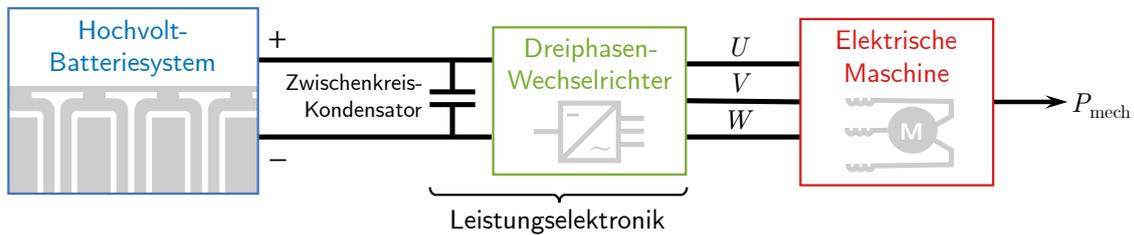


Abbildung 2.3: Schematische Darstellung des Antriebsstrangs eines Elektrofahrzeugs unter Vernachlässigung etwaiger Nebenverbraucher.

aus jeweils \mathcal{P} parallel verschalteten Zellen wird als $Ss\mathcal{P}p$ -Topologie notiert und besteht insgesamt aus $\mathcal{S} \cdot \mathcal{P} = \mathcal{Z}$ Zellen.

Damit das BMS seine Überwachungsaufgabe erfüllen kann, muss zumindest jeder Parallelstrang mit einer Spannungsmessung ausgestattet sein. Darüber hinaus müssen die Temperaturen innerhalb des Batteriesystems zumindest an einigen neuralgischen Punkten gemessen werden. Dahingegen wird in heutigen Batteriesystemen von Elektrofahrzeugen der Strom des Gesamtsystems nur einmal (gegebenenfalls redundant) gemessen [3, 44]. An den Stromsensor werden die hohen Anforderungen gestellt, in einem sehr weiten Messbereich von unter einem Ampere bis zu einigen hundert Ampere eine hohe Genauigkeit zu erzielen [18]. Letzteres ist insbesondere für die Bestimmung des Ladezustands wichtig. Hierfür sei auf Kapitel 4.1 verwiesen. Der Ladezustand des Hochvolt-Batteriesystems ist in BEVs aber insbesondere deshalb eine wichtige Funktion, weil die Bestimmung der verfügbaren Restreichweite maßgeblich darauf beruht. Eng damit verknüpft ist die Ermittlung des Gesundheitszustands (engl. *state of health*, SOH), weil mit sinkender nutzbarer Kapazität die Reichweite des Fahrzeugs ebenfalls abnimmt. Nimmt dagegen die maximal abrufbare Leistung des Batteriesystems ab, muss die Leistungsanforderung des elektrischen Antriebsstrangs reduziert werden. Dies wird im Englischen als *derating* bezeichnet und ist der Fall, wenn sich die Batteriezellen zu stark erhitzen.

Aus der Reihenschaltung von Lithium-Ionen-Zellen in Batteriesystemen resultiert die Notwendigkeit einer Balancing-Funktion. Denn da die dem System inhärenten Zellen beispielsweise aufgrund von Produktionsschwankungen leichte Unterschiede in ihrem elektrochemischen Verhalten aufweisen, driften die Ladezustände trotz der Beaufschlagung mit dem gleichen Strom über längere Zeiträume auseinander. Hierfür verantwortlich sind Zellparameter wie die Kapazität, die Selbstentladerate oder die Coulombsche Effizienz. Auch die äußeren Randbedingungen, wie beispielsweise die Temperatur, begünstigen das Auseinanderdriften der Ladezustände. Während bei parallel verschalteten Zellen ein Ladungsausgleich bis zum Erreichen der gleichen Klemmenspannung von selbst geschieht, gilt dies für serielle Stränge nicht. Dies ist insbesondere deswegen kritisch zu bewerten, weil der Ladevorgang eines Systems bereits dann beendet werden muss, sobald nur eine Zelle die obere Grenzspannung erreicht. Umgekehrt ist eine weitere Entladung des Systems nicht mehr möglich, sobald eine Zelle die untere Entladeschlussspannung erreicht. In der Folge verringern heterogene Ladezustände die nutzbare Kapazität des Gesamtsystems. BMSs umfassen daher bei großen Batteriesystemen immer Balancing-Systeme, welche die Ladezustände der Zellen durch Entladung der Zellen mit dem höchsten Ladezustand (engl. *state of charge*,

SOC) (passives Balancing) oder durch Ladungsausgleichsverfahren zwischen den Zellen (aktives Balancing) angleichen.

Eine weitere wichtige Funktion des BMS von BEVs ist das Thermomanagement, welches den Betrieb der Lithium-Ionen-Zellen in einem für die Leistungsfähigkeit und Alterung optimalen Temperaturfenster gewährleisten soll. Dieses umfasst den Bereich von circa 20 °C bis 40 °C, in welchem Lithium-Ionen-Zellen eine hohe Leistungsfähigkeit aufweisen und Alterungseffekte noch nicht verstärkt auftreten [33, S. 166]. Das Thermomanagement wird durch die Kommunikation mit dem Kühlsystem des Fahrzeugs umgesetzt, wodurch je nach Ausgestaltung desselben ein Heizen des Batteriesystems oder eine Kühlung angefordert wird.

Das BMS wird durch einen oder mehrere Mikrocontroller realisiert, welche die Überwachung jeweils eines Teils der im System enthaltenen Batteriezellen übernehmen. Die Mikrocontroller kommunizieren untereinander sowie mit anderen Fahrzeugkomponenten über Bus-Systeme. Gängige BMS-Architekturen weisen eine Master-Slave-Topologie auf, wobei das Master-Steuergerät übergeordnete Regel-, Überwachungs- und Kommunikationsaufgaben übernimmt, wohingegen die Slave-Steuergeräte für die Überwachung einer oder mehrerer Zellen zuständig sind [45, 46].

2.4 Intelligente Batteriesysteme

Schwerpunkt dieser Arbeit wie auch Gegenstand aktueller Forschung sind intelligente Batteriesysteme (IBSs), welche sich von den bis hierhin vorgestellten Batteriesystemen in mehrerlei Hinsicht unterscheiden. Einen umfassenden Überblick über das Forschungsgebiet geben Komsijska et al. [18] und Wei et al. [30].

Als ein wesentliches Kennzeichen im Unterschied zu herkömmlichen Batteriesystemen sind IBSs mit zellindividueller Sensorik ausgestattet. Neben Messtechnik zur Erfassung von Strom und Spannung können beispielsweise Zelltemperaturen erfasst und verarbeitet werden. Die Überwachung der Zellspannung ist eine auch in herkömmlichen BMSs umgesetzte Funktion, da die Einhaltung der Spannungsgrenzen für die Betriebssicherheit der Batterie essentiell ist. Aus messtechnischer Sicht ist die Erfassung der Zellspannung keine Herausforderung. Für die Zellstrom-Messung dahingegen gelten einige Anforderungen. Zunächst muss der Messbereich den gesamten zulässigen Strombereich der Batteriezelle abdecken. Insbesondere vor dem Trend, Zellen mit immer größerer Kapazität einzusetzen, stellt dies hohe Anforderungen an den Sensor. Die Abtastfrequenz ergibt sich aus der Dynamik des Anregungsstroms ebenso wie aus der Zykluszeit des BMS. Shunt-Widerstände zur Strommessung sind weit verbreitet. Sie weisen ein lineares Verhalten auf und ermöglichen so prinzipiell eine akkurate Messung. Allerdings ist zu beachten, dass der zusätzliche Widerstand im Strompfad die Leistungsfähigkeit des Batteriesystems negativ beeinflusst. Außerdem wird eine zusätzliche Wärmequelle im Batteriesystem geschaffen. Daraus resultiert die Forderung nach einem kleinen Widerstand, weswegen der Spannungsabfall über den Shunt jedoch verstärkt werden muss. Hierdurch resultieren Fehler und Nichtlinearitäten der Strommessung insgesamt. Eine Alternative bieten Hall-Effekt-basierte Stromsensoren, welche keinen zusätzlichen Widerstand im Strompfad verursachen. Diese Sensortechnologie kann jedoch anfällig sein für Störeinflüsse von außen. Nicht zuletzt spielt auch der Bauraum für die Wahl eines geeigneten Sensors eine wichtige Rolle. Temperatursensoren werden üblicherweise auf dem

Gehäuse der Batteriezelle appliziert. Zwar existieren Forschungsarbeiten zur Integration von Temperatursensoren in die Zelle selbst [47, 48], allerdings verhindern chemische Zersetzungsreaktionen bisher einen kommerziellen Einsatz [22, 49]. Die Bestimmung der Zellkerntemperatur bleibt damit eine Herausforderung, da sie erheblich von der messtechnisch erfassbaren Gehäusetemperatur abweichen kann [50].

Für die Messdatenerfassung und Signalverarbeitung können intelligente Batteriezellen eine eigene Recheneinheit ausweisen und bilden auf diese Weise ein selbstständiges Datenverarbeitungssystem. Für diese Batteriezellen hat sich der englische Begriff *smart cell* etabliert [51–54]. In einer dezentralen BMS-Architektur kommunizieren die intelligenten Batteriezellen miteinander und gegebenenfalls mit einer zentralen Recheneinheit. Bei einer hohen Anzahl an Zellen, aus denen sich das Batteriesystem zusammensetzt, stellt die Übertragung der vielen Daten und die hohe Anzahl an Kommunikationsteilnehmern eine Herausforderung dar.

Ein weiteres Kennzeichen von IBSs ist die Anwendung von Algorithmen und Methoden aus dem Bereich der künstlichen Intelligenz und des maschinellen Lernens. Damit können beispielsweise Funktionen der Fehlerdiagnose [55, 56], der Impedanzbestimmung [19, 57] oder der Zustands- und Parameterschätzung realisiert werden. Letztere ist Teil dieser Arbeit. Die Algorithmen können in der Recheneinheit der Zelle selbst implementiert werden. Sollten jedoch auch Sensordaten der anderen Zellen verarbeitet werden, ist eine Implementierung in einem übergeordneten Steuergerät sinnvoller.

Schließlich werden auch rekonfigurierbare Batteriesysteme (RBSs) als IBSs bezeichnet. Während in einem konventionellen Batteriesystem die Topologie des Systems durch die serielle und parallele Verschaltung der Batteriezellen untereinander fest vorgegeben ist, kann diese in RBSs durch Schaltelemente wie Leistungshalbleiterschaltern im Betrieb und reversibel verändert werden [58, 59]. Durch die Integration von Schaltern in den Strompfad des Batteriesystems wird dieses zum mechatronischen System, welches basierend auf den erfassten Sensordaten und sonstigen Informationen und entsprechenden Algorithmen Steuer- und Regeleingriffe durchführen kann. In RBSs können beispielsweise Funktionen zur Fehlerdiagnose [27, 28] oder zum Erreichen einer Fehlertoleranz genutzt werden, indem als defekt erkannte Batteriezellen aus dem Strompfad herausgenommen werden. Dies wird auch mit dem englischen Begriff *bad block management* bezeichnet. Weiterhin können Schalthandlungen in RBSs eingesetzt werden, um ein Balancing zwischen den seriell verschalteten Zellen zu realisieren [60–62]. Indem während eines Ladevorgangs diejenigen Zellen mit dem höchsten SOC bzw. während eines Entladevorgangs die Zellen mit dem niedrigsten SOC aus dem Strompfad genommen werden, gleichen sich die Ladezustände der Zellen untereinander an. Es ist ebenfalls möglich, durch geeignete Regelstrategien die Temperaturhomogenität innerhalb des Batteriesystems zu erhöhen und dadurch einer gleichmäßigen Alterung aller Zellen Vorschub zu leisten [63]. Schließlich kann durch Schaltvorgänge im hochfrequenten Bereich zusammen mit einer geeigneten Systemtopologie die Systemspannung derart moduliert werden, dass die für den Betrieb der elektrischen Maschine benötigte Wechselspannung statt durch die Leistungselektronik durch das IBS selbst erzeugt wird. Das resultierende System wird als Mehrphasen-Umrichter (engl. *multilevel inverter*) bezeichnet [64].

Eine Vielzahl von möglichen Schalter-Topologien kann unterschiedliche Arten von RBSs ermöglichen (eine Übersicht findet sich beispielsweise in [18, 58, 65]). Im Rahmen dieser Arbeit wird eine

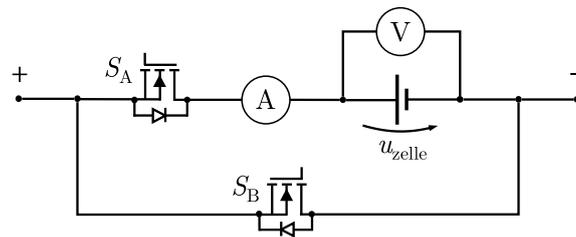


Abbildung 2.4: Schaltbild einer intelligenten Batteriezeile mit Strom- und Spannungsmessung auf Zellebene sowie Leistungs-Metall-Oxid-Halbleiter-Feldeffekttransistoren (MOSFETs) als Aktiv-Schalter S_A und Bypass-Schalter S_B .

einfache und weit verbreitete Topologie verwendet, welche in Abb. 2.4 gezeigt ist. Die intelligente Batteriezeile wird durch zwei Halbleiterschalter zu einer Halbbrücke (vgl. [26]), wobei durch den Aktiv-Schalter S_A der Stromfluss durch die Zelle geleitet werden kann und der Bypass-Schalter S_B die Lithium-Ionen-Zelle überbrückt. Es ergeben sich vier mögliche Kombinationen für die beiden Schalter, wobei eine davon (beide Schalter geschlossen) vermieden werden muss, da in diesem Fall die Zelle kurzgeschlossen würde. Als verbleibende Zustände ergeben sich der Aktiv-Zustand (S_A geschlossen, S_B geöffnet), der Ruhezustand (beide Schalter geöffnet) und der überbrückte Zustand (S_A geöffnet, S_B geschlossen), welcher im Folgenden auch als Bypass-Zustand bezeichnet wird. Zu beachten ist, dass in einem Parallelverbund von intelligenten Batteriezeilen der überbrückte Zustand einer Zelle neben aktiv geschalteten Zellen ebenfalls nicht erlaubt ist, da auch daraus ein Kurzschluss resultiert. Ferner führt das Schalten in den Ruhezustand von allen Zellen eines Parallelstrangs dazu, dass der Stromfluss durch das Batteriesystem unterbrochen ist. Schließlich muss zu jedem Zeitpunkt immer mindestens eine Zelle aktiv sein, um einen Kurzschluss der Quelle bzw. Last zu verhindern. In Abb. 2.4 sind auch die Sensoren zur Erfassung des Zellstroms und der Zellspannung dargestellt. Zu beachten ist, dass nur der Stromfluss durch den Aktiv-Pfad gemessen wird, wohingegen der den Bypass-Pfad durchlaufende Strom unbekannt ist. Die Zellspannung entspricht immer der Spannung der Lithium-Ionen-Zelle selbst, unabhängig von den Schalterstellungen.

2.5 Definition wichtiger Begriffe

Die **Nennkapazität** oder nominelle Kapazität Q_{nenn} gibt die Ladungsmenge an, welche der Batterie in einem vom Hersteller spezifizierten Entladezyklus unter definierten Randbedingungen entnommen werden kann. Neben der Höhe des Entladestroms, der Entladeschlussspannung und der Temperatur ist auch der zuvor durchgeführte Ladevorgang für die zu erzielende Kapazität maßgeblich. Üblicherweise wird die Kapazität in der Einheit Amperestunden (Ah) angegeben. Die Kapazität neuer Zellen kann oberhalb der Nennkapazität liegen, weil der Hersteller diese als untere Grenze der verfügbaren Kapazität garantiert.

Häufig wird die Angabe des Stroms, mit dem die Zelle beaufschlagt wird, auf die Nennkapazität normiert. Es ergibt sich die **C-Rate**. Beispielsweise bedeutet die Laderate von 1 C, dass eine Batteriezeile mit der nominellen Kapazität von 10 Ah mit einem Strom von 10 A geladen wird. In

dieser Arbeit gilt die Konvention, dass Ladeströme positiv und Entladeströme negativ angegeben sind.

Die tatsächlich **nutzbare Kapazität** Q berücksichtigt die zum aktuellen Zeitpunkt vorherrschenden Randbedingungen, insbesondere die Temperatur und den Entladestrom. Je mehr sich die Zelle erwärmt, desto geringer werden die der Zelle inhärenten Widerstände, sodass bis zum Erreichen der Entladeschlussspannung eine größere Ladungsmenge der Zelle entnommen werden kann [66]. Bei höheren Stromraten bedingt der Ohmsche Spannungsabfall ein vorzeitiges Erreichen der unteren Spannungsgrenze. Auch abhängig von der fortschreitenden Zellalterung der Zelle kann die Ladungsmenge, welche der Zelle entnommen werden kann, geringer als die Nennkapazität sein. Die nutzbare Kapazität wird nach dem gleichen Prüfablauf wie die Nennkapazität ermittelt.

Im Datenblatt einer Lithium-Ionen-Zelle ist üblicherweise die **Ladeschlussspannung** als die maximale Spannungsgrenze definiert, bis zu der die Batteriezelle geladen werden darf. Ein Überladen kann eine Zellschädigung verursachen und ist unter jeden Umständen zu vermeiden. Ebenso wird im Datenblatt die **Entladeschlussspannung** angegeben, bis zu welcher die Zelle betrieben werden darf. Diese bestimmt sich durch diejenige Entladung, bei der noch keine Schädigung des Materials auftritt [36, S. 158].

Der **Ladezustand** (engl. *state of charge*, SOC) wird nach (2.2) durch Integration des Zellstroms bestimmt.

$$\text{SOC}(t) = \text{SOC}(t_0) + \frac{\eta}{Q} \cdot \int_{t_0}^t i_{\text{zelle}}(\tau) \, d\tau \quad (2.2)$$

Hierbei ist η die **Coulombsche Effizienz** (auch Coulombscher Wirkungsgrad oder Ladewirkungsgrad), welche das Verhältnis zwischen geladener und bei der Entladung entnommener Ladungsmenge angibt. Bei Lithium-Ionen-Zellen kann von einer Coulombschen Effizienz von nahezu 100 % ausgegangen werden. Dies gilt nicht für die ersten Ladezyklen (der sogenannten Formierung), bei welcher sich die Deckschichten auf den Elektroden bilden und freie Lithium-Ionen gebunden werden. Üblicherweise wird ein Ladezustand von 100 % definiert für eine Zelle, welche nach dem vom Hersteller spezifizierten Ladevorgang bei definierter Umgebungstemperatur geladen wurde. Da die nutzbare Kapazität Q im Nenner von (2.2) eine veränderliche Größe ist, darf diese aus mathematischer Sicht in (2.2) eigentlich nicht vor das Integral gezogen werden. Eine Lösung hierfür bietet die Verwendung der Nennkapazität Q_{nenn} anstelle der Nutzkapazität. Allerdings besteht ein Zusammenhang zwischen dem auf die Nutzkapazität bezogenen Ladezustand und der Leerlaufspannung der Batteriezelle, welche auch angesichts der Zellalterung näherungsweise erhalten bleibt. Deswegen ist eine Skalierung des Ladezustands abhängig von der fortschreitenden Zellalterung und der damit einhergehenden Kapazitätsabnahme zu empfehlen. Im Rahmen dieser Arbeit wird für die Kapazität in (2.2) die zu Beginn der Messung vorliegende nutzbare Kapazität herangezogen. Über den Verlauf der Messung wird diese dann als konstant angenommen, um eine verlässliche Bestimmung des SOC's zu ermöglichen. Da die Alterung der Zelle ein im Vergleich zur Versuchslänge sehr langsam ablaufender Prozess ist und gleichzeitig die Temperatur während der Experimente konstant gehalten wird, ist dies eine gültige Vereinfachung.

Als übliches **Ladeverfahren** für Lithium-Ionen-Zellen kann die Konstantstrom-Konstantspannungs-Ladung (engl. *constant current constant voltage*, CCCV) angewandt werden, um – unter der Berücksichtigung der Umgebungstemperatur – einen Ladezustand von 100 % zu erreichen. Hierbei

wird die Zelle zunächst mit einer konstanten Stromrate geladen (engl. *constant current*, CC), wobei die Zellspannung ansteigt. Sobald die obere Ladeschlussspannung erreicht ist, beginnt die Konstantspannungsphase (engl. *constant voltage*, CV), während derer die Ladespannung konstant gehalten wird. Dies resultiert in einem annähernd exponentiellen Absinken des Ladestroms. Der Ladevorgang wird abgebrochen, sobald der Ladestrom eine definierte Grenze unterschreitet.

Im Betrieb ist eine Batteriezelle verschiedenen Alterungsmechanismen unterworfen. Während die kalendarische Alterung ein fortwährender Prozess ist, welcher abhängig von den Lagerbedingungen stattfindet, insbesondere von Temperatur und Ladezustand [67], resultiert die zyklische Alterung zusätzlich auf dem Ladungsdurchsatz der Zelle [68], sowie der Stromrate [69]. Als physikalische und chemische Alterungseffekte können nach Birkl et al. [70] das Anwachsen oder die Zersetzung der SEI-Schicht, Kontaktverluste von Teilen des Elektrodenmaterials aufgrund von Partikelbruch, Dendritenbildung, die Bildung von metallischem Lithium (engl. *lithium plating*) und Korrosion der Stromableiter neben anderen genannt werden. Als Folge dieser Alterungsmechanismen schwindet die Menge an für den elektrochemischen Prozess bereitstehendem Lithium oder die verfügbare Menge an Elektrodenmaterial verringert sich. In der Folge können zwei dominante Alterungseffekte beobachtet werden. Zum einen sinkt die nutzbare Kapazität, zum anderen steigt der Widerstand der Zelle, wodurch ihre Leistungsfähigkeit sinkt. Zwischen der initialen Formierung der Zelle am Lebensdauerbeginn (engl. *begin of life*, BOL) und ihrem Lebensende (engl. *end of life*, EOL) können beide Parameter über den Gesundheitszustand (engl. *state of health*, SOH) quantifiziert werden. Je nachdem, ob der Anwendungsfall der Zelle eine hohe Energiemenge oder eine hohe Leistungsfähigkeit erfordert, ist das EOL üblicherweise definiert als der Zeitpunkt, zu dem sich entweder die nutzbare Kapazität Q auf 80% der nominellen Kapazität reduziert hat, oder zu dem sich der Innenwiderstand der Zelle R_0 verdoppelt hat [71, 72]. Abhängig von der Belastung können heutige Batteriezellen mehrere Tausend Zyklen durchlaufen, bis sie das Ende der Lebensdauer erreichen [33, S. 412].

3 Modellierung von Lithium-Ionen-Zellen und -Batteriesystemen

3.1 Modelle von Batteriezellen und -systemen

Modelle werden in der Ingenieurwissenschaft zur Beschreibung von physikalischen und anderen Systemen verwendet. Sie beschreiben das Verhalten ihrer Ausgangsgrößen basierend auf einem oder mehreren Systemeingängen. Weiterhin ist die Wahl eines spezifischen Modells immer ein Kompromiss aus der zu erzielenden Genauigkeit und der dafür notwendigen Komplexität. Ein Modellierungsansatz muss demnach für den spezifischen Anwendungsfall gewählt werden, um ein System im Rahmen der Modellgrenzen hinreichend genau zu beschreiben.

Isermann und Münchhof [73, S. 1 f.] unterscheiden grundsätzlich zwischen experimentellen/datengetriebenen und physikalischen Modellen. Während erstere basierend auf Messdaten parametrisiert werden, welche zuerst aus Experimenten gewonnen werden müssen und kein Wissen über den inneren Aufbau des Systems erlauben (Black-Box-Modell), fußen letztere auf physikalischen Gesetzmäßigkeiten und deren Gleichungen. Weiterhin kann zwischen parametrischen und nicht-parametrischen Modellen unterschieden werden, abhängig davon, ob sich das System durch eine Struktur mit einer endlichen Anzahl an Modellparametern beschreiben lässt [73, S. 13].

3.1.1 Modellierungsansätze für Lithium-Ionen-Zellen

Für die Modellierung des elektrischen Verhaltens von Lithium-Ionen-Zellen im Zeitbereich kann eine Vielzahl verschiedener Modellarten eingesetzt werden, welche das Spektrum von physikalischen bis zu experimentellen/datengetriebenen Modellen abdecken, wobei auch Mischformen existieren. Daneben liefert die elektrochemische Impedanzspektroskopie eine Beschreibung des Systemverhaltens im Frequenzbereich, wodurch jedoch in erster Linie die höherfrequente Systemdynamik abgebildet wird [74]. Diese Arbeit beschränkt sich jedoch auf Modelle im Zeitbereich.

Physikalische oder **elektrochemische Modelle** beschreiben das Zellverhalten aufgrund bekannter Gesetzmäßigkeiten auf Basis des Aufbaus der Batterie und der in ihr enthaltenen Stoffe. Eine Übersicht physikalischer Modelle von Lithium-Ionen-Zellen geben Santhanagopalan et al. [75]. Diese Art der Modelle kann zwar eine sehr hohe Genauigkeit erreichen, allerdings ist die Anzahl der benötigten Parameter sehr groß. In der Folge gestaltet sich die Bestimmung der Modellparameter sehr aufwändig und kann sogar ein Hinderungsgrund für den Einsatz physikalischer Modelle sein, weil diese Parameter für eine spezifische Zelle gar nicht zu ermitteln sind. Darüber hinaus sind diese Modelle in aller Regel nicht echtzeitfähig, auch wenn Ansätze dazu in der Literatur existieren [76–80]. Als populäre physikalische Modelle der Lithium-Ionen-Zelle sind das Pseudo-Two-Dimensional-Modell (P2D-Modell) [81, 82] und das Single-Particle-Model (SPM) [78, 83] bekannt. In ersterem wird die poröse Struktur der Aktivmaterialien durch kugelförmige Partikel des Aktivmaterials modelliert, die durch den Elektrolyten umgeben sind. In letzterem werden die Elektroden durch jeweils ein kugelförmiges Partikel substituiert. Weitere

Vereinfachungen sind die Vernachlässigung von Konzentrationsunterschieden des Elektrolyten zwischen Kathode und Anode sowie jedweder Nebenreaktionen der Zellchemie. Damit verringert sich die Komplexität des Modells in gleichem Maße wie dessen Genauigkeit, da insbesondere bei hohen Stromraten der Einfluss des Konzentrationsunterschieds der Lithium-Ionen innerhalb der Elektroden nicht abgebildet wird [75].

Wird das Modellverhalten von empirischen oder stochastischen Gleichungen beschrieben, spricht man von **empirischen Modellen**. Diese Gleichungen können auf physikalischen Gesetzmäßigkeiten beruhen und werden auf der Basis von Messdaten aus Versuchen und Experimenten parametrisiert. Beispiele für empirische Modelle sind das Shepard-Modell oder das Nernst-Modell, welche die Ausgangsspannung als Summe einer Gleichspannung, dem Spannungsabfall an einem Innenwiderstand und weiteren vom Ladezustand abhängigen Funktionen abbilden [84]. Empirische Modelle können sehr effizient sein, beschränken sich aber auf den spezifischen Anwendungsbereich, für den sie ausgelegt sind, um beispielsweise Alterungseffekte zu präzisieren [85]. Die Genauigkeit dieser Modelle ist durch die häufig zugrunde liegenden einfachen Gleichungen begrenzt.

Stehen ausreichend Trainingsdaten zur Verfügung, können die Zusammenhänge zwischen Systemeingang und -ausgang durch **datengetriebene Modelle** beschrieben werden. Diese Black-Box-Modelle beruhen beispielsweise auf nichtparametrischen Modellen wie künstlichen neuronalen Netzen [12, 86–88] oder Support-Vector-Machines [13]. Während datengetriebene Modelle sehr effizient betrieben werden können, ist deren Training häufig sehr aufwendig. Die erzielbare Genauigkeit hängt hierbei von der Qualität der Trainingsdaten ab und sollte den gesamten möglichen Betriebsbereich des Modells umfassen, da die Extrapolation des Modellverhaltens auf nicht trainierte Arbeitspunkte meist sehr schlecht funktioniert. Weiterhin besteht die Gefahr einer Überanpassung, d. h. das Modell ist zu sehr auf die Trainingsdaten angepasst, worunter die Generalisierungsfähigkeit des Modells leidet [89, S. 22].

Als de-facto-Standard für die echtzeitfähige Modellierung von Lithium-Ionen-Zellen in BMSs haben sich Ersatzschaltbildmodelle (engl. *equivalent circuit models*, ECMs) etabliert. Das dynamische Verhalten der Zellspannung bilden ECMs durch einen elektrischen Schaltkreis ab, welcher Spannungsquellen, Widerstände, Induktionen und Kapazitäten beinhalten kann. Dadurch lässt sich das elektrische Verhalten der Batteriezelle durch wenige Modellparameter beschreiben. Die Parameter der elektrischen Bauteile können abhängig vom Ladezustand, der Temperatur oder dem SOH variieren. Einen Überblick über ECMs für die Modellierung von Lithium-Ionen-Zellen findet sich in [90–93]. In Abb. 3.1 sind typische Komponenten dargestellt, aus denen sich ECMs zusammensetzen. Beispielsweise besteht das Rint-Modell aus (a) einer Spannungsquelle und (b) einem Ohmschen Widerstand, wobei beide Größen vom SOC, SOH und der Temperatur abhängig sind [90]. Ein stromrichtungsabhängiger Innenwiderstand für das Batteriemodell kann, wie in (c) gezeigt, durch ideale Dioden modelliert werden. Das Thevenin-Modell setzt sich neben (a) der Spannungsquelle aus (b) einem Ohmschen Widerstand und (e) aus einem RC-Element zusammen, welches das transiente Verhalten der Zellspannung während einer Strombelastung abbildet [94]. Ergänzt man das Thevenin-Modell um (d) eine zusätzliche Kapazität vor dem RC-Glied, welche die Änderung der Leerlaufspannung während des Ladevorgangs beschreibt, ergibt sich das PNGV-Modell (*Partnership for New Generation of Vehicles*). Dahingegen entsteht das Dual-Polarization-Modell (DP-Modell) durch eine Erweiterung des Thevenin-Modells um ein weiteres RC-Glied. Die über den beiden RC-Gliedern abfallenden Spannungen werden in der Literatur häufig gewissen

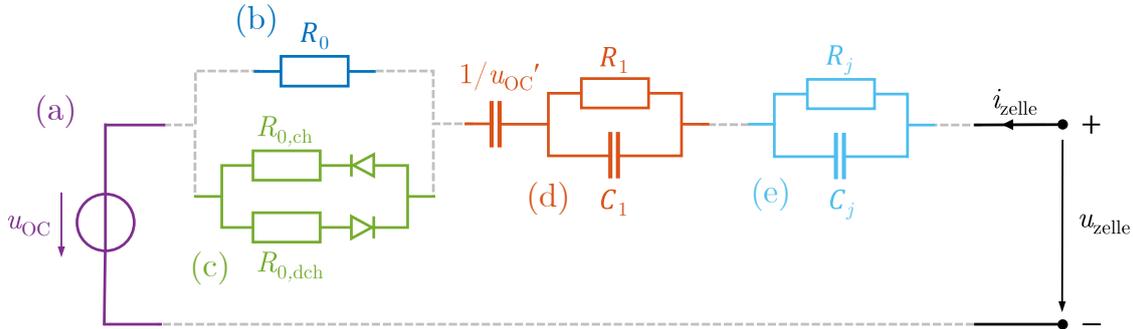


Abbildung 3.1: Ersatzschaltbildmodelle werden zusammengesetzt aus (a) einer ladezustandsabhängigen Gleichspannungsquelle, (b) einem Ohmschen Innenwiderstand oder (c) einem stromrichtungsabhängigen Innenwiderstand, (d) dem PNGV-Modell oder (e) einer beliebigen Anzahl von RC-Gliedern. Alle Modellparameter sind auch temperaturabhängig.

dynamischen physikalischen Effekten zugeordnet, z. B. dem Ladungsdurchtrittswiderstand der Lithium-Ionen durch die Passivierungsschicht auf den Elektroden, der Festkörperdiffusion oder der Doppelschichtkapazität [40, 92, 95]. Weiter verbreitet ist jedoch der Ansatz, das ECM als empirisches Modell aufzufassen und die Parameter der elektrischen Komponenten basierend auf Trainingsdaten zu bestimmen (siehe Kapitel 3.2). Aufbauend auf dem DP-Modell kann die Anzahl der RC-Glieder N_{RC} beliebig erweitert werden. Mit dem Fokus auf die Ladezustandsschätzung kommen Wang et al. [96] zu der Erkenntnis, dass eine Korrelation zwischen der Modellgenauigkeit und den Schätzergebnissen besteht. Je besser das Modell ist, desto geringer sind die Schätzfehler eines auf diesem Modell beruhenden Filters. Andererseits zeigen Untersuchungen jedoch, dass für NMC-Zellen zwei RC-Glieder einen guten Kompromiss zwischen der Modellgüte und dem Parametrierungsaufwand darstellen [94, 97–99]. Zu diesem Ergebnis kommen auch Hu et al. [100], welche die Modellparameter als ladezustands- und temperaturabhängige Größen annehmen. Im folgenden Abschnitt wird das im Rahmen dieser Arbeit verwendete Ersatzschaltbild genauer vorgestellt.

3.1.2 Elektrisches Ersatzschaltbildmodell der Lithium-Ionen-Zelle

Die Leerlaufspannung einer Lithium-Ionen-Zelle wird im Ersatzschaltbild durch eine Gleichspannungsquelle repräsentiert, deren Spannung u_{OC} abhängig vom SOC und der Zelltemperatur T variiert. Der Zusammenhang ist nichtlinear und wird in der Literatur durch analytische Funktionen (z. B. Polynome [101, 102] oder Splines [103]), ANNs [104] oder Look-up-Tabellen abgebildet [105]. Die Funktion der ladezustandsabhängigen Leerlaufspannung wird auch als OCV-Kurve bezeichnet. Die Änderung der Leerlaufspannung ist bei niedrigen und hohen Ladezuständen größer, wohingegen sie sich – abhängig von der Zellchemie – bei mittleren SOC geringer ändert. Aus (2.2) kann die Differentialgleichung für die stromabhängige Änderung des SOC hergeleitet werden:

$$\dot{\text{SOC}} = \frac{\eta \cdot i_{\text{zelle}}}{3600 \cdot Q}. \quad (3.1)$$

Der Faktor 3600 berücksichtigt die Konvention, die Kapazität in Amperestunden anzugeben, wohingegen die Zeit in Sekunden gemessen wird. Der Coulombsche Wirkungsgrad η wird als 100% angenommen. Da die nutzbare Kapazität Q mit zunehmender Alterung sinkt, ist der Ladezustand eine vom SOH abhängige Größe. Unter der Annahme, dass die Alterung über die Kapazitätsabnahme in erster Linie eine Stauchung der OCV-Kurve verursacht [106], ist dann auch die Leerlaufspannung vom SOH abhängig.

Die Zellspannung reagiert auf eine Strombelastung der Zelle mit einer unstetigen Spannungsänderung gemäß dem Ohmschen Gesetz und wird durch R_0 im Ersatzschaltbild repräsentiert. Mit höheren Temperaturen steigt die Reaktionsrate der elektrochemischen Prozesse gemäß der Arrhenius-Gleichung. Weiterhin erhöht sich die Ionen-Leitfähigkeit der Elektroden und des Elektrolyten. Dadurch sinkt der Innenwiderstand der Lithium-Ionen-Zellen [107]. Weiterhin ist R_0 auch ladezustandsabhängig, weil sich die Ausdehnung der Elektroden abhängig von ihrem Lithiierungsgrad ändert. Beim Ladevorgang dehnt sich die Anode durch die Interkalation von Lithium aus [108]. Dadurch erhöht sich bei einer zylindrischen oder prismatischen Lithium-Ionen-Zelle mit fester Dimension der mechanische Druck der Elektroden, der Stromableiter und des Separators zueinander, wodurch die Übergangswiderstände sinken und die Leitfähigkeit steigt. Dies resultiert in einem geringeren Innenwiderstand. Auch eine fortschreitende Alterung wird in R_0 sichtbar, da die SEI-Schicht, welche die Anode bedeckt, typischerweise über die Batterie-Lebensdauer anwächst [70]. Dadurch erhöht sich deren Durchtrittswiderstand, was sich in einer Erhöhung des Innenwiderstands niederschlägt. Allerdings beobachten Li et al. [109] in ihren Untersuchungen eine Abnahme des Ohmschen Widerstands mit steigender Zahl an Lastzyklen. Sie führen dies darauf zurück, dass bei Formierung der SEI-Schicht die Li^+ -Konzentration im Elektrolyten steigt, was zu einem verringerten Widerstand führt. Diese Beobachtungen stehen aber beispielsweise den Resultaten anderer Veröffentlichungen entgegen [110–112], welche einen Anstieg des Innenwiderstands messen. Weiterhin kann auch die mechanische Verspannung und die ladezustandsabhängige Verpressung der Zelle den Innenwiderstand beeinflussen [113, S. 10].

Die dynamische Spannungsantwort einer Lithium-Ionen-Zelle auf einen Entlade-Strompuls zeigt Abb. 3.2. Der Zusammenhang der Systemantwort mit den einzelnen Bauteilen des ECMs ist ebenfalls dargestellt. Ausgehend von der Leerlaufspannung lässt sich der Ohmsche Spannungsabfall zum Zeitpunkt t_1 beobachten, zu welchem die Zelle mit dem Entladestrom i_{zelle} beaufschlagt wird. Dieser ist durch R_0 modelliert. Anschließend sinkt die Zellspannung weiter ab, was sich auf mehrere überlagernde Effekte zurückführen lässt. Zum einen sinkt u_{OC} durch die Entladung der Zelle, zum anderen ändern sich die Polarisationsspannungen u_1 und u_2 , welche durch die RC-Glieder im Ersatzschaltbild modelliert werden. Endet der Strompuls zum Zeitpunkt t_2 , ist der Spannungsverlauf bis auf die Veränderung von u_{OC} umgekehrt. Der unmittelbare Anstieg der Zellspannung ist auf den Ohmschen Widerstand R_0 zurückzuführen. Anschließend nähert sie sich mit der Entladung der RC-Glieder wieder der Leerlaufspannung an, welche aufgrund des geringeren SOC unterhalb der ursprünglichen Ruhespannung liegt.

Als Differentialgleichung für das j -te RC-Glied lässt sich

$$\dot{u}_j = \frac{i_{\text{zelle}}}{C_j} - \frac{u_j}{R_j C_j} = \frac{i_{\text{zelle}} \cdot R_j}{\tau_j} - \frac{u_j}{\tau_j} \quad (3.2)$$

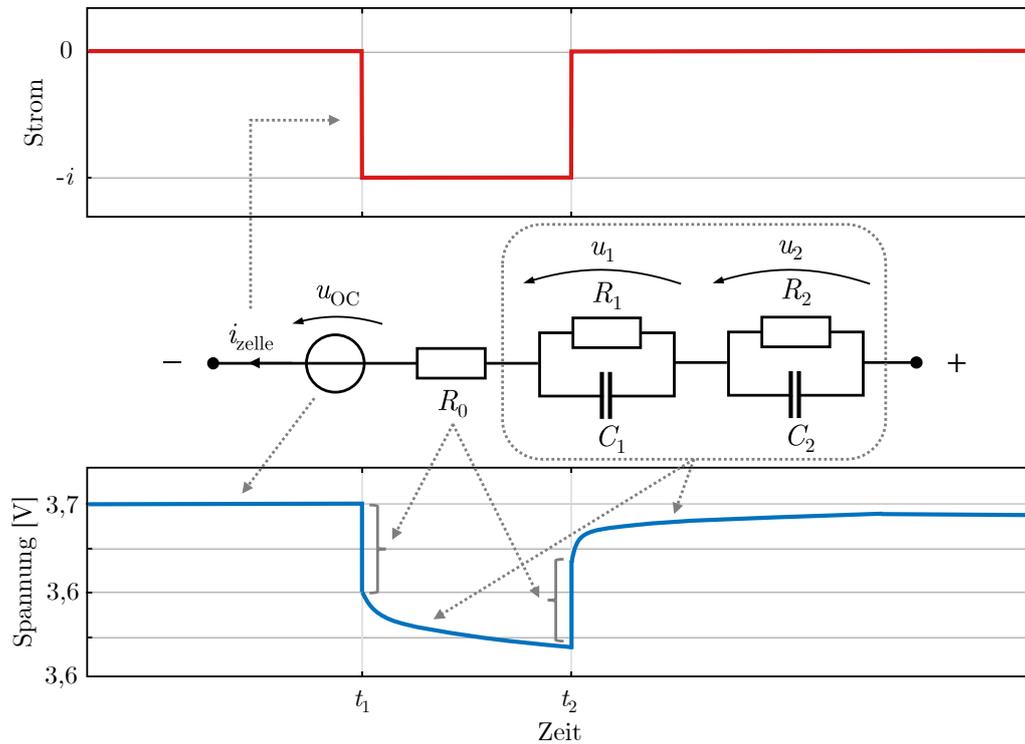


Abbildung 3.2: Spannungsantwort einer Batteriezelle auf einen Strompuls und korrespondierende Komponenten des Ersatzschaltbildmodells.

ansetzen, wobei sich die alternative Notation durch die Substitution $\tau_j = R_j \cdot C_j$ mit der Zeitkonstante des RC-Glieds ergibt. Auch die Parameter der RC-Glieder können temperaturabhängig sein, weil sich die zugrundeliegenden elektrochemischen Effekte gemäß der Arrhenius-Gleichung verändern. Ebenso kann eine Abhängigkeit vom SOH angenommen werden. Die resultierende Zellspannung ergibt sich als Summe der Leerlaufspannung mit den Polarisationspannungen der RC-Glieder und dem Ohmschen Spannungsabfall am Innenwiderstand zu

$$u_{\text{zelle}} = u_{\text{OC}} + \sum_{j=1}^{N_{\text{RC}}} u_j + R_0 \cdot i_{\text{zelle}}. \quad (3.3)$$

Die mathematischen Zusammenhänge des dynamischen Systemverhaltens des ECMs aus (3.1), (3.2) und (3.3) lassen sich in einer für die Zustandsschätzung vorteilhaften Art und Weise im Zustandsraum darstellen. Mit der Wahl des Zustandsvektors

$$\mathbf{x} = [\text{SOC} \quad u_1 \quad u_2]^T \quad (3.4)$$

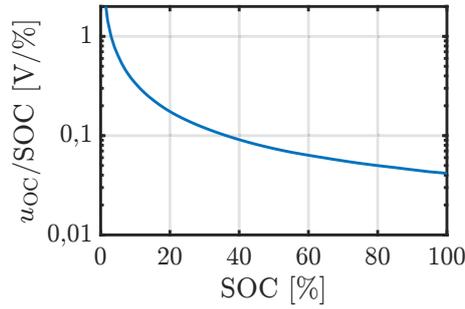


Abbildung 3.3: Quotient aus Leerlaufspannung und Ladezustand.

ergibt sich ein lineares System der Dimension $n = 3$ mit $p = 1$ Eingängen und $q = 1$ Ausgängen, welches als Single-Input-Single-Output-System (SISO-System) bezeichnet wird zu

$$\underbrace{\begin{bmatrix} \dot{\text{SOC}} \\ \dot{u}_1 \\ \dot{u}_2 \end{bmatrix}}_{\dot{\mathbf{x}}} = \underbrace{\begin{bmatrix} 0 & 0 & 0 \\ 0 & -\frac{1}{R_1 C_1} & 0 \\ 0 & 0 & -\frac{1}{R_2 C_2} \end{bmatrix}}_{\Phi} \underbrace{\begin{bmatrix} \text{SOC} \\ u_1 \\ u_2 \end{bmatrix}}_{\mathbf{x}} + \underbrace{\begin{bmatrix} \frac{\eta}{3600Q} \\ \frac{1}{C_1} \\ \frac{1}{C_2} \end{bmatrix}}_{\Gamma} \underbrace{i_{\text{zelle}}}_{u} \quad (3.5a)$$

$$\underbrace{u_{\text{zelle}}}_{y} = \underbrace{\begin{bmatrix} \frac{u_{\text{OC}}(\text{SOC})}{\text{SOC}} & 1 & 1 \end{bmatrix}}_{\mathbf{H}} \underbrace{\begin{bmatrix} \text{SOC} \\ u_1 \\ u_2 \end{bmatrix}}_{\mathbf{x}} + \underbrace{R_0}_{\Psi} \underbrace{i_{\text{zelle}}}_{u}, \quad (3.5b)$$

wobei das System durch die Matrix $\Phi \in \mathbb{R}^{n \times n}$, die Vektoren $\Gamma \in \mathbb{R}^{n \times p}$ und $\mathbf{H} \in \mathbb{R}^{q \times n}$ sowie den Skalar $\Psi \in \mathbb{R}^{q \times q}$ beschrieben wird. Zur Verdeutlichung sind Vektoren und Matrizen in dieser Arbeit fett gedruckt, um sie von skalaren Größen zu unterscheiden. Weiterhin wurde aus Gründen der Übersichtlichkeit auf die explizite Darstellung der Abhängigkeiten der Modellparameter vom SOC, der Temperatur T und dem SOH verzichtet. Ausgenommen hiervon ist die Leerlaufspannung, da deren SOC-Abhängigkeit am stärksten ausgeprägt ist und in keiner Vereinfachung des Modells vernachlässigt werden kann. Um die Nichtlinearität der OCV-Funktion zu berücksichtigen, ohne die wünschenswerte Eigenschaft der Linearität für das Modell nach (3.5) zu verlieren, enthält das erste Element des Ausgangsvektors \mathbf{H} den Faktor $\frac{1}{\text{SOC}}$, der sich nach der Multiplikation $\mathbf{H}\mathbf{x}$ mit dem SOC herauskürzt. Eine Alternative böte die Wahl von u_{OC} anstelle vom SOC als Zustandsgröße [114]. In Abb. 3.3 ist der Verlauf von $\frac{u_{\text{OC}}}{\text{SOC}}$ in Abhängigkeit von SOC für eine Batteriezelle bei 25 °C dargestellt. Wie im Diagramm zu erkennen ist, wird der Wert für $\text{SOC} \rightarrow 0$ beliebig groß. Die Batteriezellen in heutigen Elektrofahrzeugen werden jedoch nie vollständig entladen, sondern nur in einem SOC-Fenster betrieben. Daher sind keine Ladezustände unter 10% zu erwarten. Damit bleibt der Wert deutlich unter 1 V/% und es sind für die Modellierung des Systems mit den Zustandsgleichungen keine numerischen Probleme zu erwarten.

Für die Implementierung des Modells in Recheneinheiten wie Mikrocontrollern und Steuergeräten ist eine Diskretisierung der Modellgleichungen mit der äquidistanten Schrittweite t_s vorteilhaft. Unter der Annahme, dass der Systemeingang u für die Dauer einer Iteration konstant sei, was durch ein Halteglied in digitalen Regelsystemen realisiert werden kann, lassen sich die

Differentialgleichungen lösen und es ergibt sich das diskrete System im Zustandsraum mit der Systemmatrix $\mathbf{A} \in \mathbb{R}^{n \times n}$, dem Eingangsvektor $\mathbf{B} \in \mathbb{R}^{n \times p}$, dem Ausgangsvektor $\mathbf{C} \in \mathbb{R}^{q \times n}$ und dem Durchgriff $D \in \mathbb{R}^{q \times q}$. Im Rahmen dieser Arbeit werden zeitkontinuierliche Größen durch runde Klammern als beispielsweise $x(t)$ notiert. Dahingegen wird für zeitdiskrete Größen $x(k \cdot t_s)$ die Index-Schreibweise x_k verwendet und es ergibt sich

$$\mathbf{x}_{k+1} = \underbrace{\begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{t_s}{R_1 C_1}} & 0 \\ 0 & 0 & e^{-\frac{t_s}{R_2 C_2}} \end{bmatrix}}_{\mathbf{A}} \mathbf{x}_k + \underbrace{\begin{bmatrix} \frac{\eta t_s}{3600Q} \\ R_1(1 - e^{-\frac{t_s}{R_1 C_1}}) \\ R_2(1 - e^{-\frac{t_s}{R_2 C_2}}) \end{bmatrix}}_{\mathbf{B}} \underbrace{i_{zelle,k}}_{u_k} \quad (3.6a)$$

$$\underbrace{u_{zelle,k}}_{y_k} = \underbrace{\begin{bmatrix} \frac{u_{OC}(\text{SOC}_k)}{\text{SOC}_k} & 1 & 1 \end{bmatrix}}_{\mathbf{C}} \mathbf{x}_k + \underbrace{R_0}_{D} \underbrace{i_{zelle,k}}_{u_k}. \quad (3.6b)$$

Als nützliche Modellgröße wird an dieser Stelle die Spannung u_Σ eingeführt

$$u_\Sigma = u_{OC} + \sum_{j=1}^{N_{RC}} u_j = \mathbf{C} \mathbf{x}, \quad (3.7)$$

welche der Summe von u_{OC} mit den Polarisationsspannungen entspricht. Die Bestimmung der Modellparameter für einen bestimmten Zelltyp oder eine spezielle Zelle erfolgt durch Versuche, welche auch als Charakterisierungsversuche bezeichnet werden. Die Bestimmung der Parameter von den in dieser Arbeit verwendeten Zellen erfolgt in Kapitel 3.2.

3.1.3 Modellierung von Batteriesystemen

Batteriesysteme als Energiespeicher für Traktionsantriebe in Elektrofahrzeugen bestehen immer aus dem Zusammenschluss von Zellen in seriellen Strängen und parallelen Zellverbänden. Daraus ergibt sich der Bedarf an Systemmodellen, welche ein Zusammenschluss der im vorherigen Abschnitt vorgestellten Zellmodelle sind. Allgemein gilt die vereinfachende Annahme: Die Systemspannung ist die Summe der Spannungen der seriell verschalteten Stränge. Innerhalb eines Parallelstrangs ist die Zellspannung der Batteriezellen identisch. Kontaktwiderstände zwischen den Zellen werden demnach vernachlässigt. Während die Summe der Ströme zwischen den seriellen Strängen immer gleich dem Gesamtstrom sein muss, teilt sich dieser innerhalb eines Parallelverbands zwischen den Zellen auf. Abhängig von der Homogenität der in diesem Verbund enthaltenen Lithium-Ionen-Zellen, kann das Verhältnis der Ströme zueinander sehr unterschiedlich ausfallen. Insbesondere für die modellbasierte Sensordatenfusion, welche in Kapitel 6 vorgestellt wird, ist die Modellierung der Stromaufteilung innerhalb des Batteriesystems eine wichtige Grundlage.

Die Stromaufteilung innerhalb parallelgeschalteter Batteriezellen ist in den vergangenen Jahren eine Forschungsfrage von großem Interesse. Eine frühe Untersuchung stammt von Fouchard und Taylor [115], die Batteriepacks in verschiedenen Topologien untersucht haben. Die Autoren stellen aufgrund der Ausgleichsströme zwischen parallelen Zellsträngen eine reduzierte Lebensdauer

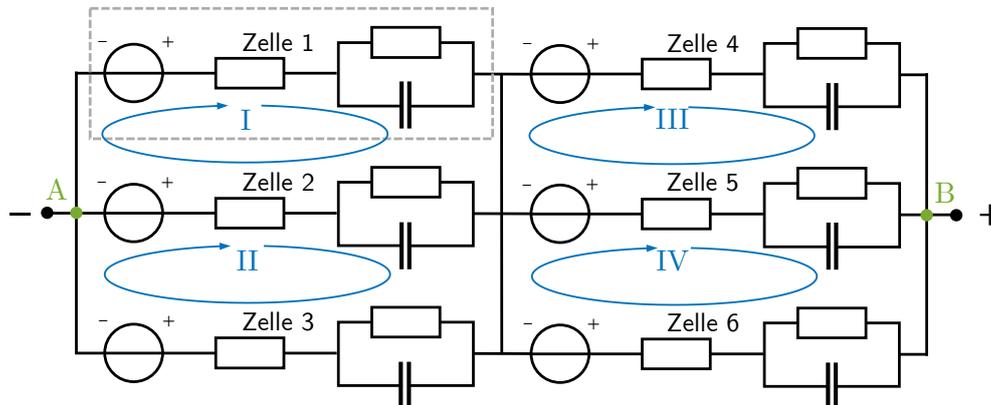


Abbildung 3.4: Ersatzschaltbild eines Batteriesystems in 2s3p-Topologie mit den Maschen I bis IV und den Knoten A und B gemäß der Kirchhoffschen Gesetze.

eines Batteriesystems gegenüber rein seriellen Topologien fest. Zhang et al. [116] validieren durch Experimente ihre Simulationen der Stromaufteilung, wobei unterschiedliche Spannungen, Ströme, Zellkapazitäten und -widerstände berücksichtigt werden. Grundlage sind ECMs der Batteriezellen. Häufig werden die Batteriemodelle stark vereinfacht, indem beispielsweise einfache Rint-Modelle genutzt werden. Dadurch lässt sich die Stromaufteilung zumindest für eine kleine Anzahl paralleler Zellen analytisch berechnen [117–121]. Alternativ dazu lösen Dubarry et al. [122] ein lineares Gleichungssystem, um für jeden Zeitpunkt aus der Differenz der Leerlaufspannungen der Zellen einen Zellstrom zu ermitteln, welche über den Spannungsabfall am Innenwiderstand diese Spannungsdifferenz kompensiert. Brand et al. [117] legen den Fokus ihrer Arbeit auf einen aufwändigen Messaufbau, mit dem die Stromaufteilung zwischen zwei parallelen Batteriezellen gemessen werden kann. Bruen et al. [123] berücksichtigen auch die Kontakt- und Stromschienenwiderstände für die Modellierung der Stromaufteilung. Allerdings unterscheidet sich die von ihnen genutzte Leiter-Verschaltung der Zellen, bei welcher der Abgriff der Systemspannung an den Polen einer Zelle stattfindet, von der im Rahmen dieser Arbeit verwendeten Konfiguration (vgl. Abb. 3.4).

Grundsätzlich ist das Ergebnis der vorgestellten Untersuchungen, dass ein einfacher Zusammenhang zwischen den Zellparametern und den daraus resultierenden Strömen nicht gefunden werden kann. Während zunächst das Verhältnis der Innenwiderstände für die Stromaufteilung maßgeblich ist, werden mit fortlaufender Entladung die Zellkapazitäten dominant, weil die schnellere Entladung zu einem stärkeren Abfall der Leerlaufspannung führt, wodurch der betreffende Zellstrom sinkt [117]. Insgesamt variiert der Verlauf der Zellströme aber über der Zeit und ist – nicht zuletzt aufgrund des nichtlinearen Verlaufs der Leerlaufspannung abhängig vom SOC – nur schwer zu präzisieren [124]. Entladen sich die Batteriezellen im Parallelverbund aufgrund ihrer Parameter-Heterogenität unterschiedlich schnell, kommt es am Ende von Entladephasen zu Ausgleichsströmen zwischen den Zellen, bei denen sich die Ladezustände wieder aneinander angleichen, bis die Klemmenspannungen identisch sind. Wie Chang et al. [120] feststellen, sind diese Ausgleichsströme weniger dynamisch, wenn die OCV-Kurve einen flachen Verlauf hat, wie es für LFP-Kathoden der Fall ist.

Am weitesten verbreitet ist die Modellierung der Stromaufteilung über ein ECM des Batteriesystems, welches numerisch gelöst wird [114, 123, 125–129]. Im Folgenden wird eine Vektor-Matrix-basierte Berechnungsmethode für die Zellströme innerhalb eines Batteriesystems vorgestellt [114, 129, 130]. Zur Veranschaulichung beziehen sich die folgenden Berechnungen auf ein exemplarisches Batteriesystem mit 3s2p-Topologie, wie es in Abb. 3.4 dargestellt ist. Eine Übertragung auf beliebige Systemtopologien ist ohne weiteres möglich. In der Abbildung wurde aus Gründen der Übersichtlichkeit nur ein RC-Glied des Zellmodells dargestellt. Weitere Vereinfachungen des System-Ersatzschaltbildes betreffen zusätzliche Widerstände, welche sich aus dem konstruktiven Aufbau eines Batteriesystems ergeben. Nach Schmid et al. [130] sind dies die Kontaktwiderstände am positiven und negativen Terminal der Batteriezelle, sowie die Leitungswiderstände der Stromschienen, mit welchen die Zellen miteinander verbunden werden. Während die Kontaktwiderstände ohne Wechselwirkungen dem Zellinnenwiderstand zugerechnet werden können und dies auch bei der vorgestellten Zellcharakterisierung in Kapitel 3.2 getan wird, sind die Stromschienenwiderstände aufgrund ihrer kleinen Werte vernachlässigbar. Eine Worst-Case-Abschätzung basierend auf den verwendeten Kupfer-Stromschienen ergibt einen Leitungswiderstand von unter $50 \mu\Omega$ für die Stromschiene zwischen zwei Zellen (siehe Abb. B.4 in Anhang B). Für die Kontaktwiderstände gehen Baumann et al. [131] von einem Wert von circa $150 \mu\Omega$ bis $200 \mu\Omega$ aus.

Gemäß den Kirchhoffschen Gesetzen können pro Parallelstrang $\mathcal{P} - 1$ Maschengleichungen aufgestellt werden, sowie eine Knotengleichung:

$$0 = u_{\Sigma,p+1} - u_{\Sigma,p} + (R_{0,p+1} - R_{0,p}) \cdot i_{zelle} \quad \text{für } p \in \{1, \dots, \mathcal{P} - 1\}, \quad (3.8a)$$

$$0 = i_{ges} - \sum_{p=1}^{\mathcal{P}} i_{zelle,p}. \quad (3.8b)$$

In (3.8) wie auch im Folgenden bezeichnet der zweite Index der Variablen die Zellnummer, auf die sich die Größe bezieht. Der den Parallelstrang durchfließende Strom entspricht dem Gesamtstrom des Batteriesystems i_{ges} und ist für jeden seriell verschalteten Parallelstrang gleich

groß. Dann lassen sich für das eingangs betrachtete 2s3p-System aus Abb. 3.4 alle Maschen- und Knotengleichungen aus (3.8) in Matrix-Vektor-Schreibweise wie folgt anordnen [114]

$$\begin{aligned}
 0 = & \underbrace{\begin{bmatrix} -1 & 1 & 0 & 0 & 0 & 0 \\ 0 & -1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1 & 1 & 0 \\ 0 & 0 & 0 & 0 & -1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}}_{\mathfrak{E}} \underbrace{\begin{bmatrix} u_{\Sigma,1} \\ u_{\Sigma,2} \\ u_{\Sigma,3} \\ u_{\Sigma,4} \\ u_{\Sigma,5} \\ u_{\Sigma,6} \end{bmatrix}}_{\mathbf{u}_{\Sigma}} + \\
 & \underbrace{\begin{bmatrix} -R_{0,1} & R_{0,2} & 0 & 0 & 0 & 0 \\ 0 & -R_{0,2} & R_{0,3} & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & -R_{0,4} & R_{0,5} & 0 \\ 0 & 0 & 0 & 0 & -R_{0,5} & R_{0,6} \\ 0 & 0 & 0 & 1 & 1 & 1 \end{bmatrix}}_{\mathfrak{R}} \underbrace{\begin{bmatrix} i_{zelle,1} \\ i_{zelle,2} \\ i_{zelle,3} \\ i_{zelle,4} \\ i_{zelle,5} \\ i_{zelle,6} \end{bmatrix}}_{\mathbf{i}_{zelle}} + \underbrace{\begin{bmatrix} 0 \\ 0 \\ -1 \\ 0 \\ 0 \\ -1 \end{bmatrix}}_{\mathfrak{F}} i_{ges}, \quad (3.9)
 \end{aligned}$$

wobei $\mathfrak{E} \in \mathbb{R}^{\mathcal{Z} \times \mathcal{Z}}$ und $\mathfrak{R} \in \mathbb{R}^{\mathcal{Z} \times \mathcal{Z}}$ Blockdiagonalmatrizen sind und sich jeder der $\mathcal{P} \times \mathcal{P}$ -Blöcke auf einen der \mathcal{S} Parallelverbände bezieht. Durch einige einfache Umformungen ergibt sich mit

$$\mathbf{i}_{zelle} = -\mathfrak{R}^{-1} (\mathfrak{E} \mathbf{u}_{\Sigma} + \mathfrak{F} i_{ges}) \quad (3.10)$$

ein kompakter Ausdruck zur Berechnung des Vektors der Zellströme \mathbf{i}_{zelle} basierend auf dem Gesamtstrom, den in \mathbf{u}_{Σ} enthaltenen Zuständen der Zellen und den Zellmodellparametern in \mathfrak{R} und \mathbf{u}_{Σ} .

Anhand einer Simulation eines kleinen Batteriesystems bestehend aus drei parallelen Zellen soll die Stromverteilung während einer Konstant-Entladung verdeutlicht und die Wirksamkeit der Modellierung gezeigt werden. Der Entladestrom hat während der gesamten Simulationsdauer von 500s einen Betrag von 45 A. Der initiale SOC beträgt für alle drei Zellen 100%. Um den Einfluss der Zellparameter auf die Stromverteilung zu visualisieren, weichen die nutzbare Kapazität und der Innenwiderstand der Zellen leicht voneinander ab: Während Zelle 1 eine Kapazität von 2500mAh bei einem Innenwiderstand von 25mΩ aufweist, ist die Kapazität bei Zelle 2 mit 2600mAh etwas größer. Der Innenwiderstand ist ebenfalls um 1mΩ erhöht. Die Zelle 3 hat dagegen eine verminderte nutzbare Kapazität von 2300mAh und der Innenwiderstand beträgt nur 23mΩ. Den simulierten Verlauf der Zellströme und -spannungen, sowie die Ladezustände der Zellen zeigt Abb. 3.5. Während die Klemmenspannungen der Batteriezellen aufgrund der Parallelschaltung über den Verlauf identisch sind, zeigen die Ströme ein deutlich komplexeres Verhalten. Zunächst trägt Zelle 3, welche den geringsten Innenwiderstand aufweist, die größte Stromlast. Zelle 2 dagegen ist aufgrund des höchsten Innenwiderstands zunächst am wenigsten belastet. Durch diese ungleiche Strombelastung driften jedoch auch die Ladezustände der Zellen auseinander. Da Zelle 3 die geringste Kapazität aufweist, sinkt deren SOC am schnellsten, was sich in einer schneller fallenden Leerlaufspannung niederschlägt. Aufgrund dieses Effekts kehrt

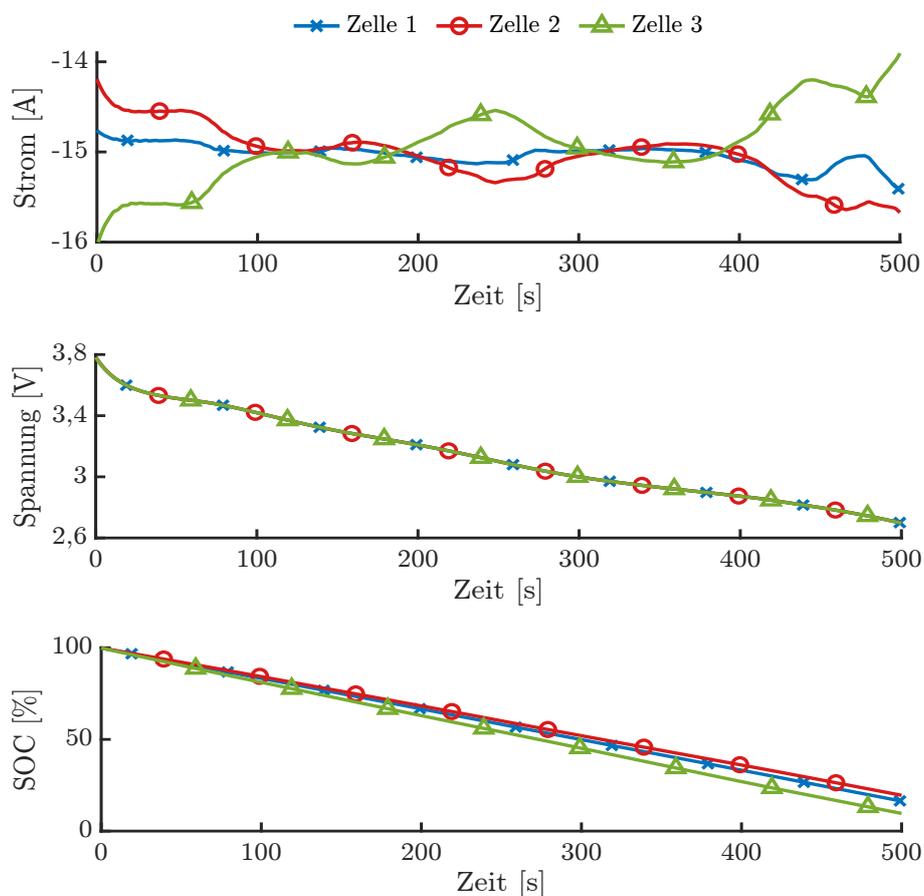


Abbildung 3.5: Modellierung einer Konstantstrom-Entladung (-45 A) eines 1s3p-Systems mit variierenden Zellparametern.

sich die Stromverteilung allmählich um und die Zelle mit der höchsten Kapazität – Zelle 2 – muss den Hauptteil der Stromlast tragen. Durch den nichtlinearen Verlauf der Leerlaufspannung schwankt die Verteilung der Ströme auf wenig intuitive Weise.

3.1.4 Einfluss von Parametervariationen

Abhängig davon, wie inhomogen die Parameter der in einem Batteriesystem verbauten Lithium-Ionen-Zellen sind, steigen die Ausgleichsströme zwischen parallel geschalteten Zellen. Weiterhin divergieren mit der Zeit auch die Ladezustände serieller Stränge, was häufiges Balancing notwendig macht. Beide Effekte können dazu führen, dass das Batteriesystem weniger effizient betrieben werden kann und die zyklische Alterung beschleunigt wird [131]. Um möglichst homogene Batteriesysteme zu erhalten, werden bei der Herstellung die Einzelzellen vor dem Verbau charakterisiert und entsprechend der Ergebnisse sortiert (engl. *cell matching*). Es werden beispielsweise Zellen mit ähnlichen Innenwiderständen [132], Kapazitäten [14] oder basierend auf dem Produkt $Q \cdot R_0$ [120] miteinander verbaut.

Inwiefern die Parameter von Lithium-Ionen-Zellen innerhalb einer Charge oder eines Systems variieren, wird in einer relevanten Zahl von experimentellen Arbeiten untersucht. Eine umfassende

Zusammenfassung stammt von Rumpf et al. [133]. Entscheidend für die Stromaufteilung ist in erster Linie die Streuung der nutzbaren Zellkapazität Q und des Innenwiderstands R_0 [130], auf welche sich auch der folgende Abschnitt beschränkt. Als statistische Kenngrößen für die Parameterverteilung innerhalb einer untersuchten Menge N werden in der Regel der Mittelwert μ und die Standardabweichung σ herangezogen:

$$\mu_x = \frac{1}{N} \cdot \sum_{i=1}^N x_i \quad (3.11a)$$

$$\sigma_x = \sqrt{\frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - \mu_x)^2}. \quad (3.11b)$$

Wird die Standardabweichung auf den Mittelwert normiert, ergibt sich der Koeffizient der Parameterstreuung

$$\kappa_x = \frac{\sigma_x}{\mu_x}, \quad (3.12)$$

welcher im Folgenden aus Gründen der Vergleichbarkeit genutzt wird.

In Tabelle 3.1 sind Arbeiten der letzten Jahre aufgeführt, in denen die Parametervariation von Lithium-Ionen-Zellen systematisch untersucht wurde. Die Menge der vermessenen Zellen variiert hierbei zwischen 24 [134] und 20 000 [16]. Meist wurde die Variation der Kapazität und des Innenwiderstands innerhalb der Menge an Zellen im Neuzustand (BOL) untersucht, einige Arbeiten beinhalten jedoch auch Alterungsversuche, bei denen die Zellen entweder einzeln [14, 133, 134] oder im System verbaut [14, 135] zyklisiert wurden, bis das Lebensende (EOL) der Zellen erreicht wurde. Auch die im Rahmen dieser Arbeit verwendeten Lithium-Ionen-Zellen weisen eine Parametervariation auf (siehe auch Kapitel 3.2). Wie der Tabelle entnommen werden kann liegt diese im Rahmen der aus der Literatur entnommenen Werte.

Schmid et al. [130] nehmen für die Simulation großer Batteriesysteme eine Normalverteilung für die Streuung der Kapazitäten und Innenwiderstände der Zellen an. Sie legen dabei die Parameterstreuung aus der Literatur zugrunde. Ein ähnliches Vorgehen wird in Kapitel 6.3.4.2 verfolgt, wenn Simulationen eines gealterten Moduls durchgeführt werden. Soll eine Modellierung realer Batteriesysteme anhand damit durchgeführter Experimente validiert werden, müssen jedoch die tatsächlichen, individuellen Parameter jeder Zelle ermittelt werden. Abhängig von der Anzahl an Zellen und dem damit einhergehenden Messaufwand ist es ein plausibles Vorgehen, ausgehend von einem generischen Zellmodell nur die individuellen Innenwiderstände und Kapazitäten zu vermessen und für die Modellierung zu verwenden [63]. Für die im Rahmen dieser Arbeit geführten Validierungen anhand von Experimenten wird jedoch jede einzelne Batteriezelle charakterisiert. Dies umfasst den Innenwiderstand und die nutzbare Kapazität ebenso wie den Verlauf der ladezustandsabhängigen Leerlaufspannung und das dynamische Zellverhalten durch die Parametrierung der RC-Glieder des ECMs. Die Charakterisierung wird in Kapitel 3.2 vorgestellt.

Tabelle 3.1: Übersicht über experimentelle Untersuchungen zur Parametervariation von Lithium-Ionen-Zellen. Die mit * bezeichneten Werte sind für die Simulationen (siehe Kapitel 6.3.4.2) frei gewählt.

Quelle	Kapazität		Innenwiderstand		Anzahl	Zelltyp
	$\kappa_{Q,BOL}$	$\kappa_{Q,EOL}$	$\kappa_{R_0,BOL}$	$\kappa_{R_0,EOL}$		
[136]	1,9 %				100	LCO (300 mAh)
[16]	1,3 %		5,8 %		20 000	LFP (4400 mAh)
[137]			19,5 %		96	LFP (> 70 Ah)
[138]	1,0 %		0,3 %		48	NMC (2050 mAh)
[132]	0,6 %		4,1 %		48	NMC (2050 mAh)
[135]	0,8 %	1,6 %/2,3 %	1,9 %	2,6 %/3,2 %	2392	NMC (1950 mAh)
[139]	1,0 %				7739	NMC (5300 mAh)
[117]	0,7 %		1,8 %		172	NMC (1950 mAh)
[14]	0,2 %	2,4 %/2,5 %	0,7 %	2,8 %/13,2 %	250	NCA (2800 mAh)
[133]	0,3 %	0,4 %/0,5 %	0,7 %	1,4 %/1,2 %	1100	LFP (3000 mAh)
[131]	0,4 %		0,9 %		164	NCA (2900 mAh)
[134]	0,2 %	0,4 %	0,7 %	0,8 %	24	NMC (3500 mAh)
hier:	0,2 %	2,0 %*	2,5 %	20,0 %*	12	NMC (2500 mAh)

3.1.5 Modellierung von rekonfigurierbaren Batteriesystemen

Während sich die Modellierung in den vorherigen Abschnitten auf herkömmliche Batteriesysteme bezog, soll nun die Rekonfigurierbarkeit von IBSs Berücksichtigung finden. Gemäß dem für diese Arbeit verwendeten System kommt die in Kapitel 2.4 vorgestellte Schalttopologie mit zwei Schaltern pro intelligenter Batteriezelle zur Anwendung. Es ergibt sich das erweiterte Ersatzschaltbild einer intelligenten Lithium-Ionen-Zelle in Abb. 3.6. Die MOSFETs sind als ideale Schalter mit dem Innenwiderstand R_A bzw. R_B modelliert. Dies ist für die verwendeten Leistungshalbleiterschalter eine gültige Annahme, weil etwaige Schaltverluste vernachlässigt werden können, da die Schaltfrequenzen nicht im hochfrequenten Bereich liegen. Außerdem sind die Innenwiderstände der Schalter im Vergleich zur Zellimpedanz sehr klein (siehe Anhang B), weswegen sie hier vernachlässigt werden können. Dies gilt nicht zwangsläufig bei der Betrachtung der Effizienz eines IBS.

Wie bereits in Kapitel 2.4 beschrieben, ergeben sich aus den zwei Schaltern für jede Batteriezelle drei sinnvolle Schalterstellungen bzw. Schaltzustände, welche in der Modellierung unterschiedlich behandelt werden müssen:

Aktiv-Zustand

Dieser Zustand entspricht der herkömmlichen Batteriezelle ohne Schalter. Der Aktiv-Schalter S_A ist geschlossen, der Bypass-Schalter S_B geöffnet. Der Strom durchfließt die Zelle und lädt bzw. entlädt diese. Da gemäß Abb. 2.4 die Strommessung im Aktiv-Pfad realisiert ist, wird der die Zelle durchfließende Zellstrom erfasst.

Ruhezustand

Sind beide Schalter geöffnet, ist die Lithium-Ionen-Zelle elektrisch isoliert, während gleich-

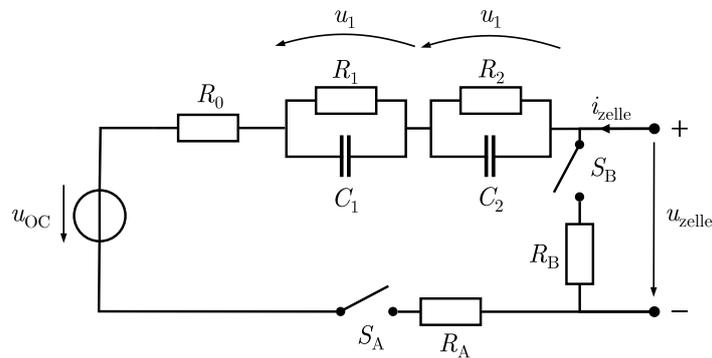


Abbildung 3.6: Ersatzschaltbildmodell einer intelligenten Lithium-Ionen-Zelle mit Aktiv- und Bypass-Schalter im Ruhezustand.

zeitig auch kein Strom über den Bypass-Pfad geleitet werden kann. Die gemessene Spannung entspricht der zur Leerlaufspannung tendierenden Zellspannung, der Zellstrom ist null. Sind alle Zellen in einem Parallelverbund im Ruhezustand, ist der Systemstrom unterbrochen, weswegen die Zellen bevorzugt in den Bypass-Zustand geschaltet werden sollten.

Bypass-Zustand

Ist der Aktiv-Schalter S_A geöffnet, aber der Bypass-Schalter S_B geschlossen, kann Strom über den Bypass-Pfad fließen. Die Zelle ist jedoch wie im Ruhe-Zustand elektrisch vom restlichen Batteriesystem entkoppelt und wird nicht ge- oder entladen. Gemäß Abb. 2.4 erfasst die Strommessung nicht den Bypass-Pfad, weswegen der durch diesen fließende Strom nicht messtechnisch erfasst wird.

Der vierte Schaltzustand (S_A und S_B geschlossen) würde zu einem Kurzschluss der Zelle führen und ist deswegen bei den in den Experimenten verwendeten Prototypen hardwareseitig unterbunden.

Betrachtet man das rekonfigurierbare Batteriesystem als Ganzes, so ergeben sich durch die Zellschalter Implikationen für das System. Von Interesse ist hierbei wieder der Parallelverbund aus mehreren Zellen und insbesondere die Stromaufteilung zwischen ihnen. Die im vorherigen Abschnitt beschriebenen Gesetzmäßigkeiten für den Zusammenhang der Zellparameter und den resultierenden Zellströmen gelten auch in RBSs. Allerdings implizieren deren Charakteristika einige Besonderheiten. Während in herkömmlichen Batteriesystemen die Ladezustände paralleler Zellen im Betrieb meist in einem ähnlichen Bereich liegen, gilt dies nicht mehr in RBSs, weil einzelne Zellen für längere Zeit aus dem System geschaltet werden können und sich deren SOC im Vergleich zu den anderen Zellen dann nicht mehr ändert. Auch kommt es am Ende von Lade- bzw. Entladephasen nicht mehr zwangsläufig zu Ausgleichsvorgängen zwischen parallelgeschalteten Zellen, weil diese abhängig von den Schalterstellungen nicht mehr dauerhaft miteinander gekoppelt sind. In der Folge steigt die Heterogenität der Ladezustände im System an, wodurch sich der Gesamtstrom sehr ungleich zwischen den Batteriezellen aufteilt.

Damit auch die Schalterstellungen und die damit einhergehenden Effekte berücksichtigt werden, muss die Matrix-Vektor-basierte Berechnungsmethode aus Abschnitt 3.1.3 für RBSs erweitert werden. Der Aktiv-Schalter S_A kann im geöffneten Zustand durch einen sehr hohen Innenwider-

stand R_0 der betreffenden Zelle modelliert werden. Gemäß (3.10) ergibt sich dann ein Strom nahe 0 A für die betreffende Zelle. Die Stromaufteilung der benachbarten Zellen bleibt hiervon unberührt. Ein Augenmerk muss jedoch darauf gelegt werden, dass es bei der Invertierung der Matrix \mathbf{R} in (3.10) zu numerischen Problemen kommen kann, wenn diese schlecht konditioniert ist. Dies ist dann der Fall, wenn sich die Innenwiderstände, mit denen die Haupt- und Nebendiagonale belegt sind, in Größenordnungen zueinander unterscheiden. Bei der Wahl des künstlich erhöhten Innenwiderstands im Falle des offenen Aktiv-Schalters ist deshalb ein Wert zu wählen, welcher einen im Rahmen der Messgenauigkeit verschwindend geringen Zellstrom ergibt, ohne dass es zu numerischen Problemen bei der Invertierung kommt. Im Rahmen dieser Arbeit wird ein Wert von 100 M Ω gewählt. Eine Alternative zur Modifikation des Innenwiderstands ist die Änderung der Systemtopologie nach jeder Schalthandlung. Damit werden die Matrizen und Vektoren aus (3.9) unter Vernachlässigung der ausgeschalteten und überbrückten Zellen aufgestellt und deren Strom immer auf null gesetzt. Da sich dadurch die Dimensionen der Matrizen und Vektoren permanent ändern, ist dieses Verfahren nur schwer auf Mikrocontrollern zu implementieren.

Bei der Modellierung des Bypass-Zustands kann der Bypass-Strom dadurch berechnet werden, dass der Zellinnenwiderstand auf einen sehr kleinen Wert gesetzt wird, wodurch sich der Strom ausschließlich zwischen den Zellen im Bypass-Zustand aufteilt. Es wird ein Wert für R_B von 100 $\mu\Omega$ gewählt, wobei dieser neben dem Innenwiderstand des geschlossenen Schalters auch die Leitungsverluste des Bypass-Pfads umfasst. Der für die Modellierung des Systems ermittelte Bypass-Strom unterscheidet sich jedoch vom Strom der betreffenden Zelle im Bypass-Zustand, da die Lithium-Ionen-Zelle selbst vom System entkoppelt ist. Dementsprechend wird für diese ein Strom von 0 A angenommen.

Die Modellierung der Stromaufteilung in einem RBS soll anhand eines einfachen Beispiels demonstriert werden. Betrachtet wird ein 1s3p-System, dessen elektrisches Verhalten über einen Zeitraum von 500s simuliert wird. Der Einfachheit halber sind die Parameter der Zellen identisch angenommen. Während der ersten Hälfte der Simulation wird der Zellverbund mit einem Strom von 30 A entladen, anschließend gibt es keine weitere Anregung. Zelle 1 und Zelle 2 führen während der Simulation jeweils einen Schaltvorgang aus und sind für eine gewisse Zeitdauer im Ruhezustand, wohingegen Zelle 3 dauerhaft aktiv bleibt. Die Schaltzustände sind ebenso wie der Strom, die Spannung und die resultierenden SOC's in Abb. 3.7 dargestellt.

Die Simulation lässt sich in fünf Abschnitte untergliedern. Während der ersten 150s sind alle drei Zellen aktiv und der Laststrom beträgt 30 A. Aufgrund der homogenen Zellparameter teilt sich der Gesamtstrom zu gleichen Teilen zwischen den Zellen auf. Die Zellspannungen und auch die Ladezustände sinken. Zum Zeitpunkt $t = 150$ s schalten Zelle 1 und Zelle 2 in den Ruhezustand. Entsprechend trägt nun Zelle 3 die gesamte Stromlast, was zu einem stärkeren Einbruch der Zellspannung führt, wohingegen die Spannungen der ersten beiden Zellen relaxieren. Auch die SOC's divergieren, da nur die dritte Zelle weiter entladen wird. Nach einer Simulationszeit von 200s wird Zelle 1 wieder in den Aktiv-Zustand geschaltet, wodurch sich der Strom zwischen Zelle 1 und Zelle 3 aufteilt. Aufgrund der unterschiedlichen Zellzustände, insbesondere was den SOC betrifft, ist die Aufteilung des Gesamtstroms aber nicht mehr gleichmäßig. Vielmehr trägt die weniger entladene Zelle 1 einen größeren Anteil an der Stromlast, wobei sich die Zellströme schnell wieder aneinander annähern. Auch die Zellspannungen der beiden eingeschalteten Zellen erreichen schnell einen Gleichgewichtszustand. Zum Zeitpunkt $t = 250$ s wird der Gesamtstrom

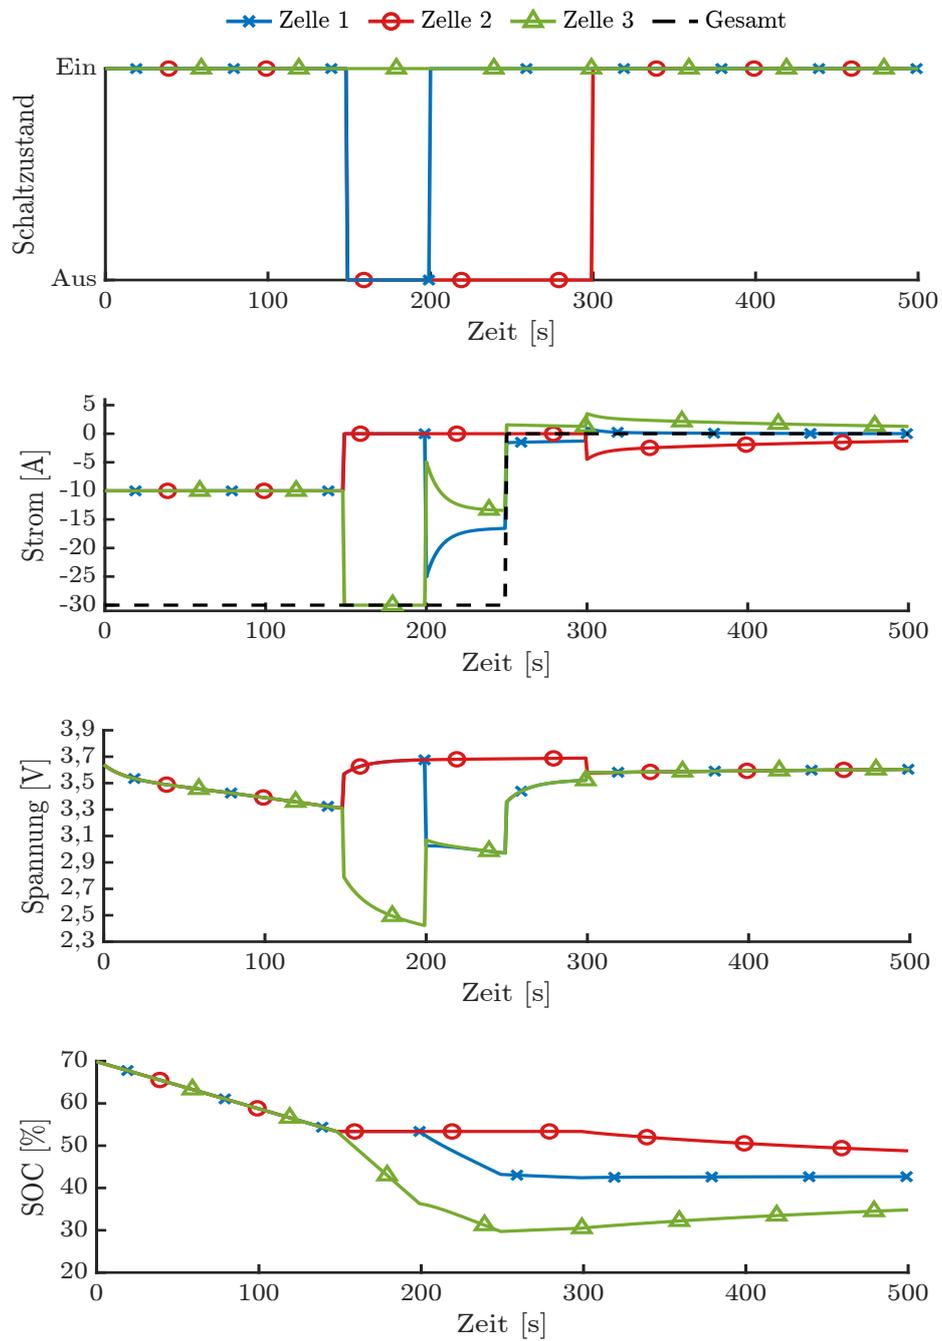


Abbildung 3.7: Modellierung der Stromaufteilung eines RBS mit 1s3p-Topologie.

gleich null. Das System wird also nicht mehr belastet. Dennoch sind die Zellströme nicht ebenfalls null. Vielmehr setzt sich der Ausgleichsvorgang zwischen Zelle 1 und Zelle 3 fort, wobei ein Ladungsausgleich von ersterer zu letzterer geschieht. Die SOCs der beiden Zellen nähern sich langsam aneinander an. Wenn nach 300s Simulationszeit auch Zelle 2 wieder in den Aktiv-Zustand wechselt, nimmt sie ebenfalls an dem Ausgleichsvorgang des Zellverbunds teil. Sie weist den höchsten Ladezustand der drei Zellen auf, weswegen ihr über einen Entladestrom Ladung entnommen wird, welche die anderen beiden Zellen lädt. Die Ladezustände nähern sich stetig einander an und der Betrag der Ausgleichsströme sinkt entsprechend. Zum Ende der Simulation ist dieser Vorgang noch nicht abgeschlossen.

Schließlich soll die Modellierung des elektrischen Verhaltens eines 1s3p-Systems anhand realer Messdaten validiert werden. Der Anregungsstrom hat einen Betrag von 15 A und wird während einer Dauer von 300s betrachtet. Die Zellen werden währenddessen in unregelmäßigen Abständen ein- und ausgeschaltet. In Abb. 3.8 sind diese Schalthandlungen sowie die resultierenden Zellströme und -spannungen dargestellt. Die Innenwiderstände und nutzbaren Kapazitäten der drei vermessenen Zellen wurden zuvor experimentell bestimmt (vgl. Kapitel 3.2). Wie den Verläufen von Zellströmen und -spannungen entnommen werden kann, erreicht die Modellierung der Stromverteilung innerhalb des Parallelstrangs eine hohe Genauigkeit. Die durch die permanenten Schaltvorgänge entstehenden Inhomogenitäten in den Zellzuständen und die sich daraus ergebenden Ströme werden präzise abgebildet. Insbesondere ist zu erkennen, wie die Zellen immer wieder durch dem Laststrom überlagerte Ausgleichsströme ihre Ladezustände aneinander angleichen. Dies gilt sowohl für den Fall von zwei als auch von drei parallel geschalteten Zellen. Es ergibt sich insgesamt ein Root-Mean-Squared-Error (RMSE) der Zellströme von im Mittel 140mA. Gleichzeitig ist auch eine hinreichende Genauigkeit der Spannungsmessung feststellbar. Durch die kontinuierliche Entladung sinken die Zellspannungen über den Verlauf des Versuchs ab, durch die Ruhephasen beim Ausschalten der Zelle bzw. der erhöhten Strombelastung beim Schalten der benachbarten Zellen ergibt sich ein stufenförmiger Verlauf. Der RMSE beträgt hier 10,3mV, was in etwa der Zellmodell-Genauigkeit entspricht.

3.2 Parameteridentifikation des Ersatzschaltbildmodells

Die Identifikation der Parameter durch die gezielte Zyklisierung der Lithium-Ionen-Zellen wird gemeinhin auch als Zell-Charakterisierung bezeichnet. Für den Fall des im vorherigen Abschnitt vorgestellten Ersatzschaltbildmodells umfassen die Modellparameter neben der nutzbaren Kapazität Q die Größen u_{OC} , R_0 , R_1 , R_2 sowie C_1 und C_2 . Alle Größen sind temperaturabhängig und mit Ausnahme von Q auch abhängig vom Ladezustand.

Im Frequenzbereich ist die elektrochemische Impedanzspektroskopie (EIS) ein gängiges Verfahren, um die frequenzabhängige Zellimpedanz zu bestimmen und daraus beispielsweise Ersatzschaltbildmodelle zu parametrieren, welche das dynamische Systemverhalten der Batteriezelle beschreiben. Diese wird hierbei mit sinusförmigen Wechselströmen bzw. -spannungen beaufschlagt [140, 141] und die resultierende Spannung bzw. der resultierende Strom gemessen, woraus sich die Impedanz der Zelle ermitteln lässt. Die EIS ist in der Lage, die bei unterschiedlichen Anregungsfrequenzen dominanten elektrochemischen und physikalischen Reaktionen innerhalb der Lithium-Ionen-Zelle

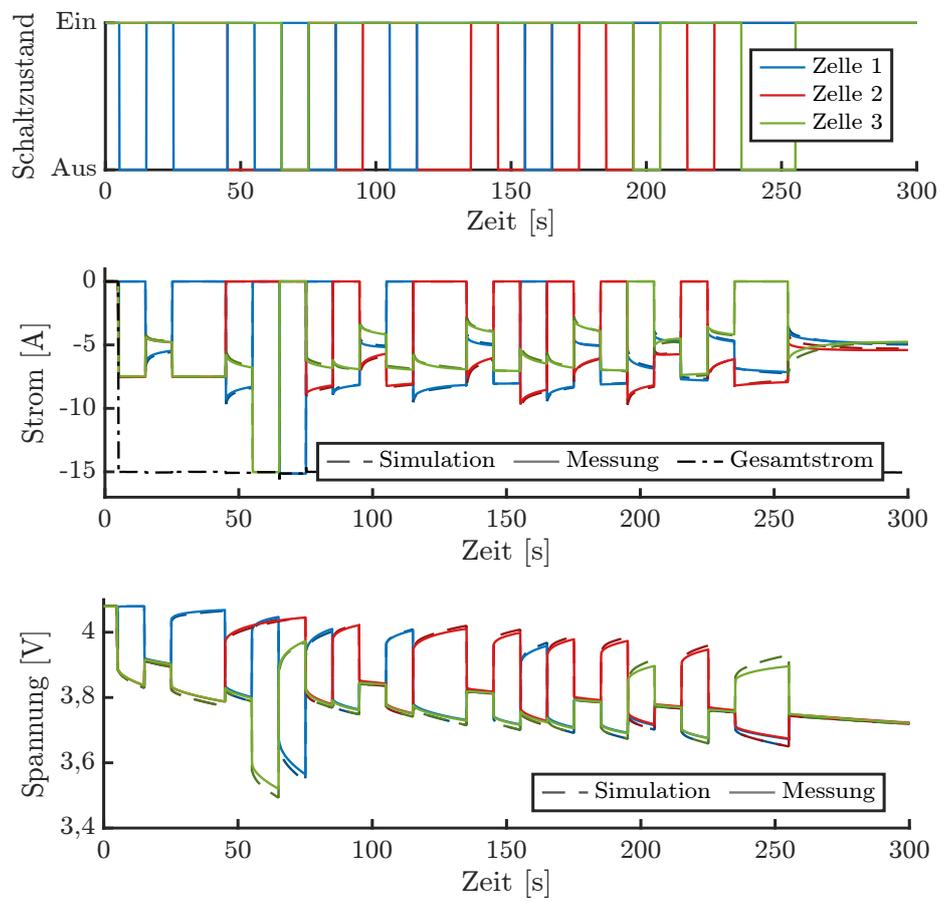


Abbildung 3.8: Experimentelle Validierung der Stromaufteilung eines RBS mit 1s3p-Topologie.

aufzulösen. Sie eignet sich insbesondere zur Identifikation des hochfrequenten Systemverhaltens, wohingegen die Messdauer für niederfrequente Anregungssignale immer weiter anwächst. Für die Parameteridentifikation des niederfrequenten dynamischen Verhaltens sind Verfahren im Zeitbereich vorteilhafter, um beispielsweise auch Effekte mit langen Zeitkonstanten wie die Festkörperdiffusion abzubilden. Die Modellparameter werden hierbei anhand charakteristischer Strompulse und deren Spannungsantwort durch Regressions-Verfahren ermittelt. Teilweise kommen für die Optimierung auch fortgeschrittenere Verfahren zum Einsatz wie genetische Algorithmen (GAs) [100] oder Partikelschwarm-Optimierung (PSO) [142, 143]. Mit einer im Rahmen dieser Arbeit angewandten einfachen Optimierung können jedoch auch bereits zufriedenstellende Ergebnisse erzielt werden.

Bei der im Folgenden vorgestellten Parameteridentifikation ist zu beachten, dass die Größen keine Abhängigkeit zum SOH aufweisen. Hierfür wären aufwändige Alterungstest notwendig, wie sie beispielsweise in [70, 112, 144–146] vorgestellt werden. Die Übertragbarkeit solcher Ergebnisse auf andere Zelltypen oder auf andere Art und Weise gealterte Zellen ist jedoch immer fraglich [16]. Deshalb ist die durchgeführte Charakterisierung eine Beschreibung des aktuellen Zellzustands zum Zeitpunkt der Messung. Aufgrund des moderaten Umfangs an Versuchen und Experimenten ist die Annahme zulässig, dass die Alterung während der Dauer der Experimente klein ist und die ermittelten Modellparameter für alle durchgeführten Messungen Gültigkeit haben.

3.2.1 Vorstellung der verwendeten Batteriezelle

Im Rahmen der vorliegenden Arbeit werden die Validierungsversuche mit zylindrischen Zellen der Firma Samsung SDI durchgeführt. Bei den Zellen handelt es sich um Lithium-Ionen-Zellen im 18650-Format mit der Typenbezeichnung INR18650-25R und einer nominellen Kapazität von 2500 mAh. Es wurde ein kommerziell erhältlich und verbreiteter Zelltyp gewählt, da aufgrund der hohen Stückzahlen bei der Produktion nur eine geringe Streuung des Zellverhaltens innerhalb einzelner Produktionschargen zu erwarten ist. Weiterhin sind die Zellen weithin verfügbar. Die wichtigsten Charakteristika listet Tabelle 3.2 auf. Ein Foto einer Zelle des verwendeten Zelltyps ist als Abb. B.1 in Anhang B abgedruckt.

Der verwendete Batteriezellen-Typ kann in einem Spannungsbereich von 2,5 V bis 4,2 V betrieben werden. Ein dauerhafter Entladestrom bis zu einem Betrag von 20 A ist spezifiziert, wobei der Ladestrom maximal 4 A betragen darf. Als Standard-Ladeverfahren ist eine CCCV-Ladung mit 0,5 C bis zur Ladeschlussspannung von 4,2 V spezifiziert, wobei die CV-Phase bei Unterschreiten der Stromgrenze von 125 mA abgebrochen wird. Ein Schnellladen mit bis zu 4 A ist jedoch ebenfalls erlaubt, weswegen im Rahmen dieser Arbeit während der CC-Phase die Zelle mit einer Rate von 1 C geladen wird. Die sonstigen Parameter des CCCV-Ladeverfahrens bleiben im Vergleich zum Datenblatt unverändert.

3.2.2 Beschreibung der durchgeführten Versuche zur Parameteridentifikation

Das Prozedere zur Parameteridentifikation wird für jede der in den Versuchen verwendeten Batteriezelle einzeln durchgeführt. Dazu wird diese in einer Temperaturkammer der Firma Binder auf die gewünschte Umgebungstemperatur temperiert und diese Temperatur während der

Tabelle 3.2: Auszug aus dem Datenblatt der verwendeten Lithium-Ionen-Zelle [147, 148]

Samsung INR18650-25R	
Hersteller	Samsung SDI
Format	18650
Kathodenmaterial	NCA+NMC
Anodenmaterial	Graphit und Silizium
Nennkapazität (bei 0,2 C)	2500 mAh
(bei 4,0 C)	2450 mAh
Nennspannung	3,6 V
Energiedichte	216 Wh/kg

Messungen konstant gehalten. Die Versuche selbst werden mit einem Arbin 5 V/60 A Batterietester durchgeführt.

Der gesamte Ablauf der Zellcharakterisierung ist in Abb. 3.9 dargestellt. Er gliedert sich in vier Abschnitte, welche nacheinander durchlaufen werden und im Folgenden noch genauer vorgestellt werden. Jeder Abschnitt beginnt mit einer CCCV-Ladung um einen definierten Ladezustand zu erreichen. Die Ladeprozedur ist für alle drei Umgebungstemperaturen identisch. Es ist jedoch zu beachten, dass der Ladezustand nur bei einer Umgebungstemperatur von 25 °C dem SOC von 100 % entspricht, da andernfalls die Lade-Prozedur nicht gemäß der Herstellerspezifikation durchgeführt wird. Nach einem Kapazitätstest wird die Leerlaufspannung der Zelle in Abhängigkeit vom Ladezustand ermittelt. Anschließend dienen Strompulse, mit welchen ebenfalls für unterschiedliche SOCs die Batterie angeregt wird, der Identifikation des Ohmschen Innenwiderstands sowie der Parameter der RC-Glieder des ECMs. Schließlich wird die Zelle durch dynamische Stromprofile entladen, welche nicht zur Parameteridentifikation selbst verwendet werden, sondern zur Validierung des resultierenden ECMs und der Quantifizierung von dessen Genauigkeit. Zwischen den CCCV-Ladungen und den Prüfschritten sowie innerhalb der Abschnitte werden zwischen den einzelnen Testschritten Ruhepausen von 10 min eingehalten. Die Abfolge der vier Prüfabschnitte wird für drei Umgebungstemperaturen wiederholt. Durch die Wahl der Temperaturen von 15 °C, 25 °C und 35 °C wird der Bereich um den für die späteren Versuche genutzten Temperaturbereich um 25 °C abgedeckt. Während aller im Folgenden durchgeführten Experimente bleiben die Batteriezellen damit in einem Temperaturfenster, welches durch die Charakterisierung abgedeckt ist. Der gesamte Prüfzyklus hat eine Dauer von ungefähr 120 h und ist in Anhang B detailliert aufgeführt.

Die Bestimmung der nutzbaren Kapazität als temperaturabhängige Größe erfolgt durch eine Konstantstrom-Entladung mit einer 1 C-Stromrate. Der Ladezustand der untersuchten Batteriezelle beträgt nur bei der Umgebungstemperatur von 25 °C tatsächlich 100 %. Der Einfluss auf die resultierende nutzbare Kapazität ist jedoch durch diesen Umstand gering im Vergleich zum Einfluss der sinkenden Widerstände, wenn die Umgebungstemperatur steigt. Diese führt dazu, dass die elektrochemischen Prozesse schneller ablaufen und der Innenwiderstand der Zelle sinkt. In der Folge kann der Zelle eine größere Ladungsmenge entnommen werden, bis die Entladeschlussspannung von 2,5 V erreicht wird. Das Resultat ist in Abb. 3.10 zu sehen. Die Streuung der

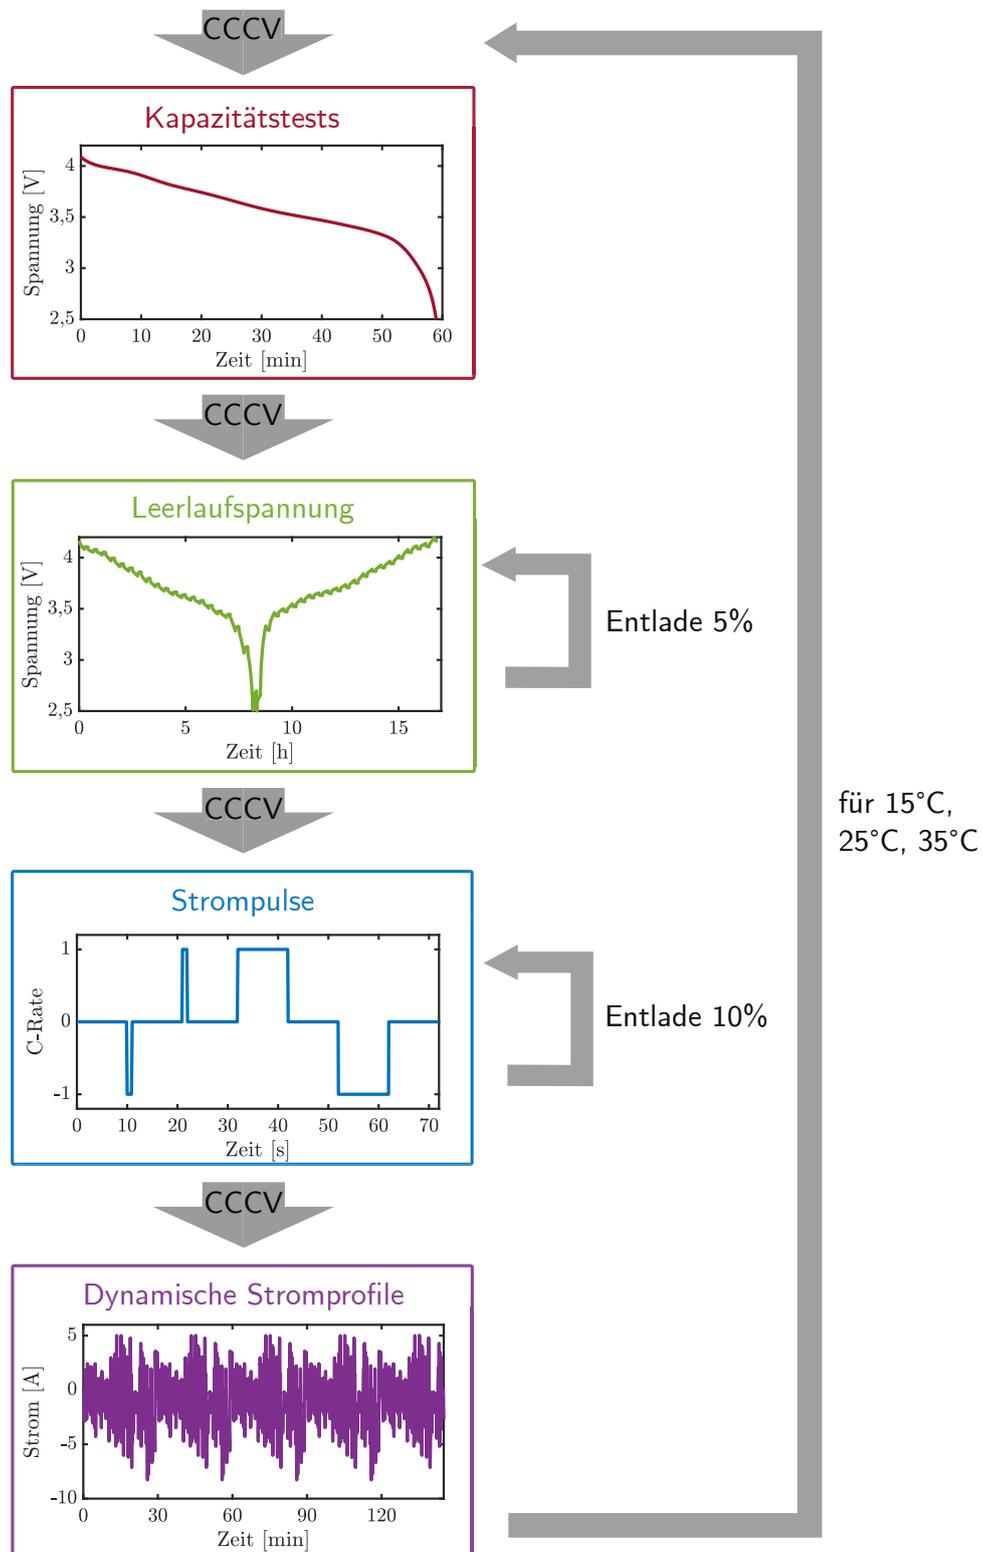


Abbildung 3.9: Schema des Testplans zur Charakterisierung der Lithium-Ionen-Zellen.

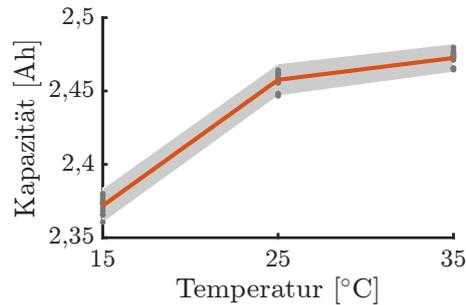


Abbildung 3.10: Abhängigkeit der nutzbaren Kapazität von den untersuchten Temperaturen. Die Streuung der Zellen sind durch Punkte und das 2σ -Konfidenzintervall, in dem 95 % der Parameter liegen, durch die grau hinterlegte Fläche visualisiert.

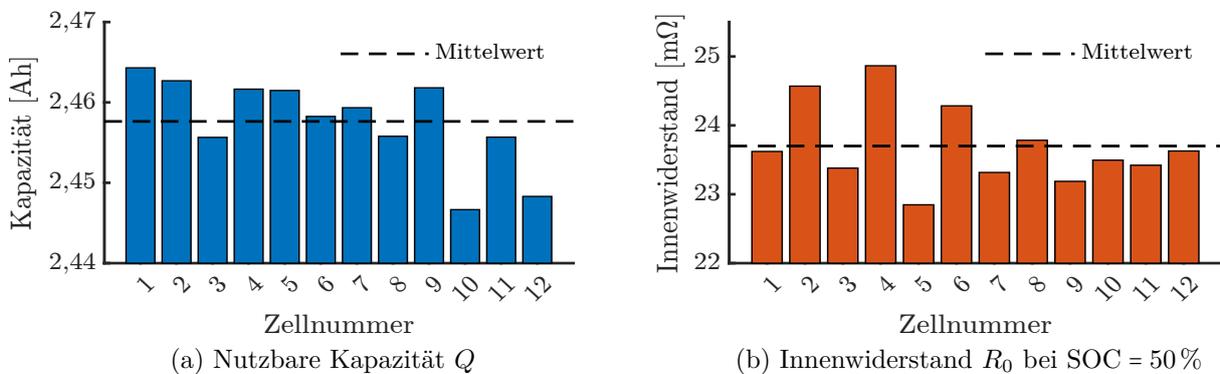


Abbildung 3.11: Verteilung der nutzbaren Kapazitäten und Innenwiderstände der charakterisierten Zellen bei einer Umgebungstemperatur von 25 °C.

Kapazität innerhalb der untersuchten Zellen ist über die drei untersuchten Temperaturen nahezu konstant. Da im Gegensatz zur im Datenblatt spezifizierten Kapazitätsmessung die C-Rate um den Faktor 5 vergrößert ist, sind die gemessenen Kapazitäten für die untersuchten Temperaturen erwartungsgemäß kleiner als die Nennkapazität. Für eine Umgebungstemperatur größer gleich 25 °C werden jedoch immer annähernd 2450 mAh erreicht.

Die Verteilung der nutzbaren Kapazität innerhalb des untersuchten Batteriemoduls ist für die Temperatur von 25 °C in Abb. 3.11a nochmal als Balkendiagramm gezeigt. Aus der Darstellung ist ersichtlich, dass hauptsächlich Zelle 10 und Zelle 12 eine auffällig geringe Kapazität aufweisen. Insgesamt liegen sieben Zellen oberhalb des Durchschnittswerts von 2458 mAh. Gemäß (3.12) ist der Koeffizient der Parameterstreuung für die Kapazität $\kappa_Q = 2,5\%$.

Der Zusammenhang der Leerlaufspannung u_{OC} zum SOC ist für die Zustandsschätzung in Batteriesystemen von großer Bedeutung und hat einen signifikanten Einfluss auf die erzielbare Genauigkeit der Schätzung [38, 101]. Die ladezustandsabhängige Leerlaufspannung zu ermitteln, kann ein zeitaufwändiger Prozess sein, wobei zwischen zwei verbreiteten Methoden unterschieden wird. Üblicherweise wird der Ladezustand der Batteriezelle bei konstanter Umgebungstemperatur variiert und dieser Vorgang dann für weitere Umgebungstemperaturen wiederholt.

Bei der Pseudo-OCV-Methode entlädt man die Batteriezelle ausgehend von einem SOC von 100% mit einem kleinen Konstantstrom (beispielsweise 0,05 C bis 0,1 C) bis zur Entladeschlussspannung. Anschließend folgt ein Ladevorgang mit einem Konstantstrom der gleichen Höhe. Die Zelle wird hierbei so lang geladen, bis die Ladeschlussspannung erreicht ist. Über die Integration des geflossenen Stromes kann die Entladetiefe bzw. der SOC der Zelle ermittelt werden. Um für einen bestimmten Ladezustand die Leerlaufspannung zu erhalten, wird sie als Mittelwert aus den korrespondierenden Datenpunkten der Entlade- und Ladekurve bestimmt. Durch die Mittelwertbildung werden die Ohmschen Spannungsverluste ebenso ausgeglichen wie die Überspannungen und eine Hysterese. Die der Pseudo-OCV-Methode zugrunde liegende Annahme ist, dass diese Effekte symmetrisch zur Stromrichtung sind. Nachteilig bei dem Verfahren ist, dass die elektrochemischen und physikalischen Vorgänge möglicherweise zu bestimmten Zeitpunkten noch nicht eingeschwungen sind und am Umkehrpunkt bei niedrigen SOCs eine Umpolarisierung stattfindet. Die Fehler der Pseudo-OCV-Methode lassen sich verringern, indem eine kleinere Stromrate gewählt wird, allerdings verlängert dies die Messdauer. Beispielsweise muss bei einer Stromrate von $C/20$ bereits mit einer Versuchsdauer von mehr als 40 Stunden pro Temperatur gerechnet werden. Petzl und Danzer [149] stellen zudem selbst bei einer Stromrate von $C/40$ noch Fehler von bis zu 10 mV gegenüber dem nun vorgestellten Verfahren fest.

Als alternative Messmethode zur Bestimmung der Leerlaufspannung wird daher im Rahmen dieser Arbeit eine schrittweise Entladung vorgenommen. Laut Lin et al. [101] ist dieses Verfahren der Pseudo-OCV-Methode für NMC- und LFP-Zellen überlegen. Statt die Batterie kontinuierlich zu belasten, wird sie – ausgehend von SOC = 100% – mit einer Stromrate von 0,2 C wiederholt um 5% entladen. Dadurch werden 21 Ladezustände angefahren. An jedem dieser Punkte ruht die Zelle für eine definierte Zeitspanne (hier: 10 min), wodurch sich die Überspannungen abbauen und die gesuchte Leerlaufspannung einstellt. Auch bei der schrittweisen OCV-Bestimmung erfolgt im Anschluss an die Entladung eine Umkehr der Stromrichtung. Die Zelle wird wiederum in 5%-Schritten geladen und fährt somit die gleichen Ladezustände ab, wie bei der Entladung. Es ergeben sich die Messpunkte gemäß Abb. 3.12. Die Leerlaufspannung wird nun wieder aus dem Mittelwert aus Entlade- und Ladekurve berechnet. Vorteile der schrittweisen Bestimmung der Leerlaufspannung ist, dass an den Messpunkten kein Ohmscher Spannungsabfall und nur geringe Überspannungen auftreten. Allerdings ist weiterhin eine Hysterese sichtbar, welcher durch die Mittelwertbildung aus Entladung und Ladung Rechnung getragen wird. Als Nachteil der Methode kann gelten, dass die Leerlaufspannung nur an einigen Stützstellen exakt bestimmt werden kann, zwischen denen üblicherweise interpoliert wird [150]. Eine Erhöhung der angefahrenen Ladezustände erhöht wiederum die Messdauer. Die hier vorgestellte Messung hat eine Dauer von etwa 17 Stunden pro Temperaturwert. Weiterhin sinkt die Genauigkeit des Verfahrens für tiefe Ladezustände, da die Klemmenspannung der Batteriezelle an diesem Punkt innerhalb der Ruhezeit nicht zu einem konstanten Wert einschwingt.

Die Wahl der Stromrate und die Ruhepause vor der eigentlichen Messung von u_{OC} stellen einen Kompromiss dar. Je höher der Betrag der Stromrate und die Dauer des Strompulses ist, desto länger muss die Ruhephase sein, bis sich eine konstante Klemmenspannung einstellt [150]. Dass die relativ geringe Ruhephase von 10 min keinen Genauigkeitsverlust bewirkt, kann Abb. 3.12 entnommen werden. Als Referenzwert ist im Diagramm die resultierende OCV-Kurve für eine hochgenaue Messung gezeigt (Referenz), bei welcher die Ladezustände mit nur 0,1 C angefahren

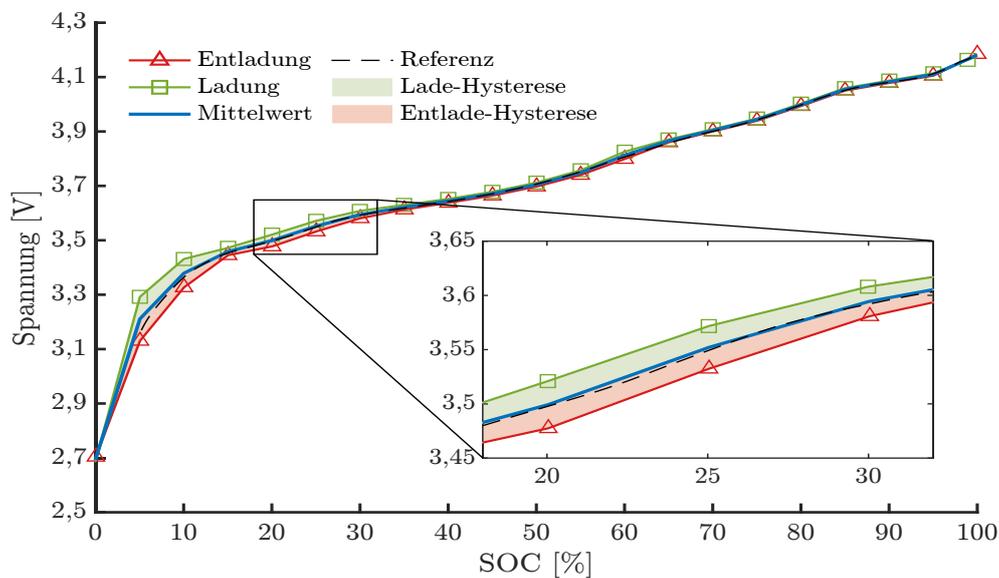


Abbildung 3.12: Bestimmung der OCV-Kurve als Mittelwert (blau) von Entladekurve (rot) und Ladekurve (grün).

wurden und die Ruhephase 3 h betrug. Die Unterschiede in den resultierenden Werten für die Leerlaufspannung sind zu vernachlässigen. Waag und Sauer [151] stellen eine Methode vor, bei der die Relaxation der Klemmspannung zur Leerlaufspannung durch eine Exponentialfunktion approximiert wird. Dadurch kann die Leerlaufspannung auch dann abgeschätzt werden, wenn die gemessene Klemmspannung noch nicht ihre Ruhelage erreicht hat.

Die Differenz zwischen den Spannungswerten von Ladung und Entladung bei gleichem Ladezustand erklärt sich zum einen durch die Tatsache, dass die Klemmspannung nach 10 min noch nicht der Leerlaufspannung entspricht. Insbesondere bei niedrigen SOC's dauert die Relaxation mehrere Stunden oder sogar Tage. Zum anderen kann eine Hysterese für die Spannungsdifferenz verantwortlich sein. Für die Ursache dieser beobachteten Hysterese gibt es unterschiedliche Erklärungsansätze [152]. Srinivasan und Newman [153] begründen das Auftreten unterschiedlicher Potentiale abhängig von der Stromrichtung damit, dass sich in der Kathode entweder eine lithiumarme Schicht innerhalb eines Elektrodenpartikels um eine lithiumreiche Schicht bildet, bzw. der Partikel-Kern lithiumreich ist, während die Oberfläche eine geringere Lithiumkonzentration aufweist. In beiden Fällen ergeben sich trotz des gleichen Lithium-Gehalts in der Kathode unterschiedliche Potentiale. Von [154] wird die Hysterese mit dem nichtmonotonen Kathoden-Potenzial abhängig vom Lithiierungsgrad begründet. Die Annahme der Autoren ist, dass innerhalb des Aktivmaterials das Lithium unterschiedlich verteilt sein kann und sich dennoch das gleiche Gesamtpotenzial ergibt. Abhängig von der Stromrichtung kommt es zu Ausgleichsvorgängen von benachbarten Partikeln, wobei diese aufgrund der nichtlinearen Potenzial-Funktion nicht symmetrisch ablaufen. Die Hysterese ist besonders bei Lithium-Ionen-Zellen mit LFP-Kathoden ausgeprägt, ist aber auch bei NMC-Zellen vorhanden. Barai et al. [152] untersuchen eine NMC-Zelle mit einer nominellen Kapazität von 2,2 Ah und messen eine Hysterese von bis zu 20 mV abhängig vom Ladezustand. Im Vergleich mit anderen Zellen stellen die Autoren fest, dass die Hysterese bei größeren Zellen stärker ausgeprägt ist. Für die hier untersuchte Zelle beträgt

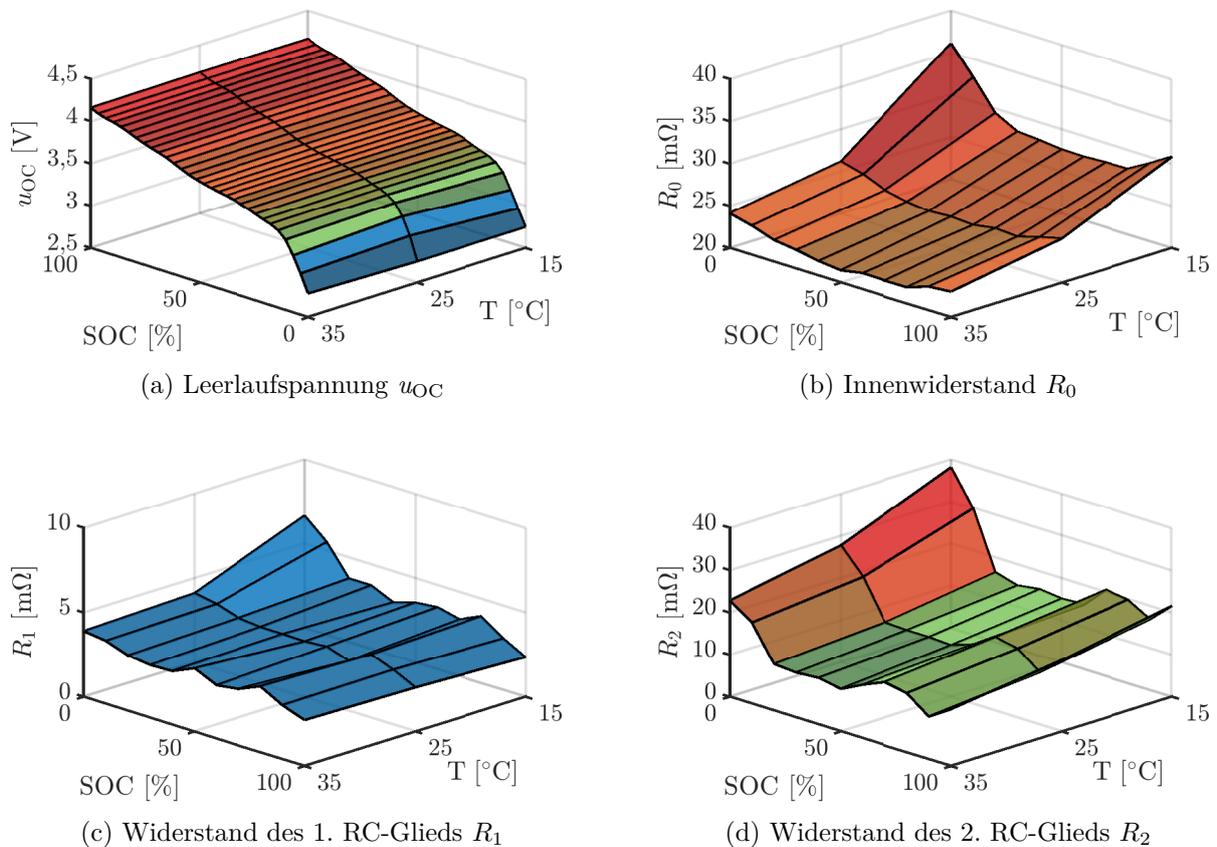


Abbildung 3.13: Ergebnisse der Parameteridentifikation als Mittelwert aus zwölf charakterisierten Zellen. Alle Parameter sind abhängig vom Ladezustand und der Umgebungstemperatur dargestellt.

die Hysterese maximal 15 mV bei einem SOC von circa 5 %. Für $SOC \geq 15\%$ ist die Hysterese immer kleiner als 5 mV. Der maximal auftretende Fehler ist in Lade- bzw. Entladerichtung in der Regel nur halb so groß, da die Hysterese die Abweichung von Lade- und Entladekurve aufsummiert. Das im Rahmen dieser Arbeit verwendete DP-Batteriemodell vernachlässigt deswegen die Hysterese. Es existieren jedoch in der Literatur auch Modelle, welche die Hysterese explizit berücksichtigen [155–157].

In Abb. 3.13a ist für eine der charakterisierten Zellen die Leerlaufspannung in Abhängigkeit vom SOC und der Temperatur dargestellt. Die Änderung der Spannung mit dem Ladezustand ist deutlich stärker ausgeprägt als die Temperaturabhängigkeit.

Zur Bestimmung des dynamischen Zellverhaltens werden HPPC-Testprofile (Hybrid-Pulse-Power-Characterization) eingesetzt. Hierbei wird die Batteriezelle an einem Betriebspunkt mit definiertem Ladezustand und Umgebungstemperatur durch Strompulse angeregt und die Spannungsantwort gemessen. Basierend auf der Systemantwort können dann die Modellparameter R_0 , R_1 und R_2 bestimmt werden. In der vorliegenden Arbeit seien die RC-Glieder feste Zeitkonstanten mit

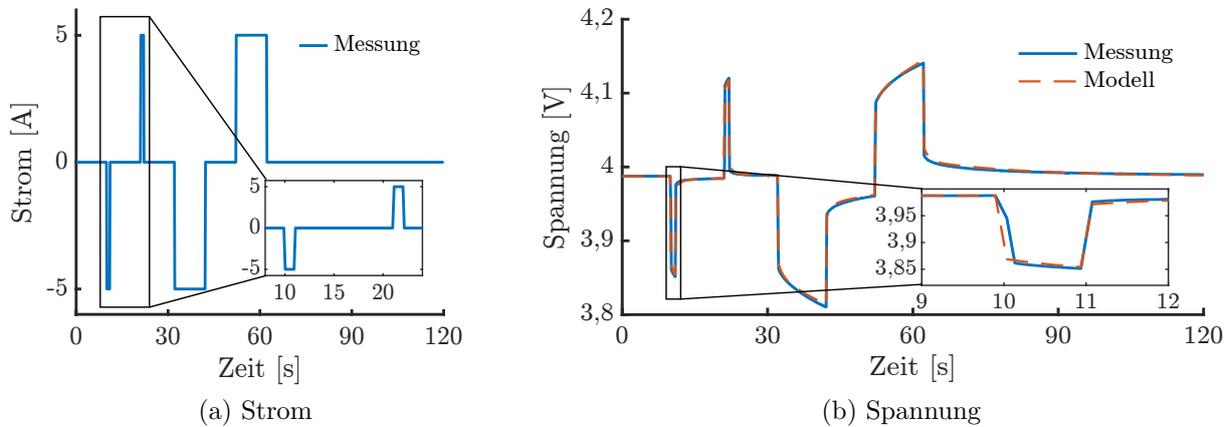


Abbildung 3.14: Ausschnitt aus dem Charakterisierungstest bei 25 °C: (a) Strompulse und (b) Spannungsantwort sowie resultierende Systemantwort des Modells mit gefitteten Parametern.

$\tau_1 = 1$ s und $\tau_2 = 20$ s. Dadurch ergeben sich die Kapazitäten der RC-Glieder als von R_j abhängige Parameter zu

$$C_j = \frac{\tau_j}{R_j} \quad \text{für } j = 1, 2. \quad (3.13)$$

Der Freiheitsgrad des Systems wird durch die festen Zeitkonstanten reduziert. Untersuchungen der verwendeten Zellen zeigen, dass die beiden gewählten Werte für τ_1 bzw. τ_2 gut in der Lage sind, das dynamische Zellverhalten zu beschreiben [130].

Die für die Parameteridentifikation verwendete Pulsfolge kann Abb. 3.14a entnommen werden. Nach einer Ruhephase von 10 min folgt auf einen 2 C-Entladepuls von einer Sekunde eine Pause von 10 s und ein umgekehrter Strompuls gleicher Länge. Nach der anschließenden Pause von 10 s folgt ein zweiter Entladepuls, welcher ebenfalls 10 s dauert. Nach wiederum 10 s Pause wird der umgekehrte Puls eingebracht. Es schließt sich eine längere Pause von einer Minute an. Durch die hohe Stromrate soll eine ausreichende Anregung der elektrochemischen und physikalischen Reaktionen innerhalb der Lithium-Ionen-Zelle erreicht werden. Die kurzen und langen Pulse adressieren jeweils die den Zeitkonstanten zugeordneten Effekte. Dabei wird jedoch berücksichtigt, dass sich die Randbedingungen des Arbeitspunktes, das heißt der Ladezustand und die Zelltemperatur, während der Testsequenz nicht signifikant ändern. Die vorgestellte HPPC-Pulsfolge wird jeweils für zehn Ladezustände zwischen 10 % und 100 % bei den drei Temperaturen (15 °C, 25 °C und 35 °C) zur Anregung der Batteriezellen genutzt.

Die Systemantwort des HPPC-Tests ist in Abb. 3.14b exemplarisch für einen Ladezustand von 80 % und eine Umgebungstemperatur von 25 °C gezeigt. Es ergibt sich die dynamische Systemantwort, wie sie bereits in Abb. 3.2 skizziert wurde. Die gesuchten drei Widerstände werden durch ein Optimierungsverfahren ermittelt, welches den RMSE zwischen der aus der Modellierung resultierenden Systemantwort und der gemessenen Spannung minimiert. Es kommt die MATLAB-Funktion `fminsearch` zum Einsatz, welche auf dem Simplex-Algorithmus beruht. Die für das Optimierungsverfahren verwendeten Parameter können Tabelle 3.3 entnommen werden. Um im Optimierungsprozess negative Werte für die gesuchten Widerstände zu vermeiden, welche physikalisch unplausibel wären, werden als zu optimierende Parameter die natürlichen

Tabelle 3.3: Verwendete Parameter für das Optimierungsverfahren zur Bestimmung der Modellparameter mit der MATLAB-Funktion `fminsearch`.

Parameter	Wert
Optimierungsverfahren	Nelder-Mead-Simplex-Algorithmus [158]
Startwerte	$R_0 = 25 \text{ m}\Omega$, $R_1 = 3 \text{ m}\Omega$ und $R_2 = 15 \text{ m}\Omega$
Abbruchkriterium Schrittweite (<code>TolX</code>)	10^{-9}
Abbruchkriterium Funktionswert (<code>TolFun</code>)	10^{-9}

Logarithmen der drei Widerstände gewählt. Der für die Modellierung der Systemantwort benötigte Ladezustand zu Beginn wird ausgehend von der Leerlaufspannung am Anfang der Pulsfolge bestimmt.

Die Optimierung wird für jede der $10 \cdot 3 = 30$ Pulsfolgen separat durchgeführt, wodurch sich für jeden Arbeitspunkt individuelle Modellparameter ergeben. Ein kontinuierlicher Verlauf der Größen abhängig vom Ladezustand und der Temperatur sind ein Indiz für plausible Ergebnisse der Optimierung, wohingegen stark schwankende Resultate darauf hindeuten, dass in der Optimierung nur lokale Minima gefunden wurden.

Die Ergebnisse der Optimierung sind für Zelle 1 in Abb. 3.13b bis Abb. 3.13d dargestellt. Beim Ohmschen Innenwiderstand R_0 fällt die starke Temperaturabhängigkeit auf. Mit steigender Temperatur sinkt R_0 deutlich ab. Weiterhin ist der Innenwiderstand für große und besonders kleine Ladezustände erhöht. Dieses Verhalten ist für niedrige Temperaturen stärker ausgeprägt. Ähnlich verhält es sich auch für die Widerstände der beiden RC-Glieder des Ersatzschaltbildmodells. Diese sind für kleine Ladezustände stark erhöht und bewegen sich ansonsten in einem Bereich um $3 \text{ m}\Omega$ bis $4 \text{ m}\Omega$ für R_1 beziehungsweise $10 \text{ m}\Omega$ bis $15 \text{ m}\Omega$ für R_2 . Für mittlere und hohe Ladezustände ist die Temperaturabhängigkeit von R_1 gering.

Die Verteilung der Innenwiderstände unter den zwölf untersuchten Zellen zeigt Abb. 3.11b für eine Temperatur von $25 \text{ }^\circ\text{C}$ und einen Ladezustand von 50% . Der Mittelwert der Zellen beträgt $23,7 \text{ m}\Omega$ mit einer Standardabweichung von $0,6 \text{ m}\Omega$. Werden die Zellen in aufsteigender Reihenfolge zu einem 4s3p-Batteriemodul verbaut, wie es für die Modulversuche dieser Arbeit getan wird, fällt auf: Die Widerstände in den ersten beiden Parallelsträngen variieren untereinander stark, wohingegen sie in den letzten beiden Strängen homogen sind. Wird keine Sortierung der Zellen durchgeführt, ergeben sich demnach Parallelstränge mit größerer und kleinerer Heterogenität, was für die Versuche zusätzliche Erkenntnisse liefern kann. Gemäß (3.12) ist $\kappa_{R_0} = 2,5\%$, was in der Größenordnung anderer Untersuchungen liegt (vergleiche Kapitel 3.1.4).

3.2.3 Ergebnisse der Parameteridentifikation

Um die Ergebnisse der Parameteridentifikation abschließend zu bewerten, erfolgt eine Validierung anhand dreier dynamischer Anregungsprofile. Sie beaufschlagen die Batteriezelle mit einem veränderlichen Strom, sodass die Systemantwort mit der Modellierung verglichen werden kann.

Tabelle 3.4: Ergebnisse der Validierungsversuche. Der RMSE ist mit Mittelwert und Standardabweichung über die Gesamtheit der zwölf charakterisierten Zellen angegeben.

Anregungsprofil	RMSE	bei 15 °C	bei 25 °C	bei 35 °C
WLTP (0 % bis 100 % SOC)	29,2 ± 8,4 mV	30,9 ± 15,4 mV	47,1 ± 14,2 mV	
WLTP (20 % bis 100 % SOC)	11,7 ± 1,1 mV	10,9 ± 1,6 mV	10,0 ± 0,5 mV	
UDDS (0 % bis 100 % SOC)	25,9 ± 4,8 mV	23,7 ± 7,3 mV	40,2 ± 13,0 mV	
UDDS (20 % bis 100 % SOC)	8,7 ± 1,0 mV	9,0 ± 3,2 mV	8,0 ± 2,1 mV	
PRBS (0 % bis 100 % SOC)	49,2 ± 13,4 mV	69,6 ± 15,0 mV	81,0 ± 10,4 mV	
PRBS (20 % bis 100 % SOC)	37,1 ± 12,0 mV	38,8 ± 8,0 mV	75,5 ± 18,8 mV	

Als Stromprofile kommen zwei bekannte Fahrzyklen, der Worldwide-Harmonized-Light-Duty-Vehicles-Test-Procedure (WLTP) und der Urban-Dynamometer-Driving-Schedule (UDDS), zum Einsatz. Weiterhin wird ein synthetisches Profil basierend auf einer Pseudo-Random-Binary-Sequence (PRBS) verwendet, um eine Anregung in einem weiten Frequenzbereich zu ermöglichen. Weitere Details zu den Profilen finden sich in Anhang A, sowie in Kapitel 5.3. Die Validierungsprofile werden ausgehend von einem Ladezustand von circa 90 % mehrfach wiederholt, bis die Entladeschlussspannung erreicht ist.

Für alle charakterisierten Zellen ergeben sich für die drei Validierungsprofile die RMSEs, wie sie in Tabelle 3.4 angegeben sind. Die Fehlerwerte sind hierbei die Mittelwerte über alle zwölf Zellen, wobei die Standardabweichung mit angegeben ist. Das Fehlermaß ist weiterhin einmal für die gesamte Messung berechnet, einmal jedoch nur für den Zeitraum, in welchem der SOC größer als 20 % ist. Der Bereich niedriger Ladezustände wird in der Anwendung häufig vernachlässigt [105]. In Elektrofahrzeugen werden diese meist nicht erreicht, da die Hersteller zum einen den Betrieb nur innerhalb eines SOC-Fensters erlauben, zum anderen die Fahrzeuge vom Kunden meist schon bei höheren Ladezuständen wieder geladen werden. Franke und Krems [159] gehen davon aus, dass mehr als 80 % der Ladevorgänge von BEVs bei Ladezuständen über 30 % gestartet werden.

Exemplarisch ist in Abb. 3.15 das Ergebnis des UDDS-Validierungsprofils für eine Zelle bei einer Temperatur von 25 °C gezeigt (Resultate für den WLTP-Fahrzyklus und das PRBS-Profil finden sich in Anhang E). Das Profil wird mehr als sechsmal durchlaufen, bevor die Zelle die Entladeschlussspannung von 2,5 V erreicht. Wie Abb. 3.15c entnommen werden kann, beträgt der Fehler über weite Bereiche des Ladezustands deutlich weniger als 30 mV. Erst für sehr niedrige Ladezustände unter 20 % steigt der Fehler stark an, was auf Defizite bei der Bestimmung der OCV-Kurve zurückzuführen ist (vergleiche 3.2.2). Der SOC-Bereich oberhalb von 20 % ist im Diagramm rot hinterlegt. Die folgende Betrachtung bezieht sich nur auf diesen Bereich (Reihen mit hellem Hintergrund in Tabelle 3.4).

Für die beiden Fahrzyklen WLTP und UDDS ergibt sich ein sehr geringer Modellierungsfehler von unter 12 mV. Die Genauigkeit des Modells ist für alle drei getesteten Temperaturen gleichermaßen gegeben. Auch die Variation unter den Zellen des Batteriemoduls ist klein und beträgt nur wenige Millivolt. Im Vergleich zu einem Referenz-Parametersatz des gleichen Zelltyps, welcher auf mehrmonatigen Charakterisierungstests beruht, ist der Fehler vergleichbar. Dieser lag bei circa 15 mV

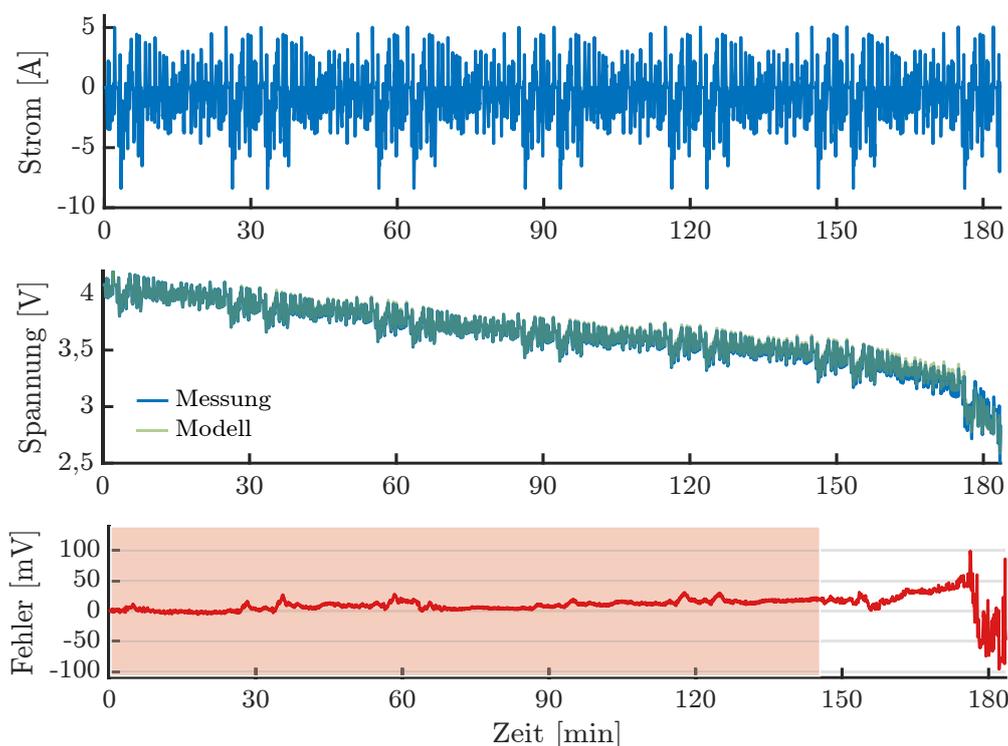


Abbildung 3.15: Resultat der Validierung des Modells mit den ermittelten Parametern für eine Zelle anhand des UDDS-Profiles bei 25 °C Umgebungstemperatur. Der rot hinterlegte Bereich kennzeichnet einen Ladezustand von über 20 %.

für den WLTP-Fahrzyklus. Die Modellgenauigkeit beim PRBS-Stromprofil ist deutlich schlechter als bei den Fahrprofilen. Selbst im Bereich SOC > 20 % beträgt der RMSE der Zellspannung zwischen 37 mV und 76 mV. Diese im Vergleich schlechten Resultate lassen sich auf die hohe Dynamik der Anregung zurückführen. Die Entladung der Zelle findet in weniger als 15 min statt. Dadurch treten physikalische Effekte auf, wie beispielsweise ein Konzentrationsgefälle innerhalb des Elektrolyten, welche durch den HPPC-Test nicht angeregt wurden und dementsprechend auch nicht im Modell enthalten sind. Für die Fahrzyklen, welche den realen Anregungsströmen im Betrieb sehr nahekommen, ist die Modellgenauigkeit aber sehr gut.

Da alle untersuchten Batteriezellen der gleichen Produktionscharge entstammen, ist eine Erwartung an die ermittelten Parameter, dass diese für alle Zellen ähnliche Werte aufweisen. Die Streuung der Parameter innerhalb der charakterisierten Zellen gibt weiterhin darüber Aufschluss, mit welcher Sicherheit und Signifikanz die ermittelten Modellparameter betrachtet werden können. In Abb. 3.16 sind die gefundenen Parameter aller Zellen und für alle untersuchten Ladezustände aufgetragen. Betrachtet werden die Messdaten bei einer Umgebungstemperatur von 25 °C.

Auffällig ist, dass die Leerlaufspannung zwischen den Zellen kaum schwankt. Lediglich in einem SOC-Bereich um 10 % gibt es eine leichte Variation zwischen den Zellen. Wie bereits erläutert, stellt jedoch gerade die Bestimmung der Leerlaufspannung bei niedrigen Ladezuständen eine Herausforderung dar. Der Innenwiderstand variiert mit einer Standardabweichung von circa 0,7 mΩ, wobei die Schwankung bei niedrigen und hohen SOC's höher ist als bei mittleren Ladezuständen. Für die beiden Widerstände der RC-Glieder ergibt sich ein diametrales Bild. Während

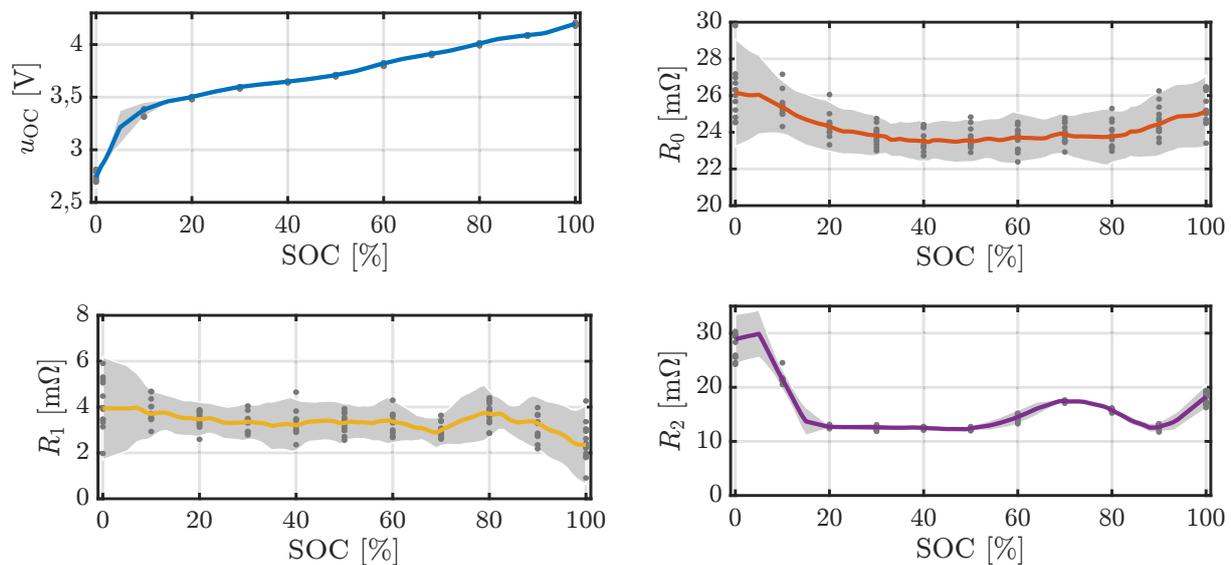


Abbildung 3.16: Streuung der Modellparameter bei 25 °C innerhalb der untersuchten Zellen. Alle Parameter sind abhängig vom Ladezustand dargestellt. Grau hinterlegt ist das 2σ -Konfidenzintervall. Die farbige Linie zeigt den Mittelwert aller Zellen.

R_1 innerhalb der untersuchten Stichprobe um circa 20% schwankt, bleibt der Wert abhängig vom Ladezustand weitgehend konstant. Dahingegen ist die ladezustandsabhängige Variation von R_2 insbesondere für kleine SOC deutlich ausgeprägt, die Schwankung zwischen den Zellen ist mit unter 3% sehr viel geringer. Analog zur Leerlaufspannung steigt die Variation für niedrige Ladezustände an.

3.2.4 Schlussfolgerungen für die Online-Parameterschätzung

Zum Abschluss der Zellcharakterisierung können auf Basis der vorgestellten Ergebnisse einige Beobachtungen gemacht werden. Zunächst zeigt sich, dass alle Modellparameter eine Abhängigkeit vom Ladezustand aufweisen. Diese ist für u_{OC} und R_2 stärker ausgeprägt als für R_0 und R_1 , sollte jedoch auch bei diesen nicht unberücksichtigt bleiben. Insbesondere bei niedrigen Temperaturen ist die SOC-Abhängigkeit auch bei diesen Parametern stärker ausgeprägt. Weiterhin sind insbesondere u_{OC} und R_0 temperaturabhängige Modellparameter. Unter Berücksichtigung niedriger Ladezustände gilt das auch für die RC-Glied-Widerstände. Sofern ein Sensor- oder Schätzwert für die Zelltemperatur zur Verfügung steht, kann die Modellierung demnach verbessert werden, indem dieses Signal als Modelleingang genutzt wird.

Die Schwankung der ermittelten Modellparameter innerhalb der Stichprobe von zwölf Zellen zeigt eine Variation, die in derselben Größenordnung liegt wie die Untersuchungen anderer Autoren. Während die nutzbare Kapazität der Zellen beim hier betrachteten BOL um nur 0,2% schwankt, ist die Variation der Innenwiderstände mit 2,5% größer. Die Ergebnisse rechtfertigen den Einsatz individueller Parametersätze für jede Zelle, auch angesichts der Schwankung von R_1 . Dies gilt insbesondere, weil das so parametrisierte Modell im weiteren Verlauf der vorliegenden Arbeit zur Validierung der Schätzverfahren genutzt werden soll und als solches eine höchstmögliche

Genauigkeit aufweisen muss. Hierzu kann festgehalten werden: Für Ladezustände von 20% und darüber ist die Modellgenauigkeit sehr gut. Der RMSE liegt im Durchschnitt bei ungefähr 10 mV für die Anregung mit typischen Fahrzyklen. Diese und ähnliche Profile werden auch im weiteren Verlauf der Arbeit genutzt. Der Modellfehler kann als untere Schranke für die Güte gelten, welche das im folgenden Kapitel vorgestellte Schätzverfahren erreichen kann, da es sich um ein modellbasiertes Verfahren handelt.

4 Zustands- und Parameterschätzung im Batteriemanagementsystem

4.1 Modellbasierte Zustandsschätzverfahren

Eine wichtige Aufgabe der BMSs von Lithium-Ionen-Zellen ist die Bestimmung des aktuellen Ladezustands. Dieser ist messtechnisch nicht direkt zu erfassen, hat jedoch für den praktischen Betrieb der Batterie eine große Bedeutung. Beispielsweise erlaubt die Kenntnis des SOC die Prädiktion der verfügbaren Restreichweite von Elektrofahrzeugen, wenn die bis zur vollständigen Entladung des Batteriesystems noch vorhandene Restkapazität bekannt ist. Weiterhin kann auch das Balancing der Zellen im Batteriesystem basierend auf den jeweiligen Ladezuständen durchgeführt werden. Einen Überblick über Verfahren zur SOC-Bestimmung geben beispielsweise Rivera-Barrera et al. [5].

Die kontinuierliche Bestimmung des SOC durch Integration des Zellstroms wird als Coulomb-Counting bezeichnet. Die Genauigkeit des Verfahrens ist durch die Messfehler des Stromsensors begrenzt. Beispielsweise können schon kleine Offset-Fehler über längere Zeiträume zu beträchtlichen Abweichungen des ermittelten Ladezustands vom wahren Wert führen. In Abb. 4.1a ist der Einfluss eines Bias des Stromsensors von bis zu ± 100 mA auf das Coulomb-Counting als grauer Bereich eingezeichnet. In rot ist die Abweichung des SOC dargestellt, wenn der Bias -30 mA beträgt. Diese Fehler sind groß gewählt, um die Kumulation des SOC-Fehlers zu verdeutlichen. Ein Bias der Strommessung lässt sich durch eine Kalibrierung während Ruhephasen gut kompensieren. Herausfordernder sind Nichtlinearitäten des Analog-Digital-Wandlers oder des Verstärkers, welcher die über den Shunt abfallende Spannung verstärkt. Darüber hinaus ist der Zellstrom in herkömmlichen Batteriesystemen unbestimmt, wenn mehrere Lithium-Ionen-Zellen parallelgeschaltet sind, jedoch nur der Gesamtstrom gemessen wird.

Eine Bestimmung des Ladezustands auf Basis der Klemmenspannung der Zelle und der Leerlaufspannungskennlinie resultiert in einem stark verrauschten Wert für den SOC, da die Polarisationsspannungen zu einer signifikanten Abweichung der gemessenen Klemmenspannung zur Leerlaufspannung führen. Darüber hinaus begrenzt die Unsicherheit bei der Messung der Leerlaufspannung die Genauigkeit der SOC-Bestimmung. In Abb. 4.1b ist die Messunsicherheit der Leerlaufspannung (blauer Pfeil) und die daraus resultierende Abweichung bei der Bestimmung des SOC (roter Pfeil) gezeigt. Zur Verdeutlichung beträgt die Spannungsunsicherheit im großen Diagramm 100 mV statt der realistischeren 3 mV im kleinen Diagramm. Abhängig von der Steigung der Leerlaufspannungskurve kann die Messunsicherheit für den SOC größer oder kleiner ausfallen.

Aufgrund der Limitierung der Verfahren hat sich daher in Batteriesystemen die Schätzung des SOC mit Beobachtern und insbesondere mit dem Kalman-Filter als praktikable Lösung erwiesen [7], bei welchen beide Verfahren – die Integration des Stroms und die Messung der Klemmenspannung – kombiniert und die jeweiligen Informationen zueinander gewichtet werden.

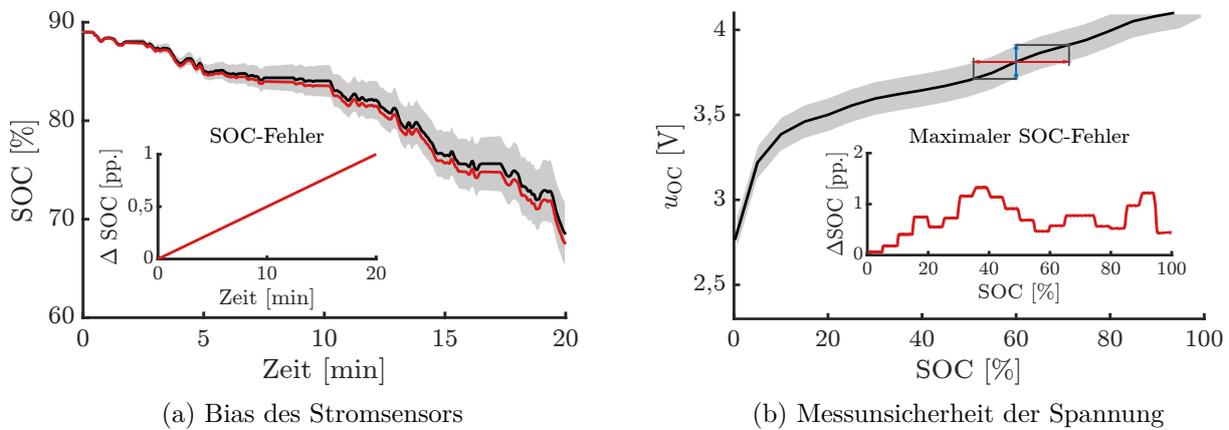


Abbildung 4.1: Einfluss (a) eines Bias der Strommessung und (b) der Messunsicherheit der Leerlaufspannungsmessung auf die SOC-Bestimmung. Ein Bias der Strommessung kumuliert über die Zeit zu einer Abweichung des SOC. Die Unsicherheit für die Ladezustandsbestimmung basierend auf der Leerlaufspannung ist abhängig vom SOC.

Darüber hinaus berücksichtigen Beobachter Modellwissen, wodurch die tatsächliche Klemmen- spannung präzisiert werden kann.

Häufig wird das Batteriesystem für die Bestimmung des Ladezustands als eine Einheit verstan- den [31, 32, 160]. Unter Berücksichtigung der Gesamtspannung und des Gesamtstroms wird demnach ein Ladezustand ermittelt, welcher dem Durchschnitt der dem System inhärenten Einzelzellen entspricht. Es existieren Verfahren in der Literatur, welche versuchen, den spezifischen SOC in einem herkömmlichen Batteriesystem für jede Einzelzelle zu bestimmen. Beispielswei- se stellt Plett [161] ein Verfahren namens Bar-Delta-Filterung vor, bei welchem zunächst ein Durchschnitts-Ladezustand bestimmt wird. Anschließend werden die Abweichungen jeder Zelle von diesem Durchschnitt berücksichtigt. Ein ähnliches Vorgehen wird von Roscher et al. [162] vorgeschlagen, wobei ein Beobachter den System-SOC schätzt und für jede Zelle ein individueller Korrekturfaktor bestimmt wird. Weiterhin werden hierfür in der Literatur mehrere Kalman- Filter verwendet [163, 164]. Einen gänzlich anderen Ansatz verfolgen Zhong et al. [165], welche den Ladezustand des Batteriesystems basierend auf dem Ladezustand der stärksten und der schwächsten Zelle berechnen. Ihrer Argumentation nach ist der individuelle Zell-SOC von gerin- gerer Bedeutung im Vergleich zum größten bzw. kleinsten SOC, weil durch diese die maximale Ladungsmenge bestimmt wird, mit welcher das System geladen bzw. entladen werden kann. Weitere Verfahren sind auf rein serielle Topologien begrenzt [166, 167].

In intelligenten Batteriesystemen sind die Messdaten von Strom und Spannung für jede Einzel- zelle vorhanden, weswegen sich eine Zustandsschätzung auf Zellebene realisieren lässt. Daraus resultiert Wissen über den Ladezustand jeder einzelnen Lithium-Ionen-Zelle und ermöglicht es, diese Informationen in einer Betriebsstrategie zu berücksichtigen. Beispielsweise kann ein Balancing der Ladezustände durch Zu- und Wegschalten der Einzelzellen durchgeführt werden. Die Schalthandlungen im intelligenten Batteriesystem sind es auch, die eine Zustandsschätzung auf Zellebene motivieren: Während in einem konventionellen Batteriesystem die Ladezustän- de aufgrund von möglicherweise heterogenen Zellparametern nur langsam auseinander driften, unterscheiden sich die SOC in intelligenten Batteriesystemen deutlich stärker, wenn Zellen

Tabelle 4.1: Dimensionen der Systemvektoren und -matrizen.

Vektor/Matrix	Symbol	Dimension
Systemzustand	\mathbf{x}	$n \times 1$
Systemeingang	u	$p \times 1$
Systemausgang	y	$q \times 1$
Systemmatrix	\mathbf{A}	$n \times n$
Eingangsmatrix	\mathbf{B}	$n \times p$
Ausgangsmatrix	\mathbf{C}	$q \times n$
Durchgriffsmatrix	\mathbf{D}	$q \times p$

während des Betriebs phasenweise ausgeschaltet werden. Die Stromlast verteilt sich dann für einen betrachteten Zeitabschnitt ungleichmäßig auf die Zellen des Batteriesystems.

Im weiteren Verlauf dieser Arbeit wird folgende Notation verwendet: Schätzwerte \hat{x} sind mit einem Zirkumflex gekennzeichnet, um sie von den realen Werten x zu unterscheiden. Weiterhin gilt, dass Messwerte \tilde{y} mit einer Tilde gekennzeichnet sind und fusionierte Daten \bar{y} (siehe Kapitel 6) durch einen Balken.

4.1.1 Luenberger-Beobachter

In der Regelungstechnik werden Beobachter zur Erfassung nicht messbarer Größen eingesetzt. In Abb. 4.2 ist das Konzept eines solchen sogenannten Luenberger-Beobachters für ein lineares System dargestellt. Dieses kann durch die diskrete System- und Messgleichung im Zustandsraum beschrieben werden.

$$\mathbf{x}_{k+1} = \mathbf{A}\mathbf{x}_k + \mathbf{B}u_k \quad (4.1a)$$

$$y_k = \mathbf{C}\mathbf{x}_k + Du_k \quad (4.1b)$$

Für ein Modell mit n Systemzuständen, p Eingängen und q Ausgängen ergeben sich für die verwendeten Vektoren und Matrizen die Dimensionen gemäß Tabelle 4.1. Mit dem Fokus auf die Anwendung im Batteriemanagementsystem sind im Folgenden die Vektoren und Matrizen der Gleichungen für ein SISO-System ($p = 1$, $q = 1$) mit n Systemzuständen abgebildet. Dennoch wird im Folgenden verallgemeinert von der Eingangs- und Ausgangsmatrix bzw. der Durchgriffsmatrix gesprochen, auch wenn es sich für SISO-Systeme um Vektoren bzw. einen Skalar handelt.

Unter der Annahme, dass der Systemeingang u und die Ausgangsgröße y zu jedem Zeitpunkt bekannt sind, kann ein Modell des Systems als Zustandsbeobachter diesem parallel geschaltet werden. Es wird für jeden Zeitschritt mit dem Eingangssignal u_k beaufschlagt, sodass sich eine Prädiktion für die Messung \hat{y}_k und den Zustandsvektor $\hat{\mathbf{x}}_k$ ergibt.

$$\hat{\mathbf{x}}_{k+1} = \mathbf{A}\hat{\mathbf{x}}_k + \mathbf{B}u_k \quad (4.2a)$$

$$\hat{y}_k = \mathbf{C}\hat{\mathbf{x}}_k + Du_k \quad (4.2b)$$

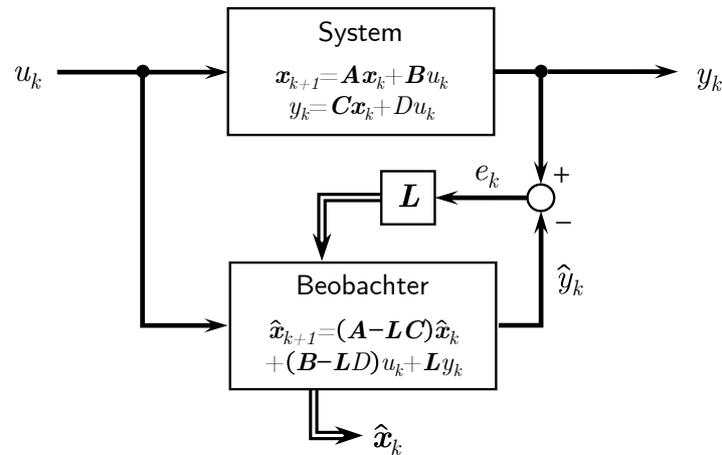


Abbildung 4.2: Blockschaltbild eines linearen Systems mit Luenberger-Beobachter angelehnt an Adamy [169, Bild 6.9].

Naturgemäß bilden die Matrizen \mathbf{A} , \mathbf{B} , \mathbf{C} und \mathbf{D} das reale System nur bis zu einem gewissen Grad ab, so wie jedes Modell Grenzen hinsichtlich seiner Gültigkeit und Genauigkeit aufweist. Zusätzlich ist der initiale Systemzustand \mathbf{x}_0 in aller Regel unbekannt. In der Folge ergibt sich eine Divergenz zwischen dem geschätzten Systemzustand $\hat{\mathbf{x}}$ und dem tatsächlichen Systemzustand \mathbf{x} . Daher wird dem Beobachter eine Rückkopplung hinzugefügt, welcher basierend auf der gewichteten Abweichung der Messwerte $e = \hat{y} - y$, den Schätzfehler minimiert und den geschätzten Zustandsvektor korrigiert [168, S. 353 ff.].

$$\hat{\mathbf{x}}_{k+1} = \mathbf{A}\hat{\mathbf{x}}_k + \mathbf{B}u_k + \mathbf{L}e_k \quad (4.3a)$$

$$= \mathbf{A}\hat{\mathbf{x}}_k + \mathbf{B}u_k + \mathbf{L}(y_k - \hat{y}_k) \quad (4.3b)$$

$$= \mathbf{A}\hat{\mathbf{x}}_k + \mathbf{B}u_k + \mathbf{L}(y_k - \mathbf{C}\hat{\mathbf{x}}_k - \mathbf{D}u_k) \quad (4.3c)$$

$$= (\mathbf{A} - \mathbf{L}\mathbf{C})\hat{\mathbf{x}}_k + \begin{bmatrix} \mathbf{B} - \mathbf{L}\mathbf{D} & 0 \\ 0 & \mathbf{L} \end{bmatrix} \begin{bmatrix} u_k \\ y_k \end{bmatrix} \quad (4.3d)$$

Über die Rückführungsmatrix \mathbf{L} kann die Dynamik der Zustandskorrektur angepasst werden, welche sich aus der Systemmatrix des geschlossenen Regelkreises $(\mathbf{A} - \mathbf{L}\mathbf{C})$ ergibt. Das Ziel bei der Auslegung von \mathbf{L} ist es, die Abweichung der Zustandsvektoren $\boldsymbol{\varepsilon} = \mathbf{x} - \hat{\mathbf{x}}$ zu minimieren. Beim Luenberger-Beobachter erfolgt die Wahl von \mathbf{L} beispielsweise durch Eigenwertvorgabe. Wird das System als stochastisches System betrachtet, liefert das Kalman-Filter mit der Kalman-Verstärkung eine optimale Gewichtungsmatrix, bei welcher das Gütemaß $\mathbb{E}\{\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^T\}$ minimal wird [168, S. 359 f.].

Wei et al. [170] verwenden einen Beobachter zur SOC-Schätzung einer Batteriezelle. Die Rückführungsmatrix \mathbf{L} wird durch Polvorgabe mit der Formel nach Ackermann bestimmt [168, Kap. 13]. Die Autoren berücksichtigen bei der Validierung des Algorithmus hohe sowie niedrige Systemanregung. Xu et al. [171] ersetzen die konstante Rückführungsmatrix durch einen Proportional-Integral-Regler und erhalten so einen adaptiven Beobachter zur Ladezustandsschätzung. Die Parameter des Reglers können durch Polvorgabe oder die LQ-Methode bestimmt werden.

4.1.2 Lineares Kalman-Filter

Für die Zustands- und Parameterschätzung in Batteriemanagementsystemen sind das Kalman-Filter und seine Varianten weit verbreitete Verfahren (siehe beispielsweise [156, 163, 172–182]). Es stellt geringe Anforderungen an die Rechenleistung und ist daher auf Steuergeräten im Fahrzeug implementierbar [183].

Das Kalman-Filter ist ein iteratives Verfahren, welches basierend auf den fehlerbehafteten Größen u_k und y_k einen Schätzwert für den Systemzustand $\hat{\mathbf{x}}_{k|k}$ liefert [184]. Die Notation des Index $k|j$ bedeutet, dass der Schätzwert zum Zeitpunkt k unter Berücksichtigung der Messungen von Zeitschritt 1 bis j vorliegt. Benannt ist das Filter nach Rudolf Emil Kálmán (*1930; †2016), der als einer der Entdecker des Algorithmus gilt. Bekannt wurde das Kalman-Filter durch seinen erfolgreichen Einsatz im Steuersystem der Raumfähren des Apollo Raumfahrtprogramms der NASA [185, S. 14]. Die Einsatzmöglichkeiten des Kalman-Filters sind vielfältig und so ist es auch in heutigen Batteriemanagementsystemen als Zustandsschätzer für den Ladezustand und andere Modellgrößen weit verbreitet.

Im Gegensatz zum klassischen Beobachter handelt es sich beim Kalman-Filter um ein stochastisches Verfahren, bei dem die Rückführungsmatrix nicht konstant ist, sondern für jede Iteration optimal gewählt wird. Dem Algorithmus liegt die Annahme zugrunde, dass der Systemzustand ebenso wie die Messung von einer Störung überlagert sind, welche durch ein stochastisches Rauschsignal modelliert werden kann. Der Systemzustand zum Zeitpunkt k und der zugehörige Systemausgang errechnen sich aus dem Zustand des vorherigen Zeitschritts, des aktuellen Eingangssignals sowie dem Prozessrauschen q bzw. Messrauschen r zu

$$\mathbf{x}_{k+1} = \mathbf{A}_k \mathbf{x}_k + \mathbf{B}_k u_k + \mathbf{q}_k \quad (4.4a)$$

$$y_k = \mathbf{C}_k \mathbf{x}_k + \mathbf{D}_k u_k + r_k. \quad (4.4b)$$

Entsprechend des zugrunde liegenden Modells ergeben sich für die verwendeten Vektoren und Matrizen des Kalman-Filters die Dimensionen gemäß Tabelle 4.2.

Für das sogenannte System- bzw. Prozessrauschen und das Messrauschen müssen die folgenden weiteren Annahmen getroffen werden [186, S. 124]:

$$\mathbb{E} \{ \mathbf{q}_k \mathbf{q}_j^T \} = \mathbf{Q} \delta_{k-j} \quad (4.5a)$$

$$\mathbb{E} \{ r_k r_j^T \} = R \delta_{k-j} \quad (4.5b)$$

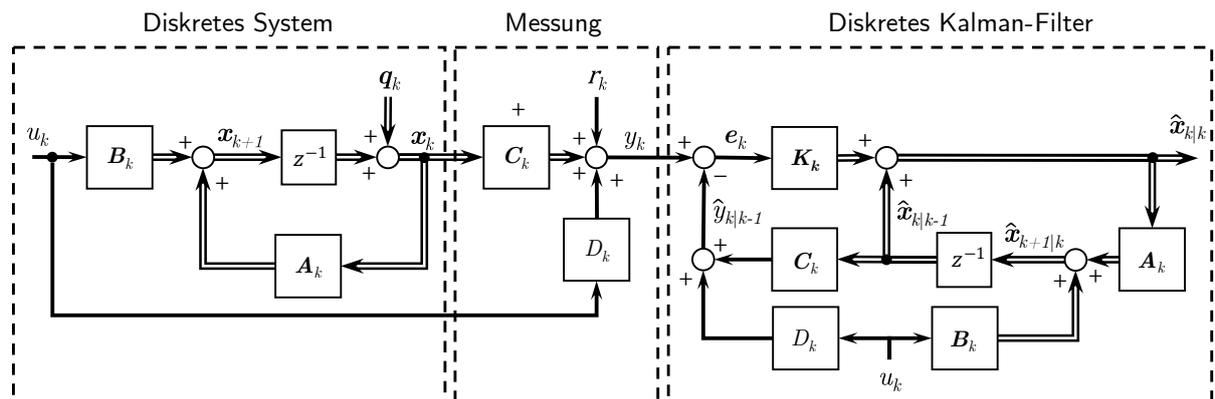
$$\mathbb{E} \{ r_k \mathbf{q}_j^T \} = 0 \quad (4.5c)$$

Hierbei ist mit δ_k der Dirac-Puls notiert. Beim System- bzw. Messrauschen handelt es sich also um normalverteiltes und mittelwertfreies Rauschen, dessen Kovarianz \mathbf{Q} bzw. R ist. Weiterhin muss gelten, dass r und \mathbf{q} nicht miteinander korreliert sind. In der Praxis zeigt sich, dass das Kalman-Filter auch in solchen Fällen akzeptable Ergebnisse liefert, in denen die Annahme der Gauß-Verteilung für das Mess- oder Systemrauschen verletzt ist oder nicht nachgewiesen werden kann, auch wenn dann die Optimalität des Verfahrens nicht mehr gilt [168, S. 360].

Die folgende Herleitung der Gleichungen des Kalman-Filters basiert auf [89, 185–187]. Eine schematische Darstellung des Kalman-Filters kann Abb. 4.3 entnommen werden. Aus der Ge-

Tabelle 4.2: Dimensionen der für das Kalman-Filter relevanten Vektoren und Matrizen.

Matrix	Symbol	Dimension
Geschätzter Zustandsvektor	$\hat{\mathbf{x}}$	$n \times 1$
Kovarianz der Schätzung	$\hat{\mathbf{P}}$	$n \times n$
System-/Prozessrauschen	\mathbf{q}	$n \times 1$
Kovarianz des System-/Prozessrauschens	\mathbf{Q}	$n \times n$
Messrauschen	r	$q \times 1$
Kovarianz des Messrauschens	R	$q \times q$
Systemmatrix	\mathbf{A}	$n \times n$
Eingangsmatrix	\mathbf{B}	$n \times p$
Ausgangsmatrix	\mathbf{C}	$q \times n$
Durchgriffsmatrix	\mathbf{D}	$q \times p$
Innovation	e	$q \times 1$
Kalman-Verstärkung	\mathbf{K}	$n \times q$

**Abbildung 4.3:** Blockschaltbild eines linearen Systems und einem zugehörigen Kalman-Filter angelehnt an Grewal [185, S. 138].

wichtungsmatrix \mathbf{L} des Luenberger-Beobachters wird die Kalman-Verstärkung \mathbf{K} . Die Matrizen \mathbf{A} , \mathbf{B} , \mathbf{C} und \mathbf{D} werden im Folgenden aus Gründen der Übersichtlichkeit ohne den Index k angegeben, auch wenn sich diese für zeitvariante Systeme zu jedem Zeitschritt ändern können. Solange die Matrizen und Vektoren bekannt sind, bleibt das Verfahren unverändert.

Der Algorithmus gliedert sich in zwei Teile. Zunächst wird im Prädiktionsschritt die *a priori* Schätzung $\hat{\mathbf{x}}_{k+1|k} = p(\mathbf{x}_{k+1}|y_{1:k}, u_1)$ für den nächsten Zeitschritt basierend auf der *a posteriori* Schätzung des aktuellen Zeitschritts $\hat{\mathbf{x}}_{k|k} = p(\mathbf{x}_k|y_{1:k}, u_{1:k})$ prädiert.

$$\hat{\mathbf{x}}_{k+1|k} = \mathbf{A}\hat{\mathbf{x}}_{k|k} + \mathbf{B}u_k \quad (4.6)$$

Zusammen mit dem geschätzten Zustandsvektor selbst wird auch die Kovarianzmatrix des Schätzfehlers $\hat{\mathbf{P}}_{k+1|k} = \text{Var}\{\boldsymbol{\varepsilon}_{k+1|k}\}$ für den nächsten Zeitschritt bestimmt. Vereinfachend wird angenommen, dass der Systemeingang u_k sicher bekannt ist und demnach $\text{Var}\{u_k\} = 0$ gilt. Im

Falle einer Messunsicherheit des Systemeingangs wird diese dem Prozessrauschen zugerechnet, dessen Kovarianz dann größer gewählt werden muss.

$$\hat{\mathbf{P}}_{k+1|k} = \text{Var} \{ \hat{\mathbf{x}}_{k+1|k} \} \quad (4.7a)$$

$$= \text{Var} \{ \mathbf{A}\hat{\mathbf{x}}_{k|k} + \mathbf{B}u_k + \mathbf{q}_k \} \quad (4.7b)$$

$$= \text{Var} \{ \mathbf{A}\hat{\mathbf{x}}_{k|k} \} + \text{Var} \{ \mathbf{B}u_k \} + \text{Var} \{ \mathbf{q}_k \} \quad (4.7c)$$

$$= \mathbf{A}\hat{\mathbf{P}}_{k|k}\mathbf{A}^T + \mathbf{Q} \quad (4.7d)$$

Der zweite Teil des Kalman-Filter-Algorithmus ist der Korrekturschritt, bei welchem die a priori Schätzung auf Basis des neu verfügbaren Messwerts y_k korrigiert wird, sodass sich der a posteriori Schätzwert für den aktuellen Zeitschritt $\hat{\mathbf{x}}_{k|k} = p(\mathbf{x}_k | y_{1:k}, u_{1:k})$ ergibt. Die Korrektur kann als Gewichtung bzw. Fusion von zwei Informationsquellen verstanden werden: zum einen existiert Modellwissen über den vorangegangenen Prädiktionsschritt, zum anderen liegt der aktuelle Messwert y_k vor. Basierend auf $\hat{\mathbf{x}}_{k|k-1}$ kann der prädizierte Systemausgang mit zugehöriger Kovarianz nach (4.8) bestimmt werden. Die Varianz der Messung y_k ist R .

$$\hat{y}_{k|k-1} = \mathbf{C}\hat{\mathbf{x}}_{k|k-1} + Du_k \quad (4.8a)$$

$$\begin{aligned} \text{Var} \{ \hat{y}_{k|k-1} \} &= \text{Var} \{ \mathbf{C}\hat{\mathbf{x}}_{k|k-1} + Du_k \} \\ &= \mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T \end{aligned} \quad (4.8b)$$

Auch hier gilt die vereinfachte Annahme, dass der Systemeingang bekannt sei. Etwaige Unsicherheiten werden dem Messrauschen zugeschlagen. Für die optimale Fusion zweier Informationen X und Y mit entsprechendem Erwartungswert und Varianz gilt:

$$\mathbb{E} \{ X|Y \} = \frac{\text{Var} \{ Y \} \mathbb{E} \{ X \} + \text{Var} \{ X \} \mathbb{E} \{ Y \}}{\text{Var} \{ X \} + \text{Var} \{ Y \}} \quad (4.9a)$$

$$= \mathbb{E} \{ X \} + \underbrace{\frac{\text{Var} \{ X \}}{\text{Var} \{ X \} + \text{Var} \{ Y \}}}_{\mathbf{K}} (\mathbb{E} \{ Y \} - \mathbb{E} \{ X \}) \quad (4.9b)$$

Analog kann die Korrektur des Zustandsvektors geschrieben werden als

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (y_k - \hat{y}_{k|k-1}), \quad (4.10)$$

wobei für die Kalman-Verstärkung (4.11) gilt. Der vorangestellte Faktor \mathbf{C}^+ projiziert den Korrekturwert vom Mess- in den Zustandsraum. Er kürzt sich dann jedoch heraus.

$$\mathbf{K}_k = \mathbf{C}^+ \frac{\mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T}{\mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T + R} = \frac{\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T}{\mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T + R} = \hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T (\mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T + R)^{-1} \quad (4.11)$$

Schließlich wird auch die a posteriori Kovarianz der Zustandsschätzung im Korrekturschritt ermittelt. Wegen $\text{Var}\{\mathbf{x}_k\} = 0$ gilt $\text{Var}\{\hat{\mathbf{x}}_{k|k}\} = \text{Var}\{\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}\}$ und damit:

$$\hat{\mathbf{P}}_{k|k} = \text{Var}\{\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}\} \quad (4.12a)$$

$$= \text{Var}\{\mathbf{x}_k - \hat{\mathbf{x}}_{k|k-1} - \mathbf{K}_k(y_k - \mathbf{C}\hat{\mathbf{x}}_{k|k-1} - Du_k)\} \quad (4.12b)$$

$$= \text{Var}\{\mathbf{x}_k - (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{x}}_{k|k-1} - \mathbf{K}_ky_k + \mathbf{K}_kDu_k\} \quad (4.12c)$$

$$= \text{Var}\{\mathbf{x}_k - (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{x}}_{k|k-1} - \mathbf{K}_k\mathbf{C}\mathbf{x}_k - \mathbf{K}_kDu_k + \mathbf{K}_kDu_k - \mathbf{K}_kr_k\} \quad (4.12d)$$

$$= \text{Var}\{(\mathbf{I} - \mathbf{K}_k\mathbf{C})\mathbf{x}_k - (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{x}}_{k|k-1} - \mathbf{K}_kr_k\} \quad (4.12e)$$

$$= \text{Var}\{(\mathbf{I} - \mathbf{K}_k\mathbf{C})\varepsilon_{k|k-1} - \mathbf{K}_kr_k\} \quad (4.12f)$$

$$= (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{P}}_{k|k-1}(\mathbf{I} - \mathbf{K}_k\mathbf{C})^\top + \mathbf{K}_k\mathbf{R}\mathbf{K}_k^\top \quad (4.12g)$$

Es handelt sich bei (4.12) um die Joseph-Form der Kovarianz-Korrektur. Sie ist weniger anfällig gegenüber Rundungsfehlern [185, S. 136 f.] als die aufgrund des geringeren Rechenaufwands häufiger verwendete Gleichung

$$\hat{\mathbf{P}}_{k|k} = (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{P}}_{k|k-1}. \quad (4.13)$$

Zwei alternative Herleitungen des Korrekturschritts der Kovarianzmatrix können [187, S. 87 ff.] entnommen werden. Eine Herleitung basierend auf der Bayesschen Statistik liefert Chen [188].

Algorithmus 4.1 fasst die Schritte des linearen Kalman-Filters übersichtlich zusammen. Es kann nach Lunze [189, S. 373 f.] als Erweiterung des Luenberger Beobachters insofern angesehen werden, als dass die Rückführungsmatrix \mathbf{L} des Beobachters zur Kalman-Verstärkung \mathbf{K} wird und diese optimal gewählt wird zu

$$\mathbf{K} = \mathbf{P}\mathbf{C}^\top\mathbf{S}^{-1}, \quad (4.14)$$

wobei \mathbf{P} eine positiv definite Lösung der Matrix-Ricatti-Gleichung

$$\mathbf{A}\mathbf{P} + \mathbf{P}\mathbf{A}^\top - \mathbf{P}\mathbf{C}^\top\mathbf{R}^{-1}\mathbf{C}\mathbf{P} + \mathbf{Q} = \mathbf{0} \quad (4.15)$$

ist. Das Kalman-Filter kann demnach als Optimal-Regler angesehen werden, wobei \mathbf{Q} und \mathbf{R} als Gewichtungsmatrizen des Optimal-Regler-Entwurfs Verwendung finden mit dem Ziel, den quadratischen Fehler der Schätzung zu minimieren.

Das Kalman-Filter ist unter den Annahmen aus (4.5) und wenn \mathbf{Q} und \mathbf{R} sowie die Modellgleichungen bekannt sind, optimal im Sinne eines Minimum-Varianz-Schätzers. Außerdem ist der Schätzfehler ε erwartungstreu [188]. Für ein Multiple-Input-Single-Output-System (MISO-System) mit $\mathbf{A} = \mathbf{I}$, $\mathbf{Q} = 0$ und $u_k = 0$ vereinfachen sich die Kalman-Filter-Gleichungen zu denen des RLS-Algorithmus (Recursive-Least-Squares) [186, S. 129].

Von Bedeutung ist auch die Initialisierung des Filters, welche aus einem Schätzwert für den Systemzustand zum Zeitpunkt $k = 0$ und der zugehörigen Kovarianzmatrix besteht, wenn noch keine Messungen vorliegen. Ist der initiale Systemzustand bekannt, wählt man $\hat{\mathbf{P}}_{0|0} = 0$, ist er dagegen gänzlich unbekannt, sollte $\hat{\mathbf{P}}_{0|0} = \alpha\mathbf{I}$ mit $\alpha \gg 1$ gewählt werden. In diesem Fall wird der Startzustand innerhalb der ersten Iterationen des Filters gering gewichtet im Vergleich zum Residuum der Messung [89, S. 633]. Allerdings hat dann die (potenziell verrauschte) Messung einen großen Einfluss auf den Schätzwert, was zu einem schlechten Einschwingverhalten

Algorithmus 4.1 Lineares Kalman-Filter

-
- 1: **Initialisierung:**
 - 2: $\hat{\mathbf{x}}_{0|0} \leftarrow \mathbb{E}\{\mathbf{x}_0\}$
 - 3: $\hat{\mathbf{P}}_{0|0} \leftarrow \mathbb{E}\{(\hat{\mathbf{x}}_{0|0} - \mathbf{x}_0)(\hat{\mathbf{x}}_{0|0} - \mathbf{x}_0)^T\}$
 - 4: **Prädiktion:**
 - 5: $\hat{\mathbf{x}}_{k|k-1} \leftarrow \mathbf{A}\hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}u_{k-1}$
 - 6: $\hat{\mathbf{P}}_{k|k-1} \leftarrow \mathbf{A}\hat{\mathbf{P}}_{k-1|k-1}\mathbf{A}^T + \mathbf{Q}$
 - 7: **Korrektur:**
 - 8: $\mathbf{S}_k \leftarrow \mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T + \mathbf{R}$
 - 9: $\mathbf{K}_k \leftarrow \hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T\mathbf{S}_k^{-1}$
 - 10: $e_k \leftarrow y_k - (\mathbf{C}\hat{\mathbf{x}}_{k|k-1} + \mathbf{D}u_k)$
 - 11: $\hat{\mathbf{x}}_{k|k} \leftarrow \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k e_k$
 - 12: $\hat{\mathbf{P}}_{k|k} \leftarrow (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{P}}_{k|k-1}$
-

des Filters führen kann. Nach Grewal [185, S. 139] ist ein beliebiger Schätzwert $\hat{\mathbf{x}}_{k|k}$ jedoch unabhängig von den Startwerten für große k , da das Kalman-Filter ein asymptotisch stabiles System ist. Liegen unvollständige Informationen über den initialen Systemzustand vor, so kann das vorhandene a priori Wissen für die Bestimmung des Startwerts herangezogen werden [73, S.272]. Im Falle der Ladezustandsbestimmung lässt sich beispielsweise ein initialer Schätzwert für den SOC über den Zusammenhang des Ladezustands mit der Leerlaufspannung herstellen. Die Klemmenspannung der Batterie zum Startzeitpunkt kann hierbei als Approximation für u_{OC} dienen. Diese Annäherung ist umso mehr gültig, je mehr sich die Batteriezelle im Ruhezustand befindet. Ist die Abweichung zwischen initialem Schätzwert und dem wahren Wert bekannt, kann auch darüber die Kovarianzmatrix $\hat{\mathbf{P}}_{0|0}$ bestimmt werden.

$$\hat{\mathbf{P}}_0 = \mathbb{E}\{(\mathbf{x}_0 - \hat{\mathbf{x}}_0)(\mathbf{x}_0 - \hat{\mathbf{x}}_0)^T\} \quad (4.16)$$

Naturgemäß sind die wahren Werte zum Startzeitpunkt jedoch in vielen Fällen nicht bekannt. Dies ist beim Batterie-Ersatzschaltbildmodell beispielsweise bei den Polarisationsspannungen der Fall, wenn das System zum Zeitpunkt $k = 0$ nicht in Ruhelage ist. Wassiliadis et al. [182] nehmen daher die größtmögliche Abweichung des Startwerts vom wahren Wert als Grundlage und interpretieren diese als $1\text{-}\sigma$ -Grenze. Dementsprechend wird dann der j -te Eintrag der Hauptdiagonalen der initialen Kovarianzmatrix besetzt.

$$\hat{\mathbf{P}}_{0|0,j,j} = \sigma_j^2 \quad (4.17)$$

Weiterhin kann eine Schätzung der Startwerte durch ein Least-Squares-Verfahren über die ersten Zeitschritte gefunden werden [73, S. 272]. Werden Monte-Carlo-Simulationen der Schätzung durchgeführt, kann der initiale Systemzustand nach Bar-Shalom et al. [190, S. 246] als multivariate Normalverteilung $\hat{\mathbf{x}}_{0|0} = \mathcal{N}(\mathbf{x}_0, \hat{\mathbf{P}}_{0|0})$ aufgefasst werden. Für jeden Durchlauf ist $\hat{\mathbf{x}}_{0|0}$ dann zufällig, aber die initialen Werte $\hat{\mathbf{x}}_{0|0}$ und $\hat{\mathbf{P}}_{0|0}$ konsistent zueinander. Das Vorgehen ist demnach genau entgegengesetzt zu (4.16), weil $\hat{\mathbf{x}}_{0|0}$ aus $\hat{\mathbf{P}}_{0|0}$ bestimmt wird, statt umgekehrt.

4.1.3 Erweiterungen für nichtlineare Systeme

Die Anwendung des Kalman-Filters, wie es im vorangegangenen Abschnitt vorgestellt wurde, beschränkt sich auf die Zustandsschätzung von linearen Systemen. Für das Ersatzschaltbildmodell nach (3.6a) und (3.6b) ist dies gegeben, solange das erste Element der Ausgangsmatrix für jede Iteration des Filters aktualisiert wird, um die Steigung der OCV-Funktion zu adaptieren. Damit beschränkt sich die Zustandsschätzung jedoch nur auf den SOC und die beiden Überspannungen der RC-Glieder des Ersatzschaltbildes. Sollen neben diesen Zuständen auch Parameter des Modells in die Schätzung integriert werden, kann der Zustandsvektor um diese Parameter $\boldsymbol{\theta}$ erweitert werden, wodurch sich eine neue Beschreibung des Modells im Zustandsraum ergibt.

$$\begin{bmatrix} \mathbf{x}_{k+1} \\ \boldsymbol{\theta}_{k+1} \end{bmatrix} = \underbrace{\begin{bmatrix} \mathbf{A}(\boldsymbol{\theta}_k) & \mathbf{0} \\ \mathbf{0} & \mathbf{I} \end{bmatrix} \begin{bmatrix} \mathbf{x}_k \\ \boldsymbol{\theta}_k \end{bmatrix} + \begin{bmatrix} \mathbf{B}(\boldsymbol{\theta}_k) \\ \mathbf{0} \end{bmatrix} u_k + \mathbf{q}_k}_{\mathbf{f}(\mathbf{x}_k, \boldsymbol{\theta}_k, u_k)} \quad (4.18a)$$

$$y_k = \underbrace{\mathbf{C}(\boldsymbol{\theta}_k) \mathbf{x}_k + \mathbf{D}(\boldsymbol{\theta}_k) u_k + r_k}_{h(\mathbf{x}_k, \boldsymbol{\theta}_k, u_k)} \quad (4.18b)$$

Da über die zeitliche Entwicklung der Parameter keine Modellinformationen vorliegen, wird ein Random-Walk-Modell mit $\dot{\boldsymbol{\theta}} = \mathbf{0}$ angenommen. Die bestmögliche Prädiktion der Parameter zum Zeitpunkt $k+1$ ist also $\boldsymbol{\theta}_k$. Änderungen des Parametervektors werden durch das Prozessrauschen abgebildet. Im weiteren Verlauf dieses Kapitels umfasst der Zustandsvektor \mathbf{x} die Zustände *und* Parameter. Aufgrund der Abhängigkeit der Matrizen von den Parametern ergibt sich ein nichtlineares System, welches jenseits des Gültigkeitsbereichs des konventionellen Kalman-Filters liegt. Lösungen für dieses Problem liefern das Extended-Kalman-Filter (EKF) oder das Sigma-Point-Kalman-Filter (SPKF).

Im EKF werden die nichtlinearen Funktionen $\mathbf{f}(\mathbf{x}, u)$ und $h(\mathbf{x}, u)$ mittels einer Taylor-Approximation erster Ordnung um den gegenwärtigen Arbeitspunkt linearisiert. Dadurch können anschließend die Schritte des linearen Kalman-Filters verwendet werden. Das EKF ist in Algorithmus 4.2 dargestellt [169, S. 312 ff.]. Zu beachten ist: Während die Linearisierung der Systemgleichung am Arbeitspunkt $\{\hat{\mathbf{x}}_{k-1|k-1}, u_{k-1}\}$ durchgeführt wird, also auf Basis der a posteriori Schätzung des vorangegangenen Zeitschritts, wird die Taylor-Approximation der Ausgangsgleichung am Arbeitspunkt der a priori Schätzung $\{\hat{\mathbf{x}}_{k|k-1}, u_k\}$ angewandt [89, S. 648 f.].

Die Schätzwerte des EKFs sind prinzipiell nicht erwartungstreu, da $\mathbb{E}\{\mathbf{f}(\hat{\mathbf{x}}, u)\} \neq \mathbf{f}(\mathbb{E}\{\hat{\mathbf{x}}\}, u)$ gilt [188]. Dennoch lassen sich quasi-lineare Probleme mit dem EKF lösen, solange die Nichtlinearität nicht so stark ist, dass die Annahme verletzt wird, die durch das System propagierte Verteilung sei normalverteilt. Für schwache Nichtlinearitäten sind die resultierenden Modellfehler jedoch zu vernachlässigen im Vergleich zu Fehlern aufgrund des Messrauschens oder einer nicht modellierten Systemdynamik [185, S. 20 f.].

Anstatt die System- und Messfunktion zu approximieren, nähert das SPKF die durch die Funktion propagierte Verteilung an eine Normalverteilung an. Hierfür werden sogenannte Sigma-Punkte als Stützstellen der Verteilung verwendet. Im Gegensatz zum EKF, welches eine Approximation erster Ordnung nutzt, ist das SPKF bis zum zweiten Moment der Verteilung exakt [89,

Algorithmus 4.2 Extended-Kalman-Filter

-
- 1: **Initialisierung:**
 - 2: $\hat{\mathbf{x}}_{0|0} \leftarrow \mathbb{E}\{\mathbf{x}_0\}$
 - 3: $\hat{\mathbf{P}}_{0|0} \leftarrow \mathbb{E}\{(\hat{\mathbf{x}}_{0|0} - \mathbf{x}_0)(\hat{\mathbf{x}}_{0|0} - \mathbf{x}_0)^T\}$
 - 4: **Prädiktion:**
 - 5: $\hat{\mathbf{x}}_{k|k-1} \leftarrow \mathbf{f}(\hat{\mathbf{x}}_{k-1|k-1}, u_{k-1})$
 - 6: $\mathbf{A} \leftarrow \left. \frac{\partial \mathbf{f}(\mathbf{x}, u)}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k-1|k-1}, u=u_{k-1}}$
 - 7: $\hat{\mathbf{P}}_{k|k-1} \leftarrow \mathbf{A}\hat{\mathbf{P}}_{k-1|k-1}\mathbf{A}^T + \mathbf{Q}$
 - 8: **Korrektur:**
 - 9: $\mathbf{C} \leftarrow \left. \frac{\partial h(\mathbf{x}, u)}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, u=u_k}$
 - 10: $\mathbf{S}_k \leftarrow \mathbf{C}\hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T + \mathbf{R}$
 - 11: $\mathbf{K}_k \leftarrow \hat{\mathbf{P}}_{k|k-1}\mathbf{C}^T\mathbf{S}_k^{-1}$
 - 12: $e_k \leftarrow y_k - h(\hat{\mathbf{x}}_{k|k-1}, u_k)$
 - 13: $\hat{\mathbf{x}}_{k|k} \leftarrow \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k e_k$
 - 14: $\hat{\mathbf{P}}_{k|k} \leftarrow (\mathbf{I} - \mathbf{K}_k\mathbf{C})\hat{\mathbf{P}}_{k|k-1}$
-

S.650f]. Das Filter beruht auf der sogenannten Unscented-Transformation (UT), bei welcher die Verteilung $p(\mathbf{y}) = \mathcal{N}(\mathbf{y}|\boldsymbol{\mu}_y, \boldsymbol{\Sigma}_y)$ basierend auf der Normalverteilung $p(\mathbf{x}) = \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_x, \boldsymbol{\Sigma}_x)$ und der nichtlinearen Funktion $\mathbf{y} = \mathbf{f}(\mathbf{x})$ berechnet wird [191]. An dieser Stelle sind \mathbf{x} und \mathbf{y} beliebige Vektoren, $\boldsymbol{\Sigma}_x$ und $\boldsymbol{\Sigma}_y$ die zugehörigen Kovarianzmatrizen und \mathbf{f} eine beliebige nichtlineare Funktion. Zunächst werden $2n+1$ Sigma-Punkte angelegt, welche die Verteilung von $\mathbf{x} \in \mathbb{R}^{n \times 1}$ abbilden. Dies ist die minimal benötigte Anzahl an Punkten, um die n -dimensionale Normalverteilung bis in zweiter Ordnung hinreichend zu beschreiben.

$$\mathcal{X}_0 = \boldsymbol{\mu}_x \quad (4.19a)$$

$$\mathcal{X}_\zeta = \boldsymbol{\mu}_x + \left(\gamma\sqrt{\boldsymbol{\Sigma}_x}\right)_\zeta \quad \text{für } \zeta = 1, \dots, n \quad (4.19b)$$

$$\mathcal{X}_\zeta = \boldsymbol{\mu}_x - \left(\gamma\sqrt{\boldsymbol{\Sigma}_x}\right)_\zeta \quad \text{für } \zeta = n+1, \dots, 2n \quad (4.19c)$$

$(\sqrt{\boldsymbol{\Sigma}})_\zeta$ bezeichnet hier die ζ -te Spalte der Quadratwurzel der Kovarianzmatrix $\boldsymbol{\Sigma}$. Der Parameter γ erlaubt es, die Streuung der Sigma-Punkte um den Mittelwert zu variieren. Anschließend werden diese einzeln durch die Funktion \mathbf{f} propagiert, sodass mit $\mathbf{y}_\zeta = \mathbf{f}(\mathcal{X}_\zeta)$ neue Punkte im Messraum entstehen. Der Mittelwert und die Varianz der neuen Normalverteilung können bestimmt werden zu [89, S. 651]

$$\boldsymbol{\mu}_y = \sum_{\zeta=0}^{2n} \alpha_\zeta^{(m)} \mathbf{y}_\zeta \quad (4.20a)$$

$$\boldsymbol{\Sigma}_y = \sum_{\zeta=0}^{2n} \alpha_\zeta^{(c)} (\mathbf{y}_\zeta - \boldsymbol{\mu}_y)(\mathbf{y}_\zeta - \boldsymbol{\mu}_y)^T. \quad (4.20b)$$

Hierbei sind $\alpha_\zeta^{(m)}$ und $\alpha_\zeta^{(c)}$ Gewichte, welche den Sigma-Punkten zugeordnet werden. Es ergibt sich das SPKF in Algorithmus 4.3 [89, S. 652].

Algorithmus 4.3 Sigma-Point-Kalman-Filter

-
- 1: **Initialisierung:**
 - 2: $\hat{\mathbf{x}}_{0|0} \leftarrow \mathbb{E}\{\mathbf{x}_0\}$
 - 3: $\hat{\mathbf{P}}_{0|0} \leftarrow \mathbb{E}\{(\hat{\mathbf{x}}_{0|0} - \mathbf{x}_0)(\hat{\mathbf{x}}_{0|0} - \mathbf{x}_0)^T\}$
 - 4: **Prädiktion:**
 - 5: $\mathcal{X}_{0,k-1|k-1} \leftarrow \left\{ \hat{\mathbf{x}}_{k-1|k-1}, \hat{\mathbf{x}}_{k-1|k-1} + \gamma\sqrt{\hat{\mathbf{P}}_{k-1|k-1}}, \hat{\mathbf{x}}_{k-1|k-1} - \gamma\sqrt{\hat{\mathbf{P}}_{k-1|k-1}} \right\}$
 - 6: $\mathcal{X}_{\zeta,k|k-1} \leftarrow \mathbf{f}(\mathcal{X}_{0,k-1|k-1}, u_{k-1})$
 - 7: $\hat{\mathbf{x}}_{k|k-1} \leftarrow \sum_{\zeta=0}^{2n} \alpha_{\zeta}^{(m)} \mathcal{X}_{\zeta,k|k-1}$
 - 8: $\hat{\mathbf{P}}_{k|k-1} \leftarrow \mathbf{Q} + \sum_{\zeta=0}^{2n} \alpha_{\zeta}^{(c)} (\mathcal{X}_{\zeta,k|k-1} - \hat{\mathbf{x}}_{k|k-1})(\mathcal{X}_{\zeta,k|k-1} - \hat{\mathbf{x}}_{k|k-1})^T$
 - 9: $\mathcal{Y}_{\zeta,k} \leftarrow h(\mathcal{X}_{\zeta,k|k-1}, u_k)$
 - 10: $\hat{y}_k \leftarrow \sum_{\zeta=0}^{2n} \alpha_{\zeta}^{(m)} \mathcal{Y}_{\zeta,k}$
 - 11: **Korrektur:**
 - 12: $\mathbf{P}_y \leftarrow R + \sum_{\zeta=0}^{2n} \alpha_{\zeta}^{(c)} (\mathcal{Y}_{\zeta,k} - \hat{y}_k)(\mathcal{Y}_{\zeta,k} - \hat{y}_k)^T$
 - 13: $\mathbf{P}_{xy} \leftarrow \sum_{\zeta=0}^{2n} \alpha_{\zeta}^{(c)} (\mathcal{X}_{\zeta,k|k-1} - \hat{\mathbf{x}}_{k|k-1})(\mathcal{Y}_{\zeta,k} - \hat{y}_k)^T$
 - 14: $\mathbf{K}_k \leftarrow \mathbf{P}_{xy} \mathbf{P}_y^{-1}$
 - 15: $\hat{\mathbf{x}}_{k|k} \leftarrow \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (y_k - \hat{y}_k)$
 - 16: $\hat{\mathbf{P}}_{k|k} \leftarrow \hat{\mathbf{P}}_{k|k-1} - \mathbf{K}_k \mathbf{P}_{xy} \mathbf{K}_k^T$
-

Mit dem Unscented-Kalman-Filter (UKF) von Wan und Merwe [192] und Merwe [193] sowie dem Central-Difference-Kalman-Filter (CDKF) [193–195] existieren zwei weit verbreitete Varianten des SPKFs, welche sich hinsichtlich des Parameters γ und der Wahl der Gewichte $\alpha_{\zeta}^{(m)}$ und $\alpha_{\zeta}^{(c)}$ voneinander unterscheiden. Eine Übersicht über die beiden Varianten des SPKFs und ihrer Koeffizienten gibt Tabelle 4.3. Während beim UKF die Sigma-Punkte basierend auf der Taylor-Reihe gewählt werden, beruht das CDKF auf der Stirlingformel [174]. Mit α , β und κ besitzt das UKF drei Koeffizienten, die gewählt werden müssen, wohingegen das CDKF nur durch den Parameter h eingestellt wird. Im weiteren Verlauf wird daher das CDKF verwendet. Es besitzt außerdem eine leicht höhere theoretische Genauigkeit [195].

Wird die Anzahl an Sigma-Punkten stark erhöht, kann die Nichtlinearität des Systems durch eine Art Monte-Carlo-Simulation abgebildet werden. Man erhält das sogenannte Partikel-Filter,

Tabelle 4.3: Koeffizienten für zwei Varianten des Sigma-Point-Kalman-Filters [174].

	γ	$\alpha_0^{(m)}$	$\alpha_{\zeta}^{(m)}$	$\alpha_0^{(c)}$	$\alpha_{\zeta}^{(c)}$
UKF	$\sqrt{n+\lambda}$	$\frac{\lambda}{n+\lambda}$	$\frac{1}{n(n+\lambda)}$	$\frac{\lambda}{n+\lambda} + (1 - \alpha^2 + \beta)$	$\frac{1}{2(n+\lambda)}$
CDKF	h	$\frac{h^2-n}{h^2}$	$\frac{1}{2h^2}$	$\frac{h^2-n}{h^2}$	$\frac{1}{2h^2}$

$\lambda = \alpha^2(n+\kappa) - n$ ist ein Skalierungsparameter, mit $(0, 1 \leq \alpha \leq 1)$. Zu beachten ist, dass sich α von $\alpha^{(m)}$ bzw. $\alpha^{(c)}$ unterscheidet. κ ist entweder 0 oder $3 - n$. β umfasst Vorwissen und sollte für Normalverteilungen $\beta = 2$ gewählt werden. h kann jeglichen positiven Wert annehmen. Für Normalverteilungen wählt man $h = \sqrt{3}$.

wobei der Begriff Partikel die vielen Sigma-Punkte bezeichnet, die dann allerdings zufällig verteilt gewählt werden [188]. Eine Normalverteilung wird dann nicht mehr vorausgesetzt, sodass durch die Partikel auch andere Wahrscheinlichkeitsverteilungen abgebildet werden können. Der Mechanismus ist für eine große Anzahl an Partikeln sehr mächtig, um auch starke Nichtlinearitäten abzubilden, allerdings steigt auch der Rechenaufwand stark an. Als Zustandsschätzverfahren für den Online-Einsatz ist das Partikel-Filter daher nicht zielführend, obwohl in [196] eine auf dem Partikelfilter beruhende SOC- und SOH-Schätzung implementiert wird.

Inwiefern sich EKF und SPKF hinsichtlich der Approximation der a priori Wahrscheinlichkeitsverteilung des Zustandsvektors unterscheiden, soll vereinfachend für den eindimensionalen Fall ($n = 1$) in Abb. 4.4 illustriert werden. Die ursprüngliche Normalverteilung $p(x)$ vor der Propagierung durch die Modellgleichung ist in Grün gezeigt. Diese wird durch die in Rot dargestellte Modellfunktion $f(x)$ in den y -Raum transformiert. Es ergibt sich die nun nicht mehr normalverteilte Wahrscheinlichkeitsdichte $p(y)$ (in blau). Zunächst soll die Taylor-Approximation 1. Ordnung analysiert werden, auf der das EKF beruht. Dabei wird die nichtlineare Funktion am aktuellen Arbeitspunkt linearisiert und $p(y)$ auf Basis der linearisierten Funktion von f (schwarz gestrichelt) angenähert. Die resultierende Normalverteilung ist in Gelb dargestellt. Für die UT werden die drei Sigma-Punkte \mathcal{X} (in der Abbildung als grüne Kreise) angelegt, welche die Verteilung $p(x)$ bis zum zweiten Moment repräsentieren. Diese werden direkt durch die nichtlineare Funktion propagiert, sodass sich \mathcal{Y} ergibt (blaue Kreise in der Abbildung). Auf Basis dieser Sigma-Punkte wird nun wieder die Verteilung $p(y)$ approximiert, wobei wiederum eine Gauß-Verteilung angenommen wird (dargestellt in hellblau). Wie aus der Abbildung ersichtlich ist, unterscheiden sich die beiden Approximationen hinsichtlich ihrer Momente. Insbesondere nimmt die auf der UT angelehnte Wahrscheinlichkeitsverteilung eine größere Varianz für $p(y)$ an. Die Asymmetrie der realen Verteilung von y bildet keine der Approximationen ab, da beiden die Annahme einer Normalverteilung zugrunde liegt. Insbesondere bei starken Nichtlinearitäten ist die UT robuster gegenüber Messrauschen, da die Varianz größer geschätzt wird. Ist $f(x)$ quasi-linear, ist die Taylor-Approximation des EKFs ausreichend [185, S. 20 f.]. Wie Merwe [193, S. 35 ff.] herausstellt, ist für die Eignung des EKFs außerdem von Bedeutung, wie groß die Varianz der Eingangsgröße x und damit der betrachtete Bereich von f ist, über den linearisiert wird, denn je weiter entfernt vom Arbeitspunkt die Wahrscheinlichkeitsverteilung ungleich null ist, desto größer kann der Linearisierungsfehler $f(x) - f_{\text{lin}}(x)$ werden.

Plett vergleicht in [174] die SOC-Schätzung mittels EKF und CDKF miteinander, wobei sich das verwendete Batteriemodell leicht vom Modell in der vorliegenden Arbeit unterscheidet. Aufgrund der nur geringen Nichtlinearität des Batteriemodells, welche hauptsächlich auf die OCV-Kurve zurückzuführen ist, sind keine signifikanten Unterschiede zwischen beiden nichtlinearen Erweiterungen des Kalman-Filters zu erwarten. Die Ergebnisse sind dann auch sehr ähnlich. Ein vergleichbares Resultat kann auch in eigenen Simulationen erzielt werden, bei denen der SOC mit EKF, CDKF und UKF jeweils auf den gleichen Sensordaten basierend geschätzt wird. Grundlage ist ein Referenzmodell der Batteriezellen, welches mit einem auf dem WLTP basierenden Stromprofil angeregt wird. Die Schätzergebnisse sind quasi identisch und es tritt kein sichtbarer Unterschied zwischen den Implementierungen auf. Der RMSE unterscheidet sich um weniger als 0,001 %. Auch bezüglich der Komplexität sind die Implementierungen vergleichbar. Sowohl das EKF, als auch das SPKF weisen die Komplexität $\mathcal{O}(n^2)$ auf [192].

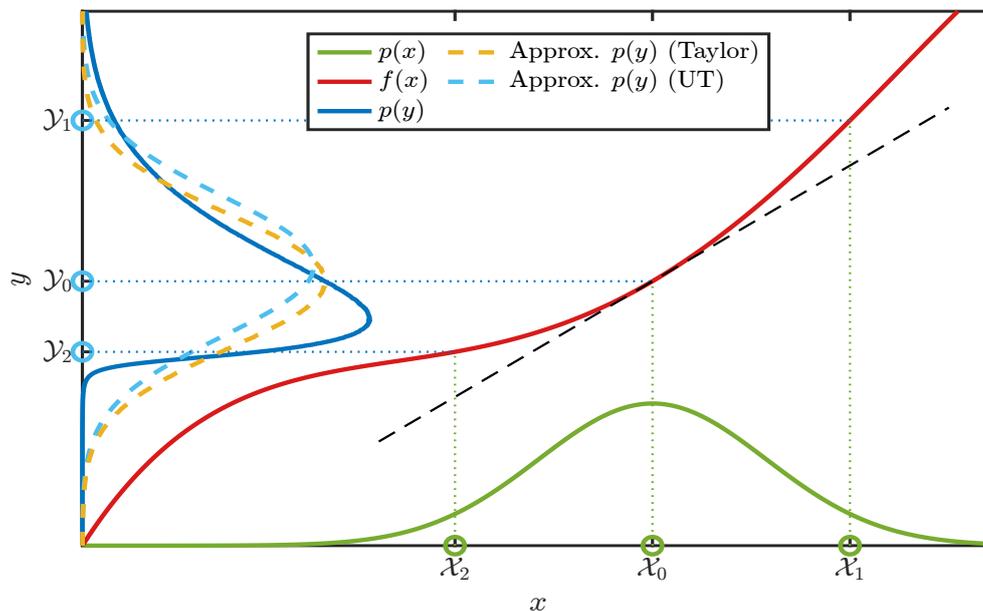


Abbildung 4.4: Approximation der Verteilung $p(y)$ mit Taylor-Approximation 1. Ordnung und UT. Abbildung angelehnt an Plett [174].

Da das SPKF seine Vorteile bei starker Nichtlinearität der Systemgleichung ausspielt, diese aber bei den verwendeten Batteriemodellen nicht gegeben ist, wird im weiteren Verlauf das EKF als nichtlineare Implementierung des Kalman-Filters verwendet. Da es im Gegensatz zu CDKF und UKF keine Einstellparameter aufweist, sind die Ergebnisse auch leichter nachvollziehbar. Das EKF kann somit als Referenzimplementierung eines nichtlinearen Kalman-Filters angesehen werden und ist als solche mit der Literatur vergleichbar.

4.1.4 Dual-Kalman-Filter

Die Erweiterung der Systemmatrix um die Parameter θ des Batteriemodells wie in (4.18) wird auch als Joint-Estimation bezeichnet: Zustände und Parameter werden in einem Vektor zusammengefasst und in einem gemeinsamen Filter geschätzt. Joint-Kalman-Filter (JKF) werden in der Literatur unter anderem von Zou et al. [197] zur Zustands- und Parameterschätzung eingesetzt. Demgegenüber verfolgt das als Dual-Estimation bezeichnete Konzept die Idee, zwei Kalman-Filter parallel arbeiten zu lassen, welche untereinander Informationen austauschen. Das Konzept wurde von Anderson und Moore [198] erstmalig vorgeschlagen. Der Verbund aus zwei parallelen Kalman-Filtern wird als Dual-Kalman-Filter (DKF) bezeichnet.

Das Blockschaltbild eines DKFs ist in Abb. 4.5 gezeigt. Die beiden Kalman-Filter tauschen miteinander Informationen aus, indem die prädizierten Zustände bzw. Parameter für den Korrekturschritt des jeweils anderen Filters verwendet werden. Das Verfahren kann als generalisierter EM-Algorithmus (Expectation-Maximization) gesehen werden, bei welchem durch die iterative Optimierung von Zustands- und Parameterschätzung allerdings nur eine suboptimale Lösung erzielt wird [188].

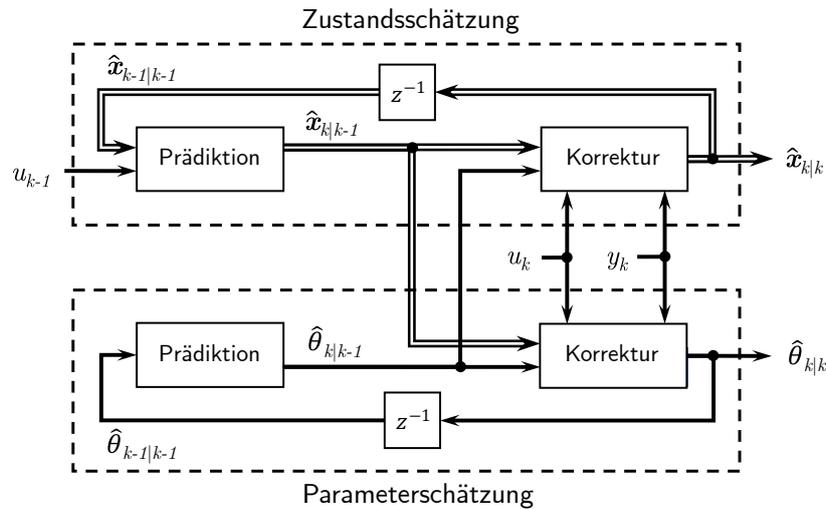


Abbildung 4.5: Blockdiagramm der Zustands- und Parameterschätzung mithilfe eines DKFs. Angelehnt an Plett [173].

Ein Vorteil des DKFs ist der niedrigere Rechenaufwand aufgrund der Operationen mit kleineren Matrizen im Vergleich zum JKF [174]. Dahingegen können jedoch sehr unterschiedliche Dynamiken der Zustände und Parameter zu einer schlechten Konditionierung des Schätzproblems führen [175]. Laut Andre et al. [179] erhöht sich durch die Verwendung eines DKFs die Robustheit der Gesamtschätzung, weil Wechselwirkungen zwischen der Schätzung der Zustände bzw. der Parameter vermieden werden.

DKFs werden in der Literatur vielfach in Batteriemanagementsystemen eingesetzt, um den Ladezustand sowie weitere Zustände und Parameter adaptiv zu bestimmen. Plett [156, 172, 173] nutzt ein EKF um die Coulombsche Effizienz, die Zellkapazität, den stromrichtungsabhängigen Innenwiderstand sowie weitere Parameter zusätzlich zu den Systemzuständen seines Batteriemodells zu schätzen. In weiteren Arbeiten des Autors wird ein SPKF verwendet [174, 175]. Andre et al. [179] verwenden ein DP-Batteriemodell wie in Abb. 3.2. Die Menge aus Zuständen und Parametern werden bei ihnen derart aufgeteilt, dass ein lineares System entsteht, deren Zustandsvektor $\mathbf{x}_1 = [R_0 \ u_1 \ u_2]^T$ mit einem konventionellen Kalman-Filter geschätzt werden kann. Ein zweiter Zustandsvektor $\mathbf{x}_2 = [\text{SOC} \ R_1 \ R_2]^T$ wird mit einem UKF geschätzt, da diesem ein nichtlineares Modell zugrunde liegt. Die Zustände der beiden Filter des DKFs müssen also nicht zwangsläufig Systemzustände bzw. Parameter enthalten. Die Zeitkonstanten der RC-Glieder τ_1 und τ_2 werden als konstant angenommen. Ein ähnlicher Ansatz wird von Wang et al. [199] verfolgt, wobei sich jedoch die beiden Zustandsvektoren klassisch auf die Zustände (SOC und Überspannungen) und Parameter (Widerstände und Kapazitäten) aufteilen. Die Gruppierung stellt eine Einteilung der Zustände und Parameter in sich schnell bzw. langsam verändernde Größen dar. In der Arbeit von Wang et al. werden auch die Kapazitäten der RC-Glieder geschätzt und für beide Filter kommen UKFs zum Einsatz. Die Validierung des Algorithmus beschränkt sich allerdings nur auf den SOC und den Ohmschen Innenwiderstand. Campestrini et al. [200] nutzen ein einfacheres Modell mit nur einem RC-Glied und schätzen zusätzlich zu den Zuständen SOC und u_1 mit einem EKF die Zellkapazität Q sowie die Widerstände R_0 und R_2 . In der

Validierung wird allerdings die Kapazität als konstant angenommen, da sich diese über die Dauer der Experimente nicht nennenswert verändert. Wassiliadis et al. [182] untersuchen die Schätzfehler eines DKFs abhängig von der Alterung der Zellen sowie für unterschiedliche Stärken der Systemanregung.

Weiterhin kommen in der Literatur auch statt eines Kalman-Filters RLS- (Recursive-Least-Squares) oder TLS-Verfahren (Total-Least-Squares) zum Einsatz, um die Parameter zu schätzen, wobei letzteres jedoch zu einem erhöhten Rechenaufwand führt [170, 180, 201–203]. Einen Vergleich von DKF sowie der Kombination eines EKF mit RLS bzw. TLS geben Wei et al. [204]. Auch bei der Kombination aus Kalman-Filter und Least-Squares-Verfahren können unterschiedliche Zeitskalen für die Zustands- und Parameterschätzung verwendet werden [102]. Durch dieses Vorgehen kann der unterschiedlichen Dynamik der sich schnell verändernden Zustände gegenüber den nur langsam driftenden Parametern Rechnung getragen werden.

Während sich viele Ansätze neben der Zustandsschätzung auf die Bestimmung des Innenwiderstands und der Parameter der RC-Glieder beschränken [205–207], kann auch die verfügbare Zellkapazität als Maß für den SOH adaptiv bestimmt werden [106]. Aufgrund der geringen Sensitivität der Messwerte bezüglich der Kapazität ist diese allerdings nur schwer exakt zu bestimmen. Deshalb verwenden Hu et al. [208] beim Kalman-Filter für die Kapazitätsschätzung eine andere Zeitskala, bei welcher der Korrekturschritt für den Parameterschätzer nur sporadisch durchgeführt wird. Ähnlich gehen Zou et al. [197] vor, um die Kapazität und den Innenwiderstand als Maß für den SOH zu bestimmen.

In Kapitel 6.2 wird eine Zustandsschätzung um eine robuste Innenwiderstandsschätzung basierend auf dem Prinzip der Dual-Estimation erweitert und modifiziert. Hierbei wird das Potenzial ebenso wie mögliche Schwachstellen des DKFs genauer betrachtet.

4.1.5 Versuchsdurchführung und Methodik zur Beurteilung der Filtergüte

In den folgenden Kapiteln werden Simulationen von und Experimente mit IBSs durchgeführt. Der das System anregende Stromverlauf kann hierbei auf zwei Arten gewonnen werden, wie in Abb. 4.6 dargestellt. Zum einen werden Messdaten aus realen Versuchsfahrten von BEVs oder Prüfstandsmessungen verwendet, wenn der Lade-/Entladestrom gemessen und gespeichert wurde. Hier ist lediglich eine Skalierung des Stromes notwendig, um ihn auf die Kapazität der verwendeten Batteriezellen anzupassen und deren Stromgrenzen einzuhalten. Der Batteriestrom lässt sich neben der Leistungsanforderung des elektrischen Antriebsstrangs auch auf Nebenverbraucher im Fahrzeug zurückführen. Aufgrund des hohen Aufwands ist die Anzahl zur Verfügung stehender Messdaten aus Versuchsfahrten und Messungen von Prüfständen begrenzt. Daher kommen zum anderen synthetische Anregungsprofile zum Einsatz, welche durch Modelle hergeleitet werden. Ausgehend vom Geschwindigkeitsprofil eines Fahrzyklus kann die benötigte elektrische Leistung über ein Fahrzeuglängsmodell hergeleitet werden, welches die Fahrwiderstände berücksichtigt. Unter der Vereinfachung, dass diese Leistung von allen Batteriezellen zu gleichen Teilen aufgebracht wird, kann durch ein Modell einer Batteriezelle ein Zellstrom und damit der Batteriesystemstrom i_{ges} bestimmt werden. Weitere Informationen zu den verwendeten Anregungsprofilen finden sich in Anhang A.

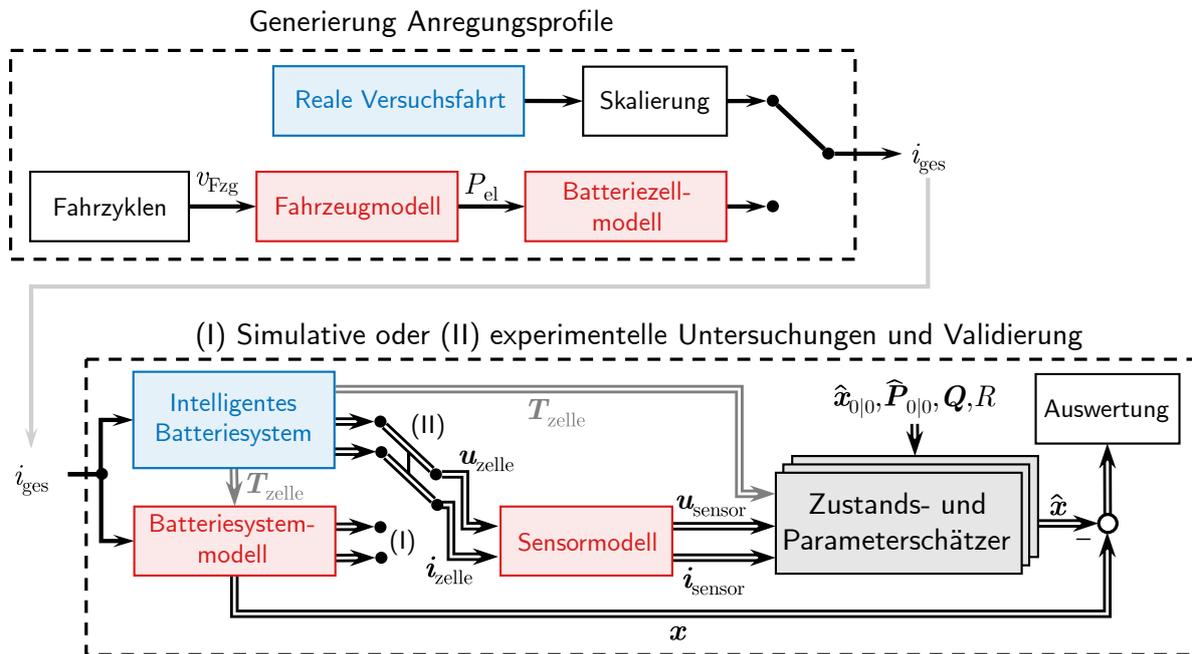


Abbildung 4.6: Methodik zur Untersuchung und Validierung der Zustands- und Parameterschätzung anhand von (I) Simulationen und (II) Experimenten (vgl. Wassiliadis et al. [182]).

Im unteren Teil der Abb. 4.6 ist die Methodik zur Untersuchung der Zustands- und Parameterschätzung dargestellt. Während in den durchgeführten Simulationen lediglich ein Modell des Batteriesystems mit dem Stromprofil angeregt wird, kommt bei den Experimenten eine reale Batteriezelle oder ein reales Modul bestehend aus zwölf intelligenten Batteriezellen zum Einsatz (für eine detaillierte Beschreibung des Versuchsaufbaus siehe Anhang B). Das Batteriesystemmodell ist aber dennoch wichtig, um Referenzwerte für die nicht messbaren Zustandsgrößen wie den Ladezustand oder die Polarisationsspannungen zu erzeugen. Unabhängig davon, ob die experimentell gewonnenen Sensordaten für Strom und Spannung oder simulative Daten verwendet werden, ist dem Kalman-Filter ein Sensormodell vorgeschaltet. Dieses überlagert den Messdaten ein künstliches Sensorrauschen. Dadurch, dass dessen Charakteristik einstellbar und bekannt ist, kann die Güte der Schätzung in Abhängigkeit vom Rauschlevel beurteilt werden. Schließlich wird die Zustands- und Parameterschätzung durchgeführt, wobei für jede (intelligente) Batteriezelle eines Moduls eigene unabhängige Schätzwerte ermittelt werden. Im Falle der experimentellen Untersuchungen kann hierzu auch auf die gemessene Zelltemperatur zurückgegriffen werden. Da das Batteriesystemmodell kein Modell der Wärmegenerierung und -ausbreitung beinhaltet, ist für die simulativen Untersuchungen die Temperatur konstant. Die gemessenen Temperaturwerte des Experiments werden aber im Batteriesystemmodell berücksichtigt. Zum Schluss erfolgt die Auswertung der Schätzfehler, welche sich aus der Differenz der geschätzten Zustandsgrößen \hat{x} zu den aus dem Modell ermittelten Referenzzuständen x bildet.

Beim Einsatz von Kalman-Filtern zur Zustands- und Parameterschätzung stellt sich die Frage, auf welche Art und Weise deren Güte bewertet werden kann. Insbesondere, wenn in den Kapiteln 4.4, 5 und 6.2 die Auswirkungen von Modifikationen der Filter oder deren Anregung systematisch untersucht werden, ist ein Verfahren zur Beurteilung der Schätzung notwendig.

Campestrini et al. [209] stellen in ihrer Arbeit eine sehr umfassende Methodik zur Bewertung von SOC-Schätzern vor. Neben der Schätzgenauigkeit, welche basierend auf dem Zeitanteil bestimmt wird, während derer die Schätzung innerhalb bestimmter Fehlergrenzen liegt, wird ein Wegdriften der Schätzung, die finale Abweichung und das Einschwingverhalten bewertet. Zusätzlich wird auch die Robustheit gegenüber Sensor- oder Modellfehlern untersucht. Die Autoren diskutieren ebenfalls die Problematik, dass bei realen Experimenten auch die Referenzsensorik mit Fehlern behaftet sein kann, sodass der tatsächliche Ladezustand der untersuchten Batteriezelle nicht sicher bekannt ist. In der Veröffentlichung werden die untersuchten Algorithmen bezüglich jedes Bewertungskriteriums mit einem Zahlenwert zwischen 0 (schlecht) und 5 (sehr gut) bewertet. Die Festlegung dieser Bewertungsklassen ist allerdings beliebig, weswegen sie nicht im Rahmen dieser Arbeit verwendet werden. Stattdessen wird die folgende Methodik, welche sich auf wenige Fehlermaße beschränkt, angewendet, um die Filtergüte zu bewerten:

Die Genauigkeit der Schätzung eines Zustands oder Parameters wird basierend auf dem RMSE bewertet. Dieser ist für K Iterationen des Zustandsschätzers für den Zustand/Parameter x definiert als

$$\text{RMSE}_x = \sqrt{\frac{1}{K} \cdot \sum_{k=1}^K (x_k - \hat{x}_{k|k})^2}. \quad (4.21)$$

Dieses Fehlermaß berücksichtigt Abweichungen über die gesamte Dauer der Schätzung. Daher beeinflusst sowohl das Einschwingverhalten zu Beginn als auch die stationäre Genauigkeit über den weiteren Verlauf den RMSE. Da durch das Quadrieren des Schätzfehlers große Abweichungen stärker gewichtet werden als kleine, steigt das Fehlermaß, wenn der Schätzwert stärker um den wahren Wert rauscht. Der RMSE einer Größe hat die gleiche Einheit wie der Zustand bzw. Parameter selbst. Wird der RMSE bezüglich des Mittelwerts von $|x|$ normiert, ergibt sich der Relative-Root-Mean-Squared-Error (RRMSE) zu

$$\text{RRMSE}_x = \frac{\sqrt{\frac{1}{K} \cdot \sum_{k=1}^K (x_k - \hat{x}_{k|K})^2}}{\frac{1}{K} \cdot \sum_{k=1}^K |x_k|}. \quad (4.22)$$

Der RRMSE ist einheitenlos oder wird in Prozent angegeben. Durch ihn können Schätzungen unterschiedlicher Größenordnung miteinander verglichen werden. Insbesondere kann der Mittelwert der RRMSEs aller Zustände und Parameter genutzt werden, um die Gesamtgenauigkeit der Schätzung zu bewerten.

Die Güte der Filter bemisst sich darüber hinaus auch an der Fähigkeit, mit fehlerhaften Startwerten umzugehen. Deshalb wird der initiale Zustandsvektor $\hat{x}_{0|0}$ mit einem zufälligen Fehler beaufschlagt. Dieser Fehler wird als stochastisches Rauschen mit der Normalverteilung $\mathcal{N}(0, \mathbf{P}_{0|0})$ initialisiert. Es wird $\hat{\mathbf{P}}_{0|0} = \text{diag}\{2,5 \cdot 10^{-3} \ 1 \cdot 10^{-4} \ 1 \cdot 10^{-4} \ 1 \cdot 10^{-6} \ 1 \cdot 10^{-8} \ 1 \cdot 10^{-6}\}$ gewählt, sodass die Schätzwerte zum Zeitpunkt $k = 0$ mit einer Wahrscheinlichkeit von 99,7% um höchstens circa $\pm 15\%$ vom wahren Startwert abweichen. Zu beachten ist, dass die Überspannungen, welche üblicherweise mit einem Wert von 0 mV initialisiert werden, ebenfalls einem zufälligen Anfangsfehler unterliegen. Das Einschwingverhalten der Zustands- und Parameterschätzung kann abhängig vom initialen Schätzfehler und dem künstlichen Sensorrauschen stark variieren. Im schlimmsten Fall kann die Schätzung komplett fehlschlagen, wenn der Fehler zu Beginn zu groß ist. Um diesen Zufallsfaktor in der Bewertung der Filtergüte zu minimieren, kann die Validierung der Zustands-

schätzung mehrfach wiederholt werden, wobei die Startwerte und das künstliche Sensorrauschen stochastische Zufallsgrößen sind und daher in jedem Durchlauf variiert werden. Man spricht dann von **Monte-Carlo-Simulationen**. Am Ende kann als Fehlermaß der Mittelwert des RMSEs bzw. RRMSEs der Monte-Carlo-Simulationen ermittelt werden.

Neben den resultierenden Fehlern eines Schätzers wird auch die **Konsistenz** der Schätzung als Maß für die Optimalität bewertet. Nach Bar-Shalom et al. [190, S. 232 ff.] ist ein Filter für ein dynamisches System konsistent, wenn die Momente des Schätzfehlers bis zur zweiten Ordnung mit den aus der Filtertheorie angenommenen Werten übereinstimmen. Das heißt, die Schätzfehler sollen erwartungstreu sein und eine Wahrscheinlichkeitsverteilung aufweisen, welche den vom Filter bestimmten Kovarianzen der Schätzung entspricht. Es gilt dann

$$\mathbb{E} \{ \mathbf{x}_k - \hat{\mathbf{x}}_{k|k} \} = 0 \quad (4.23a)$$

$$\mathbb{E} \{ (\mathbf{x}_k - \hat{\mathbf{x}}_{k|k})(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k})^T \} = \hat{\mathbf{P}}_{k|k}. \quad (4.23b)$$

Eine nicht-optimale Schätzung gilt als zu *optimistisch*, wenn die Kovarianz der Schätzunsicherheit im Vergleich zu den tatsächlichen Schätzfehlern zu klein ist, das Filter der Schätzung demnach zu sehr vertraut. Dahingegen ist ein Filter *pessimistisch*, wenn die Schätzunsicherheit zu groß ist. Zur Prüfung der Konsistenz können verschiedene statistische Hypothesen-Tests durchgeführt werden.

Der normierte quadratische Schätzfehler (engl. *normalized estimation error squared*, NEES) ist

$$\epsilon_k = (\mathbf{x}_k - \hat{\mathbf{x}}_{k|k})^T \hat{\mathbf{P}}_{k|k}^{-1} (\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}). \quad (4.24)$$

Wenn das Kalman-Filter konsistent ist, so ist ϵ_k Chi-Quadrat-verteilt mit dem Freiheitsgrad n , welcher der Dimension des Zustandsraums entspricht. Dann gilt

$$\mathbb{E} \{ \epsilon_k \} = n \quad (4.25)$$

und (4.25) kann als Kriterium herangezogen werden, um die Konsistenz des Filters zu bewerten.

Eine Überprüfung wird anhand N_{MC} Monte-Carlo-Durchläufen der Schätzung mit variierenden Startwerten und stochastischem Messrauschen durchgeführt. Es ergeben sich für jeden Zeitschritt N_{MC} unabhängige Stichproben der Zufallsgröße ϵ_k . Mittels des Chi-Quadrat-Tests [190, S. 72 ff.] (siehe Anhang C.3) kann nun die Hypothese \mathcal{H}_0 überprüft werden, dass die Schätzfehler mit der berechneten Kovarianzmatrix genau dann konsistent sind, wenn

$$\bar{\epsilon}_k \in [r_1, r_2] \quad \text{mit} \quad \bar{\epsilon}_k = \frac{1}{N_{MC}} \cdot \sum_{m=1}^{N_{MC}} \epsilon_{k,m}. \quad (4.26)$$

Der zweite Index von ϵ bezeichnet hierbei den m -ten Monte-Carlo-Durchlauf. Das zweiseitige Akzeptanzintervall $[r_1, r_2]$ wird so gewählt, dass

$$p(\bar{\epsilon}_k \in [r_1, r_2] | \mathcal{H}_0) = 1 - \alpha. \quad (4.27)$$

Das Signifikanzniveau sei $\alpha = 0,05$. Liegt also $\bar{\epsilon}$ zu 95% der Zeitpunkte innerhalb des Akzeptanzintervalls, gilt die Schätzung als konsistent. Es ist zu beachten, dass der NEES-Test zunächst

nur simulativ durchgeführt werden kann, da in aller Regel die wahren Systemzustände \mathbf{x}_k nicht bekannt sind. Daher werden zwei weitere Kriterien zur Bewertung der Konsistenz vorgestellt.

Auch die Innovationssequenz $e_k = y_k - h(\hat{\mathbf{x}}_{k|k-1}, u_k)$ eines konsistenten Schätzers soll mittelwertfrei sein. Weiterhin muss für die Kovarianz der Innovation gelten, dass

$$\text{Var} \{e_k\} = \text{Var} \{y_k - h(\hat{\mathbf{x}}_{k|k-1}, u_k)\} \quad (4.28a)$$

$$= \text{Var} \{y_k\} + \mathbf{C}_k \text{Var} \{\mathbf{x}_{k|k-1}\} \mathbf{C}_k^T \quad (4.28b)$$

$$= \mathbf{R} + \mathbf{C}_k \hat{\mathbf{P}}_{k|k-1} \mathbf{C}_k^T \quad (4.28c)$$

$$= \mathbf{S}_k. \quad (4.28d)$$

Damit muss auch die normierte quadratische Innovationssequenz (engl. *normalized innovation squared*, NIS)

$$\delta_k = e_k^T \mathbf{S}_k^{-1} e_k \quad (4.29)$$

Chi-Quadrat-verteilt sein mit dem Freiheitsgrad p (Anzahl an Systemeingängen, hier: $p = 1$). Diese Bedingung lässt sich ebenfalls über N_{MC} Durchläufe mit dem Chi-Quadrat-Test überprüfen, indem der Mittelwert über den Stichprobenumfang gebildet wird.

$$\bar{\delta}_k = \frac{1}{N_{\text{MC}}} \cdot \sum_{m=1}^{N_{\text{MC}}} \delta_{k,m} \quad (4.30)$$

Schließlich kann über die Autokorrelation überprüft werden, ob es sich bei der Innovationssequenz um weißes Rauschen handelt.

$$\rho_{k,j}^l = \frac{\sum_{m=1}^{N_{\text{MC}}} e_{k,m}^l e_{j,m}^l}{\sqrt{\sum_{m=1}^{N_{\text{MC}}} (e_{k,m}^l)^2 \cdot \sum_{m=1}^{N_{\text{MC}}} (e_{j,m}^l)^2}} \quad \text{für } l = 1, \dots, p \quad (4.31)$$

Das Superskript l bezeichnet für $p > 1$ die Zeile innerhalb der Innovation. Ist die Annahme eines weißen Rauschens erfüllt, so muss $\rho_{k,j}^l$ für $k \neq j$ eine Normalverteilung mit dem Mittelwert 0 und der Varianz $1/N$ sein. Es lässt sich daher ein Konfidenzintervall ermitteln, innerhalb dessen $\rho_{k \neq j}^l$ liegen müssen. Dieses kann beispielsweise der dreifache Standardfehler (engl. *standard error*, SE) in positiver und negativer Richtung sein, wobei der SE definiert ist als

$$\text{SE} = \sqrt{\frac{1}{K}} \quad (4.32)$$

unter der Annahme, dass die Innovationssequenz zufällig ist.

Das NIS-Kriterium und die Autokorrelation lassen sich auch anwenden, indem die Berechnung nicht über die Stichproben der Monte-Carlo-Durchläufe, sondern über den Zeitverlauf erfolgt. Dieses Vorgehen ist gültig, weil die Innovationssequenz ergodisch ist. Für die NIS ergibt sich dann für einen Durchlauf der Schätzung der Länge K

$$\bar{\delta}_k = \frac{1}{K} \cdot \sum_{k=1}^K e_k^T \mathbf{S}_k^{-1} e_k \quad (4.33)$$

und die Autokorrelation wird bestimmt zu

$$\rho_j^l = \frac{\sum_{k=1}^K e_k^l e_{k+j,n}^l}{\sqrt{\sum_{k=1}^k (e_{k,n}^l)^2 \cdot \sum_{k=1}^K (e_{k+j,n}^l)^2}} \quad \text{für } l = 1, \dots, Nu, \quad (4.34)$$

wobei sich gemäß dem zentralen Grenzwertsatz für ein ausreichend großes K ein Mittelwert 0 und die Varianz $1/K$ ergibt, sofern der Schätzer konsistent ist. Die drei vorgestellten Kriterien können auch zur Parametrierung des Kalman-Filters herangezogen werden, wie in Kapitel 4.3 beschrieben wird.

4.2 Untersuchung der Beobachtbarkeit

Als wichtige Voraussetzung für den Einsatz eines Kalman-Filters (oder allgemein eines Beobachters) zur Zustands- und Parameterschätzung gilt der Nachweis der Beobachtbarkeit aller Zustände. Mit Zuständen sind hier und im Folgenden alle Größen des Zustandsvektors (Systemzustände und geschätzte Modellparameter) gemeint. In der Regel sind nicht alle Zustände eines zu beobachtenden Systems direkt messbar – dies ist auch in der hier betrachteten Anwendung der Fall. Der SOC, die Überspannungen und auch die Parameter des Ersatzschaltbildmodells haben nur indirekt Einfluss auf die messbare Klemmenspannung u_{zelle} , welche der Messung y des Kalman-Filters entspricht.

Nach Lunze heißt ein System **vollständig beobachtbar**, wenn aus dem Verlauf von Eingang u und Ausgang y über ein endliches Zeitintervall der Anfangszustand des Systems \mathbf{x}_0 ermittelt werden kann [189, S. 91-115]. Gilt diese Bedingung nur für einen eingeschränkten Unterraum des Zustandsraums, ist das System beobachtbar, jedoch nicht vollständig. Adamy [210, S. 525-538] verwendet den Begriff schwache Beobachtbarkeit für nicht vollständig beobachtbare Systeme. Dabei muss der Eingang u bis zur $(n-1)$ -ten Ableitung bekannt sein.

Im Folgenden wird das in Kapitel 3.1.2 vorgestellte Ersatzschaltbildmodell einer Lithium-Ionen-Zelle hinsichtlich seiner Beobachtbarkeit untersucht. Dabei kann die Dimension des Zustandsvektors variieren, je nachdem wie viele und welche Parameter in die Schätzung einbezogen werden sollen. Die untersuchten Ordnungen der Modelle mit den entsprechenden Zustandsvektoren sind in Tabelle 4.4 dargestellt. Durch den Zusammenhang $\tau_j = R_j C_j$ der Parameter der RC-Glieder, ließen sich in Tabelle 4.4 die Zeitkonstanten auch durch die Kapazitäten als zu schätzende Parameter ersetzen. Je mehr Modellparameter der Zustandsvektor umfasst, desto stärker ist die Adaptivität des resultierenden Schätzers gegenüber einer Veränderung des Systemverhaltens ausgeprägt. Erhöht sich beispielsweise aufgrund von Alterung der Ohmsche Innenwiderstand, verschlechtert sich die Genauigkeit des Modells für den Fall, dass R_0 keine Schätzgröße ist ($n = 3$). Für $n > 3$ dagegen wird die Vergrößerung von R_0 vom Filter adaptiert und die Modellgüte bleibt erhalten.

Die Analyse der Beobachtbarkeit wird in der Literatur zu Schätzverfahren in BMSs häufig vernachlässigt (siehe beispielsweise [102, 163, 179, 202, 207, 208]), wenn auch Ausnahmen existieren. In [211] wird für ein Modell der Ordnung $n = 3$ die Beobachtbarkeit gezeigt unter der Bedingung, dass mindestens eine Ableitung der OCV-Funktion ungleich null ist. Weiterhin

Tabelle 4.4: Modellordnungen und die zugehörigen Zustandsvektoren eines Zustandsschätzers.

Modellordnung	Zustandsvektor	Linearität
$n = 3$	$\mathbf{x} = [\text{SOC } u_1 \ u_2]^T$	ja ¹
$n = 4$	$\mathbf{x} = [\text{SOC } u_1 \ u_2 \ R_0]^T$	nein
$n = 6$	$\mathbf{x} = [\text{SOC } u_1 \ u_2 \ R_0 \ R_1 \ R_2]^T$	nein
$n = 8$	$\mathbf{x} = [\text{SOC } u_1 \ u_2 \ R_0 \ R_1 \ R_2 \ \tau_1 \ \tau_2]^T$	nein

¹Wie bereits in Kapitel 3.1 beschrieben, muss das erste Element der Ausgangsmatrix \mathbf{C} abhängig vom SOC zu jedem Zeitschritt aktualisiert werden. Ansonsten ist das Modell jedoch linear.

wird der Zustandsvektor um einen Bias des Strom- bzw. Spannungssensors ergänzt. Hier ist die Beobachtbarkeit immer dann gegeben, wenn die zweite oder eine höhere Ableitung der OCV-Kurve ungleich null ist. Wassiliadis et al. [182] kommen für das von ihnen eingesetzte DKF zu dem Schluss, dass ein analytischer Nachweis der Beobachtbarkeit nicht praktikabel ist. Daher beurteilen sie die Ergebnisse des Filters mit aus Simulationen gewonnenen Referenzdaten und sehen eine schlechte Schätzperformanz als Indiz für schlechte Beobachtbarkeit. Meng et al. [212] untersuchen ein Modell der Ordnung $n = 8$ auf seine Beobachtbarkeit, indem sie das Modell in zwei Submodelle unterteilen. Die Autoren stellen fest, dass der Betrag des Eingangs u einen Einfluss auf die Beobachtbarkeit des Systems hat. Die Arbeit baut auf der Untersuchung von Shi et al. [213] auf, in der die Beobachtbarkeit des linearen Teils des Modells gezeigt wird. Auch hier gelten Anforderungen an die Dynamik des Systemeingangs.

4.2.1 Strukturelle Beobachtbarkeit

Als notwendige Bedingung an die Beobachtbarkeit eines Systems kann die **strukturelle Beobachtbarkeit** im Zustandsraum geprüft werden. Als erstes Kriterium dafür muss nach Lunze [189, S. 116-135] sichergestellt werden, dass alle Systemzustände ausgangsv Verbunden sind. Dazu kann ein Strukturgraph, wie in Abb. 4.7 dargestellt, verwendet werden. Die Knoten des Graphen sind der Ein- und Ausgang des Systems, sowie alle Zustände. Durch gerichtete Kanten von Knoten x_i zum Knoten x_j wird ausgedrückt, dass der Systemzustand bzw. Ausgang x_j zum Zeitschritt $k + 1$ vom Zustand bzw. Eingang x_i des vorherigen Zeitschritts k abhängt. Damit ein Zustand als ausgangsv Verbunden gelten kann, muss es einen Pfad geben, der vom betreffenden Zustand zum Systemausgang y führt. Dies leuchtet intuitiv ein, denn Zustände, welche keinerlei Einfluss auf den Systemausgang haben, können aus diesem auch nicht rekonstruiert werden.

Dem Strukturgraphen in Abb. 4.7 ist zu entnehmen, dass bei dem in dieser Arbeit betrachteten Batteriemodell alle Zustände ausgangsv Verbunden sind. Gleichzeitig ist jedoch schon ersichtlich, dass die Zustände R_1 , R_2 , τ_1 und τ_2 nur indirekt durch die Überspannungen u_1 und u_2 mit dem Ausgang verbunden sind. Daraus lässt sich schließen, dass diese Zustände nur solange beobachtbar bleiben, wie die Überspannungen ungleich null sind. Dies ist nicht mehr der Fall, wenn der Systemeingang die RC-Glieder für längere Zeit nicht anregt.

Als weitere Bedingung an die strukturelle Beobachtbarkeit muss die strukturelle Beobachtungsmatrix den Rang n aufweisen [189, S. 116-135]. Diese Matrix ergibt sich auf Basis der strukturellen

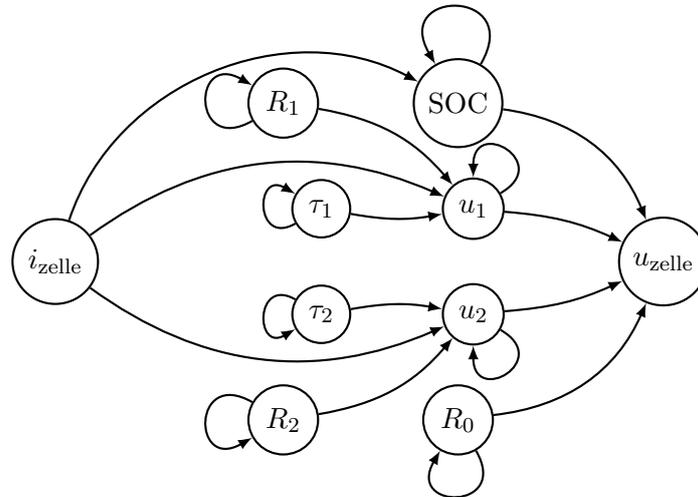


Abbildung 4.7: Strukturgraph des Batterie-Ersatzschaltbildmodells für $n = 8$.

Systemmatrix \mathbf{A}_s und Ausgangsmatrix \mathbf{C}_s , welche aus den Systemgleichungen bestimmt werden können. Für jeden Eintrag, der ungleich null ist, wird dessen Wert durch ein * ersetzt, ansonsten ist der Wert null. Die strukturelle Beobachtungsmatrix ist

$$\mathcal{O}_S = \begin{bmatrix} \mathbf{A}_s \\ \mathbf{C}_s \end{bmatrix}. \quad (4.35)$$

Für das lineare Modell ($n = 3$) lassen sich die Matrizen bestimmen zu

$$\mathbf{A}_s = \begin{bmatrix} * & 0 & 0 \\ 0 & * & 0 \\ 0 & 0 & * \end{bmatrix}, \quad \mathbf{C}_s = \begin{bmatrix} * & * & * \end{bmatrix} \quad (4.36)$$

und die strukturelle Beobachtungsmatrix ist

$$\mathcal{O}_S = \begin{bmatrix} * & 0 & 0 \\ 0 & * & 0 \\ 0 & 0 & * \\ * & * & * \end{bmatrix}, \quad \text{rank} \{ \mathcal{O}_S \} = 3. \quad (4.37)$$

Um die strukturelle Beobachtbarkeit nichtlinearer Systeme zu prüfen, müssen diese um einen Arbeitspunkt herum linearisiert werden [214]. Im Folgenden werden jedoch andere Verfahren für die Überprüfung deren Beobachtbarkeit vorgeschlagen, sodass an dieser Stelle auf eine Prüfung der nicht-linearen Beobachtbarkeit für $n > 3$ verzichtet wird.

4.2.2 Beobachtbarkeitskriterium von Kalman

Das von Rudolph Kálmán vorgeschlagene Kriterium zur Untersuchung der Beobachtbarkeit ist das für lineare Systeme am häufigsten verwendete. Es untersucht die Systemmatrix \mathbf{A} und die Ausgangsmatrix \mathbf{C} , um die Sichtbarkeit und Separierbarkeit der einzelnen Zustände im Messausgang nachzuweisen. Doch auch für den nichtlinearen Fall kann das Kriterium eingesetzt werden [189, S. 93 f.].

Für den linearen Fall ist das Verfahren der Prüfung der strukturellen Beobachtbarkeit aus dem vorherigen Abschnitt ähnlich. Für ein System der Ordnung n lässt sich die Beobachtbarkeitsmatrix \mathcal{O}_B

$$\mathcal{O}_B = \begin{bmatrix} \mathbf{C} \\ \mathbf{C}\mathbf{A} \\ \mathbf{C}\mathbf{A}^2 \\ \vdots \\ \mathbf{C}\mathbf{A}^{n-1} \end{bmatrix} \quad (4.38)$$

aufstellen. Das System ist genau in solchen Fällen vollständig beobachtbar, wenn die Beobachtbarkeitsmatrix den Rang n hat.

$$\text{rank} \{ \mathcal{O}_B \} \stackrel{!}{=} n \quad (4.39)$$

Für das lineare System mit $n = 3$ lässt sich somit leicht die Beobachtbarkeit nachweisen, wenn $\tau_1 \neq \tau_2$ gilt, weil dann

$$\mathcal{O}_B = \begin{bmatrix} \frac{u_{OC}(\text{SOC})}{\text{SOC}} & 1 & 1 \\ 0 & -\frac{1}{\tau_1} & -\frac{1}{\tau_2} \\ 0 & \frac{1}{\tau_1^2} & \frac{1}{\tau_2^2} \end{bmatrix} \quad \text{rank} \{ \mathcal{O}_B \} = 3. \quad (4.40)$$

Nach Zhao et al. [211] ist es ein übliches Vorgehen zur Beurteilung der Beobachtbarkeit nichtlinearer Systeme, diese um einen Arbeitspunkt herum zu linearisieren und die Beobachtbarkeit dieses Systems zu überprüfen. Wie die Autoren allerdings festhalten, ist die Beobachtbarkeit des linearisierten Systems keine notwendige Bedingung für die Beobachtbarkeit des nichtlinearen Systems, sodass dieses beobachtbar sein kann, auch wenn dies nicht für das am Arbeitspunkt linearisierte System gilt. Zur Erweiterung des Kalman-Kriteriums für die Beobachtbarkeit autonomer¹ nichtlinearer Systeme kann stattdessen nach Adamy [210, S. 525-540] die Lie-Derivierte

$$\mathbf{L}_f h(\mathbf{x}) = \frac{\partial h(\mathbf{x})}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}) \quad (4.41)$$

und die mehrfache Lie-Derivierte

$$\mathbf{L}_f^k h(\mathbf{x}) = \frac{\partial \mathbf{L}_f^{k-1} h(\mathbf{x})}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}) \quad (4.42)$$

verwendet werden, um die Beobachtbarkeit zu untersuchen. Hierzu werden die Lie-Derivierten 1 bis $n-1$ in einem Zeilenvektor $\mathbf{q}(\mathbf{x})$ zusammengefasst und nach \mathbf{x} abgeleitet. Die nullte

¹Ein System heißt *autonom*, wenn es keinen Systemeingang besitzt.

Lie-Derivierte entspricht der Messgleichung $h(\mathbf{x})$. Die resultierende Matrix muss den Rang n besitzen.

$$\text{rank} \left\{ \frac{\partial \mathbf{q}(\mathbf{x})}{\partial \mathbf{x}} \right\} = \text{rank} \left\{ \begin{bmatrix} \frac{\partial L_f^0 h(\mathbf{x})}{\partial \mathbf{x}} \\ \frac{\partial L_f^1 h(\mathbf{x})}{\partial \mathbf{x}} \\ \vdots \\ \frac{\partial L_f^{n-1} h(\mathbf{x})}{\partial \mathbf{x}} \end{bmatrix} \right\} \stackrel{!}{=} n \quad (4.43)$$

Die Beobachtbarkeitsmatrix des linearen Systems kann als Spezialfall der nichtlinearen Beobachtbarkeitsmatrix angesehen werden. Zusätzlich soll nun auch der Systemeingang u berücksichtigt werden. Hierzu müssen für die Messgleichung $y = h(\mathbf{x}, u)$ die $n-1$ totalen Ableitungen ermittelt werden

$$\dot{y} = \frac{\partial h(\mathbf{x}, u)}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}, u) + \frac{\partial h(\mathbf{x}, u)}{\partial u} \dot{u} \quad (4.44a)$$

$$\ddot{y} = \frac{\partial \dot{y}}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}, u) + \frac{\partial \dot{y}}{\partial u} \dot{u} + \frac{\partial \dot{y}}{\partial \dot{u}} \ddot{u} \quad (4.44b)$$

⋮

$$y^{(n-1)} = \frac{\partial y^{(n-2)}}{\partial \mathbf{x}} \mathbf{f}(\mathbf{x}, u) + \sum_{i=1}^{n-1} \frac{\partial y^{(n-2)}}{\partial u^{(i-1)}} u^{(i)} \quad (4.44c)$$

und in einem Vektor zusammengefasst werden

$$\text{rank} \left\{ \frac{\partial \mathbf{q}(\mathbf{x}, u, \dot{u}, \dots, u^{(n-1)})}{\partial \mathbf{x}} \right\} = \text{rank} \left\{ \begin{bmatrix} \frac{\partial y(\mathbf{x}, u, \dot{u})}{\partial \mathbf{x}} \\ \frac{\partial \dot{y}(\mathbf{x}, u, \dot{u}, \ddot{u})}{\partial \mathbf{x}} \\ \vdots \\ \frac{\partial y^{(n-1)}(\mathbf{x}, u, \dot{u}, \dots, u^{(n-1)})}{\partial \mathbf{x}} \end{bmatrix} \right\} \stackrel{!}{=} n, \quad (4.45)$$

dessen Rang wiederum geprüft werden muss. Für den nichtlinearen Fall ist die Beobachtbarkeit nun nicht mehr unabhängig vom Systemeingang [210, S. 528-531]. Stattdessen bestimmen u und dessen Ableitungen maßgeblich, welchen Rang die Beobachtbarkeitsmatrix hat. Weiterhin ist auch die Gestalt der OCV-Kurve für die Beobachtbarkeit wichtig. Eigene Analysen zeigen, dass schon die zweite Ableitung dieser Funktion über einen weiten SOC-Bereich nahezu null ist. Diese Annahme liegt der folgenden Untersuchung zugrunde und es kann als erste notwendige Bedingung für die Beobachtbarkeit des nichtlinearen ECM [211] formuliert werden, dass

$$\frac{\partial u_{\text{OC}}}{\partial \text{SOC}} \stackrel{!}{\neq} 0. \quad (4.46)$$

Andernfalls wird der erste Eintrag der ersten Zeile von $\partial \mathbf{q} / \partial \mathbf{x}$ null und die Matrix verliert einen Rang. Für die im Rahmen dieser Arbeit verwendeten Lithium-Ionen-Zellen mit NMC-Kathoden kann (4.46) für den gesamten SOC-Bereich als erfüllt angesehen werden. Herausfordernder ist die Zustandsschätzung von Lithium-Ionen-Zellen mit LFP-Chemie, welche sich durch einen sehr flachen Verlauf der OCV-Kurve bei mittleren Ladezuständen auszeichnet. Abb. 4.8 zeigt den Rang der Beobachtungsmatrix für die verschiedenen Modellordnungen. Die Ableitungen vom Systemeingang u von der j -ten Ableitung beginnend bis zur $n-1$ -ten Ableitung werden dabei auf null gesetzt. Der Wert j entspricht der Abszisse. Erwartungsgemäß ist der Rang der

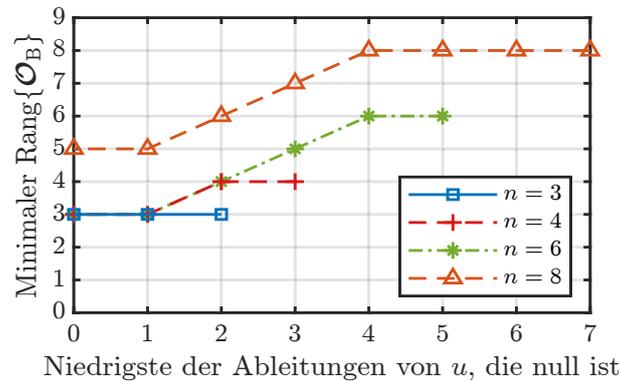


Abbildung 4.8: Rang der Beobachtbarkeitsmatrix für kontinuierliche Ersatzschaltbildmodelle unterschiedlicher Ordnung. Die Abszisse bezeichnet, welche Ableitungen von u aufsteigend null sind.

Beobachtbarkeitsmatrix für $n = 3$ immer drei und damit das System beobachtbar. Dahingegen ist das System für $n = 4$ nur in den Fällen beobachtbar, in denen noch mindestens die erste Ableitung von u einen von null abweichenden Wert aufweist. Für $n = 6$ und $n = 8$ muss auch die zweite und dritte Ableitung des Systemeingangs ungleich null sein, damit die Beobachtbarkeitsmatrix vollen Rang hat. Mit wachsender Modellordnung steigt demnach die Anforderung an die Dynamik des Systemeingangs, um die einzelnen Systemzustände im Messausgang zu separieren. Nur wenn auch diese zweite Bedingung erfüllt ist, ist das System beobachtbar.

Die Beobachtbarkeit zeitdiskreter Systeme setzt als notwendig voraus, dass das kontinuierliche System beobachtbar ist. Im linearen Fall lässt sich die Beobachtbarkeit mit dem Kriterium von Kalman analog zum kontinuierlichen Fall durchführen, wobei die diskretisierten Systemmatrizen zu verwenden sind. Als zusätzliche Bedingung muss geprüft werden, dass immer zwei beliebige Eigenwerte λ_i, λ_j der Systemmatrix die folgende Ungleichung erfüllen [189, S. 474-486]:

$$e^{\lambda_i t_s} \neq e^{\lambda_j t_s}. \quad (4.47)$$

Für den nichtlinearen Fall wird die Beobachtbarkeitsmatrix gemäß

$$\text{rank} \{ \mathcal{O}_B \} = \text{rank} \left\{ \begin{bmatrix} \frac{\partial y_1}{\partial \mathbf{x}} \\ \frac{\partial y_2}{\partial \mathbf{x}} \\ \vdots \\ \frac{\partial y_n}{\partial \mathbf{x}} \end{bmatrix} \right\} \stackrel{!}{=} n \quad (4.48)$$

aufgestellt, wobei y_1 bis y_n ähnlich dem kontinuierlichen Fall aus einer Verkettung von System- und Messfunktion gewonnen werden können. Der Operator $f \circ g$ bezeichnet die Verkettung $f(g(x))$. Zusätzlich wird die abkürzende Schreibweise $\mathbf{f}_{u_k}(\cdot) = \mathbf{f}(\cdot, u_k)$ verwendet [215, 216].

$$y_1 = h(\mathbf{x}_k, u_k) \quad (4.49a)$$

$$y_n = h(\mathbf{f}_{u_{k+n-2}} \circ \dots \circ \mathbf{f}_{u_{k-1}}(\mathbf{x}_{k-1})) \quad (4.49b)$$

Wie im vorangegangenen Abschnitt sei Bedingung (4.46) gültig. Der Rang von \mathcal{O}_B kann dann für verschiedene Modellordnungen bestimmt werden. Dabei wird von den Stromwerten u_k bis u_{k+n-1}

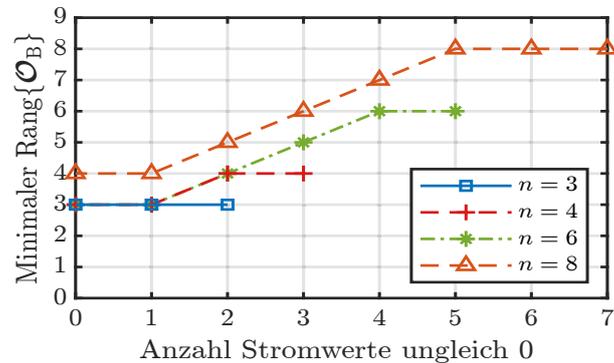


Abbildung 4.9: Rang der Beobachtbarkeitsmatrix für diskrete Ersatzschaltbildmodelle unterschiedlicher Ordnung. Die Abszisse bezeichnet, wie viele Stromwerte von u_k bis u_{k+n} ungleich null sind.

eine veränderliche Anzahl an Elementen auf null gesetzt. Es können sich daraus unterschiedliche Ränge für \mathcal{O}_B ergeben, von Interesse ist aber immer der minimale Rang im Sinne einer Worst-Case-Betrachtung. Die Ergebnisse dieser Untersuchung sind in Abb. 4.9 dargestellt. Wie zu sehen ist, ähneln die Ergebnisse der Betrachtung des kontinuierlichen Systems. Das lineare Modell ist beobachtbar, auch wenn keine Anregung erfolgt. Für $n = 4$ dürfen zwei der vier berücksichtigten Strommessungen null sein. Dieser Wert beträgt für $n = 6$ vier und für $n = 8$ fünf. Ist neben (4.46) diese zweite Bedingung erfüllt, kann die Beobachtbarkeit nach dem Kriterium von Kalman als erfüllt angesehen werden.

4.2.3 Quantifizierung der Beobachtbarkeit durch den Beobachtbarkeitsindex

Das Beobachtbarkeitskriterium von Kalman aus dem vorangegangenen Abschnitt erlaubt zwar eine Aussage darüber, ob alle Systemzustände im Ausgang beobachtbar sind, allerdings können in der Anwendung trotzdem Probleme auftreten, wenn einzelne Zustände nur sehr schwach beobachtbar sind. Als alternatives Vorgehen lässt sich die Beobachtbarkeit mittels Singulärwertzerlegung quantifizieren. Dabei wird ein Beobachtbarkeitsindex ς ermittelt, welcher ein Maß für das Verhältnis der Beobachtbarkeit der verschiedenen Zustände zueinander darstellt. Mithilfe des Beobachtbarkeitsindex wird die Konditionierung der Beobachtbarkeitsmatrix überprüft [217].

Die Singulärwertzerlegung spaltet die Matrix $\mathbf{M} \in \mathbb{C}^{m \times n}$ eindeutig in die zwei orthogonalen Matrizen $\mathbf{U} \in \mathbb{C}^{m \times m}$ und $\mathbf{V} \in \mathbb{C}^{n \times n}$ auf, sowie die reelle Diagonalmatrix $\mathbf{\Sigma} \in \mathbb{R}^{m \times n}$. Diese enthält auf der Hauptdiagonalen die sogenannten Singulärwerte $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_k$ der Matrix \mathbf{M} , während alle anderen Elemente von $\mathbf{\Sigma}$ null sind [218]. Bei der Matrix \mathbf{V}^* handelt es sich um die komplex Konjugierte der Matrix \mathbf{V} , welche für reelle Einträge der Transponierten \mathbf{V}^T entspricht.

$$\mathbf{M} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^* \quad (4.50)$$

Die Anzahl an Singulärwerten auf der Hauptdiagonalen von $\mathbf{\Sigma}$ entspricht dem Rang der Matrix \mathbf{M} . Wird die Singulärwertzerlegung auf die Beobachtbarkeitsmatrix angewandt, so muss es mindestens n Singulärwerte größer null geben, damit das zugehörige System beobachtbar ist. Je größer ein Singulärwert ist, desto besser ist der zugehörige Zustand beobachtbar. Umgekehrt gilt, dass ein

Tabelle 4.5: Werte der Modellparameter für die Berechnung des Beobachtbarkeitsindex. Sie entsprechen den Ergebnissen der Zellcharakterisierung für 25 °C und SOC = 50 %.

Parameter	Wert
R_0	23,6 mΩ
R_1	4,0 mΩ
R_2	12,0 mΩ
τ_1	1 s
τ_2	20 s
t_s	0,1 s

Wert nahe null auf eine schwache Beobachtbarkeit hindeutet. Nakhaeinejad und Bryant [217] definieren die Konditionszahl ζ als Verhältnis zwischen dem größten und kleinsten Singulärwert. Diese Größe wird als **Beobachtbarkeitsindex** bezeichnet.

$$\zeta = \frac{\sigma_{\max}}{\sigma_{\min}} \quad (4.51)$$

Ein großer Wert für ζ zeigt eine schlechte Beobachtbarkeit an. Ein Systemzustand dominiert in diesem Fall den Messausgang, andere Zustände haben nur einen schwachen Einfluss. Dahingegen ist ein kleiner Wert von ζ ein Indikator für eine gute Beobachtbarkeit.

Die Beobachtbarkeitsmatrix und damit auch der Beobachtbarkeitsindex hängen vom Arbeitspunkt des Systems ab. Unter der Annahme konstanter Modellparameter (für die im Rahmen der folgenden Betrachtung gewählten Parameter siehe Tabelle 4.5) bestimmt sich der Arbeitspunkt durch den SOC, die Überspannungen u_1 und u_2 , sowie durch den Systemeingang i_{zelle} . Wie bereits in Kapitel 4.2.1 herausgestellt wurde, sind die Parameter der RC-Glieder nicht beobachtbar, wenn die Überspannungen null sind. In der folgenden Untersuchung sei daher angenommen, dass beide Kapazitäten zu zwei Dritteln geladen sind und die Polarisationsspannung u_j des j -ten RC-Glieds demnach $67\% \cdot R_j i_{\text{zelle}}$ betrage. Diese Annahme muss jedoch nur für $n = 8$ getroffen werden, weil nur dann u_1 und u_2 Teil der Beobachtbarkeitsmatrix sind. Es verbleiben als wichtige Einflussfaktoren auf den Beobachtbarkeitsindex der Ladezustand und die Anregung durch den Zellstrom. Beide Größen werden für die folgende Untersuchung systematisch variiert.

Der Quotient $u_{\text{OC}}(\text{SOC})/\text{SOC}$ (der erste Eintrag der Ausgangsmatrix \mathbf{C}) wird in einem Intervall von ± 5 Prozentpunkten (pp.) um den betrachteten Ladezustand durch ein Polynom dritter Ordnung approximiert, damit die Messgleichung differenzierbar ist. Der Anregungsstrom wird zwischen -20 A bis $+20\text{ A}$ variiert. Da jedoch der Einfluss eines über die betrachteten Zeitschritte konstanten Stroms in der Untersuchung nicht betrachtet werden soll, ist i_{zelle} ein stochastisches Rauschen mit einer Standardabweichung von einem Prozent des Nennwerts überlagert. Um einen Einfluss des individuellen Rauschens auszuschließen, ist der ermittelte Beobachtbarkeitsindex der Median aus 100 Monte-Carlo-Simulationen. Die Ergebnisse der Beobachtbarkeitsanalyse sind in Abb. 4.10 zu sehen.

Zunächst lässt sich beobachten, dass der Beobachtbarkeitsindex für $i_{\text{zelle}} \rightarrow 0$ ansteigt und bei $n > 3$ sogar unendlich wird. In diesem Fall ist der Innenwiderstand R_0 nicht mehr beobachtbar.

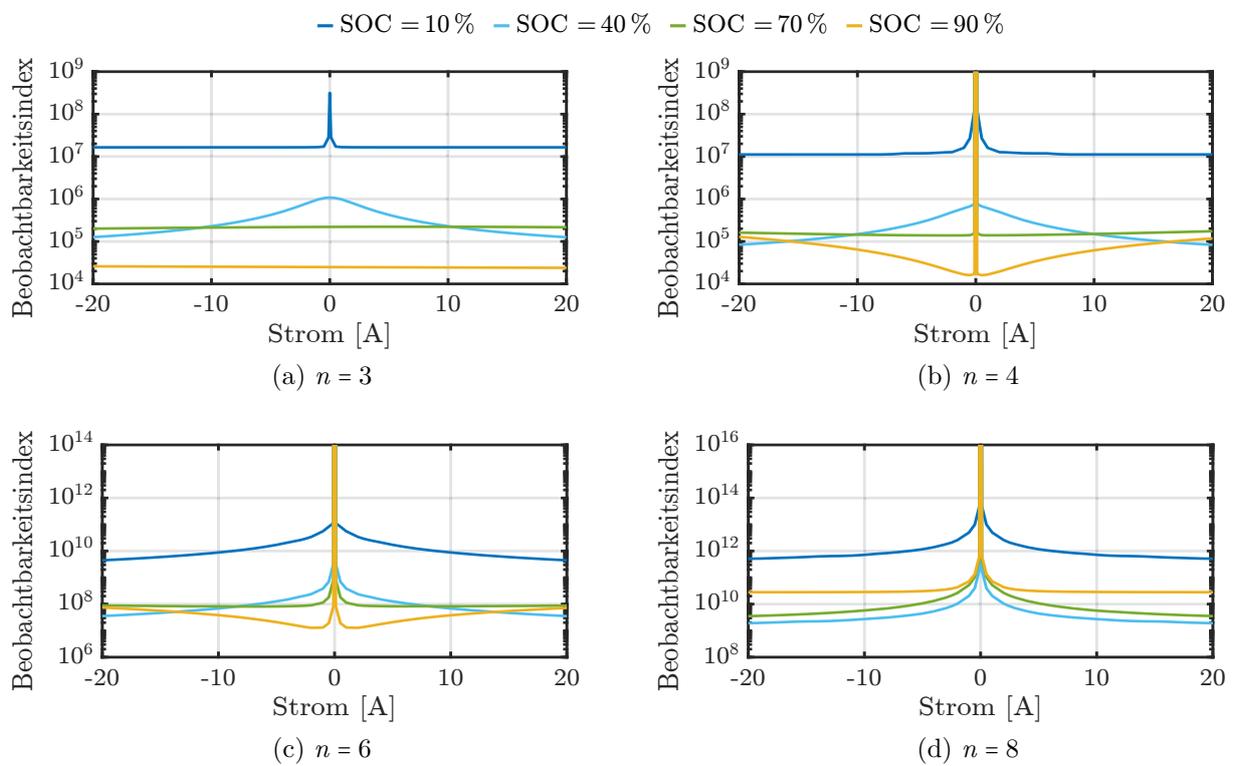


Abbildung 4.10: Verlauf des Beobachtbarkeitsindex ζ für unterschiedliche Modellgrößen in Abhängigkeit vom Anregungsstrom und für verschiedene Ladezustände. Ein kleiner Wert entspricht einer guten Beobachtbarkeit. Für $n > 3$ ist der Wert an der Stelle $i = 0$ abgeschnitten.

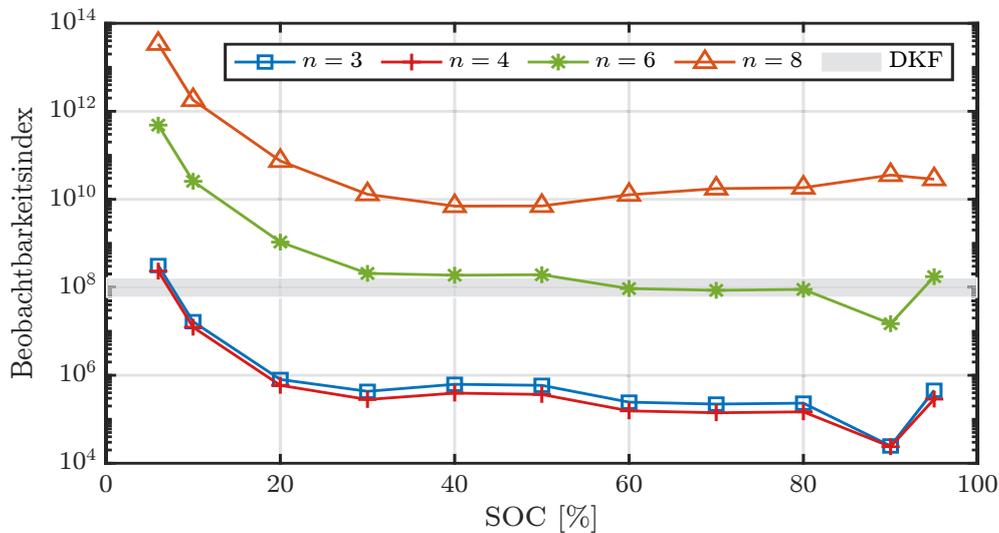


Abbildung 4.11: Beobachtbarkeitsindex ζ abhängig vom Ladezustand für unterschiedliche Modellgrößen bei einem Anregungsstrom von 5 A. Ein kleiner Wert entspricht einer guten Beobachtbarkeit. Die Ergebnisse des DKFs werden im weiteren Verlauf diskutiert.

Weiterhin lässt sich im Vergleich der Modellordnungen erkennen, dass die Beobachtbarkeit deutlich schlechter wird, wenn die Ordnung des Zustandsvektors größer als vier ist. Außerdem hängt der Wert von ζ nur vom Betrag des Anregungssignals ab, die Graphen sind daher spiegelsymmetrisch zur Ordinate. Die Beobachtbarkeit der Modelle mit den Ordnungen 3 und 4 sind sehr ähnlich. Betrachtet man für die einzelnen Modellordnungen verschiedene Ladezustände, lassen sich deutliche Unterschiede feststellen. Das System ist also für unterschiedliche Ladezustände unterschiedlich gut beobachtbar. Insbesondere gilt: Beim kleinsten betrachteten SOC von 10 % ist die Beobachtbarkeit am schlechtesten – der Beobachtbarkeitsindex ist am größten. Die beste Beobachtbarkeit ergibt sich dagegen für hohe Ladezustände bei SOC = 90 %, wenn $n \leq 6$, für $n = 8$ bei SOC = 40 %. Hier hat der Verlauf der OCV-Kurve einen Einfluss auf die Beobachtbarkeit.

Um dieses Verhalten weiter zu untersuchen, sind in Abb. 4.11 die Werte für ζ bei einer festen Höhe des Anregungsstroms von 5 A abhängig vom Ladezustand dargestellt. Dies entspricht einer Stromrate von 2 C. Der Einfluss der Modellordnung auf die Beobachtbarkeit ist wiederum gut zu erkennen. Deutlich zu sehen ist, dass der Beobachtbarkeitsindex für niedrige Ladezustände ansteigt. Erklären lässt sich dieses Verhalten durch einen Blick auf Abb. 3.3. Der SOC-abhängige Wert u_{OC}/SOC entspricht dem ersten Element der Ausgangsmatrix C . Für niedrige Ladezustände wird er sehr groß und dominiert dadurch den Messausgang. Die anderen Zustände sind im Vergleich ungleich schwächer im Ausgangssignal zu sehen, was in einer schlechten Konditionierung der Beobachtbarkeitsmatrix resultiert. Die Konditionszahl ist am besten, wenn die Zustandsgrößen in ähnlicher Gewichtung den Messausgang beeinflussen. Dies ist für mittlere Ladezustände bei circa 50 % der Fall.

Die Beobachtbarkeit eines Systems an verschiedenen Arbeitspunkten zu untersuchen, stößt an Grenzen, wenn die Einflussgrößen – wie hier der Strom und seine Ableitungen, der Ladezustand und die Sättigung der RC-Glieder – zu zahlreich sind. Ein alternatives Vorgehen ist es, die Beobachtbarkeit für jeden Zeitschritt einer Simulationssequenz zu untersuchen. Die betrachteten

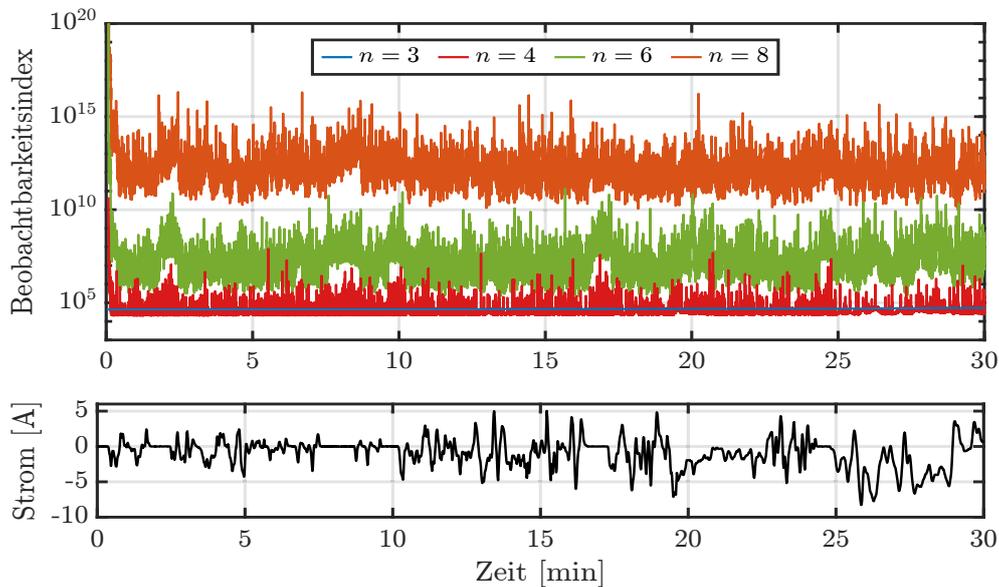


Abbildung 4.12: Beobachtbarkeitsindex ζ für verschiedene Ordnungen n des Systems über den Verlauf eines WLTP-Fahrzyklus und dazugehöriger Zellstrom.

Arbeitspunkte beruhen demnach auf dem Systemzustand zu unterschiedlichen Zeitpunkten, welche sich abhängig vom untersuchten Szenario einstellen. Idealerweise deckt die Simulation einen weiten Bereich des zu untersuchenden Wertebereichs der Parameter und Zustände ab. In Abb. 4.12 ist der Beobachtbarkeitsindex für die unterschiedlichen Modellordnungen dargestellt, wobei die der Simulation zugrunde liegende Anregung auf dem WLTP-Fahrzyklus beruht. Ein Diagramm der Beobachtbarkeit basierend auf dem UDDS-Fahrzyklus findet sich in Anhang E (siehe Abb. E.3). Der Eingangsstrom basiert auf realen Messungen im Rahmen der Zellcharakterisierung aus Kapitel 3.2.3. Der Ladezustand und die Überspannungen der RC-Glieder werden durch ein Zellmodell bestimmt. Basierend auf dem aktuellen Zellzustand zu jedem Zeitpunkt wird dann der Beobachtbarkeitsindex abhängig von der Modellordnung n berechnet. Da ζ stark schwankt und für Phasen ohne Stromanregung beliebig groß werden kann, wird im Folgenden der Median als vergleichendes Maß zwischen den Modellordnungen verwendet, da er gegenüber dem Mittelwert robuster ist.

Für das lineare System mit $n = 3$ ist der Beobachtbarkeitsindex nahezu konstant, da die Beobachtbarkeit nur vom Ladezustand abhängt. Der Median von ζ beträgt $4,6 \cdot 10^4$. Die Beobachtbarkeit für $n = 4$ liegt in derselben Größenordnung – der Median beträgt hier $2,6 \cdot 10^4$. Erhöht sich die Anzahl an Zustandsgrößen, verschlechtert sich die Beobachtbarkeit des Systems deutlich. Für $n = 6$ beträgt der Median des Beobachtbarkeitsindex $7,6 \cdot 10^6$, bei $n = 8$ sogar $9,3 \cdot 10^{11}$. Für den UDDS-Fahrzyklus (siehe Abb. E.3) sind die Werte in der gleichen Größenordnung. Gleichzeitig ist zu erkennen, wie ζ in Phasen geringen Stroms um Größenordnungen ansteigt. Dies geschieht analog zu Entladung der RC-Glieder, wodurch sich deren Parameter nicht mehr beobachten lassen. Erst wenn das System wieder durch einen Strom angeregt wird, verbessert sich die Beobachtbarkeit.

4.2.4 Beobachtbarkeit des Dual-Kalman-Filters

Als effiziente Alternative zur Joint-Estimation, bei denen die Zustände und Parameter in einem großen Zustandsvektor zusammengefasst sind und mit einem Filter geschätzt werden, wurde in Kapitel 4.1.4 das DKF vorgestellt. Da bei diesem Zustände und Parameter auf zwei Kalman-Filter aufgeteilt werden, stellt sich die Frage nach der Beobachtbarkeit dieses zusammengesetzten Systems. Der von Wang et al. [199] vorgeschlagene DKF verwendet für die Schätzung der Systemzustände das Modell der Ordnung $n = 3$. Die Beobachtbarkeit dieses Systems wurde bereits gezeigt. Für das zweite Kalman-Filter soll die Beobachtbarkeit im Folgenden untersucht werden. Dabei werden die Annahmen getroffen: Wenn das Teilsystem 1 beobachtbar ist, können dessen Zustände mit dem ersten Kalman-Filter erwartungstreu geschätzt werden. Damit können diese Größen als Eingang für das zweite Teilsystem dienen. Das zweite Kalman-Filter schätzt die Parameter R_0 , R_1 , R_2 , τ_1 und τ_2 basierend auf dem Eingang $\mathbf{u}_k = [u_{1,k-1} \ u_{2,k-1} \ u_{OC}]^T$ und der Messung $\mathbf{y}_k = [u_{zelle,k} \ u_{1,k} \ u_{2,k}]^T$. Es handelt sich um ein System fünfter Ordnung. Mit der Methode für zeitdiskrete und nichtlineare Systeme (siehe Abschnitt 4.2.2) kann die Beobachtungsmatrix aufgestellt und deren Rang untersucht werden. Aufgrund der größeren Dimension des Messvektors \mathbf{y} reicht es, \mathbf{y}_1 und \mathbf{y}_2 zu bestimmen – es ergibt sich die 6x5-Matrix \mathcal{O}_B , welche aus Gründen der Übersichtlichkeit hier nicht aufgeführt ist. Durch eine systematische Untersuchung des Rangs dieser Matrix, abhängig von den Eingängen, kann festgestellt werden, dass die Matrix einen Rang von fünf besitzt, solange nicht mehr als zwei Elemente von u_k und u_{k-1} gleich null sind. Das zweite Teilsystem ist demnach dann ebenfalls beobachtbar und somit insgesamt alle zu bestimmenden Zustände und Parameter des DKFs.

Auch der Beobachtbarkeitsindex kann für den Parameterschätzer untersucht werden. Es zeigt sich hierbei, dass der Strom oder der Ladezustand keinen Einfluss auf ς haben, solange ersterer ungleich null ist. Dahingegen ist die Beobachtbarkeit von der Sättigung der RC-Glieder abhängig. Je kleiner diese ist, desto stärker ändern sich die Überspannungen u_1 und u_2 innerhalb eines Zyklus, was die Beobachtbarkeit der Parameter der RC-Glieder verbessert. Den Beobachtbarkeitsindex ς in Abhängigkeit von einer Sättigung der beiden RC-Glieder zwischen 0% und 100% zeigt Abb. 4.13. Dieser ergibt sich als Median aus 100 Monte-Carlo-Simulationen mit stochastischem Sensorrauschen des Stromes. Zu sehen ist, dass nur die Sättigung von u_2 die Beobachtbarkeit signifikant verändert. Dies ist darauf zurückzuführen, dass die größere Zeitkonstante des zweiten RC-Gliedes eine Veränderung der Überspannung während eines Zeitschritts nur dann zulässt, wenn es noch nicht eingeschwungen ist. Das erste RC-Glied mit kurzer Zeitkonstante verändert sich dagegen während eines Simulationsschritts stärker, unabhängig von der Sättigung. Insgesamt ist die Änderung von ς abhängig von der Sättigung der RC-Glieder jedoch gering.

In Abb. 4.11 ist der Beobachtbarkeitsindex des DKFs als grauer Bereich eingezeichnet. Die Schwankungsbreite ergibt sich aus der Sättigung der RC-Glieder zwischen jeweils 0% und 100%. Im Vergleich zur Joint-Estimation mit $n = 8$ ist die Beobachtbarkeit des DKFs besser. Der Beobachtbarkeitsindex liegt um zwei Größenordnungen unter dem des JKF. Nur, wenn der Strom verschwindet, ist R_0 nicht mehr beobachtbar, wobei dies für beide Implementierungen des Kalman-Filters gilt.

An dieser Stelle ist zu beachten, dass die Beobachtbarkeit kein Maß für die erzielbare Genauigkeit der Schätzung ist. Schätzunsicherheiten innerhalb des Zustands- oder Parameterschätzers

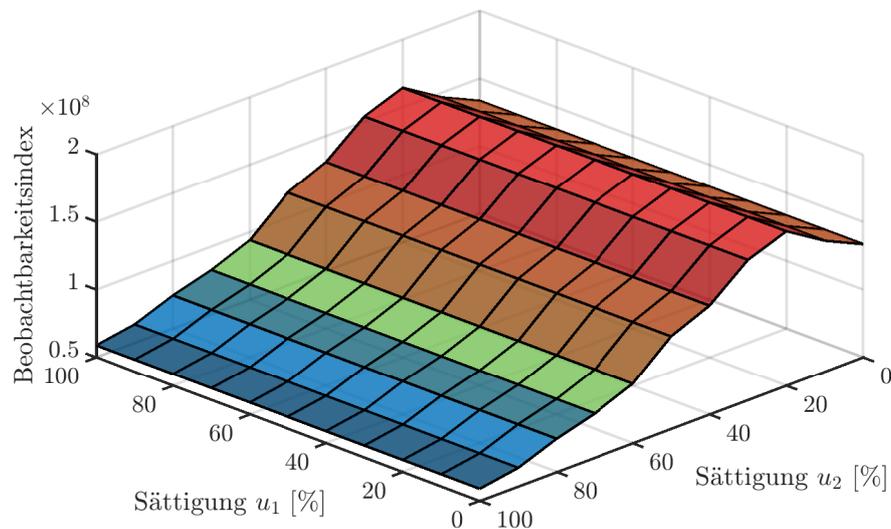


Abbildung 4.13: Beobachtbarkeitsindex ζ abhängig von der Sättigung der RC-Glieder. Ein kleiner Wert entspricht einer guten Beobachtbarkeit.

des DKFs können zu Schätzfehlern des jeweils anderen Filters führen. Eine grundsätzliche Aussage zur Eignung von DKFs insbesondere mit hoher Modellordnung kann deshalb aus der Beobachtbarkeitsanalyse nicht getroffen werden.

4.2.5 Schlussfolgerungen für die Anwendung

Die Analyse der Beobachtbarkeit des Ersatzschaltbildmodells einer Lithium-Ionen-Zelle zeigt, dass unter der Voraussetzung einer permanenten Systemanregung alle Systemzustände beobachtbar sind, unabhängig von der Dimension des Zustandsvektors. Es zeigt sich aber auch, dass die Beobachtbarkeit schlechter wird, je mehr Modellparameter Teil des Zustandsvektors werden. Für die Modellordnung $n = 8$ liegt der Beobachtbarkeitsindex im Mittel um fünf Größenordnungen über dem für $n = 6$. Daraus lassen sich verschiedene Schlussfolgerungen ableiten: Soll das Batteriemodell adaptiv bleiben und demnach möglichst viele Modellparameter Teil der Zustandsschätzung sein, empfiehlt es sich, neben den Zuständen des Systems auch die Widerstände R_0 , R_1 und R_2 in den Zustandsvektor zu integrieren. Es ergibt sich die Modellordnung $n = 6$. Dessen Beobachtbarkeit ist grundsätzlich gegeben, wird jedoch umso besser, je größer die Anregung ist. Nachfolgend werden daher in Kapitel 5 Maßnahmen im Kontext von RBSs untersucht, die Systemanregung durch Schaltoperationen zu erhöhen und die Zustands- und Parameterschätzung auf diese Art und Weise zu verbessern. Ein anderer Ansatz wird in Kapitel 6.2 verfolgt: Als Schätzverfahren für die modellbasierte Sensordatenfusion wird ein einfaches und robustes Filter benötigt. Folgerichtig wird deswegen ein DKF vorgestellt und optimiert, welches neben den Systemzuständen nur den Innenwiderstand R_0 als zu schätzenden Modellparameter beinhaltet. Wie in Kapitel 3.1.3 gezeigt wurde, ist insbesondere der Ohmsche Innenwiderstand für die Modellierung des Batteriesystems von Bedeutung, weswegen dieser als einziger Parameter Teil der Parameterschätzung ist.

Abschließend soll an dieser Stelle festgehalten werden, dass die Beobachtbarkeit eine notwendige, jedoch keine hinreichende Bedingung für eine erfolgreiche modellbasierte Zustands- und Parameterschätzung ist. Insofern kann eine gute Beobachtbarkeit als wichtige Grundlage einer Schätzung angesehen werden, weitere Voraussetzungen wie eine ausreichende Systemanregung, ein gutes Modellwissen und die richtige Parametrierung des Filters müssen jedoch ebenso erfüllt sein.

4.3 Methoden zur Parametrierung des Kalman-Filters

Zusammen mit dem initialen Zustandsvektor $\hat{x}_{0|0}$ und der zugehörigen Kovarianzmatrix $\hat{P}_{0|0}$ bilden Q und R die **Hyperparameter** des Kalman-Filters und bestimmen dessen Leistungsfähigkeit maßgeblich. Dass das Kalman-Filter ein optimaler Schätzer im Sinne der kleinsten Fehlerquadrate ist, gilt nur unter der Annahme, dass die Hyperparameter richtig gewählt sind. Andernfalls verhält sich das Filter nicht optimal und es können größere Schätzfehler oder sogar divergente Schätzungen auftreten [219, 220]. Wie in Kapitel 4.1.2 erwähnt wurde, schwindet der Einfluss schlechter Startwerte auf die Schätzergebnisse über längere Zeiträume, da deren Gewichtung exponentiell abnimmt [221]. Deshalb liegt der Fokus im Folgenden auf der Bestimmung von Q und R . Die Bestimmung der Kovarianzmatrizen von Prozess- und Messrauschen wird auch als **Filter-Tuning** bezeichnet.

Wie auch Wassiliadis et al. [182] feststellen, werden die Hyperparameter in vielen Veröffentlichungen zur Ladezustandsschätzung in BMSs nicht angegeben oder die Methodik zu ihrer Ermittlung ist unbekannt. Ein Vergleich unterschiedlicher Filter zur SOC-Bestimmung aus der Literatur ist somit nur eingeschränkt möglich, da die Wahl von Q und R die Ergebnisse der Schätzung stark beeinflusst. Tatsächlich werden die Hyperparameter in der Anwendung häufig durch den applizierenden Ingenieur manuell variiert, bis ein zufriedenstellendes Schätzergebnis erreicht wird. Bei dieser Trial-and-Error-Methode hängt das erzielte Resultat jedoch stark von der Erfahrung des Anwenders ab. Es ist daher ein wünschenswertes Ziel, eine Methodik zur Bestimmung der Hyperparameter zu nutzen, wodurch diese nachvollziehbar und optimal bestimmt werden können.

4.3.1 Stand der Wissenschaft zum Filter-Tuning

Die im Folgenden beschriebenen Verfahren bestimmen die Kovarianzmatrizen von Prozess- und Messrauschen größtenteils *offline*. Während die analytischen Verfahren die Charakteristik der Sensoren von Eingang und Messung voraussetzen, erfolgt die Parametrierung meist anhand einer Trainingssequenz, für die Referenzzustände bekannt sein können, aber nicht zwangsläufig sind. Die Hyperparameter werden dann derart gewählt, dass die Zustandsschätzung über die Trainingssequenz optimal ist. Davon abweichend existieren auch Verfahren zur Bestimmung der Hyperparameter *online*, also im Betrieb. Diese Adaptive-Kalman-Filter (AKFs) werden ebenfalls diskutiert.

4.3.1.1 Analytische Abschätzung von Prozess- und Messrauschen

Insbesondere das Messrauschen lässt sich häufig leicht basierend auf der Charakteristik des Sensors der Messgröße (hier: des Spannungssensors) ermitteln. Ist beispielsweise die Varianz des Sensorrauschens aus im Vorhinein durchgeführten Messungen bekannt, kann $R = \text{Var}\{\tilde{u}\}$ bestimmt werden. Diese Methode wird auch im Rahmen dieser Arbeit verfolgt. Weiterhin ist es jedoch auch möglich, das Messrauschen basierend auf Datenblattwerten anstatt auf Messdaten zu ermitteln. Maletić et al. [206] entnehmen dem Datenblatt des Sensors den größtmöglichen Sensorfehler und setzen diesen als dreifache Standardabweichung des Messrauschens an.

Während das Rauschen des Spannungssensors unmittelbar mit dem Messrauschen gleichgesetzt werden kann, beeinflusst das Rauschen des Stromsensors die Zustandsgleichung (4.4a) indirekt über den Eingangsvektor \mathbf{B} . Damit kann das Prozessrauschen abgeschätzt werden zu

$$\mathbf{Q} = \mathbf{B} \cdot \text{Var}\{\tilde{i}\} \cdot \mathbf{B}^T, \quad (4.52)$$

wobei hier die Annahme zugrunde gelegt wird, dass das Prozessrauschen sich ausschließlich durch das Messrauschen des Stromsensors bemisst. Dies ist in der Realität nicht haltbar, da Modellfehler ebenfalls in \mathbf{Q} Berücksichtigung finden müssen. Dies ist am augenscheinlichsten für die erweiterte Zustandsgleichung (4.18a), wobei die Prädiktion der Parameter mit einem Random-Walk-Modell nachgebildet ist. Nach (4.52) ergäben sich für das Prozessrauschen der Parameter Einträge von 0 in der Matrix \mathbf{Q} . Damit würde das Kalman-Filter die Parameter jedoch nicht mehr verändern können. Vielmehr wird durch das Prozessrauschen die Änderungsrate der Parameter quantifiziert. Marchthaler und Dingler [187, S. 121 ff.] stellen eine Methode vor, bei der durch die Abschätzung der Änderungsrate der Zustandsgröße das Prozessrauschen bestimmt werden kann. Allerdings setzen die Autoren voraus, dass der Verlauf und die Änderung der zu schätzenden Größe bekannt ist. Dies ist in der Regel nicht der Fall. Für den Anwendungsfall der Parameterschätzung im BMS lässt sich das Prozessrauschen der Random-Walk-Parameter mit folgender Überlegung abschätzen: Die Parameter können als Größen betrachtet werden, welche sich abhängig vom Ladezustand, der Temperatur und der Zellalterung verändern. Für eine Iteration des Filters mit t_s kann die Zellalterung im Vergleich zu den anderen beiden Einflussgrößen vernachlässigt werden. Es stellt sich demnach die Frage, wie groß die maximale Änderung der Parameter innerhalb einer Iteration sein kann. Unter der Annahme eines maximalen Strombetrags von 20 A und einer maximalen Temperaturänderung von 1K innerhalb eines Zeitschritts ergibt sich beispielsweise für den Innenwiderstand R_0 gemäß der Charakterisierung aus Kapitel 3.2 eine maximale Änderung um $4,8 \mu\Omega$. Demnach kann der entsprechende Eintrag auf der Hauptdiagonalen von \mathbf{Q} gewählt werden zu

$$Q_{R_0} \approx \left(\frac{4,8 \mu\Omega}{3} \right) = 2,6 \cdot 10^{-12} \Omega. \quad (4.53)$$

Der Abschätzung liegt wiederum die Annahme zugrunde, dass die maximale Änderung des Parameters der dreifachen Standardabweichung entspricht und somit 99,7% der Änderungen von R_0 innerhalb dieses Intervalls liegen. In ähnlicher Weise können auch die Einträge für die weiteren Random-Walk-Parameter bestimmt werden. Etwaige Modellfehler wie beispielsweise Fehler in der OCV-Kurve sind in der Matrix des Prozessrauschens jedoch immer noch nicht berücksichtigt.

Diese lassen sich aus einer analytischen Betrachtung des Modells auch nur schwer ableiten. Daher sind insbesondere zur Bestimmung von \mathbf{Q} alternative Methoden notwendig [222].

4.3.1.2 Klassische Verfahren des Filter-Tunings

Parallel zur Verbreitung des Kalman-Filters existieren bereits seit den 1970er-Jahren Ansätze zur Bestimmung der Kovarianzmatrizen \mathbf{Q} und R . Unterschieden werden hierbei vier verschiedene Ansätze [219, 223], welche im Folgenden vorgestellt und in unterschiedlicher Tiefe diskutiert werden: Bayessche Schätzung, Maximum-Likelihood-Schätzung, die Correlation-Methode und Covariance-Matching.

Im Folgenden von Bedeutung ist sowohl die bereits vorgestellte Innovations-Sequenz

$$e_k = y_k - h(\hat{\mathbf{x}}_{k|k-1}, u_k) \quad \text{mit } \mathbb{E}\{e e^T\} = S \quad (4.54)$$

als auch die Residual-Sequenz

$$d_k = y_k - h(\hat{\mathbf{x}}_{k|k}, u_k) \quad \text{mit } \mathbb{E}\{d d^T\} = S_d, \quad (4.55)$$

welche die Differenz der Messung y_k zum Zeitpunkt k mit der prädizierten $\hat{y}_{k|k-1} = h(\hat{\mathbf{x}}_{k|k-1}, u_k)$ bzw. gefilterten Messung $\hat{y}_{k|k} = h(\hat{\mathbf{x}}_{k|k}, u_k)$ darstellt. Die Innovations-Sequenz ist bei einem optimalen Kalman-Filter normalverteilt und mittelwertfrei [224].

Das klassische Kalman-Filter-Tuning wird offline anhand eines Trainingsdatensatzes durchgeführt. Die bestimmten Hyperparameter sind dann während der Filterung konstant und werden nicht mehr angepasst.

In der **Bayesschen Schätzung** wird eine rekursive Lösung der a posteriori Wahrscheinlichkeitsdichte von $\hat{\mathbf{x}}$ und den Hyperparametern $\{\mathbf{Q}, R\}$ abhängig von den Messungen $Y_k = \{y_1, y_2, \dots, y_k\}$ gesucht.

$$p(\hat{\mathbf{x}}_k, \mathbf{Q}, R | Y_k) = p(\hat{\mathbf{x}}_k | \mathbf{Q}, R, Y_k) p(\mathbf{Q}, R | Y_k) \quad (4.56)$$

Aufgrund des großen möglichen Wertebereichs ist eine numerische Lösung in aller Regel nur mit erheblichem Rechenaufwand möglich, da über diesen integriert werden muss [219, 225], obwohl der Ansatz von Matisko und Havlena [226] und Chen et al. [227] unter Rückgriff auf die heutzutage verfügbare Rechenleistung erneut aufgegriffen wurde.

Alternativ können die Hyperparameter durch **Maximum-Likelihood**-Schätzung bestimmt werden. Das Verfahren zielt darauf ab, die Likelihood verschiedener Fehlermaße durch Variation der Hyperparameter $\{\mathbf{Q}, R\}$ zu maximieren [228].

$$\{\mathbf{Q}, R\} = \arg \max_{\{\mathbf{Q}, R\}} p(y_k | \mathbf{Q}, R) \quad (4.57)$$

Nach [229] sind die Kovarianzmatrizen optimal gewählt, wenn die Likelihood der Innovations-Sequenz S maximiert wird. Dieses Optimierungsproblem lässt sich als Minimierung der negativen logarithmierten Likelihood

$$\mathcal{L}_e = -\frac{K}{2} \cdot \ln \det \{S\} - \sum_{k=1}^K \frac{1}{2} (y_k - h(\hat{\mathbf{x}}_{k|k-1}, u_k))^T S_k^{-1} (y_k - h(\hat{\mathbf{x}}_{k|k-1}, u_k)), \quad (4.58)$$

auffassen, wobei die Annahme der Gauß-Verteilung für die Innovation getroffen wird. Dies ist für das optimale Kalman-Filter gegeben [230]. Die Autoren wenden den EM-Algorithmus [231] zur iterativen Bestimmung der gesuchten Hyperparameter an. Dabei wird das EKF als Filter zugrunde gelegt.

$$\{\mathbf{Q}, R\} = \arg \min_{\{\mathbf{Q}, R\}} \sum_{k=1}^K \ln |S_k| + e_k^T S_k^{-1} e_k \quad (4.59)$$

Statt die Likelihood der Innovations-Sequenz als Grundlage für die Optimierung zu verwenden, betrachten Dreano et al. [232] die Summe der Log-Likelihood (a) der Startwerte $\{\hat{\mathbf{x}}_0, \hat{\mathbf{P}}_0\}$, (b) des Residuums und (c) der Schätzfehler (siehe (4.60)).

$$\mathcal{L}_{x_{0|0}} = -\frac{1}{2} \ln \det \{\mathbf{P}_{0|0}\} - \frac{1}{2} (\hat{\mathbf{x}}_{0|0} - \mathbf{x}_{0|K})^T \mathbf{P}_{0|0}^{-1} (\hat{\mathbf{x}}_{0|0} - \mathbf{x}_{0|K}) \quad (4.60a)$$

$$\mathcal{L}_y = -\frac{K}{2} \cdot \ln \det \{R\} - \frac{1}{K} \cdot \sum_{k=1}^K \frac{1}{2} (y_k - h(\hat{\mathbf{x}}_{k|K}, u_k))^T R^{-1} (y_k - h(\hat{\mathbf{x}}_{k|K}, u_k)) \quad (4.60b)$$

$$\mathcal{L}_x = -\frac{K}{2} \cdot \ln \det \{\mathbf{Q}\} - \frac{1}{K} \cdot \sum_{k=1}^K \frac{1}{2} (\hat{\mathbf{x}}_{k|K} - f(\hat{\mathbf{x}}_{k-1|K}, u_{k-1}))^T \mathbf{Q}^{-1} (\hat{\mathbf{x}}_{k|K} - f(\hat{\mathbf{x}}_{k-1|K}, u_{k-1})) \quad (4.60c)$$

Dabei werden die geglätteten Zustände $\hat{\mathbf{x}}_{k|K}$ mithilfe eines Kalman-Smoother auf Basis aller verfügbaren Messdaten $y_{1:K}$ ermittelt. Die Autoren wenden wiederum das Expectation-Maximization-Verfahren zur iterativen Optimierung an. Mohan et al. [230] verwendet als Kostenfunktion für die Optimierung der Hyperparameter ebenfalls die Zusammenhänge aus (4.60) sowie weitere Statistiken.

Bereits in den 1970er-Jahren wurden Verfahren vorgestellt, die als **Correlation-Methode** bezeichnet werden [219, 224, 233]. Grundlage der Methode ist wiederum die Innovations-Sequenz. Im Falle eines optimal parametrisierten Kalman-Filters ist die Innovation zu einem beliebigen Zeitpunkt nur mit sich selbst korreliert, nicht jedoch mit ihren Vorgängern bzw. Nachfolgern. Daraus können Schätzungen für \mathbf{Q} und R abgeleitet werden, wobei nach Mehra [224] für das Prozessrauschen häufig keine eindeutige Lösung existiert. Erweitert wurde das Verfahren von Odelson et al. [221] und Åkesson et al. [234]. Das von ihnen vorgestellte Autocorrelation-Least-Squares-Verfahren betrachtet die Residual-Sequenz über die Zeit, genauer deren Autokorrelation. Die Hyperparameter des Filters werden variiert, um die gewünschte Charakteristik der Autokorrelation zu erhalten. Die Schätzwerte sind erwartungstreu. Nachteilig kann bei diesem Verfahren angesehen werden, dass kein Wahrscheinlichkeitsmaß für die ermittelten Hyperparameter angegeben wird [226]. Darüber hinaus ist die Correlation-Methode basierend auf der Residual-Sequenz nur anwendbar, wenn die Systemmatrix \mathbf{A} stabil ist [219]. Dies ist im konkreten Anwendungsfall der SOC-Schätzung nicht der Fall, denn \mathbf{A} ist nur asymptotisch stabil.

Der als **Covariance-Matching** bezeichnete Ansatz verfolgt das Ziel, die statistischen Eigenschaften der Innovations-Sequenz mit deren theoretischen Eigenschaften in Übereinstimmung zu bringen. Wenn die statistische Varianz der Innovation vom theoretisch zu erwartenden Wert abweicht, können \mathbf{Q} und R derart angepasst werden, dass sich die gewünschte Übereinstimmung einstellt [235]. Eine ausführliche Herleitung kann bei Mohamed und Schwarz [236] gefunden werden. Es ist zu beachten, dass bei diesem Verfahren nur in einigen Fällen eine eindeutige Lösung existiert [219].

Für eine Trainingsdaten-Sequenz der Länge K kann die Kovarianzmatrix der Innovations-Sequenz nach

$$\hat{S}_k = \frac{1}{K} \cdot \sum_{j=k-K+1}^k e_j e_j^T \quad (4.61)$$

geschätzt werden. Basierend auf dem Maximum-Likelihood-Prinzip und unter der Annahme, dass R bekannt ist, lässt sich zeigen, dass

$$\hat{Q}_k = \frac{1}{K} \cdot \sum_{j=k-K+1}^k \Delta \mathbf{x}_j \Delta \mathbf{x}_j^T + \hat{P}_{k|k} - \mathbf{A} \hat{P}_{k-1|k-1} \mathbf{A}^T \quad (4.62)$$

mit der Zustandskorrektur-Sequenz

$$\Delta \mathbf{x}_k = \hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k-1}. \quad (4.63)$$

Über den Korrekturschritt des Kalman-Filters (siehe Algorithmus 4.1) ist dann leicht ersichtlich, dass

$$\text{Var} \{ \Delta \mathbf{x}_k \} = \mathbf{K}_k \text{Var} \{ e_k \} \mathbf{K}_k^T = \mathbf{K}_k S_k \mathbf{K}_k^T. \quad (4.64)$$

Damit erhält man als Schätzwert für die Kovarianzmatrix des Prozessrauschens zum Zeitpunkt k

$$\hat{Q}_k = \mathbf{K}_k \hat{S}_k \mathbf{K}_k^T + \hat{P}_{k|k} - \mathbf{A} \hat{P}_{k-1|k-1} \mathbf{A}^T, \quad (4.65)$$

wobei die Kovarianz der Innovations-Sequenz nach (4.61) basierend auf den zurückliegenden K Zeitschritten berechnet werden kann. Im eingeschwungenen Zustand verschwinden der zweite und dritte Summand nahezu und es gilt [236]

$$\hat{Q}_k \approx \mathbf{K}_k \hat{S}_k \mathbf{K}_k^T. \quad (4.66)$$

Analog ergibt sich für das Messrauschen

$$\hat{R}_k = \hat{S}_k - \mathbf{C} \hat{P}_{k|k-1} \mathbf{C}^T. \quad (4.67)$$

Das Covariance-Matching garantiert nicht, dass \mathbf{Q} oder R positiv definit ist [229]. Außerdem sind laut Odelson et al. [221] die ermittelten Kovarianzmatrizen mit einem systematischen Fehler behaftet.

4.3.1.3 Adaptive Kalman-Filter

Neben der Bestimmung des Prozess- und Messrauschens *offline* mit ausgewählten Trainingsdaten, können die Rausch-Kovarianzen auch *online* während des Betriebs des Kalman-Filters bestimmt werden. Die Charakteristiken des Mess- und Prozessrauschens werden dann selbst zu zeitveränderlichen Größen, weswegen man von Adaptive-Kalman-Filtern (AKFs) spricht.

In [237] wird ein auf (4.66) basierendes AKF zur Bestimmung des Ladezustands eines Blei-Akkumulators verwendet. Die Kovarianz der Innovations-Sequenz wird über ein gleitendes Fenster gemäß (4.61) berechnet, wobei K die Fensterbreite ist. Die Ergebnisse werden mit einem herkömmlichen EKF verglichen. Die Autoren beobachten einen geringeren Schätzfehler bei Verwendung des AKFs. Ähnliche Beobachtungen werden von verschiedenen Autoren für Lithium-Ionen-Zellen [238–242] und -Module [243] gemacht. Campestrini et al. [244] vergleichen das AKF mit dem EKF, SPKF und DKF bei veränderlichen Umgebungstemperaturen, wobei das Batteriemodell diese nicht berücksichtigt. Sie stellen fest, dass das AKF insbesondere vorteilhaft ist, wenn sich die Umgebungstemperatur von der während der Modellparameterbestimmung herrschenden Temperatur unterscheidet. Die Differenz der Umgebungstemperatur von derjenigen, welche bei der Zellcharakterisierung vorherrschte, erzeugt unterschiedlich große Modellfehler, welche durch das AKF durch entsprechend gewähltes Prozessrauschen berücksichtigt wird. Eigene Untersuchungen zeigen, dass beim Verfahren nach Mohamed und Schwarz [236] das Prozessrauschen systematisch für einige Zustände zu klein geschätzt wird, wodurch die Schätzfehler ansteigen. Es zeigt sich ebenfalls, dass ein AKF nach dem vorgestellten Verfahren einer sorgfältigen *Offline*-Bestimmung der Kovarianz des Prozessrauschens unterlegen ist. Weiterhin kann die Adaption mittels Covariance-Matching auch für SPKF [178, 245, 246] eingesetzt werden. Zur Stabilisierung der \hat{Q} -Schätzung kann nach Junping et al. [177] zusätzlich ein Mittelwert-Filter mit Vergessensfaktor λ wie in (4.68) eingesetzt werden. Übliche Werte für λ liegen zwischen 0,9 und 0,999.

$$\hat{Q}_k = \lambda \hat{Q}_{k-1} + (1 - \lambda) \mathbf{K}_k \hat{S}_k \mathbf{K}_k^T \quad (4.68)$$

Von Cheng et al. [247] wird das Mittelwert-Filter eingesetzt, um den Ladezustand einer Lithium-Ionen-Zelle zu bestimmen, wenn der Stromsensor einen Offset-Fehler aufweist. Die Ergebnisse des AKFs sind dann den Autoren nach einem herkömmlichen EKF überlegen.

Bei Wang et al. [248] wird statt der Innovations-Sequenz die Residual-Sequenz verwendet. Die Berechnung der Kovarianzmatrix des Prozessrauschens variiert leicht zu den zuvor vorgestellten Ansätzen. Allerdings verzichten die Autoren auf eine Herleitung der Gleichung.

$$\hat{Q}_k \approx \mathbf{K}_k \hat{S}_{d,k} \mathbf{K}_k^T + \hat{S}_{d,k} \quad (4.69)$$

Der ROSE-Filter (Rapid-Ongoing-Stochastic-Covariance-Estimation), der von Marchthaler und Dingler [187] vorgestellt wird, beruht ebenfalls auf der Kovarianzmatrix der Innovations-Sequenz. Basierend auf den schon gezeigten Zusammenhängen gilt

$$S_k = \mathbf{C} \hat{\mathbf{P}}_{k|k-1} \mathbf{C}^T + R \quad (4.70a)$$

$$S_k = \mathbf{C} (\mathbf{A} \hat{\mathbf{P}}_{k-1|k-1} \mathbf{A}^T + \mathbf{Q}) \mathbf{C}^T + R \quad (4.70b)$$

und damit

$$\hat{\mathbf{Q}}_k = \mathbf{C}^T (S_k - R) \mathbf{C} - \mathbf{A} \hat{\mathbf{P}}_{k-1|k-1} \mathbf{A}^T. \quad (4.71)$$

Die Autoren schlagen vor, S_k über eine gleitende Mittelwertbildung zu ermitteln. Weiterhin ist zu beachten, dass über die Schätzung von S_k die Differenz in (4.71) negativ werden kann. In diesem Fall schlagen die Autoren vor, die entsprechenden Einträge von \mathbf{Q} auf null zu setzen. Für die Anwendung als Parameterschätzer in BMSs eignet sich das ROSE-Filter nicht. Beispielsweise führt ein Strom von 0 A dazu, dass der vierte Eintrag von \mathbf{C} null wird. Dann wird für die Schätzung des Innenwiderstands der entsprechende Eintrag in \mathbf{Q} ebenfalls null, obwohl die Schätzunsicherheit ohne neue Informationen größer werden sollte. In gleicher Weise werden die Einträge in \mathbf{Q} von R_1 und R_2 immer zu null bestimmt, weil diese in der Ausgangsmatrix mit null gewichtet werden. Es ergibt sich dadurch ein zu großes Modellvertrauen. Weiterhin schwankt das Prozessrauschen stark, wodurch die Kovarianz der Schätzung ebenfalls keinen stetigen Verlauf aufweist.

Eigentlich entwickelt für die Offline-Bestimmung der Hyperparameter, schlagen Einicke et al. [249] ein Verfahren vor, welches sich ebenfalls für die adaptive Schätzung (online) von \mathbf{Q} eignet. Unter der Annahme, dass $\hat{\mathbf{x}}_{k|k-1} = \mathcal{N}(\hat{\mathbf{x}}|f(\hat{\mathbf{x}}_{k-1|k-1}, u_{k-1}), \mathbf{Q})$, gilt

$$\mathbf{Q} = \mathbb{E} \left\{ (\hat{\mathbf{x}}_{k|k-1} - f(\hat{\mathbf{x}}_{k-1|k-1}, u_{k-1})) (\hat{\mathbf{x}}_{k|k-1} - f(\hat{\mathbf{x}}_{k-1|k-1}, u_{k-1}))^T \right\}. \quad (4.72)$$

Vorausgesetzt, dass das Kalman-Filter bereits eingeschwungen ist und $\hat{\mathbf{x}}_{k|k}$ eine gute Schätzung des Systemzustandes zum Zeitpunkt k ist, kann eine erwartungstreue Schätzung $\hat{\mathbf{Q}}_k$ wie folgt bestimmt werden:

$$\hat{\mathbf{Q}}_k = \frac{1}{M-1} \cdot \sum_{j=k-M+1}^k (\hat{\mathbf{x}}_{j|j} - f(\hat{\mathbf{x}}_{j-1|j-1}, u_{j-1})) (\hat{\mathbf{x}}_{j|j} - f(\hat{\mathbf{x}}_{j-1|j-1}, u_{j-1}))^T. \quad (4.73)$$

M ist hierbei die Fensterlänge. Es zeigt sich jedoch, dass $\hat{\mathbf{x}}_{k|k} - f(\hat{\mathbf{x}}_{k-1|k-1}, u_{k-1})$ in (4.73) beispielsweise für den SOC sehr klein ist, wenn das Modell gut und der Strom gering ist. Dann geht das Filter von einem sehr guten Modellwissen aus und korrigiert den prädizierten Schätzwert kaum noch. In der Folge bleibt die Differenz auch weiterhin sehr klein, wodurch schließlich keine Korrektur des Filters mehr durchgeführt wird.

Li et al. [250] untersuchen verschiedene Arbeitspunkte eines Verbrennungsmotors und bestimmen für jeden dieser Punkte das Prozessrauschen. Das für jeden Arbeitspunkt optimale \mathbf{Q} speichern sie in einer Look-up-Tabelle ab und adaptieren so das Prozessrauschen abhängig von Drehzahl und Einspritzmenge des Motors zum aktuellen Zeitpunkt. Auch dadurch ergibt sich eine Art adaptives Kalman-Filter. Allerdings ist die Methode zur Bestimmung der optimalen Kovarianzmatrix des Prozessrauschens nicht näher erläutert. Das Ziel der vorgestellten Zustandsschätzung ist die Bestimmung des Sauerstoffgehalts im Ansaugtrakt und Abgas eines Verbrennungsmotors mit Abgasrückführung.

Insgesamt ist die Validierung eines AKF zur Ladezustandsschätzung schwierig und in der Literatur häufig nur ungenügend gelöst. In aller Regel beschränken sich die Autoren auf die Betrachtung des Schätzfehlers vom Ladezustand, wohingegen die anderen Größen nicht berücksichtigt werden. Cheng et al. [247] vergleichen das von ihnen implementierte AKF zur SOC-Schätzung mit

einem EKF mit $\mathbf{Q} = \mathbf{0}$. Bei Han et al. [237] wird das Verhältnis Q/R von 0,1 bis 10 variiert und der resultierende Schätzfehler mit einem AKF verglichen. In weiteren Arbeiten fehlen zu den als Referenz herangezogenen EKF bzw. SPKF die Angaben zu Prozess- und Messrauschen völlig [178, 246, 248] oder der Vergleich mit einem herkömmlichen nichtlinearen Kalman-Filter fehlt gänzlich [238, 240, 243, 248].

In Kapitel 6.2 wird eine Kalman-Filter-Variante vorgestellt, welche ähnlich einem AKF die Kovarianz des Messrauschens für jeden Zeitschritt adaptiert.

4.3.1.4 Filter-Tuning als Optimierungsproblem

Die Bestimmung des Prozess- und Messrauschens kann auch als nichtlineares Optimierungsproblem verstanden werden, bei welchem \mathbf{Q} und R derart gewählt werden, dass eine Kostenfunktion J minimal wird.

$$\{\mathbf{Q}, R\} = \arg \min_{\{\mathbf{Q}, R\}} J(\mathbf{Q}, R) \quad (4.74)$$

Bei der Wahl der Kostenfunktion ist grundsätzlich zwischen zwei Fällen zu unterscheiden. Werden Simulationen mit einem Referenzmodell durchgeführt (siehe Fall (I) in Abb. 4.6), sind die Systemzustände, welche der Schätzer ermittelt, zu jedem Zeitpunkt aus dem Batteriesystemmodell bekannt. Eine Bewertung der Schätzfehler ist dann möglich. Als Kostenfunktion kann dann beispielsweise der Mean-Squared-Error (MSE) [251, 252] oder RMSE [182] genutzt werden. Wassiliadis et al. [182] addieren zum RMSE zusätzlich einen Strafterm, wenn $\hat{\mathbf{P}}$ und S während der Simulation ansteigen. Dadurch soll verhindert werden, dass die Kovarianzen unbegrenzt ansteigen. Durch die Minimierung der Schätzfehler erhält man nicht zwangsläufig einen konsistenten Schätzer (vgl. Kapitel 4.1.5). Die Konsistenz des Schätzers kann beispielsweise durch einen Hypothesentest auf Basis des NEES überprüft werden, wie in Abschnitt 4.1.5 vorgestellt wurde. Nachteilig bei der Optimierung von \mathbf{Q} und R auf Basis eines Referenzmodells ist, dass die Modellfehler nicht berücksichtigt werden und demnach das Prozessrauschen zu klein gewählt wird, da diese zusätzlichen Modellfehler in \mathbf{Q} berücksichtigt werden sollen. Das durch Simulationen gefundene Prozessrauschen ist daher als untere Schranke zu verstehen.

Beim zweiten Fall – der Optimierung anhand realer, experimenteller Daten (vgl. Fall (II) in Abb. 4.6)– stehen die Referenzzustände nicht mehr zwangsläufig zur Verfügung. Durch eine hochgenaue Strommessung und Coulomb-Counting lässt sich zwar der Referenz-Ladezustand ermitteln, wenn der SOC zu Beginn der Messung bekannt ist, die Widerstände R_0 , R_1 und R_2 sind jedoch nur als ladezustands- und temperaturabhängige Größen aus der Charakterisierung bekannt und können aus Look-up-Tabellen entnommen werden. Die Überspannungen u_1 und u_2 schließlich haben als Hilfsgrößen des Modells gar keine Referenz. Die Kostenfunktion J kann in der Optimierung daher nur die Schätzfehler derjenigen Zustände berücksichtigen, dessen Referenzwerte bekannt sind. Wang et al. [203] wählen als Kostenfunktionen daher nur den Mean-Absolute-Error (MAE) der SOC- und R_0 -Schätzung. Darüber hinaus wird in der Literatur häufig nur das Residuum $d_k = y_k - h(\hat{\mathbf{x}}_{k|k}, u_k)$ minimiert, ohne die Systemzustände selbst zu berücksichtigen [253, 254].

Da zur Bestimmung des Funktionswerts J ein Durchlauf des Kalman-Filters notwendig ist, handelt es sich um ein rechenintensives Verfahren und zur Lösung müssen numerische Opti-

mierungsalgorithmen eingesetzt werden. Als Verfahren können der einfache Downhill-Simplex-Algorithmus [255] benutzt werden, ANNs [251] oder metaheuristische Verfahren wie die PSO [252], GAs [203, 222, 253] oder Reinforcement-Learning [256]. Auf GAs geht der nachfolgende Abschnitt detaillierter ein. Korniyenko et al. [251] bilden den Zusammenhang des MSEs der Schätzung zu den Hyperparametern durch ein ANN ab, welches sie anschließend zur Optimierung dieser nutzen. Die Testpunkte zum Training des ANNs werden nach den Prinzipien des Design--of-Experiments-Ansatzes ausgewählt und der Schätzfehler als Mittelwert über mehrere Monte-Carlo-Durchläufe gewonnen. Für ein System der Ordnung 6 wählen die Autoren 77 Testpunkte. Dennoch ist fraglich, ob der Hyperparameter-Raum ausreichend durch die Testpunkte abgedeckt wird.

Ting et al. [253] optimieren Mess- und Prozessrauschen gleichzeitig für ein EKF der Ordnung 3 mittels GA. Der RMSE des Residuums kann um ungefähr zwei Größenordnungen gegenüber der ursprünglichen Parametrierung verringert werden. Allerdings ist die Populationsgröße mit fünf Individuen recht klein. Darüber hinaus wird die Konsistenz des sich ergebenden Filters nicht überprüft. Bei Wang et al. [203] wird ein GA mit einer deutlich größeren Population von 200 eingesetzt, um das Prozess- und Messrauschen zu bestimmen. Das SPKF schätzt neben dem SOC und der Überspannung eines Thevenin-Modells auch die Parameter R_0 , R_1 und τ_1 . Die Autoren geben an, dass die Parameter des GAs nach der Trial-and-Error-Methode bestimmt wurden. Es ist allerdings unklar, ob alle $5 \cdot 5 = 25$ Einträge von \mathbf{Q} oder nur deren Hauptdiagonaleinträge optimiert wurden. Ein Konsistenzmaß basierend auf dem NEES stellen Oshman und Shaviv [222] vor. Die Optimierung mittels GA greift auf dieses Maß als Fitnessfunktionswert zu. Die Autoren stellen fest, dass es dann keine eindeutige Lösung für das Optimierungsproblem gibt, weil ein Filter zwar konsistent sein und dennoch große Schätzfehler aufweisen kann. Daher wird, wenn das Filter als konsistent eingestuft wird (das Konsistenzmaß unterhalb einer Schwelle liegt), die Norm der Kovarianzmatrix $\hat{\mathbf{P}}_{k|K}$ als Kostenfunktionswert herangezogen, wodurch sich eine eindeutige Lösung ergibt. Die Bestimmung des Konsistenzwerts nach Oshman und Shaviv [222] wird im folgenden Abschnitt noch genauer vorgestellt.

Prinzipiell erscheint auch die sogenannte Surrogate-Optimization (SO), welche für die Anwendung mit rechenintensiven Kostenfunktionen geeignet ist, ein möglicher Kandidat für das vorliegende Optimierungsproblem. Die Idee der SO ist es, die Kostenfunktion nur an wenigen Stellen des Parameterraums zu evaluieren und dann die Fehlerfläche durch beispielsweise eine radiale Basisfunktion zu modellieren. Anhand dieses Modells werden dann neue Kandidaten für ein Minimum gesucht und das Modell der Fehlerfläche verfeinert. Dadurch wird die Kostenfunktion im Vergleich zur PSO oder dem GA signifikant seltener berechnet. Allerdings existieren keine bewährten Methoden zur multikriteriellen Optimierung, wenn die Fehlerfläche stark zerklüftet ist oder die Pareto-Front nicht konvex ist [257].

Bei den metaheuristischen Optimierungsverfahren wie der PSO, SO oder dem GA kann die Optimalität der gefundenen Lösung nicht garantiert werden. Dennoch zeigt sich, dass die Verfahren sehr gute Ergebnisse für ein breites Spektrum an Anwendungen liefern und auch für das Kalman-Filter-Tuning prinzipiell geeignet sind. Im Folgenden wird daher ein multikriterieller GA zur Bestimmung des Prozessrauschens entwickelt und untersucht. Prinzipiell wäre auch eine PSO als Optimierungsverfahren denkbar, allerdings neigt diese ohne zusätzliche Maßnahmen zu einer schnellen Konvergenz hin zu einem Bereich des Suchraums. Allgemein kann das Verhalten der

metaheuristischen Optimierungsverfahren durch die Wahl geeigneter Parameter in einem weiten Bereich angepasst werden.

4.3.2 Multikriterielle Optimierung zur Bestimmung des Prozessrauschens

Zur Bestimmung der Kovarianzmatrizen des Kalman-Filters wird im Rahmen dieser Arbeit die folgende Methodik verwendet: Das Messrauschen r wird durch das Rauschen des Spannungssensors dominiert, weswegen $R = \text{Var}\{\tilde{u}\}$ auf Basis der Varianz der Spannungsmesswerte gewählt wird. Zur Bestimmung der Kovarianz des Prozessrauschens wird dagegen eine multikriterielle Optimierung mit dem GA vorgestellt.

4.3.2.1 Vorstellung des Optimierungsalgorithmus

Genetische Algorithmen (GAs) sind vielversprechende Verfahren für die numerische Optimierung der Hyperparameter aufgrund ihrer Fähigkeit, auch große Wertebereiche effizient nach einer optimalen Lösung zu durchsuchen [258, S. 41 f.]. Dazu operieren sie statt mit nur einem initialen Lösungskandidaten mit einer Population von Punkten im Suchraum, wodurch sie leicht parallelisiert werden können. Es handelt sich um ein gradientenfreies Verfahren, wodurch GAs für viele Optimierungsprobleme eingesetzt werden können [259, S. 7]. Das Verfahren geht auf die Arbeiten von John Holland zurück [260]. Im GA werden die Prozesse der Evolutionsmechanik nach dem Darwinschen Prinzip der Bestenauslese (engl. *survival of the fittest*) in vereinfachter Form für die Suche eines im Sinne eines Optimierungsproblems besten Individuums nachgebildet [258, S. 24 ff.]. Ein Individuum ist hierbei ein möglicher Lösungskandidat für das Optimierungsproblem, welches hier als Genotyp einen möglichen Parametersatz \mathbf{Q} beinhaltet. Zu Beginn des Optimierungsprozesses wird eine Population aus einer festgelegten Zahl von Individuen gebildet, deren Genotypen möglichst einen weiten Bereich des Lösungsraums abdecken. Für jeden Teil der Population der ersten Generation wird nun die Fitness $g(\mathbf{Q})$ bestimmt, welche ein Maß für die Güte der durch das Individuum erreichten Lösung ist. Dafür kann auf die Kostenfunktion zurückgegriffen werden, sodass $g = -J$. Im anschließenden Selektionsprozess, wird basierend auf drei Mechanismen eine Population der zweiten Generation gebildet. Zum ersten sind Individuen mit einer hohen Fitness mit höherer Wahrscheinlichkeit in der neuen Generation enthalten, wohingegen schlechte Individuen aussortiert werden. Zweitens bilden sich aus der zufälligen Kombination der Genotype von Individuen der aktuellen Generation (Eltern) neue Individuen der neuen Generation (Kinder). Dies wird als Rekombination bezeichnet. Schließlich kommt es drittens bei der Mutation zu zufälligen Veränderungen der Genotype einzelner Individuen, sodass auch Bereiche des Parameterraums untersucht werden, welche in der ursprünglichen Population nicht enthalten sind. Die Schritte (a) Berechnung der Fitnessfunktion und (b) Selektion wiederholen sich iterativ, bis ein Abbruchkriterium für die Optimierung erfüllt ist. Beispielsweise kann der GA abgebrochen werden, wenn sich der Fitnesswert über mehrere Generationen nicht mehr bedeutend verbessert, oder die Optimierung endet nach einer festen Anzahl an Generationen. Das Individuum der letzten Generation mit dem höchsten Fitnesswert gilt als die beste gefundene Lösung für das Optimierungsproblem. Der Prozess des GAs ist in Abb. 4.14 dargestellt. Der sogenannte Selektionsdruck beim GA entsteht durch die Auswahl derjenigen Individuen mit

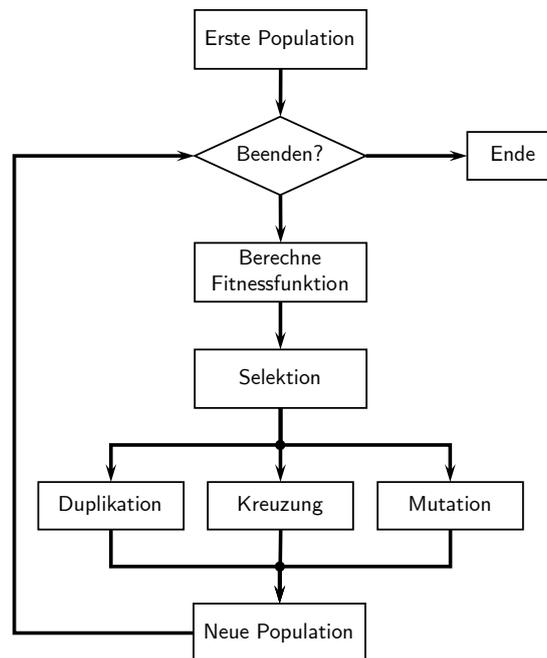


Abbildung 4.14: Flussdiagramm des Genetischer Algorithmus. Angelehnt an Yang et al. [254].

der höchsten Fitness. Dadurch nähert sich die Population über mehrere Generationen lokalen Minima im Kostenraum an.

Bei der multikriteriellen Optimierung existieren mehrere unabhängige Optimierungsziele, die gegenläufig zueinander stehen. Daher kann in aller Regel kein Optimum gefunden werden, welches alle Ziele gleichermaßen bestmöglich erfüllt. Vielmehr bewirkt eine Verbesserung bezüglich eines Zieles, dass sich die anderen verschlechtern. Anstatt die Kostenfunktionen der Einzelziele durch eine gewichtete Summe zu einer einzigen Kostenfunktion zusammenzufassen, bei der die Gewichtung der Einzelziele willkürlich festgelegt werden muss, betrachtet die sogenannte Pareto-Optimierung die Teilziele unabhängig voneinander. Es ergeben sich folglich viele Lösungen, welche als Pareto-Menge oder Pareto-Front bezeichnet werden. Diese ist dadurch charakterisiert, dass keines der in ihr beinhalteten Elemente von einer anderen Lösung dominiert wird. Deb [261, S. 28] definiert die Dominanz einer Lösung x_i des Optimierungsproblems gegenüber einer alternativen Lösung x_j wie folgt:

1. Die Lösung x_i ist hinsichtlich keines Optimierungsziels schlechter als die Lösung x_j .
2. Die Lösung x_i ist hinsichtlich mindestens eines Optimierungsziels besser als die Lösung x_j .

Beide Bedingungen müssen erfüllt sein. Da keines der Elemente der Pareto-Menge von einer anderen Lösung dominiert wird, kann für sie keine Verbesserung eines Teilziels erreicht werden ohne gleichzeitig eine Verschlechterung eines anderen Teilziels in Kauf zu nehmen. Daher sind alle Elemente der Pareto-Menge pareto-optimal. Die endgültige Auswahl einer der möglichen Lösungen ist am Ende eine Abwägung der Optimierungsziele, welche durch die Anwendung bestimmt wird. Alle Lösungen der Pareto-Menge besitzen den Rang 1. Aus der verbleibenden Menge an Lösungskandidaten werden diejenigen mit Rang 2 bezeichnet, welche nun diese

Teilmenge dominieren. Dieser Vorgang kann iterativ durchgeführt werden, sodass sich eine Rangfolge der Kandidaten ergibt.

Für die Bestimmung der Kovarianzmatrix \mathbf{Q} werden drei unabhängige Optimierungsziele herangezogen [262]. Da es wünschenswert ist, eine Zustandsschätzung mit möglichst kleinen Schätzfehlern zu erhalten, wird erstens der RRMSE der Schätzfehler als Kostenfunktion des ersten Optimierungsziels gewählt. Dieser ist als Erweiterung von (4.22) für vektorielle Größen definiert als

$$J_{\text{RRMSE}} = \text{RRMSE}_{\mathbf{x}} = \frac{\sqrt{\frac{1}{K} \cdot \sum_{k=1}^K (\mathbf{x}_k - \hat{\mathbf{x}}_{k|k})^T (\mathbf{x}_k - \hat{\mathbf{x}}_{k|k})}}{\frac{1}{K} \cdot \sum_{k=1}^K |\mathbf{x}_k|}. \quad (4.75)$$

Durch die Normierung des RRMSEs auf den mittleren Systemzustand wird den unterschiedlichen Größenordnungen der Zustände und Parameter Rechnung getragen, welche sich beispielsweise für den SOC und die Widerstände voneinander unterscheiden. Als zweites Optimierungsziel soll die Zustandsschätzung konsistent sein. Dies kann basierend auf dem NEES über mehrere Monte-Carlo-Durchläufe geprüft werden. Der herkömmliche Hypothesentest (siehe Kapitel 4.1.5) liefert jedoch nur eine binäre Aussage zur Konsistenz der Schätzung und kann daher nur schwerlich für eine Optimierung herangezogen werden. Oshman und Shaviv [222] stellen in ihrer Arbeit ein Verfahren vor, bei dem eine kontinuierliche Kostenfunktion als Maß für die Inkonsistenz der Schätzung berechnet werden kann und sich der NEES in eine quantifizierbare Größe umwandeln lässt. Ausgehend vom Mittelwert des NEES zum diskreten Zeitschritt k über N_{MC} Monte-Carlo-Durchläufe aus (4.26) kann für jeden Zeitschritt die Wahrscheinlichkeit

$$F_k^{\chi^2} = P(\chi_{n \cdot N_{\text{MC}}}^2 < N_{\text{MC}} \cdot \bar{\epsilon}_k) \quad (4.76)$$

berechnet werden. Da der NEES über die Monte-Carlo-Durchläufe statistisch Chi-Quadrat-verteilt ist mit dem Freiheitsgrad $n N_{\text{MC}}$, gibt $F_k^{\chi^2}$ die Wahrscheinlichkeit dafür an, dass der Mittelwert des NEES dieser Chi-Quadrat-Verteilung folgt. n ist die Anzahl gesuchter Parameter, da nur die Hauptdiagonaleinträge von \mathbf{Q} optimiert werden sollen. Die resultierenden Wahrscheinlichkeiten $F_k^{\chi^2}$ werden nun der Größe nach sortiert und auf der Ordinate in Abb. 4.15 dargestellt, wohingegen auf der Abszisse die Indizes von 0 bis K normiert auf 1 aufgetragen sind. Im Falle eines konsistenten Schätzers, ergibt sich eine Diagonale vom Ursprung zum Punkt $\{1, 1\}$, da $F_k^{\chi^2}$ eine Chi-Quadrat-Verteilung ist. Ist die Schätzung dagegen inkonsistent, weicht die Kurve von der Winkelhalbierenden ab und liegt darüber oder darunter. Oshman und Shaviv [222] schlagen nun vor, die Fläche zwischen der Kurve und der Diagonalen als Fehlermaß zu verwenden. Das Prinzip ist schematisch in Abb. 4.15 dargestellt. Die gesuchte Fläche lässt sich ermitteln zu

$$J_{\text{NEES}} = \frac{1}{K} \cdot \sum_{k=1}^K \left| F_k^{\chi^2} - \frac{k}{K} \right|. \quad (4.77)$$

Die Kostenfunktion hat somit einen Wertebereich von 0 bis $\frac{1}{2}$.

In gleicher Weise lässt sich auch die Konsistenz der Innovations-Sequenz bewerten, indem die Konsistenzprüfung basierend auf dem NIS durchgeführt wird. Erwartet wird, dass der NIS für jeden Zeitschritt über die Monte-Carlo-Durchläufe Chi-Quadrat-verteilt ist mit dem Freiheitsgrad N_{MC} . Der Fehlerwert J_{NIS} ist dann das dritte Optimierungsziel der multikriteriellen

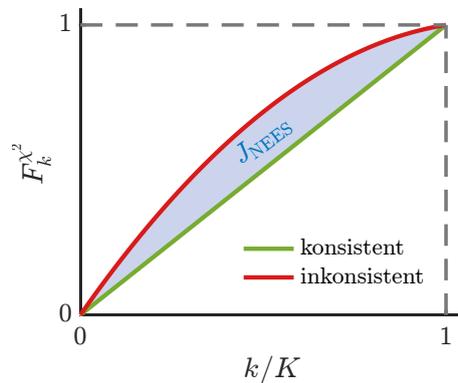


Abbildung 4.15: Schematische Darstellung zur Ermittlung einer Kostenfunktion basierend auf der Konsistenz. Angelehnt an Oshman und Shaviv [222].

Optimierung. Auch der Wertebereich von J_{NIS} ist nach oben auf $\frac{1}{2}$ begrenzt. Es ergibt sich als mehrdimensionales Optimierungsziel

$$\mathbf{J} = \{J_{RRMSE}, J_{NEES}, J_{NIS}\}. \quad (4.78)$$

Die Implementierung des multikriteriellen GAs erfolgt mithilfe der Funktion `gamultiobj` von MATLAB R2021b, welche auf dem NSGA-II Algorithmus von Deb [261] beruht. Die wichtigsten Einstellparameter der Funktion sind in Tabelle 4.6 aufgelistet. Es werden nur die sechs Hauptdiagonaleinträge von \mathbf{Q} optimiert. Zagrobelny und Rawlings schlagen vor, anstatt der Einträge selbst deren Quadratwurzel zu optimieren, um positive Werte für \mathbf{Q} zu erzwingen [228, S. 12]. Stattdessen wird in der vorliegenden Arbeit der dekadische Logarithmus der Einträge gewählt. Dadurch wird ebenfalls gewährleistet, dass der Wertebereich nur positive Werte umfasst. Gleichzeitig findet die Optimierung über einen weiten Suchbereich statt. Die Populationsgröße jeder Generation ist 200 Individuen. Die initiale Population wird zufällig gleichverteilt im Intervall von -15 bis 0 angelegt. Dieses Intervall hat sich durch Vorversuche als realistischer Wertebereich für eine Lösung herausgestellt. Das Pareto-Verhältnis gibt an, wie viel Prozent der Individuen, welche an der Selektion teilnehmen, aus der Pareto-Menge entnommen werden. Der restliche Anteil der Population besteht dann aus Individuen geringerer Dominanz, welche jedoch die Diversität der Population erhöhen. Dies ist für die Optimierung wichtig, da eine Beschränkung auf Individuen der Pareto-Menge das Finden möglicher anderer Optima verhindert [261, S. 233 ff.]. Aus der Population mit 200 Individuen stammen demnach 70 aus der Pareto-Menge (Individuen mit Rang 1). Die verbleibenden Lösungskandidaten werden gemäß der Crowding-Distance aus den Individuen höheren Ranges ausgewählt. Die Crowding-Distance

$$w_i = \sum_{j=1}^3 (J_{j,i+1} - J_{j,i-1}) \quad (4.79)$$

ist hierbei ein Maß für den Abstand des i -ten Individuums im Lösungsraum zu seinen direkten Nachbarn gleichen Ranges für die drei Teilziele der Mehrzieloptimierung. Die Individuen am Randbereich der Lösungsmenge des betreffenden Rangs weisen definitionsgemäß eine unendlich große Crowding-Distance auf. Durch die Selektion von Individuen mit großem w werden Lösungen

Tabelle 4.6: Parameter des GA-Optimierungsalgorithmus (umgesetzt in MATLAB R2021b).

Konfigurationsparameter	Wert
Algorithmus	NSGA-II [261]
Anzahl gesuchter Parameter	6
Optimierungsziele	J_{RRMSE} , J_{NEES} , J_{NIS}
Populationsgröße	200
Untersuchter Lösungsraum	$[-15, 0]$
Pareto-Verhältnis	35 %
Max. Generationen	50
Selektionsfunktion	Turnier
Rekombinationsverhältnis	80 %
Rekombinationsfunktion	<code>crossoverintermediate</code>
Mutations-Funktion	<code>mutationadaptfeasible</code>
Anzahl an Monte-Carlo-Durchläufen	30

entlang der gesamten Pareto-Front selektiert. Die Optimierung endet, wenn ein Minimum der Kostenfunktion gefunden wurde, spätestens aber nach 50 Generationen. Als Selektionsfunktion erlaubt die genutzte MATLAB-Funktion `gamultiobj` nur die Turnier-Selektion. Diese wählt aus einer beliebigen Anzahl (hier: vier) von Individuen der alten Generation das fitteste aus, um ein Individuum der neuen Generation zu selektieren. Je größer die Turniergröße gewählt wird, desto mehr steigt der Selektionsdruck an, da die Wahrscheinlichkeit für ein Individuum sinkt, ein Turnier zu gewinnen [263, S. 84f.]. Das Rekombinationsverhältnis gibt den Anteil der neuen Population an, welche durch die Rekombinationsfunktion erzeugt wird. Hierzu wird die Funktion `crossoverintermediate` gewählt, welche ein Kind zufällig innerhalb des Hyperwürfels platziert, welchen die beiden Eltern-Individuen als entgegengesetzte Ecken aufspannen. Demnach wird der durch die Population abgedeckte Lösungsraum mit der Rekombinationsfunktion reduziert. Durch die Mutationsfunktion `mutationadaptfeasible` werden die Individuen jedoch in zufällige Richtungen des Lösungsraums mutiert, wobei die vorgegebenen Grenzen des zu untersuchenden Wertebereichs eingehalten werden. Die Richtung der Mutation ist hierbei adaptiv in Abhängigkeit der letzten Population und deren Fitness [264]. Die Mutation vergrößert demnach den von der Population abgedeckten Lösungsraum wieder. Ohne Mutation kann der Algorithmus vorzeitig in ein lokales Minimum konvergieren [263, S. 42]. Die Optimierung verwendet als Trainingsdatensatz einen Ausschnitt des WLTP-Stromprofils aus der Validierung der Zellcharakterisierung (siehe Kapitel 3.2.3) mit einer Länge von 30 min. Für jeden der $N_{MC} = 30$ Monte-Carlo-Durchläufe wird das zufällige künstliche Sensorrauschen von Strom- und Spannungsmessung ebenso variiert wie die Startwerte. Diese werden zufällig gemäß der Normalverteilung $\mathcal{N}(\hat{\mathbf{x}}_{0|0} | \mathbf{x}_0, \hat{\mathbf{P}}_{0|0})$ gewählt.

Der multikriterielle GA gibt als Ergebnis die Pareto-Menge $\{\mathbf{J}_1, \mathbf{J}_2, \dots, \mathbf{J}_\xi, \dots, \mathbf{J}_\Xi\}$ mit $\Xi \leq 100$ und $\mathbf{J}_\xi = \{J_{RRMSE,\xi}, J_{NEES,\xi}, J_{NIS,\xi}\}$ der letzten Iteration zurück. Aus dieser Menge ist die für die Anwendung optimale Lösung als Kompromiss der Optimierungsziele zu wählen. Hierfür wird

ein Vorgehen in zwei Schritten umgesetzt: Zunächst wird im Lösungsraum der Schnittpunkt der hinsichtlich jedes Teilziels bestmöglichen Lösung aus der Pareto-Menge bestimmt.

$$\mathbf{J}_{\min} = \{\min(J_{\text{RRMSE}}), \min(J_{\text{NEES}}), \min(J_{\text{NIS}})\} \quad (4.80)$$

Anschließend wird dann als optimale Lösung der Optimierungsaufgabe derjenige Punkt ausgewählt, der diesem Punkt am nächsten liegt. Hierfür wird die euklidische Norm der Differenz $\mathbf{J}_{\min} - \mathbf{J}_{\xi}$ für jede Lösung der Pareto-Menge \mathbf{J}_{ξ} bestimmt und die Lösung mit dem kleinsten Resultat ausgewählt.

$$\mathbf{Q}_{\text{opt}} = \arg \min_{\mathbf{Q}_{\xi}} \|\mathbf{J}_{\min} - \mathbf{J}_{\xi}\| \quad \text{für } \xi = 1, \dots, \Xi \quad (4.81)$$

Zur Überprüfung der Optimierung erfolgt schließlich eine Validierung der gefundenen Kovarianzmatrix anhand eines Stromprofils basierend auf dem UDDS-Fahrzyklus (siehe Anhang A). Dadurch soll eine Überanpassung der Optimierung auf den Trainingsdatensatz verhindert werden.

4.3.2.2 Ergebnisse und Bewertung

Zunächst wird eine Optimierung von \mathbf{Q} basierend auf einem Batteriemodell (siehe Abb. 4.6) durchgeführt. Da das Kalman-Filter und die Referenz auf dem gleichen Modell beruhen, müssen im Prozessrauschen keine Modellfehler berücksichtigt werden. Durch diese simulative Untersuchung soll das Optimierungsverfahren selbst zunächst auf seine Eignung überprüft werden.

Zur Bewertung des Optimierungsprozesses ist in Abb. 4.16 der Verlauf der drei Fehlermaße über die 50 Iterationen des GAs dargestellt. Auf der linken Seite ist für jede Generation der jeweils beste Wert innerhalb der gesamten Population aufgetragen, wohingegen auf der rechten Seite die Fehlerwerte des besten Individuums dargestellt sind, welches gemäß (4.81) aus der Population bestimmt wurde. Da dieses Individuum einen Kompromiss aus den drei Fehlerdimensionen darstellt, sind dessen Werte in der Regel schlechter als der bestmögliche Wert innerhalb der Population. Wie aus Abb. 4.16a ersichtlich ist, sinken die Fehlerwerte über die Iterationen des GAs ab, wobei die Verbesserungen gegen Ende nur noch marginal sind. Die Generationen entwickeln sich daher gegenüber ihren Vorgänger-Generationen weiter. Abhängig davon, welches Individuum von der Pareto-Menge als beste Lösung identifiziert wird, fallen die einzelnen Fehlerwerte dieses Individuums unterschiedlich groß aus. Deswegen schwanken diese in Abb. 4.16b. Ab circa der fünften Generation bilden sich jedoch stabile Fehlerwerte heraus. J_{NEES} und J_{NIS} liegen deutlich unterhalb der oberen Grenze von 0,5. Auch der RRMSE erreicht ein zufriedenstellendes Niveau von ungefähr 0,1.

Die Pareto-Menge der letzten Generation ist in Abb. 4.17 im Fehlerraum dargestellt. Es ist deutlich zu erkennen, inwiefern jeder gefundene Lösungskandidat einen Kompromiss der drei Fehlerwerte darstellt. Eine Verbesserung des NEES geht mit einer Verschlechterung des NIS einher. Gleichzeitig verbessert sich aber auch der RRMSE. Die beste Lösung \mathbf{J}_{opt} und der euklidische Abstand zu \mathbf{J}_{\min} sind in der Abbildung ebenfalls eingezeichnet.

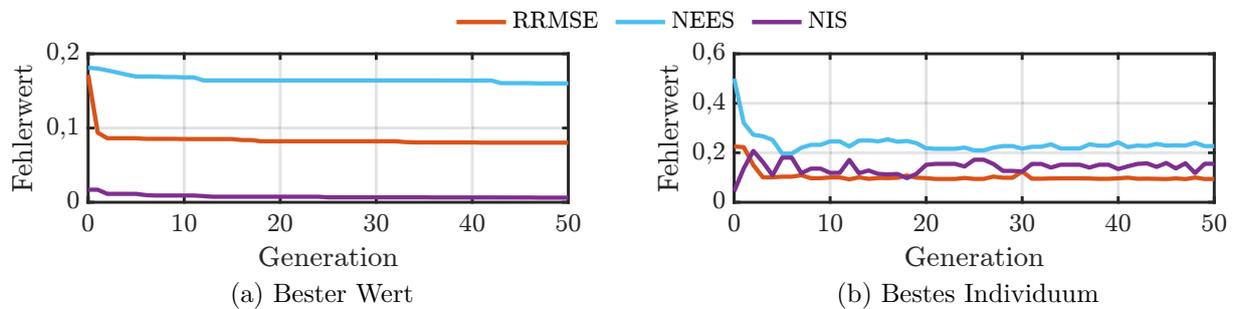


Abbildung 4.16: Verlauf der Kostenfunktionen über die Iterationen des GAs für die Simulation. Dargestellt ist jeweils für jede Generation der beste Wert innerhalb der Population für jede Dimension der Kostenfunktion und der Wert des innerhalb der jeweiligen Population insgesamt besten Individuums.

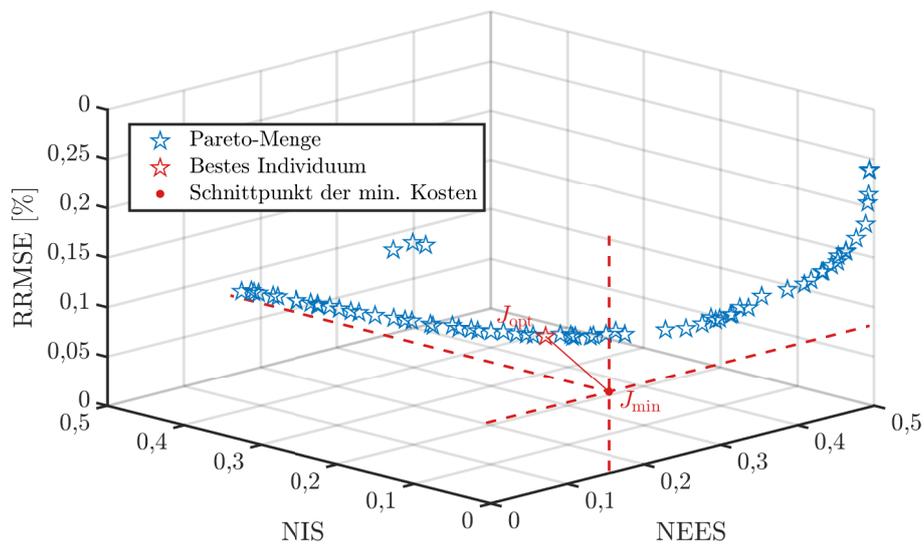


Abbildung 4.17: Pareto-Menge der letzten Generation des GAs für die Simulation. Das beste Individuum wird anhand des geringsten Abstands von J_{\min} ausgewählt.

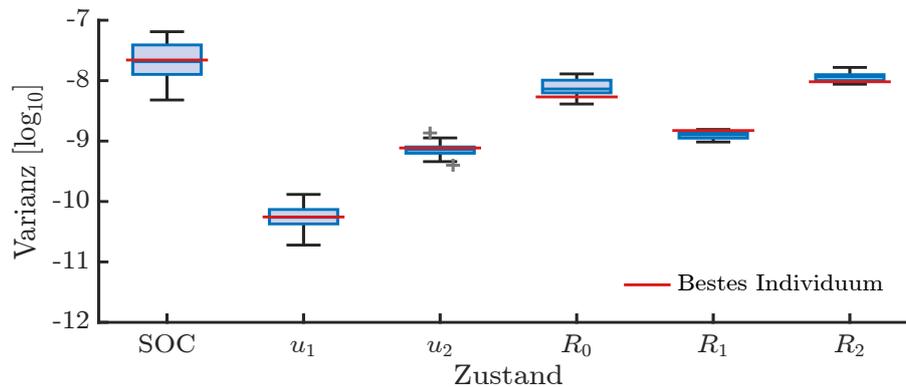


Abbildung 4.18: Box-Plot der Verteilung der Hyperparameter von 20 Lösungen innerhalb der Pareto-Menge basierend auf Simulationen, welche der optimalen Lösung am nächsten liegen. Die gewählte optimale Lösung ist mit den roten Linien besonders hervorgehoben. Die Werte für die Prozessvarianz sind im dekadischen Logarithmus angegeben.

Die optimale Lösung basierend auf der Simulation ist

$$\mathbf{Q}_{\text{opt,sim}} = \text{diag} \{2,2 \cdot 10^{-8} \quad 5,5 \cdot 10^{-11} \quad 7,7 \cdot 10^{-10} \quad 5,4 \cdot 10^{-9} \quad 1,5 \cdot 10^{-9} \quad 9,6 \cdot 10^{-9}\}. \quad (4.82)$$

Es ergeben sich daraus die Fehlermaße $\text{RRMSE} = 0,09$, $J_{\text{NEES}} = 0,23$ und $J_{\text{NIS}} = 0,16$. Die Anzahl an Monte-Carlo-Simulationen ist hierfür 30, wie auch in der Optimierung zuvor. Zur Validierung wird eine Zustands- und Parameterschätzung basierend auf dem UDDS-Fahrzyklus durchgeführt. Es ergibt sich ein RRMSE von 0,14, das Fehlermaß J_{NEES} ist 0,20 und J_{NIS} ist gleich 0,19. Damit liegen die Werte in einem ähnlichen Bereich wie die Resultate der Optimierung basierend auf der Trainingssequenz.

Wie Abb. 4.17 entnommen werden kann, liegen einige Elemente der Pareto-Menge in unmittelbarer Nachbarschaft der gewählten besten Lösung. Hier stellt sich nun die Frage, inwiefern sich diese Lösungen mit ähnlichen Fehlerwerten hinsichtlich \mathbf{Q} von der besten Lösung unterscheiden. Um diese Fragestellung zu beantworten, ist in Abb. 4.18 für jeden der Hauptdiagonaleinträge der Kovarianzmatrix ein Box-Plot derjenigen 20 Lösungen gezeigt, welche der besten Lösung im Fehlerraum am nächsten liegen. Die Einträge von \mathbf{Q} sind im Diagramm den Zuständen bzw. Parametern zugeordnet, dessen Prozessrauschen sie repräsentieren. Es fällt auf, dass insbesondere Q_{11} , welches die Varianz des SOC's repräsentiert, innerhalb der untersuchten Lösungsteilmenge um mehr als eine Größenordnung schwankt. Eine ähnliche Beobachtung kann auch für die Varianz von u_1 gemacht werden, wobei hier die Variation innerhalb der beiden mittleren Quartile jedoch deutlich kleiner ist. Das heißt, dass die Sensitivität dieser beiden Einträge von \mathbf{Q} auf die Fehlerwerte geringer sind, als bei den anderen Größen. Das beste Individuum ist ebenfalls im Diagramm eingezeichnet. Auffällig ist, dass dessen Werte auch am Rand der untersuchten Lösungsmenge liegen können, wie es für den Eintrag für R_0 der Fall ist. Neben Aussagen zur Sensitivität lässt sich aus dem Box-Plot-Diagramm schließen, dass die Fehlermaße in dem Sinne konsistent sind, als dass sich ähnliche Werte nur für die Fälle ergeben, für die auch \mathbf{Q} ähnlich gewählt ist.

Weiterhin können alle Lösungskandidaten der Pareto-Menge anhand J_{NEES} oder J_{NIS} sortiert werden, wie Abb. 4.19 jeweils links bzw. rechts gezeigt. Diese Sortierung entspricht einer Bewegung

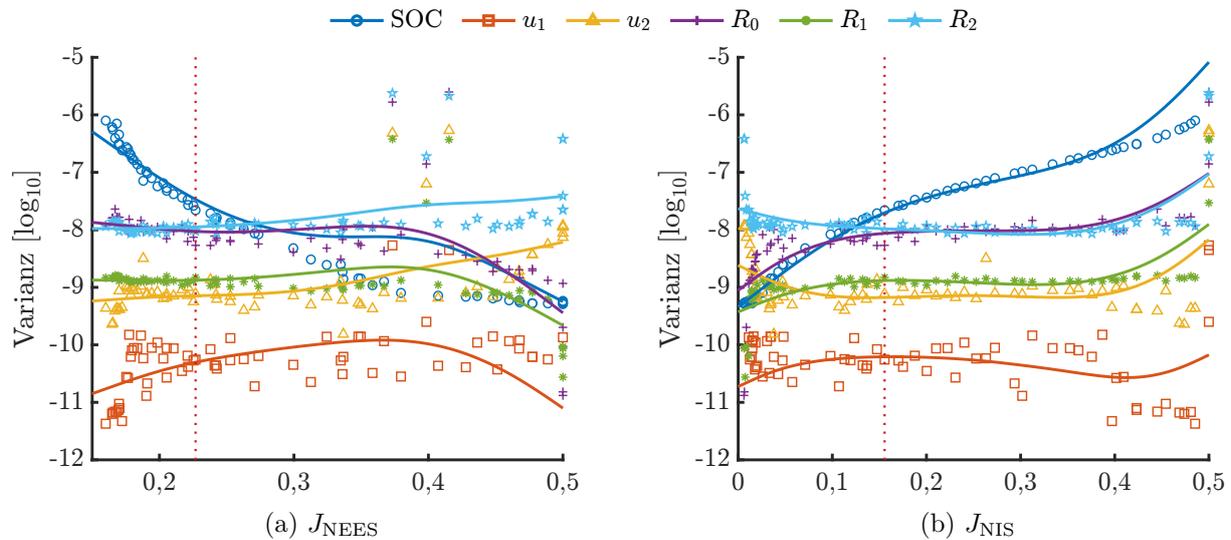


Abbildung 4.19: Einträge der Hauptdiagonalen der Kovarianzmatrix des Prozessrauschens aus der Pareto-Menge sortiert nach J_{NEES} und J_{NIS} . Durch den rot gepunkteten senkrechten Schritt ist der optimal ausgewählte Parametersatz markiert.

entlang der in Abb. 4.17 dargestellten Pareto-Front. Es ist zu beachten, dass die Y-Achse mit dem dekadischen Logarithmus skaliert ist. Der Verlauf der Hauptdiagonaleinträge von \mathbf{Q} abhängig von den beiden Fehlermaßen in Abb. 4.19 ist durch die Trendlinien verdeutlicht. Trotz Rauschen zeigen die Varianzen einen Trend, der mit der Veränderung der Gewichtung von J_{NEES} und J_{NIS} korreliert. Beispielsweise wird der Eintrag für den SOC mit steigendem J_{NIS} größer und fällt entsprechend, wenn J_{NEES} anwächst. Für $J_{NEES} \ll 0,5$ und $J_{NIS} \gg 0$ zeigt sich außerdem, dass die Rangordnung der Varianzen sich kaum verändert. Die Varianz für u_1 ist immer am kleinsten und die Varianzen für den SOC und R_0 sowie R_2 um mehrere Ordnungen größer. Es kann aus den Graphen geschlossen werden, dass die Fehlerfläche von \mathbf{J} abhängig von \mathbf{Q} nicht beliebig komplex ist, sondern vielmehr eine begrenzte Sensitivität der Einträge von \mathbf{Q} auf die Kostenfunktion vorherrscht. Andernfalls würden kleine Veränderungen des Prozessrauschens zu stark abweichenden Resultaten führen. Das ist jedoch nicht der Fall.

In einem zweiten Schritt werden nun die experimentellen Daten als Trainingsdaten für den GA herangezogen. Dadurch ergeben sich zwangsläufig Modellfehler, da das Batteriemodell des Kalman-Filters das reale Zellverhalten nur mit einer beschränkten Genauigkeit beschreibt. In Abb. 4.20 ist der Verlauf der drei Fehlermaße analog zur Simulation dargestellt. Die Betrachtung der besten Fehlerwerte innerhalb der Generationen in Abb. 4.20a weist eine hohe Ähnlichkeit zu den Ergebnissen der Simulation auf. Auch hier sinken die Fehler mit fortschreitender Optimierung ab, auch wenn J_{NEES} insgesamt größer ist. Betrachtet man dagegen die Fehlerwerte des besten Individuums in Abb. 4.20b, so zeigen sich signifikante Unterschiede für die experimentellen Daten im Vergleich zu Abb. 4.16. Als beste Lösung wird für die meisten Iterationen des Optimierungsalgorithmus eine solche gewählt, deren J_{NEES} mit 0,5 nah an der oberen Grenze liegt. Eine Konsistenz der Zustandsschätzung lässt sich demnach nicht erreichen, ohne eine Verschlechterung der anderen beiden Fehlermaße in Kauf zu nehmen. Hierzu sei angemerkt, dass die Referenzwerte, auf deren Basis der NEES berechnet wird, dem Batteriemodell entstammen, da die wahren Zustände des realen Systems unbekannt sind. Ein Konsistenz-Test mit dem NEES

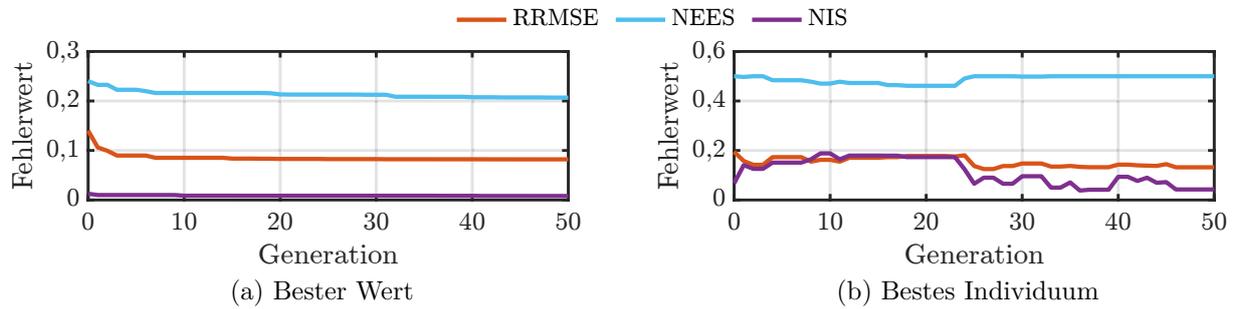


Abbildung 4.20: Verlauf der Kostenfunktionen über die Iterationen des GAs mit experimentellen Daten. Dargestellt ist jeweils für jede Generation der beste Wert innerhalb der Population für jede Dimension der Kostenfunktion und der Wert des innerhalb der jeweiligen Population insgesamt besten Individuums.

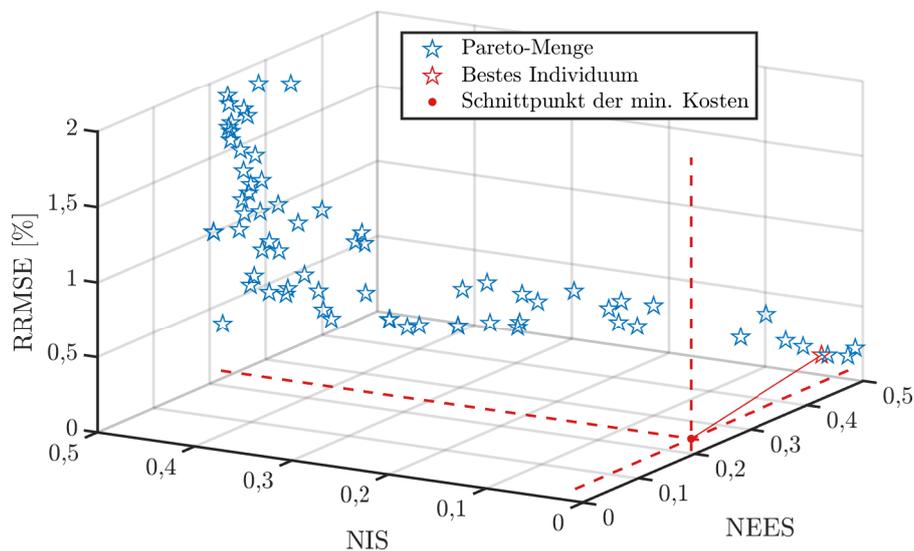


Abbildung 4.21: Pareto-Menge der letzten Generation des GAs für die experimentellen Daten. Das beste Individuum wird anhand des geringsten Abstands von \mathbf{J}_{\min} ausgewählt und ist rot markiert.

ist laut Bar-Shalom et al. [190, S. 234] dann gar nicht möglich, weswegen die hier erreichte Lösung nachvollziehbar erscheint.

Die resultierende Pareto-Menge und der beste Lösungskandidat ist in Abb. 4.21 dargestellt. Es zeigt sich, dass dieser am Rand der Pareto-Front liegt und nur einen schlechten Kompromiss zwischen J_{NEES} und J_{NIS} bedeutet. Gleichzeitig ist ersichtlich, dass gleichermaßen gute Werte für J_{NEES} zu einem hohen RRMSE führen. Die mit dem GA gefundene beste Lösung basierend auf realen Daten ist

$$\mathbf{Q}_{\text{opt,exp}} = \text{diag} \{4,2 \cdot 10^{-9} \quad 1,1 \cdot 10^{-10} \quad 1,2 \cdot 10^{-8} \quad 3,3 \cdot 10^{-9} \quad 6,3 \cdot 10^{-12} \quad 2,0 \cdot 10^{-11}\}. \quad (4.83)$$

Damit ergeben sich die Fehlerwerte im Training zu $J_{RRMSE} = 0,13$, $J_{NEES} = 0,50$ und $J_{NIS} = 0,04$. Wieder erfolgt eine Validierung anhand des UDDS-Fahrzyklus und es ergibt sich ein RRMSE von 0,20, J_{NEES} beträgt 0,50 und J_{NIS} ist 0,06.

Damit liegen Hyperparameter für die Zustands- und Parameterschätzung sowohl mit simulativen als auch realen Daten vor. Eine Analyse der resultierenden Schätzung wird in Abschnitt 4.5 gegeben.

Für das DKF in Kapitel 6.2 werden ebenfalls die Kovarianzmatrizen des Prozessrauschens mittels GA optimiert. Es ergibt sich $\mathbf{Q}_x = \text{diag}\{[10^{-8} \ 10^{-7} \ 10^{-8}]\}$ für den Zustandsschätzer mit $n = 3$ und $Q_\theta = 10^{-6}$ für den Parameterschätzer.

4.3.3 Fazit zum Filter-Tuning

Nachdem das Kalman-Filter-Tuning fast genauso lange wie das Kalman-Filter selbst Gegenstand der Forschung ist, bieten die heutigen Rechenkapazitäten die Möglichkeit, Optimierungsverfahren für die Bestimmung der gesuchten Kovarianzmatrizen einzusetzen. Der im Rahmen dieser Arbeit verwendete GA mit drei unabhängigen Fehlermaßen ist grundsätzlich in der Lage, das Prozessrauschen anhand von experimentellen Trainingsdaten zu bestimmen. Es wird jedoch deutlich, dass die Konsistenz der Schätzung anhand realer Daten nicht überprüft werden kann, da die Referenzwerte selbst inkonsistent zu den unbekannt realen Zuständen des Systems sind. Trotzdem ergeben sich Hyperparameter, welche zumindest bezüglich des RRMSEs und des NIS gute Ergebnisse liefern. Es zeigt sich aber auch, dass trotz des methodischen Vorgehens eine Bewertung der Ergebnisse durch den Anwender notwendig ist, um aus der Pareto-Menge eine geeignete Lösung zu wählen. Das in diesem Kapitel vorgestellte Kriterium der minimalen Distanz zu \mathbf{J}_{\min} ist nur eine Möglichkeit, passende Hyperparameter zu erhalten. Nichtsdestotrotz können die Lösungen der Pareto-Menge der multikriteriellen Optimierung als pareto-optimal angesehen werden, wodurch die Anwendung des Verfahrens gerechtfertigt ist.

4.4 Verbesserung der Zustands- und Parameterschätzung in Batteriesystemen

In der realen Anwendung von Kalman-Filtern zur Zustands- und Parameterschätzung in BMSs sind die Voraussetzungen für eine optimale Zustandsschätzung in der Regel nicht erfüllt. Beispielsweise beschreibt das verwendete Modell das Systemverhalten unvollständig. Wang et al. [96] untersuchen die Korrelation zwischen den Fehlern verschiedener Batteriemodelle mit den Schätzfehlern, welche ein auf diesen Modellen beruhendes Kalman-Filter erzielt. Die Autoren stellen fest, dass ein Zusammenhang zwischen der Modellgüte und der Performanz der Zustandsschätzung besteht. Weitere Untersuchungen zum Einfluss von Modellfehlern auf Schätzverfahren in BMSs stammen von Zhang et al. [265], Zheng et al. [266] sowie Lai et al. [143].

Weiterhin beeinflussen systematische Fehler der Strom- und Spannungsmessung die SOC-Schätzung. Die Bestimmung des Ladezustands über die Leerlaufspannung kann durch einen Fehler des Spannungssensors signifikant beeinträchtigt werden, wohingegen sich beim Coulomb-Counting Fehler des Stromsensors aufsummieren und zu Fehlern der Schätzung führen [266]. Den Einfluss von Sensorfehlern auf die Zustandsschätzung untersuchen Lai et al. [143] und Li et al. [202]. Ren et al. [267] beaufschlagen die Strom- und Spannungsmessung mit einem Bias von 20 mA bzw.

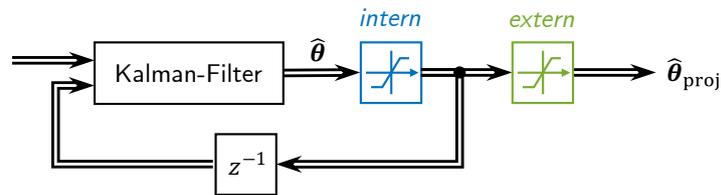


Abbildung 4.22: Begrenzung der Parameterschätzung durch interne (blau) und externe (grün) Beschränkung.

20 mV und berücksichtigen die Sensorfehler als zusätzlichen Systemzustand eines DKFs. Dadurch erhöht sich die Robustheit des Filters und die Genauigkeit der Ladezustandsschätzung.

Das Kalman-Filter wird als Verfahren in einer Vielzahl von Anwendungsbereichen eingesetzt. Die Ladezustands- und Modellparameterschätzung in Batteriesystemen ist nur ein kleiner Teilbereich dessen. In der Literatur finden sich viele Ergänzungen und Erweiterungen, welche das generelle Kalman-Filter für spezielle Anwendungsfälle modifizieren. Im Folgenden werden einige dieser Modifikationen vorgestellt, die den Besonderheiten der Schätzverfahren in Batteriesystemen Rechnung tragen.

4.4.1 Berücksichtigung physikalischer Grenzen

Während des Einsatzes des Kalman-Filters können unplausible Schätzungen für die Zustände und Parameter auftreten. Dies kann beispielsweise ein negativer Wert für den Innenwiderstand sein. Unter Berücksichtigung von Vorwissen über die physikalische Bedeutung der Zustände und Parameter kann deren Wertebereich mit

$$\theta_{\min} \leq \hat{\theta} \leq \theta_{\max} \quad (4.84)$$

beschränkt und damit die Robustheit der Schätzung erhöht werden. Für das verwendete Batteriemodell kann als untere Schranke für R_0 , R_1 und R_2 , sowie C_1 und C_2 bzw. τ_1 und τ_2 der Wert 0 gewählt werden, da nur positive Werte physikalisch sinnvoll sind. Grundsätzlich ließen sich auch für den SOC Schranken definieren, da dessen Wertebereich theoretisch auf das Intervall $[0, 1]$ beschränkt ist. Allerdings bezieht sich der SOC auf diejenige Kapazität, welche der Batteriezelle mit einer definierten Stromrate entnommen werden kann. Daher stellen sich mitunter auch Werte kleiner null ein, wenn die Entladung mit geringeren Strömen erfolgt.

Rhode und Gauterin [268] schlagen eine Projektion der geschätzten Parameter auf die Parameterschranken vor, sobald diese überschritten werden (siehe Algorithmus 4.4). Die Schätzung wird also am Ende jeder Iteration des Filters bei Bedarf auf die Grenzen zurückgesetzt. Im Gegensatz zu externen Parametergrenzen, bei welchen der Filter mit den (unplausiblen) Werten weiter rechnet und nur die Ausgabe beschränkt ist, verwendet das Filter bei einer internen Parameterbeschränkung die projizierten Werte im nächsten Zeitschritt [269, S. 134]. In diesem Fall ist die Schätzung jedoch nicht mehr optimal, da zwar der Schätzwert \hat{x} , aber nicht die Kovarianz \hat{P} korrigiert wird. Der Unterschied zwischen interner und externer Parameterbeschränkung ist in Abb. 4.22 gezeigt.

Algorithmus 4.4 Parameter-Projektion nach Rhode und Gauterin [268]

Eingang: $\hat{\boldsymbol{\theta}}, \boldsymbol{\theta}_{\min}, \boldsymbol{\theta}_{\max}$
for $j = 1 \dots n$ **do**
 if $\hat{\theta}_j < \hat{\theta}_{j,\min}$ **then**
 $\hat{\theta}_{j,\text{proj}} = \hat{\theta}_{j,\min}$
 else if $\hat{\theta}_j > \hat{\theta}_{j,\max}$ **then**
 $\hat{\theta}_{j,\text{proj}} = \hat{\theta}_{j,\max}$
 end if
end for
Ausgang: $\hat{\boldsymbol{\theta}}_{\text{proj}}$

Ein weiteres Verfahren der internen Parameterbeschränkung stellen Gupta und Hauser [270] vor. Anstatt die a posteriori Schätzung der Parameter zu korrigieren, wird die Kalman-Verstärkung derart gewählt, dass die Parameter nach dem Korrekturschritt des Kalman-Filters im gültigen Wertebereich liegen. Die Wahl der Kalman-Verstärkung kann als Optimierungsproblem mit Nebenbedingung formuliert werden zu

$$\mathbf{K}_{\text{opt}} = \arg \min_{\mathbf{K}_k} \text{spur} \{ (\mathbf{I} - \mathbf{K}_k \mathbf{C}) \hat{\mathbf{P}}_{k|k-1} (\mathbf{I} - \mathbf{K}_k \mathbf{C})^T + \mathbf{K}_k \mathbf{R} \mathbf{K}_k^T \} \quad (4.85a)$$

$$\text{mit Nebenbedingung: } \mathbf{Z} (\hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \mathbf{e}_k) \leq \mathbf{b}, \quad (4.85b)$$

wobei

$$\mathbf{Z} = \begin{bmatrix} \mathbf{I} \\ -\mathbf{I} \end{bmatrix} \quad \text{und} \quad \mathbf{b} = \begin{bmatrix} \boldsymbol{\theta}_{\max} \\ \boldsymbol{\theta}_{\min} \end{bmatrix}.$$

Auch die herkömmliche Herleitung der Kalman-Verstärkung minimiert die Spur der korrigierten Fehlerkovarianzmatrix $\hat{\mathbf{P}}_{k|k}$. Durch die zusätzliche Nebenbedingung wird jedoch garantiert, dass die festgelegten Parametergrenzen eingehalten werden. Außerdem wird auch die a posteriori Kovarianzmatrix korrekt bestimmt, was ein Vorteil des Verfahrens ist. Nachteilig zu bewerten ist der hohe Rechenaufwand, da das Minimierungsproblem in (4.85) in aller Regel keine geschlossene Lösung aufweist und durch einen iterativen Algorithmus gelöst werden muss. Der hierfür benötigte Rechenaufwand liegt in aller Regel über der verfügbaren Rechenkapazität eines BMS.

Ein echtzeitfähiges Verfahren zur Beschränkung der Parameter stellt Beyer [269, S. 138 ff.] vor, bei dem durch sogenannte weiche Grenzen die Schätzwerte bei Überschreiten der Parametergrenzen in den gültigen Bereich korrigiert werden (siehe Algorithmus 4.5). Durch die Wahl des Parameters c kann die Stärke der Korrektur eingestellt werden. Sie ist weiterhin abhängig von der Kovarianz $\hat{\mathbf{P}}$, sodass die Korrektur stärker ausfällt, wenn die Schätzunsicherheit groß ist.

In der Praxis zeigt sich, dass die optimale Wahl von c herausfordernd ist. Wird der Parameter zu klein gewählt, werden die Schätzungen nicht effektiv korrigiert. Bei einem zu großen c besteht jedoch die Gefahr, dass die Korrektur zu stark ist und die Schätzung über das Maß hinaus in entgegengesetzte Richtung korrigiert wird. Dieser Fall tritt insbesondere dann auf, wenn $\hat{\mathbf{P}}$ große Werte annimmt. Wie die späteren Ergebnisse zeigen werden, ist der in dieser Arbeit eingesetzte Schätzer hinreichend genau, sodass die Parametergrenzen nicht erreicht werden. Daher ist die Parametrierung der Begrenzung für die im Rahmen dieser Arbeit vorgestellte

Algorithmus 4.5 Weiche Parametergrenzen nach Beyer [269, S. 138 ff.]

Eingang: $\hat{\theta}$, \hat{P} , θ_{\min} , θ_{\max}
for $j = 1 \dots n$ **do**
 if $\hat{\theta}_i < \hat{\theta}_{j,\min}$ **then**
 $\hat{\theta}_{j,\text{proj}} = \hat{\theta}_{j,\min}$
 else if $\hat{\theta}_i > \hat{\theta}_{j,\max}$ **then**
 $\hat{\theta}_{j,\text{proj}} = \hat{\theta}_{j,\max}$
 end if
end for
 $\hat{\theta} = \hat{\theta} - c\hat{P}(\hat{\theta} - \hat{\theta}_{\text{proj}})$
Ausgang: $\hat{\theta}$

Zustands- und Parameterschätzung von geringerer Relevanz. Abhängig von den Randbedingungen wie beispielsweise die Stärke der Anregung oder der Größe des Ohmschen Widerstands der untersuchten Batteriezelle kann eine Beschränkung der Parameter jedoch sinnvoll sein.

4.4.2 Einbeziehen der Hysterese der Zellspannung

Die im Rahmen dieser Arbeit verwendeten Ersatzschaltbildmodelle der Lithium-Ionen-Zellen vernachlässigen eine mögliche Hysterese der Zellspannung, welche abhängig vom Ladezustand ist. Barai et al. [152] konnten für eine prismatische NMC-Zelle eine Hysterese von bis zu 20 mV bei niedrigem SOC feststellen. Aus der Zellcharakterisierung aus Kapitel 3.2 ergibt sich eine Hysterese von maximal 160 mV (siehe Abb. 4.23), allerdings beinhaltet diese auch Effekte aufgrund eines nicht vollständigen Einschwingens nach dem Lade- bzw. Entladevorgang. Im Bereich von 20% bis 100% SOC beträgt die Hysterese nur 16 mV. Durch die Vernachlässigung der Hysterese im Modell sinkt dessen Genauigkeit und die Zustands- und Parameterschätzung verschlechtert sich.

Es existieren von Plett [156] Batteriemodelle verschiedener Ordnung, welche die Hysterese als zusätzlichen Systemzustand schätzen und ihr so Rechnung tragen. Allerdings unterscheiden sich diese Modelle stark von den im Rahmen dieser Arbeit verwendeten und beinhalten viele Parameter, die manuell eingestellt werden müssen.

Anstatt das Batteriemodell um die Hysterese zu erweitern, modifizieren Maletić et al. [206] den Kalman-Filter-Algorithmus weitaus pragmatischer. Da Modellfehler aufgrund der nicht berücksichtigten Hysterese vornehmlich bei einem Wechsel der Stromrichtung auftreten, erhöhen die Autoren die Kovarianzmatrix des Prozessrauschens um einen konstanten Wert immer für diejenigen Zeitschritte, in welchen ein solcher Wechsel detektiert wird. Das Filter gewichtet in der folgenden Iteration die Prädiktion des Modells weniger stark, sodass der geringeren Modellgenauigkeit bei Vorzeichenwechseln des Stroms Rechnung getragen wird. Da das der Veröffentlichung zugrunde liegende Elektrofahrzeug, in dessen BMSs die Zustandsschätzung implementiert wird, keine Rekuperationsfähigkeit hat, findet ein Wechsel der Stromrichtung jedoch nur beim stationären Laden der Batterie statt. Der Betrag der Erhöhung der Kovarianz ist ein heuristischer Wert, der frei gewählt werden kann und auf der Größe der Hysterese beruht.

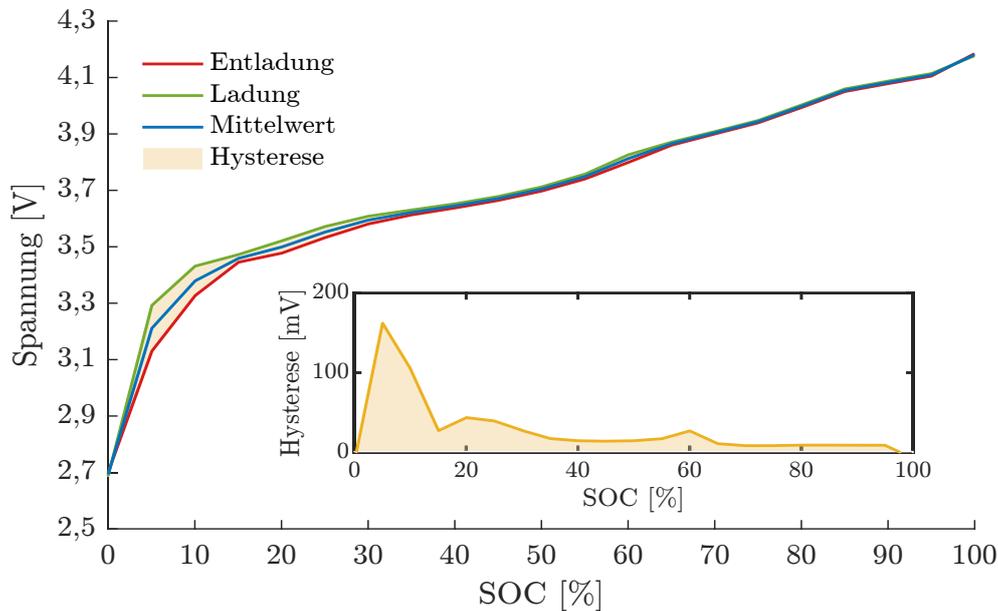


Abbildung 4.23: Hysterese der OCV-Kurve basierend auf der durchgeführten Zellcharakterisierung.

Dies ist für die Anwendung der Modifikation von Nachteil, da keine nachvollziehbare Methodik für die Bestimmung dieses Wertes existiert.

Um das Potenzial der Hysterese-Kompensation nach Maletić et al. zu beurteilen, wird das Verfahren für die Zustandsschätzung basierend auf realen Messdaten untersucht und mit dem herkömmlichen Ansatz verglichen. Die zugrunde liegende Stromanregung ist das UDDS-Profil. Immer, wenn in einem Iterationsschritt des Kalman-Filters das Vorzeichen des Anregungsstroms im Vergleich zum vorherigen diskreten Zeitschritt wechselt, wird das Prozessrauschen für den j -ten Hauptdiagonaleintrag um einen Faktor c_j erhöht. Der für jeden Zustand bzw. Parameter optimale Faktor wird mit der MATLAB-Funktion `fminsearch` mit der Simplex-Methode bestimmt, sodass der resultierende Mittelwert der RMSEs der sechs Zustände minimal wird. Es ergibt sich als Vektor der Faktoren des Verfahrens

$$\mathbf{c} = [16,5 \ 4250 \ 0 \ 101 \ 0 \ 424]. \quad (4.86)$$

Die resultierenden RMSEs im Vergleich zum herkömmlichen Schätzverfahren sind in Abb. 4.24 dargestellt. Zu beachten ist, dass die Einheit des RMSEs für den SOC Prozentpunkte, für die Überspannungen Millivolt und für die Widerstände Milliohm beträgt.

Wie dem Balkendiagramm entnommen werden kann, lässt sich durch die Hysterese-Kompensation eine Reduktion der Schätzfehler um 2% bis 40% erreichen. Während die SOC-Schätzung kaum genauer wird, sinken insbesondere die Fehler für u_2 und R_2 stark. Bei der Bewertung des Verfahrens ist allerdings zu beachten, dass der Vektor der Faktoren \mathbf{c} für die speziellen Messdaten optimiert wurden. Daher sind die Ergebnisse eine Best-Case-Abschätzung, welche in der Anwendung kaum zu erreichen ist, da die optimalen Faktoren der Hysterese-Kompensation nicht bekannt sind. Das zeigt auch eine Validierung auf Basis des WLTP-Stromprofils, bei der

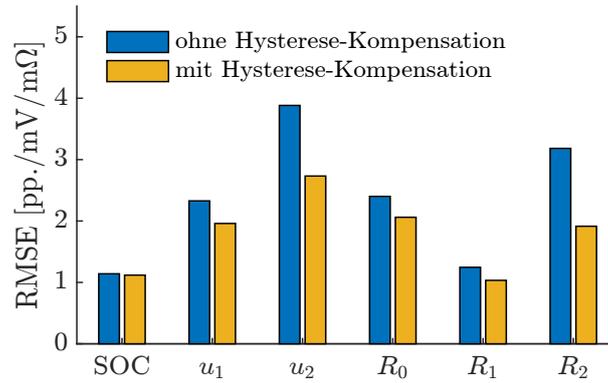


Abbildung 4.24: Verbesserung der RMSEs der Zustands- und Parameterschätzung mit der Hysterese-Kompensation nach Maletić et al. [206] (Stromprofil: UDDS).

sich die Schätzfehler mit dem gefundenen \mathbf{c} nicht verringern, sondern um 50 % verschlechtern. Das Verfahren kommt deshalb im weiteren Verlauf nicht zur Anwendung.

4.4.3 Stabilisierung der Schätzung durch Pseudo-Messwerte

Insbesondere, wenn die Anzahl an zu bestimmenden Zuständen und Parametern groß ist, ist eine Konvergenz der Schätzung zu den physikalisch richtigen Werten nicht garantiert. Dann kann eine Stabilisierung der Zustandsschätzung durch Pseudo-Messwerte sinnvoll sein.

Plett [175] erweitert die Ladezustandsschätzung um eine weitere Messung

$$z_k = u_{OC}^{(-1)}(u_{zelle,k} - R_{0,k}i_{zelle,k}), \quad (4.87)$$

welche basierend auf der invertierten OCV-Funktion eine stark verrauschte Schätzung des SOC's ist. Die Überspannungen der RC-Glieder werden hier vernachlässigt, weswegen (4.87) nur eine grobe Näherung des SOC's ist und nur über längere Zeiträume als mittelwertfrei gelten kann. Der Innenwiderstand wird beispielsweise durch die Parameterschätzung eines DKF's bestimmt.

In [27] erweitern die Autoren die Messgleichung eines SPKF's zur Parameterschätzung um die relative Differenz zu einem vorgegebenen Parametervektor $\boldsymbol{\theta}_0$. Dieser wird auf Basis der vorherigen Zellcharakterisierung bestimmt und dient als Orientierungswert, um den die Parameterschätzung schwanken darf. Als Messgleichung erhält man

$$\begin{bmatrix} y_k \\ \mathbf{0} \end{bmatrix} = \begin{bmatrix} h(\mathbf{x}_k, \boldsymbol{\theta}_k, u_k) \\ \frac{\hat{\boldsymbol{\theta}}_k - \boldsymbol{\theta}_0}{\boldsymbol{\theta}_0} \end{bmatrix} + \begin{bmatrix} r_k \\ \mathbf{r}_{z,k} \end{bmatrix}. \quad (4.88)$$

Mit der Randbedingung, dass $\mathbf{r}_z = \mathcal{N}(\mathbf{0}, \boldsymbol{\Sigma}_0)$, es sich bei der relativen Differenz also um eine mittelwertfreie Normalverteilung handelt, wird ein Wegdriften der Schätzung $\hat{\boldsymbol{\theta}}$ von $\boldsymbol{\theta}_0$ verhindert. Bei dieser Modifikation der Parameterschätzung muss die Stärke der Stabilisierung durch die Wahl von $\boldsymbol{\Sigma}_0$ von Hand eingestellt werden. Ebenso ist die Wahl von $\boldsymbol{\theta}_0$ beliebig, sodass der Erfolg der Modifikation von ihrer konkreten Applikation abhängt. Insbesondere verhindern Pseudo-Messwerte eine Adaption des Modells, wenn die vorgegebenen Parameter beispielsweise mit

zunehmender Alterung vom wahren Wert abweichen. Auch diese Modifikation des Kalman-Filters findet daher in dieser Arbeit keine Verwendung.

4.4.4 Vernachlässigung unplausibler Kovarianzen

Die Systemgleichung des Ersatzschaltbildmodells im Zustandsraum gemäß (3.6a) für $n = 3$ kann als JKF aufgefasst werden, da die Veränderung des Ladezustands abhängig vom Strom auf der einen Seite und das elektrische Verhalten der RC-Glieder auf der anderen Seite in einem System zusammengefasst sind. Tatsächlich gibt es jedoch keine physikalisch motivierte Korrelation zwischen den Zuständen SOC, u_1 oder u_2 . Während die Modellierung des Ladezustands auf dem Coulomb-Counting beruht, sind die Überspannungen Ergebnisse des ECMs, welches derart das dynamische Zellverhalten abbildet. Während des Korrekturschritts des Kalman-Filters können jedoch fälschlicherweise Korrelationen auftreten, was sich durch Einträge ungleich null auf den Nebendiagonalen der Kovarianzmatrix $\hat{\mathbf{P}}_{k|k}$ äußert.

Yang et al. [242] schlagen deshalb vor, den Ladezustand und die Überspannungen in zwei separaten Filtern zu schätzen. Es ergibt sich ein DKF. Dadurch werden die physikalisch nicht begründeten Korrelationen zwischen den Zuständen vermieden. Die Autoren stellen fest, dass insbesondere zu Beginn die Schätzwerte weniger stark schwanken und schneller konvergieren.

Ein vergleichbares Ergebnis lässt sich auch ohne Auftrennung der Zustandsgleichungen erzielen, indem die unerwünschten Korrelationen der Zustände vernachlässigt werden. Dazu müssen am Ende jedes Korrekturschritts des Kalman-Filters die Einträge auf den Nebendiagonalen der Kovarianzmatrix $\hat{\mathbf{P}}_{k|k}$ auf null gesetzt werden. Hierzu kann das Hadamard-Produkt genutzt werden, welches hier durch den Operator \odot repräsentiert wird. Für eine Zustandsschätzung mit $n = 3$ ergibt sich

$$\hat{\mathbf{P}}_{k|k} \leftarrow \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \odot \hat{\mathbf{P}}_{k|k}. \quad (4.89)$$

Wenn in einem Joint-Extended-Kalman-Filter (JEKF) neben den Zuständen auch weitere Modellparameter geschätzt werden sollen, müssen die Korrelationen der Zustände differenzierter betrachtet werden. Exemplarisch werde das JEKF der Ordnung $n = 8$ mit dem Zustandsvektor

$$\hat{\mathbf{x}} = [\text{SOC} \quad u_1 \quad u_2 \quad R_0 \quad R_1 \quad R_2 \quad \tau_1 \quad \tau_2]^T$$

untersucht. Es werden demnach alle Parameter des Ersatzschaltbildmodells geschätzt. Zwischen der Modellierung des SOCs, den RC-Gliedern sowie dem Innenwiderstand besteht kein physikalischer Zusammenhang. Dahingegen beziehen sich u_1 , R_1 und τ_1 auf das gleiche elektrische

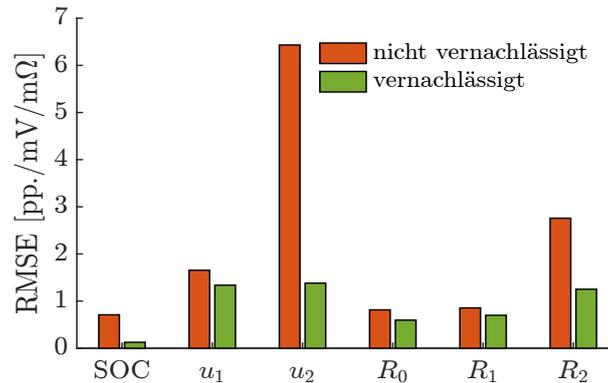


Abbildung 4.25: Verbesserung der RMSEs der Zustands- und Parameterschätzung mit bzw. ohne Vernachlässigung unplausibler Kovarianzen (Simulation, Stromprofil: UDDS).

System, weswegen eine Korrelation begründet ist. Für das zweite RC-Glied gilt diese Aussage analog. Die unerwünschten Korrelationen können demnach wie folgt getilgt werden:

$$\hat{\mathbf{P}}_{k|k} \leftarrow \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 1 \\ 0 & 1 & 0 & 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 1 \end{bmatrix} \ominus \hat{\mathbf{P}}_{k|k}. \quad (4.90)$$

Das Balkendiagramm in Abb. 4.25 zeigt die resultierenden RMSEs von zwei Simulationen basierend auf dem UDDS-Stromprofil, wobei einmal die unplausiblen Kovarianzen vernachlässigt wurden. Der Zustandsvektor hat die Ordnung $n = 6$. Es ist deutlich zu erkennen, wie sich die Schätzgenauigkeit durch diese Modifikation des Kalman-Filters verringern. Der Fehler des SOC lässt sich so auf ein Fünftel verkleinern und auch für u_2 bzw. R_2 ist die Verbesserung deutlich. Im Mittel sinkt der RMSE aller Zustände und Parameter um 47%. Zu beachten ist, dass diese Löschung unplausibler Kovarianzen für das vorgestellte Verfahren zum Kalman-Filter-Tuning in Abschnitt 4.3 erst nach der Berechnung der Konsistenzmaße NEES und NIS erfolgte. Diese berücksichtigen folglich auch die Kovarianzen, welche sich innerhalb einer Iteration des Kalman-Filters ergeben.

4.5 Ergebnisse der Zustands- und Parameterschätzung

Zum Abschluss dieses Kapitels werden die entwickelten Verfahren zur Zustands- und Parameterschätzung anhand von Simulationen und realen Messdaten validiert. Es kommt wie zuvor ein JEKF der Ordnung $n = 6$ mit den Hyperparametern zum Einsatz, welche im Abschnitt 4.3

Tabelle 4.7: Ergebnisse der Zustands- und Parameterschätzung für Simulation und Experiment (Stromprofil: UDDS).

Zustand	Simulation		Experiment	
	RMSE	RRMSE	RMSE	RRMSE
SOC	0,1 pp.	0,1 %	1,2 pp.	2,4 %
u_1	0,7 mV	28,8 %	2,0 mV	106,0 %
u_2	0,7 mV	7,2 %	1,9 mV	18,0 %
R_0	0,4 m Ω	1,5 %	1,3 m Ω	5,0 %
R_1	0,4 m Ω	10,8 %	1,1 m Ω	40,7 %
R_2	0,7 m Ω	4,6 %	1,4 m Ω	9,2 %

ermittelt wurden. Für die Systemanregung wird das UDDS-Stromprofil genutzt, welches nicht zum Trainingsdatensatz für das Filter-Tuning verwendet wurde.

Zunächst betrachten wir die Ergebnisse einer Simulation. Dadurch ist das Modellwissen des Filters ideal und die Referenzwerte sind exakt bekannt. Eine Batteriezelle wird ausgehend von einem Ladezustand von 90 % durch das wiederholte Anwenden des Stromprofils entladen, bis ein SOC von 10 % erreicht ist. Die Ergebnisse der Schätzung sind in Abb. 4.26 für das Validierungsprofil dargestellt.² Die Schätzungen der Zustände und Parameter sind konsistent. Weiterhin fällt auf, dass die Konfidenzintervalle stark schwanken. Dies ist darauf zurückzuführen, dass sich die Messfunktion h abhängig vom Anregungsstrom stark ändert, weil der Systemeingang ein Teil dieser ist. Über die Korrektur der Kovarianz des EKF's (siehe Algorithmus 4.2) ändert sich die Größe der a posteriori Kovarianz der Schätzung mit zunehmendem und abnehmendem Strom.

Es ergeben sich für die Schätzung mit simulativen Daten RMSEs und RRMSEs gemäß der mittleren Spalte von Tabelle 4.7. Hier fällt der relativ große RRMSE von u_1 auf, allerdings ist der RMSE in einer Größenordnung mit u_2 , sodass der hohe RRMSE aus den geringen absoluten Werten der Spannung resultiert. Die SOC-Schätzung ist überaus exakt, aber auch die Widerstände werden mit einer guten Genauigkeit geschätzt: Der Fehler liegt unter 1 m Ω .

Als Test der Konsistenz kann auch die Autokorrelation der Innovationssequenz nach (4.31) überprüft werden. Für die Simulation ist diese in Abb. 4.27a zusammen mit dem Konfidenzintervall dargestellt, welches dem dreifachen SE in positiver und negativer Richtung entspricht. Es zeigt sich, dass die Innovationssequenz zwar nur eine geringe Autokorrelation für Verschiebungen um mehr als einen Zeitschritt aufweist, diese jedoch größer ist, als aufgrund des SEs zu erwarten ist. Die verschobene Innovationssequenz ist demnach leicht negativ mit der ursprünglichen Sequenz korreliert. Dies deckt sich mit dem Ergebnis der Validierung $J_{NIS} = 0,19$ aus Kapitel 4.3.

Die Ergebnisse des realen Versuchs für das UDDS-Profil zeigt Abb. 4.28.² Neben Limitierungen des Filters an sich beeinflussen nun auch Modellierungsfehler die Ergebnisse. Zunächst fällt auf, dass die Schätzung signifikant zu optimistisch ist. Die 3σ -Grenzen sind abgesehen von R_0 und u_2 deutlich zu klein, sodass keine konsistenten Schätzergebnisse erzielt werden. Dies entspricht jedoch der Erwartung, welche die Ergebnisse des Filter-Tunings in Kapitel 4.3 gezeigt haben.

²Die Ergebnisse der Schätzung mit dem WLTP-Stromprofil sind in Abb. E.4 (Simulation) und Abb. E.5 (Experiment) in Anhang E dargestellt.

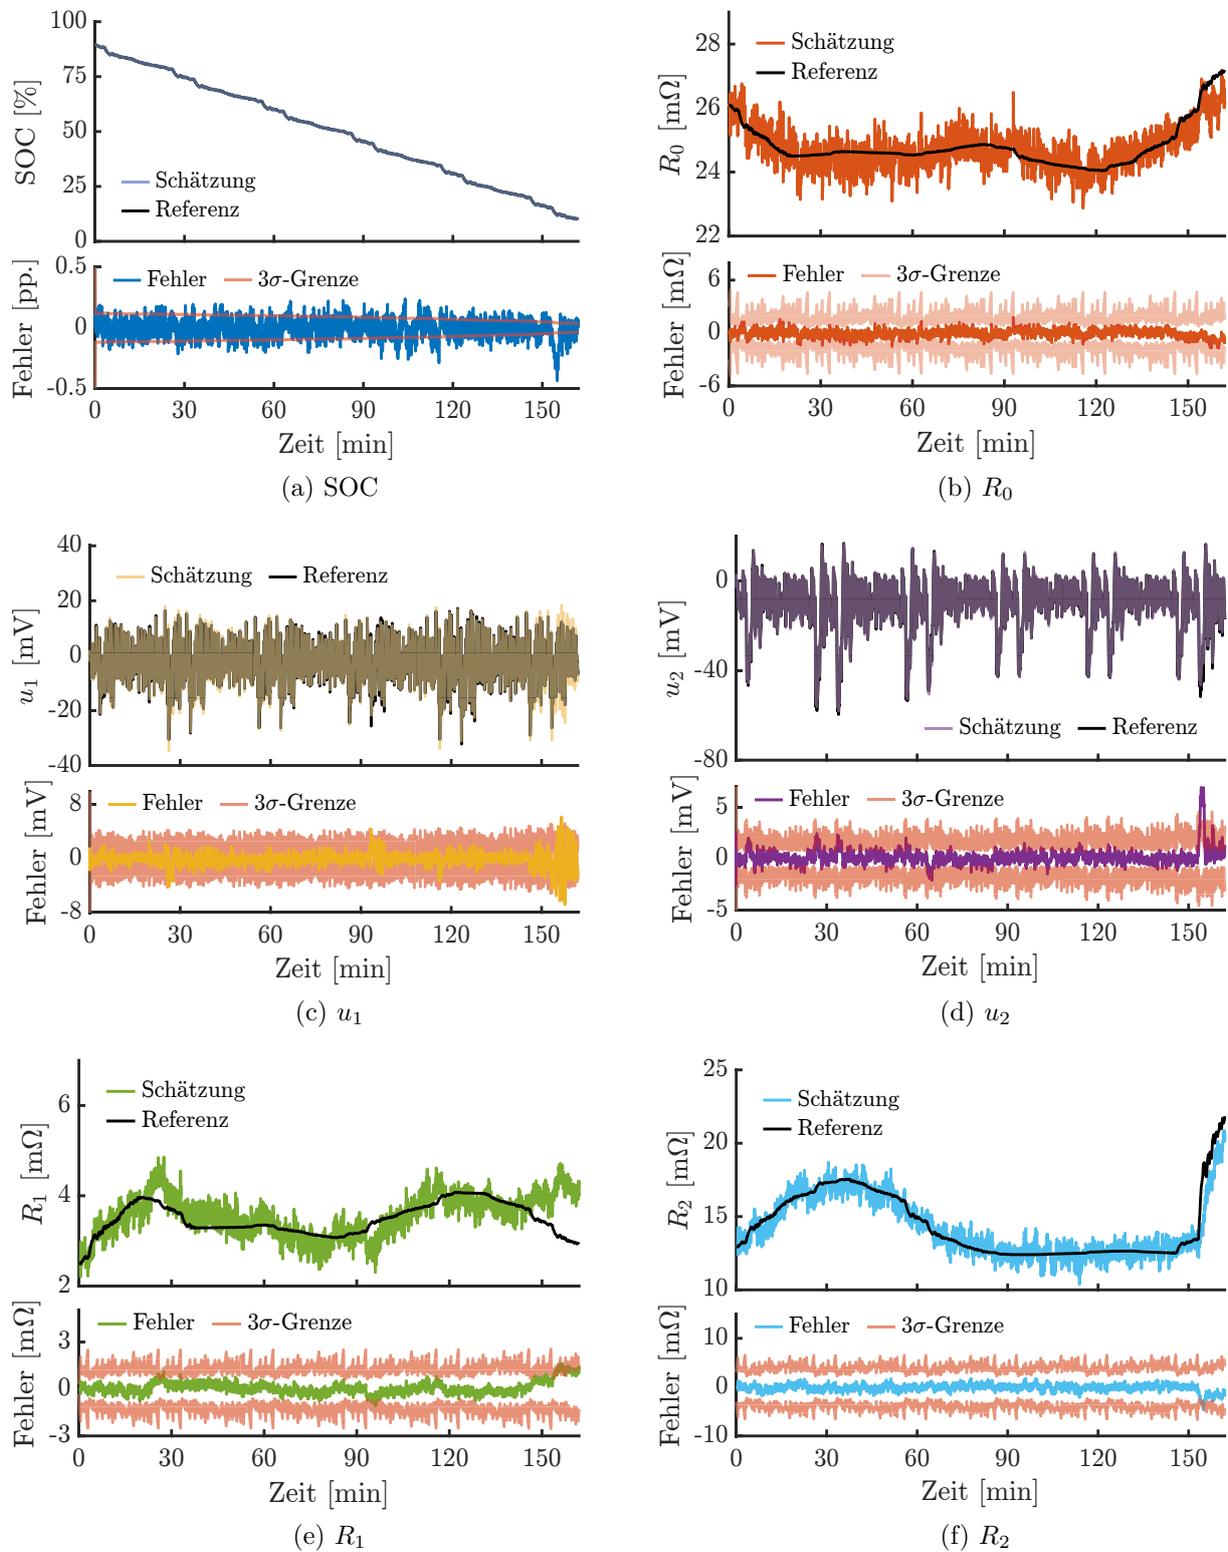


Abbildung 4.26: Ergebnisse der Zustands- und Parameterschätzung mit simulativen Daten (Stromprofil: UDDS).

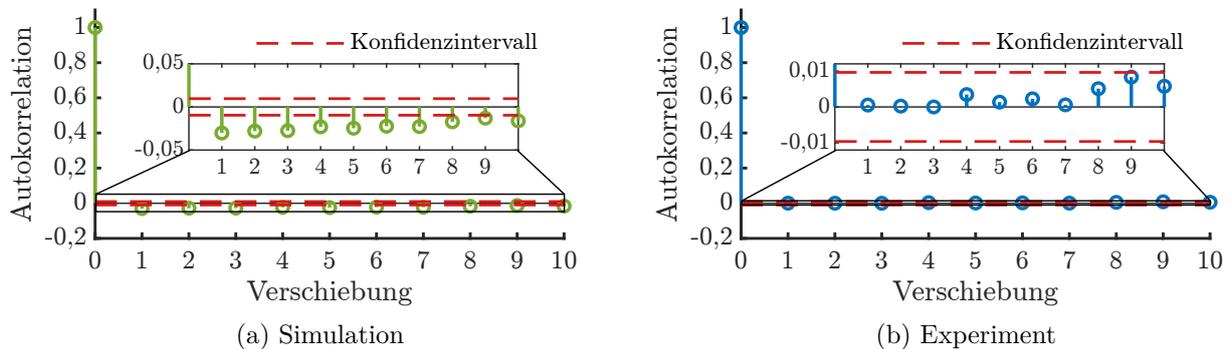


Abbildung 4.27: Autokorrelation der Innovationssequenz (Stromprofil: UDDS).

Unabhängig davon sind die Schätzfehler für die Zustände und Parameter unterschiedlich groß. Die entsprechenden Werte können den rechten Spalten von Tabelle 4.7 entnommen werden. Auffällig ist analog zur vorherigen Simulation der große RRMSE von u_2 , aber auch R_1 wird nur mit einem RRMSE von über 40 % geschätzt. Hier kommt es bei einer Simulationszeit von ungefähr 60 min zu einer auffälligen Vergrößerung des Fehlers. Der absolute Wert dieses Widerstands ist allerdings auch deutlich kleiner als die übrigen beiden Widerstände, sodass die absoluten Fehler nicht größer sind als für R_0 und R_2 .

Auch für die experimentellen Daten kann die Autokorrelation der Innovationssequenz überprüft werden (siehe Abb. 4.27b). Es zeigt sich, dass die Autokorrelation für eine Verschiebung um mehr als einen Zeitschritt immer innerhalb des Konfidenzintervalls liegt und damit die Hypothese einer autokorrelierten Innovationssequenz verworfen werden kann. Dieses Ergebnis steht in Einklang mit dem Fehlerwert J_{NIS} , welcher für den UDDS-Fahrzyklus in Kapitel 4.3 zu 0,06 bestimmt wurde.

Die experimentellen Ergebnisse deuten an, dass die Zustandsschätzung nicht in allen SOC-Bereichen die gleiche Schätzgenauigkeit erreicht. Um diese Annahme zu untersuchen, werden die experimentellen Daten des WLTP- und UDDS-Stromprofils in kleine Abschnitte unterteilt, welche jeweils ein kleines SOC-Intervall repräsentieren. Anschließend wird die Zustandsschätzung für diese Messequenzen durchgeführt. Hierbei wird kein initialer Schätzfehler eingepreist, da das System zu Beginn der jeweiligen Abschnitte nicht in Ruhelage ist. Die Sequenzen haben jeweils eine Länge von 15 min und der mittlere SOC variiert zwischen ihnen in einem Bereich von 7 % und 87 %. Zur Bewertung wird der Mittelwert des RRMSEs aller sechs Zustände und Parameter herangezogen. Die Ergebnisse sind in Abb. 4.29 dargestellt. Die Fehler für beide Anregungsprofile sind in einer ähnlichen Größenordnung und weisen denselben charakteristischen Verlauf auf, welcher durch die Trendlinie angedeutet ist. So steigt der RRMSE in den Bereichen um ungefähr 33 % und 61 % an, wohingegen für die Ladezustände um 22 %, 51 % und 76 % kleinere Schätzfehler erreicht werden. Diese Ladezustandsabhängigkeit ist möglicherweise auf Charakteristika der OCV-Kurve zurückzuführen, wodurch die Zustandsschätzung immer dann schlechtere Ergebnisse liefert, wenn die OCV-Kurve einen flachen Verlauf hat. Hierzu können die ladezustandsabhängige Änderung der Leerlaufspannung in Abb. 4.29 und insbesondere die lokalen Minima der Funktion bei 35 % und 75 % verglichen werden. Eindeutig ist jedoch zu sehen, dass der Schätzfehler für

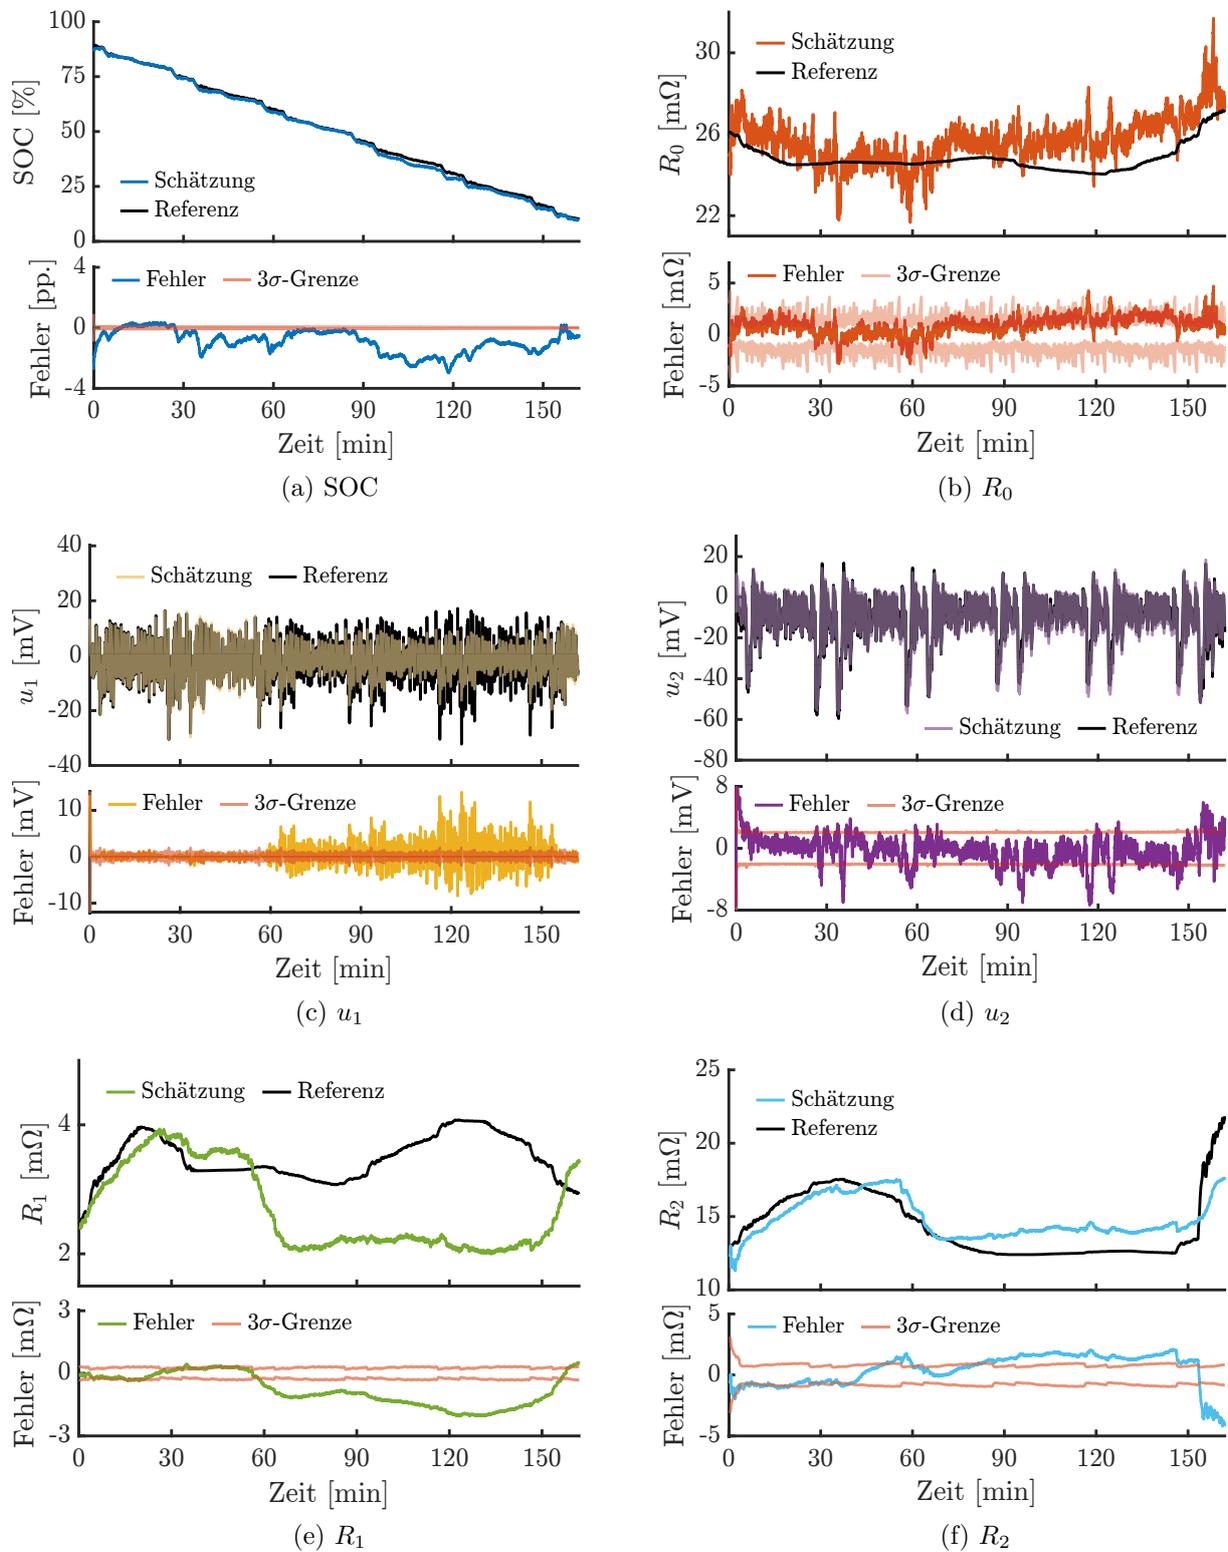


Abbildung 4.28: Ergebnisse der Zustands- und Parameterschätzung mit experimentellen Daten (Stromprofil: UDDS).

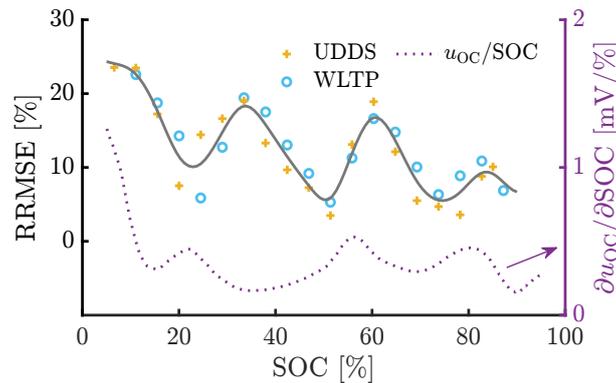


Abbildung 4.29: Fehlermaß RRMSE für UDDS (gelb) und WLTP (blau) an verschiedenen SOC. Die Fensterlänge einer Schätzung beträgt immer 15 min und der SOC ist der Mittelwert über diese Zeitdauer. Zusätzlich ist der Gradient der u_{OC} -Kurve (lila gepunktet) dargestellt.

Tabelle 4.8: RRMSE abhängig von der Umgebungstemperatur des Versuchs und der bei der Charakterisierung vorherrschenden Temperatur für reale (simulative) Daten (Stromprofil: UDDS).

Parametersatz \ Versuch	15 °C	25 °C	35 °C
15 °C	-	+0,8 % (+0,8 %)	+1,0 % (+1,1 %)
25 °C	+0,1 % (+1,7 %)	-	+0,1 % (+0,0 %)
35 °C	+1,6 % (+8,6 %)	+0,1 % (+1,0 %)	-

niedrige Ladezustände stark ansteigt. Ursache hierfür ist die geringe Modellgüte für niedrige SOC, wie bereits in Kapitel 3.2 erwähnt.

Weicht die Zelltemperatur von der Umgebungstemperatur ab, bei welcher das Batteriemodell charakterisiert wurde, steigen die Modellfehler an. In der Folge können auch die Schätzfehler der Zustands- und Parameterschätzung zunehmen. Campestrini et al. [200] untersuchen daher den Einfluss der Temperatur auf die Schätzgüte eines DKFs, welcher für ein Thevenin-Modell Zustände und Parameter schätzt. Die Validierung erfolgt mit Lade- und Entladeprofilen, wobei insbesondere während des Ladevorgangs die Dynamik der Anregung gering ist. In einer eigenen Untersuchung anhand des UDDS-Stromprofils werden Modellfehler aufgrund eines falschen Temperaturbereichs ebenfalls untersucht. Hierzu werden Experimente bzw. Simulationen durchgeführt, wobei das Zellmodell des Kalman-Filters für einen anderen Temperaturbereich ermittelt wurde, als die tatsächliche Umgebungstemperatur der Untersuchung ist. Dadurch ergeben sich Abweichungen des Zellmodells vom realen System bzw. vom Referenzmodell. Der Anstieg des mittleren RRMSEs ist in Tabelle 4.8 gezeigt. Die Ergebnisse zeigen, dass zwar der Schätzfehler durch die Divergenz des Parametersatzes vom Versuch grundsätzlich ansteigt, allerdings ist dieser Anstieg sehr moderat und liegt zwischen 0,0 % und 1,7 %. Lediglich in einem Fall (Versuch bei 15 °C, Parametersatz für 35 °C) steigt der Fehler um 8,6 % an. Es kann daher gefolgert werden, dass – zumindest im untersuchten Temperaturbereich – die Temperaturabhängigkeit des Modells so gering ist, dass keine größeren Einflüsse auf die Güte der Zustands- und Parameterschätzung zu erwarten sind.

Abschließend soll an dieser Stelle ein Fokus auf das Potenzial von IBSs mit zellindividueller Sensorik für die Zustands- und Parameterschätzung gelegt werden. Während die Zellspannung auch in herkömmlichen Batteriesystemen aus Sicherheitsgründen erfasst wird, ist ein Alleinstellungsmerkmal von IBSs die Zellstrom-Messung durch eigene Sensoren für jede Zelle. Damit stehen der Zustands- und Parameterschätzung genauere Informationen zur Verfügung, um für jede Batteriezelle den Ladezustand und die weiteren Zustände zu bestimmen.

Anhand einer Simulation eines Batteriemoduls in 4s3p-Topologie soll das Potenzial der Zellstrom-Sensoren untersucht werden. Als Anregungsprofil kommt beispielhaft der UDDS-Fahrzyklus zum Einsatz. Im Falle eines IBS basiert die Schätzung auf Zellebene auf den Zellsensoren für Strom und Spannung. Um einen Vergleich mit herkömmlichen Batteriesystemen anzustellen, wird für diese angenommen, dass nur der Gesamtstrom gemessen wird. Dementsprechend kann der Zellstrom nur abgeschätzt werden, indem die Annahme getroffen wird, der Gesamtstrom teile sich gleichmäßig auf die Zellen eines Parallelstrangs auf. Damit einher gehen zwangsläufig Fehler, da diese Annahme in der Regel nicht korrekt ist. Vielmehr ergibt sich zwischen parallel verschalteten Zellen eine inhomogene Stromaufteilung, welche durch die Parameter der involvierten Zellen gegeben ist. Diese Inhomogenität wird umso größer, je unterschiedlicher die Zellparameter sind. Wie in Kapitel 3.1.4 gezeigt wurde, nimmt die Variation der Parameter über die Lebensdauer des Batteriesystems zu. Daher wird die Zustands- und Parameterschätzung für herkömmliche Batteriesysteme und IBSs mit Zellsensoren für BOL und EOL betrachtet. Gemäß Tabelle 3.1 wird hierzu angenommen, dass die Innenwiderstände am EOL einen Koeffizienten der Parameterstreuung von $\kappa_{R_0, \text{EOL}} = 20,0\%$ aufweisen und die Kapazitäten um $\kappa_{Q, \text{EOL}} = 2,0\%$ variieren. In Abb.4.30 sind die RMSEs für die sechs Zustände für BOL und EOL dargestellt, wobei der Fehlerwert als Mittelwert der zwölf Zellen des Batteriemoduls ermittelt wird. Die Ergebnisse für den WLTP-Fahrzyklus sind qualitativ vergleichbar und sind in Abb. E.6 in Anhang E gezeigt.

Betrachtet man zunächst die geringere Parameterstreuung am BOL in Abb. 4.30a, so sind bereits die Unterschiede zwischen herkömmlichen Batteriesystemen ohne Zellstrommessung auf der einen Seite und IBSs auf der anderen Seite sichtbar. Die Fehlerwerte liegen im Mittel um 30% niedriger, wenn Messwerte des Zellstroms vorhanden sind, obwohl die Stromaufteilung nur eine geringe Inhomogenität aufweist. Insbesondere die SOC-Schätzung ist jedoch sensitiv für Fehler der Strommessung, da sich diese beim Coulomb-Counting aufaddieren und durch die Spannungsmessung nur zum Teil kompensiert werden. Deutlicher wird das Potenzial eines IBS mit zellindividueller Sensorik am EOL. Aufgrund der inhomogenen Parameter der Zellen des Batteriesystems ergibt sich eine deutlich ungleiche Stromaufteilung, was den Einsatz von Zellstrom-Sensoren rechtfertigt. Die resultierenden RMSEs der Zustände in Abb. 4.30b des IBS bleiben im Vergleich zum BOL nahezu unverändert, wohingegen die Zustands- und Parameterschätzung eines herkömmlichen Batteriesystems signifikant schlechtere Ergebnisse erzielt. Der RMSE steigt im Mittel um 78%. Insbesondere die Innenwiderstandsschätzung ist mit einem großen Fehler behaftet. Zusammenfassend zeigt sich, dass die Stromsensoren des IBS einen deutlichen Gewinn für die Genauigkeit des Schätzverfahrens bringen, insbesondere angesichts inhomogener Zellparameter, wie sie charakteristisch am Ende der Lebensdauer eines Batteriesystems sind.

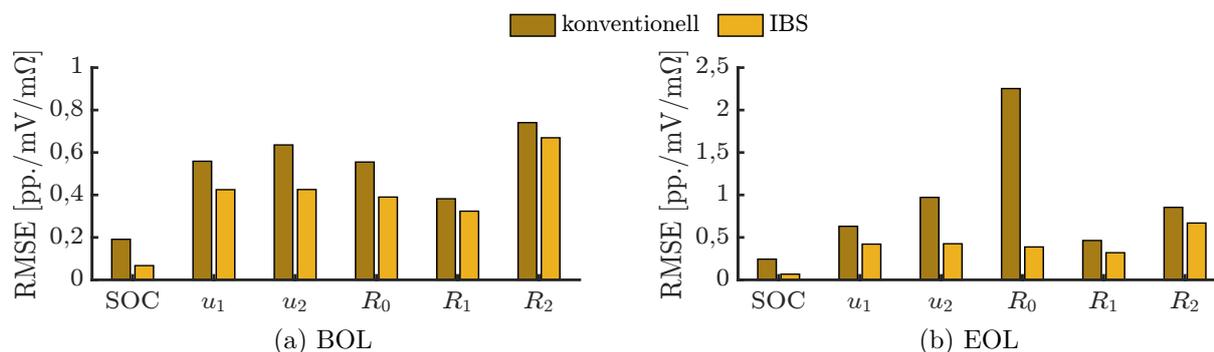


Abbildung 4.30: Simulative Ergebnisse der Zustands- und Parameterschätzung mit herkömmlicher Strommessung und Zellstrom-Sensoren. Der RMSE ist der Mittelwert aus den zwölf Zellen des untersuchten Batteriemoduls (Stromprofil: UDDS). Der Fehler des SOC's ist in Prozentpunkten (pp.) angegeben, der beider Überspannungen in Millivolt und der Widerstände in Milliohm.

4.6 Zusammenfassung der Zustands- und Parameterschätzung

Die Zustands- und Parameterschätzung ist eine der grundlegenden Funktionen in BMSs. Der Einsatz von Kalman-Filtern zur Bestimmung wichtiger Zustände wie dem Ladezustand oder Parametern wie dem Innenwiderstand entspricht dem Stand der Technik. Dennoch blieben bei der Entwicklung und dem Einsatz von Zustandsschätzern offene Forschungsfragen, welche im Rahmen dieses Kapitels diskutiert wurden. Zum einen konnte für verschiedene Dimensionen des Zustandsvektors gezeigt werden, wie sich die Beobachtbarkeit der Zustände verändert. Hierzu wurden unterschiedliche Randbedingungen wie beispielsweise die Höhe des Anregungsstroms systematisch variiert. Weiterhin stellt die Parametrierung des Kalman-Filters eine offene Forschungsfrage dar, welcher in dieser Arbeit durch eine multikriterielle Optimierung mittels GA begegnet werden konnte. Schließlich existieren verschiedene Modifikationen des Kalman-Filters, welche für die Anwendung der Zustandsschätzung in Batteriesystemen geprüft wurden. Insbesondere das Vernachlässigen physikalisch nicht plausibler Kovarianzen der Zustände kann die Schätzung verbessern.

Die Ergebnisse anhand von Simulationen und realen Experimenten zeigen, dass nicht immer eine konsistente Schätzung erzielt werden kann. Die Schätzfehler sind dennoch klein, insbesondere für den SOC, bei dem mit realen Daten ein RMSE von 1,2 Prozentpunkten erzielt werden kann, und die Widerstände, bei denen der Schätzfehler kleiner als $1,5 \text{ m}\Omega$ ist.

Das vorgestellte Schätzverfahren lässt sich grundsätzlich auch in jedem Batteriemanagementsystem umsetzen, wenn Zellstrom und -spannung bekannt sind. Das ist in rein seriellen Topologien der Fall oder in IBSs, wenn Strom, Spannung und Temperatur jeder Zelle erfasst werden. Wie gezeigt werden konnte, bieten die Zellstrom-Sensoren von IBSs einen signifikanten Gewinn an Genauigkeit für die Zustands- und Parameterschätzung. Das zweite wichtige Merkmal von IBSs, die Rekonfigurierbarkeit, wird im folgenden Abschnitt genauer untersucht. Die Eingriffsmöglichkeit in das Batteriesystem in Form von Schaltoperationen ermöglicht es, die Systemanregung gezielt zu beeinflussen und somit die Zustands- und Parameterschätzung weiter zu verbessern.

5 Aktive Parameterschätzung in rekonfigurierbaren Batteriesystemen

5.1 Motivation für den Einsatz von Schaltoperationen

Die Systemanregung ist eine wichtige und notwendige Voraussetzung für die Zustands- und Parameterschätzung, insbesondere wenn die Zahl der zu schätzenden Modellparameter groß ist. Das hat die Beobachtbarkeitsanalyse des vorherigen Kapitels gezeigt. RBSs bieten durch die ihnen inhärenten Schalter eine Eingriffsmöglichkeit in den Strompfad, welche herkömmliche Batteriesysteme nicht besitzen. Inwiefern Schaltoperationen vorteilhaft dazu genutzt werden können, die Zustands- und Parameterschätzung zu verbessern, ist die diesem Kapitel zugrunde liegende Forschungsfrage.

Im Kontext der Least-Squares-Schätzverfahren ist bekannt, dass für eine zuverlässige Parameteridentifikation der Systemeingang eine ausreichende Dynamik aufweisen muss. Diese Anforderung wird in der Literatur als permanente Anregung (engl. *persistent excitation*, PE) bezeichnet [271][272, S. 64]. Anschaulich gesprochen, muss das Anregungssignal in allen relevanten Frequenzbereichen Anteile aufweisen, welche das System charakterisieren. Nur dann haben alle Systemparameter einen Einfluss auf die Ausgangsgröße, was eine Voraussetzung für die Identifikation dieser ist. Beim Kalman-Filter kann die Beobachtbarkeit als Analogie zur PE angesehen werden, denn wie bereits in Kapitel 4.2 erläutert, ist diese für nicht-lineare Systeme eine vom Systemeingang abhängige Eigenschaft. Insbesondere die RC-Glieder des Batterieersatzschaltbildmodells müssen in ihren charakteristischen Frequenzen angeregt werden, um in der Messung beobachtbar zu sein.

Verfahren zur Zustands- und Parameterschätzung von Lithium-Ionen-Zellen werden in der Literatur oftmals durch Experimente validiert, bei denen eine ausreichende Anregung sichergestellt ist. Häufig verwendete Anregungsprofile sind beispielsweise synthetische Stromverläufe wie die HPPC [248] oder der Dynamic-Stress-Test (DST) [96, 197, 199, 202, 254], sowie dynamische Fahrprofile z. B. WLTP, Federal-Urban-Driving-Cycle (FUDDS) [88, 197], UDDS [8, 13, 156, 175, 196, 254] oder der Neue Europäische Fahrzyklus (NEFZ) [196]. Dagegen wird nur selten der Fall geringer Systemanregung betrachtet, wie er beispielsweise während des Ladens oder bei Fahrt mit konstanter Geschwindigkeit (z. B. auf der Autobahn) auftritt [182]. Dabei weisen die Batteriesysteme heutiger BEVs eine hohe Kapazität auf, weil sie eine große Reichweite bieten sollen. Dadurch bedingt tritt häufig die Situation auf, dass die Einzelzellen nur geringen Belastungen ausgesetzt sind und die Anregung klein ist.

In [213] wird ein Verfahren vorgestellt, bei dem die alterungsabhängigen Parameter eines Ersatzschaltbildmodells geschätzt werden sollen, welches einen Superkondensator beschreibt. Zur Erhöhung der Anregung wird ein PRBS-Signal dem Eingangssignal überlagert, wenn dieses ansonsten null wäre. Dadurch soll die Zustandsschätzung verbessert werden. Um das Anregungssignal zu erzeugen, ist jedoch zusätzliche Hardware notwendig. Intelligente Batteriesysteme

ermöglichen durch ihre Rekonfigurierbarkeit die gezielte Steuerung des Stromflusses. Dadurch kann die Systemanregung für jede Einzelzelle durch Schalthandlungen beeinflusst werden und die Zustands- und Parameterschätzung wird verbessert. Liebhart et al. nutzen diese Art der zusätzlichen Anregung für die Impedanzspektroskopie innerhalb intelligenter Batteriesysteme [20, 21]. Bei dem von ihnen als *hybride* Anregung bezeichneten Verfahren wird der Laststrom durch hochfrequente Schalthandlungen überlagert. Dadurch ist es möglich, das Frequenzspektrum des Eingangssignals gezielt durch Frequenzanteile in Bereichen ansonsten geringer Anregung anzureichern.

In diesem Kapitel werden unterschiedliche Schaltmuster und -strategien untersucht, mit dessen Hilfe die Systemanregung für die Zustands- und Parameterschätzung auf Zellebene erhöht werden kann. Dieses Vorgehen wird als **aktive Zustands- und Parameterschätzung** bezeichnet [273]. Der Einfluss auf die Schätzergebnisse wird durch Simulationen und Experimente validiert. Schließlich wird auch diskutiert, inwiefern die Schalthandlungen einer verstärkten Zellalterung Vorschub leisten. Die folgenden Untersuchungen beruhen auf einem Ersatzschaltbildmodell der Batteriezelle der Ordnung $n = 6$. Neben den Zuständen (SOC, u_1, u_2) sind demnach die drei Modellparameter R_0, R_1 und R_2 Teil des Zustandsvektors. Um mögliche Seiteneffekte auszuschließen, die durch die Synchronisation mehrerer Filter zueinander auftreten könnten, wird ein JEKF für die Schätzung von Zuständen *und* Parametern verwendet.

5.2 Schaltstrategie zur Erhöhung der Systemanregung

Das grundsätzliche Ziel einer Schaltstrategie für eine verbesserte Zustands- und Parameterschätzung im Zeitbereich ist es, die Stromanregung für die intelligenten Batteriezellen in für die Schätzverfahren relevanten Frequenzbereichen zu erhöhen. Abhängig von der Topologie des Batteriesystems können dabei zwei Fälle unterschieden werden [273]:

Parallelschaltung

Sind Zellen miteinander parallel verschaltet, teilt sich der Strom zwischen diesen Zellen auf. Zur Erhöhung der Anregung kann eine Zelle für einen gewissen Zeitraum abgeschaltet werden, wodurch sich für die verbleibenden Zellen der Strom um den Faktor $\frac{\mathcal{P}}{\mathcal{P}-1}$ erhöht. Der Gesamtstrom bleibt unverändert.

Reihenschaltung

Bei seriell verschalteten Zellen kann die Anregung erhöht werden, indem eine Zelle des Strangs überbrückt wird. Unter der Annahme, dass die entnommene Leistung des Batteriesystems insgesamt gleich bleibt, steigt auch dann der Strom der im Strang verbleibenden Zellen um den Faktor $\frac{\mathcal{S}}{\mathcal{S}-1}$, da die Gesamtspannung des Batteriesystems um die Zellspannung der überbrückten Zellen sinkt.

Heutige Batteriesysteme bestehen häufig aus gemischten Topologien, bei denen mehrere parallel geschaltete Zellen zu seriellen Strängen verknüpft sind. In diesem Fall können beide Schaltstrategien angewandt werden. Dadurch, dass in der Regel $\mathcal{P} \ll \mathcal{S}$ gilt, kann aber die Anregung durch Wegschalten von Zellen im Parallelstrang stärker erhöht werden. Im Folgenden beschränkt sich die Betrachtung auf den ersten Fall, also die Parallelschaltung. Hierbei wird der Einfachheit

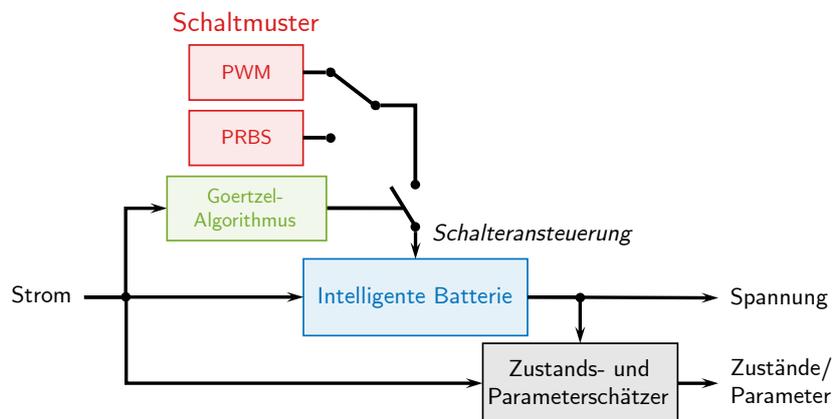


Abbildung 5.1: Blockschaltbild der aktiven Parameterschätzung.

halber ein Modul bestehend aus drei intelligenten Batteriezellen betrachtet. Die Erkenntnisse und Ergebnisse sind jedoch prinzipiell auch auf größere Systeme und andere Topologien übertragbar.

In Abb. 5.1 ist der grundsätzliche Aufbau der aktiven Parameterschätzung dargestellt. Abhängig von der Fahr-situation des BEVs ergibt sich ein Laststrom, mit welchem das Batteriesystem und die intelligente Batteriezelle beaufschlagt werden. Gleichzeitig wird die resultierende Spannung gemessen. Wie bei herkömmlichen Schätzverfahren werden diese beiden Werte zur Bestimmung der Zustände herangezogen. Die Ansteuerung der Schalter wird durch die Schaltstrategie bestimmt, wobei unterschiedliche Schaltmuster zur Anwendung kommen können. Wie noch gezeigt wird, kann die Schalteransteuerung in Abhängigkeit vom Anregungssignal, also dem Strom, erfolgen. Durch die Schaltoperationen ergeben sich für die Batteriezellen vom Laststrom abweichende Anregungsströme mit erhöhter Dynamik.

5.2.1 Schaltmuster zur Anregung relevanter Frequenzen

An mögliche Schaltmuster werden generell folgende Anforderungen gestellt [274]:

1. Die Schaltstrategie soll die Batteriezelle in den für die Bestimmung der Modellzustände und -parameter wichtigen Frequenzbereichen anregen.
2. Durch die Schalthandlungen soll keine Divergenz der Ladezustände innerhalb der involvierten Batteriezellen auftreten.
3. Die Schaltoperationen sollen keinen oder nur geringen Einfluss auf die Alterung der Lithium-Ionen-Zellen haben.
4. Zu jedem Zeitpunkt muss die globale Leistungsanforderung im Rahmen der Zellgrenzen erfüllt werden.

Basierend darauf werden im Folgenden zwei Schaltmuster vorgestellt und im weiteren Verlauf auf ihre Wirkung untersucht.

Pulsweitenmodulation Für das erste vorgestellte Schaltmuster wird angenommen, dass hauptsächlich das RC-Glied mit der geringeren Zeitkonstante ($\tau_1 = 1$ s) angeregt werden muss, da

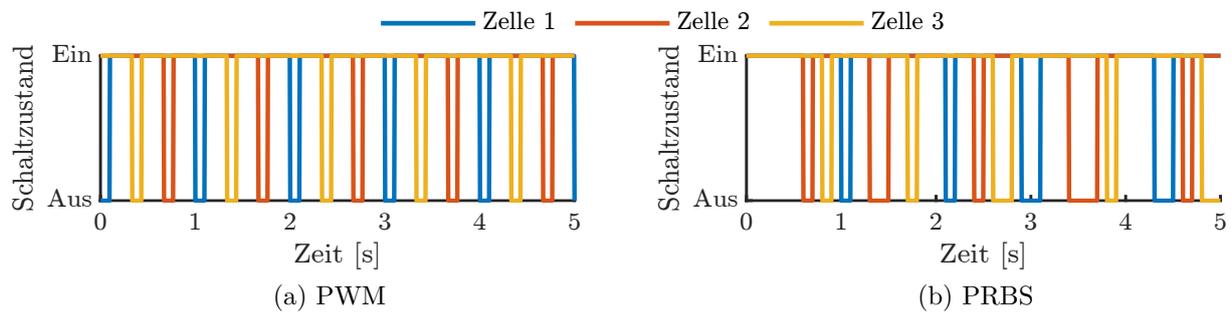


Abbildung 5.2: Untersuchte Schaltmuster zur Erhöhung der Systemanregung.

die ursprüngliche Systemanregung eher niederfrequente Anteile beinhaltet. Deshalb wird ein Rechtecksignal mit einer Frequenz entsprechend der Grenzfrequenz des ersten RC-Glieds zu $f_{\text{PWM}} = \frac{1}{2\pi\tau_1}$ als Grundlage gewählt. Um gemäß der dritten gestellten Anforderung die Alterung der Batteriezellen zu begrenzen, wird ein Tastgrad D von zunächst 90% gewählt. So bleiben die Zeiträume klein, in denen die Stromlast von nur $Z-1$ Zellen getragen werden muss. Um eine gleiche Entladung aller beteiligten Zellen zu erreichen, werden diese sequenziell geschaltet, wobei sich eine Phasenverschiebung von 120° ergibt. Über längere Zeiträume sind dann alle Zellen gleich oft zu- bzw. weggeschaltet, sodass sich im Mittel ähnliche Ladezustände einstellen. Es ergibt sich ein Signal wie in Abb. 5.2a, welches im Folgenden als Pulsweitenmodulation (PWM)-Schaltmuster bezeichnet wird.

Pseudo-Random-Binary-Sequence Als weiteres Schaltmuster wird eine Pseudo-Random-Binary-Sequence (PRBS) genutzt. Es handelt sich hierbei um eine binäre Folge, weswegen sie für die Schalthandlungen in rekonfigurierbaren Batteriesystemen einfach angewandt werden kann. Als hilfreiches Werkzeug der Systemidentifikation regt die PRBS ein System in einem weiten Frequenzbereich an [275, S. 157 f.]. Deren Basisfrequenz ist wiederum basierend auf dem RC-Glied mit der kleineren Zeitkonstante gewählt zu $f_{\text{PRBS}} = \frac{10}{2\pi\tau_1}$. Der Frequenzbereich des Schaltmusters umfasst damit einen breiten Bereich bis zur zehnfachen Grenzfrequenz des RC-Glieds. Dieser Wert liegt oberhalb der Abschätzung von Schoukens et al. [276], die eine Basisfrequenz vom mindestens Zweieinhalbfachen der anzuregenden Frequenz empfehlen. Es ergibt sich eine breitbandige Anregung ähnlich von weißem Rauschen im durch die Abtastung erfassten Frequenzbereich. Ein Ausschnitt des PRBS-Schaltmusters ist in Abb. 5.2b gezeigt. Um gemäß der zweiten oben erwähnten Anforderung die Ladezustände auf einem Niveau zu halten, wird die zu schaltende Batteriezelle bei jeder negativen Flanke der Sequenz reihum variiert. Im Mittel ergeben sich dadurch ähnliche SOCs. Dieses Vorgehen kann als Rundlaufverfahren (engl. *round robin*) bezeichnet werden. Die PRBS wird im Rahmen dieser Arbeit durch eine Maximalfolge realisiert, welche sich durch ein linear rückgekoppeltes Schieberegister generieren lässt [73, S. 164 ff.]. Die Länge des Registers beträgt 16.

5.2.2 Situatives Schalten abhängig von der Anregung

Jeder zusätzliche Schaltvorgang im Batteriesystem erhöht die Belastung für die Zellen. Diesem Gedanken folgend sollen die Schaltoperationen nur in Zeiträumen durchgeführt werden, wenn die

Anregung des ursprünglichen Fahrprofils nicht ausreicht. Es gilt daher ein Maß für die Bewertung der für das Batteriemodell spezifischen Anregung zu finden. Als relevante Frequenzbereiche können die Grenzfrequenzen der beiden RC-Glieder identifiziert werden [273]. Um die Höhe der Frequenzanteile im Stromprofil bezüglich dieser spezifischen Frequenzen zu quantifizieren, kann das Goertzel-Filter [277] eingesetzt werden. Hierbei handelt es sich um eine effiziente Berechnungsmethode, um die Stärke G eines diskreten Signals y bezüglich einer spezifischen Frequenzkomponente f_{target} zu ermitteln (siehe Algorithmus 5.1). Hierbei ist M die Fensterbreite des Filters über die der Frequenzanteil ermittelt wird. Je größer M gewählt wird, desto höher ist die Auflösung im Frequenzbereich. Allerdings nimmt auch die Adaptivität ab, sodass Frequenzanteile nur mit größerer Verzögerung ermittelt werden können [278]. Der Goertzel-Algorithmus ist für die Online-Berechnung in BMSs geeignet. Für die folgenden Untersuchungen ist $M = 400$ und es wird die Anregung bezüglich der Grenzfrequenzen beider RC-Glieder ermittelt.

Algorithmus 5.1 Goertzel Filter

1: **Initialisierung:**

2: $a_{2,0} = 0, \quad a_{3,0} = 0$

3: $\omega_0 = 2\pi t_s f_{\text{target}}$

4: **Sammle für** $k = 1 \dots M$:

5: $a_{1,k} = y_k + 2 \cos(\omega_0) \cdot a_{2,k-1} - a_{3,k-1}$

6: $a_{3,k} = a_{2,k-1}$

7: $a_{2,k} = a_{1,k-1}$

8: **Auswertung bei** M :

9: $G_K^2(f_{\text{target}}) = \frac{M}{2} (a_{2,M}^2 + a_{3,M}^2 + a_{2,M} a_{3,M} \cos(\omega_0))$

Die Schalthandlungen gemäß der beiden Schaltmuster können immer dann pausiert werden, wenn die Anregung bezüglich der Grenzfrequenzen *beider* RC-Glieder oberhalb eines Schwellwerts liegt. In diesem Fall wird die Anregung des ursprünglichen Systemeingangs als ausreichend angesehen. Der Schwellwert ist ein zu wählender Einstellparameter. Zur Verdeutlichung sind in Abb. 5.3 auf der linken Seite zwei Stromprofile dargestellt, welche für die folgenden Untersuchungen herangezogen werden. Zum einen in Blau dargestellt ist ein Stromprofil basierend auf dem WLTP, welches mit einer Länge von 1800s dynamische Anteile ebenso enthält wie Phasen ohne Anregung. Zum anderen ist ein Stromverlauf basierend auf einer Konstantfahrt mit 120 km/h nach Beschleunigung aus dem Stillstand gezeigt. Bei diesem Profil, welches eine Dauer von 1500s hat, ist der Strom nach der Beschleunigungsphase nahezu konstant. Es wird im weiteren Verlauf als Autobahn-Profil bezeichnet. Beide Profile stammen aus realen Fahrzeugmessungen am Prüfstand. Mittig in Abb. 5.3 ist die Anregungsstärke für die Stromprofile über der Zeit dargestellt, wobei nur die beiden Frequenzen betrachtet werden, welche den Grenzfrequenzen der beiden RC-Glieder entsprechen. Der Schwellwert (rot gestrichelt) ist 1,0 A für den WLTP-Fahrzyklus und 10 A für das Autobahn-Profil auf Basis der Stärke des Anregungssignals gewählt. Gemäß der obigen Bedingung für ausreichende Anregung des Eingangssignals werden die Schalthandlungen nun abhängig von der Signalstärke der Frequenzanteile durchgeführt bzw. pausiert, wie auf der rechten Seite der Abbildung für beide Schaltprofile zu sehen ist. Augenscheinlich weist der WLTP-Fahrzyklus signifikant mehr Phasen auf, in denen die Anregung von sich aus ausreichend ist.

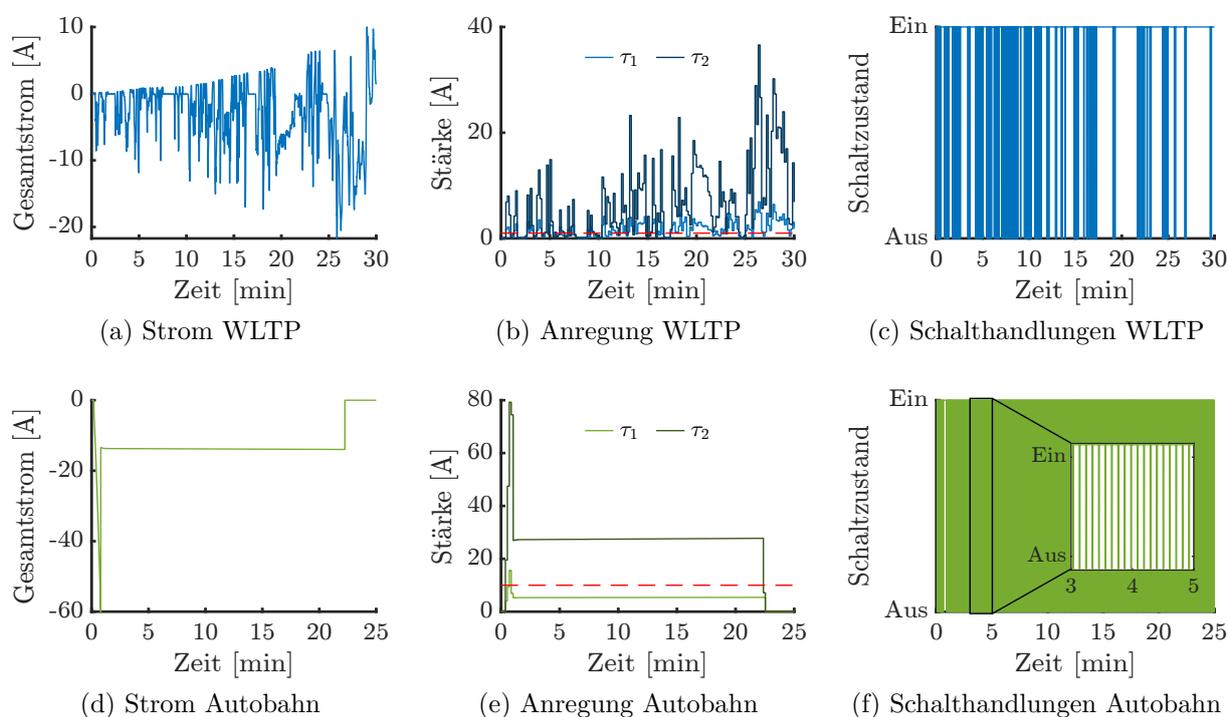


Abbildung 5.3: Untersuchte Stromprofile, die Stärke ihrer Anregung im Frequenzbereich nach dem Goertzel-Algorithmus in Bezug auf die untersuchten Zeitkonstanten und die resultierenden Schaltfrequenzen. Der Schwellwert (rot gestrichelt) für die Schaltoperationen ist hier 1,0 A für den WLTP-Fahrzyklus bzw. 10,0 A für die Autobahnfahrt.

Dagegen ist die Dynamik der Autobahnfahrt so gering, dass von der Beschleunigung zu Beginn abgesehen dauerhaft geschaltet wird.

5.3 Analyse der Schaltmuster und Fahrprofile im Frequenzbereich

Bevor der Einfluss der Schalthandlungen auf die Zustands- und Parameterschätzung bewertet wird, sollen die Schaltmuster und der durch die Schalthandlungen beeinflusste Zellstrom im Frequenzbereich untersucht werden. Eine Auswertung der Frequenzspektren gibt einen erweiterten Einblick in die Wirkungsweise der aktiven Parameterschätzung und hilft beim Verständnis der anschließenden Validierungsversuche.

5.3.1 Frequenzspektrum der Schaltmuster

Um zunächst einen grundlegenden Blick auf die Schaltmuster und deren Frequenzanteile zu erhalten, sind in Abb. 5.4 auf der linken Seite vier periodische Signale im Zeitbereich dargestellt: Zwei Rechteck-Signale mit einem Tastgrad von $D = 50\%$ bzw. $D = 90\%$, ein schematisches Stromprofil in einem 3p-System sowie eine PRBS. Auf der rechten Seite der Abbildung finden sich die den Signalen zugehörigen Frequenzspektren, wobei die Abszisse auf die Taktfrequenz des

Rechteck-Signals bzw. der Grundfrequenz der PRBS normiert ist. Die Frequenzspektren wurden auf Basis der diskreten Fourier-Transformation (DFT) ermittelt. Hierbei ist die Darstellung auf das positive Frequenzspektrum begrenzt, da dieses achsensymmetrisch zur Ordinate ist. Weiterhin ist das Spektrum mit $1/K$ normiert, wobei K die Signallänge ist. Dadurch ergeben sich identische Amplituden für den Zeit- und Frequenzbereich [279, S. 166 f.].

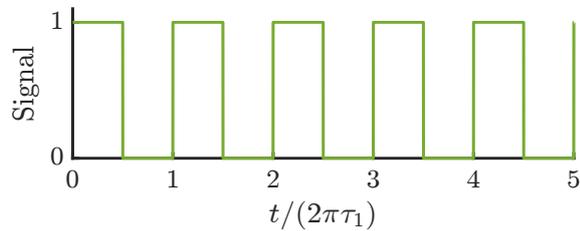
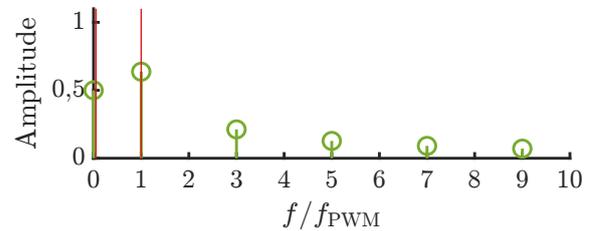
Betrachten wir zunächst das Frequenzspektrum des ersten Signals in Abb. 5.4b, so sind neben dem Gleichanteil bei $f = 0$ die charakteristischen Frequenzanteile bei den ungeraden Vielfachen der Taktfrequenz zu sehen, deren Amplituden mit steigender Frequenz abnehmen. Vergrößert sich der Tastgrad nun auf 90 %, wie in Abb. 5.4c und Abb. 5.4d gezeigt, treten auch gerade Vielfache der Taktfrequenz f_{PWM} auf. Gleichzeitig ist die Amplitude der ersten Vielfachen kleiner, die Amplituden der höheren Harmonischen nehmen weniger stark ab. Für den Fall des vorgestellten Schaltmusters, bei dem die Taktfrequenz des Rechteck-Signals der Grenzfrequenz des ersten RC-Glieds des Batterie-Ersatzschaltbildmodells entspricht, sind die Grenzfrequenzen beider RC-Glieder in das Frequenzspektrum eingetragen. Das Schaltmuster regt das erste RC-Glied signifikant an, wohingegen das zweite RC-Element in einem tieferen Frequenzbereich liegt.

Tatsächlich überlagern sich die Schaltmuster in einem 1s3p-System, sodass der Strom beim Abschalten der Zelle auf null zurückgeht, sich jedoch um die Hälfte erhöht, wenn eine der parallelen Zellen abgeschaltet wird. Das entstehende Stromprofil für das PWM-Schaltmuster mit einem Tastgrad von 90 % ist schematisch in Abb. 5.4e gezeigt. Es ergibt sich basierend auf diesem Signal ein Frequenzspektrum wie in Abb. 5.4f. Es treten Harmonische der Grundfrequenz auf, wobei jedoch die 3., 6., 9., ... Vielfachen nicht vorhanden ist. Die Amplituden nehmen mit höherer Frequenz ab.

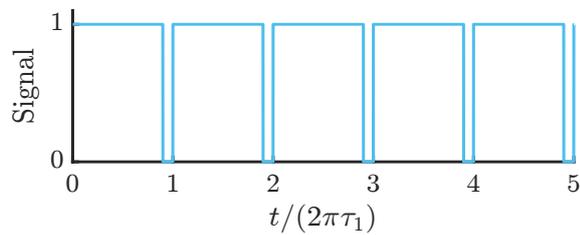
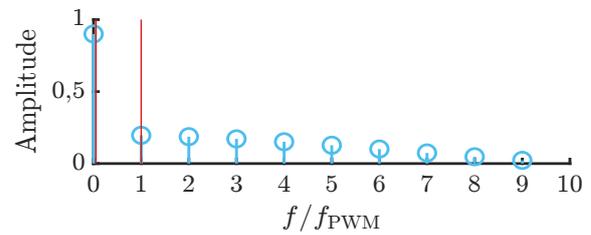
In Abb. 5.4g ist dagegen ein PRBS-Signal dargestellt, dessen maximale Schaltfrequenz f_{PRBS} dem Zehnfachen der Grenzfrequenz des ersten RC-Glieds entspricht. Es ergibt sich, wie in Abb. 5.4h dargestellt, ein Frequenzspektrum, bei dem, vom Gleichanteil abgesehen, die Amplitude bis zur Grundfrequenz f_{PRBS} kontinuierlich absinkt. Für $f \ll f_{\text{PRBS}}$ ähnelt das Spektrum daher dem von weißem Rauschen und sorgt für eine breitbandige Anregung [276]. Diese Bedingung ist bezüglich der beiden Zeitkonstanten des Batterie-Ersatzschaltbildmodells erfüllt, weswegen sich das PRBS-Schaltmuster für die aktive Parameterschätzung eignet.

Die Anwendung des PRBS-Schaltmusters auf ein 1s3p-System ergibt wiederum einen charakteristischen Stromverlauf für eine Einzelzelle. Dies ist in Abb. 5.4j dargestellt. Der daraus resultierende Frequenzverlauf in Abb. 5.4j ist nun nicht mehr gleichmäßig. Insbesondere im Bereich der Grenzfrequenz des ersten RC-Glieds ist die Anregung erhöht.

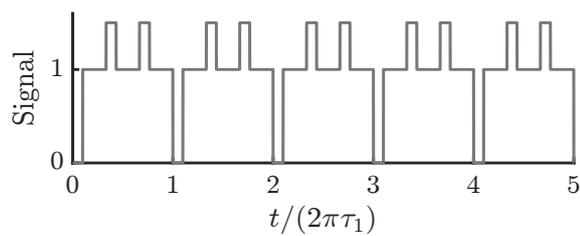
Bei der Analyse der Frequenzspektren ist zu beachten: Bei den zugrunde liegenden Signalen handelt es sich nur um die Grundmuster der Schaltoperationen. Das Spektrum des für die Anregung der Zustandsschätzung relevanten Zellstroms unterscheidet sich von diesen jedoch, da ein geringer Strom auch durch Schaltoperationen nur in geringem Maße manipuliert wird. Die betrachteten Frequenzspektren der Signale liefern daher zwar einen Einblick in die Wirkungsweise der Schaltmuster, das Spektrum des resultierenden Zellstroms kann sich davon jedoch stark unterscheiden, nicht zuletzt auch auf Basis des gewählten Stromprofils. Daher folgt an dieser Stelle eine Spektralanalyse der zwei betrachteten Stromprofile.

(a) Rechteck-Signal mit $D = 50\%$ 

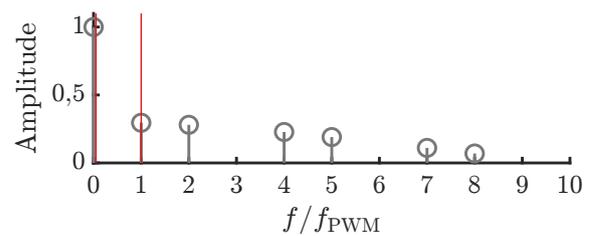
(b) Frequenzspektrum des Rechteck-Signals

(c) Rechteck-Signal mit $D = 90\%$ 

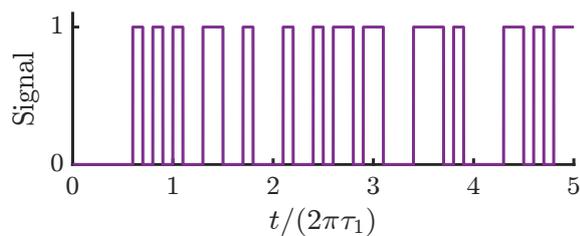
(d) Frequenzspektrum des Rechteck-Signals



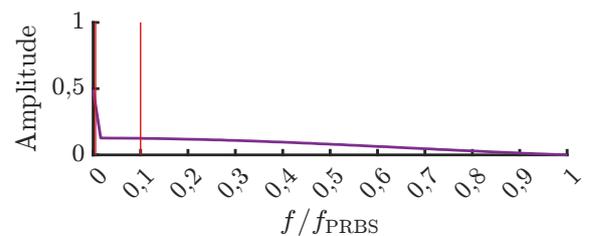
(e) 1s3p-Stromverlauf (PWM)



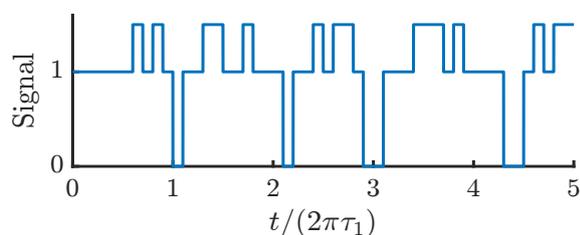
(f) Frequenzspektrum des PWM-Stromverlaufs



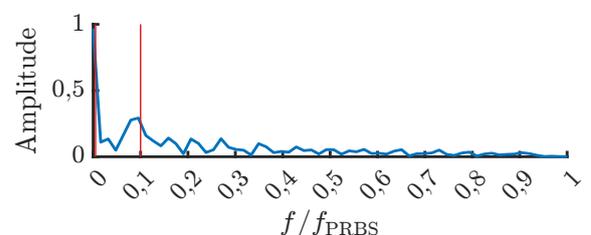
(g) PRBS



(h) Frequenzspektrum der PRBS



(i) 1s3p-Stromverlauf (PRBS)



(j) Frequenzspektrum des PRBS-Stromverlaufs

Abbildung 5.4: Verschiedene Signale und deren Frequenzspektren. In rot markiert sind die Grenzfrequenzen der RC-Glieder des Batterie-Ersatzschaltbildmodells (rechte Linie: 1. RC-Glied, linke Linie: 2. RC-Glied).

5.3.2 Spektralanalyse der verwendeten Stromprofile

Zur Betrachtung des Frequenzspektrums eines Signals über einen Zeitverlauf werden Spektrogramme verwendet, wie in Abb. 5.5 gezeigt. Diese beruhen wiederum auf der DFT. Auf der Abszisse ist die Zeit aufgetragen und auf der Ordinate das Frequenzspektrum des gefensternten Signals zu diesem Zeitpunkt. Als Fensterfunktion kommt im Folgenden ein Hanning-Fenster mit einer Breite von 2400 Samples zum Einsatz, was bei einer Abtastrate von 40 Hz einer Zeitspanne von einer Minute entspricht. Zusätzlich sollen sich die Fenster um 90 % überlappen, sodass eine Zeitauflösung von 6 s erreicht wird. Der darstellbare Frequenzbereich reicht gemäß der Abtastrate von 0 Hz bis 20 Hz, wobei in der Abbildung nur der Bereich bis 1 Hz dargestellt ist.

Abb. 5.5 enthält drei Diagramme, welche aus drei Experimenten eines 1s3p-Systems stammen [280]. Im ersten Fall wurden keine Schaltoperationen durchgeführt (im Folgenden als *passiv* bezeichnet), in den anderen wurde das PWM- bzw. PRBS-Schaltmuster zur Erhöhung der Anregung angewandt. Es wird ein Durchlauf des WLTPs mit einer Dauer von 30 min dargestellt. Der Anregungsstrom hat eine Auflösung von 10 Hz, die Fahrzeuggeschwindigkeit des WLTPs ist jedoch nur mit 1 Hz vorgegeben¹, weshalb das Frequenzspektrum des passiven Versuchs in Abb. 5.5a nur in einem niedrigen Frequenzbereich signifikante Anteile aufweist. Weiterhin sind im Spektrogramm die Phasen einer hohen Anregung von Phasen mit geringer oder keiner Anregung zu unterscheiden, wie sie beispielsweise nach ungefähr 9 min auftreten. In den Spektrogrammen sind die Grenzfrequenzen der RC-Glieder des Batterie-Ersatzschaltbildmodells als rote waagerechte Linien markiert. Während für die tiefe Frequenz des zweiten RC-Glieds eine Anregung vorhanden ist, fällt sie für das erste RC-Glied deutlich geringer aus. In Abb. 5.5b ist das Spektrogramm des Zellstroms dargestellt, bei dessen zugrunde liegendem Experiment das PWM-Schaltmuster angewandt wurde. Deutlich ist zu erkennen, dass Frequenzanteile, welche der Grundfrequenz des Rechteck-Signals sowie der zweiten, vierten und fünften Harmonischen entsprechen, signifikant erhöht sind. Diese Beobachtung deckt sich mit dem erwarteten Frequenzspektrum aus Abb. 5.4f. Schließlich zeigt Abb. 5.5c das zeitlich aufgelöste Frequenzspektrum unter dem PRBS-Schaltmuster. Im Gegensatz zum vorherigen Spektrogramm, bei welchem die Vielfachen der Grundfrequenz deutlich zu erkennen sind, ist die Anregung erwartungsgemäß breitbandig in dem betrachteten Frequenzbereich. Für Phasen mit einer relevanten Anregung erhöht sich der Zellstrom über das dargestellte Frequenzband.

Die Anregung der spezifischen Frequenzen der RC-Glieder über die Zeit ist in Abb. 5.6 für den WLTP-Fahrzyklus zusätzlich gezeigt. Die Verläufe für die verschiedenen Schaltmuster entsprechen hierbei dem Wert der Leistungsdichte Φ entlang der roten Markierungen in Abb. 5.5. Es ist zu erkennen, dass die Anregung des ersten RC-Glieds höher ist, wenn Schalthandlungen angewandt werden. Dies gilt insbesondere für das letzte Drittel des Fahrprofils, in welchem die auftretenden Ströme hoch sind. Beide untersuchten Schaltmuster erhöhen die Leistungsdichte dabei um einen vergleichbaren Betrag. Blickt man dahingegen auf das zweite RC-Glied des Ersatzschaltbildmodells in Abb. 5.6b, so ist kein signifikanter Unterschied zwischen den drei Schaltstrategien zu erkennen. Die Leistungsdichte liegt auf einem im Vergleich zum ersten RC-Glied höheren Niveau, die Schalthandlungen haben jedoch keinen Effekt darauf. Da die Anregung in diesem Frequenzbereich

¹siehe Anhang B für Details zur Gewinnung der Anregungsprofile

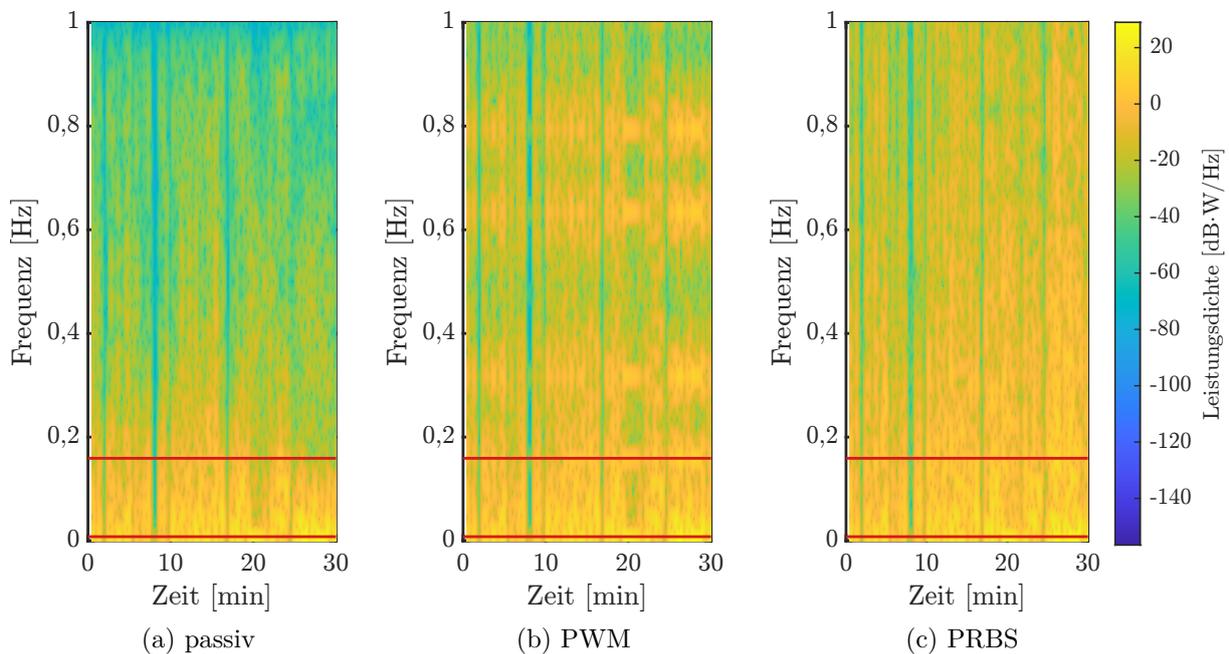


Abbildung 5.5: Spektrogramm des Zellstroms beim WLTP-Fahrzyklus abhängig vom Schaltmuster. Die Grenzfrequenzen der RC-Glieder sind rot markiert (obere Linie: 1. RC-Glied, untere Linie: 2. RC-Glied).

in erster Linie vom Stromprofil bestimmt wird und die Schaltfrequenz der Schaltmuster oberhalb der untersuchten Frequenz liegt, wird keine Verbesserung der Anregung erreicht.

Noch klarer wird der Einfluss der Schaltoperationen auf die Anregung beim Autobahn-Stromprofil, dessen Spektrogramm in Abb. 5.7 dargestellt ist. Die Parameter der DFT zur Ermittlung der Frequenzanteile sind identisch zum vorherigen Abschnitt. Wie aus dem linken Spektrogramm deutlich wird, beinhaltet das Profil nur zu Beginn nennenswerte Anteile in Frequenzen über 0,1 Hz. Danach ist die Leistungsdichte der höheren Frequenzen sehr niedrig, weswegen der Einfluss der Schalthandlungen deutlich sichtbar wird. Abb. 5.7b zeigt, wie unter dem Einfluss des PWM-Schaltmusters die charakteristischen Frequenzen als erste, zweite, vierte und fünfte Vielfache der Grundfrequenz des Schaltmusters angeregt werden. Da f_{PWM} der Grenzfrequenz des ersten RC-Glieds entspricht, wird dieses entsprechend stark angeregt. Deutlich zu erkennen ist auch in Abb. 5.7c das breitbandige Frequenzspektrum, welches sich durch die Anwendung des PRBS-Schaltmusters ergibt. Hierbei nimmt die Leistungsdichte mit steigender Frequenz leicht ab, der für die Parameterschätzung relevante Frequenzbereich wird jedoch ausreichend angeregt.

Auch für das Autobahn-Profil werden die Grenzfrequenzen der RC-Glieder im Speziellen untersucht. Dazu sind in Abb. 5.8 die spezifischen Frequenzanteile für die verschiedenen Schaltmuster über der Zeit aufgetragen. Die Resultate ähneln stark denen des WLTP-Fahrzyklus. Während die Anregung der kleineren Zeitkonstante durch die Schaltoperationen stark gesteigert werden kann, wird das zweite RC-Glied bereits durch das Stromprofil ausreichend angeregt, sodass keine Verbesserung durch Schaltoperationen sichtbar ist. Auffällig ist, dass insbesondere durch das PWM-Schaltmuster eine stabile Anregung der Grenzfrequenz des ersten RC-Glieds erreicht wird. Die Verbesserungen durch die Schaltoperationen sind sehr prägnant.

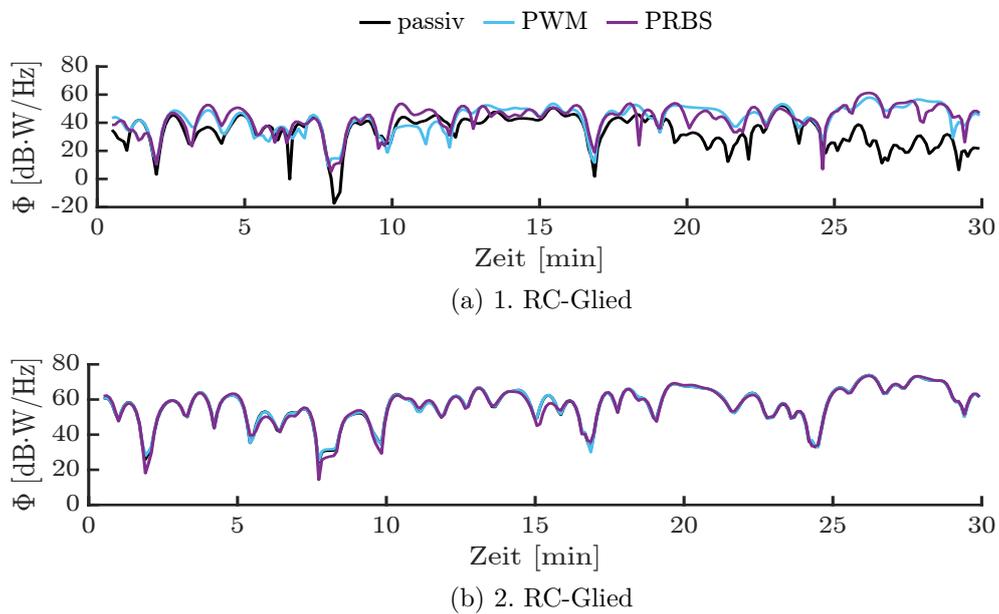


Abbildung 5.6: Leistungsdichte des Zellstroms beim WLTP-Fahrzyklus für die Grenzfrequenzen der beiden RC-Glieder.

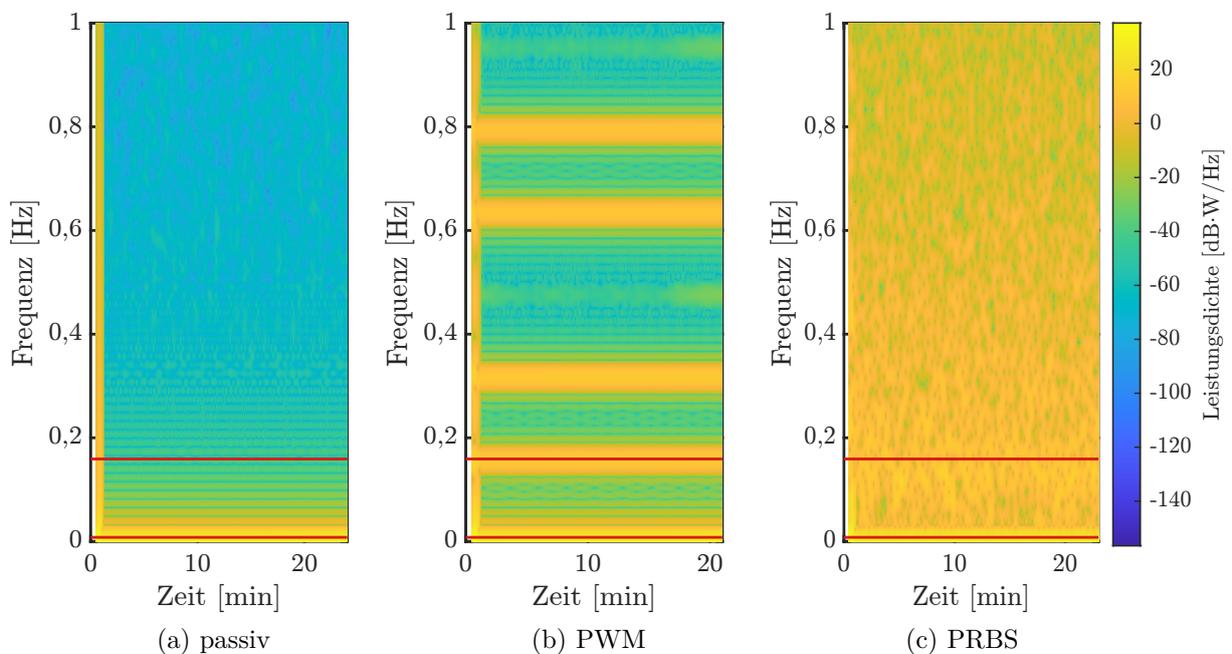


Abbildung 5.7: Spektrogramm des Zellstroms beim Autobahn-Profil abhängig vom Schaltmuster. Die Grenzfrequenzen der RC-Glieder sind rot markiert (obere Linie: 1. RC-Glied, untere Linie: 2. RC-Glied).

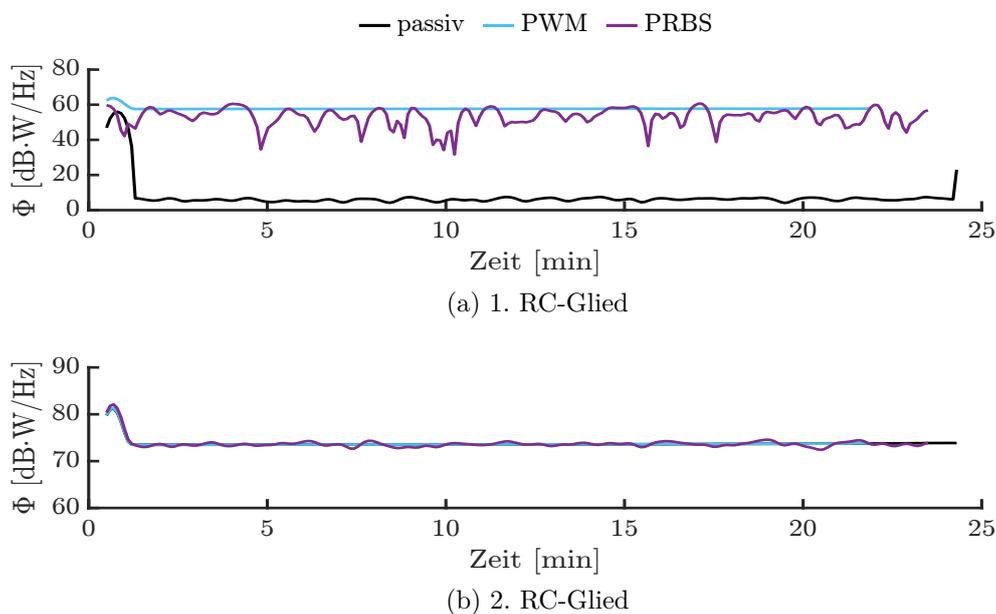


Abbildung 5.8: Leistungsdichte des Zellstroms beim Autobahn-Profil für die Grenzfrequenzen der beiden RC-Glieder.

Auf Basis der Frequenzanalyse ist also zu erwarten, dass Defizite der Schätzverfahren aufgrund mangelnder Anregung der RC-Glieder durch die Schaltoperationen gemindert werden können. Dies ist insbesondere für das Autobahn-Profil der Fall, das keine nennenswerten Anteile im Frequenzbereich oberhalb von 0,1 Hz aufweist.

5.4 Validierung der aktiven Parameterschätzung

Die Wirksamkeit der Schalthandlungen soll anhand eines Versuchsaufbaus bestehend aus zwölf intelligenten Batteriezellen überprüft werden, die in 4s3p-Topologie verschaltet sind. Die SOC- und temperaturabhängigen Parameter der Zellen wurden im Vorfeld durch Charakterisierungstests ermittelt (siehe Kapitel 3.2). Um vergleichbare Ergebnisse zwischen den Versuchsdurchläufen zu erzielen, wird das Batteriemodul zu Beginn jedes Versuchsdurchgangs mit dem CCCV-Verfahren mit 1 C auf 16,4 V geladen, was einer Zellspannung von 4,1 V entspricht. Die CC-Phase endet bei einer Stromrate von 0,1 C. Als Anregung für die Validierungsversuche werden das WLTP- und das Autobahn-Profil eingesetzt. Diese werden in jedem Versuchsdurchgang unter Anwendung der verschiedenen Schaltstrategien wiederholt durchlaufen, bis eine der Zellen des Moduls eine Klemmenspannung von 3,0 V erreicht. Zwischen den Versuchsdurchläufen variiert neben dem Schaltmuster auch der Schwellwert, welcher das anregungsabhängige Schalten beeinflusst. Wenn nicht anders angegeben, gibt es jedoch zunächst keinen Schwellwert, sodass kontinuierlich Schaltoperationen gemäß dem entsprechenden Schaltmuster angewandt werden. Zusätzlich durchgeführte Versuche ohne jede Schalthandlung dienen als Referenz. Während aller Versuche wird die Umgebungstemperatur durch eine Temperatorkammer konstant auf 25 °C gehalten. Die Messwerte von Zellstrom und -spannung werden mit einer Abtastrate von 40 Hz erfasst. Für die weitere Untersuchung erfolgt ein Downsampling auf 10 Hz. Zusätzlich

werden die Messdaten mit einem normal-verteilten künstlichen Rauschen überlagert, dessen Standardabweichung 10 mA bzw. 5 mV ist.

Ein EKF schätzt die Systemzustände $\mathbf{x} = [\text{SOC } u_1 \ u_2]^T$ und -parameter $\boldsymbol{\theta} = [R_0 \ R_1 \ R_2]^T$ mit einer Zykluszeit von 100 ms. Die initiale Kovarianzmatrix ist

$$\hat{\mathbf{P}}_{0|0} = \text{diag}\{2,5 \cdot 10^{-3} \ 1 \cdot 10^{-4} \ 1 \cdot 10^{-4} \ 1 \cdot 10^{-6} \ 1 \cdot 10^{-8} \ 1 \cdot 10^{-6}\} \quad (5.1)$$

und das Messrauschen wird gesetzt zu $R = 2,5 \cdot 10^{-5}$. Das Prozessrauschen entspricht den ermittelten optimalen Werten aus Kapitel 4.3 für die Simulation bzw. die realen Messungen. Die Zustands- und Parameterschätzung wird in 100 Monte-Carlo-Durchläufen wiederholt, um statistisch belastbare Aussagen über die Wirksamkeit der aktiven Parameterschätzung zu erhalten. Hierbei variiert das künstliche Rauschen und der initiale Schätzwert wird mit einem zufälligen Fehler beaufschlagt. Dieser ist für jeden Zustand und Parameter gemäß $\hat{\mathbf{P}}_{0|0}$ normalverteilt. Dadurch wird das Einschwingverhalten des Kalman-Filters ebenfalls in die Bewertung miteinbezogen. Im Folgenden werden die Ergebnisse der Zustands- und Parameterschätzung aus Gründen der Übersichtlichkeit nur für eine intelligente Batteriezelle gezeigt. Die Resultate der restlichen Zellen ähneln jedoch denen der hier gewählten.

5.4.1 Validierung mit Simulationen und Experimenten

Zunächst werden Ergebnisse der Zustands- und Parameterschätzung basierend auf Simulationen mit einem Referenzmodell diskutiert. Die Strom- und Spannungsmesswerte entstammen dabei einem White-Box-Modell der Batteriezelle, wodurch perfektes Wissen über die zu schätzenden Zustände und Parameter vorliegt. Defizite der Modellidentifikation haben keinen Einfluss auf die Schätzung. Zur Bewertung der Güte der Schätzwerte wird der RMSE aller Zustände und Parameter über die Dauer der Simulation herangezogen. Die ermittelten Fehlerwerte werden auf den RMSE des Durchlaufs ohne Schalthandlungen normiert. Ein Wert kleiner eins weist demnach auf eine Verbesserung der Schätzgüte hin. Die Ergebnisse für das WLTP- und das Autobahn-Stromprofil sind in Abb. 5.9 dargestellt. Es handelt sich hierbei um Mittelwerte der 100 Monte-Carlo-Durchläufe.

Betrachtet man zunächst den WLTP-Fahrzyklus, zeigt sich, dass die Schaltoperationen grundsätzlich zu einer Verringerung der Schätzfehler gegenüber einer Zustandsschätzung ohne Schalthandlungen führen. Das PWM-Schaltmuster ist der PRBS überlegen. Der Vorteil gegenüber dem PRBS-Schaltmuster ist für alle Parameter ähnlich. Die Zustände verbessern sich hierbei im Schnitt um 33,7%, die der Parameter sogar um 45,6%. Beim Schalten nach der PRBS sind die Verbesserungen mit 15,6% für die Zustände und 24,3% für die Parameter geringer. Die besseren Ergebnisse des PWM-Schaltmusters können darauf zurückzuführen sein, dass dieses gezielt die Grenzfrequenz des ersten RC-Glieds anregt, wohingegen das PRBS-Schaltmuster eine breite Anregung im Frequenzspektrum verursacht. Indifferentere sind die Ergebnisse für das Autobahn-Profil (siehe Abb. 5.9b). Insgesamt verringert sich der Schätzfehler im Mittel um 33,8% für das PWM-Schaltmuster und um 33,5% für die PRBS. Insbesondere der Innenwiderstand wird mit signifikant erhöhter Genauigkeit geschätzt, wohingegen keine Verbesserung bei u_2 erzielt wird – der Schätzfehler wird hier sogar größer. Dass die Innenwiderstandsbestimmung durch die

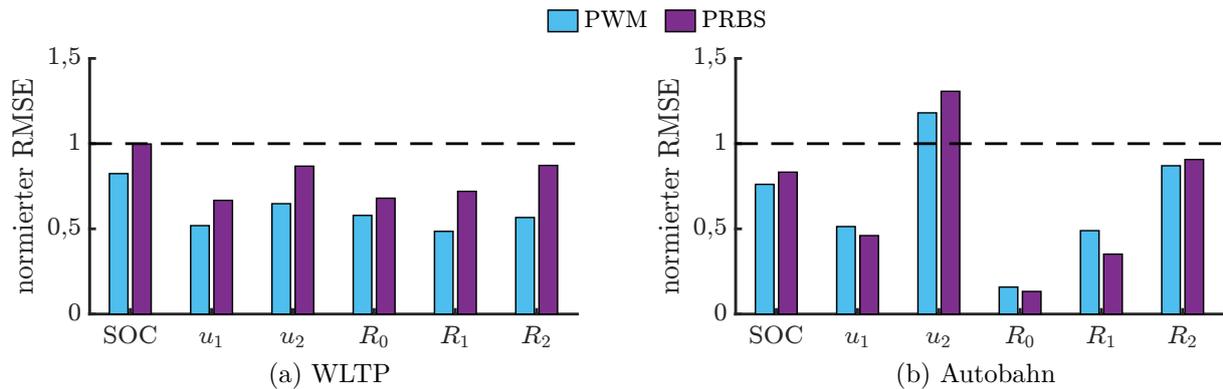


Abbildung 5.9: Normierter RMSE in Bezug auf den Betrieb ohne Schalthandlungen für das WLTP- und Autobahn-Stromprofil (Simulation).

Schalthandlungen signifikant verbessert wird, erscheint auch nachvollziehbar, da das ursprüngliche Autobahn-Stromprofil keinerlei Spannungssprünge aufweist, an denen der Ohmsche Spannungsabfall sichtbar werden kann. Die Schalthandlungen verursachen genau solche Spannungssprünge und in der Folge kann der R_0 präziser bestimmt werden. Auch der u_2 wird im Autobahn-Stromprofil nicht dynamisch angeregt. Aufgrund des nahezu konstanten Stromverlaufs erreicht das zweite RC-Glied einen Ladezustand, danach verändert sich die Spannung jedoch nicht mehr. Dadurch sind die Größen des RC-Glieds nicht mehr gut bestimmbar. Die eingebrachten Schaltoperationen ändern daran nur wenig: Da die angeregten Frequenzen deutlich oberhalb der Grenzfrequenz des zweiten RC-Glieds liegen, wird dieses kaum nennenswert ge- oder entladen. In der Folge verbessert sich auch die Schätzung kaum bzw. verschlechtert sich sogar.

Die Ergebnisse zeigen, dass die geringe Dynamik des Eingangssignals durch die Schaltstrategien der aktiven Parameterschätzung kompensiert werden kann. Eine signifikante Reduktion des RMSEs ist für beide Fahrprofile sichtbar. Beim Autobahn-Profil profitiert insbesondere R_0 , aber auch die Zustände, welche sich auf das erste RC-Glied beziehen. Hier sinkt der Fehler um mehr als die Hälfte. Dass die Reduktion des Schätzfehlers bei denjenigen Zuständen geringer ausfällt, welche dem zweiten RC-Glied zuzuordnen sind – u_2 und R_2 – lässt sich damit begründen, dass sich auch die Anregung des spezifischen Frequenzbereichs nur marginal verbessert, wie in Abschnitt 5.3 gezeigt wurde. Dahingegen erhöht sich durch die Schaltoperationen die Anregung des ersten RC-Glieds deutlich, wodurch auch eine entsprechende Verringerung der Schätzfehler zu erwarten ist.

Die Validierung der Schätzwerte basierend auf den experimentellen Daten erweist sich grundsätzlich als schwierig, weil die Referenzwerte selbst mit einiger Unsicherheit behaftet sind. Da die Referenzparameter aus den Charakterisierungsversuchen das Modellverhalten nicht perfekt widerspiegeln, addieren sich diese Modellfehler zu den Schätzfehlern in der experimentellen Validierung. Dennoch können basierend auf den Monte-Carlo-Durchläufen statistisch signifikante Aussagen zur Verbesserung der Schätzgüte durch die Schaltstrategien abgeleitet werden. Die Ergebnisse sind in Abb. 5.10 dargestellt. Analog zu den simulativen Ergebnissen ist die Verbesserung der Schätzungen beim WLTP-Fahrzyklus geringer ausgeprägt im Vergleich zum Autobahn-Profil. Im Schnitt sinkt der RMSE um 13,3% mit dem PWM-Schaltmuster, jedoch nur 2,4% mit der PRBS. Hier kann auch nicht für alle Zustände bzw. Parameter eine Verbesserung

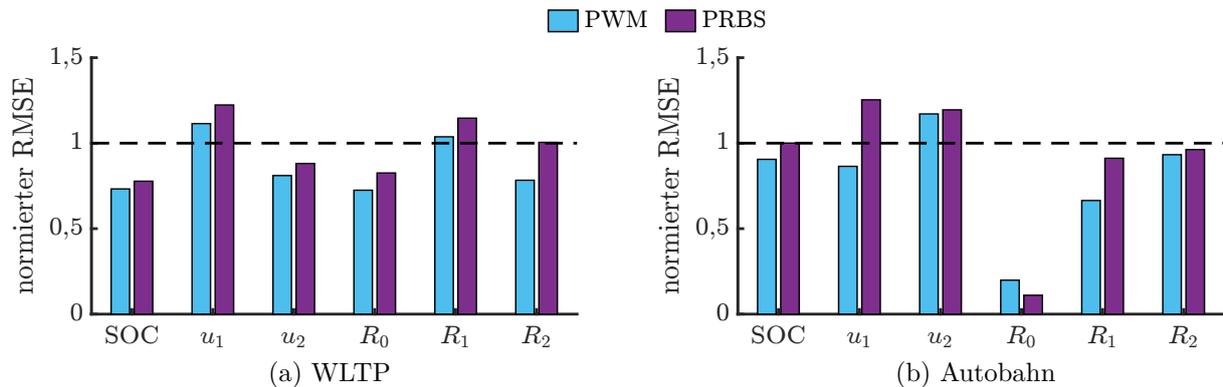


Abbildung 5.10: Normierter RMSE in Bezug auf den Betrieb ohne Schalthandlungen für das WLTP- und Autobahn-Profil (Experiment).

durch die Schalthandlungen erzielt werden. Die Schätzung des SOC's verbessert sich dahingegen um gut ein Viertel und auch der Fehler des Innenwiderstands wird entsprechend kleiner. Das PWM-Schaltmuster ist der PRBS wieder grundsätzlich überlegen. Deutlich ungleichmäßiger sind die Verbesserungen der Schätzung dagegen beim Autobahn-Profil verteilt, bei welchem die Schalthandlungen das Frequenzspektrum des Eingangssignals stärker beeinflussen. Das PWM-Schaltmuster verringert die Schätzfehler von fünf der sechs Zustände, bei der PRBS sind es drei. Insbesondere der Innenwiderstand wird durch die Schalthandlungen jedoch signifikant genauer geschätzt. Mit dem PWM-Schaltmuster verringert sich der RMSE im Mittel um 21,1%, beim PRBS-Schaltmuster sind es lediglich 9,4%.

Bei den durchgeführten Untersuchungen konnte festgestellt werden, dass die Ergebnisse stark von der Parametrierung des Kalman-Filters abhängen. Je nach gewählten Hyperparametern verbessert sich die Schätzung einzelner Zustände oder Parameter mehr oder weniger. Durch das systematische Filter-Tuning aus Kapitel 4.3 kann jedoch das gewählte Prozessrauschen als nachvollziehbar optimal angesehen werden. Insgesamt zeigt sich, dass sich mit dem PWM-Schaltmuster bessere Ergebnisse in Simulation und Experiment erzielen lassen. Die resultierenden Schätzfehler sind in den meisten Fällen geringer. Die folgenden Untersuchungen betrachten daher dieses Schaltmuster genauer.

5.4.2 Einfluss der Schaltfrequenz und des Tastgrads

Um das PWM-Schaltmuster weiter zu untersuchen, werden zwei charakteristische Parameter der Modulation in den folgenden Simulationen variiert: (a) die Taktfrequenz des Rechtecksignals sowie (b) der Tastgrad der PWM. Aufgrund der Topologie des untersuchten Systems mit drei parallelen Zellen pro seriellen Strang und unter der Prämisse, dass höchstens eine Zelle aus dem System geschaltet werden darf, kann der Tastgrad D nicht kleiner als $66,6\%$ sein. Hierbei wird angenommen, dass der Tastgrad jeweils für alle drei Zellen identisch ist. Für die Simulationen werden daher die Tastgrade $D = \{70\%, 80\%, 90\%\}$ untersucht. Die Frequenz des der PWM zugrunde liegenden Rechtecksignals wird in einem Bereich zwischen 3,2 mHz und 1,6 Hz variiert (Kreisfrequenz im Intervall $\omega = [0,02, 10] \frac{1}{s}$). Es werden für jeden der 15 Arbeitspunkte 30 Monte-Carlo-Durchläufe durchgeführt, bei denen das künstliche Messrauschen ebenso variiert

wird, wie die Phasenlage der Schalthandlungen. Dadurch kann ausgeschlossen werden, dass der Einschwingvorgang stark von den ersten Schalthandlungen abhängig ist und dadurch die Schätzergebnisse signifikant abweichen. Die Ergebnisse sind auch immer Mittelwerte über die drei Zellen des Systems.

Die Ergebnisse für das Autobahn-Profil zeigt Abb. 5.11 für alle Zustände und Parameter. Der RMSE ist wieder auf die Resultate ohne Schalthandlungen normiert, sodass Werte unterhalb von eins eine Verbesserung der Schätzgenauigkeit bedeuten. Die Abszisse ist logarithmisch skaliert. Die für die vorhergehenden Ergebnisse aus Abschnitt 5.4.1 zugrunde liegende Frequenz ist durch eine senkrechte rote Linie markiert. Der kontinuierliche Verlauf der resultierenden Fehler abhängig von der Frequenz und des Tastgrads ist ein Indiz für die Validität der ermittelten Ergebnisse. Eine Frequenzabhängigkeit kann für alle Parameter festgestellt werden. Bis auf R_0 weisen alle Kurven eine konvexe Form auf mit einem Minimum im mittleren Frequenzbereich. Während dieses für den SOC, u_2 und R_2 im Bereich um 0,01 Hz liegt, ist die Frequenz der kleinsten Schätzfehler bei u_1 und R_1 um ungefähr den Faktor zehn höher. Der Innenwiderstand wird umso besser geschätzt, je größer die PWM-Frequenz ist. Allerdings stellt sich für Werte über circa 0,4 Hz eine Sättigung ein. Die geringsten Schätzfehler werden mit einer umso niedrigeren Frequenz erreicht, je höher der Tastgrad ist. Grundsätzlich liegt der RMSE für $D = 70\%$ unterhalb dem für $D = 90\%$. Davon abweichende Ergebnisse finden sich nur für hohe Frequenzen bei den Zuständen des zweiten RC-Glieds. Insgesamt lässt sich feststellen, dass die Schaltfrequenz ein Kompromiss aus den resultierenden Schätzfehlern aller Zustände ist und demnach keine optimale Frequenz für die Schätzung aller Zustände und Parameter existiert.

Die Ausschaltzeit der Zellen abhängig von Frequenz und Tastgrad lässt sich berechnen zu

$$t_{\text{off}} = (100\% - D) \cdot \frac{1}{f_{\text{PWM}}}. \quad (5.2)$$

Betrachtet man nun die Minima der Diagramme in Abb. 5.11, also die für den betreffenden Parameter optimale Schaltfrequenz, so lässt sich Folgendes feststellen: Für u_1 und R_1 ergeben sich für t_{off} Werte zwischen 1,26 s und 1,89 s. Dahingegen liegen für u_2 und R_2 die Werte in einem Bereich zwischen 18,85 s und 25,13 s und damit ungefähr um den Faktor zehn höher. Diese Werte erscheinen insofern plausibel, als dass bei Ausschaltzeiten, welche ungefähr der Zeitkonstante des betreffenden RC-Glieds entsprechen, eine Ladung der Kapazität und damit ein Einschwingen der Überspannung stattfindet. Ist die Ausschaltzeit zu klein gewählt, kann keine relevante Entladung der Kapazität stattfinden. Umgekehrt sinkt die Überspannung auf null Volt und weist keine Dynamik mehr auf, wenn die Ausschaltzeit zu groß ist. Es kann daher geschlussfolgert werden, dass eine ideale Anregungsfrequenz der RC-Glieder und ein dazu passender Tastgrad ungefähr Ausschaltzeiten im Bereich der entsprechenden Zeitkonstante erzeugt. Dementsprechend verschieben sich die Minima in den Diagrammen von u_1 , R_1 , u_2 und R_2 in Abb. 5.11 mit steigendem Tastgrad hin zu tieferen Frequenzen.

Der Schätzfehler für den SOC korreliert mit denen von u_2 und R_2 . In Fällen, in denen diese beiden Größen gut geschätzt werden, sinkt entsprechend auch der Schätzfehler für den Ladezustand. Dies kann darauf zurückgeführt werden, dass eine fehlerhafte Schätzung von u_2 durch den SOC kompensiert wird, um die prädiizierte zur gemessenen Zellspannung zu korrigieren. Beispielsweise führt eine zu große Polarisationsspannung dann zu einem zu kleinen Wert für den Ladezustand.

Dieser Effekt tritt beim ersten RC-Glied kaum auf, weil dessen Zeitkonstante klein und das Verhalten weniger träge ist.

Die Schätzung von R_0 profitiert von Schalthandlungen, weil bei sprunghaften Stromänderungen der instantane Spannungsabfall aufgrund des Innenwiderstands deutlich wird. Daher ist der Schätzfehler umso kleiner, je höher die Schaltfrequenz ist. Allerdings ist für Frequenzen ab circa 0,3 Hz eine Sättigung erkennbar.

Die Simulationen werden für das WLTP-Stromprofil wiederholt. Die Ergebnisse zeigt Abb. 5.12 für alle Zustände und Parameter. Der Verlauf der Größen ist im Vergleich zum Autobahnprofil weniger stetig. Das ist möglicherweise darauf zurückzuführen, dass im Gegensatz zum Autobahnprofil die Anregung nicht mehr konstant ist. Abhängig von den Schaltvorgängen sind daher die Zellen während Phasen guter oder schlechter Anregung ausgeschaltet, was die Korrektur der Schätzung und damit deren Fehler beeinflusst. Insbesondere bei geringen Schaltfrequenzen sind die Ausschaltzeiten der Zellen so lang, dass relevante dynamische Stromsequenzen die ausgeschaltete Zelle nicht anregen. Abgesehen von R_2 gilt für alle Zustände, dass eine hohe Schaltfrequenz zu einem geringeren RMSE führt. Diese ist jedoch durch die Zykluszeit des Filters begrenzt. Für alle Zustände gilt zudem, dass ein geringerer Tastgrad von $D = 70\%$ zu besseren Ergebnissen führt gegenüber $D = 80\%$ oder sogar $D = 90\%$, wenn $f_{\text{PWM}} > 30$ MHz ist. Weiterhin kann den Diagrammen entnommen werden, dass sich abgesehen von u_2 ab einer Schaltfrequenz von ungefähr 5 MHz immer eine Verbesserung der Schätzgenauigkeit gegenüber der Schätzung ohne Schalthandlungen ergibt.

Je nach Wahl der Taktfrequenz und des Abtastgrads der PWM befindet sich die betrachtete Zelle für kürzere oder längere Zeiträume im ein- bzw. ausgeschalteten Zustand. Hierzu lässt sich festhalten: Die Zustände des Batteriesystems SOC, u_1 und u_2 lassen sich mit höherer Genauigkeit schätzen, wenn der Strom $i_{\text{zelle}} = 0$ A ist, da sich der Ladezustand dann allein aus der Leerlaufspannung bemisst und die Überspannungen abklingen. Sie können also nach einer gewissen Abklingzeit mit Sicherheit zu 0 V angenommen werden. Wie bereits gezeigt, sind jedoch die Parameter des Modells, R_0 , R_1 und R_2 für $i_{\text{zelle}} = 0$ A nicht beobachtbar. Daraus folgt, dass die Parameter immer dann gut geschätzt werden können, wenn die Zelle eingeschaltet und ein Anregungsstrom vorhanden ist. Die präzise Schätzung der Zustände und Parameter ist daher ein Zielkonflikt für die aktive Parameterschätzung.

5.4.3 Einfluss des Schwellwerts für situatives Schalten

Der Schwellwert für das anregungsabhängige Schalten bestimmt, wie viele Schaltvorgänge während der Schätzung durchgeführt werden. Ist er niedrig gewählt, finden nur wenige Schaltvorgänge statt, da die Anregung des Eingangssignals schneller als ausreichend bewertet wird. Ein hoher Schwellwert dagegen erhöht die Anzahl an Schalthandlungen bis hin zu dauerhaftem Schalten, wenn der Schwellwert beliebig groß wird. Um zu untersuchen, inwiefern die Wahl der Schwellwertes das Schätzverfahren beeinflusst, können die RMSEs in Abhängigkeit von diesem untersucht werden. Die Untersuchung stützt sich nur auf den WLTP-Fahrzyklus, weil in diesem die Stärke der Anregung im Frequenzbereich von τ_1 und τ_2 signifikanten Änderungen unterworfen ist. Wie Abb. 5.3e zu entnehmen ist, gilt dies nicht für das Autobahn-Profil. Die Wahl des Schwellwerts hat hier entweder zur Folge, dass dauerhaft geschaltet wird oder gar keine Schalthandlungen

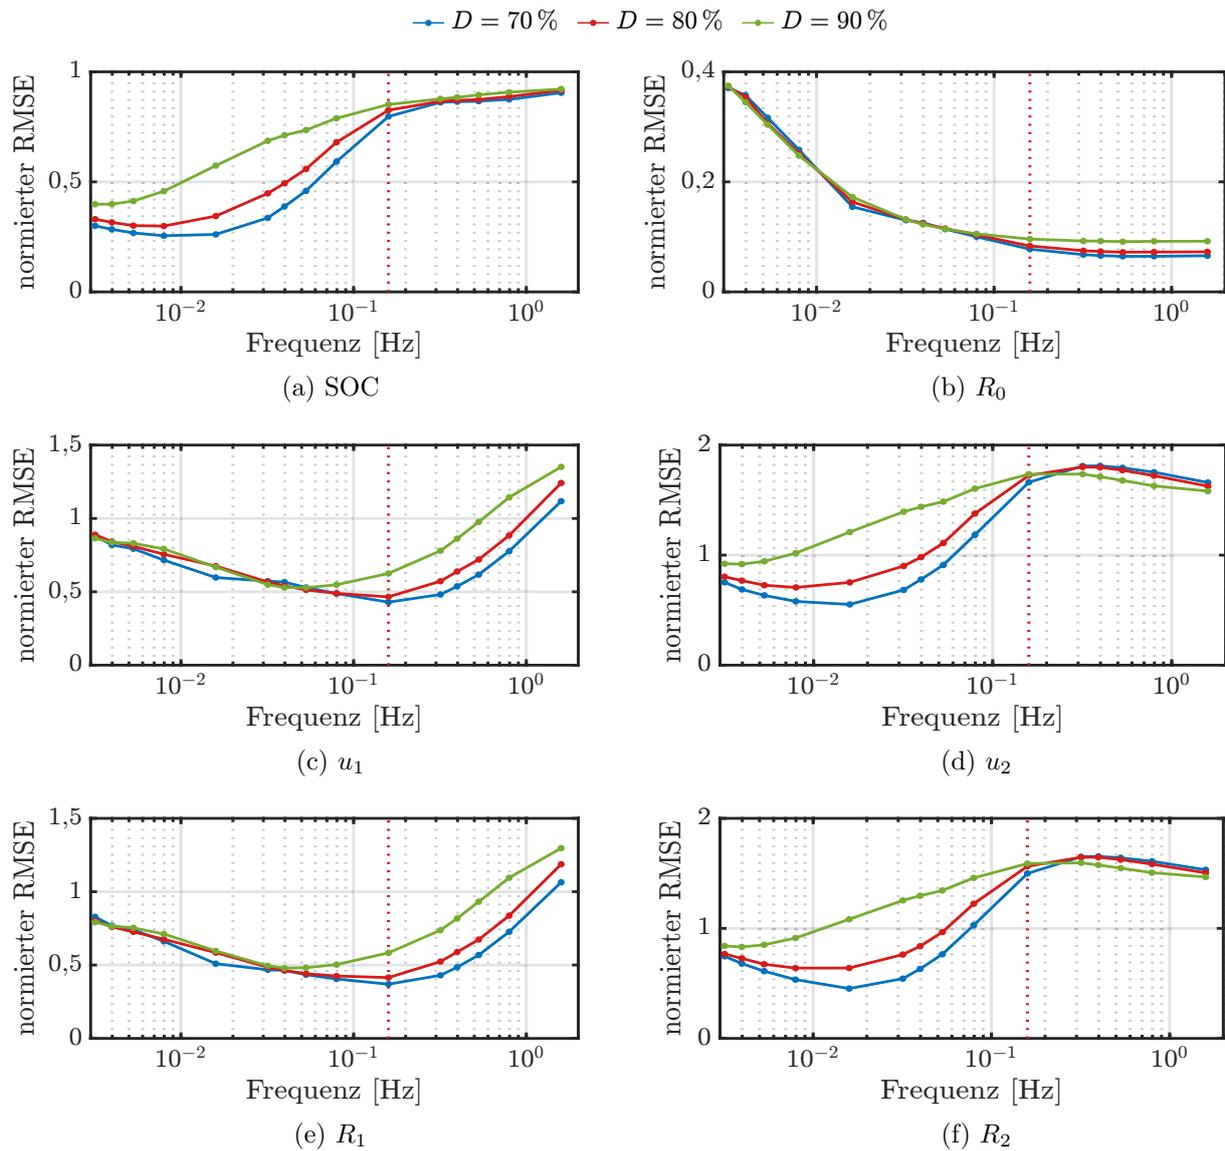


Abbildung 5.11: Normierter RMSE aller Zustände und Parameter in Abhängigkeit von der Taktfrequenz des PWM-Schaltmusters für das Autobahn-Stromprofil.

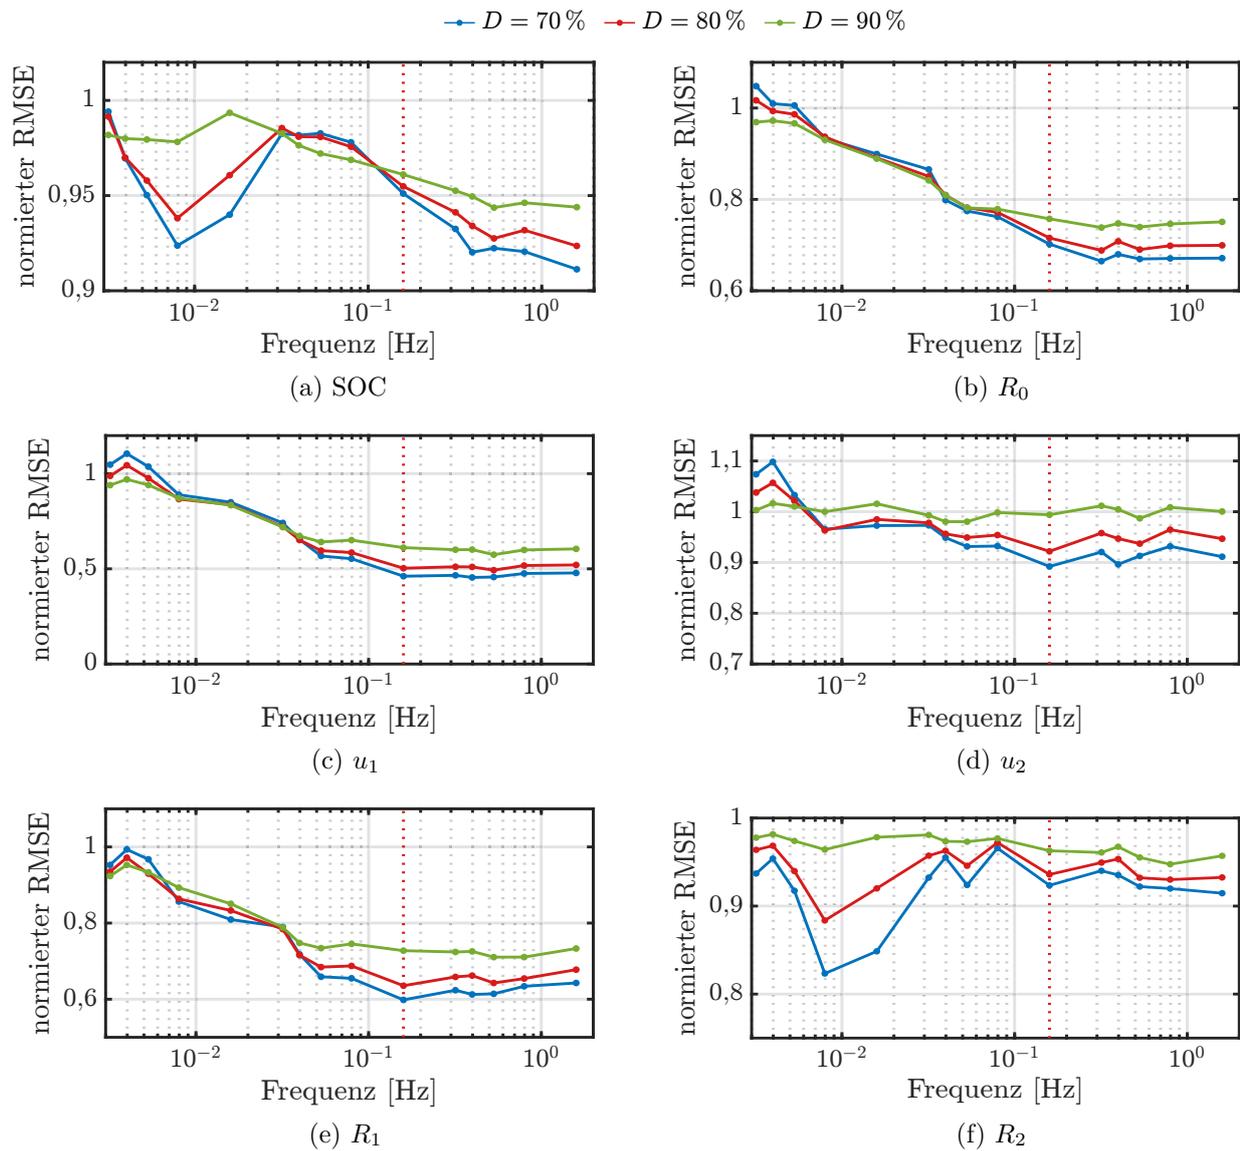


Abbildung 5.12: Normierter RMSE aller Zustände und Parameter in Abhängigkeit von der Taktfrequenz des PWM-Schaltmusters für das WLTP-Stromprofil.

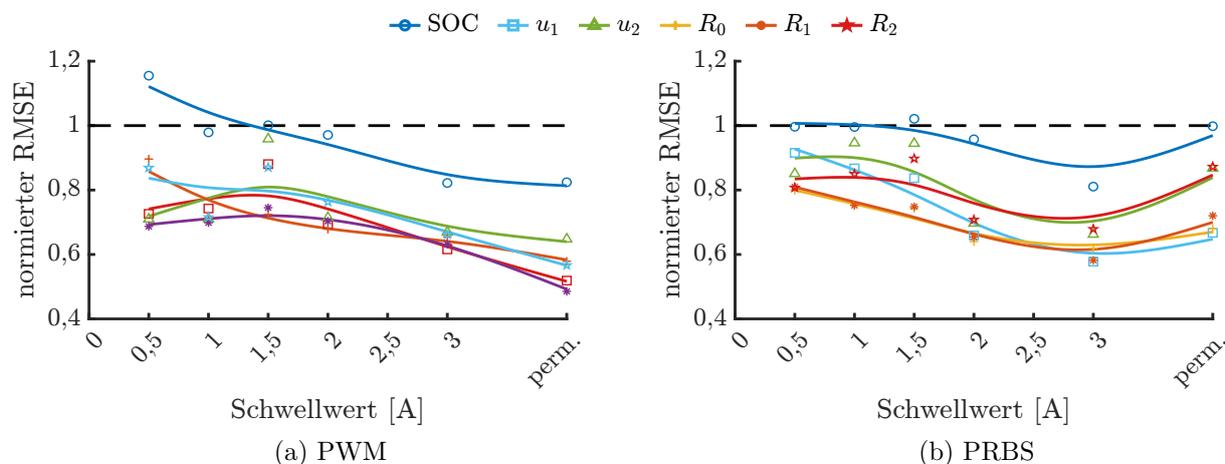


Abbildung 5.13: Normierter RMSE des WLTP-Fahrzyklus für unterschiedliche Schwellwerte und permanentes (perm.) Schalten.

durchgeführt werden. Eine Untersuchung des Einflusses vom Schwellwert auf die Schätzung ist demnach nicht zweckmäßig.

Die normierten RMSEs für alle Schätzgrößen in Abhängigkeit vom Schwellwert sind in Abb. 5.13 aufgetragen. Die Normierung bezieht sich erneut auf die Zustands- und Parameterschätzung ohne Schalthandlungen. Die Ergebnisse stammen aus den durchgeführten Simulationen und sind für beide untersuchten Schaltmuster getrennt dargestellt. Es handelt sich wieder um den Mittelwert aus 100 Monte-Carlo-Durchläufen. Aus den Diagrammen wird deutlich, dass der Schwellwert abhängig vom Schaltmuster einen Einfluss auf die Schätzung hat. Beim PWM-Schaltmuster führt eine Erhöhung des Schwellwerts zu einer Reduktion der Schätzfehler. Ein lokales Maximum des RMSEs für u_2 und R_2 kann bei einem Schwellwert von 1,5 A beobachtet werden. Ist der Schwellwert zu gering, kann sich die SOC-Schätzung gegenüber der passiven Zustandsschätzung sogar verschlechtern. Beim PRBS-Schaltmuster ist kein klarer Trend der Fehler abhängig vom Schwellwert erkennbar. Die geringsten RMSEs werden bei einem Wert von 3,0 A erreicht. Nur dann findet eine relevante Reduktion des Schätzfehlers für den SOC statt. Insgesamt ist die Sensitivität des Schwellwerts auf die Zustands- und Parameterschätzung aber gering. Zur abschließenden Bewertung eines sinnvollen Schwellwerts muss darüber hinaus auch der Einfluss auf die Zellalterung bedacht werden.

5.4.4 Diskussion des Einflusses von Schaltvorgängen auf die Zellalterung

Die Frage, inwiefern Schalthandlungen die Zellalterung beeinflussen, ist in der Wissenschaft noch nicht abschließend geklärt. Zunächst bestimmt die Strombelastung im Verhältnis zur Stromtragfähigkeit der Batteriezelle deren Alterung [112]. Aufgrund der großzügigen Dimensionierung der Batteriesysteme in heutigen BEVs mit dem Ziel einer für den Kunden akzeptablen Reichweite ist die Stromrate in weiten Betriebsbereichen relativ gering. Daher werden die Grenzen der Stromtragfähigkeit der Batteriezellen nur selten erreicht, am ehesten noch während Schnellladevorgängen. Die Schalthandlungen selbst können Alterungseffekte adressieren, allerdings scheint dies vor allem für Schaltfrequenzen im Kilohertz-Bereich zu gelten [281–283]. Andererseits

können Schalthandlungen auch eine Homogenisierung der Ladezustände innerhalb der Zellen bewirken. Diesen Sachverhalt nutzen beispielsweise Pulsladeverfahren aus, bei denen zwischen den Ladepausen der Ladestrom reduziert, abgeschaltet oder sogar invertiert wird. Dadurch bauen sich Inhomogenitäten innerhalb der Anoden- und Kathodenmaterialien ab [284, S. 327]. In jedem Fall aber erhöhen die vorgestellten Schaltstrategien den Effektivwert der Zellströme. Die dadurch bedingte Vergrößerung der Verlustleistung kann zu höheren Zelltemperaturen führen, was Alterungseffekte beschleunigt [285–288]. Wie von Juang et al. [287] vorgeschlagen, soll daher der Effektivwert (engl. *root mean squared*, RMS) des Zellstroms als Maß für eine potenzielle Beschleunigung der Zellalterung dienen.

Abhängig vom Schwellwert und der dadurch bedingten Häufigkeit von Schaltvorgängen sinkt die Zeit, in welchen die Batteriezellen eingeschaltet sind. Der prozentuale Anteil an der Gesamtversuchsdauer, in welcher die Zelle eingeschaltet ist, wird in Tabelle 5.1 als Einschalttrate bezeichnet. Je größer der Schwellwert gewählt wird, desto geringer wird sie, weil mehr Schaltvorgänge stattfinden. Ein unendlicher Schwellwert bedeutet hierbei dauerhaftes Schalten. In Tabelle 5.1 ist weiterhin für jeden Versuch der RMS und außerdem der relative RMS angegeben. Mit Letzterem ist die prozentuale Veränderung im Vergleich zum konventionellen Betrieb ohne Schalten gemeint. Wie der Tabelle entnommen werden kann, erhöht sich der Effektivwert des Stroms abhängig vom gewählten Schaltmuster und auch abhängig vom Schwellwert um 0,6 % bis 9,8 %. Es stellt sich nun die Frage, bis zu welchem Grad die Verbesserung der Schätzung mit einer erhöhten Zellalterung bezahlt wird. Aus den Ergebnissen des vorherigen Abschnitts konnte ein für die Zustands- und Parameterschätzung vorteilhafter Schwellwert von 3,0 A für das PRBS-Schaltmuster ermittelt werden. Beim PWM-Schalten sind die Fehler am kleinsten, wenn dauerhaft geschaltet wird. Die dabei auftretende Erhöhung der Verlustleistung um 5,1 % (PWM) bzw. 2,5 % (PRBS) erscheint akzeptabel. Bei der Einordnung der Erhöhung der Verlustleistung ist zu beachten: Ein leistungsfähiges Thermomanagement ist in der Lage, die zusätzliche Wärme aus dem Batteriesystem abzuführen und damit eine Beschleunigung der Zellalterung zu verhindern. In jedem Fall sinkt dadurch aber der Wirkungsgrad des Gesamtsystems. Eine Begrenzung vom Effektivwert des Stroms ist daher in jedem Fall anzustreben, in dem hier beobachteten Rahmen jedoch tolerierbar.

5.5 Zusammenfassung der Ergebnisse

Eine robuste Zustands- und Parameterschätzung in intelligenten Batteriesystemen lässt sich nicht nur durch Modifikationen des Filters selbst erreichen. Als mechatronisches System erlauben die Schalter eine gezielte Steuerung des Stromflusses und damit eine Erhöhung der Systemanregung. In diesem Kapitel wurden dafür geeignete Schaltmuster und -strategien vorgestellt und auf ihre Wirksamkeit hin untersucht. Die Ergebnisse zeigen, dass Schaltvorgänge in der Tat die Genauigkeit der Schätzung von Zuständen und Parametern verbessern können. Der als Fehlermaß herangezogene RMSE konnte im Mittel signifikant reduziert werden. Insbesondere das PWM-Schaltmuster zeigt gute Ergebnisse. Gleichzeitig bleibt die Erhöhung der Verlustleistung moderat, was eine mögliche Beschleunigung der Zellalterung limitiert. Zwar verringern sich in den durchgeführten Versuchen nicht die Schätzfehler aller Zustandsgrößen und Parameter, allerdings verbessert sich die Schätzung immer für den Ladezustand und signifikant für den Innenwider-

Tabelle 5.1: Schaltmuster und ihre Charakteristik basierend auf dem WLTP-Fahrzyklus. Der relative Effektivwert (rel. RMS) beschreibt die Ab- bzw. Zunahme im Vergleich zur Anregung ohne Schalthandlungen.

Schaltmuster	Schwellwert	Einschaltrate	RMS	rel. RMS
PWM	0,5 A	96,9 %	1,83 A	+2,3 %
PWM	1,0 A	95,8 %	1,80 A	+0,8 %
PWM	1,5 A	94,6 %	1,84 A	+3,0 %
PWM	2,0 A	93,0 %	1,81 A	+1,4 %
PWM	3,0 A	91,2 %	1,80 A	+0,6 %
PWM	∞	90,5 %	1,88 A	+5,1 %
PRBS	0,5 A	94,8 %	1,82 A	+1,7 %
PRBS	1,0 A	93,2 %	1,84 A	+2,9 %
PRBS	1,5 A	91,1 %	1,87 A	+4,5 %
PRBS	2,0 A	88,6 %	1,87 A	+4,7 %
PRBS	3,0 A	86,0 %	1,83 A	+2,5 %
PRBS	∞	83,5 %	1,96 A	+9,8 %

stand R_0 . Da der Ladezustand eine für den Betrieb wichtige Kenngröße für den Energieinhalt und der Innenwiderstand bestimmend für die Leistungsfähigkeit des Batteriesystems ist, können die Schalthandlungen der aktiven Parameterschätzung insgesamt als hilfreich für den Betrieb des Batteriesystems angesehen werden.

Die in diesem Kapitel gemachten Untersuchungen in der Zeit-Domäne können auch im Frequenzbereich angewandt werden. Wie Liebhart et al. [21] in ihrer Arbeit beschreiben, lassen sich Schaltoperationen in RBSs dazu nutzen, bessere Impedanzspektren zu messen. Dabei werden allerdings deutlich höhere Schaltfrequenzen betrachtet.

Auch in herkömmlichen Batteriesystemen mit fest vorgegebener Topologie können die Erkenntnisse dieses Kapitels von Nutzen sein. Statt durch die Schaltoperationen in RBSs kann die Anregung bestimmter Frequenzen auch durch eine externe Last erreicht werden. Wird beispielsweise ein Verbraucher im Fahrzeug zyklisch zu- und weggeschaltet, lässt sich dem Laststrom ebenso ein bestimmter Frequenzanteil einprägen.

6 Sensordatenfusion in intelligenten Batteriesystemen

6.1 Motivation für eine Sensordatenfusion

Durch die Verwendung robuster Schätzmethoden lassen sich die Systemzustände eines intelligenten Batteriesystems ebenso wie die Modellparameter der Zellen zu jedem Zeitpunkt sicher bestimmen. Unter dieser Voraussetzung können modellbasierte Verfahren eingesetzt werden, um die Sensordaten der Zell-Sensoren für Strom und Spannung miteinander zu fusionieren.

Als Datenfusion werden allgemein Techniken verstanden, bei denen durch die Verknüpfung von Daten mehrerer Quellen die Genauigkeit und Zuverlässigkeit der Information erhöht wird. Weiterhin kann auch ein Ziel der Datenfusion sein, die räumliche oder zeitliche Abdeckung einer Messung zu erhöhen oder die Robustheit einer Messung zu steigern [289, 290]. Bei der Sensordatenfusion (SDF) können unterschiedliche Sensordomänen und Informationsquellen herangezogen werden, beispielsweise, wenn für die Umfeldwahrnehmung eines Fahrzeugs Messdaten von Radar, Lidar und Kamera kombiniert werden. Im Rahmen dieser Arbeit werden jedoch die gleichartigen Strom- bzw. Spannungssensoren im IBS mit zellintegrierter Sensorik miteinander fusioniert, welche entsprechend der Anzahl an Batteriezellen vorhanden sind.

Das erste Ziel der SDF ist die Reduktion der Varianz des Messrauschens. Unter der gültigen Annahme, dass das Rauschen der Sensoren zueinander unkorreliert ist, sinkt dessen Störeinfluss auf den Messwert, wenn mehrere Sensormessungen miteinander fusioniert werden. Bei gegebener Anforderung eines bestimmten zulässigen Sensorrauschens können demnach unter Anwendung der SDF einfachere und damit günstigere Sensoren verwendet werden, als dies ohne Fusion notwendig wäre.

Die SDF in IBSs trägt dem zusätzlichen Hardwareaufwand Rechnung, der durch die Verwendung von Sensoren in jeder Einzelzelle verursacht wird. Dieser Aufwand ist mit zusätzlichen Kosten verbunden und läuft den gängigen Bestrebungen der Entwicklung in der Automobilbranche entgegen, die Anzahl an Sensoren in Systemen allgemein möglichst gering zu halten. Durch die SDF ist es möglich, sehr einfache Sensoren und eine simple Messdatenerfassung für die Zellströme und -spannungen zu verwenden und dennoch eine ausreichende Messgenauigkeit bzw. geringe Messunsicherheit durch die Fusion der korrelierten Sensordaten zu erhalten.

Als zweites Ziel erhöht sich die Robustheit der Messung, da bei Ausfall eines Sensors das Messsignal basierend auf den verbleibenden Sensoren noch mit ausreichender Genauigkeit rekonstruiert werden kann. Damit bleiben beispielsweise Funktionen des Batteriemangements, welche auf der Messung der Zellströme beruhen, im Fall eines Sensordefekts intakt.

Während die Stromfusion für rein serielle Topologien ein triviales Problem darstellt (da der die Zellen durchfließende Strom überall gleich groß ist) muss bei Parallelsträngen die Stromaufteilung zwischen den Zellen berücksichtigt werden. Analog ist die Fusion der Spannungen von parallel geschalteten Zellen trivial, wohingegen im seriellen Strang die Aufteilung der Gesamt-

spannung auf die einzelnen Zellen von Bedeutung ist. Für beide nicht-trivialen Fälle lässt sich ein Batteriesystemmodell mit den entsprechenden Zuständen und Parametern verwenden.

Wie im weiteren Verlauf des Kapitels gezeigt wird, kann ein modellbasierter Ansatz zur Fusion von Strom- und Spannungsmessdaten vorteilhaft angewandt werden. Voraussetzung dafür ist, dass neben den Zuständen der Innenwiderstand der zugrunde liegenden Zellmodelle zur Laufzeit adaptiert wird, um Veränderungen aufgrund des Ladezustands, der Temperatur oder Alterungseffekten Rechnung zu tragen. Hierfür kommt eine Innenwiderstandsschätzung zur Anwendung, welche im Folgenden basierend auf den Ergebnissen der vorangehenden Kapitel adaptiert wird. Weil ein Fokus auf der Robustheit des Schätzverfahrens liegt, werden für die SDF weitere Modifikationen des Schätzers vorgenommen, welche diesem Ziel dienen.

Teile dieses Kapitels werden in wissenschaftlichen Publikationen des Autors behandelt. Inhalte von Abschnitt 6.2 finden sich in [291]. Teile des Kapitels 6.3 sind in [292] veröffentlicht und Kapitel 6.4 beruht auf [293].

6.2 Verfahren zur robusten Bestimmung des Innenwiderstands

Je mehr Zustände und Parameter Teil der Schätzung sind, desto geringer ist deren Robustheit. Campestrini et al. [244] beobachten, dass ein DKF basierend auf einem Batteriemodell mit nur einem RC-Glied eine höhere Schätzgenauigkeit aufweist, als mit zwei. Als Grund hierfür wird die größere Anzahl an zu schätzenden Zuständen genannt, was die Schätzung erschwert. Darüber hinaus steigt der Parametrierungsaufwand, je mehr Parameter geschätzt werden sollen. Folglich ist es für eine robuste Zustands- und Parameterschätzung zielführend, nur so viele Zustände und Parameter zu schätzen, wie für den Anwendungsfall notwendig sind, und so wenige wie möglich. Mit steigender Dimension des Zustandsvektors ist darüber hinaus eine Systemanregung in einem immer breiteren Frequenzband und mit größerer Amplitude notwendig, um eine akzeptable Schätzgenauigkeit zu erhalten. Im Gegensatz zu Kapitel 5, in dem genau dies durch die Anwendung gezielter Schalthandlungen forciert wurde, wird in diesem Abschnitt ein einfacher Parameterschätzer für den Innenwiderstand entworfen und untersucht, welcher den Zustandsschätzer von SOC und den Überspannungen ergänzt. Dadurch ist für die Umsetzung der Sensordatenfusion keine Rekonfigurierbarkeit des Batteriesystems notwendig. Die Betrachtung einer sehr einfachen kombinierten Zustands- und Parameterschätzung ist dadurch motiviert, dass der Innenwiderstand neben den Zuständen des Ersatzschaltbildmodells eine wichtige Grundlage für die SDF ist. Das hier vorgestellte Kalman-Filter stellt Schätzwerte genau für diese benötigten Größen bereit. Ein Fokus beim Entwurf des Filters liegt auf einer hohen Robustheit gegenüber Phasen mit einer ungenügenden Systemanregung und daraus resultierenden Messausreißern.

6.2.1 Adaption eines Dual-Kalman-Filters

Für die Zustandsschätzung und die Bestimmung des Innenwiderstands wird in diesem Kapitel ein DKF adaptiert, dessen beide Filter mit ihren relevanten Charakteristika in Tabelle 6.1 zusammengefasst sind. Während auf der einen Seite der Zustandsschätzer den Ladezustand sowie die Überspannungen der RC-Glieder des Ersatzschaltbildmodells schätzt, fokussiert sich der

Tabelle 6.1: Übersicht über die beiden Kalman-Filter des DKFs.

	Zustandsschätzer	Parameterschätzer
Zustandsvektor	$\mathbf{x} = [\text{SOC} \ u_1 \ u_2]^\top$	$\theta = [R_0]$
Systemeingang	i_{zelle}	-
Messausgang	u_{zelle}	$\frac{u_{\text{zelle}} - \hat{u}_\Sigma}{i_{\text{zelle}}}$
Systemgleichung	siehe (3.6a)	$\theta_{k+1} = \theta_k$
Messgleichung	siehe (3.6b)	$y_{\theta,k} = \theta_k$

Parameterschätzer auf der anderen Seite auf die Bestimmung des Innenwiderstands. Aufgrund der Wahl der Zustands- und Messgrößen in beiden Teilen des DKFs können jeweils lineare Kalman-Filter eingesetzt werden. Im Folgenden werden die dem Zustandsschätzer zugehörigen Größen mit dem Index x bezeichnet und damit gegenüber den Größen des Parameterschätzers mit dem Index θ abgegrenzt, sofern dies notwendig ist.

Während es sich beim ersten Kalman-Filter um einen herkömmlichen Zustandsschätzer handelt, wie er in Kapitel 4.1.2 vorgestellt wurde, weist der Parameterschätzer einige Besonderheiten auf. Da kein Modellwissen über die Veränderung von R_0 vorhanden ist, wird ein Random-Walk-Modell für die Prädiktion verwendet. Die bestmögliche Schätzung des Innenwiderstands zum Zeitpunkt $k + 1$ ist also der Schätzwert zum Zeitpunkt k . Weiterhin erfolgt die Korrektur der a priori Schätzung über eine indirekte Messung des Innenwiderstands, indem der angenommene Spannungsabfall über den Innenwiderstand ($u_{\text{zelle}} - u_\Sigma$) durch den Zellstrom geteilt wird. Damit entspricht die Messung y dem geschätzten Innenwiderstand \hat{R}_0 , bzw. dem Parameter $\hat{\theta}$.

Für die Parametrierung der Kovarianzmatrizen von Prozess- und Messrauschen des Zustandsschätzers können Abschätzungen auf Basis der Messunsicherheiten der involvierten Sensoren getroffen werden. So ist für das Prozessrauschen das Messrauschen des Stromsensors relevant, welches über die Eingangsmatrix \mathbf{B} auf den Systemzustand \mathbf{x} wirkt. Weiterhin werden die Modellierungsfehler der Systemgleichung als Prozessrauschen abgebildet und durch den additiven Term $\Delta\mathbf{Q}$ in dessen Kovarianzmatrix berücksichtigt. Hierbei handelt es sich um eine Diagonalmatrix mit den für die Systemzustände relevanten Einträgen auf der Hauptdiagonalen. Es zeigt sich, dass $\Delta\mathbf{Q}$ das Prozessrauschen des Zustandsschätzers dominiert, weswegen im Folgenden vereinfachend $\mathbf{Q}_x \approx \Delta\mathbf{Q}$ angenommen wird. Diese Matrix wird durch die Mehrziel-Optimierung aus Kapitel 4.3 bestimmt. Das Messrauschen setzt sich aus zwei Summanden zusammen, welche auf das Messrauschen des Spannungs- bzw. Stromsensors zurückgehen. Während Fehler der Spannungsmessung direkt auf die Messung y_x wirken, ist der Einfluss des Stromsensors von der Größe des Innenwiderstands R_0 abhängig. Als bestmögliche Näherung für dessen Wert kann die Schätzung \hat{R}_0 herangezogen werden, welche dem Zustand des Parameterschätzers entspricht. Für eine mathematisch exakte Beschreibung des Messrauschens müsste auch der Einfluss der Unsicherheit der Innenwiderstandsschätzung $\text{Var}\{\hat{R}_0\}$ auf die Messung y_x berücksichtigt werden. Da die Kovarianzmatrizen jedoch weniger analytisch exakt, sondern vielmehr als auf die Größenordnung genau gewählt werden und darüber hinaus der Innenwiderstand als hinlänglich genau bekannt gelten kann, ist eine Vernachlässigung der Unsicherheit der Innenwiderstandsschätzung gerechtfertigt. Alternativ kann eine Näherung von Oliveira und Seijas-Macias [294] für das Produkt $z = p \cdot q$ von zwei

normalverteilten Zufallsgrößen $p(x) = \mathcal{N}(x|\mu_p, \sigma_p^2)$ und $q(x) = \mathcal{N}(x|\mu_q, \sigma_q^2)$ angewandt werden.

$$\mathbb{E}\{z\} = \mu_p \mu_q \quad (6.1a)$$

$$\text{Var}\{z\} = \mu_q^2 \sigma_p^2 + \mu_p^2 \sigma_q^2 + \sigma_p^2 \sigma_q^2 \quad (6.1b)$$

Unter der Annahme, dass die Varianz der Innenwiderstandsschätzung im Vergleich zum Messrauschen des Stromsensors sehr klein ist ($\sigma_q^2 \ll \sigma_p^2$), nähert sich der Wert der angenommenen Vereinfachung an, welcher den Einfluss von $\text{Var}\{\hat{R}_0\}$ vernachlässigt.

$$\text{Var}\{z\} = \mu_q^2 \sigma_p^2 \quad \text{für } \sigma_q^2 \ll \sigma_p^2 \quad (6.2)$$

Das Prozessrauschen des Parameterschätzers ist naturgemäß unbekannt, da es sich beim zugrunde liegenden Modell um ein Random-Walk-Modell handelt. Verfahren zur Bestimmung des Prozessrauschens wurden in Kapitel 4.3 beschrieben und werden hier angewandt. Betrachtet man dahingegen die Varianz der Messung

$$\text{Var}\{y_\theta\} = \text{Var}\left\{\frac{\tilde{u}_{\text{zelle}} - \hat{u}_\Sigma}{\tilde{i}_{\text{zelle}}}\right\}, \quad (6.3)$$

so gilt zwar, dass die Messgrößen \tilde{u}_{zelle} , \tilde{i}_{zelle} und die Schätzung \hat{u}_Σ normalverteilte Zufallsgrößen sind, dies gilt jedoch nicht für den Bruch zweier normalverteilter Größen. Die Varianz des Messrauschens lässt sich aber zumindest abschätzen, wofür im Folgenden zwei Verfahren vorgestellt werden. Eine Näherung der Varianz $\text{Var}\{p/q\}$ mit den beiden normalverteilten Zufallszahlen $p(x) = \mathcal{N}(\mu_p, \sigma_p^2)$ und $q(x) = \mathcal{N}(\mu_q, \sigma_q^2)$ liefern Díaz-Francés und Rubio [295] basierend auf einer Taylor-Approximation erster Ordnung mit

$$\text{Var}\left\{\frac{p}{q}\right\} = \frac{\mu_p^2}{\mu_q^2} \left(\frac{\sigma_p^2}{\mu_p^2} - 2 \frac{\text{Cov}\{p, q\}}{\mu_p \mu_q} + \frac{\sigma_q^2}{\mu_q^2} \right). \quad (6.4)$$

Damit ergibt sich als Abschätzung für die gesuchte Varianz der Messung

$$\text{Var}\{y\} = \frac{(\tilde{u}_{\text{zelle}} - \hat{u}_\Sigma)^2}{\tilde{i}_{\text{zelle}}^2} \cdot \left(\frac{\text{Var}\{\tilde{u}_{\text{zelle}}\} + \text{Var}\{\hat{u}_\Sigma\}}{(\tilde{u}_{\text{zelle}} - \hat{u}_\Sigma)^2} + \frac{\text{Var}\{\tilde{i}_{\text{zelle}}\}}{\tilde{i}_{\text{zelle}}^2} \right), \quad (6.5)$$

wenn die Kovarianz zwischen dem Fehler der Spannungen und des Stroms vernachlässigt wird. Die Gleichung ist gültig, wenn für den Strom $\tilde{i}_{\text{zelle}} \neq 0$ gilt. Da \hat{u}_Σ die Summe von $u_{\text{OC}}(\text{SOC})$, u_1 und u_2 ist und damit auf dem Zustandsvektor $\hat{\mathbf{x}}$ beruht, dessen Kovarianzmatrix $\hat{\mathbf{P}}$ bekannt ist, kann die benötigte Varianz $\text{Var}\{\hat{u}_\Sigma\}$ abgeschätzt werden zu

$$\text{Var}\{\hat{u}_\Sigma\} = \text{Var}\{u_{\text{OC}}(\text{SOC})\} + \sum_{j=1}^2 \text{Var}\{u_j\} = \text{Var}\{\mathbf{C}\hat{\mathbf{x}}\} = \mathbf{C}\text{Var}\{\hat{\mathbf{x}}\}\mathbf{C}^T = \mathbf{C}\hat{\mathbf{P}}\mathbf{C}^T. \quad (6.6)$$

Alternativ kann die Varianz der Messung auch durch die Unscented-Transformation (UT) (siehe Kapitel 4.1.3) bestimmt werden. Untersuchungen zeigen, dass für $|\tilde{i}| \gg 0$ beide Verfahren vergleichbare Ergebnisse liefern. Probleme können bei der UT allerdings auftreten, wenn der

Tabelle 6.2: Parametrierung des Mess- und Prozessrauschens der beiden Kalman-Filter des DKFs.

	Zustandsschätzer	Parameterschätzer
Prozessrauschen	$B \text{Var} \{\tilde{i}_{\text{zelle}}\} B^T + \Delta Q \approx \Delta Q$	<i>Optimierung</i>
Messrauschen	$\text{Var} \{\tilde{u}_{\text{zelle}}\} + \hat{R}_0^2 \cdot \text{Var} \{\tilde{i}_{\text{zelle}}\}$	(6.5) oder UT

gemessene Strom \tilde{i} sehr klein und damit in der Größenordnung des Messrauschens $\text{Var} \{\tilde{i}\}$ liegt. Bei der Erzeugung der Sigma-Punkte können dann Vorzeichenwechsel auftreten, wodurch sich negative Werte für u_Σ ergeben. Dieses Problem wird im weiteren Verlauf dieses Kapitels noch weiter diskutiert.

Aus Gründen der Stabilität werden nur die Elemente auf der Hauptdiagonalen der Kovarianzmatrizen berücksichtigt, wohingegen alle anderen Einträge auf null gesetzt werden. Dies kann durch das Hadamard-Produkt mit einer Einheitsmatrix gleicher Dimension wie die betreffende Kovarianzmatrix erreicht werden. In Tabelle 6.2 ist die analytische Herleitung der Kovarianzmatrizen von Prozess- und Messrauschen für die beiden Schätzer zusammengefasst.

Das Problem der Schätzung von SOC, u_1 , u_2 und R_0 ließe sich auch mittels Joint-Estimation anstelle der hier vorgeschlagenen Dual-Estimation lösen. Hierbei würde der Zustandsvektor um den Parameter R_0 erweitert. Während allerdings beim DKF zwei lineare Kalman-Filter verwendet werden können, muss für das JEKF ein nichtlineares Kalman-Filter eingesetzt werden. Deshalb und auch aufgrund der höheren Ordnung des Systems weist dieses Filter einen größeren Rechenaufwand auf. Ein weiterer und grundlegender Vorteil des vorgestellten Konzepts mit DKF liegt in der Bestimmung des Messrauschens des Parameterschätzers nach (6.5). Dessen Kovarianz kann zu jedem Zeitschritt basierend auf den aktuellen Sensor- und Schätzwerten aktualisiert werden und liefert dann ein akkurates Maß für die Güte des Messwerts. Insbesondere abhängig vom Strom variiert die Qualität der Messungen stark, da für kleine Ströme der Signal-Rausch-Abstand stark sinkt. Damit verliert der entsprechende Messwert $y_{\theta,k}$ an Signifikanz und soll für den Korrekturschritt der Parameterschätzung gering gewichtet werden. Über die iterative Aktualisierung von der Rauschvarianz R_θ wird genau das erreicht.

Der Vorteil der dem Parameterschätzer inhärenten adaptiven Gewichtung der Messung zeigt sich, wenn die Innenwiderstandsschätzung mit DKF der Implementierung mit JEKF gegenübergestellt wird. Dafür werden beide Algorithmen in einer Simulation verglichen basierend auf einer Stromanregung vom UDDS-Fahrzyklus (siehe Anhang A). Das Stromprofil hat eine Länge von 1800 s. Die Messdaten von Strom und Spannung werden durch die Überlagerung der Referenzdaten mit einem normalverteilten, künstlichen Rauschen erzeugt (Standardabweichung des Sensorrauschens 10 mA bzw. 5 mV). Weiterhin gilt $\mathbf{Q}_x = \text{diag} \{[10^{-8} \ 10^{-7} \ 10^{-8}]\}$ und $Q_\theta = 10^{-6}$ für das DKF bzw. analog $\mathbf{Q} = \text{diag} \{[10^{-8} \ 10^{-7} \ 10^{-8} \ 10^{-6}]\}$ für das JEKF. Diese Werte sind Resultat der Optimierung in Kapitel 4.3. Die Schätzung vom SOC und dem Innenwiderstand sind in Abb. 6.1 nebeneinander gestellt. Während sich die Ergebnisse der SOC-Schätzung kaum unterscheiden und der RMSE beim DKF 0,032 pp. gegenüber 0,046 pp. beim JEKF beträgt, sind die Unterschiede bei der Innenwiderstands-Schätzung deutlich ersichtlich. Insbesondere wenn der Strom klein wird, ergeben sich für den JEKF große Abweichungen in der Schätzung. Es ergibt sich ein RMSE über die gesamte Simulationsdauer von 1,9 mΩ. Durch die adaptive Gewichtung der Messwerte

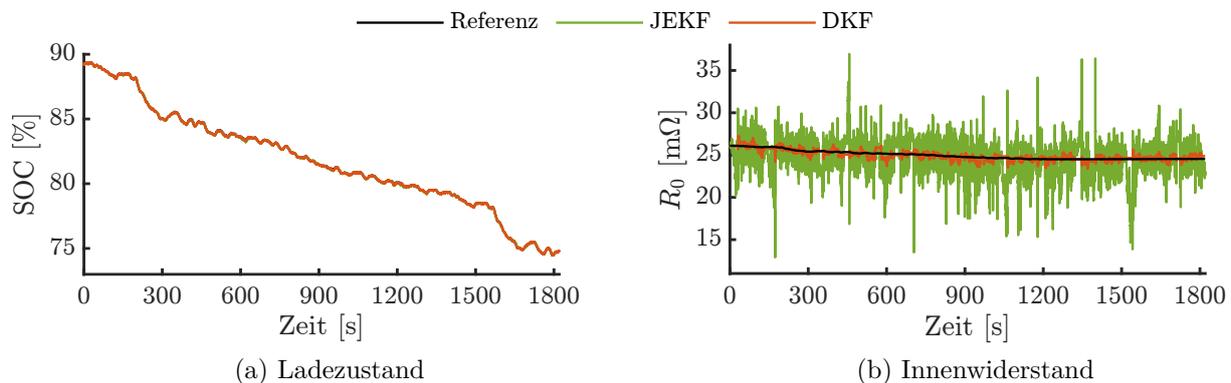


Abbildung 6.1: Vergleich der Schätzung von SOC und Innenwiderstand mittels JEKF und DKF (Anregung basierend auf dem UDDS-Stromprofil).

ist die Schätzung des Innenwiderstands vom DKF deutlich weniger verrauscht. Es ergeben sich signifikant kleinere Fehler: Der RMSE ist mit $0,32 \text{ m}\Omega$ im Vergleich zum JEKF nur ein Sechstel so groß.

6.2.2 Erhöhung der Robustheit

Durch weitere Anpassungen kann die Innenwiderstandsschätzung weiter verbessert werden. Insbesondere eine Steigerung der Robustheit soll im Folgenden untersucht und umgesetzt werden. Als robuste Schätzverfahren gelten solche, bei denen auch angesichts von Messausreißern oder einer geringen Systemanregung stabile Schätzergebnisse erzielt werden. Dabei muss ein robustes Filter jedoch eine hinreichend schnelle Reaktionszeit gegenüber Zustandsänderungen bewahren. Üblicherweise werden ebenfalls Kalman-Filter als robust bezeichnet, die auch dann noch präzise Schätzergebnisse liefern, wenn die Bedingungen an das System- und Messrauschen – insbesondere deren Normalverteilung und Erwartungstreue, wie in (4.5) postuliert – nicht erfüllt sind [296]. Das vorgestellte Kalman-Filter zur Schätzung des Innenwiderstands ist in mehrerer Hinsicht mit den Schwierigkeiten konfrontiert, welche robuste Schätzverfahren motivieren. Diese werden in den folgenden Abschnitten diskutiert.

6.2.2.1 Phasen mangelnder Systemanregung

Wie in Kapitel 5 bereits gezeigt wurde, ist die Anregung des Stroms vom Batteriesystem im Betrieb von Elektrofahrzeugen nicht immer ausreichend für eine hinreichende Schätzgüte. Gerade bei kleinen Strömen ist die Beobachtbarkeit des Innenwiderstands schlecht. Aber auch während Phasen gleichmäßiger Ströme, wie sie bei Fahrt mit konstanter Geschwindigkeit oder während Ladevorgängen auftreten, erschweren die Schätzung des Innenwiderstands. Wie am Beispiel des WLTP-Stromprofils im vorherigen Kapitel in Abb. 5.5a gezeigt wurde, kann die Anregung des Systems in relevanten Frequenzbereichen ungenügend sein. Eine Lösung für dieses Problem – ohne Schaltoperationen zu nutzen, wie sie RBSs bieten – ist die Anpassung der Varianz des Messrauschens, wie bereits im vorhergehenden Abschnitt beschrieben, und der damit einhergehenden Gewichtung des Informationsgehalts der Messwerte zu jedem Zeitpunkt. Für

Phasen sehr geringer Ströme wird die Varianz nach (6.5) sehr groß, sodass keine Korrektur des Zustands stattfindet. Vielmehr behält das Kalman-Filter die Schätzgröße über das Random-Walk-Modell bei. In Phasen, in denen der Strom sehr klein ist, hält der Parameterschätzer demnach den Innenwiderstand konstant, solange, bis der Strom wieder ansteigt und plausible Messwerte für den Innenwiderstand zur Verfügung stehen.

6.2.2.2 Windup-Effekt des Schätzers

Die praktische Umsetzung des adaptiven Messrauschens für die Parameterschätzung führt jedoch für längere Phasen geringer Anregung zu einem Phänomen, das als Schätz-Windup (engl. *estimator's windup*) oder Windup-Effekt bekannt ist. Dadurch, dass aufgrund der sehr großen Kovarianz der Messung keine Korrektur des Modells stattfindet, steigt die Varianz der Schätzung $\hat{P}_{k|k}$ fortwährend an, denn für $R \rightarrow \infty$ gilt für die Gleichungen des Kalman-Filters (vgl. Algorithmus 4.1)

$$\hat{P}_{\theta,k|k-1} \leftarrow \hat{P}_{\theta,k-1|k-1} + Q_{\theta} \quad (6.7a)$$

$$S \leftarrow C_{\theta} \hat{P}_{\theta,k|k-1} C_{\theta}^T + R = \infty \quad (6.7b)$$

$$K_k \leftarrow \hat{P}_{\theta,k|k-1} C_{\theta}^T S^{-1} = 0 \quad (6.7c)$$

$$\hat{\theta}_{k|k} \leftarrow \hat{\theta}_{k|k-1} + K_k e = \hat{\theta}_{k|k-1} \quad (6.7d)$$

$$\hat{P}_{\theta,k|k} \leftarrow (1 - K_k C_{\theta}) \hat{P}_{\theta,k|k-1} = \hat{P}_{\theta,k|k-1}. \quad (6.7e)$$

Damit sinkt auch das Vertrauen des Filters in das Modellwissen. Der Windup-Effekt ist auf die Verletzung der Bedingung an eine dauerhafte Systemanregung zurückzuführen [269, S. 73 f.]. Wird das Kalman-Filter mit Random-Walk-Modell als RLS-Algorithmus aufgefasst, lässt sich der Windup-Effekt so interpretieren, dass das Filter keine neuen Informationen auf Basis der Messungen erhält, während gleichzeitig die alten Schätzwerte „vergessen“ werden. Vom Schätz-Windup spricht man in Analogie zum Integrator-Windup, der bei PI-Reglern auftreten kann.

Zu dem Zeitpunkt, an dem erstmals wieder eine gültige Messung vorliegt, wird diese gegenüber dem Modell übermäßig stark gewichtet, da dann $R \ll \hat{P}_{k|k}$ ist. Diese Kausalität führt dazu, dass das Kalman-Filter sehr sensitiv auf die erste Messung nach der Ruhephase reagiert und sich abhängig vom stochastischen Rauschen des Messwerts y zum betreffenden Zeitpunkt der Schätzwert des Parameters stark ändern kann [272, S. 473 ff.]. Die eigentlich beim Kalman-Filter gewünschte Eigenschaft, die Messungen gemäß ihrem stochastischen Rauschen zu filtern, fällt beim Windup-Effekt des Schätzers weg. Erschwerend kommt für den hier betrachteten Anwendungsfall hinzu, dass der Strom in vielen Fällen nach einer Pause nur langsam wieder ansteigt. Da bei kleinen Strömen das Signal-Rausch-Verhältnis des Messwerts y_{θ} besonders schlecht ist, wird einer schlechten Korrektur der Parameterschätzung Vorschub geleistet, weil die hohe Sensitivität des Filters auf schlechte Messwerte trifft.

In der Literatur existieren verschiedene Ansätze, dem Windup-Effekt entgegenzuwirken. Diese werden als Anti-Windup-Verfahren bezeichnet. Viele Methoden werden im Kontext von RLS-Verfahren diskutiert, wie die Variation des Vergessensfaktors oder die Regularisierung des Least-Squares-Problems. Eine Übersicht gibt Beyer [269, S. 118 ff.]. Der Vergessensfaktor kann als

Analogie zum Prozessrauschen des Kalman-Filters gesehen und unter bestimmten Vereinfachungen in diesen überführt werden.

Eine Möglichkeit, das ungebremste Anwachsen der Kovarianzmatrix $\hat{\mathbf{P}}$ zu verhindern, ist es, deren Spur für jeden Zeitpunkt zu skalieren, wie es Salgado et al. [297] vorschlagen. Dadurch bleibt die Summe der Diagonaleinträge der Matrix konstant und nur das Verhältnis der Einträge zueinander ändert sich. Åström und Wittenmark [272, S. 477] addieren zur skalierten Kovarianz noch ein Vielfaches der Einheitsmatrix, damit die Eigenwerte der Matrix nicht gegen null konvergieren und dadurch auch die Kalman-Verstärkung null wird.

$$\hat{\mathbf{P}}_{k|k,\text{lim}} = c_1 \frac{\hat{\mathbf{P}}_{k|k}}{\text{spur}\{\hat{\mathbf{P}}_{k|k}\}} + c_2 \mathbf{I} \quad \text{mit } c_1 > 0, c_2 > 0 \quad (6.8)$$

Die Einstellparameter c_1 und c_2 müssen vom Anwender gewählt werden, wozu jedoch keine theoretische oder methodische Grundlage existiert. Dies ist für die Anwendung des Verfahrens von Nachteil. Krus und Gunnarsson [298] begrenzen die Spur von $\hat{\mathbf{P}}$ auf einen Maximalwert P_{\max} , sodass die Kovarianz der Schätzung auch über längere Zeiträume geringer Anregung nicht über diesen Wert hinausgeht. In [299–302] wird ein Verfahren vorgestellt, bei dem der Vergessensfaktor beim RLS-Verfahren mit exponentiellem Vergessen bzw. die Kovarianz des Prozessrauschens des Kalman-Filters derart in Abhängigkeit von der Anregung adaptiert wird, dass ein Lernen nur in denjenigen Dimensionen des Parameterraums stattfindet, in denen das Anregungssignal einen Informationsgehalt aufweist. Für den vorliegenden Anwendungsfall der Innenwiderstandsschätzung ist dies von geringerem Interesse, da es sich um ein eindimensionales Schätzproblem handelt.

Statt einer harten Grenze soll im Folgenden die Kovarianz umso stärker limitiert werden, je näher sich diese dem festgelegten Maximalwert P_{\max} nähert. Die Limitierung der Kovarianz kann demnach als weiche Grenze angesehen werden. Für den hier betrachteten skalaren Fall wird die limitierte Kovarianz bestimmt durch

$$\hat{P}_{k|k,\text{lim}} = \hat{P}_{k|k} - Q_\theta \left(\frac{\hat{P}_{k|k}}{P_{\max}} \right)^\alpha. \quad (6.9)$$

Über den Faktor $\alpha > 0$ kann die Stärke der Limitierung eingestellt werden. Da für einen Zeitschritt die Kovarianz $\hat{P}_{k|k}$ maximal um Q_θ ansteigen kann, gilt für $\hat{P}_{k|k} \rightarrow P_{\max}$, dass $\hat{P}_{k|k,\text{lim}} = \hat{P}_{k|k} - Q_\theta$. Die obere Schranke P_{\max} kann demnach in keinem Fall überschritten werden, solange $P_0 \leq P_{\max}$ und $Q_\theta \leq P_{\max}$ gelten.

Am Beispiel des WLTP-Stromprofils soll die Wirkungsweise des vorgestellten Anti-Windup-Verfahrens untersucht werden. Die Untersuchung basiert auf experimentellen Strom- und Spannungsmessungen an einer Lithium-Ionen-Batteriezelle, die mit dem Stromprofil am Prüfstand beaufschlagt wurde. Die Messwerte weisen ein (künstliches) Rauschen mit der Standardabweichung 10 mA bzw. 5 mV auf. Der Parameterschätzer des DKFs wird derart modifiziert, dass die Schätzvarianz des Innenwiderstands gemäß (6.9) limitiert wird. Die resultierende Schätzung und die zugehörige Schätzvarianz ist für verschiedene Werte von P_{\max} in Abb. 6.2 gezeigt. Die blaue Kurve entspricht $P_{\max} = \infty$, d. h. in diesem Fall kommt das Anti-Windup-Verfahren nicht zur Anwendung.

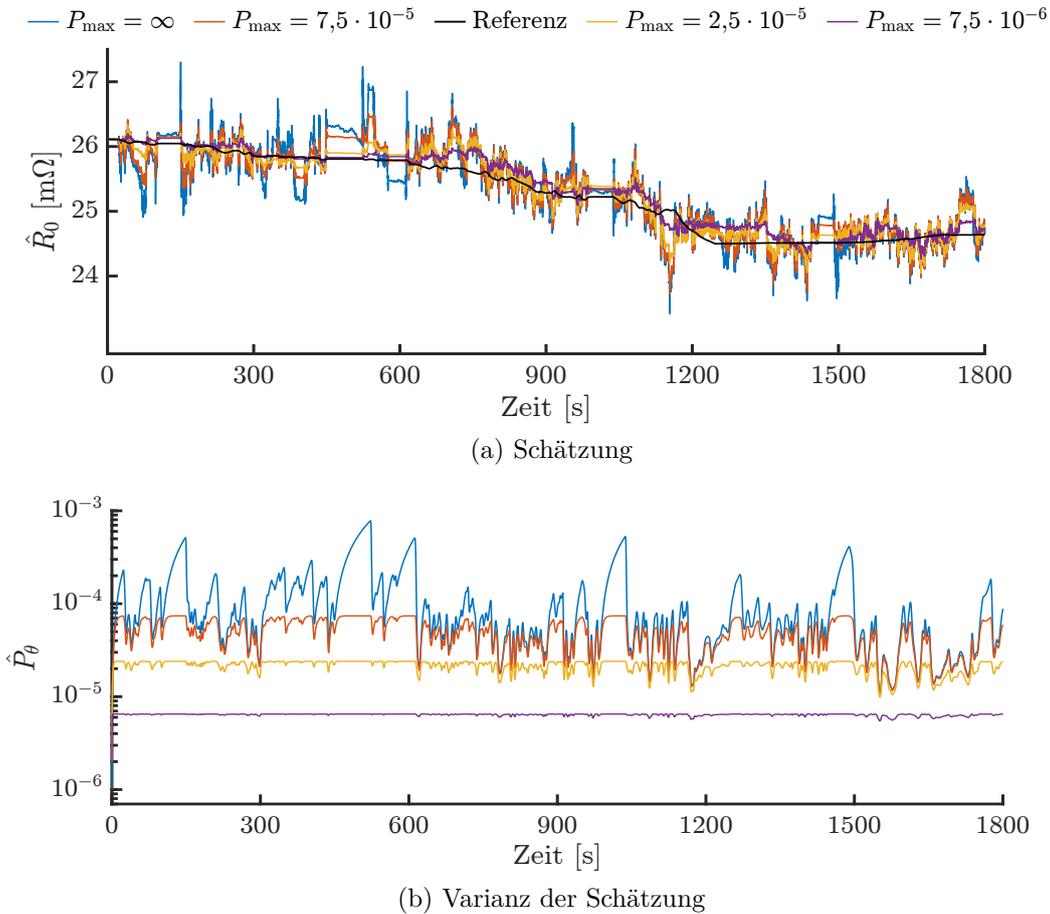


Abbildung 6.2: Schätzung des Innenwiderstands mit Anti-Windup durch Limitierung der Varianz der Schätzung (Stromprofil: WLTP).

Die Beschränkung der Varianz der Schätzung \hat{P}_θ ist in Abb. 6.2b gut zu erkennen. Während sie im unlimitierten Fall Werte in einer Größenordnung bis zu 10^{-3} erreicht, liegen die untersuchten Schranken deutlich darunter. In Abb. 6.2a sind daher die Vor- und Nachteile einer limitierten Schätzvarianz gut zu erkennen. Zunächst sind für die Schätzung ohne Anti-Windup-Verfahren (blaue Kurve) deutlich die Ausreißer zu erkennen, welche auf die Phasen geringer bzw. keiner Anregung folgen. Durch den übermäßigen Anstieg der Varianz reagiert das Filter sensitiv auf Rauschen und Störungen und korrigiert den Schätzwert zu stark. Mit einer moderaten Limitierung kann dieses unerwünschte Verhalten unterbunden werden. Allerdings verringert sich, wie ebenfalls im Diagramm zu erkennen ist, damit auch die Adaptivität des Filters. Ist die obere Schranke für die Schätzvarianz zu niedrig angesetzt, kann das Filter der Änderung des Innenwiderstands nicht mehr adäquat folgen. Dies ist beispielsweise um die Zeit von 1200s für $P_{\max} = 7,5 \cdot 10^{-6}$ (lila Kurve) zu erkennen. Die Schranke P_{\max} ist daher mit Bedacht zu wählen. Ihr optimaler Wert hängt von der zu erwartenden Änderung des Innenwiderstands ab.

Um einen optimalen Wert für P_{\max} zu bestimmen, kann dieser variiert werden, während gleichzeitig die Güte der Parameterschätzung beobachtet wird. In Abb. 6.3 wurde der RMSE des Innenwiderstands als Maß zur Bewertung der Güte der Parameterschätzung gewählt und gegenüber P_{\max} auf der Abszisse aufgetragen. Es wird sowohl der WLTP- als auch der UDDS-

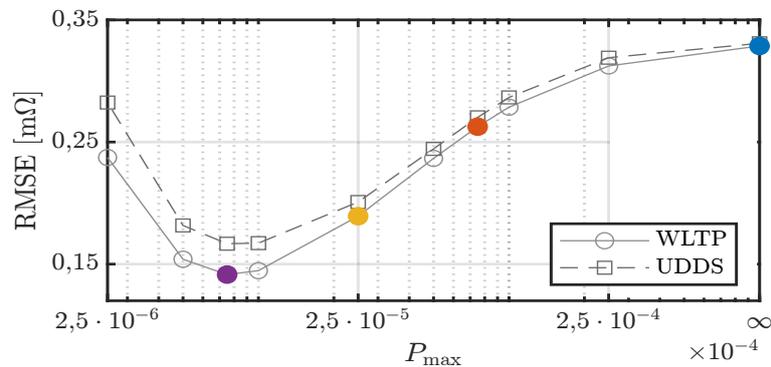


Abbildung 6.3: RMSE der Innenwiderstandsschätzung abhängig von der Schranke P_{\max} für die Schätzvarianz.

Fahrzyklus untersucht, um unterschiedlichen Änderungsraten des Innenwiderstands abhängig von der Stromanregung Rechnung zu tragen. Die Ergebnisse sind aber für beide Anregungsprofile vergleichbar. Zusätzlich sind in der Abbildung die resultierenden Schätzfehler markiert, welche mit den Zeitverläufen in Abb. 6.2 korrespondieren. Die Auswertung des Diagramms zeigt, dass ein Wert von $7,5 \cdot 10^{-6}$ für das hier betrachtete Szenario ein Optimum für die Schranke P_{\max} darstellt. Letzterer Wert wird im Folgenden verwendet. Im Vergleich zur Schätzung ohne Anti-Windup kann der RMSE der Innenwiderstandsschätzung ungefähr um den Faktor zwei reduziert werden.

6.2.2.3 Stochastische Verteilung der Messwerte

Messdaten können von Messausreißern (engl. *outliers*) durchsetzt sein, welche außerhalb des statistischen Erwartungsbereichs liegen. Gründe dafür sind fehlerhafte Messungen oder Störungen der Übertragung. Um die Robustheit der Zustands- und Parameterschätzung zu erhöhen, sollen Ausreißer detektiert und aus der Messreihe ausgeschlossen werden. Dafür existieren verschiedene Verfahren, zu welchen Beyer [269, S. 61 ff.] eine Übersicht gibt. Nachteilig an vielen Methoden zur Detektion von Messausreißern ist deren hoher Speicherbedarf und die Notwendigkeit, Grenzwerte manuell festzulegen, wodurch der Einsatz erschwert wird. Weiterhin kann sich die Konvergenzgeschwindigkeit verringern, wenn die Startwerte der Parameterschätzung weit von den wahren Werten abweichen und die ersten Messwerte zunächst als Ausreißer klassifiziert werden [269, S. 95 ff.]. Im vorliegenden Anwendungsfall der Innenwiderstandsschätzung treten Messwerte auf, welche ebenfalls als Ausreißer bezeichnet werden können, da sie weit vom wahren Innenwiderstand entfernt sind. Der Grund für diese auffälligen Messungen ist die hohe Sensitivität von y_θ gegenüber Messfehlern der Spannung, wenn der Zellstrom sehr klein wird. Durch die Struktur der Messung des Parameterschätzers

$$y_\theta = \frac{\tilde{u}_{\text{zelle}} - \hat{u}_\Sigma}{\tilde{i}_{\text{zelle}}} \quad (6.10)$$

kann y_θ , wie leicht zu erkennen ist, für kleine Ströme sehr große Werte annehmen. Ist der Strom null, können sogar gar keine plausiblen Messwerte für den Innenwiderstand bereitgestellt

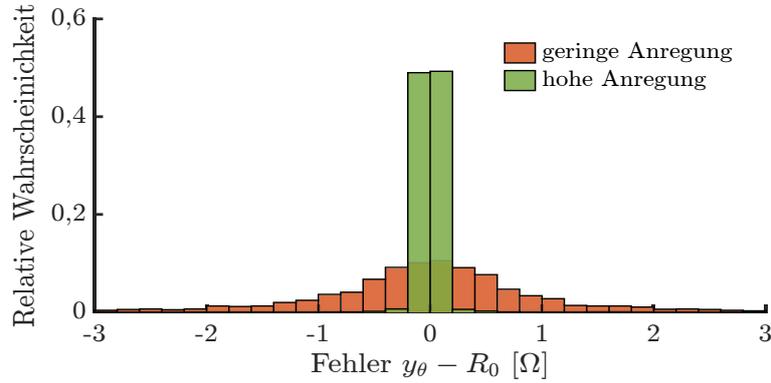


Abbildung 6.4: Histogramme der Fehlerhäufigkeit der Messwerte y_θ für geringe und hohe Stromanregung.

werden und lediglich das Rauschen der Strommessung bestimmt das Vorzeichen des Messwerts. Im Folgenden wird der Index *zelle* für die Bezeichnung von Zellstrom und -spannung der Übersichtlichkeit halber weggelassen. Wendet man das Gesetz zur Fehlerfortpflanzung mittels Taylor-Approximation 1. Ordnung für die fehlerbehafteten Messdaten $\tilde{u} = u + \Delta u$ und $\tilde{i} = i + \Delta i$, sowie für die fehlerbehaftete Schätzung $\hat{u}_\Sigma = u_\Sigma + \Delta u_\Sigma$ an, so ergibt sich für den Messfehler

$$\Delta y_\theta = \left| \frac{\partial y_\theta}{\partial u} \cdot \Delta u \right| + \left| \frac{\partial y_\theta}{\partial u_\Sigma} \cdot \Delta u_\Sigma \right| + \left| \frac{\partial y_\theta}{\partial i} \cdot \Delta i \right| \quad (6.11a)$$

$$= \left| \frac{1}{i} \cdot \Delta u \right| + \left| \frac{1}{i} \cdot \Delta u_\Sigma \right| + \left| \frac{u - u_\Sigma}{i^2} \cdot \Delta i \right|. \quad (6.11b)$$

Für den Grenzfall $i \rightarrow 0$ steigt die Sensitivität für die Fehler der Messungen bzw. Schätzung beliebig an, sodass auch der resultierende Fehler von y_θ groß wird.

Analysiert man das WLTP- oder UDDS-Stromprofil, so lässt sich feststellen, dass in ungefähr 20% der Simulationszeit die C-Rate kleiner als 0,05 C ist. Da beide Profile die reale Belastung eines elektrischen Antriebsstrangs nachbilden, legt dies den Schluss nahe, dass die Betrachtung von Situationen mit geringer Anregung in der Anwendung relevant und daher für die robuste Parameterschätzung notwendig ist.

Als valide Messwerte sollen für die Parameterschätzung nur solche herangezogen werden, bei denen der Betrag des Stroms einen gewissen Schwellwert überschreitet. Im Folgenden wird die dreifache Standardabweichung des Sensorrauschens gewählt, weil dadurch – unter der Annahme eines normalverteilten Messrauschens des Stromsensors – mit einer Sicherheit von 99,7% ausgeschlossen werden kann, dass sich durch den stochastischen Fehler das Vorzeichen des Messwerts ändert. In Abb. 6.4 ist die Wahrscheinlichkeitsverteilung des Messfehlers $y_\theta - R_0$ für die beiden Fälle dargestellt, dass der Betrag des Stroms kleiner gleich $3\sigma_{i,\text{sensor}}$ (geringe Anregung) bzw. größer (hohe Anregung) ist. Als Standardabweichung des Messrauschens wurde zur Verdeutlichung 1 mA bzw. 1 mV gewählt. Die Schätzung von u_Σ sei fehlerfrei. Deutlich ist zu erkennen, dass der Fehler für kleine Ströme leicht mehrere Ohm groß sein kann. Dahingegen ist die Streuung der gefilterten Messwerte ungefähr um den Faktor 175 kleiner und liegt im Bereich von wenigen Milliohm. Große Messfehler treten demnach immer vor allem dann auf, wenn der Anregungsstrom klein ist, wodurch eine Vorfilterung der Daten sinnvoll erscheint.

Tabelle 6.3: Parameter der Normal- und Student-t-Verteilung, welche die Verteilung des Messrauschens nachbilden.

	μ	σ^2	ν
Normalverteilung	$3,3 \cdot 10^{-6}$	$1,2 \cdot 10^{-6}$	
Student-t-Verteilung	$6,5 \cdot 10^{-6}$	$1,7 \cdot 10^{-7}$	0,62

Es ist zu beachten, dass das Sensorrauschen von Strom und Spannung als normalverteilt angenommen wird. Das Auftreten von Ausreißern als weit vom wahren Wert entfernte Messpunkte ist ausschließlich auf die Wahl des Messeingangs y_θ zurückzuführen und motiviert die Filterung der unplausiblen Messdaten. Im Framework des Kalman-Filters kann der Ausschluss unplausibler Messwerte dadurch realisiert werden, dass die zugehörige Messvarianz-Matrix R_θ auf einen sehr hohen Wert gesetzt wird. Entsprechend wird der Messwert für die Filterung nicht berücksichtigt. Die Vorschrift für diese als **Gating** bezeichnete Vorfilterung der Messwerte [190, S. 263] ist

$$R_{\theta,k} = \begin{cases} \text{siehe (6.5)}, & \text{für } |\tilde{i}_k| > 3 \cdot \sigma_{i,\text{sensor}} \\ \infty, & \text{für } |\tilde{i}_k| \leq 3 \cdot \sigma_{i,\text{sensor}}. \end{cases} \quad (6.12)$$

Im weiteren Verlauf dieses Kapitels werden nur die vorgefilterten Messdaten verwendet.

Die Annahme über die Normalverteilung des Messrauschens ist verletzt, weil – wie bereits beschrieben – zwar $\tilde{u} - \hat{u}_\Sigma$ und \tilde{i} als normalverteilte Größen angenommen werden können, dies jedoch nicht für deren Quotienten gilt. Zwar lassen sich die Momente einer postulierten Normalverteilung approximieren – abhängig von der Beschaffenheit des Anregungsstromes treten jedoch vermehrt Messausreißer auf, sodass die Bedingung verletzt ist, dass die Messwerte normalverteilt sein müssen. Andere Verteilungen, insbesondere die Student-t-Verteilung, sind besser in der Lage, die Streuung der Messwerte zu beschreiben. Die Student-t-Verteilung wird zusammen mit Grundlagen zur Normalverteilung im Anhang C vorgestellt. Sie weist im Vergleich zur Normalverteilung signifikant höhere Wahrscheinlichkeiten dafür auf, dass weit vom Erwartungswert entfernte Messfehler auftreten. Daher ist sie zur Beschreibung von Ausreißern behafteter Messsignale gut geeignet.

Die Fehler der vorgefilterten Messwerte des Parameterschätzers sind in Abb. 6.5 in einem Histogramm dargestellt. Die Verteilung der Messfehler wird zum einen durch eine Normalverteilung, zum anderen durch eine Student-t-Verteilung angenähert. Hierfür kommt ein MLE-Verfahren (Maximum-Likelihood-Estimation) zum Einsatz. Die resultierenden Parameter der Verteilungen listet Tabelle 6.3 auf. Wie in Anhang C erläutert, wird durch die weit vom Mittelwert entfernt liegenden Messpunkte, welche außerhalb der Erwartung der Normalverteilung liegen, deren Varianz zu groß geschätzt. Daher wurden für die Bestimmung der Parameter der Normalverteilung in der Abbildung nur Messfehler berücksichtigt, die kleiner als $4 \text{ m}\Omega$ sind. Trotzdem kann eine Normalverteilung die Verteilung der Messung nur unzureichend abbilden, wohingegen die Student-t-Verteilung eine deutlich bessere Modellierung der Fehlerverteilung erlaubt – bei Berücksichtigung aller Messfehler. Daher werden im Folgenden Erweiterungen des Kalman-Filters untersucht, welche statt einer Normalverteilung eine Student-t-Verteilung für das Messrauschen annehmen.

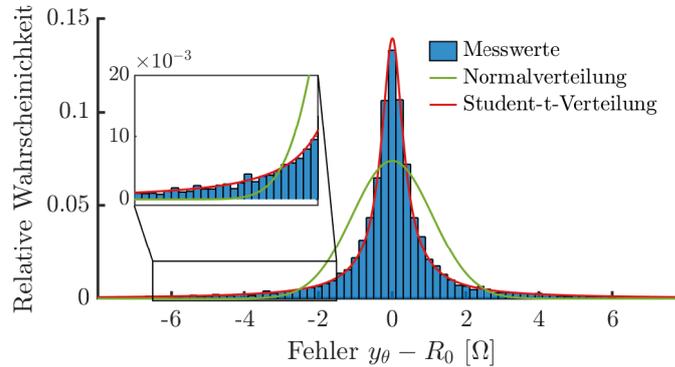


Abbildung 6.5: Approximation des Messfehlers mit (a) einer Normalverteilung und (b) einer Student-t-Verteilung. Angelehnt an Beyer [269, S. 71].

Das Kalman-Filter ist auch dann der lineare Schätzer mit der geringsten Varianz des Schätzergebnisses, wenn die Annahmen zur Normalverteilung von Prozess- und Messrauschen nicht mehr erfüllt sind [303]. Es existieren jedoch Näherungsverfahren, welche auch für andere Wahrscheinlichkeitsdichten eine nichtlineare Filterung ermöglichen, welche dem linearen Kalman-Filter überlegen sind. Als eine der ersten Verfahren kann der Gaussian-Sum-Filter gelten, bei dem die nicht-normalverteilte Dichtefunktion als Summe aus Normalverteilungen approximiert wird. Der hohe Rechenaufwand steht einem Onboard-Einsatz allerdings entgegen [304]. Beim Partikel-Filter werden die Wahrscheinlichkeitsdichten durch eine große Anzahl an diskreten Realisierungen (Partikel) repräsentiert, welche gemäß der angenommenen Verteilung zufällig bestimmt werden. Dadurch lassen sich beliebige Wahrscheinlichkeitsverteilungen behandeln. Dieses Monte-Carlo-Verfahren kann daher auch für die robuste Zustandsschätzung verwendet werden (siehe beispielsweise [196, 305]), allerdings ist der Rechenaufwand im Vergleich zu analytischen Näherungsverfahren signifikant höher, welche im Folgenden betrachtet werden.

Das Outlier-Robust-Kalman-Filter (ORKF) von Agamennoni et al. [306] nimmt zwar ein normalverteiltes Prozessrauschen an, weicht die Annahmen des konventionellen Kalman-Filters jedoch dahingehend auf, dass das Messrauschen weder konstant noch normalverteilt sein muss. Die Prädiktion des ORKF entspricht dem herkömmlichen Kalman-Filter. Während es sich beim klassischen Kalman-Filter aufgrund der Annahme eines Gaußschen Messrauschens tatsächlich um eine Normalverteilung handelt, wird für den Korrekturschritt die a posteriori Kovarianz der Schätzgröße beim ORKF nur durch eine Normalverteilung approximiert. Als Maß für die Ähnlichkeit zweier Verteilungen wird auf die KL-Divergenz (Kullback-Leibler) zurückgegriffen [307], welche für die Dichtefunktionen zweier Verteilungen $p(\mathbf{x})$ und $q(\mathbf{x})$ definiert ist als

$$\text{KL}(p \parallel q) = \int p(\mathbf{x}) \ln \left(\frac{p(\mathbf{x})}{q(\mathbf{x})} \right) d\mathbf{x}. \quad (6.13)$$

Es gilt $\text{KL}(p \parallel q) \geq 0$, wobei die KL-Divergenz nur für den Fall null ist, dass $p(\mathbf{x}) = q(\mathbf{x})$. Außerdem ist zu beachten, dass $\text{KL}(p \parallel q) \neq \text{KL}(q \parallel p)$, wodurch sich zwei mögliche Optimierungsprobleme für die Ähnlichkeit zweier Verteilungen ergeben (siehe [308, S. 468]). Die KL-Divergenz wird in der Regel numerisch bestimmt.

Beim ORKF wird die a posteriori Schätzkovarianz als Normalverteilung aus der Student-t-Verteilung, die sich aufgrund des von Ausreißern behafteten Messrauschens ergibt, angenähert. Daraus resultiert der Berechnungsschritt der Kalman-Verstärkung

$$K_k = \hat{P}_{k|k-1} C^T (C \hat{P}_{k|k-1} C^T + \Lambda_k)^{-1}, \quad (6.14)$$

wobei die Kovarianz des Messrauschens R des herkömmlichen Kalman-Filters durch Λ_k ersetzt wurde.

$$\Lambda_k = \frac{(\nu - 1)R + \mathbb{E}\{m_k m_k^T\}}{\nu} \quad \text{mit } \mathbb{E}\{m_k m_k^T\} = d_k d_k^T + C P_{k|k} C^T \quad (6.15)$$

Hierbei ist ν der Freiheitsgrad der Student-t-Verteilung. Es ist zu beachten, dass sich Λ_k für $\nu \rightarrow \infty$ an R annähert und sich die Kalman-Verstärkung des herkömmlichen Kalman-Filters ergibt. Da es für (6.14) und (6.15) keine geschlossene Lösung gibt, wird die VB-Methode (Variational-Bayes) angewandt, um Λ iterativ zu bestimmen. Der Korrekturschritt des ORKFs ist in Algorithmus 6.1 zusammengefasst. Die Schleife ist konvergiert, wenn sich $\hat{x}_{k|k}$ nicht mehr ändert. Agamennoni et al. [306] erreichen nach drei bis sechs Iterationen eine Toleranz von unter 1%, weswegen Leitner [309, S. 125] zehn Iterationen als ausreichend erachtet. Dadurch ist der Rechenaufwand konstant und das Filter kann in echtzeitfähigen Systemen eingesetzt werden. Die Implementierung kann auch als eine Art AKF interpretiert werden, welches das Messrauschen für jeden Messwert neu parametrisiert. Wenn Ausreißer auftreten, wird das Messrauschen adaptiv erhöht, sodass die Schätzung stabil bleibt.

Algorithmus 6.1 Korrekturschritt des ORKF nach [306]

```

1:  $\hat{x}_{k|k} \leftarrow \hat{x}_{k|k-1}$ 
2:  $\hat{P}_{k|k} \leftarrow \hat{P}_{k|k-1}$ 
3:  $\Lambda \leftarrow R$ 
4: while not converged do
5:    $e_k \leftarrow y_k - (C \hat{x}_{k|k-1} + D u_k)$ 
6:    $S_k \leftarrow C \hat{P}_{k|k-1} C^T + \Lambda$ 
7:    $K_k \leftarrow \hat{P}_{k|k-1} C^T S_k^{-1}$ 
8:    $\hat{x}_{k|k} \leftarrow \hat{x}_{k|k-1} + K_k e_k$ 
9:    $\hat{P}_{k|k} \leftarrow (I - K_k C) \hat{P}_{k|k-1} (I - K_k C)^T + K_k \Lambda K_k^T$ 
10:   $d_k \leftarrow y_k - (C \hat{x}_{k|k} + D u_k)$ 
11:   $\Lambda \leftarrow \frac{\nu}{\nu+1} R + \frac{1}{\nu+1} (d_k d_k^T + C \hat{P}_{k|k} C^T)$ 
12: end while

```

Unter der Annahme, dass neben dem Messrauschen auch das Prozessrauschen nicht mehr normalverteilt ist, kann das Student-t-Kalman-Filter (TKF) von Roth et al. [310–312] verwendet werden. Das Filter kann als Assumed-Density-Filter (ADF) angesehen werden, bei welchen beliebige Wahrscheinlichkeitsverteilungen durch eine vorgegebene Verteilung angenähert werden, beispielsweise aus der Familie der Normalverteilungen oder, wie im hier behandelten Fall, der Student-t-Verteilungen. Die hier dargestellte Herleitung beruht auf Roth et al. [310, S. 79 ff.] und Leitner [309, S. 117 ff.], wobei Letzterer auch den Systemeingang u mitberücksichtigt, welcher im Folgenden der Vollständigkeit halber mit aufgeführt ist. In der späteren Umsetzung für die Innenwiderstandsschätzung weist das System keinen Eingang auf. Weiterhin wird hier der

allgemeine Fall eines SISO-Systems mit einem Zustandsvektor der Dimension $n \geq 1$ behandelt, auch wenn die Innenwiderstandsschätzung nur mit skalaren Größen rechnet. Schließlich wird das Prozessrauschen letztendlich als Normalverteilung angenommen. Wie im weiteren Verlauf jedoch zu sehen sein wird, kann dies als Spezialfall des allgemeinen TKFs ohne Weiteres Berücksichtigung finden, indem der Freiheitsgrad der betreffenden Student-t-Verteilung beliebig hoch gewählt wird, wodurch diese in eine Normalverteilung übergeht.

Zunächst seien der Zustandsvektor $\mathbf{x} \in \mathbb{R}^{n \times 1}$, das Prozessrauschen $\mathbf{q} \in \mathbb{R}^{n \times 1}$ und das Messrauschen $r \in \mathbb{R}^{1 \times 1}$ Student-t-Verteilungen mit den entsprechenden Mittelwerten, Kovarianzen und Freiheitsgraden. Das Rauschen wird, wie beim herkömmlichen Kalman-Filter auch, als mittelwertfrei angenommen.

$$p(\mathbf{x}_k) = t(\mathbf{x}_k | \hat{\mathbf{x}}_{k|k}, \hat{\mathbf{P}}_{k|k}, \nu_\eta) \quad (6.16a)$$

$$p(\mathbf{q}_k) = t(\mathbf{q}_k | 0, \mathbf{Q}, \nu_\gamma) \quad (6.16b)$$

$$p(r_k) = t(r_k | 0, R, \nu_r) \quad (6.16c)$$

In einem ersten Schritt gelte nun die Annahme einer gemeinsamen Student-t-Verteilung für die Prädiktion des Zustandsvektors und des Prozessrauschens, da beide Größen zwar unkorreliert, aber nicht unabhängig sein müssen. Der Freiheitsgrad der gemeinsamen Wahrscheinlichkeitsdichtefunktion sei $\nu_x \in \mathbb{R}_{>0}$.

$$p(\mathbf{x}_k; \mathbf{q}_k | y_{1:k}) = t\left(\begin{bmatrix} \mathbf{x}_k \\ \mathbf{q}_k \end{bmatrix} \middle| \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \mathbf{0} \end{bmatrix}, \begin{bmatrix} \hat{\mathbf{P}}'_{k|k} & \mathbf{0} \\ \mathbf{0} & \mathbf{Q}' \end{bmatrix}, \nu_x\right) \quad (6.17)$$

Aus der Zusammenfassung beider Zufallsgrößen in eine gemeinsame Verteilung resultiert die Notwendigkeit, die Kovarianzmatrizen $\hat{\mathbf{P}}_{k|k}$ und \mathbf{Q} zu modifizieren. Darauf wird noch zu einem späteren Zeitpunkt eingegangen. Der Prädiktionsschritt des Kalman-Filters lässt sich jetzt als lineare Transformation formulieren zu

$$\mathbf{x}_{k+1} = \begin{bmatrix} \mathbf{A} & \mathbf{I} \end{bmatrix} \cdot \begin{bmatrix} \mathbf{x}_k \\ \mathbf{q}_k \end{bmatrix} + \mathbf{B}u_k. \quad (6.18)$$

Aus den Eigenschaften einer gemeinsamen Student-t-Verteilung (siehe (C.18) in Anhang C.4) resultiert für den prädierten Zustandsvektor (6.19), wodurch der Prädiktionsschritt des TKFs dem des herkömmlichen Kalman-Filters entspricht.

$$p(\mathbf{x}_{k+1} | y_{1:k}) = t(\mathbf{x}_{k+1} | \hat{\mathbf{x}}_{k+1|k}, \hat{\mathbf{P}}_{k+1|k}, \nu_x) \quad (6.19a)$$

$$\hat{\mathbf{x}}_{k+1|k} = \mathbf{A}\hat{\mathbf{x}}_{k|k} + \mathbf{B}u_k \quad (6.19b)$$

$$\hat{\mathbf{P}}'_{k+1|k} = \mathbf{A}\hat{\mathbf{P}}'_{k|k}\mathbf{A}^\top + \mathbf{Q}' \quad (6.19c)$$

Auch für den Korrekturschritt wird eine gemeinsame Student-t-Verteilung dergestalt angenommen, dass der korrigierte Zustandsvektor und das Messrauschen den gleichen Freiheitsgrad aufweisen.

Auch hier wird die Kovarianzmatrix der a priori Schätzung und die Rauschmatrix der Messung modifiziert.

$$p(\mathbf{x}_k; r_k | y_{1:k-1}) = t\left(\begin{bmatrix} \mathbf{x}_k \\ r_k \end{bmatrix} \middle| \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ 0 \end{bmatrix}, \begin{bmatrix} \hat{\mathbf{P}}'_{k|k-1} & \mathbf{0} \\ \mathbf{0} & R' \end{bmatrix}, \nu_y\right) \quad (6.20)$$

Die Messgleichung lässt sich nun analog zum Prädiktionsschritt als lineare Transformation darstellen und lautet:

$$\begin{bmatrix} \mathbf{x}_k \\ y_k \end{bmatrix} = \begin{bmatrix} \mathbf{I} & \mathbf{0} \\ \mathbf{C} & I \end{bmatrix} \cdot \begin{bmatrix} \mathbf{x}_k \\ r_k \end{bmatrix} + \begin{bmatrix} \mathbf{0} \\ D \end{bmatrix} \cdot u_k \quad (6.21)$$

Die gemeinsame Wahrscheinlichkeitsdichtefunktion von \mathbf{x} und y ist dann

$$p(\mathbf{x}_k, y_k | y_{1:k-1}) = t\left(\begin{bmatrix} \mathbf{x}_k \\ y_k \end{bmatrix} \middle| \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{y}_{k|k-1} \end{bmatrix}, \begin{bmatrix} \hat{\mathbf{P}}'_{k|k-1} & \hat{\mathbf{P}}'_{k|k-1} \mathbf{C}^T \\ \mathbf{C} \hat{\mathbf{P}}'_{k|k-1} & S_k \end{bmatrix}, \nu_y\right), \quad (6.22a)$$

$$\hat{y}_{k|k-1} = \mathbf{C} \hat{\mathbf{x}}_{k|k-1} + D u_k, \quad (6.22b)$$

$$S_k = \mathbf{C} \hat{\mathbf{P}}'_{k|k-1} \mathbf{C}^T + R'. \quad (6.22c)$$

Gemäß (C.22) aus Anhang C.4 gilt nun

$$p(\mathbf{x}_k | y_{1:k}) = t(\mathbf{x}_k | \hat{\mathbf{x}}_{k|k}, \hat{\mathbf{P}}_{k|k}, \nu'_y) \quad (6.23a)$$

$$e_k = y_k - \hat{y}_{k|k-1} \quad (6.23b)$$

$$\mathbf{K}_k = \hat{\mathbf{P}}'_{k|k-1} \mathbf{C}^T S^{-1} \quad (6.23c)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k e_k \quad (6.23d)$$

$$m^2 = e_k^T S^{-1} e_k \quad (6.23e)$$

$$\hat{\mathbf{P}}_{k|k} = \frac{\nu_y + m^2}{\nu_y + q} (\hat{\mathbf{P}}'_{k|k-1} - \mathbf{K}_k \mathbf{C} \hat{\mathbf{P}}'_{k|k-1}) \quad (6.23f)$$

$$\nu'_y = \nu_y + q. \quad (6.23g)$$

Die Berechnung der Kalman-Verstärkung und die Korrektur des Zustandsvektors entsprechen dem Korrekturschritt des herkömmlichen Kalman-Filters. Für die Bestimmung der korrigierten Schätzkovarianz kommt eine Berechnung basierend auf der quadrierten Mahalanobis-Distanz des Residuums zur Anwendung. Die Mahalanobis-Distanz [308, S. 692]

$$m(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \mathbf{y})} \quad (6.24)$$

transformiert den Abstand zweier Punkte \mathbf{x}, \mathbf{y} in einem mehrdimensionalen Raum anhand der Kovarianzmatrix $\boldsymbol{\Sigma} = \text{Cov}\{\mathbf{x}, \mathbf{y}\}$, wenn diese als Zufallszahlen aufgefasst werden. Im zweidimensionalen Raum bilden Punkte gleicher Mahalanobis-Distanz eine Ellipse.

Der vorgestellte Korrekturschritt ist analytisch exakt. Allerdings steigt mit jeder Iteration der Freiheitsgrad der Student-t-Verteilungen an (siehe (6.23g)), wodurch sich nach einer größeren Zahl an Durchläufen die Verteilung einer Normalverteilung annähert. Dadurch gehen die robusten Eigenschaften des Filters verloren.

Um die gemeinsame Dichtefunktion (6.17) aus (6.16a) und (6.16b) zu bilden, müssen deren Freiheitsgrade identisch sein. Da dies in der Regel nicht der Fall ist, werden beide Verteilungen durch eine Student-t-Verteilung mit festem, gemeinsamen Freiheitsgrad ν_x approximiert.

$$p(\mathbf{x}_k | y_{1:k}) \approx q(\mathbf{x}_k | y_{1:k}) = t(\mathbf{x}_k | \hat{\mathbf{x}}_{k|k}, \hat{\mathbf{P}}'_{k|k}, \nu_x) \quad (6.25a)$$

$$p(\mathbf{q}_k) \approx q(\mathbf{q}_k) = t(0, \mathbf{Q}', \nu_x) \quad (6.25b)$$

In gleicher Weise gilt für das Messrauschen und die prädiizierte Zustandskovarianz

$$p(\mathbf{x}_k | y_{1:k-1}) \approx q(\mathbf{x}_k | y_{1:k-1}) = t(\mathbf{x}_k | \hat{\mathbf{x}}_{k|k-1}, \hat{\mathbf{P}}'_{k|k-1}, \nu_y), \quad (6.26a)$$

$$p(r_k) \approx q(r_k) = t(0, R', \nu_y), \quad (6.26b)$$

wobei eine gemeinsame Student-t-Verteilung mit dem Freiheitsgrad ν_y angenähert wird. Die aus der Approximation resultierenden Matrizen $\hat{\mathbf{P}}'_{k|k}$, \mathbf{Q}' , $\hat{\mathbf{P}}'_{k|k-1}$ und R' werden dann im Prädiktions-schritt (6.19) und Korrekturschritt (6.23) verwendet.

Um die Frage zu beantworten, wie die benötigten Näherungen (6.25a) und (6.26a) bestimmt werden können, wird hier eine Optimierung aus [313] vorgestellt, bei der allgemein die Wahrscheinlichkeitsverteilung $p(\mathbf{z}) = t(\mathbf{z} | \mathbf{0}, \mathbf{\Sigma}_p, \nu_p)$ durch eine andere Verteilung $q(\mathbf{z}) = t(\mathbf{z} | \mathbf{0}, \mathbf{\Sigma}_q, \nu_q)$ angenähert werden soll. Eine Lösung für die Approximation ist es, den resultierenden Freiheitsgrad ν_q vorzugeben und die Matrix $\mathbf{\Sigma}_q$ durch Skalierung mit dem Faktor $c_{\nu_p, \nu_q} \in \mathbb{R}_{>0}$ aus $\mathbf{\Sigma}_p$ zu bestimmen [310, S. 85 f.]. Dieser Skalierungsfaktor lässt sich durch Minimierung der KL-Divergenz mit folgender Fallunterscheidung ermitteln [313]:

$$c_{\nu_p, \nu_q} = \arg \min_{c_{\nu_p, \nu_q} \in \mathbb{R}_{>0}} \begin{cases} \text{KL}(p \parallel q), & \text{für } \nu_p > \nu_q \\ \text{KL}(q \parallel p), & \text{für } \nu_p < \nu_q. \end{cases} \quad (6.27)$$

Für den hier diskutierten Anwendungsfall soll das Prozessrauschen normalverteilt sein, weswegen $\nu_p \rightarrow \infty$. Für den Freiheitsgrad des Messrauschens gilt $0 < \nu_y < \infty$. Es ergibt sich der Korrekturschritt des TKFs nach Algorithmus 6.2. Zu beachten ist, dass sich die Skalierungsfaktoren $c_{\nu_y, \infty}$ und c_{∞, ν_y+q} zur Laufzeit nicht ändern und daher vorab offline bestimmt werden können. Dies ist auch der Fall, wenn sich das Messrauschen ändert, da der Skalierungsfaktor bei gegebenen Freiheitsgraden der zugrunde liegenden Verteilungen konstant bleibt. Die Optimierungen müssen also nur einmal zu Beginn durchgeführt werden, wodurch der Rechenaufwand des TKFs zum herkömmlichen Kalman-Filter vergleichbar bleibt. Weiterhin ist ersichtlich, dass sich das TKF für $\nu_y \rightarrow \infty$ dem konventionellen Kalman-Filter annähert. Dieser kann daher als Spezialfall des TKFs für normalverteiltes Prozess- und Messrauschen angesehen werden.

Die Wirkungsweise der beiden vorgestellten robusten Kalman-Filter wird zunächst anhand eines synthetischen Beispiels untersucht. Hierzu soll der skalare Parameter θ , der über die Laufzeit von 40 Iterationen leicht ansteigt, durch ein Random-Walk-Modell modelliert werden. Der Messausgang entspricht dem Parameter $y = \theta$, dieser ist jedoch durch das normalverteilte Messrauschen $r = \mathcal{N}(r | 0, R)$ mit $R = 0,1$ verfälscht. Das Prozessrauschen wird mit $Q = 10^{-3}$ parametrisiert. Für die robusten Schätzer wird jedoch ein student-t-verteilt Messrauschen mit dem Freiheitsgrad $\nu_y = 3$ angenommen. Dies ist laut Gelman et al. [314, S. 441] ein plausibler

Algorithmus 6.2 Korrekturschritt des Student--t-Kalman-Filters nach [310–312]

-
- 1: $\hat{\mathbf{P}}'_{k|k-1} \leftarrow c_{\nu_y, \infty}^2 \cdot \hat{\mathbf{P}}_{k|k-1}$
 - 2: $S_k \leftarrow \mathbf{C} \hat{\mathbf{P}}'_{k|k-1} \mathbf{C}^T + R$
 - 3: $e_k \leftarrow y_k - (\mathbf{C} \hat{\mathbf{x}}_{k|k-1} + D u_k)$
 - 4: $m^2 \leftarrow e_k^T S_k^{-1} e_k$
 - 5: $\mathbf{K}_k \leftarrow \hat{\mathbf{P}}'_{k|k-1} \mathbf{C}^T S_k^{-1}$
 - 6: $\hat{\mathbf{P}}_{k|k} \leftarrow \frac{\nu_y + m^2}{\nu_y + q} (\hat{\mathbf{P}}'_{k|k-1} - \mathbf{K}_k \mathbf{C} \hat{\mathbf{P}}'_{k|k-1})$
 - 7: $\hat{\mathbf{x}}_{k|k} \leftarrow \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k e_k$
 - 8: $\hat{\mathbf{P}}_{k|k} \leftarrow c_{\infty, \nu_y + q} \cdot \hat{\mathbf{P}}'_{k|k}$
-

Wert für eine Ausreißer-robuste Schätzung. Zum Zeitpunkt $k = 10$ (rote senkrechte Linie) sowie im Zeitraum $20 \leq k \leq 30$ (violetter Bereich) treten Ausreißer auf. Das Messrauschen ist hier also stark erhöht und die Annahme eines normalverteilten Messrauschens ist nicht mehr gültig. Die Ergebnisse der Filterung sind in Abb. 6.6 dargestellt.

Betrachtet man zunächst das Verhalten des herkömmlichen Kalman-Filters, so fällt auf, dass dessen Schätzkovarianz konstant ist, weil das Messrauschen nicht adaptiv ist. Damit stellt sich auch eine konstante Kalman-Verstärkung ein. In der Folge kommt es beim Auftreten der Ausreißer zu großen Schätzfehlern und auch im Anschluss an diese Phasen konvergiert die Schätzung nur langsam zum wahren Wert zurück. Das ORKF weist ein anderes Verhalten auf: Weil für jeden Zeitschritt das Messrauschen R über die VB-Methode neu bestimmt wird, werden Ausreißer im Korrekturschritt des Filters nur gering gewichtet. In der Folge bleibt der Schätzfehler klein. Der einzelne Ausreißer bei $k = 10$ hat daher kaum Einfluss auf die Schätzgüte. Anders liegt der Fall, wenn die Schätzung aufgrund mehrerer aufeinanderfolgender Ausreißer schlecht wird. Für den Zeitraum $k > 30$ konvergiert die Schätzung nur langsam zum wahren Wert zurück, der Schätzfehler wird dem Messrauschen zugeschlagen. Schließlich zeigt die Analyse des TKFs, dass dieser in Phasen großer Messausreißer die Kovarianz der Schätzung stark erhöht. Da dies erst für den nächsten Iterationsschritt geschieht, führt das Auftreten eines Ausreißers trotzdem zu einer starken Korrektur der Schätzung und somit zu großen Schätzfehlern. Das TKF findet aber im Vergleich zu den beiden anderen Filtern schnell zum wahren Wert zurück, sobald die Messwerte wieder im regulären Rahmen liegen.

Mit den Erkenntnissen des einfachen Beispiels werden im Folgenden die Varianten des Kalman-Filters für die Parameterschätzung im DKF angewandt und verglichen. Als Anregungsprofil wird der WLTP gewählt. Die Standardabweichung der Sensoren beträgt wieder 10 mA bzw. 5 mV und ν_y ist gleich 3. Analog zum einführenden Beispiel ist in Abb. 6.7 das Ergebnis der Schätzung gezeigt. Betrachtet man die Schätzwerte des Innenwiderstands der drei Filter-Varianten im Vergleich, sind die Unterschiede insbesondere zwischen dem herkömmlichen Kalman-Filter und dem ORKF auf der einen Seite und dem TKF auf der anderen Seite deutlich zu sehen. Letzteres weist eine Schätzung auf, die wesentlich geringeren Schwankungen unterworfen ist. Der RMSE für die Innenwiderstandsschätzung beträgt beim TKF nur 0,15 mΩ im Vergleich zu 0,34 mΩ (0,36 mΩ) beim Kalman-Filter (ORKF). Die kleineren Korrekturschritte des TKFs spiegeln sich auch in der geringeren Schätzkovarianz in Abb. 6.7b wieder. Durch das höhere Vertrauen in das Modellwissen fällt die Kalman-Verstärkung kleiner aus. Interessanterweise ist die Varianz

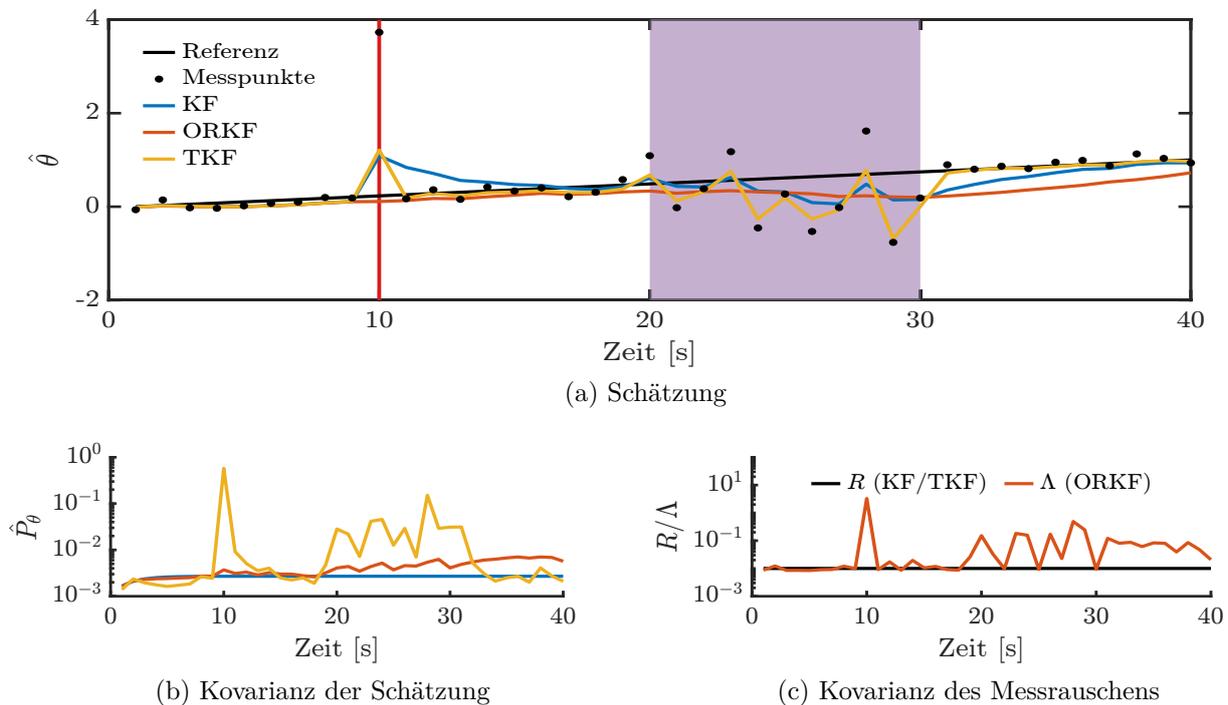


Abbildung 6.6: Synthetisches Beispiel mit Random-Walk-Modell zum Vergleich des Kalman-Filters (KF) mit ORKF und TKF. Während $k = 10$ (roter vertikaler Strich) und $20 \leq k \leq 30$ (violetter Bereich) treten Messausreißer auf.

des Messrauschens beim Kalman-Filter und TKF bzw. deren Schätzung Λ des ORKFs gleich groß. Dass \hat{P}_θ beim TKF dennoch nicht so stark ansteigt wie bei den anderen beiden Varianten liegt daran, dass die a posteriori Schätzkovarianz, wie in Algorithmus 6.2 zu sehen, mit der Mahalanobis-Distanz skaliert wird. Diese steigt jedoch nicht übermäßig an, wenn zwar R groß, die Innovation e jedoch klein ist. In der Folge wird der Anstieg der Schätzkovarianz gebremst, was in einer stabilen Schätzung resultiert. Dass der ORKF im Vergleich zum herkömmlichen Kalman-Filter kaum Unterschiede aufweist, lässt sich damit erklären, dass die Robustheit des Filters daraus resultiert, für jede Iteration R optimal zu wählen. Zu Zeitpunkten, während derer ein hoher Messfehler auftritt, wird Λ sehr groß und die Messung wird gering gewichtet, indem eine kleine Kalman-Verstärkung gewählt wird. Durch die Adaption des Messrauschens gemäß (6.5) ist eine für das zu erwartende Messrauschen optimale Varianz R bereits gewählt. Das ORKF bringt deswegen keinen weiteren Vorteil hinsichtlich der Schätzgenauigkeit mehr. Maßgeblich für die Genauigkeit der Schätzung des herkömmlichen Kalman-Filters und des ORKFs sind die großen Abweichungen, welche am Ende von Phasen auftreten, in denen kein Strom das System anregt. Wie bereits im vorherigen Abschnitt diskutiert, sind der Windup-Effekt und die damit einhergehenden hohen Schätzkovarianzen Grund für dieses Verhalten. Während das TKF aufgrund der beschränkten Kovarianz der Schätzung robust gegenüber dem Windup-Effekt ist, kommt es bei den beiden anderen untersuchten Varianten zu den sichtbaren großen Schätzfehlern. Eine Untersuchung mit dem UDDS-Stromprofil bestätigt die Ergebnisse des Vergleichs. Für das DKF kommt daher eine robuste Innenwiderstandsschätzung basierend auf dem TKF zur Anwendung.

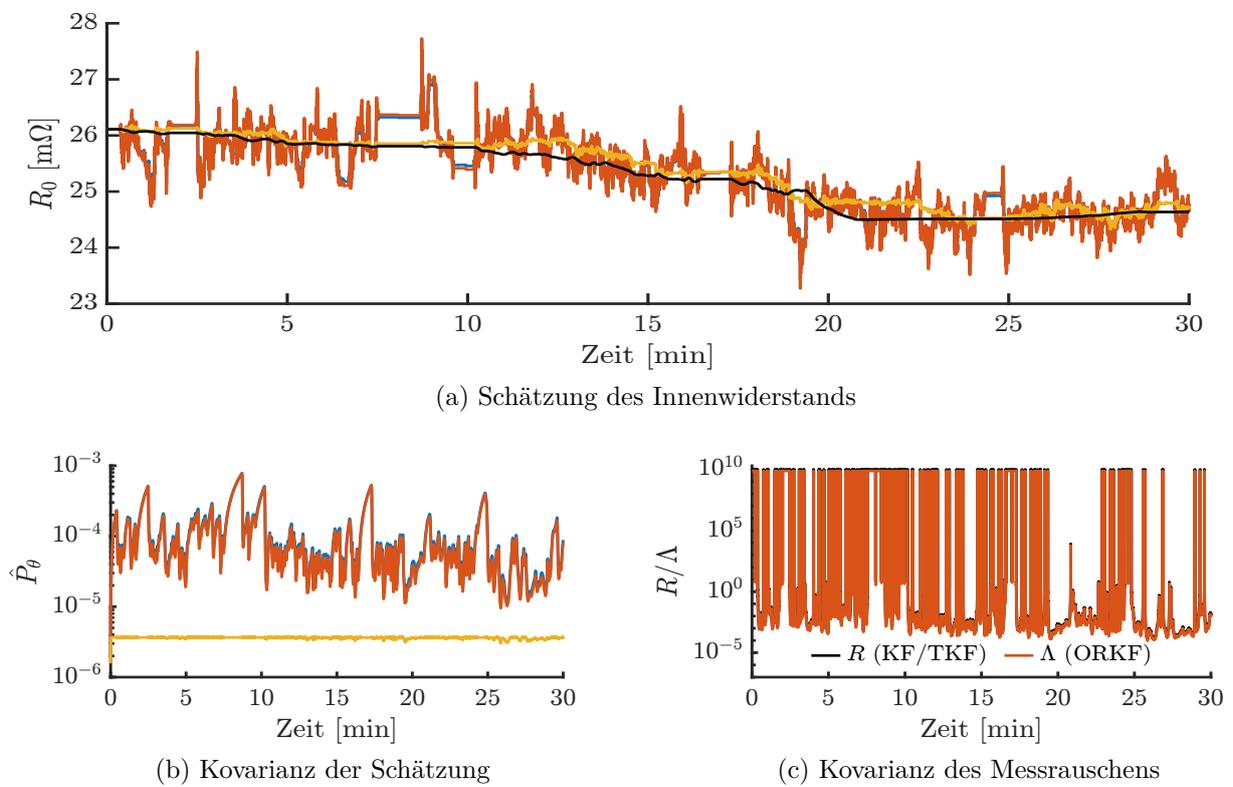


Abbildung 6.7: Vergleich des herkömmlichen Kalman-Filters (KF) mit ORKF und TKF anhand einer Simulation basierend auf dem WLTP-Anregungsprofil.

6.2.3 Zusammenfassung der robusten Parameterschätzung

Tabelle 6.4 listet die resultierenden RMSEs der Innenwiderstandsschätzung in Abhängigkeit von den eingesetzten Verfahren zur Robustifizierung auf. Grundsätzlich ist die Tendenz zu erkennen, dass sich die Schätzung umso mehr verbessert, je mehr der vorgestellten Verfahren eingesetzt werden. Eine Kombination der Ansätze ist daher möglich und auch sinnvoll. Zu beachten ist, dass die Schätzung nicht erfolgreich durchgeführt werden kann, wenn R_θ nicht adaptiv bestimmt wird und weder die Messwerte vorgefiltert werden, noch der Anstieg der Schätzkovarianz beschränkt wird. Es ergeben sich dann sehr große RMSEs. Es gilt allerdings, dass der Einfluss des Anti-Windup-Verfahrens immer vom Stromprofil und dem Auftreten von Phasen mit geringer Anregung abhängt. Den größten Einfluss auf die Schätzgüte insgesamt weist die Adaption von R_θ auf – dann liegt der Schätzfehler immer unter $0,4\text{ m}\Omega$. Unter dieser Voraussetzung erweist es sich als nachteilig, wenn weder ein robuster Schätzer eingesetzt, noch das Anti-Windup-Verfahren angewandt wird. Im Vergleich zum JEKF aus Kapitel 4 kann der Schätzfehler des Innenwiderstands mit dem hier vorgestellten robusten DKF mehr als halbiert werden, wobei die Grundlage der Ergebnisse dynamische Fahrprofile wie der UDDS oder WLTP sind. Dabei bietet der robuste Innenwiderstandsschätzer für die SDF insbesondere dann Vorteile, wenn der Strom gering und die Anregung damit für eine herkömmliche Schätzung unzureichend ist. Daher ist für solche Szenarien ein noch größerer Vorteil des DKFs zu erwarten.

Tabelle 6.4: Schätzfehler des Innenwiderstands abhängig von den eingesetzten Verfahren zur Robustifizierung der Parameterschätzung (Stromprofil: WLTP).

Adaptives R_θ	Vorfilterung abh. von $ \tilde{i} $	Robuster Schätzer (TKF)	Anti-Windup	RMSE
-	-	-	-	116 m Ω *
-	-	-	✓	5,36 m Ω
-	-	✓	-	1,80 k Ω *
-	-	✓	✓	46,6 Ω *
-	✓	-	-	1,03 m Ω
-	✓	-	✓	1,03 m Ω
-	✓	✓	-	1,03 m Ω
-	✓	✓	✓	1,03 m Ω
✓	-	-	-	0,33 m Ω
✓	-	-	✓	0,14 m Ω
✓	-	✓	-	0,15 m Ω
✓	-	✓	✓	0,16 m Ω
✓	✓	-	-	0,36 m Ω
✓	✓	-	✓	0,14 m Ω
✓	✓	✓	-	0,15 m Ω
✓	✓	✓	✓	0,16 m Ω

* Die Schätzung ist aufgrund hoher Fehler als fehlgeschlagen zu bewerten.

Basierend auf den vorhergehenden Untersuchungen werden die folgenden Maßnahmen umgesetzt, um die Parameterschätzung robust zu gestalten. Mit dem besonderen Fokus auf eine robuste Innenwiderstandsschätzung wird im Folgenden ein TKF als Parameterschätzer angewandt. Diese Methode zur Robustifizierung ist weniger von einem Einstellparameter abhängig als das Anti-Windup-Verfahren, welches ähnliche Ergebnisse liefert. Um dem erhöhten Auftreten von weit vom Erwartungswert entfernt liegenden Messpunkten Rechnung zu tragen, wird $\nu_y = 3$ als Freiheitsgrad der angenommenen Student-t-Verteilung des Messrauschens gewählt. Weiterhin werden die Messwerte mit der Schranke $|\tilde{z}| \stackrel{!}{\geq} 3 \cdot \sigma_{i,\text{sensor}}$ gefiltert, um unplausible Messwerte von der Schätzung auszuschließen. Auf das Anti-Windup-Verfahren wird verzichtet, da sich in der Kombination der Verfahren kein Vorteil daraus ergibt.

Zusammenfassend gilt: Die größte Verbesserung der Schätzung wird, wie gezeigt, durch die adaptive Anpassung des Messrauschens des Parameterschätzers erreicht. Durch Ausnutzung des strukturellen Wissens über die Messung des Parameterschätzers lässt sich eine analytische Abschätzung von deren Unsicherheit vornehmen. Die dadurch stromabhängige Gewichtung der Messwerte führt zu einer signifikanten Erhöhung der Robustheit der Parameterschätzung.

Im Gegensatz zum reduzierten Parameterschätzer lassen sich auch weitere Modellparameter in den Parametervektor integrieren, wie es beispielsweise Andre et al. [179] oder Wang et al. [199] vorschlagen. Allerdings steigen mit zunehmender Anzahl an Schätzgrößen in gleichem Maße die Anforderungen an die Systemanregung. Mit dem Fokus auf eine stabile und robuste Schätzung wird für die Anwendung der SDF darauf verzichtet.

6.3 Modellbasierte Sensordatenfusion von Zellstrom und -spannung

Die SDF in IBSs ist ein Forschungsgebiet, in dem sich aufgrund der Neuheit dieser Batteriesystem-Architektur kaum Forschungsergebnisse finden lassen. Charakteristisch für die Problemstellung ist, dass die SDF basierend auf vielen gleichartigen Sensoren durchgeführt wird, wohingegen viele Arbeiten im Bereich der Datenfusion die Kombination unterschiedlicher Sensortypen und Informationsquellen behandeln. In [315, 316] stellen Frolik et al. ein Verfahren für die Robustifizierung und Validierung von gleichartigen Sensordaten vor, welche eine hohe Korrelation untereinander aufweisen. Die Autoren verwenden hierfür den Begriff der *quasi-redundanten* Sensordaten. Darunter wird verstanden, dass die Sensoren nicht zwangsläufig den gleichen Messwert erfassen müssen, aber dennoch die Messgrößen stark miteinander korreliert sind. Das ist auch für die Sensordaten innerhalb eines IBS mit zellindividueller Sensorik der Fall: Obwohl sich die Zellströme und -spannungen voneinander unterscheiden, sind sie miteinander korreliert. So hängen die Zellströme vom Gesamtstrom ab, auch wenn sich die Ströme innerhalb eines Parallelstrangs nicht exakt gleichmäßig aufteilen müssen. Park et al. [317] untersuchen verschiedene Verfahren zur Kombination mehrerer redundanter Messungen. Sie kommen zu dem Schluss, dass die Mittelwertbildung in vielen Fällen kein optimales Verfahren ist, insbesondere wenn die Messunsicherheit der Sensoren bekannt ist. Dies ist für die Anwendung in einem IBS eine gültige Annahme, weil das Sensorrauschen entweder durch geeignete Messungen charakterisiert werden kann oder die Varianz des Messrauschens geschätzt wird, wie Abschnitt 6.4 zeigt.

Im Folgenden wird die modellbasierte SDF für die Fusion der Zellströme und -spannungen vorgestellt. Das Systemwissen wird durch ein Batteriesystemmodell repräsentiert, weswegen es sich um ein modellbasiertes Verfahren handelt.

6.3.1 Vorstellung der modellbasierten Sensordatenfusion

Die SDF findet in zwei Schritten statt. Im ersten Schritt wird basierend auf den Sensormesswerten der Zellströme ein Gesamtstrom berechnet und analog auf Basis der Zellspannungen die Gesamtspannung ermittelt. Gesamtstrom und -spannung berücksichtigen alle Sensoren zu dem betreffenden Zeitpunkt. Im zweiten Schritt wird dieser fusionierte Wert durch ein Modell des Batteriesystems propagiert, um die Ströme und Spannungen der einzelnen Zellen zurückzugewinnen. Der resultierende fusionierte Strom und die resultierende Spannung jeder Zelle beruhen damit auf allen berücksichtigten Messwerten der Zellsensoren und weisen eine gegenüber der Sensormessung verringerte Messunsicherheit und geringeres Messrauschen auf.

6.3.1.1 Sensordatenfusion der Strommessung

Ein Blockschaltbild der modellbasierten SDF ist in Abb. 6.8 dargestellt. Zur Ermittlung des fusionierten Gesamtstroms wird das Weighted-Least-Squares (WLS)-Verfahren verwendet. Eine Herleitung findet sich in Anhang D. Seien zum Zeitpunkt k die Messwerte von \mathcal{Z} Zell-Stromsensoren bekannt, wobei $\tilde{\mathbf{i}}_{\text{zelle}}$ der Spaltenvektor der Messwerte und $\text{Var}\{\tilde{\mathbf{i}}_{\text{zelle}}\}$ der Spaltenvektor der dazugehörigen Varianzen des Sensorrauschens ist, dann kann die Gewichtungsmatrix \mathbf{W} mit den Kehrwerten der Messvarianz auf den Hauptdiagonalen belegt werden zu

$$\mathbf{W} = \text{diag}\{\text{Var}\{\tilde{i}_{\text{zelle},1}\}, \text{Var}\{\tilde{i}_{\text{zelle},2}\}, \dots, \text{Var}\{\tilde{i}_{\text{zelle},\mathcal{Z}}\}\}. \quad (6.28)$$

Die unabhängigen Messwerte \mathbf{x} im WLS-Framework sind die Spannungen \mathbf{u}_{Σ} und die Zell-Innenwiderstände \mathbf{R}_0 . Die abhängigen Messwerte \mathbf{y} entsprechen den Zellströmen $\tilde{\mathbf{i}}_{\text{zelle}}$. Als Modellfunktion $\mathbf{y} = f(\mathbf{x}|a)$ kann (3.10) gewählt werden, sodass der unbekannte Parameter a dem Gesamtstrom i_{ges} entspricht. Da $\mathcal{Z} > 1$, ist das Gleichungssystem überbestimmt und es kann eine Lösung für a gefunden werden. Als fusionierter Wert für den Gesamtstrom \bar{i}_{ges} und der zugehörigen Varianz $\text{Var}\{\bar{i}_{\text{ges}}\}$ ergibt sich gemäß des kleinsten gewichteten quadratischen Fehlers

$$\bar{i}_{\text{ges}} = (\mathbf{J}^T \mathbf{W} \mathbf{J})^{-1} \mathbf{J}^T \mathbf{W} \tilde{\mathbf{i}}_{\text{zelle}} \quad (6.29a)$$

$$\text{Var}\{\bar{i}_{\text{ges}}\} = (\mathbf{J}^T \mathbf{W} \mathbf{J})^{-1}. \quad (6.29b)$$

\mathbf{J} ist die Jacobi-Matrix von $f(\mathbf{x}|a)$ am Punkt \mathbf{x} . Die Gleichungen (6.29a) und (6.29b) sind nur für lineare Systeme gültig. Da sich dies jedoch auf die Linearität von a und nicht von \mathbf{x} gegenüber $f(\mathbf{x}|a)$ bezieht, ist die Bedingung mit (3.10) erfüllt [318].

Die Matrizen in (3.10), welche das Batteriesystemmodell repräsentieren, benötigen die aktuellen Zellzustände $\hat{\mathbf{u}}_{\Sigma}$ sowie Innenwiderstände $\hat{\mathbf{R}}_0$ der im System enthaltenen Zellen. Hierfür kann auf das DKF des vorherigen Abschnitts zurückgegriffen werden, welches somit das Batteriesystemmodell auf einem aktuellen Stand hält.

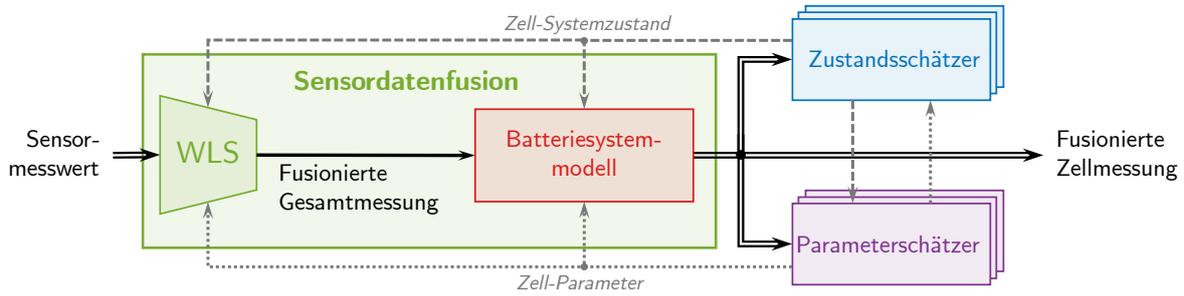


Abbildung 6.8: Blockschaltbild der modellbasierten Sensordatenfusion.

Der Wert für den fusionierten Gesamtstrom \bar{i}_{ges} mit der Schätzunsicherheit $\text{Var}\{\bar{i}_{\text{ges}}\}$ wird im zweiten Schritt mit (3.10) durch das Systemmodell propagiert, um die fusionierten Ströme \bar{i}_{zelle} zu erhalten. Die resultierende Varianz der fusionierten Zellströme kann abgeschätzt werden zu

$$\text{Var}\{\bar{i}_{\text{zelle}}\} = (-\mathfrak{R}^{-1} \mathfrak{F}) \text{Var}\{\hat{i}_{\text{ges}}\} (-\mathfrak{R}^{-1} \mathfrak{F})^T + (-\mathfrak{R}^{-1} \mathfrak{E}) \text{diag}\{\text{Var}\{\hat{\mathbf{u}}_{\Sigma}\}\} (-\mathfrak{R}^{-1} \mathfrak{E})^T. \quad (6.30)$$

Der nichtlineare Einfluss der Unsicherheit der Parameterschätzung wird vernachlässigt, sodass die Varianz von $\hat{\mathbf{R}}_0$ in (6.30) keine Berücksichtigung findet. Wie bereits gezeigt, ist diese im Vergleich zu den anderen Unsicherheiten klein.

Zu beachten ist, dass für jede involvierte Batteriezelle ein eigener Zustands- und Parameterschätzer vorgesehen ist. Der Zustandsschätzer liefert eine Schätzung für den Ladezustand SOC und die Spannung u_{Σ} für die betreffende Zelle zum aktuellen Zeitpunkt. Dagegen stellt der Parameterschätzer einen Wert für den Innenwiderstand R_0 der Zelle bereit.

6.3.1.2 Sensordatenfusion der Spannungsmessung

Die Fusion der Messwerte der Zellspannungen funktioniert analog zur beschriebenen Stromfusion. Zunächst werden die Messwerte der Sensoren über ein WLS-Verfahren zur Bestimmung der Systemspannung fusioniert. Anschließend erfolgt die Rücktransformation über das Batteriesystemmodell auf Zellebene.

Für den Zusammenhang zwischen Zellspannungen und Gesamtspannung müssen die Maschen- und Knotengleichungen aus Kapitel 3.1.3 modifiziert werden. Grundlage sei das 2s3p-Batteriesystem aus Abb. 3.4. Durch das Aufstellen von Maschen- und Knotengleichungen nach den Kirchhoffschen Gesetzen lässt sich folgender Zusammenhang zwischen Gesamtspannung und Zellströmen herstellen:

$$\begin{aligned}
0 = & \underbrace{\begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 1 & -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & -1 & 0 \\ 0 & 0 & 0 & 0 & 1 & -1 \\ 1 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}}_{\mathfrak{E}'} \underbrace{\begin{bmatrix} u_{\Sigma,1} \\ u_{\Sigma,2} \\ u_{\Sigma,3} \\ u_{\Sigma,4} \\ u_{\Sigma,5} \\ u_{\Sigma,6} \end{bmatrix}}_{\mathbf{u}_{\Sigma}} + \\
& \underbrace{\begin{bmatrix} 1 & 1 & 1 & -1 & -1 & -1 \\ R_{0,1} & -R_{0,2} & 0 & 0 & 0 & 0 \\ 0 & R_{0,2} & -R_{0,3} & 0 & 0 & 0 \\ 0 & 0 & 0 & R_{0,4} & -R_{0,5} & 0 \\ 0 & 0 & 0 & 0 & R_{0,5} & -R_{0,6} \\ R_{0,1} & 0 & 0 & R_{0,4} & 0 & 0 \end{bmatrix}}_{\mathfrak{N}'} \underbrace{\begin{bmatrix} i_{zelle,1} \\ i_{zelle,2} \\ i_{zelle,3} \\ i_{zelle,4} \\ i_{zelle,5} \\ i_{zelle,6} \end{bmatrix}}_{\mathbf{i}_{zelle}} + \underbrace{\begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ -1 \end{bmatrix}}_{\mathfrak{F}'} u_{ges}. \quad (6.31)
\end{aligned}$$

Durch Umformen erhält man

$$\mathbf{i}_{zelle} = -\mathfrak{N}'^{-1}(\mathfrak{E}' \mathbf{u}_{\Sigma} + \mathfrak{F}' u_{ges}). \quad (6.32)$$

Aus den Zellströmen lassen sich nun über den Spannungsabfall am Ohmschen Widerstand des Zellmodells die Zellspannungen ermitteln

$$\underbrace{\begin{bmatrix} u_{zelle,1} \\ u_{zelle,2} \\ u_{zelle,3} \\ u_{zelle,4} \\ u_{zelle,5} \\ u_{zelle,6} \end{bmatrix}}_{\mathbf{u}_{zelle}} = \underbrace{\begin{bmatrix} R_{0,1} & 0 & 0 & 0 & 0 & 0 \\ 0 & R_{0,2} & 0 & 0 & 0 & 0 \\ 0 & 0 & R_{0,3} & 0 & 0 & 0 \\ 0 & 0 & 0 & R_{0,4} & 0 & 0 \\ 0 & 0 & 0 & 0 & R_{0,5} & 0 \\ 0 & 0 & 0 & 0 & 0 & R_{0,6} \end{bmatrix}}_{\mathfrak{S}} \mathbf{i}_{zelle} + \mathbf{u}_{\Sigma}. \quad (6.33)$$

Mit (6.32) und (6.33) lässt sich der Zusammenhang zwischen u_{ges} und \mathbf{u}_{zelle} darstellen:

$$\mathbf{u}_{zelle} = -\mathfrak{S} \mathfrak{N}'^{-1}(\mathfrak{E}' \mathbf{u}_{\Sigma} + \mathfrak{F}' u_{ges}) + \mathbf{u}_{\Sigma} \quad (6.34)$$

Für die Fusion der Messungen der Spannungssensoren zu jedem Zeitschritt mit dem WLS-Verfahren wird die Gewichtungsmatrix \mathbf{W} mit den Kehrwerten der Varianz des Sensorrauschens belegt.

$$\mathbf{W} = \text{diag} \{ \text{Var} \{ \tilde{u}_{zelle,1} \}, \text{Var} \{ \tilde{u}_{zelle,2} \}, \dots, \text{Var} \{ \tilde{u}_{zelle,z} \} \} \quad (6.35)$$

Als Modellfunktion wird (6.34) verwendet, welche wiederum linear gegenüber dem gesuchten Parameter $\boldsymbol{\theta}$ des WLS ist. Es ergibt sich für den Schätzwert der Gesamtspannung und die dazugehörige Varianz

$$\bar{u}_{\text{ges}} = (\mathbf{J}^T \mathbf{W} \mathbf{J})^{-1} \mathbf{J}^T \mathbf{W} \tilde{\mathbf{u}}_{\text{zelle}} \quad (6.36a)$$

$$\text{Var} \{ \bar{u}_{\text{ges}} \} = (\mathbf{J}^T \mathbf{W} \mathbf{J})^{-1}, \quad (6.36b)$$

wobei \mathbf{J} weiterhin die Jacobi-Matrix von $f(\mathbf{x}|a)$ am Punkt \mathbf{x} ist.

Mit (6.34) ergeben sich die fusionierten Zellspannungen, wobei die Varianz von $\bar{\mathbf{u}}_{\text{zelle}}$ über

$$\begin{aligned} \text{Var} \{ \bar{\mathbf{u}}_{\text{zelle}} \} &= (-\mathfrak{S} \mathfrak{X}^{-1} \mathfrak{F}') \text{Var} \{ \hat{\mathbf{u}}_{\text{ges}} \} (-\mathfrak{S} \mathfrak{X}^{-1} \mathfrak{F}')^T \\ &\quad + (-\mathfrak{S} \mathfrak{X}^{-1} \mathfrak{E}') \text{diag} \{ \text{Var} \{ \hat{\mathbf{u}}_{\Sigma} \} \} (-\mathfrak{S} \mathfrak{X}^{-1} \mathfrak{E}')^T \\ &\quad + \text{diag} \{ \text{Var} \{ \hat{\mathbf{u}}_{\Sigma} \} \} \end{aligned} \quad (6.37)$$

abgeschätzt werden kann.

6.3.2 Herleitung der erzielbaren Varianzreduktion

Die resultierende Reduktion der Varianz des Sensorrauschens wird zunächst aus theoretischer Sicht quantifiziert. Die folgende Betrachtung beschränkt sich der Einfachheit halber auf die Stromfusion, kann jedoch analog auf die Spannungsfusion übertragen werden. Für eine geschlossene Lösung werden vereinfachende Annahmen getroffen: Als Modell der Batteriezeile wird ein einfacher Ohmscher Widerstand R angenommen, da die Stromaufteilung parallel verschalteter Zellen zu Beginn eines Stromsprungs hauptsächlich durch deren Ohmsche Innenwiderstände bestimmt wird [117, 128]. In einem System mit \mathcal{S} seriellen und \mathcal{P} parallelen Zellen leitet sich der Gesamtstrom \tilde{i}_{ges} dann aus dem Sensormesswert der Zelle mit Index s, p gemäß (6.38a) ab und dessen Varianz gemäß (6.38b). Die Indizes s und p beziehen sich auf die Position der Zelle in serieller bzw. paralleler Richtung. Der Widerstand $R_{\text{par},s}$ bezeichnet den Gesamtwiderstand der s -ten Parallelschaltung.

$$\tilde{i}_{\text{ges},s,p} = \frac{R_{s,p}}{R_{\text{par},s}} \cdot \tilde{i}_{\text{zelle},s,p} \quad \text{mit} \quad R_{\text{par},s} = \left(\sum_{k=1}^{\mathcal{P}} \frac{1}{R_{s,k}} \right)^{-1} \quad (6.38a)$$

$$\text{Var} \{ \tilde{i}_{\text{ges},s,p} \} = \frac{R_{s,p}^2}{R_{\text{par},s}^2} \cdot \text{Var} \{ \tilde{i}_{\text{zelle},s,p} \} \quad (6.38b)$$

Nach Maybeck [319, S. 12] kann mit (6.39) die Varianz des fusionierten Gesamtstroms \bar{i}_{ges} ausgedrückt werden. Hierbei werden alle gemessenen Zellströme berücksichtigt.

$$\text{Var} \{ \bar{i}_{\text{ges}} \} = \left(\sum_{j=1}^{\mathcal{S}} \sum_{k=1}^{\mathcal{P}} \frac{1}{\text{Var} \{ \tilde{i}_{\text{ges},j,k} \}} \right)^{-1} \quad (6.39a)$$

$$= \left(\sum_{j=1}^{\mathcal{S}} \sum_{k=1}^{\mathcal{P}} \frac{R_{\text{par},j}^2}{R_{j,k}^2 \text{Var} \{ \tilde{i}_{\text{zelle},j,k} \}} \right)^{-1} \quad (6.39b)$$

Unter der vereinfachenden Annahme, dass alle Zellinnenwiderstände gleich groß sind und alle Stromsensoren ein Sensorrauschen gleicher Varianz aufweisen, gilt

$$\text{Var} \{ \bar{i}_{\text{ges}} \} = \left(\frac{1}{\mathcal{P}^2} \cdot \sum_{j=1}^{\mathcal{S}} \sum_{k=1}^{\mathcal{P}} \frac{1}{\text{Var} \{ \tilde{i}_{\text{ges}} \}} \right)^{-1} = \frac{\mathcal{P}}{\mathcal{S}} \cdot \text{Var} \{ \tilde{i}_{\text{zelle}} \}. \quad (6.40)$$

Durch Rücktransformation des Gesamtstroms durch das Batteriemodell auf die Zelle an Position $\{s,p\}$ ergibt sich

$$\bar{i}_{\text{zelle},s,p} = \frac{R_{\text{par},s}}{R_{s,p}} \cdot \bar{i}_{\text{ges}}. \quad (6.41)$$

Schließlich kann die korrespondierende Varianz aus (6.42) gewonnen werden, wobei die getroffenen Annahmen bezüglich gleicher Widerstände und Varianzen weiterhin gültig sein sollen.

$$\begin{aligned} \text{Var} \{ \bar{i}_{\text{zelle},s,p} \} &= \left(\frac{R_{\text{par},s}}{R_{s,p}} \right)^2 \cdot \text{Var} \{ \bar{i}_{\text{ges}} \} \\ &= \left(\frac{R_{\text{par}}}{R_{s,p}} \right)^2 \cdot \frac{\mathcal{P}}{\mathcal{S}} \cdot \text{Var} \{ \tilde{i}_{\text{zelle}} \} \\ &= \frac{1}{\mathcal{P}^2} \cdot \frac{\mathcal{P}}{\mathcal{S}} \text{Var} \{ \tilde{i}_{\text{zelle}} \} \\ &= \frac{1}{\mathcal{S}\mathcal{P}} \text{Var} \{ \tilde{i}_{\text{zelle}} \} \\ &= \frac{1}{\mathcal{Z}} \text{Var} \{ \tilde{i}_{\text{zelle}} \} \end{aligned} \quad (6.42a)$$

Es zeigt sich, dass die Varianz der fusionierten Zellströme im Vergleich zu den Sensorwerten um einen Faktor reduziert werden kann, welche der Anzahl der für die Fusion berücksichtigten Zellen bzw. Sensoren entspricht. Die Topologie des Batteriesystems, also die Werte von \mathcal{S} und \mathcal{P} , spielt hierfür keine Rolle. Natürlich handelt es sich bei der vorgestellten Berechnung um eine Best-Case-Betrachtung. Unsicherheiten bei der Bestimmung des Modellzustands und der Modellparameter können die Varianz der fusionierten Werte erhöhen. Durch Simulationen und Experimente wird die tatsächliche Leistungsfähigkeit der SDF im weiteren Verlauf untersucht.

6.3.3 Erhöhung der Robustheit der Strommessung

Neben der Reduktion des Messrauschens besteht ein weiterer Vorteil der SDF darin, dass der Ausfall einzelner Sensoren durch die Messdaten der anderen Sensoren kompensiert werden kann. Eine Information beispielsweise zum Strom einer spezifischen Zelle ist dann trotz Defekt des entsprechenden Sensors noch vorhanden. Diese erhöhte Robustheit kann durch die mittlere Betriebszeit bis zum Ausfall (engl. *mean time to failure*, MTTF) quantifiziert werden. Hierbei handelt es sich um die mittlere Betriebsdauer bis zum Ausfall eines Systems oder den Erwartungswert der Betriebsdauer bis zum Ausfall. Es soll generell zwischen der mittleren Betriebsdauer der Einzelzelle $\text{MTTF}_{\text{zelle}}$ und der kombinierten Betriebsdauer des Gesamtsystems MTTF_{ges} unterschieden werden. Vereinfachend wird von einer konstanten Ausfallrate ausgegangen. Besteht allgemein ein

System aus \mathcal{A} Subsystemen, von denen *alle* für die Funktionalität des Gesamtsystems verfügbar sein müssen, gilt [320, S. 67]

$$\text{MTTF}_{\text{sys}} = \left(\sum_{a=1}^{\mathcal{A}} \frac{1}{\text{MTTF}_{\text{sub}, a}} \right)^{-1}. \quad (6.43)$$

In Anlehnung an elektrische Schaltkreise wird diese Verknüpfung *Reihenschaltung* genannt. Für die MTTF eines kombinierten Systems, in welchem \mathcal{B} von \mathcal{A} Subsystemen für die Funktionsfähigkeit des Gesamtsystems in Betrieb sein müssen, gilt [321, Seite 78]

$$\text{MTTF}_{\text{sys}, \mathcal{B} \subseteq \mathcal{A}} = \text{MTTF}_{\text{sub}} \cdot \sum_{a \in \mathcal{B}} \frac{1}{a}. \quad (6.44)$$

Die mittlere Betriebszeit des Gesamtsystems $\text{MTTF}_{\text{sys}, \mathcal{B} \subseteq \mathcal{A}}$ ist insbesondere dann größer als die des Subsystems MTTF_{sub} , wenn die Redundanz $\mathcal{R} = \mathcal{A} - \mathcal{B}$ groß ist. Insbesondere gilt jedoch für $\mathcal{R} = \mathcal{A} - 1$

$$\text{MTTF}_{\text{sys}} = \text{MTTF}_{\text{sub}} \cdot \sum_{a=1}^{\mathcal{A}} \frac{1}{a}, \quad (6.45)$$

wobei diese Verknüpfung als *Parallelschaltung* der Subsysteme bezeichnet wird.

Durch die Redundanz der Spannungsmessung in Parallelschaltungen ist die Erhöhung der Robustheit intuitiv nachzuvollziehen. Im Folgenden wird wieder nur auf die Strommessung eingegangen, die Ergebnisse sind allerdings auch auf die Spannungsmessung anwendbar.

In einem Batteriesystem ohne SDF kann für den Ausfall des Gesamtsystems folgende Annahme getroffen werden: Sobald in einem Parallelstrang mehr als ein Stromsensor ausfällt, kann der Zellstrom nicht mehr für jede Zelle ermittelt werden. Das System gilt dann als ausgefallen. Gemäß (6.43) und (6.44) gilt für ein Batteriesystem mit \mathcal{Z} Zellen, wobei jeweils \mathcal{P} Zellen parallel und \mathcal{S} Parallelstränge in Reihe geschaltet sind

$$\text{MTTF}_{\text{ges}} = \frac{1}{\mathcal{S}} \left(\frac{1}{\mathcal{P} - 1} + \frac{1}{\mathcal{P}} \right) \cdot \text{MTTF}_{\text{zelle}}. \quad (6.46)$$

Die Redundanz innerhalb der Parallelstränge ist jeweils eins, wohingegen die seriellen Stränge als Reihenschaltung keinerlei Redundanz aufweisen. Wie man der Gleichung entnehmen kann, sinkt die mittlere Betriebszeit des Batteriesystems mit steigender Anzahl von Zellen. (6.46) ist nur für $\mathcal{P} \geq 2$ gültig.

In Abb. 6.9 ist die resultierende mittlere Betriebszeit MTTF_{sys} in logarithmischer Darstellung für verschiedene typische Werte für \mathcal{S} und \mathcal{P} dargestellt. Hierbei wurde die mittlere Betriebszeit auf $\text{MTTF}_{\text{zelle}}$ normiert. Erwartungsgemäß sinkt die MTTF, je mehr Zellen involviert sind. Die Abnahme ist stärker, wenn die Zahl paralleler Zellen steigt, und schwächer bei Zunahme der seriellen Stränge.

Kommt die modellbasierte SDF zum Einsatz, ändert sich die Sichtweise auf die Robustheit des Batteriesystems. Ein oder mehrere Sensordefekte führen nicht mehr zu einem Ausfall des Gesamtsystems, da prinzipiell jeder Sensorwert aus dem Batteriemodell rekonstruiert werden

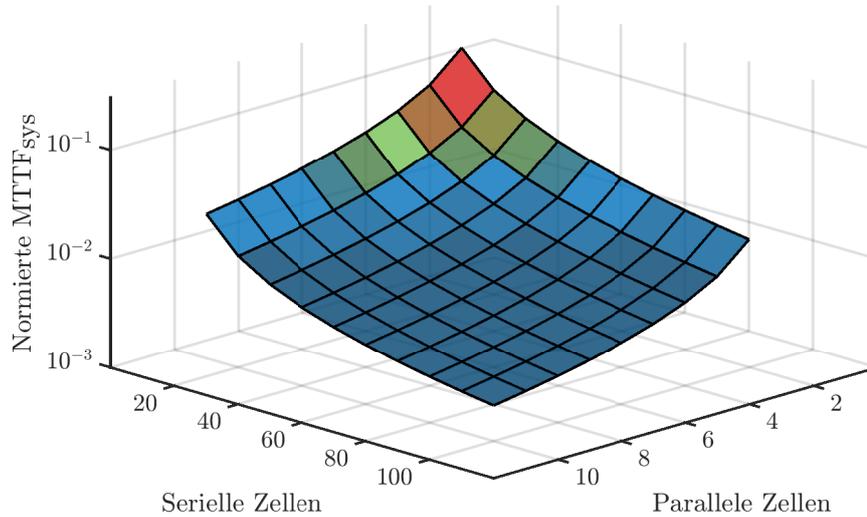


Abbildung 6.9: Normierte mittlere Betriebszeit eines Batteriesystems ohne SDF abhängig von der Anzahl serieller und paralleler Zellen.

kann. Allerdings nimmt die Unsicherheit der fusionierten Information zu, da die Reduktion der Varianz des Messrauschens gemäß Abschnitt 6.3.2 vom Kehrwert der involvierten Sensoren abhängig ist. Umgekehrt gilt: Fällt eine bestimmte Anzahl \mathcal{D} an Sensoren aus, erhöht sich die Varianz des fusionierten Stromsignals um einen gewissen Wert. Die Anzahl an tolerierbaren Zelldefekten \mathcal{D}_{tol} hängt damit von der Anforderung an die Genauigkeit des Signals ab. Unter der Annahme, dass sich die Varianz des fusionierten Stromsignals um weniger als den relativen Grenzwert ϵ_r verschlechtern soll (z. B. um nicht mehr als 10% steigen soll), kann \mathcal{D}_{tol} über die folgende Ungleichung bestimmt werden:

$$\frac{1}{\mathcal{Z} - \mathcal{D}_{\text{tol}}} / \frac{1}{\mathcal{Z}} \leq 1 + \epsilon_r. \quad (6.47)$$

Es gilt folglich durch Umformungen für \mathcal{D}_{tol} :

$$\mathcal{D}_{\text{tol}} = \left\lfloor \mathcal{Z} \left(\frac{\epsilon_r}{1 + \epsilon_r} \right) \right\rfloor. \quad (6.48)$$

Jetzt lässt sich für \mathcal{B} in (6.44) $\mathcal{Z} - \mathcal{D}_{\text{tol}}$ einsetzen und \mathcal{Z} für \mathcal{A} . Damit ergibt sich die mittlere Betriebszeit des Batteriesystems mit SDF zu

$$\text{MTTF}_{\text{SDF}} = \text{MTTF}_{\text{zelle}} \cdot \sum_{a=\mathcal{Z}-\mathcal{D}_{\text{tol}}}^{\mathcal{Z}} \frac{1}{a}. \quad (6.49)$$

Für verschiedene ϵ_r im Bereich von 1% bis 20% wird die MTTF untersucht. Die Ergebnisse sind in Abb. 6.10 dargestellt. Der Verlauf der Kurven kann als abklingender Sägezahn beschrieben werden. Tatsächlich springt die MTTF jeweils an denjenigen Punkten nach oben, an welchen sich die Zahl der zu tolerierenden Sensordefekte um eins erhöht. Anschließend sinkt der Wert wieder,

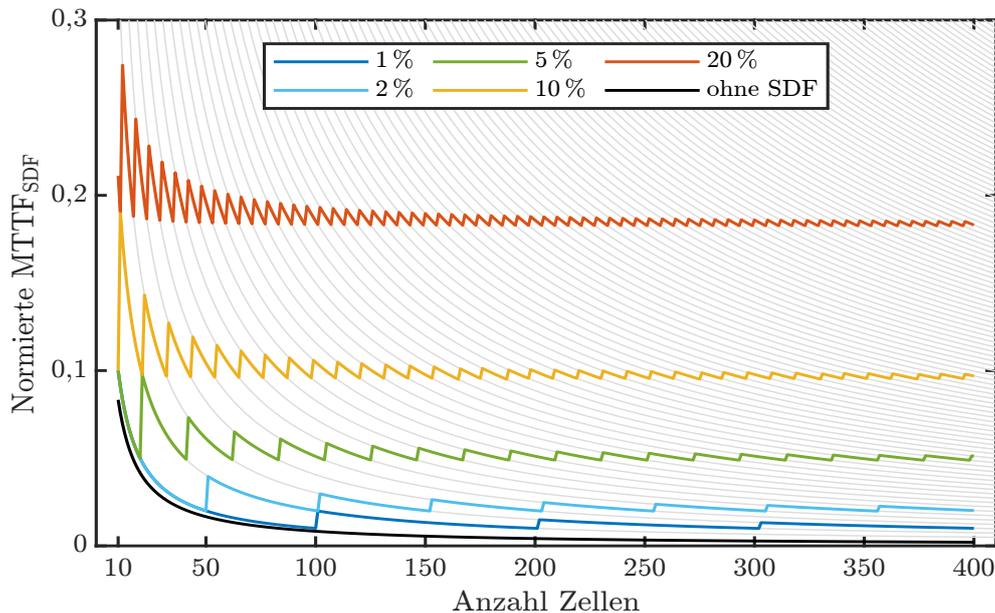


Abbildung 6.10: Normierte mittlere Betriebszeit eines Batteriesystems mit SDF abhängig von der Zellanzahl Z für verschiedene ϵ_r . Zum Vergleich ist auch $MTTF_{ges}$ eines herkömmlichen Batteriesystems (mit $\mathcal{P} = 3$) dargestellt.

wenn sich die Zahl der Zellen im System erhöht. Ab einer bestimmten Anzahl an im System involvierter Sensoren ändert sich die MTTF kaum mehr. Der Verlauf der MTTF abhängig von der Zellzahl für jedes mögliche \mathcal{D}_{tol} ist im Diagramm in Grau hinterlegt. Weiterhin lässt sich beobachten: Die mittlere Betriebszeit ist umso höher, je größer die Toleranz ϵ_r ist. Deutlich zu sehen ist jedoch, dass die Zuverlässigkeit in jedem Fall größer ist, als im konventionellen System. Während dort die MTTF immer kleiner wird, ist sie im System mit SDF näherungsweise konstant für große Z .

6.3.4 Untersuchung der Sensordatenfusion in Simulationen und Experimenten

Um die Wirkungsweise der modellbasierten SDF zu untersuchen, werden Experimente durchgeführt und die resultierenden Messdaten bewertet. Ein Batteriemodul bestehend aus zwölf intelligenten Batteriezellen in 4s3p-Verschaltung wird dazu mit unterschiedlichen Stromprofilen angeregt. Die Referenzmessdaten von Strom und Spannung werden anschließend mit künstlichem Rauschen überlagert, um Zugriff auf die Charakteristik des Sensorrauschens zu erhalten. Das Sensorrauschen ist mittelwertfrei mit einer Standardabweichung von 1 A bzw. 10 mV. Jeder Zelle liegt ein Zellmodell zugrunde, dessen Parameter durch Charakterisierungsversuche ermittelt wurden (siehe Kapitel 3.2). Weitere Details des Versuchsaufbaus können Anhang B entnommen werden.

Der sich bei Anregung mit dem WLTP-Fahrzyklus ergebende Zellstrom ist in Abb. 6.11a dargestellt. Das Anregungsprofil hat eine Länge von 1800 s. Ebenfalls zu sehen ist das (künstlich) verrauschte Messsignal zusammen mit dem fusionierten Strom. Um den Messfehler bzw. Fehler der SDF deutlicher sichtbar zu machen, sind diese zusätzlich im unteren Diagramm dargestellt.

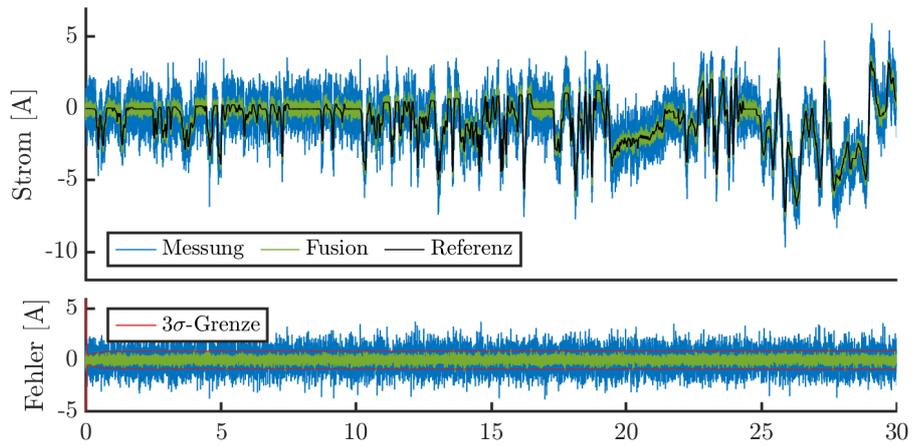
Die Reduktion des Messrauschens durch die Anwendung der SDF ist deutlich zu sehen. Ebenso kann festgestellt werden, dass der fusionierte Strom einen mittelwertfreien Fehler aufweist. Aus den Herleitungen in Kapitel 6.3.2 ist eine Reduktion der Standardabweichung des Sensorrauschens um den Faktor $\sqrt{12}$ zu erwarten, wenn die Messung mit der Fusion verglichen wird. Für die daraus resultierende Messunsicherheit ist die Grenze der dreifachen Standardabweichung im Diagramm eingezeichnet, innerhalb derer 99,7% der Messfehler liegen sollen. Wie zu sehen ist, stimmt diese prädizierte Messunsicherheit mit dem resultierenden Fehler des fusionierten Stroms überein. In Abb. 6.11b ist analog die Zellspannung zusammen mit den gemessenen und fusionierten Signalen aufgetragen. Innerhalb des Fahrprofils sinkt die Spannung von anfangs mehr als 4,05 V auf zwischenzeitlich weniger als 3,70 V ab. Auch hier ist der Fehler des Messsignals und des fusionierten Stroms separat gezeichnet. Erneut passt die prädizierte Messunsicherheit sehr gut zu den tatsächlich ermittelten Fehlern der SDF. Über den Verlauf des Fahrprofils sind leichte Abweichungen des fusionierten Spannungsfehlers von einem mittelwertfreien Rauschen zu erkennen. Diese systematischen Verschiebungen beruhen auf Defiziten des Batteriemodells. Dabei führen insbesondere Fehler bei der Modellierung der $u_{OC} - SOC$ -Kurve zu dem hier beobachtbaren Phänomen.

Eine andere Darstellung der Versuchsergebnisse erhält man, wenn die Fehler der gemessenen bzw. fusionierten Signale in einem Histogramm wie in Abb. 6.12 aufgetragen werden. Die geringere Varianz der Verteilung der Fehler der SDF zeigt sich in einer signifikant stärker ausgeprägten Wahrscheinlichkeitsdichte für kleine Fehlerwerte. Unter der Annahme eines Gaußschen Messrauschens ergibt sich auch für die Datenfusion eine gute Übereinstimmung mit einer normalverteilten Wahrscheinlichkeitsdichte, wie in der Abbildung gezeigt. Die erwartete Reduktion des Fehlers deckt sich wiederum mit der in Kapitel 6.3.2 hergeleiteten Größe. Ein leichter systematischer Fehler der fusionierten Spannung lässt sich erneut erkennen, allerdings ist der Fehler auf wenige Millivolt begrenzt.

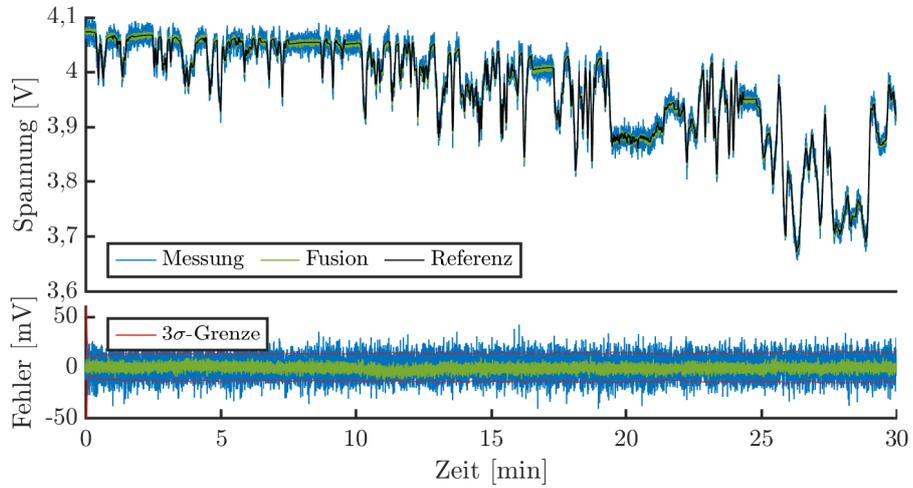
Insgesamt kann der vorgestellten SDF basierend auf den durchgeführten Versuchen prinzipiell eine gute Funktionsfähigkeit attestiert werden. Die dem Messrauschen eigene Unsicherheit kann durch die Fusion der zwölf Signale über den Verlauf des Stromprofils wirksam reduziert werden. Dabei stimmen die gemessenen Ergebnisse mit den zuvor hergeleiteten Kennwerten sehr gut überein. Im Folgenden werden die experimentellen Ergebnisse durch Simulationen ergänzt. Mit deren Hilfe ist es möglich, die Randbedingungen wie beispielsweise die Größe des Batteriesystems flexibel zu variieren und weitere Aussagen zur Funktionsweise der SDF zu treffen. Zur Validierung der simulativen Ergebnisse werden diese mit den Resultaten der realen Versuche verglichen und im Folgenden den experimentellen Ergebnissen zur Seite gestellt. Werden bei ähnlichen Randbedingungen vergleichbare Resultate ermittelt, kann die Simulation als valide angesehen werden und genutzt werden, um Aussagen über das reale System zu gewinnen. Der Aufwand für die Durchführung einer Vielzahl realer Experimente wird dadurch reduziert.

6.3.4.1 Vergleich mit herkömmlicher Strommessung

Nachdem gezeigt werden konnte, dass die SDF entsprechend ihrer Prinzipien funktionsfähig ist, stellt sich in einem zweiten Schritt die Frage, wie der vorgestellte Ansatz gegenüber herkömmlichen



(a) Strom



(b) Spannung

Abbildung 6.11: Vergleich von Sensormessungen einer Zelle mit den fusionierten Werten für (a) Strom und (b) Spannung (Stromprofil: WLTP, Topologie: 4s3p).

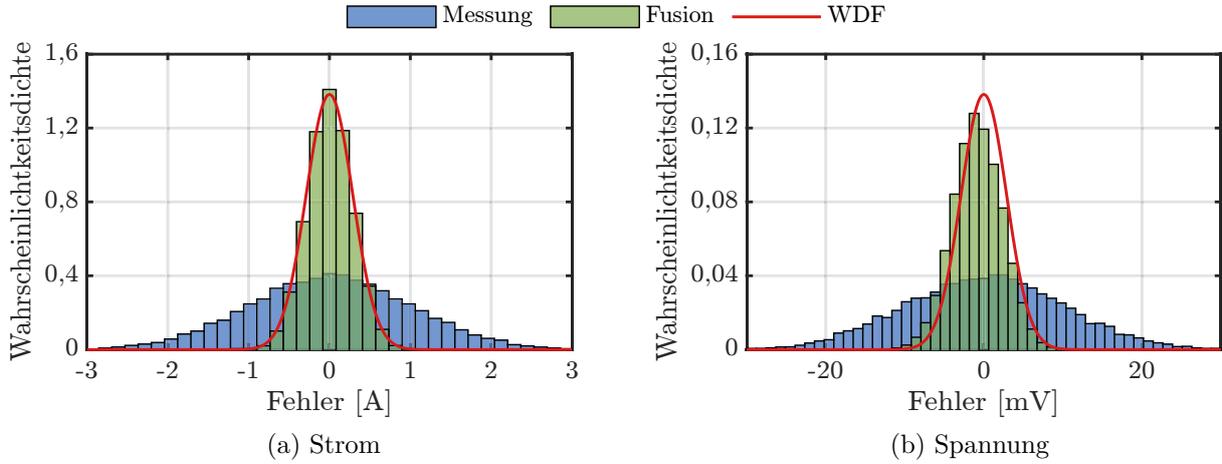


Abbildung 6.12: Histogramm zum Vergleich von Sensormessungen einer Zelle mit den fusionierten Werten für (a) Strom und (b) Spannung. Dargestellt ist die Wahrscheinlichkeitsdichte des Messfehlers und die prädierte Wahrscheinlichkeitsdichtefunktion (Stromprofil: WLTP, Topologie: 4s3p).

Verfahren der Strommessung zu bewerten ist. Eine Antwort auf diese Frage rechtfertigt dann den zusätzlichen Rechenaufwand, welcher der SDF zu eigen ist.

Stand der Technik heutiger Batteriesysteme ist eine Gesamtstrommessung (GSM) und eine individuelle Ermittlung der Zellspannungen. Um eine Vergleichbarkeit zur SDF herzustellen, wird die Annahme getroffen, dass die Standardabweichung (engl. *standard deviation*) (SD) des Rauschens des Gesamtstromsensors einem Zwölftel der Standardabweichung der Zellsensoren entspricht. Dadurch wird dem Umstand Rechnung getragen, dass üblicherweise sehr genaue Sensoren für die Gesamtstrommessung zum Einsatz kommen.

Als zweiter Benchmark für die modellbasierte SDF soll ein sehr einfaches Verfahren dienen, welches ebenfalls Zugriff auf zellindividuelle Strom- und Spannungssignale hat. Bei der Mittelwert-Strommessung (MWSM) wird kein Batteriemodell genutzt, sondern die Sensormesswerte der j -ten Zelle werden gemäß

$$\bar{i}_{\text{zelle},j} = \frac{1}{\mathcal{P}} \cdot \bar{i}_{\text{ges}} = \frac{1}{\mathcal{P}} \left(\frac{1}{\mathcal{S}} \cdot \sum_{z=1}^{\mathcal{Z}} \tilde{i}_{\text{zelle},z} \right) \quad (6.50)$$

$$\bar{u}_{\text{zelle},j} = \frac{1}{\mathcal{P}} \cdot \sum_{z=(s-1)\mathcal{P}}^{s\mathcal{P}} \tilde{u}_{\text{zelle},z} \quad \text{mit } s = \left\lceil \frac{j}{\mathcal{P}} \right\rceil \quad (6.51)$$

durch Mittelwertbildung bestimmt. Da dem Verfahren die Annahme zugrunde liegt, dass alle Zellen ein identisches Verhalten zeigen, werden die Zellströme aus den Mittelwerten der Messwerte bestimmt. Dies ist für die Ermittlung der Zellspannungen kein adäquates Vorgehen, da unterschiedliche Ladezustände der Parallelstränge zu unterschiedlichen Zellspannungen führen. Daher werden für die MWSM die Spannungssignale derjenigen Sensoren gemittelt, die in demselben Parallelstrang verschaltet sind. Für eine bessere Übersichtlichkeit wurde in den Gleichungen auf den Index k verzichtet, welcher den diskreten Zeitschritt angibt.

Für das im vorherigen Abschnitt beschriebene Szenario werden nun die drei Verfahren GSM, SDF und MWSM miteinander verglichen. Als Maß für die Güte der Fusion dient der RMSE

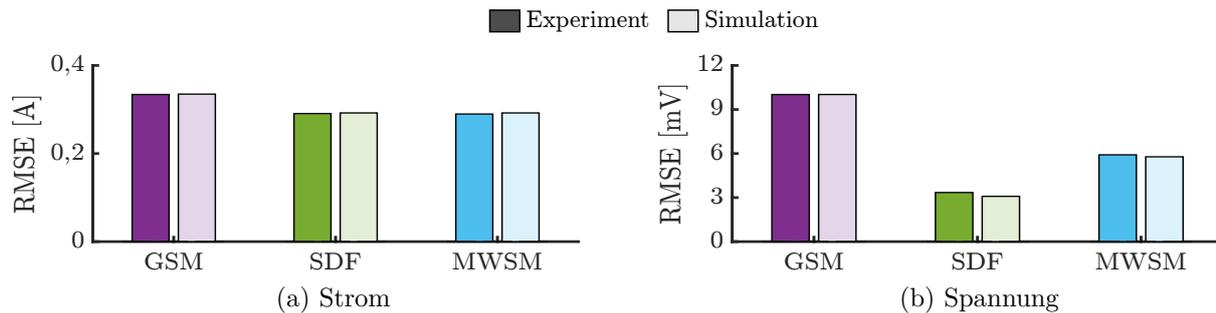


Abbildung 6.13: Vergleich der RMSE von fusioniertem Strom und fusionierter Spannung mit Benchmark-Verfahren. Dargestellt sind Ergebnisse aus Experiment und Simulation.

des Stroms bzw. der Spannung. Die Ergebnisse basieren sowohl auf Experimenten als auch Simulationen und sind in Abb. 6.13 dargestellt.

Für den Stromfehler ergeben sich für alle drei Verfahren ähnliche Werte. Für die GSM kann dies durch die im Vergleich zu den Zellsensoren geringere Messunsicherheit des Gesamtstromsensors erklärt werden. Dadurch ist das Messrauschen auf einem ähnlichen Niveau wie die SDF. Bei der MWSM führt die Mittelwertbildung des Stroms zu ähnlich guten Resultaten wie die beiden anderen Verfahren, weil die Stromaufteilung innerhalb der Parallelstränge des untersuchten Systems sehr homogen ist. Damit ist die Mittelwertbildung ein valides Verfahren für die Reduktion der Messunsicherheit auch ohne Verwendung eines Batteriemodells. Bei den Zellspannungen sind die Ergebnisse dagegen differenzierter zu betrachten. Der RMSE der GSM ist am größten und entspricht dem ursprünglichen Messrauschen, da die Zellspannungen bei diesem Verfahren nicht weiter fusioniert werden. Anders liegt der Fall bei der MWSM. Da die Spannungsmesswerte innerhalb der drei parallel verschalteten Zellen gemittelt wird, kann der Messfehler um den Faktor $\sqrt{3}$ reduziert werden. Nur bei der SDF werden alle Spannungssensoren für die Ermittlung der Zellspannung berücksichtigt. Im Ergebnis liegt der RMSE am niedrigsten, da die Standardabweichung der Messunsicherheit um den Faktor $\sqrt{12}$ reduziert werden kann.

Die Resultate von Simulation und Experiment sind für alle untersuchten Verfahren sehr ähnlich. Es kann daher davon ausgegangen werden, dass die Simulationen das reale Systemverhalten mit ausreichender Genauigkeit abbilden. Damit können im Folgenden angepasste Simulationen zur Gewinnung weiterer Ergebnisse verwendet werden.

6.3.4.2 Einfluss der Parametervariation aufgrund von Alterung

Der modellbasierte Ansatz der SDF ist insbesondere dann vorteilhaft, wenn das Zellverhalten innerhalb des Batteriesystems nicht homogen ist. Dies ist beispielsweise der Fall, wenn sich der Gesamtstrom aufgrund unterschiedlicher Innenwiderstände nicht mehr zu gleichen Teilen auf die Zellen im Parallelstrang aufteilt. Genauso führen unterschiedliche Ladezustände der Zellen zu einem heterogenen System. Insbesondere im Hinblick auf die im IBS auftretenden Schalthandlungen ist dies ein zu berücksichtigender Faktor. Aber auch mit zunehmender Zellalterung können Zellparameter auseinanderdriften.

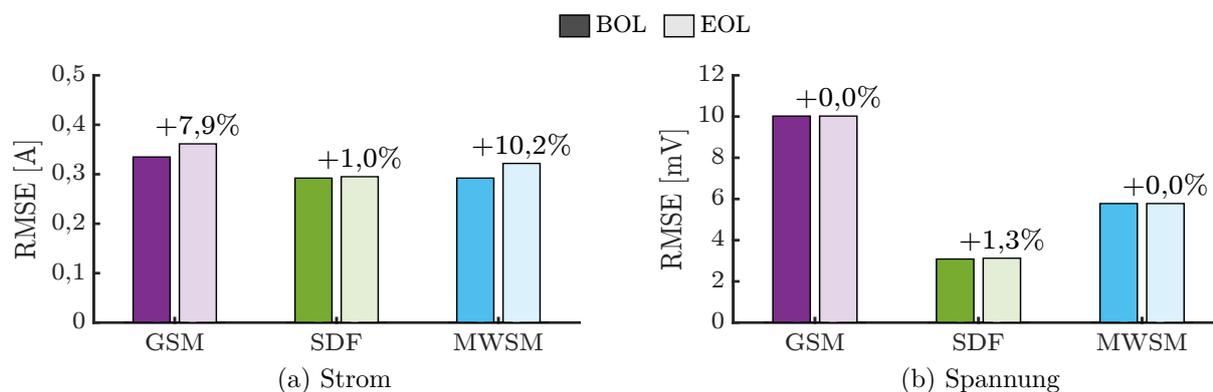


Abbildung 6.14: Vergleich des RMSEs aus der Simulation mit einer Parametervariation eines neuen und alten Batteriesystems mit den Benchmark-Verfahren.

In Kapitel 3.1.4 wurde basierend auf einer Literaturrecherche dargestellt, wie groß die Parametervariation innerhalb eines Batteriesystems sein kann und wie sehr diese Streuung über den Lebenszyklus der Batteriezellen zunimmt. Um Aussagen über die Wirksamkeit der modellbasierten SDF im Hinblick auf gealterte Zellen und damit einer hohen Parametervariation zu treffen, werden für die folgende simulative Untersuchung ein Koeffizient $\kappa_{Q,EOL} = 2\%$ für die Streuung der Kapazität und $\kappa_{R_0,EOL} = 20,0\%$ für die Streuung der Innenwiderstände angenommen. Diese Werte sind als Worst-Case-Werte zu verstehen, welche jedoch das Potenzial des vorgestellten Verfahrens zur SDF beleuchten können.

Die Ergebnisse der Simulation mit der Parameterstreuung gealterter Zellen (EOL) sind in Abb. 6.14 den bisherigen Resultaten (BOL) gegenübergestellt. Erneut werden die drei Verfahren zur Strom- und Spannungsmessung, wie im vorherigen Abschnitt beschrieben, miteinander verglichen. Die Veränderung des RMSEs ist zusätzlich prozentual angegeben. Betrachtet man zunächst die Strommessung, so fällt die Verschlechterung der Messgenauigkeit bei der GSM und der MWSM auf. Beide Verfahren berücksichtigen nicht, dass sich aufgrund der Parameterstreuung insbesondere der Zell-Innenwiderstände die Zellströme im Parallelstrang nicht mehr gleichmäßig aufteilen. Dadurch kommt es zu erheblichen Abweichungen, wenn die Ströme der Batteriezellen mit kleinem Innenwiderstand unterschätzt werden und analog die Ströme stark gealterter Zellen mit großem Innenwiderstand zu groß angenommen werden. In der Folge steigt der RMSE um 7,9% bis 10,2%. Dahingegen bildet das der SDF inhärente Modell die heterogenen Zellparameter ab, wodurch auch die Stromaufteilung modelliert werden kann. Infolgedessen bleibt die Genauigkeit der fusionierten Ströme unverändert hoch (+1,0%). Betrachtet man die Fusion der Zellspannungen in Abb. 6.14b, lassen sich keine signifikanten Veränderungen der RMSEs beobachten. Dies ist darauf zurückzuführen, dass bei der GSM von vornherein die Zellspannungen separat betrachtet werden und auch bei der MWSM nur die Zellspannungen innerhalb eines Parallelstrangs miteinander fusioniert werden. Die erhöhte Streuung der Kapazitäten und der Innenwiderstände hat keinen Einfluss auf diese. Die SDF berücksichtigt die Inhomogenitäten der Zellen zueinander adäquat, wobei die unterschiedlichen Zellspannungen in erster Linie durch unterschiedliche Ladezustände hervorgerufen werden. Dennoch zeigt sich, dass auch am EOL der Fehler der fusionierten Spannungen auf niedrigem Niveau bleibt.

6.3.4.3 Einfluss der Anzahl an Zellen/Sensoren

Die bisherigen Versuche und Experimente wurden auf der Basis eines Batteriemoduls mit zwölf intelligenten Batteriezellen durchgeführt. Üblicherweise bestehen die Batteriesysteme in BEVs jedoch aus mehreren Hundert oder gar Tausend Zellen. Gemäß Kapitel 6.3.2 nimmt die Varianz durch die SDF um den Faktor ab, welcher der Anzahl an involvierten Zellen bzw. Sensoren entspricht. Um dies zu überprüfen, werden Simulationen durchgeführt, bei denen die Anzahl an parallel verschalteten Zellen zwischen eins und zehn variiert wird und gleichzeitig die Anzahl an seriell verschalteten Strängen zwischen eins und vierzig. Es ergeben sich dadurch Batteriesysteme bis zu einer Größe von 400 Zellen. Die Ergebnisse dieser Simulationen sind in Abb. 6.15 dargestellt, wobei die Standardabweichung auf die Standardabweichung des Sensorrauschens normiert wurde, woraus die sogenannte normierte Standardabweichung resultiert. In Abb. 6.15a sind die Ergebnisse der Simulationen in einem zweidimensionalen Netz gezeichnet, wohingegen in Abb. 6.15b bzw. Abb. 6.15c die Standardabweichungen für eine fixierte Anzahl an parallelen bzw. seriellen Zellen zur Verdeutlichung gezeigt werden. Die Ergebnisse belegen, dass die analytisch hergeleitete Reduktion des Sensorrauschens in den Simulationen erreicht werden kann. Die analytisch abgeschätzte Varianzreduktion entspricht immer in sehr guter Näherung den erzielten Standardabweichungen.

6.3.4.4 Einfluss des Sensorrauschens

Bisher lag den Untersuchungen der SDF die Annahme zugrunde, dass die Sensoren aller intelligenten Batteriezellen die gleiche Charakteristik hinsichtlich des Messrauschens aufweisen. Bevor im nächsten Kapitel Verfahren zur Bestimmung des Sensorrauschens vorgestellt werden, wird an dieser Stelle eine Untersuchung durchgeführt, bei der die Standardabweichung des Messrauschens von Strom und Spannung zwischen den Zellen variiert. Grundlage der Untersuchung sind die experimentellen Daten eines Moduls bestehend aus zwölf intelligenten Batteriezellen. Für die Stromsensoren seien die Standardabweichungen des künstlichen Rauschens zufällig verteilt gemäß einer zentralen Normalverteilung mit der Standardabweichung $\sigma = 0,2 \text{ A}$ und die Standardabweichung des Sensorrauschens der Spannungssensoren entspricht der zentralen Normalverteilung mit $\sigma = 2 \text{ mV}$. In Abb. 6.16 sind die Standardabweichungen der Sensoren für Strom und Spannung für alle zwölf Zellen aufgetragen. Ebenfalls dargestellt sind die resultierenden Standardabweichungen der fusionierten Signale. Auffällig ist hierbei, dass die SDF zu einer homogenen Messunsicherheit innerhalb der Zellen des Moduls führt, da alle Zellströme bzw. -spannungen aus dem Gesamtstrom bzw. der Gesamtspannung abgeleitet werden. Kleinere Unterschiede ergeben sich lediglich durch die ungleiche Strom- bzw. Spannungsaufteilung der Zellen untereinander, wodurch das Sensorrauschen unterschiedlich skaliert wird, wenn Gesamtstrom bzw. -spannung durch das Batteriemodell propagiert werden.

In weiteren Versuchen wird das Sensorrauschen von Strom- und Spannungssensoren systematisch variiert. Das Messrauschen des Stromsensors nimmt eine Standardabweichung mit Werten zwischen 1 mA bis 10 A an, die Standardabweichung des Messrauschens des Spannungssensors variiert zwischen $0,1 \text{ mV}$ bis 1 V . Die aus der SDF resultierende Standardabweichung des Sensorrauschens ist in Abb. 6.17 für Strom und Spannung gezeigt, wobei diese auf das Messrauschen normiert ist. Dementsprechend sollte gemäß der analytischen Herleitung aus Kapitel 6.3.2 die normierte Standardabweichung bei ungefähr $0,29$ liegen. Betrachtet man zunächst in Abb. 6.17a die Fusion

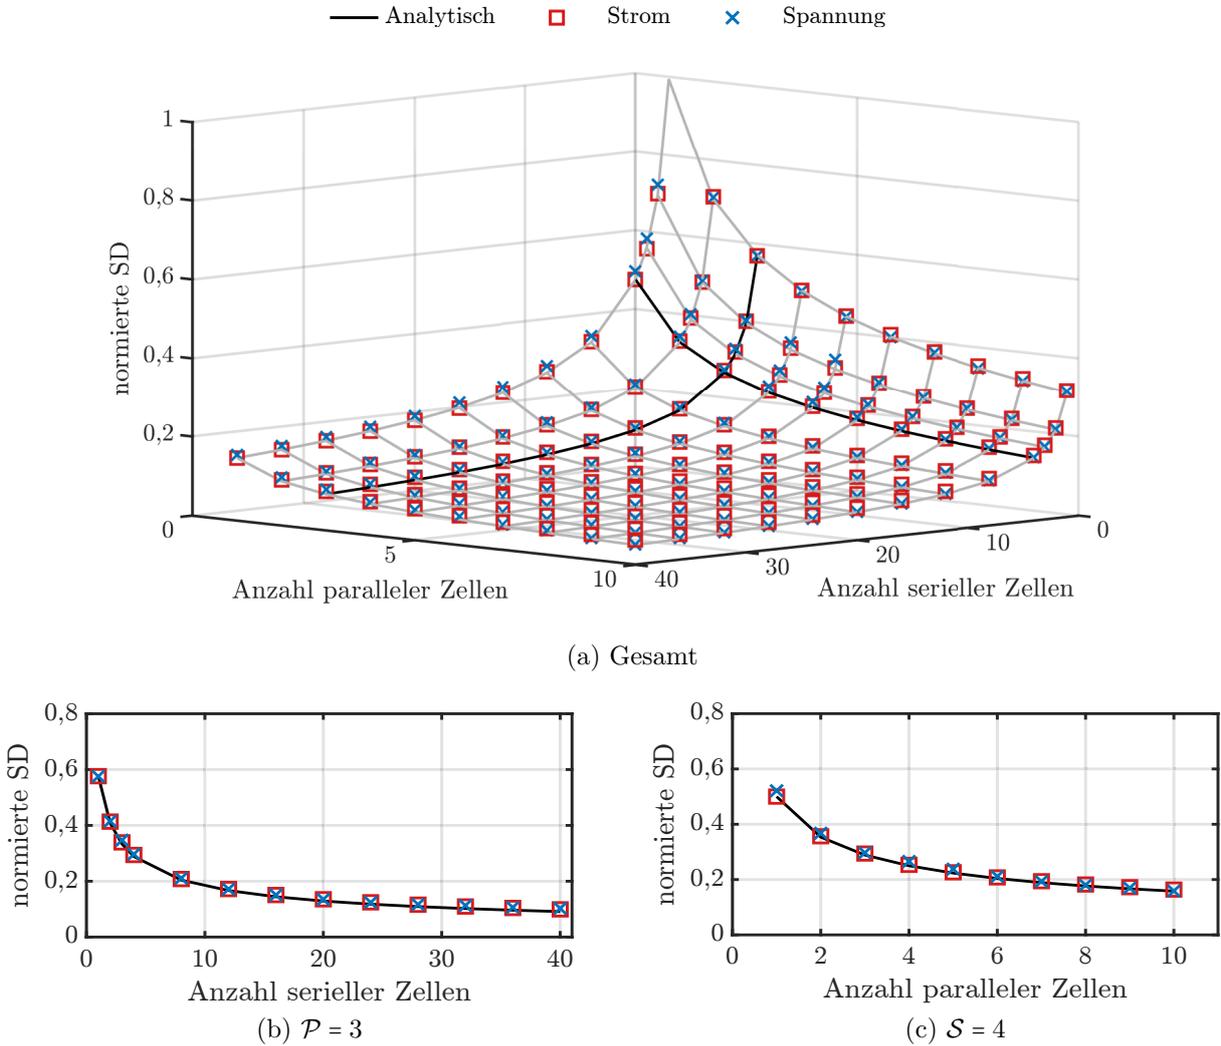


Abbildung 6.15: Analytisch hergeleitete normierte Standardabweichung (SD) und Ergebnisse der Simulation für Strom und Spannung bei Variation der Systemtopologie.

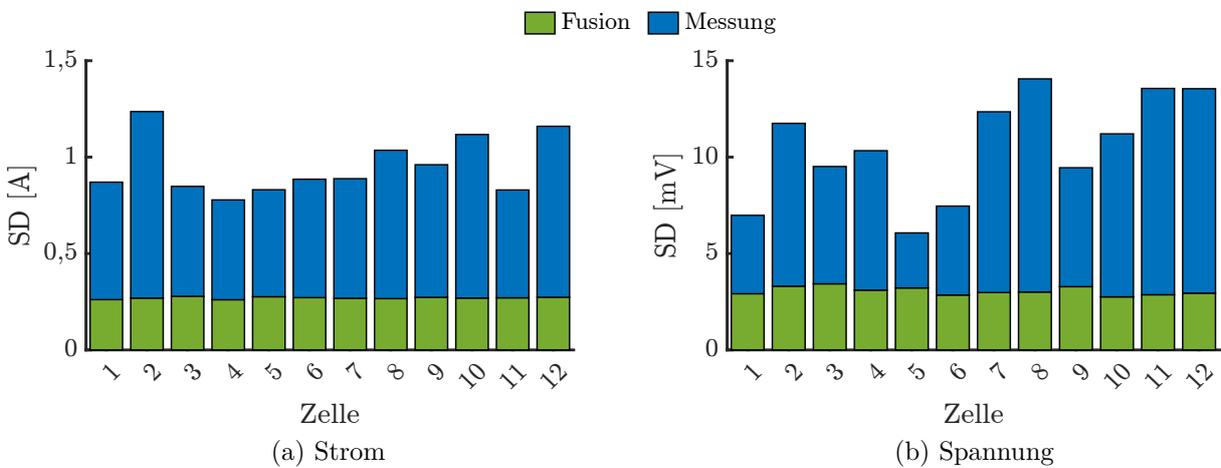


Abbildung 6.16: Standardabweichung (SD) des fusionierten Stroms bzw. der fusionierten Spannung für ein Modul mit heterogenem Sensorrauschen im Vergleich zur Standardabweichung des Sensorrauschens.

der Stromsignale, so zeigt sich, dass eine Reduktion der Messunsicherheit nur für Messrauschen des Stromsensors mit einer Standardabweichung größer 100 mA stattfindet. Ist das Sensorrauschen kleiner, steigt die normierte Standardabweichung linear an, was einer gleichbleibenden Messunsicherheit des fusionierten Stroms entspricht. Der Einfluss des Spannungssensorrauschens ist gering. Eine analoge Beobachtung lässt sich auch für die Spannungsfusion in Abb. 6.17b machen. Das Messrauschen des Stromsensors hat kaum Einfluss, wohingegen eine Reduktion der Messunsicherheit nur für eine Standardabweichung des Spannungssensors von über ungefähr 32 mV stattfindet. Liegt das Rauschlevel darunter, sinkt die Messunsicherheit der fusionierten Spannung dagegen nicht.

Begründet werden kann das beobachtete Verhalten der SDF durch das dem Verfahren inhärente Batteriemodell. Dieses hat naturgemäß eine endliche Genauigkeit, weswegen auch die Messunsicherheit der durch die SDF ermittelten Signale von Strom und Spannung nach unten beschränkt sind. Auch durch die Zustands- und Parameterschätzung ergeben sich Fehler, welche die Genauigkeit des Batteriesystemmodells limitieren. Weisen die Messwerte der Sensoren nun eine hohe Genauigkeit auf, welche unterhalb der Modellunsicherheit liegt, ist es nicht möglich, durch die SDF die Messunsicherheit noch weiter zu reduzieren. Für die Anwendung der modellbasierten SDF lässt sich daher ableiten, dass diese insbesondere dann sinnvoll ist, wenn einfache und günstige Sensoren eingesetzt werden, deren Messunsicherheit zunächst groß ist. Dann kann durch das Verfahren eine hinreichende Genauigkeit der fusionierten Signale erreicht werden. Da IBSS aufgrund des erhöhten Teileaufwands gegenüber herkömmlichen Batteriesystemen einem gewissen Entwicklungsdruck ausgesetzt sind, möglichst günstige Schalter, Sensoren, etc. zu verwenden, kommt dies dem Konzept entgegen. Es ist für die SDF ausreichend oder sogar vorteilhaft, einfache Sensoren zu verbauen. Die Anforderung an die Messunsicherheit kann dann durch die SDF erzielt werden. Alternativ kann der Versuch unternommen werden, die Modellgenauigkeit zu erhöhen, wodurch die untere Grenze des Messrauschens der Sensoren für eine sinnvolle SDF weiter nach unten verschoben werden kann.

6.3.4.5 Einfluss von Schalthandlungen

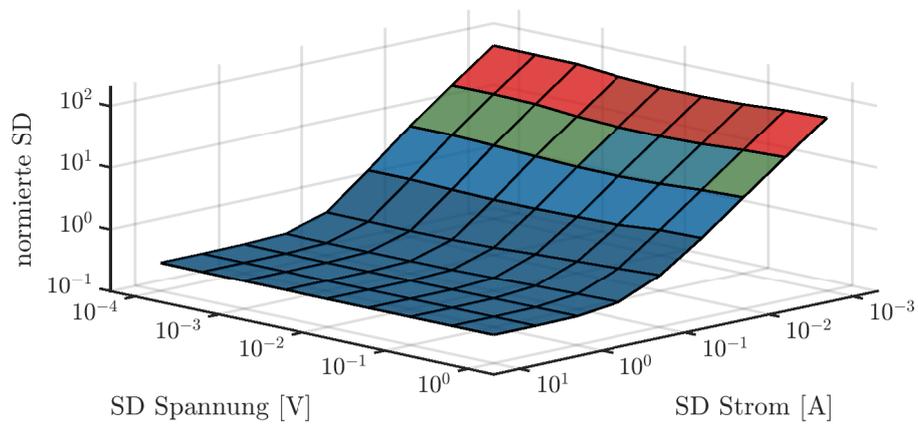
Bisher wurden zwar die Zellsensoren der intelligenten Batteriezellen für die SDF genutzt, deren Schaltfähigkeit wurde jedoch noch nicht diskutiert. Grundsätzlich wird die Datenfusion von den Schaltzuständen auf unterschiedliche Art und Weise beeinflusst:

Aktiv-Zustand

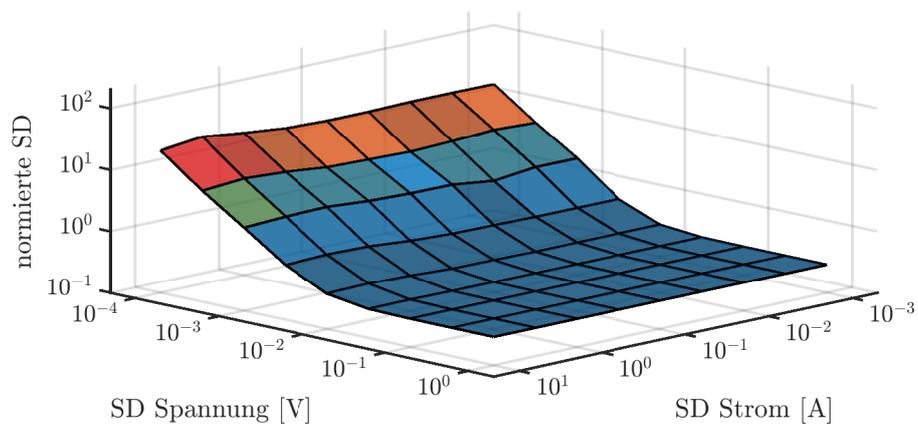
Dies ist der Normalzustand. Da Zellstrom und -spannung gemessen werden und die Zelle in das Batteriesystem eingebunden ist, können die Messwerte der Sensoren als Eingang der SDF dienen, wie es im bisherigen Verlauf dieses Kapitels beschrieben wurde.

Ruhezustand

Ist die Zelle ausgeschaltet, ist sie auch nicht mehr Teil des Batteriesystems in dem Sinne, dass kein Teil des Batterie-Gesamtstroms die Zelle durchfließt und die Zellspannung unabhängig von denen der Nachbarzellen im Parallelstrang ist. Damit folgt für die Sensormesswerte, dass diese nicht für die SDF herangezogen werden können, wodurch sich deren Performance verschlechtert. Der Zellstrom selbst kann jedoch mit hoher Sicherheit als null angenommen werden. Die Messunsicherheit ist entsprechend auf einen sehr kleinen Wert zu setzen. Für



(a) Strom



(b) Spannung

Abbildung 6.17: Normierte Standardabweichung (SD) der Sensordatenfusion abhängig von der Höhe des Sensorrauschens von Strom- und Spannungssensor.

die Zellspannung kann als Ausgang der SDF nur der Wert des Spannungssensors verwendet werden, da keine weitere Datenfusion möglich ist.

Bypass-Zustand

Der Zustand der überbrückten Zelle ähnelt dem vorherigen Fall der ausgeschalteten Zelle. Die Batterie ist nicht in das Batteriesystem eingebunden, weswegen die Messwerte nicht für die SDF herangezogen werden können. Allerdings ist auch der über den Bypass-Schalter laufende Strom unbekannt, weswegen der Messwert des Stromes ebenso wie den der Spannung nicht als Eingang für die SDF dienen kann. Allerdings ist der Zellstrom als null anzunehmen, weil die Zelle keine Anregung erfährt. Als Wert für die Zellspannung kann wiederum nur der Messwert des Spannungssensors verwendet werden.

Die bisherigen Simulationen und Experimente wurden ohne Schalthandlungen der intelligenten Batteriezellen durchgeführt. Nun soll deren Einfluss im Rahmen einer weiteren Untersuchung beleuchtet werden. Grundlage ist als Anregungsprofil der WLTP-Fahrzyklus, wobei ein Durchlauf ohne Schaltoperationen mit einem weiteren Durchlauf verglichen wird, bei dem die Zellen mit dem PWM-Muster geschaltet werden (nähere Informationen zum Schaltmuster wurden in Kapitel 5 gegeben). Die resultierenden RMSEs der fusionierten Sensorsignale aus Experiment und Simulation sind in Abb. 6.18 gezeigt. Es ist zu erkennen, dass die Stromfusion kaum von den Schaltoperationen negativ beeinflusst wird. Der RMSE bleibt nahezu unverändert (+3,8%). Hierbei profitiert der Fehlerwert des fusionierten Zellstroms insbesondere von Phasen, in welchen die betreffende Zelle ausgeschaltet ist. Aufgrund der erkannten Schalterstellung kann der Strom auf null gesetzt werden und die Messunsicherheit verschwindet. Andererseits reduziert sich während der Simulation immer zu den Zeitpunkten die Anzahl der in die SDF involvierten Zellen, in welchen Zellen aus dem System geschaltet werden. Im Resultat bleibt der Fehler des fusionierten Stroms aber auf ähnlichem Niveau.

Für die Fusion der Spannungsmesswerte zeigt sich dagegen, dass die Schalthandlungen durchaus einen negativen Einfluss auf die Genauigkeit haben. Der Grund hierfür liegt darin, dass sich zwei negative Effekte bei jedem Schaltvorgang überlagern: Zum einen reduziert sich bei der Datenfusion der Spannungen die Anzahl zu berücksichtigender Messwerte, zum anderen kann für die dann ausgeschaltete Zelle als bestmöglicher Messwert für die Spannung nur der Messwert selbst herangezogen werden. Dadurch steigt die Messunsicherheit im Vergleich zu einem Betrieb ohne Schalthandlungen im Mittel über den Simulationszeitraum an. Dass der Anstieg des RMSEs in ähnlicher Höhe im Experiment wie in der Simulation zu beobachten ist, kann als sicheres Indiz dafür gedeutet werden, dass es sich hierbei um einen systematischen Fehler handelt und keineswegs um Modellierungsfehler der Schaltvorgänge im Versuch.

6.3.5 Effiziente Implementierung durch Segmentierung der Messdaten

Die zyklische Berechnung der SDF stellt beachtliche Anforderungen an die Leistungsfähigkeit des Batteriemangement-Steuergeräts. Insbesondere der WLS-Algorithmus ist rechenaufwändig, da gemäß (6.29) eine Matrix der Dimension $\mathcal{Z} \times \mathcal{Z}$ invertiert werden muss. Gleichzeitig reduziert sich die Unsicherheit der fusionierten Strom- und Spannungswerte nur noch geringfügig mit steigender Anzahl an Zellen, wie in Abschnitt 6.3.2 analytisch und in Abschnitt 6.3.4.3 simulativ gezeigt wurde. Daher kann der Rechenaufwand der SDF reduziert werden, indem nicht die

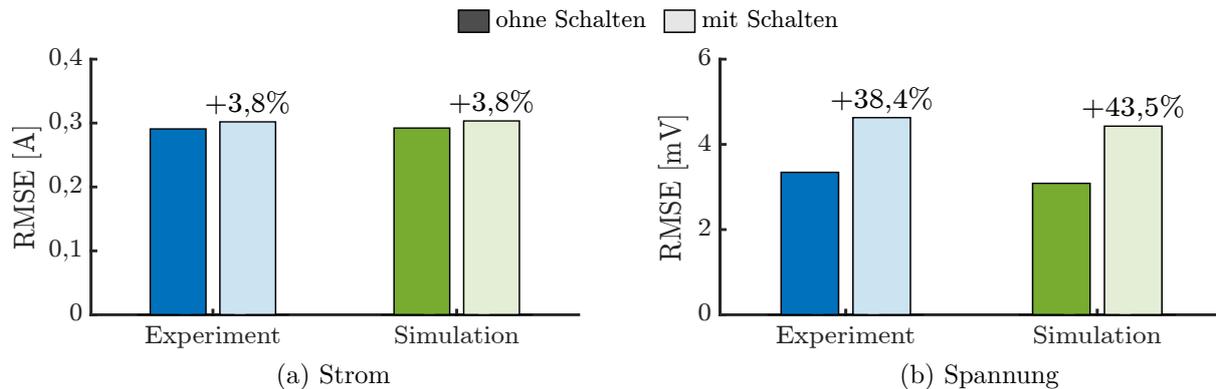


Abbildung 6.18: RMSE der Sensordatenfusion aus Experiment und Simulation jeweils mit und ohne Schalthandlungen mit dem PWM-Schaltmuster.

Messwerte aller Zellen miteinander fusioniert, sondern die Messungen in Segmenten behandelt werden. Beispielsweise können die Sensoren von jeweils zwölf benachbarten Zellen kombiniert werden, sodass entsprechend $Z/12$ parallele SDFs ausgeführt werden, deren Rechenaufwand dann bedeutend kleiner ist. Weiterhin kann durch die segmentweise Berechnung der SDF der Kommunikationsaufwand im Batteriesystem reduziert werden, wenn die Sensordaten nur noch zwischen benachbarten Zellen ausgetauscht werden müssen.

Die folgenden Untersuchungen zur Segmentierung der SDF beruhen auf Simulationen eines intelligenten Batteriesystems bestehend aus 324 Zellen in einer 108s3p-Konfiguration. Die SDF ist in einem MATLAB/Simulink-Modell implementiert, deren Simulationszeit als grober Anhaltspunkt für den Rechenaufwand der Algorithmen dient. Eine zusätzliche Optimierung der Implementierung hinsichtlich einer geringen Rechenzeit erfolgt nicht. Die Sensoren werden wie bereits in vorherigen Simulationen durch ein normalverteiltes Messrauschen nachgebildet, welches den Referenzwerten überlagert ist. Die Standardabweichung beträgt 1 A für den Stromsensor und 50 mV für den Spannungssensor. Als Zustands- und Parameterschätzer kommt ein JEKF der Ordnung $n = 4$ zum Einsatz. Dieser kann als Referenzimplementierung für eine kombinierte Zustands- und Parameterschätzung mittels Kalman-Filter gelten. Als Anregung wird ein WLTP-Stromprofil gewählt, welches eine Länge von 1800 s aufweist. Basierend auf der Anzahl an Zellen lassen sich als sinnvolle Segmentbreiten für die SDF die ganzzahligen Teiler von 324 wählen. Unter der Annahme, dass mindestens zehn Sensoren miteinander fusioniert werden sollen, ergeben sich somit als mögliche Segmentbreiten die Werte 12, 18, 27, 36, 54, 81, 108, 162 und 324, wodurch die Anzahl an parallelen SDFs zwischen 1 und 27 variiert. Die Segmentbreite von 324 entspricht der konventionellen SDF ohne Segmentierung.

Wie sich die Simulationsdauer mit steigender Segmentbreite erhöht, ist in Abb. 6.19 dargestellt. Die Rechenzeit variiert zwischen 310 s und knapp 3000 s. Die Reduktion um den Faktor 10 verdeutlicht das Potenzial der Segmentierung. Der Zusammenhang der Rechenzeit mit der Segmentbreite kann durch eine lineare Regression approximiert werden. Die Regressionsgerade ist in Abb. 6.21 ebenfalls dargestellt. Es kann demnach in erster Näherung ein linearer Zusammenhang zwischen der Segmentbreite und der daraus resultierenden Rechenzeit beobachtet werden. Dies deckt sich mit dem erwarteten Zusammenhang von Segmentbreite und Rechenzeit, weil einerseits die Komplexität des Fusionsalgorithmus quadratisch mit der Anzahl an involvierten Sensoren

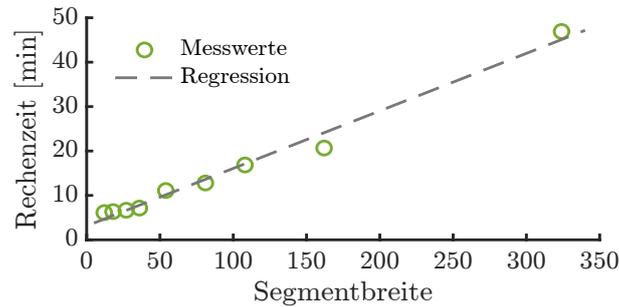


Abbildung 6.19: Rechenzeit des Modells in Abhängigkeit von der Segmentbreite der SDF.

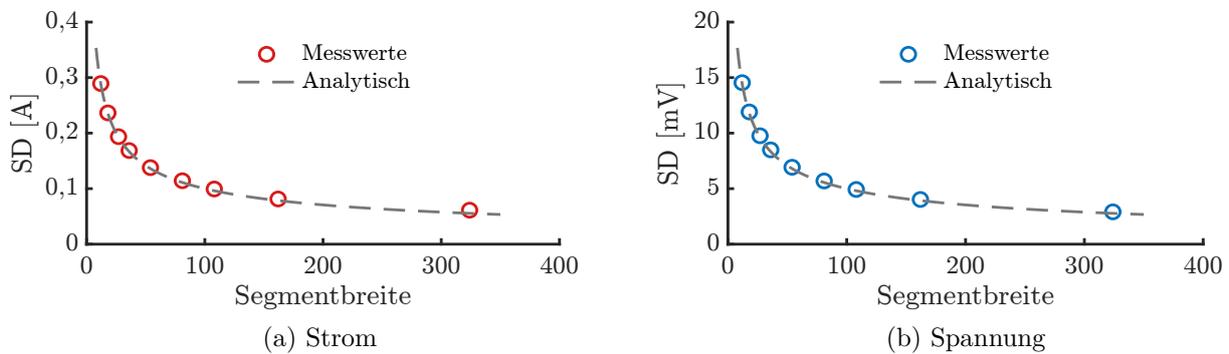


Abbildung 6.20: Standardabweichung (SD) der fusionierten Signale in Abhängigkeit von der Segmentbreite.

steigt, andererseits jedoch die Anzahl an parallel zu rechnenden Segmenten linear abnimmt. Durch Kürzen ergibt sich ein linearer Zusammenhang.

Weiterhin hat die Segmentierung der SDF Einfluss auf die Varianz der Signale, denn je weniger Sensoren miteinander korreliert werden, desto größer ist die resultierende Messunsicherheit. In Abb. 6.20 ist daher die Standardabweichung von fusioniertem Strom bzw. Spannung in Abhängigkeit von der Segmentbreite gezeigt. Neben den Messwerten ist auch die theoretisch zu erreichende Standardabweichung dargestellt, wie sie in Abschnitt 6.3.2 hergeleitet wurde. Die Ergebnisse zeigen, dass für die Strom- und Spannungsfusion die zu erwartende Messunsicherheit erreicht wird. Die Antiproportionalität der Standardabweichung zu \sqrt{Z} ist deutlich zu erkennen und die Ergebnisse sind konsistent zu Abb. 6.15.

Die beiden Ziele, zum einen eine hohe Messgenauigkeit und zum anderen eine geringe Rechenzeit zu realisieren, stehen sich konträr gegenüber. Der durch eine starke Segmentierung zu erzielende geringere Rechenaufwand impliziert gleichzeitig eine Verschlechterung im Hinblick auf den Gewinn an Genauigkeit der SDF. Für diese Art der multikriteriellen Optimierungsprobleme kann eine Pareto-Optimierung angewandt werden [322]. In Abb. 6.21 sind die beiden Optimierungsziele Rechenzeit und zu erzielende Standardabweichung auf der Abszisse und Ordinate für Strom bzw. Spannung abgebildet. In diesem zweidimensionalen Raum markieren die durchgeführten Simulationen mit unterschiedlichen Segmentbreiten einzelne Punkte, wobei diese die beiden Optimierungsziele umso besser erfüllen, je näher diese am Ursprung des Koordinatensystems liegen. Da, wie bereits festgestellt wurde, eine Verbesserung des einen Optimierungsziels eine

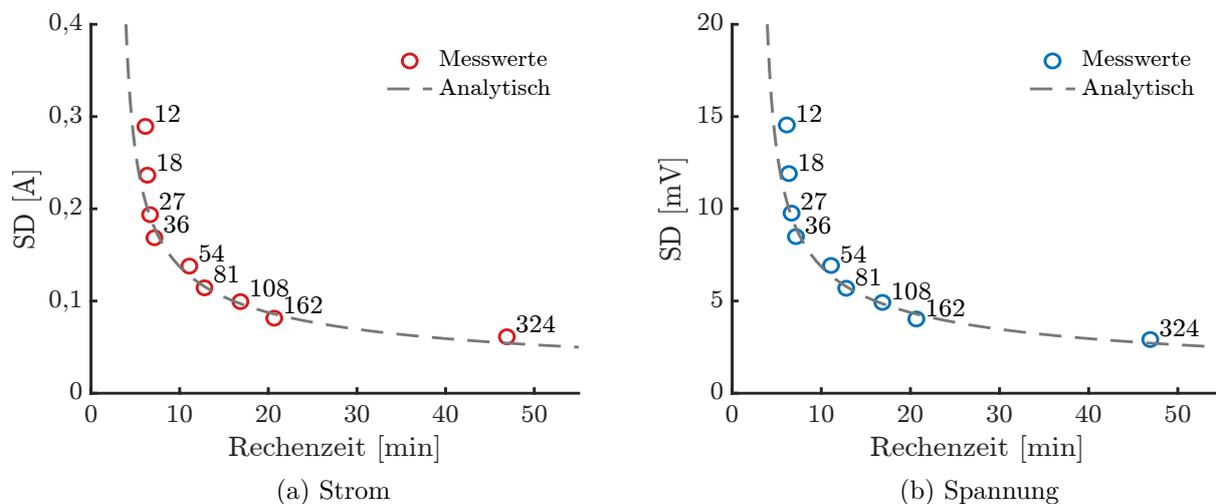


Abbildung 6.21: Pareto-Front basierend auf Rechenzeit und Standardabweichung (SD) der Sensordatenfusion. Die Zahlen geben die Segmentbreite der entsprechenden Lösung an.

Verschlechterung des anderen bedeutet, bildet sich die sogenannte Pareto-Front heraus. In Abb. 6.21 ist diese Grenzlinie angedeutet, indem basierend auf der Regressionsgerade aus Abb. 6.19 und der analytischen Reduktion der Standardabweichung ihr Verlauf bestimmt wird. Grundsätzlich heißen diejenigen Punkte *Pareto-optimal*, welche auf der Pareto-Front liegen und damit Teil der Pareto-Menge sind. Eine Verbesserung des einen Optimierungsziels impliziert dann immer eine Verschlechterung des anderen. Da die Simulationsdauer für einige Segmentbreiten unterhalb der Regressionsgerade liegt, können auch die Messwerte in Abb. 6.21a vor der analytisch berechneten Pareto-Front liegen.

Die Wahl einer optimalen Segmentbreite ergibt sich jetzt aus der Gewichtung der beiden Optimierungsziele zueinander, was einer Bewegung entlang der Pareto-Front entspricht. Ist beispielsweise die verfügbare Rechenleistung im Batteriemanager-Steuergerät begrenzt, muss die Rechenzeit höher gewichtet werden, wohingegen hohe Anforderungen an die Signalgüte zu einer stärkeren Gewichtung der resultierenden Standardabweichung führen. Die *eine*, optimale Lösung für das Problem existiert nicht. Die Pareto-Optimierung zeigt jedoch, dass eine Segmentierung der SDF ein großes Potenzial aufweist und der Verzicht auf diese einen Extremfall innerhalb der Pareto-Menge darstellt. Eine Optimierung des Rechenaufwands lässt sich jedoch bei der Implementierung der Funktion auf der Zielhardware auch auf weiteren Wegen, beispielsweise durch Parallelisierung, erreichen, sodass die Wahl einer optimalen Segmentbreite an dieser Stelle nicht endgültig getroffen werden kann.

6.4 Methode zur adaptiven Varianzschätzung des Sensorrauschens

Die im vorangegangenen Abschnitt vorgestellte modellbasierte Sensordatenfusion setzt Wissen über die Stärke des Sensorrauschens der Strom- bzw. Spannungssensoren voraus. Nur wenn die Gewichtungsmatrix \mathbf{W} im WLS-Schritt korrekt mit den Kehrwerten der Varianzen des Sensorrauschens aller Sensoren belegt ist, kann ein optimaler Schätzwert für Gesamtstrom bzw. -spannung

gefunden werden. Andernfalls wird das Rauschen eines schlechten Sensors möglicherweise zu stark gewichtet und beeinflusst den fusionierten Wert in unzulässiger Weise. Weiterhin kann basierend auf dem Wissen der Sensorvarianzen auch die Unsicherheit für die fusionierten Strom- und Spannungswerte abgeschätzt werden. Da diese beispielsweise als Eingangssignale für die Kalman-Filter zur Zustands- und Parameterschätzung dienen, verbessert dies die Leistung der gesamten Sensordatenfusion. In diesem Abschnitt wird deshalb ein Verfahren vorgestellt, wie die Varianz des Sensorrauschens adaptiv geschätzt werden kann. Damit können auch Änderungen der Charakteristik der Sensoren z. B. abhängig von der Temperatur oder Alterung Rechnung getragen werden. Wie im weiteren Verlauf gezeigt wird, ist die Sensordatenfusion selbst Grundlage des Verfahrens zur Varianzschätzung. Daher eignet sich die Methode gut, um in Kombination mit dieser eingesetzt zu werden.

6.4.1 Stand der Wissenschaft

Im Bereich der Signalfilterung ist die Varianzschätzung eine wichtige Forschungsfrage, da Messdaten üblicherweise immer von Sensorrauschen überlagert sind. Beispielhaft kann die Bestimmung der Messkovarianz-Matrix von Kalman-Filtern genannt werden. Abhängig vom spezifischen Anwendungsfall existiert eine Vielzahl an Lösungen [224, 233, 323, 324].

Allgemein ist ein Sensorsignal y von einem normalverteilten Messrauschen $r = \mathcal{N}(0, R_k)$ überlagert. Für das gemessene Signal \tilde{y} gilt zu jedem Zeitpunkt k

$$\tilde{y}_k = y_k + r_k. \quad (6.52)$$

Das Ziel der Varianzschätzung ist die Bestimmung von R_k , wobei angenommen wird, dass sich die Charakteristik des Sensorrauschens mit der Zeit ändern kann. Daher muss eine Methode zur Bestimmung der Varianz adaptiv sein. Weiterhin ist es für die Online-Anwendung erforderlich, dass es sich um einen rekursiven Algorithmus handelt, der die Varianzschätzung beim Eintreffen neuer Messwerte aktualisiert. Eine Speicherung alter Messdaten ist dann nicht erforderlich.

Zwei verbreitete Standardmethoden der Varianzschätzung werden im Folgenden näher diskutiert und dienen im weiteren Verlauf des Kapitels als Benchmark für die hier neu vorgestellte Methode. Allgemein bezeichnet die Varianz die mittlere quadratische Abweichung eines Signals y von ihrem Mittelwert \bar{y} [325, S. 57].

$$\hat{R} = \frac{1}{K} \cdot \sum_{k=1}^K (y_k - \bar{y})^2 \quad (6.53)$$

Im hier diskutierten Fall soll die Varianz des Messrauschens r bestimmt werden. Da aus (6.52) $r_k = \tilde{y}_k - y_k$ folgt, kann durch Einsetzen in (6.53) gezeigt werden, dass

$$R = \frac{1}{K} \cdot \sum_{k=1}^K (r_k - \bar{r})^2 \quad (6.54a)$$

$$= \frac{1}{K} \cdot \sum_{k=1}^K ((\tilde{y}_k - y_k) - \overline{\tilde{y}_k - y_k})^2 \quad (6.54b)$$

$$= \frac{1}{K} \cdot \sum_{k=1}^K (\tilde{y}_k - y_k - \bar{\tilde{y}}_k + \bar{y}_k)^2 \quad (6.54c)$$

$$= \frac{1}{K} \cdot \sum_{k=1}^K (\tilde{y}_k - y_k)^2 \quad (6.54d)$$

$$\approx \frac{1}{K} \cdot \sum_{k=1}^K (\tilde{y}_k - \bar{y}_k)^2. \quad (6.54e)$$

Die Varianz des Sensorrauschens entspricht also der Varianz des Messsignals, wenn als Schätzwert für das Referenzsignal y_k , dessen Mittelwert verwendet wird. Deshalb wird diese Art der Varianzschätzung im Folgenden als Mittelwert-basierte (MWB) Varianzschätzung bezeichnet.

Es existieren verschiedenste Implementierungen für rekursive Algorithmen zur MWB Varianzschätzung, die auf hohe numerische Stabilität ausgelegt sind (siehe beispielsweise [326–329]). Dies ist insbesondere wichtig, wenn das Rauschen im Vergleich zum Nutzsignal klein ist [329]. Bekannt ist der Welfordsche Online-Algorithmus [326], auf welchem die folgende Implementierung beruht (siehe Algorithmus 6.3). Die Differenz zwischen Mess- und Referenzsignal wird hierbei gebildet, indem vom Messsignal zum Zeitpunkt k der gleitende Mittelwert abgezogen wird. Unter der Annahme eines erwartungstreuen Rauschens heben sich positive und negative Fehler auf. Hierbei ist auf eine geeignete Fensterlänge M zu achten, über welche die Mittelwertbildung durchgeführt werden soll. Der gleitende Mittelwert kann auch als Tiefpassfilter angesehen werden, durch welchen die hochfrequenten Rauschanteile vom Nutzsignal getrennt werden. Naturgemäß tritt dabei eine Phasenverschiebung auf. Das Verfahren wird beispielsweise von Rogers [330] zur Fehlerdiagnose von Sensoren verwendet.

Um die Schätzung adaptiv zu halten, wird ein Vergessensfaktor λ eingeführt, wodurch einerseits eine Glättung der geschätzten Varianz erreicht wird, andererseits alte Schätzwerte mit exponentiell abnehmender Gewichtung zur Bestimmung des aktuellen Schätzwerts Berücksichtigung finden. Wenn nicht anders angegeben, wird im weiteren Verlauf $\lambda = 0,995$ gewählt.

Algorithmus 6.3 Varianzschätzung mit exponentiellem Vergessen basierend auf Tiefpass-Filterung

- 1: $\lambda = 0.9 \dots 0.999$
 - 2: $\hat{R}_0^2 = 0$
 - 3: **for** $k = (M - 1) \dots K$ **do**
 - 4: $\bar{y}_k = \frac{1}{M} \cdot \sum_{i=0}^{M-1} \tilde{y}_{k-i}$
 - 5: $\hat{R}_k = \lambda \hat{R}_{k-1} + (1 - \lambda) \cdot (y_k - \bar{y}_k)^2$
 - 6: **end for**
-

Einen anderen Ansatz verfolgt die Differenz-basierte (DB) Schätzung der Varianz, bei der die Streuung des Sensorrauschens basierend auf der Differenz aufeinanderfolgender Messwerte bestimmt wird. Das Verfahren wurde von Neumann [331] sowie Rice [332] vorgeschlagen und in weiteren Veröffentlichungen untersucht bzw. auf höhere Ordnungen erweitert (z. B. [333–336]). Die Grundannahme des Verfahrens ist, dass das Quadrat der Differenz aufeinanderfolgender Messwerte im Mittel der doppelten Varianz entspricht und diese dadurch abgeschätzt werden kann zu

$$\hat{R} = \frac{1}{2(K-1)} \cdot \sum_{k=2}^K (\tilde{y}_k - \tilde{y}_{k-1})^2. \quad (6.55)$$

Der Vorteil dieses Ansatzes ist, dass kein Schätzwert für das Referenzsignal benötigt wird, wie es beim MWB Verfahren durch die Mittelwertbildung der Fall ist. Obwohl Dette et al. [335] und Dai et al. [336] zeigen, dass DB Schätzverfahren dann nicht die gleiche Genauigkeit erreichen können, ergibt sich dessen praktische Relevanz aus dem geringen Rechenaufwand und in der Anwendung geringer Schätzfehler [335]. Eine rekursive Implementierung der DB Varianzschätzung erster Ordnung ist in Algorithmus 6.4 gezeigt. Im Folgenden wird ein Vergessensfaktor $\lambda = 0,996$ gewählt.

Algorithmus 6.4 DB Varianzschätzung mit exponentiellem Vergessen

```

1:  $\lambda = 0.9 \dots 0.999$ 
2:  $\hat{R}_0 = 0$ 
3: for  $k = 2 \dots K$  do
4:    $\hat{R}_k = \lambda \hat{R}_{k-1} + \frac{(1-\lambda)}{2} \cdot (\tilde{y}_k - \tilde{y}_{k-1})^2$ 
5: end for

```

6.4.2 Varianzschätzung basierend auf der Sensordatenfusion

Die Ermittlung eines Schätzwerts für das Referenzsignal durch Mittelwertbildung, wie im Abschnitt 6.4.1 vorgestellt, ist hinsichtlich des zusätzlichen Rechenaufwands nachteilig. Darüber hinaus ist bei einem hochdynamischen Nutzsignal ein Schätzfehler zu erwarten, wenn starke Signaländerungen die Differenz zwischen Mittelwert und wahren Wert ansteigen lassen. Die hier vorgestellte Varianzschätzung basiert auf der SDF und greift als Schätzwert für das Referenzsignal auf den fusionierten Wert anstelle des gefilterten Wertes zurück.

$$\hat{R} = \frac{1}{K} \cdot \sum_{k=1}^K (\tilde{y}_k - \bar{y}_k)^2 \quad (6.56)$$

Es ist zu beachten, dass der Querstrich in (6.56) den fusionierten Messwert anstelle des Mittelwerts kennzeichnet. Entsprechend lässt sich die SDF Varianzschätzung in rekursiver Form mit Vergessensfaktor angeben, wie in Algorithmus 6.5 gezeigt. Im Vergleich zum MWB Verfahren fällt ein Berechnungsschritt weg, sodass der Algorithmus mit geringem Rechenaufwand implementiert werden kann.

Im besten Fall reduziert sich die Varianz des Messrauschens der fusionierten Signale um den Faktor \mathcal{Z} , welcher der Anzahl der involvierten intelligenten Batteriezellen entspricht. Dies wurde in Abschnitt 6.3.2 des vorherigen Kapitels gezeigt. Daraus folgt jedoch, dass der als

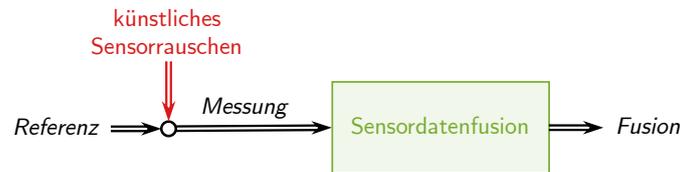


Abbildung 6.22: Signalfluss der Versuche zur Validierung der adaptiven Varianzschätzung und Benennung der Signale.

Schätzwert für das Referenzsignal angenommene Messwert selbst noch mit einem Rauschen der Varianz $\bar{R} = R/\mathcal{Z}$ gestört ist. Dementsprechend wird die Varianz des Messsignals systematisch unterschätzt, weswegen ein Bessel-Korrekturfaktor β wie folgt verwendet wird:

$$\beta = \frac{\mathcal{Z}}{\mathcal{Z} - 1}. \quad (6.57)$$

Zu beachten ist, dass es sich bei \mathcal{Z} nicht um die Länge der Messreihe (Fensterlänge) handelt, sondern um die Anzahl an Sensoren, die an der SDF beteiligt sind.

Algorithmus 6.5 SDF Varianzschätzung mit exponentiellem Vergessen

- 1: $\lambda = 0.9 \dots 0.999$
 - 2: $\hat{R}_0^2 = 0$
 - 3: **for** $k = 1 \dots K$ **do**
 - 4: $\hat{R}_k = \lambda \hat{R}_{k-1} + \beta(1 - \lambda) \cdot (\tilde{y}_k - \bar{y}_k)^2$
 - 5: **end for**
-

Beim Start der Sensordatenfusion kann es durch die Varianzschätzung zu Instabilitäten kommen, wenn die Gewichtung der Messwerte basierend auf der Varianzschätzung vorgenommen wird. Diese enthält wiederum noch keine verlässlichen fusionierten Signale aus der Sensordatenfusion. Um dieses Problem zu umgehen, werden die Ergebnisse der Varianzschätzung erst nach zehn Zyklen für die Gewichtung der Messwerte herangezogen.

6.4.3 Vergleich des Verfahrens mit herkömmlichen Methoden

Um zu untersuchen, wie performant die SDF-Varianzschätzung im Vergleich zu den beiden vorgestellten herkömmlichen Ansätzen ist, werden Versuche basierend auf experimentellen Messdaten durchgeführt. Ein intelligentes Batteriesystem wird mit einem WLTP-Stromprofil beaufschlagt und die individuellen Ströme und Spannungen der Batteriezellen gemessen. Diese mit hoher Präzision gemessenen Zellströme gelten im Folgenden als *Referenz* für den Versuch. Um die Varianzschätzung bewerten zu können, werden diese Referenzwerte mit künstlichem Rauschen überlagert, dessen Charakteristik bekannt ist. Es handelt sich um ein normalverteiltes und mittelwertfreies Rauschsignal mit bekannter Varianz. Das resultierende Signal wird als *Messung* angesehen, dessen Varianz geschätzt werden soll. Gleichzeitig findet es auch Eingang in die Sensordatenfusion, woraus schließlich die als *Fusion* bezeichneten Messungen resultieren. Der beschriebene Signalfluss des Versuchs ist in Abb. 6.22 verdeutlicht.

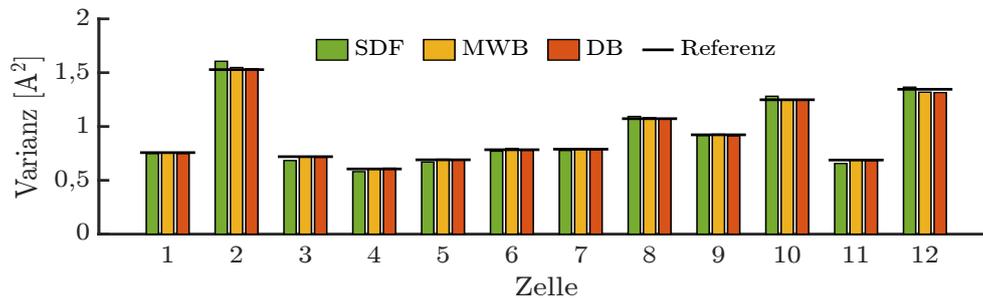


Abbildung 6.23: Tatsächliche und geschätzte Varianz des Sensorrauschens der individuellen Zellen für die drei Schätzverfahren.

Zunächst wird ein Szenario betrachtet, bei dem das Sensorrauschen innerhalb der zwölf Stromsensoren schwankt. Die Varianz des Messrauschens ist normalverteilt mit $\mu = 1,0 \text{ A}$ und $\sigma = 200 \text{ mA}$. Alle drei vorgestellten Verfahren (SDF, MWB und DB) werden angewendet, um die Varianz des Sensorrauschens zu bestimmen. Die Ergebnisse sind in Abb. 6.23 dargestellt. Es ist augenscheinlich, dass alle drei Verfahren die Varianz mit hoher Genauigkeit schätzen. Der Fehler beträgt im Mittel 2,7% für die SDF, 0,7% für die MWB und 0,8% für die DB Varianzschätzung. Auffällig ist hierbei, dass die SDF-Methode die Varianzen überschätzt, wenn diese groß sind, wohingegen kleine Varianzen unterschätzt werden. Dies ist darauf zurückzuführen, dass die Verringerung des Sensorrauschens durch die Sensordatenfusion nicht für jeden Sensor gleich groß ist: Sensoren mit hohem Sensorrauschen profitieren überproportional stark von der Fusion mit den anderen Sensoren, wohingegen die Verringerung des Rauschlevels geringer ist, wenn die Sensoren bereits wenig rauschen. Dementsprechend ist aber der Referenzwert für die SDF Varianzschätzung für diejenigen Zellen selbst stärker verrauscht, welche selbst wenig rauschen, wodurch die Varianz des Sensorrauschens unterschätzt wird. In anderen Worten ist die Bessel-Korrektur aus Abschnitt 6.4.2 nur dann exakt, wenn alle Sensoren das gleiche Rauschlevel aufweisen. Letzteres ist in der Anwendung zumindest in erster Näherung meist der Fall.

In einem weiteren Versuch wird das Sensorrauschen nicht konstant gehalten, sondern ausgehend von einer Varianz von $1,0 \text{ A}^2$ linear über einen Zeitraum von 1200s auf $9,0 \text{ A}^2$ erhöht. Eine Vergrößerung des Sensorrauschens kann beispielsweise auftreten, wenn die Umgebungstemperatur ansteigt, welcher der Sensor ausgesetzt ist. Die Schätzergebnisse sind in Abb. 6.24 zu sehen, wobei die Ordinate logarithmisch skaliert ist. Dass innerhalb dieser Skalierung der Schätzfehler über den Verlauf des Experiments ungefähr gleich groß bleibt, zeigt: Die Unsicherheit der Schätzung schwankt im Verhältnis zur zu schätzenden Varianz selbst. Die Ursache hierfür liegt darin begründet, dass die der Schätzung zugrunde liegenden Differenzen normalverteilt sind und diese zum Quadrat genommen werden. Damit weisen die Schätzfehler eine Chi-Quadrat-Verteilung auf. Um diesem Umstand Rechnung zu tragen, wird die Schätzgüte im Folgenden mit dem Root-Mean-Squared-Relative-Error (RMSRE) gemäß

$$\text{RMSRE} = \sqrt{\frac{1}{K} \cdot \sum_{k=1}^K \left(\frac{R_k - \hat{R}_k}{R_k} \right)^2} \quad (6.58)$$

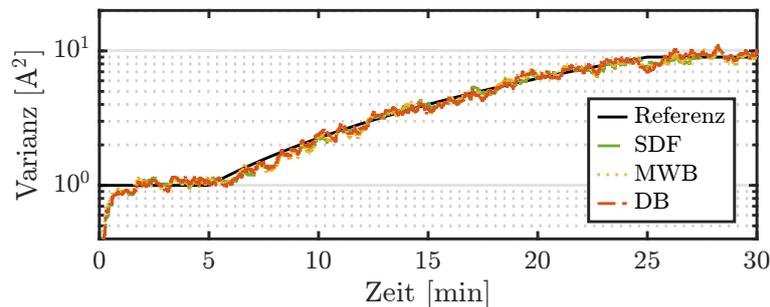


Abbildung 6.24: Tatsächliche und geschätzte Varianz des Sensorrauschens für eine Zelle mit ansteigendem Rauschlevel.

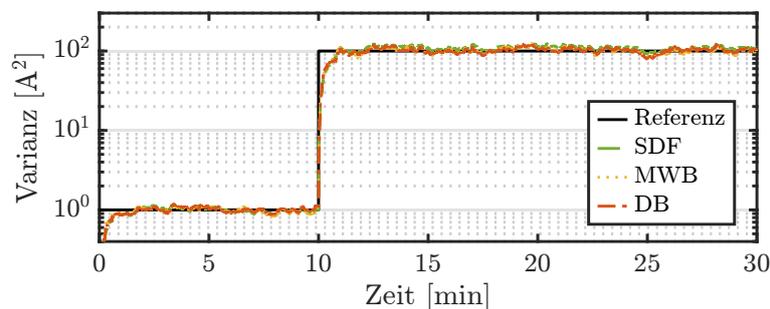


Abbildung 6.25: Tatsächliche und geschätzte Varianz des Sensorrauschens für eine Zelle mit plötzlich steigendem Rauschlevel.

bewertet, welcher die Fehler in Bezug zum Referenzwert setzt. Gemittelt über alle zwölf Zellen ergibt sich ein RMSRE von 11,1 % für die SDF, 10,8 % für die MWB und 11,6 % für die DB Varianzschätzung. Das neu vorgestellte Verfahren liegt demnach erneut auf vergleichbarem Niveau mit den herkömmlichen Ansätzen.

Schließlich wird ein letztes Szenario untersucht, bei dem die Varianz eines Zellsensors unvermittelt um den Faktor 100 ansteigt. Dieses Verhalten kann beispielsweise bei einem Sensordefekt auftreten und soll von der adaptiven Varianzschätzung detektiert werden. In Abb. 6.25 sind die Ergebnisse für den entsprechenden Stromsensor aufgetragen. Erneut ist der Unterschied zwischen den einzelnen Verfahren sehr gering. Der RMSRE der SDF beträgt 11,0 % und ist damit nur geringfügig höher als für die MWB Varianzschätzung mit einem RMSRE von 10,9 %. Auch die DB Varianzschätzung ist mit 11,5 % nicht signifikant ungenauer.

6.4.4 Optimierung der Adaptivität

Die Wahl des Vergessensfaktors hat einen großen Einfluss auf den resultierenden Schätzfehler. Je kleiner λ gewählt wird, desto schneller kann eine sich verändernde Varianz des Sensorrauschens adaptiert werden. Allerdings wird dies mit einer stärkeren Schwankung des Schätzwertes erkaufte. Für die Bestimmung eines optimalen Vergessensfaktors für die SDF-Varianzschätzung wird λ in einem Intervall von 0,990 bis 0,999 variiert und die sich daraus ergebenden Schätzungen verglichen. Betrachtet werden dabei die bereits im vorherigen Abschnitt diskutierten Szenarien von (a) konstantem und normalverteiltem Sensorrauschen, (b) einer linear ansteigenden Varianz

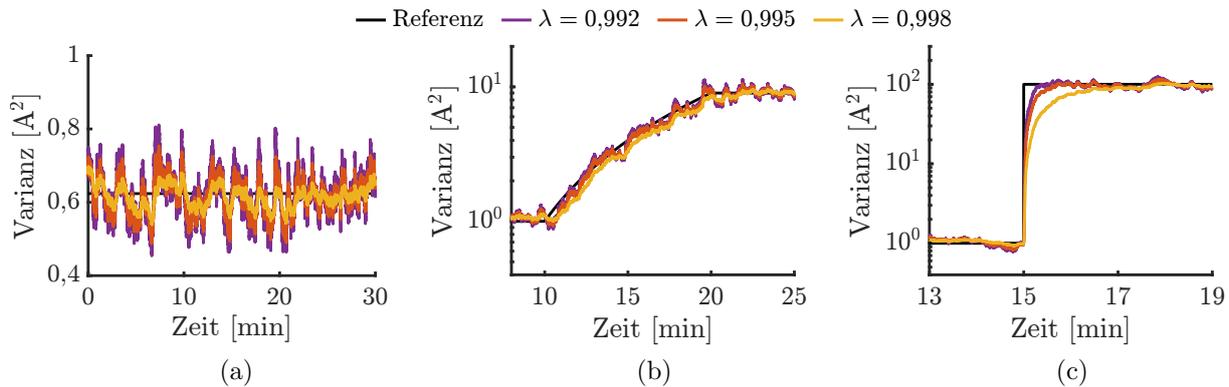


Abbildung 6.26: Einfluss des Vergessensfaktors auf die Varianzschätzung für (a) normalverteiltes Rauschen, (b) linear ansteigendes und (c) sprungförmig ansteigendes Rauschlevel.

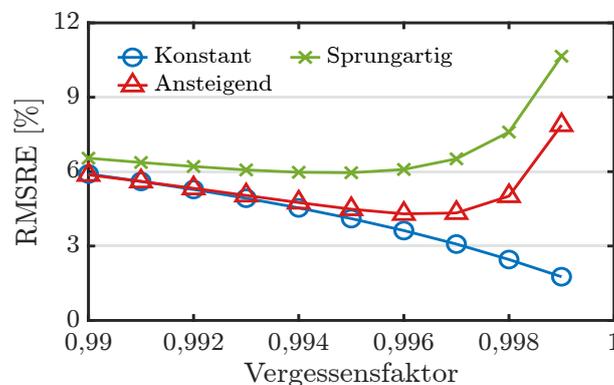


Abbildung 6.27: Fehler der Varianzschätzung bei normalverteiltem Rauschen für unterschiedliche Werte des Vergessensfaktors.

und (c) dem sprungförmigen Anstieg der Varianz eines Sensors. Die relevanten Zeitausschnitte sind in Abb. 6.26 für drei unterschiedliche Größen von λ dargestellt. Es ist zu erkennen, wie ein hoher Vergessensfaktor die Schätzung glättet, wobei gleichzeitig eine Phasenverschiebung auftritt, was insbesondere beim sprungförmigen Anstieg der Rauschvarianz zu einer deutlichen Verzögerung in der Schätzung führt.

In Abb. 6.27 ist der RMSRE für die drei untersuchten Szenarien über den Vergessensfaktor aufgetragen. Am globalen Minimum der Kurve zeigt die Abszisse das optimale λ für das betrachtete Szenario. Erwartungsgemäß sinkt der Schätzfehler für konstantes Messrauschen mit steigendem Vergessensfaktor, da keine Adaptivität notwendig ist. Anders liegt der Fall, wenn sich die Varianz verändert. Für das sprungförmig ansteigende Messrauschen ist $\lambda = 0,995$ optimal, wohingegen für den linearen Anstieg ein Vergessensfaktor von 0,996 eine ideale Wahl ist. Bei der hier aufgezeigten Abhängigkeit der Schätzfehler vom Vergessensfaktor handelt es sich um eine Best-Case-Abschätzung, da die Veränderung der Charakteristik des Sensorrauschens im Vorhinein nicht bekannt sein kann. Die Untersuchung beantwortet daher lediglich die Frage, welche Schätzgüte sich mit einem idealen Vergessensfaktor erreichen ließe. Für diese Kapitel wird $\lambda = 0,996$ gewählt.

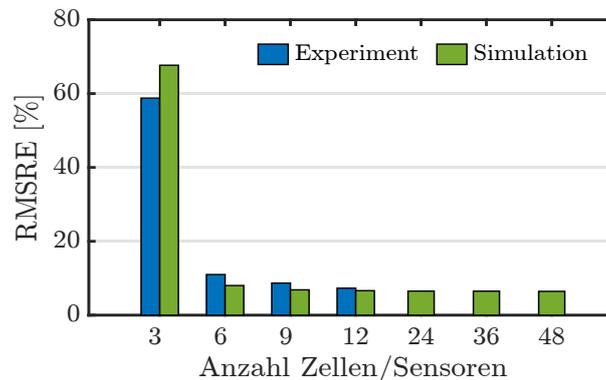


Abbildung 6.28: Fehler der Varianzschätzung abhängig von der Anzahl an in die Sensordatenfusion involvierten intelligenten Batteriezellen. Experimentelle Ergebnisse stehen nur bis zu einer Anzahl von zwölf Zellen zur Verfügung.

6.4.5 Einfluss der Anzahl an Zellen/Sensoren

Da die Performanz der Sensordatenfusion von der Anzahl an involvierten Sensoren bzw. intelligenten Batteriezellen abhängt, trifft dies auch auf die Varianzschätzung zu, denn je geringer das Rauschen der fusionierten Signale ist, desto besser eignen sich diese als Referenzwert für die Bestimmung der Varianz. Um den Zusammenhang des Schätzfehlers mit der Anzahl an Zellen zu untersuchen, wird in den folgenden Untersuchungen die Anzahl serieller Stränge variiert. Die Zahl der Zellen im Parallelstrang bleibt dagegen mit $\mathcal{P} = 3$ konstant. Für Systeme mit bis zu zwölf Zellen können die experimentellen Daten der Validierungsversuche verwendet werden. Abhängig von der gewünschten Anzahl an Zellen für den Versuchsdurchlauf werden die Messdaten der restlichen Stromsensoren verworfen. Um auch eine Aussage für größere Batteriesysteme zu treffen, werden darüber hinaus auch Simulationen durchgeführt, bei welchen die Anzahl an intelligenten Batteriezellen beliebig groß werden kann. Die Übereinstimmung von experimentellen und simulativen Ergebnissen zeigt, dass die Simulationen zur Validierung herangezogen werden können.

In Abb. 6.28 sind die RMSREs abhängig von der Zellanzahl aufgetragen. Zunächst ist ersichtlich, dass bereits bei der Fusion von sechs Sensoren ein RMSRE von unter 10% erreicht werden kann. Mit drei Sensoren kann dieses Ergebnis noch nicht erreicht werden. Es zeigt sich weiterhin, dass sich der Schätzfehler nur noch in geringem Maße reduzieren lässt, wenn mehr und mehr zusätzliche Sensorsignale für die Varianzschätzung herangezogen werden. Der RMSRE bleibt in einem Bereich von 6% bis 7%, auch wenn mehr als 24 intelligente Batteriezellen zur Varianzschätzung einbezogen werden. Eine gewisse Schätzunsicherheit lässt sich demnach nicht beseitigen, indem die Zahl an Sensoren beliebig erhöht wird. Die Ergebnisse der Untersuchung führen zu der Direktive, dass die adaptive Varianzschätzung nur für Systeme mit mehr als vier Batteriezellen angewandt werden sollte. Für kleinere Systeme wird auf Nominalwerte zurückgegriffen.

6.5 Zusammenfassung der Ergebnisse zur Sensordatenfusion

Intelligente Batteriesysteme zeichnen sich durch eine hohe Redundanz der Sensoren aus. Die Messung von Zellströmen und -spannungen geschieht zwar verteilt im Batteriesystem, dennoch sind die Signale miteinander korreliert. Dieser Eigenschaft folgend wurde ein modellbasiertes Verfahren zur SDF in diesem Kapitel vorgestellt und untersucht. Durch analytische Abschätzungen wurde gezeigt, dass die SDF zwei wichtige Ziele erfüllt. Zum einen verringert sich durch die Redundanz der Messwerte die Messunsicherheit und das Messrauschen. Zum anderen kann die Ausfallwahrscheinlichkeit des Sensorsystems reduziert werden, indem fehlerhafte Sensormesswerte beispielsweise aufgrund von Defekten durch die verbleibenden Sensoren kompensiert werden können. Das vorgestellte Verfahren wurde in realen Experimenten auf seine Leistungsfähigkeit hin geprüft. Weitere Untersuchungen und Simulationen zeigen den Vorteil der modellbasierten SDF gegenüber anderen Verfahren insbesondere für den Fall einer hohen Zellparameterstreuung, wie sie am Ende der Lebensdauer von Batterien auftreten kann. Schließlich wurde auch der Einfluss von Schalthandlungen von RBSs auf die SDF untersucht.

Angesichts der heutzutage schon mit geringem Aufwand realisierbaren Genauigkeit der Zellspannungsmessung erscheint für diese eine SDF weniger sinnvoll. Die Fusion der Stromsensoren ist vielversprechender, da der Einsatz von Zellsensoren für diese Domäne mit einem hohen Kostendruck verbunden ist. Sinnvoll ist die modellbasierte SDF nur einzusetzen, wenn das Batteriesystem eine Topologie mit $\mathcal{P} > 1$ aufweist. Es zeigt sich, dass die Fusion aller Sensoren nicht die optimale Lösung ist, sondern vielmehr durch Segmentierung ein Kompromiss aus Rechenaufwand, Messgenauigkeit, Zuverlässigkeit und Kommunikationsaufwand gefunden werden kann.

Die Gewichtung der Messwerte der einzelnen Sensoren wird über die Messunsicherheit der entsprechenden Signale vorgenommen. Daher wurde ein Verfahren zur Bestimmung der Varianzen des Sensorrauschens entwickelt, mit dem diese Gewichte dann adaptiv bestimmt werden können. Damit arbeitet die modellbasierte SDF auch dann genau, wenn sich die Charakteristik der Sensoren verändert. Wie gezeigt werden kann, sind schon wenige Sensoren ausreichend, um eine Varianzschätzung mit einem RMSRE von unter 10% zu realisieren. Damit ist das Verfahren konkurrenzfähig zu herkömmlichen Ansätzen zur Varianzschätzung, mit denen es verglichen wurde.

7 Zusammenfassung und Ausblick

In dieser Arbeit wurden Verfahren zur modellbasierten Zustands- und Parameterschätzung im Batteriemanagementsystem von Batterie-elektrischen Fahrzeugen untersucht. Die Bestimmung des Ladezustands sowie weiterer Parameter der Batteriezelle mittels Schätzverfahren und damit die Bestimmung eines adaptiven Modells ist von großer Wichtigkeit für die Batterieüberwachung, da die ermittelten Modellparameter Basis weiterer Funktionen des Batteriesteuergeräts sind. Grundlage der Arbeit bildet ein Ersatzschaltbildmodell der Lithium-Ionen-Zelle, welches durch Charakterisierungstests parametrisiert wurde. Die sich ergebenden Modellfehler von unter 12 mV für einen SOC-Bereich von 20 % bis 100 % zeigen eine gute Modellgenauigkeit, begrenzen gleichzeitig jedoch die Leistungsfähigkeit der auf dem Modell beruhenden Schätzverfahren.

Als Werkzeug für die Zustands- und Parameterschätzung in Lithium-Ionen-Zellen sind Kalman-Filter weit verbreitet und wurden auch in dieser Arbeit für diese Aufgabe gewählt. In der Literatur existieren zahlreiche Varianten und Modifikationen dieses Filter für die gestellte Aufgabe, von denen einige untersucht wurden. Fokus war hierbei der Einsatz in intelligenten Batteriesystemen mit ihren Charakteristika. Notwendige Bedingung für eine erfolgreiche Zustands- und Parameterschätzung ist immer eine ausreichende Systemanregung. Bei der Validierung von Ladezustandsschätzverfahren in der Literatur wird dies häufig vorausgesetzt und durch den Einsatz dynamischer Stromprofile sichergestellt. In der realen Anwendung können jedoch auch Fahrsituation mit geringer Anregung auftreten. Um den Einfluss der Systemanregung auf die Schätzung zu beleuchten, wurde auf das Konzept der Beobachtbarkeit zurückgegriffen und verschiedene Varianten einer Joint-Estimation wurden auf diese hin untersucht. Es zeigt sich, dass zum einen die Systemanregung eine umso höhere Dynamik aufweisen muss, je größer die Systemordnung ist (also umso mehr Modellparameter bestimmt werden sollen), zum anderen hat die Dynamik der Systemanregung einen Einfluss auf die Beobachtbarkeit.

Ein weiterer Aspekt, welcher in dieser Arbeit untersucht wurde, ist die Parametrierung des Filters durch die Festlegung der Kovarianzen von Prozess- und Messrauschen. Insbesondere, wenn für das Prozessrauschen keine analytische Herleitung möglich ist, wie es bei Random-Walk-Modellen der Fall ist, wird eine Methodik zur optimalen Wahl der Kovarianzmatrizen benötigt. In der Literatur fehlen häufig Angaben zur Parametrierung des Kalman-Filters oder die Methodik, nach der die Parameter ermittelt wurden, ist nicht dokumentiert. Im Rahmen dieser Arbeit wurde daher eine multikriterielle Optimierung mittels genetischem Algorithmus vorgestellt, wodurch das Filter-Tuning weniger auf der Erfahrung des Applikationsingenieurs beruht, sondern vielmehr auf nachvollziehbare Art und Weise anhand eines Trainingsdatensatzes durchgeführt werden kann. Zwar beinhaltet das Verfahren im letzten Schritt ebenfalls eine manuelle Auswahl eines für die Anwendung optimalen Parametersatzes aus der ermittelten Pareto-Menge, allerdings erweist sich die multikriterielle Optimierung als hilfreiches Werkzeug, um den möglichen Lösungsraum stark einzugrenzen. Während in Untersuchungen mit einem Referenzmodell gute Resultate erzielt werden können, zeigen die Ergebnisse mit realen Messdaten, dass eine konsistente Schätzung nicht möglich ist, da die Referenzwerte der Zustände aus einem Modell der Batteriezelle entnommen werden müssen, welches mit Fehlern behaftet ist. Dennoch ergeben sich geringe Schätzfehler. Der

SOC kann mit einer Genauigkeit von circa 1,2 Prozentpunkten bestimmt werden und der Fehler des Innenwiderstands ist kleiner als 5 %.

Die Charakteristika von intelligenten Batteriesystemen wie die zellindividuellen Sensoren und Rechenkapazitäten und die integrierten Halbleiterschalter beeinflussen die Zustands- und Parameterschätzung auf zweierlei Weise: Zum einen ermöglicht es die Messung der Zellströme und -spannungen, einen Kalman-Filter auf Zellebene zu realisieren. Dies ist auch geboten, da aufgrund der Schaltoperationen die Inhomogenität gegenüber herkömmlichen Batteriesystemen deutlich erhöht sein kann. Zum anderen beeinflussen die Schaltoperationen die Zellströme und damit die Systemanregung der Zellen. Aufbauend darauf wurde in dieser Arbeit die Möglichkeit untersucht, durch gezielte Schaltoperationen mit charakteristischen Mustern die Systemanregung in relevanten Frequenzbereichen zu steigern und somit die Schätzung der Zustände und Parameter zu verbessern. Dieses Vorgehen wird als aktive Parameterschätzung bezeichnet. Insbesondere für Fahrsituationen Batterie-elektrischer Fahrzeuge wie beispielsweise die Fahrt mit konstanter Geschwindigkeit erscheint diese Vorgehen sinnvoll. Durch Simulationen und Experimente konnte gezeigt werden, dass eine Verbesserung der Schätzung tatsächlich erreicht werden kann und dies insbesondere für die beiden wichtigen Größen Ladezustand und Ohmscher Innenwiderstand. Der Ladezustand bestimmt den Energieinhalt des Batteriesystems und der Innenwiderstand dessen Leistungsfähigkeit, wodurch beide Größen für den Betrieb eine wichtige Rolle einnehmen.

Zusammenfassend zeigt sich, dass intelligente Batteriesysteme großes Potenzial aufweisen, die Zustands- und Parameterschätzung zu verbessern. Die zusätzlichen Sensordaten schlagen sich in einer erhöhten Präzision nieder. Schalthandlungen im niederfrequenten Bereich, wie sie in dieser Arbeit auftreten, können adäquat modelliert und sogar zur aktiven Parameterschätzung genutzt werden.

Das Konzept intelligenter Batteriesysteme bedingt eine gegenüber herkömmlichen Batteriesystemen gesteigerte Komplexität und einen erhöhten Hardwareaufwand durch die Elektronik auf jeder Batteriezelle. Sollen intelligente Batteriesysteme zur Anwendung kommen, besteht daher die Notwendigkeit, das volle Potenzial der zusätzlich eingebrachten Elektronik optimal zu nutzen. Im Fall der Sensoren entsteht aufgrund der Verschaltung der Zellen eine hohe Redundanz, weil beispielsweise Zellspannungen und -ströme benachbarter Zellen gemessen werden. Die in dieser Arbeit vorgestellte Sensordatenfusion versucht daher, diese Redundanz über einen modellbasierten Ansatz auf zweierlei Weise nutzbar zu machen: Zum einen kann die Messgenauigkeit durch die Korrelation der Sensordaten gesteigert werden. Zum anderen lässt sich die Robustheit des Messsystems steigern, wenn benachbarte Sensoren den Ausfall einzelner Sensoren kompensieren können. Die präzise Zustands- und Parameterschätzung liefert für die Sensordatenfusion eine wichtige Voraussetzung, weil die benötigten Größen durch die eingesetzten Kalman-Filter aktuell gehalten werden. Insbesondere der für die Stromaufteilung parallel geschalteter Zellen benötigte Innenwiderstand R_0 ist solch ein wichtiger Modellparameter. Mithilfe eines Dual-Kalman-Filters, der die Besonderheiten der Innenwiderstandsbestimmung wie beispielsweise die Stromabhängigkeit berücksichtigt, kann eine hinreichende Präzision erreicht werden, welche für die Sensordatenfusion notwendig ist.

Die Ergebnisse zeigen, dass insbesondere die Fusion der Strommesswerte vorteilhaft ist, da die Erfassung der Zellströme im Gegensatz zur Spannungsmessung mit deutlichem Aufwand

verbunden ist. Der Einsatz einer Sensordatenfusion bietet immer dann Potenzial, wenn die Varianz des Messrauschens groß ist, wohingegen präzise Messungen sich kaum verbessern lassen. Der Grund hierfür ist das dem Verfahren zugrunde liegende Batteriesystemmodell, welches eine beschränkte Genauigkeit aufweist. Dadurch ist die Reduktion der Messunsicherheit limitiert. Daraus folgt, dass insbesondere günstige und einfache Sensortechnologien für die Strommessung in intelligenten Batteriesystemen sinnvoll mit der Sensordatenfusion kombiniert werden können. Wichtig bei der Wahl eines geeigneten Stromsensors ist es, keine zusätzlichen Widerstände in den Strompfad einzubringen, wodurch die Effizienz des gesamten Batteriesystems sinkt. Eine mögliche Lösung ist beispielsweise die Messung des Stroms über den Spannungsabfall an den Halbleiterschaltern, welche ein möglicher Ansatzpunkt für weitere Forschungsarbeiten ist. Herausfordernd bei dieser Methode ist die Modellierung des temperatur- und alterungsabhängigen Innenwiderstands des Leistungshalbleiterschalters.

Insgesamt lässt sich festhalten, dass intelligente Batteriesysteme für die Anwendung in Elektrofahrzeugen ein großes Potenzial bieten. Sie weisen aufgrund ihres einem herkömmlichen Batteriesystem deutlich überlegenen Funktionsumfangs eine hohe Innovationskraft auf – insbesondere in den Bereichen Diagnose und Steuerung. Die Weiterentwicklung des elektrischen Antriebsstrangs von Elektrofahrzeugen – und des Batteriesystems als dessen Kernkomponente im Besonderen – ist der Schlüssel für die Umsetzung der Mobilitätswende im Verkehrssektor. Hierfür können intelligente Batteriesysteme ein wichtiger Baustein sein, wenn die gegenüber heutigen Batteriesystemen deutlich steigende Komplexität des Systems beherrscht wird. Darin liegt eine große Herausforderung in der Umsetzung von intelligenten Batteriesystemen und deren Einsatz in der Industrie. Durch gezielte Forschung in diesem Themenfeld kann jedoch dafür ein wichtiger Grundstein gelegt werden. Diese Arbeit ist – so die Überzeugung des Autors – ein Teil dessen.

A Vorstellung der verwendeten Stromprofile

Für die Validierung von Batteriemodellen in Simulationen und Experimenten werden häufig dynamische Stromprofile benutzt. Im Gegensatz zur Konstantstrom-Entladung weisen dynamische Stromprofile eine Anregung auch in höheren Frequenzen auf und eignen sich daher dafür, auch das dynamische Modellverhalten zu untersuchen. Weiterhin werden Stromprofile für das Schätzverfahren genutzt, welche eine Abhängigkeit von der Art und Stärke der Anregung aufweist. Im Rahmen dieser Arbeit wurden hauptsächlich vier Stromprofile verwendet. Das WLTP- und das UDDS-Profil basieren auf bekannten Fahrzyklen. Sie bestehen aus einer Geschwindigkeitsvorgabe über der Zeit und werden beispielsweise zur Verbrauchsmessung herangezogen. Für die Verwendung von Stromprofilen auf Basis von Fahrzyklen spricht zum einen deren Bekanntheit und verbreiteter Einsatz zur Validierung von Batteriemodellen und Schätzverfahren in der Literatur. Zum anderen bildet das Geschwindigkeitsprofil der Fahrzyklen mehr oder weniger realistische Fahrscenarien ab. So entsprechen beispielsweise die Phasen des WLTP-Fahrzyklus Stadt-, Land- und Autobahnfahrten. Daher liefert die Validierung mit diesen Stromprofilen eine Aussage darüber, wie gut die getesteten Methoden in der realen Anwendung funktionieren. Insbesondere für die Zustands- und Parameterschätzung ist jedoch auch von Interesse, mit welcher Güte diese Ergebnisse liefern kann, wenn die Anregung gering ist. Dies wird beispielsweise in Kapitel 5 anhand eines Stromprofils überprüft, welches auf einer Autobahnfahrt mit einem realen Versuchsfahrzeug basiert. Die Anregung ist hier über weite Strecken sehr gering. Schließlich wird mit dem PRBS-Stromprofil das gegenteilige Szenario untersucht. Das synthetische Stromprofil weist eine in allen Frequenzbereichen nahezu konstante Leistungsdichte auf und kann daher als Best-Case-Szenario hinsichtlich der Anregung angesehen werden.

Tabelle A.1 listet wichtige Charakteristika der im Rahmen dieser Arbeit genutzten Stromprofile auf. Das WLTP-Stromprofil sowie das Autobahn-Stromprofil stammen aus der Vermessung eines realen Fahrzeugs auf einem Rollenprüfstand. Beide Profile beinhalten daher auch Anteile, die auf Nebenverbraucher im Fahrzeug zurückzuführen sind. Dahingegen wurde das PRBS-Profil synthetisch erzeugt und der Strom des UDDS-Profiles wurde basierend auf dem Fahrzyklus mithilfe eines Fahrzeugmodells und eines einfachen Batteriemodells ermittelt.

Die verwendeten Stromprofile dieser Arbeit sind in Abb. A.1 dargestellt. Abhängig von der Größe des Batteriesystems eines Batterie-elektrischen Fahrzeugs fällt die Strombelastung einer Einzelzelle größer oder geringer aus. Für die in den Versuchen dieser Arbeit verwendeten Batteriezellen existieren jedoch vom Hersteller vorgegebene Betriebsgrenzen, welche die aus dem Profil theoretisch ermittelten Ströme einschränken. Die Stromprofile sind daher derart skaliert, dass ein Ladestrom von 5 A und ein Entladestrom von -30 A niemals überschritten wird. Für die konkreten Versuche wird die Abtastrate der Stromprofile auf 5 Hz vereinheitlicht. Da die Zustands- und Parameterschätzer sowie die Sensordatenfusion mit einer Rate von 10 Hz betrieben werden, ist das Abtasttheorem nach Nyquist erfüllt. Weiterhin werden die Ströme für die Modulversuche abhängig von der Modul-Topologie skaliert. Dazu wird der Zellstrom, wie er hier dargestellt ist, mit \mathcal{P} skaliert. Zu beachten ist: Da in Kapitel 5 durch Schaltheandlungen des

Tabelle A.1: Verwendete Stromprofile und deren charakteristische Eigenschaften.

	WLTP	UDDS	Autobahn	PRBS
Dauer	1800 s	1800 s ¹	1800 s	1000 s
Ursprung	Prüfstand	Modell	Prüfstand	Synthetisch
Abtastrate	1 Hz	5 Hz	10 Hz	5 Hz
Max. Ladestrom	5,0 A	5,0 A	0,0 A	2,0 A
Max. Entladestrom	-10,9 A	-8,4 A	-30,0 A	-20,0 A
Mittelwert des Stroms	-1,4 A	-0,7 A	-7,1 A	-9,1 A
Entnommene Kapazität	711 mAh	360 mAh	3545 mAh	2517 mAh

¹Tatsächlich hat das UDDS-Fahrprofil eine Länge von 1876 s. Aus Gründen der Vergleichbarkeit mit dem WLTP- und dem Autobahn-Fahrzyklus wurde das Profil um 76 s gekürzt.

RBS die Situation entsteht, dass nur $\mathcal{P} - 1$ Zellen innerhalb eines Parallelstrangs aktiv sind, wird der Strom für diese Versuche mit diesem Faktor skaliert.

Auf die Ermittlung der Zellströme basierend auf einer Geschwindigkeitsvorgabe, einem Fahrzeug- sowie Batteriemodell soll an dieser Stelle kurz eingegangen werden. Ein Blockschaltbild der entsprechenden Modelle ist in Abb. A.2 gezeigt. Es handelt sich bei dem Fahrzeugmodell um ein quasi-stationäres Modell der Längsdynamik [337, S. 50ff.].

Zunächst kann ausgehend von der vorgegebenen Geschwindigkeit zum aktuellen Zeitpunkt v_{Fzg} durch Differentiation die Fahrzeugbeschleunigung a_{Fzg} ermittelt werden. Durch Multiplikation mit der Fahrzeugmasse m_{Fzg} und des Drehmassenzuschlagsfaktors λ_{rot} , welcher das Trägheitsmoment der rotierenden Antriebsstrangkomponenten berücksichtigt, kann die Beschleunigungskraft F_{B} bestimmt werden. Die Antriebskraft F_{A} ergibt sich nun aus der Summe der Beschleunigungskraft mit den Fahrwiderständen. Diese sind zum einen der Luftwiderstand

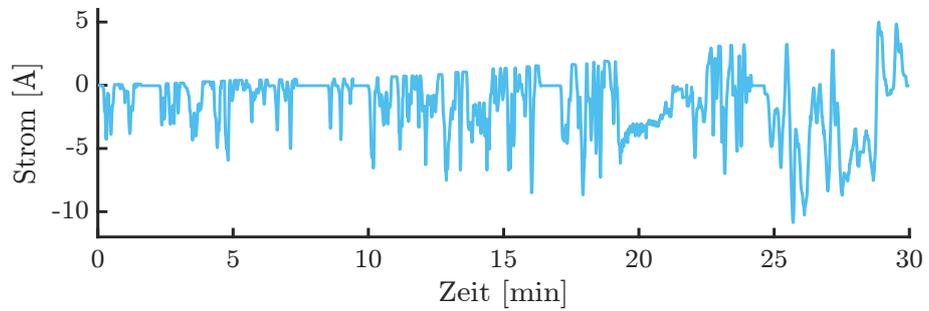
$$F_{\text{L}} = \rho_{\text{L}} \cdot A \cdot c_{\text{w}} \cdot \frac{v_{\text{Fzg}}^2}{2} \quad (\text{A.1})$$

mit der Luftdichte ρ_{L} , der Stirnfläche A , dem Luftwiderstandsbeiwert c_{w} , sowie der als konstant angenommenen Rollwiderstandskraft

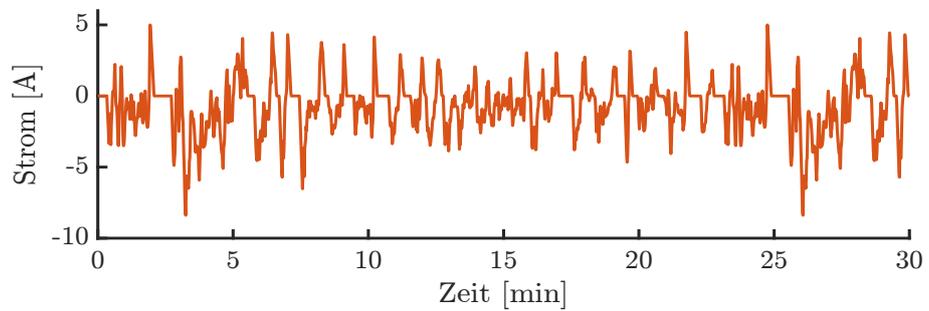
$$F_{\text{R}} = m_{\text{Fzg}} \cdot g \cdot f_{\text{R}} \quad (\text{A.2})$$

mit der Erdbeschleunigung g , der Fahrzeugmasse m_{Fzg} und dem Rollwiderstandskoeffizienten f_{R} . Das Fahrzeugmodell berücksichtigt keinerlei Steigung. Die Antriebsleistung am Rad ist schließlich das Produkt der Antriebskraft und der Fahrzeuggeschwindigkeit. Abhängig davon, in welchem Quadranten die elektrische Maschine betrieben wird, ergibt sich unter Berücksichtigung vereinfachter Wirkungsgrade für die elektrische Maschine und das Getriebe eine effektive Antriebsleistung als Ausgang des Fahrzeugmodells. Die im Rahmen dieser Arbeit verwendeten Modellparameter können Tabelle A.2 entnommen werden.

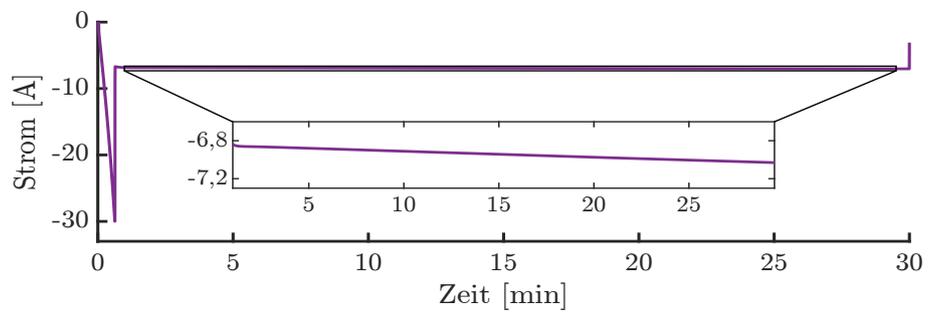
Zur Berechnung des Batterie-Zellstroms basierend auf der effektiven Antriebsleistung wird ein sehr einfaches Batteriemodell verwendet. Zunächst gelte die Annahme, dass sich die benötigte Leistung ungefähr gleich zwischen allen \mathcal{Z} Zellen des Batteriesystems aufteilt. Dann kann die



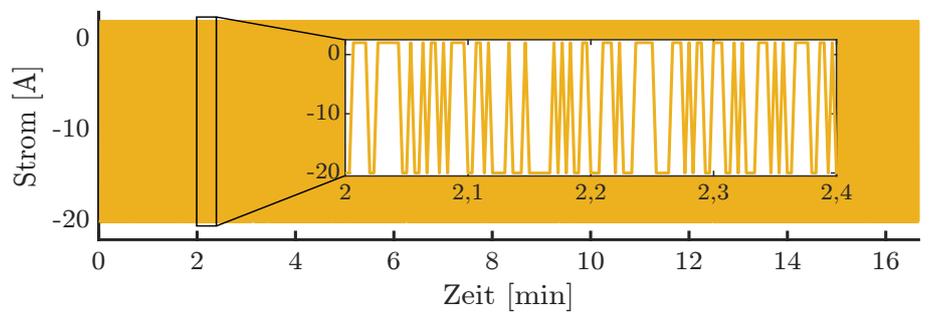
(a) WLTP



(b) UDDS



(c) Autobahn



(d) PRBS

Abbildung A.1: Verwendete Stromprofile skaliert auf eine Zelle.

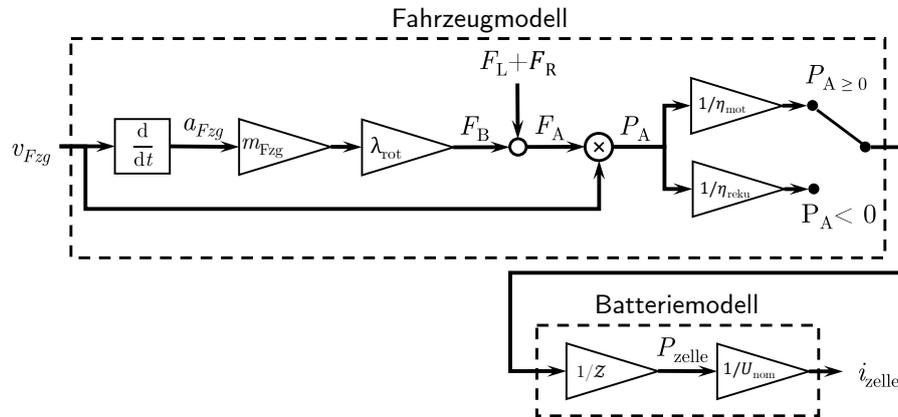


Abbildung A.2: Blockschaltbild des verwendeten Längsdynamik-Fahrzeugmodells und des Batteriemodells.

Tabelle A.2: Parameter des Fahrzeugmodells für die Längsdynamik und des Batterie-Modells

Parameter	Name	Wert
Fahrzeugmasse	m_{Fzg}	2800 kg
Drehmassenzuschlagsfaktor	λ_{rot}	1,1
Stirnfläche	A	2,65 m ²
Luftwiderstandsbeiwert	c_w	0,28
Rollwiderstandskoeffizient	f_R	0,015
komb. Motor-/Getriebewirkungsgrad	η_{mot}	0,95
Rekuperationswirkungsgrad	η_{reku}	0,75
Anzahl Zellen	Z	432
Nominelle Zellspannung	u_{nom}	3,7 V

von einer Zelle bereitzustellende Leistung durch die Division der Antriebsleistung durch Z bestimmt werden. Die Batteriezellen werden nur als Konstantspannungsquelle mit der nominellen Spannung u_{nom} modelliert, sodass sich der Zellstrom ergibt zu

$$i_{\text{zelle}} = \frac{P_{\text{zelle}}}{u_{\text{nom}}}. \quad (\text{A.3})$$

Eine detailliertere Modellierung des Batterieverhaltens ist an dieser Stelle nicht notwendig, da über das Fahrzeug- und Batteriemodell lediglich auf nachvollziehbare Weise ein Stromprofil erzeugt werden soll, welches zur Validierung der Algorithmen verwendet wird. Wichtig ist hierfür die Vergleichbarkeit der Simulationen und Experimente, was durch die Beschränkung auf nur wenige Stromprofile gewährleistet wird. Umgekehrt würde ein detailliertes Zellmodell die Vergleichbarkeit der Ergebnisse mit anderen Arbeiten erschweren, da die Ermittlung des Stromprofils von vielen weiteren Modellgleichungen und -parametern abhängig wäre.

B Vorstellung des Prüflings und Versuchsbeschreibung

Nachdem in Kapitel 3.2.1 bereits die verwendeten Lithium-Ionen-Zellen vorgestellt wurden, können dem folgenden Abschnitt weitere Informationen zur Integration der Zellen in die Versuchsaufbauten und zur Zellcharakterisierung entnommen werden. Basierend auf den einzelnen Lithium-Ionen-Zellen wurden im Rahmen des Forschungsprojekt Prototypen für intelligente Batteriezellen und -module entwickelt, welche in Abschnitt B.2 kurz vorgestellt werden. Anschließend wird der Versuchsaufbau der Modultests beschrieben und das Vorgehen zur Verarbeitung der Messdaten.

B.1 Lithium-Ionen-Zellen und deren Charakterisierung

Die im Rahmen dieser Arbeit durchgeführten Versuche greifen auf die in Kapitel 3.2.1 vorgestellte zylindrische Zelle zurück (siehe Abb. B.1). Es handelt sich um eine kommerziell erhältliche Zelle, welche in großen Stückzahlen produziert wird. Daher kann von einer hohen Produktionsqualität ausgegangen werden und die Schwankung innerhalb einzelner Produktionschargen ist gering. Im Gegensatz zu den in heutigen Elektrofahrzeugen eingesetzten Batteriezellen mit deutlich größeren Kapazitäten, ist der Energiegehalt des im Rahmen der Versuche verwendeten Batteriemoduls durch die geringen Zellkapazitäten limitiert. Dadurch sind auch die Risiken eines Zelldefekts während der Versuchsdurchführung begrenzt.

Für die Umsetzung intelligenter Batteriezellen werden die Lithium-Ionen-Zellen mit Messtechnik und Leistungshalbleiter-Schaltern ausgestattet. Um die Leiterplatte mit der Batteriezelle zu verbinden, ist letztere auf eine Leiterplatte aufgelötet. Dazu ist sie mit angeschweißten Lötflächen ausgestattet. Die Leiterplatte weist Schraubterminals auf, welche als Batteriepole die Schnittstelle zur Elektronik dienen. Sie wird deshalb als Adapterboard bezeichnet (siehe Abb. B.2). Um einen



Abbildung B.1: Foto einer der verwendeten Lithium-Ionen-Zellen des Typs INR18650-25R der Firma Samsung SDI mit Lötflächen an beiden Polen.

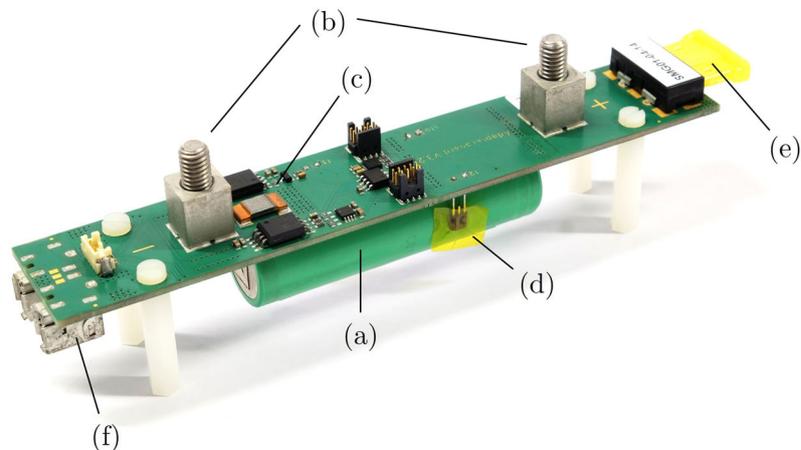


Abbildung B.2: Foto des Adapterboards mit (a) montierter zylindrischer Lithium-Ionen-Zelle, (b) Schraub-Terminals, (c) Shunt zur Strommessung, (d) Temperatursensor, (e) Schmelzsicherung und (f) Stecker für den Anschluss an die Messhardware.

Kurzschluss der Zelle bei einem ungültigen Schaltzustand zu vermeiden, ist das Adapterboard mit einer Schmelzsicherung im Strompfad ausgestattet, welche bei Strömen mit einem Betrag über 30 A auslöst. Weiterhin umfasst die Ausstattung des Adapterboards eine Referenzsensorik, auf welche näher in Abschnitt B.3 eingegangen wird. An dieser Stelle ist der Shunt von $1\text{ m}\Omega$ zur Strommessung von Bedeutung. Dieser liegt im Strompfad.

Betrachtet man die Lithium-Ionen-Zelle und das zugehörige Adapterboard als eine Einheit, so erhöht sich dessen Ohmscher Innenwiderstand ausgehend von dem Innenwiderstand der Batteriezelle um den Widerstand der Sicherung, des Shunts sowie sonstiger Leitungswiderstände. Für die Zellcharakterisierung und auch die späteren Modulversuche ist als Batteriezelle immer das zusammengesetzte System aus Adapterboard und Batterie gemeint. Die Systemgrenze dieses Verbunds sind aus elektrischer Sicht die Schraubterminals, an welchen die dann resultierende Zellspannung abgegriffen werden kann.

Die Zellcharakterisierung, wie sie Kapitel 3.2 beschreibt, wird mit einem Batterietester der Firma Arbin Instruments durchgeführt. Es handelt sich um einen Arbin LBT 5V/60A, d. h. die maximale Spannung eines Kanals beträgt 5 V und der Strom kann im Bereich von $\pm 60\text{ A}$ gestellt beziehungsweise gemessen werden. Die Strommessung hat eine Auflösung von 24 Bit, wobei sich diese auf einen der vier einstellbaren Messbereiche bezieht. Diese betragen $\pm 60\text{ A}$, $\pm 5\text{ A}$, $\pm 500\text{ mA}$ oder $\pm 20\text{ mA}$. Die Genauigkeit der Messung und auch der Strom- und Spannungsregelung ist laut Datenblatt $< 0,01\%$.

Die Zellen werden für die Charakterisierung einzeln per Vierleiter-Messung an ihren Schraubterminals mit den Kanälen des Batterietesters verbunden. Sie werden in einer Temperaturkammer des Typs KB115 der Firma Binder platziert, welche die Umgebungstemperatur während des Versuchs mit einer Genauigkeit von $\pm 1\text{ K}$ kontrolliert. Der Messablauf, wie in Abb. 3.9 dargestellt, läuft für eine vorgegebene Umgebungstemperatur vollautomatisch ab, wobei der Batterietester eine

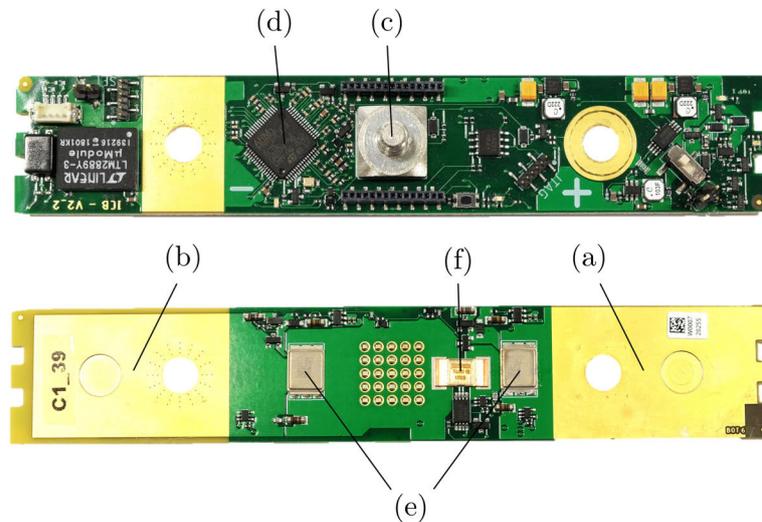


Abbildung B.3: Foto der Leiterplatte eines Prototypen einer intelligenten Batteriezelle mit (a) Terminal für den Batterie-Minuspol bzw. (b) Pluspol, (c) drittem Pol, (d) Mikrocontroller, (e) Halbleiterschalter und (f) Shunt zur Strommessung.

vorgegebene Abfolge an Prüfschritten durchläuft und die resultierenden Messdaten aufzeichnet. Der detaillierte Prüfplan ist in Tabelle B.1 aufgeführt.

B.2 Prototypen intelligenter Batteriezellen und -module

Um die Batteriezelle, welche auf dem Adapterboard montiert ist, gemäß den Charakteristika von IBSs zu ertüchtigen, wurde im Rahmen des Forschungsprojekts ein Prototyp der Elektronik einer intelligenten Batteriezelle entwickelt. Es handelt sich um eine Leiterplatte (siehe Abb. B.3), welche (a) Sensoren, (b) Rechenkapazität in Form eines Mikrocontrollers, (c) eine Kommunikationsschnittstelle und (d) Aktuatorik in Form von Leistungs-MOSFETs als Aktiv- und Bypass-Schalter beinhaltet. Damit sind alle Hauptbestandteile einer intelligenten Batteriezelle vorhanden. Auf sie wird im Folgenden näher eingegangen.

- (a) Der Prototyp enthält Sensoren zur Strom-, Spannungs- und Temperaturmessung. Die Strommessung ist über einen Shunt mit einem Nennwert von $1\text{ m}\Omega$ und nachgeschaltetem Differenzverstärker realisiert. Die Analog-Digital-Wandlung hat eine Auflösung von 16 Bit, woraus sich bei einem Messbereich von $-102,5\text{ A}$ bis $+52,5\text{ A}$ ein theoretischer Quantisierungsfehler von maximal $2,5\text{ mA}$ ergibt. Die tatsächliche Auflösung der Messdaten ist gewählt zu 3 mA . Zusätzlich sind jedoch Nichtlinearitäten des Analog-Digital-Konverters zu beachten.

Die Spannungsmessung ist mit einem Sigma-Delta-Analog-Digital-Wandler realisiert, der ebenfalls eine Auflösung von 16 Bit aufweist. Daraus ergibt sich bei einem Messbereich von $0 - 6,6\text{ V}$ eine Auflösung von $0,1\text{ mV}$. Auch hier sind über den Messbereich Nichtlinearitäten zu erwarten. Diese werden in der Signalverarbeitung vernachlässigt.

Tabelle B.1: Detaillierter Prüfplan zur Charakterisierung der Lithium-Ionen-Zellen für eine feste Umgebungstemperatur.

Nr.	Aktion	Abbruchkriterium	Abtastfrequenz
Start			
1	Ruhephase	nach 30 min	1 Hz
2	Laden mit 1 C	$u_{zelle} > 4,2 \text{ V}$	0,1 Hz
3	Entladen mit 1 C	$u_{zelle} < 2,5 \text{ V}$	0,1 Hz
	Wiederhole Schritt 2 bis Schritt 3 dreimal		
Kapazitätstest			
4	CCCV-Laden (1 C bis $u_{zelle} > 4,2 \text{ V}$)	$i_{zelle} < 125 \text{ mA}$	0,1 Hz
5	Ruhephase	nach 10 min	0,1 Hz
6	Entladen mit 1 C	$u_{zelle} < 2,5 \text{ V}$	0,1 Hz
7	Ruhephase	nach 10 min	0,1 Hz
Leerlaufspannung			
8	CCCV-Laden (1 C bis $u_{zelle} > 4,2 \text{ V}$)	$i_{zelle} < 125 \text{ mA}$	0,1 Hz
9	Ruhephase	nach 10 min	0,1 Hz
10	Entladen mit 0,2 C	nach 15 min	0,1 Hz
11	Ruhephase	nach 10 min	0,1 Hz
	Wiederhole Schritt 10 bis Schritt 11 bis $u_{zelle} < 2,5 \text{ V}$		
12	Ruhephase	nach 10 min	0,1 Hz
13	Laden mit 0,2 C	$t > 15 \text{ min}$	0,1 Hz
14	Ruhephase	nach 10 min	0,1 Hz
	Wiederhole Schritt 13 bis Schritt 14 bis $u_{zelle} > 4,2 \text{ V}$		
15	Ruhephase	nach 10 min	0,1 Hz
HPPC			
16	CCCV-Laden (1 C bis $u_{zelle} > 4,2 \text{ V}$)	$i_{zelle} < 125 \text{ mA}$	0,1 Hz
17	Ruhephase	nach 10 min	0,1 Hz
18	Entladen mit 0,2 C	nach 30 min	0,1 Hz
19	Ruhephase	nach 10 min	0,1 Hz
20	Strompuls-Folge (s. Abb. 3.14)	nach 122 s	10 Hz
	Wiederhole Schritt 18 bis Schritt 20 bis $u_{zelle} < 2,5 \text{ V}$		
Validierungsprofile			
21	CCCV-Laden (1 C bis $u_{zelle} > 4,2 \text{ V}$)	$i_{zelle} < 125 \text{ mA}$	0,1 Hz
22	Ruhephase	nach 10 min	0,1 Hz
23	Entladen mit 1 C	nach 3 min	0,1 Hz
24	Ruhephase	nach 10 min	0,1 Hz
25	WLTP-Stromprofil	$u_{zelle} < 2,5 \text{ V}$	10 Hz
26	Ruhephase	nach 10 min	0,1 Hz
27	CCCV-Laden (1 C bis $u_{zelle} > 4,2 \text{ V}$)	$i_{zelle} < 125 \text{ mA}$	0,1 Hz
28	Ruhephase	nach 10 min	0,1 Hz
29	Entladen mit 1 C	nach 3 min	0,1 Hz
30	Ruhephase	nach 10 min	0,1 Hz
31	UDDS-Stromprofil	$u_{zelle} < 2,5 \text{ V}$	10 Hz
32	Ruhephase	nach 10 min	0,1 Hz
33	CCCV-Laden (1 C bis $u_{zelle} > 4,2 \text{ V}$)	$i_{zelle} < 125 \text{ mA}$	0,1 Hz
34	Ruhephase	nach 10 min	0,1 Hz
35	Entladen mit 1 C	nach 3 min	0,1 Hz
36	Ruhephase	nach 10 min	0,1 Hz
37	PRBS-Stromprofil	$u_{zelle} < 2,5 \text{ V}$	10 Hz
38	Ruhephase	nach 10 min	0,1 Hz
Schluss			
39	Laden mit 1 C	$u_{zelle} > 3,7 \text{ V}$	0,1 Hz
	Ende		

Die Strom- und Spannungswerte werden mit einer Frequenz von 10 kHz erfasst. Anschließend erfolgt eine Vorfilterung der Messdaten derart, dass über Blöcke von 500 Messwerten ein Mittelwert gebildet wird. Durch diese Überabtastung stehen alle 20 ms gefilterte Messsignale zur Verfügung. Eine Vermessung der Stromsensoren in dem für die Versuche dieser Arbeit relevanten Bereich von ± 10 A ergibt eine Standardabweichung des Sensorrauschens von $2,38 \pm 0,23$ mA. Die Standardabweichung des Sensorrauschens des Spannungssensors wird aus Messungen zu $72,5 \pm 10,1$ μ V ermittelt.

Bei der Erfassung der Temperatur ist zu beachten, dass es sich hierbei um die Temperatur der Leiterplatte handelt, wobei externe Temperatursensoren für die Zelltemperaturmessung zusätzlich an die Elektronik angeschlossen werden können. Die Messgenauigkeit beträgt 1 K.

- (b) Der Mikrocontroller dient der Messdatenerfassung, der Vorfilterung der Daten und auch der Kommunikation mit dem BMS. Die Messdaten werden zyklisch an das BMS verschickt, in welchem die Speicherung der Messdaten realisiert ist. Weiterhin ist der Mikrocontroller auch für die Ansteuerung der Leistungshalbleiter-Schalter zuständig. Die Signale des BMS werden hierzu empfangen und in Schaltoperationen übersetzt.
- (c) Als Kommunikationskanal der intelligenten Batteriezellen untereinander und zum BMS ist ein CAN-Bus (Controlled-Area-Network) vorgesehen. Über diesen erfolgt die dynamische Adressierung der Zellen, die Übertragung der Messdaten von den Zellen zum BMS, sowie umgekehrt die Übertragung der Schaltbefehle an die Zellen. Zusätzliche Trigger-Signale synchronisieren die Schalthandlungen einer Iteration untereinander bis auf wenige Millisekunden genau.
- (d) Bei den Halbleiterschaltern handelt es sich um Leistungs-MOSFETs des Typs IRL7472 der Firma Infineon. Diese weisen im leitenden Zustand einen Innenwiderstand von ungefähr 0,34 m Ω auf. Der maximal zulässige Strombetrag ist im Datenblatt mit 375 A angegeben. Die nominelle Einschalt-/Ausschaltzeit beträgt weniger als 180 ns und ist damit vernachlässigbar.

Weiterhin beinhaltet die Elektronik LEDs, welche den aktuellen Schaltzustand anzeigen. Außerdem sind auf der Leiterplatte Spannungswandler für den Betrieb der diversen elektronischen Bauteile untergebracht. Die Elektronik kann sich hierbei grundsätzlich aus der Zellspannung selbst speisen und so einen autonomen Betrieb gewährleisten. Im Rahmen der durchgeführten Versuche wurde die Elektronik jedoch extern durch zusätzliche Netzteile versorgt, um einen Einfluss auf die Lithium-Ionen-Zellen auszuschließen. Während an den Leiterplatten-Außenseiten die Anschlusspunkte für die Schraubterminals des Adapterboards vorgesehen sind, ergibt sich durch die Mikrotopologie gemäß Abb. 2.4 ein weiteres Terminal, welches den geschalteten Plus-Pol darstellt. Dieser dritte Pol ist in der Mitte der Platine angeordnet. Die Spannung zwischen diesem Pol und dem Minus-Pol der Leiterplatte wird ebenfalls gemessen.

Das BMS ist in der Software CANoe der Firma Vector Informatik GmbH implementiert. Hauptaufgaben sind die Überwachung der Betriebsgrenzen des Batteriesystems (Strom, Spannung, Temperatur), die Kommunikation mit den Batteriezellen und das Speichern der empfangenen Messdaten. Die Schaltoperationen werden durch ein MATLAB/Simulink-Modell realisiert, welches in kompilierter Form Teil des BMS-Programms ist. Innerhalb dieses Modells kann auf sämtliche

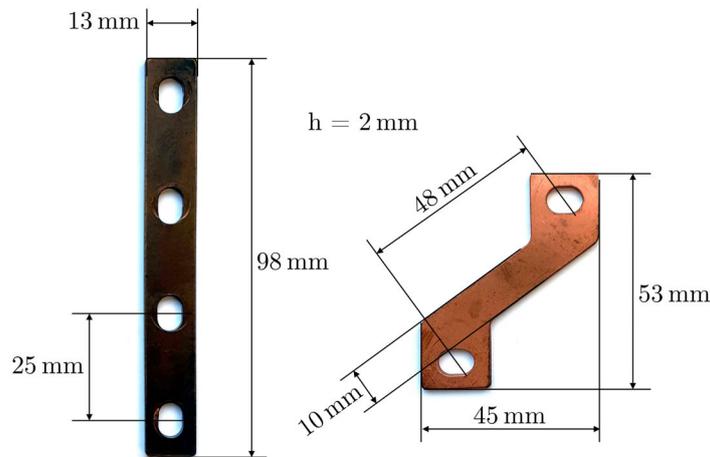


Abbildung B.4: Abbildung der verwendeten Kupfer-Stromschienen mit den wichtigsten Maßen. Die Dicke der Stromschienen beträgt $h = 2$ mm.

Messdaten des Batteriesystems zugegriffen werden, was die Umsetzung von Regelalgorithmen ermöglicht.

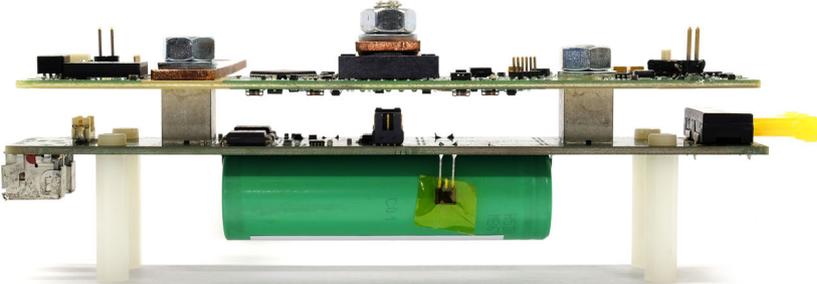
Durch Stromschienen aus Kupfer (siehe Abb. B.4) werden zwölf intelligente Batteriezellen zu einem Modul zusammengeschlossen. Die Batteriezellen bestehen hierbei, wie in Abb. B.5b ersichtlich ist, aus den zylindrischen Zellen, dem Adapterboard und der erweiterten Elektronik, welche auf das Adapterboard gesetzt wird. Die Zellen sind in einer Reihe angeordnet und auf einer Platte verschraubt. Aus der gewählten 4s3p-Topologie resultieren die diagonalen Stromschienen, welche die Parallelverbünde seriell miteinander verbinden. Hierzu werden die geschalteten Plus-Pole eines Parallelstrangs in der Mitte der Leiterplatten mit den Minus-Polen des nächsten Strangs verbunden. Es ergibt sich das für die Versuche dieser Arbeit verwendete intelligente Batteriemodul in Abb. B.5a.

B.3 Versuchsaufbau und Signalverarbeitung der Modulversuche

Das im vorherigen Abschnitt vorgestellte Modul wird an einen Chroma 69225-60-4 Modultester angeschlossen. Der Tester ist für den Betrieb von Batteriemodulen mit einer Systemspannung von bis zu 80 V und Lade-/Entladeströmen von $\pm 62,5$ A ausgelegt und regt den Prüfling gemäß einem vorgegebenen Prüf Ablauf mit definierten Strömen oder Spannungen an. Die Erfassung der Messdaten erfolgt mit einem Daten-Logger der Firma Hioki, welcher mit der auf den Adapterboards verbauten Referenzsensorik verbunden ist. Es ergibt sich eine Spannungsauflösung von 0,5 mV bei einer Genauigkeit von 1 mV. Für die Strommessung ergibt sich ein Messbereich von ± 100 A bei einer Auflösung von 10 mA. Für die Messung der Zelltemperaturen werden Thermocouples Typ K auf die Seitenfläche der Batteriezellen geklebt und ebenfalls vom Hioki Daten-Logger überwacht. Die Abtastfrequenz der Sensoren beträgt 40 Hz. Die Modulversuche werden in einem Klimaschrank des Typs DY110 der Firma ATT durchgeführt, welcher die Umgebungstemperatur auf 25 ± 1 °C regelt. Damit liegt die Temperatur in der Mitte des charakterisierten Temperaturfensters von 15 °C bis 35 °C.



(a) Aufsicht



(b) Frontalansicht (eine Zelle)

Abbildung B.5: Aufbau des für die Versuche verwendeten intelligenten Batteriemoduls.

Zu Beginn jeder Messung wird das System mit dem CCCV-Ladeverfahren auf eine Systemspannung von 16,4 V geladen, was einer individuellen Zellspannung von 4,1 V entspricht. Der Ladevorgang endet, wenn der Systemstrom die Grenze von 1 A unterschreitet. Nach einer anschließenden Ruhephase von 30 min wird das Modul mit einem definierten Stromprofil angeregt, bis eine der Zellen eine Spannung von 3 V unterschreitet. Dadurch, dass nicht der gesamte zulässige Spannungsbereich bis 2,5 V genutzt wird, werden Modellungenauigkeiten vermieden, welche an den Randbereichen des Betriebsbereichs bei niedrigen Ladezuständen auftreten können. Der individuelle Ladezustand zu Beginn der Stromanregung ist zunächst unbekannt. Über die Umkehrfunktion $\text{SOC} = u_{\text{OC}}^{(-1)}$ lässt sich jedoch aus der Ruhespannung direkt vor Beginn der Anregung der entsprechende Ladezustand ermitteln. Dies ist möglich weil die u_{OC} -Funktion für die verwendete Zellchemie bijektiv ist.

Aus der Differenz zwischen der Zellspannung an den Terminals des Adapterboards und der Spannung am dritten Pol der intelligenten Elektronik können die Widerstände der Elektronik-Leiterplatte und der Bauelemente im Strompfad abgeschätzt werden. Dies sind im Wesentlichen der Aktiv-MOSFET, der Shunt-Widerstand zur Strommessung und die Widerstände der Leiterbahnen. Es ergibt sich für die Zellen des Moduls ein Wert von $1,57 \pm 0,04 \text{ m}\Omega$. Ausgehend von dem Innenwiderstand des MOSFET von circa $0,3 \text{ m}\Omega$ und dem Widerstand des Shunts von $1 \text{ m}\Omega$ erscheint dieser Wert plausibel. Für die Modellierung der Stromverteilung in Parallelsträngen (siehe Kapitel 3.1.3) muss dieser Wert dem Ohmschen Widerstand der Zelle zugeschlagen werden.

Die Messdaten werden im Modultester und auf dem Messrechner, welcher das BMS beinhaltet, aufgezeichnet. Anschließend durchlaufen sie einige Verarbeitungsschritte, bevor sie für die Validierung der Algorithmen und weitere Untersuchungen zur Verfügung stehen. Zunächst müssen die Sensoren kalibriert werden. Für die Stromsensoren auf dem Adapterboard und der intelligenten Elektronik wird hierzu die Abweichung der Signale zum Nullpunkt zu Beginn der Messung ermittelt, wenn noch keine Zellströme fließen. Es ergibt sich ein Betrag von maximal 68 mA für den Sensor-Bias. Um diese Abweichung werden die Sensordaten korrigiert. Zusätzlich wird für die Strommessung der intelligenten Batteriezelle ein Gain-Fehler ermittelt, indem Strompulse auf das System gegeben werden und die Abweichung des vorgegebenen Stroms zur Messung untersucht wird. Es ergibt sich für die zwölf Zellen ein Gain-Fehler von maximal 1,4 %. Der Durchschnitt beträgt 0,7 %. Auch die Spannungssensoren der intelligenten Batteriezelle werden kalibriert. Ausgehend von der Annahme, dass die Zellspannungen parallel geschalteter Zellen identisch sein muss, werden Abweichungen der Spannungswerte benachbarter Zellen von deren Mittelwert als Fehler angesehen und korrigiert. Die Korrektur erfolgt gegenüber dem Mittelwert der drei parallelen Zellen. Der Betrag des Fehlers ist für die zwölf Zellen durchschnittlich $3,3 \pm 3,0 \text{ mV}$ groß.

Da die Referenzmessdaten und die Messdaten des BMS separat gespeichert werden, ist eine Synchronisation der Messsignale aus beiden Quellen untereinander erforderlich. Eine erste Abschätzung liefert das Auftreten des ersten Strompulses in beiden Messreihen, aus denen sich der zeitliche Versatz grob bestimmen lässt. In einem zweiten Schritt wird eine Optimierung durchgeführt, welche basierend auf der MATLAB-Funktion `fminsearch` diejenige zeitliche Verschiebung

bestimmt, welche die Abweichung der Z Zellströme des BMS $i_{\text{BMS}}(t)$ und des Modultesters $i_{\text{MT}}(t)$ zueinander minimiert.

$$t_{\text{offset}} = \arg \min_{T \in \mathbb{R}} \sum_{n=1}^Z \int_{t=0}^{T_{\text{end}}} i_{\text{BMS},n}(t-T) - i_{\text{MT},n}(t) dt \quad (\text{B.1})$$

Schließlich wird die Abtastrate der synchronisierten Messdaten von 20 Hz beziehungsweise 40 Hz auf die Sample-Rate der Kalman-Filter bzw. der Sensordatenfusion reduziert. Diese beträgt $t_s = 10$ Hz. Durch diese Maßnahme wird auch der Speicherbedarf der Messdateien reduziert.

C Stochastische Grundlagen

Die vorliegende Arbeit beruht auf einigen Grundlagen der Mathematik und Stochastik, auf welche in diesem Kapitel in Kürze eingegangen werden soll. Weiterführende Informationen können den zitierten Grundlagenwerken entnommen werden. Im Rahmen dieser Arbeit werden Wahrscheinlichkeitsdichtefunktionen (WDFs) auch vereinfachend als Wahrscheinlichkeitsdichte oder Dichte bezeichnet. Weiterhin erfolgt keine Unterscheidung in der Notation zwischen Zufallsvariablen und deren Realisierungen.

C.1 Momente einer Zufallsvariablen

Für eine kontinuierliche Zufallsvariable $\mathbf{x} \in \mathbb{R}^{n \times 1}$ ist der Erwartungswert als erstes zentrales Moment definiert als [308, S. 19]

$$\mathbb{E}\{\mathbf{x}\} = \int \mathbf{x}p(\mathbf{x}) d\mathbf{x}. \quad (\text{C.1})$$

Hierbei ist $p(\mathbf{x})$ die WDF der Wahrscheinlichkeitsfunktion $P(\mathbf{x})$.

Für zwei Zufallsvariablen $x, y \in \mathbb{R}$ lässt sich die Kovarianz berechnen zu

$$\text{Cov}\{x, y\} = \mathbb{E}\{(x - \mathbb{E}\{x\})(y - \mathbb{E}\{y\})^T\}. \quad (\text{C.2})$$

Gilt $x = y$, entspricht die Kovarianz der Varianz mit

$$\text{Var}\{x\} = \mathbb{E}\{(x - \mathbb{E}\{x\})^2\} = \int (x - \mathbb{E}\{x\})^2 p(x) dx. \quad (\text{C.3})$$

Im multivariaten Fall ist die Kovarianzmatrix der Zufallsvariable \mathbf{x} [89, S. 45]

$$\text{Var}\{\mathbf{x}\} = \mathbb{E}\{(\mathbf{x} - \mathbb{E}\{\mathbf{x}\})(\mathbf{x} - \mathbb{E}\{\mathbf{x}\})^T\} = \int (\mathbf{x} - \mathbb{E}\{\mathbf{x}\})(\mathbf{x} - \mathbb{E}\{\mathbf{x}\})^T d\mathbf{x}. \quad (\text{C.4})$$

Aus Gründen der Konsistenz in der Notation wird die Kovarianzmatrix ebenfalls mit dem Varianz-Operator gebildet. Sie hat die Dimension $n \times n$ und enthält auf der Hauptdiagonalen die Varianzen der n Elemente von \mathbf{x} und auf den Nebendiagonalen die Kovarianzen der Elemente zueinander. Es handelt sich um eine symmetrische Matrix.

Weiterhin kann die gemeinsame WDF zweier Zufallsvariablen $p(\mathbf{x}, \mathbf{y})$ marginalisiert werden zu [308, S. 19]

$$p(\mathbf{x}) = \int p(\mathbf{x}, \mathbf{y}) d\mathbf{y}. \quad (\text{C.5})$$

Ist \mathbf{x} gegeben, kann die sogenannte bedingte Wahrscheinlichkeit $p(\mathbf{y}|\mathbf{x})$ durch Konditionieren gefunden werden [308, S. 22].

$$p(\mathbf{y}|\mathbf{x}) = \frac{p(\mathbf{x}, \mathbf{y})}{p(\mathbf{x})} = \frac{p(\mathbf{x}, \mathbf{y})}{\int p(\mathbf{x}, \mathbf{y}) d\mathbf{y}} \quad (\text{C.6})$$

Durch Umformung ergibt sich direkt der Satz von Bayes zu

$$p(\mathbf{x}|\mathbf{y}) = \frac{p(\mathbf{y}|\mathbf{x})p(\mathbf{x})}{p(\mathbf{y})} = \frac{p(\mathbf{x},\mathbf{y})}{\int p(\mathbf{x},\mathbf{y}) d\mathbf{x}}. \quad (\text{C.7})$$

C.2 Normalverteilung

In der Beschreibung stochastischer Prozesse der Natur oder Technik können Zufallsvariablen häufig durch die Normalverteilung (auch Gauß-Verteilung) beschrieben werden. Der Grund hierfür ist, dass die Summe vieler zufälliger und voneinander unabhängiger Ereignisse normalverteilt ist, wenn jedes Zufallsereignis nur einen geringen Betrag zur Gesamtsumme liefert [325, S. 90]. Für den univariaten Fall ist die Zufallsvariable x normalverteilt, wenn gilt

$$p(x) = \mathcal{N}(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \cdot \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right). \quad (\text{C.8})$$

Hierbei ist μ der Erwartungswert und $\sigma > 0$ die Standardabweichung der Normalverteilung mit $\sigma^2 = \text{Var}\{x\}$. Für den multivariaten Fall ist die Normalverteilung mit Mittelwert $\boldsymbol{\mu} \in \mathbb{R}^{n \times 1}$ und Kovarianz $\boldsymbol{\Sigma} \in \mathbb{R}^{n \times n}$ gegeben gemäß [311, S. 103]

$$p(\mathbf{x}) = \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{(2\pi)^n \det\{\boldsymbol{\Sigma}\}}} \cdot \exp\left(-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x}-\boldsymbol{\mu})\right). \quad (\text{C.9})$$

Für Mittelwert und Kovarianzmatrix gilt

$$\mathbb{E}\{\mathbf{x}\} = \boldsymbol{\mu}, \quad \text{Var}\{\mathbf{x}\} = \boldsymbol{\Sigma}. \quad (\text{C.10})$$

Die Kovarianzmatrix muss immer positiv definit sein, damit eine gültige WDF gebildet wird [308, S. 81]. Weiterhin soll sie symmetrisch sein, da unsymmetrische Komponenten von $\boldsymbol{\Sigma}$ im Exponenten von (C.9) immer wegfallen.

Eine normalverteilte Zufallsvariable $\mathbf{x} \in \mathbb{R}^{n \times 1}$ lässt sich linear transformieren. Für die Transformation $\mathbf{A}\mathbf{x} + \mathbf{b}$ mit $\mathbf{A} \in \mathbb{R}^{n \times n}$ und $\mathbf{b} \in \mathbb{R}^{n \times 1}$ gilt [311, S. 104]

$$p(\mathbf{x}) = \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) \Rightarrow p(\mathbf{A}\mathbf{x} + \mathbf{b}) = \mathcal{N}(\mathbf{A}\mathbf{x} + \mathbf{b}|\mathbf{A}\boldsymbol{\mu} + \mathbf{b}, \mathbf{A}\boldsymbol{\Sigma}\mathbf{A}^T). \quad (\text{C.11})$$

Es ergibt sich also nach der linearen Transformation wieder eine Normalverteilung, deren Momente sich darüber hinaus analytisch berechnen lassen. Dies ist für viele Anwendungen (wie zum Beispiel das Kalman-Filter) von Vorteil. Die Normalverteilung mit dem Erwartungswert 0 und der Standardabweichung 1 wird als Standard-Normalverteilung bezeichnet. Durch eine lineare Transformation lässt sich jede Normalverteilung in eine Standard-Normalverteilung umwandeln. In Abb. C.1 ist die WDF einer Normalverteilung dargestellt. Die einfache Standardabweichung σ ist in das Diagramm eingezeichnet. Je größer diese ist, mit umso höherer Wahrscheinlichkeit treten auch Realisierungen auf, die vom Erwartungswert μ abweichen. In Blau hinterlegt ist die Fläche, welche der Wahrscheinlichkeit entspricht, dass eine Realisierung der Zufallszahl innerhalb des Intervalls $[\mu - \sigma, \mu + \sigma]$ liegt. Die Wahrscheinlichkeit hierfür liegt bei ungefähr 68,3%. Innerhalb des 3- σ -Intervalls $[\mu - 3\sigma, \mu + 3\sigma]$ liegen 99,7% der Realisierungen.

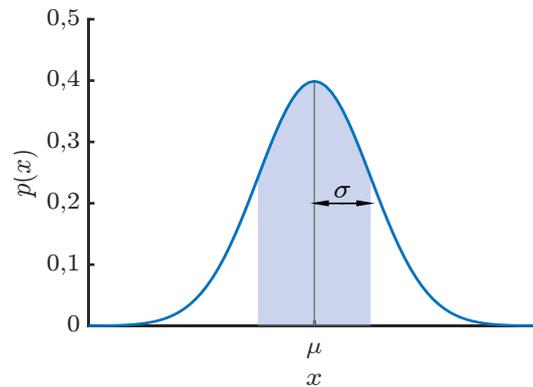


Abbildung C.1: Wahrscheinlichkeitsdichte einer Standard-Normalverteilung mit Standardabweichung.

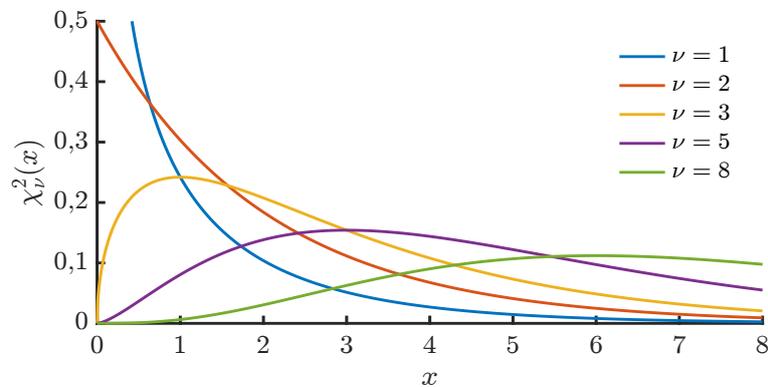


Abbildung C.2: Verlauf der Chi-Quadrat-Verteilung für verschiedene Freiheitsgrade.

In der vorliegenden Arbeit wird auch die Kurzschreibweise $\mathcal{N}(x|\mu, \Sigma) = \mathcal{N}(\mu, \Sigma)$ verwendet, wenn keine Unklarheit bezüglich der Zufallsvariablen herrscht.

C.3 Chi-Quadrat-Verteilung und Hypothesen-Test

Gegeben seien n Zufallsvariablen X_1, X_2, \dots, X_n , welche gemäß $\mathcal{N}(0, \sigma^2)$ normalverteilt sind. Dann gilt für die Summe der Quadrate $Y = \sum_{j=1}^n X_j^2$, dass diese Chi-Quadrat-verteilt sind mit n Freiheitsgraden. Die Chi-Quadrat-Verteilung (auch χ^2 -Verteilung) mit dem Freiheitsgrad n ist gegeben durch die WDF [338, S. 303 f.]

$$\chi_n^2(x) = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} \cdot x^{\frac{n}{2}-1} \cdot \exp\left(-\frac{x}{2}\right) \quad (\text{C.12})$$

Hierbei ist $\Gamma(\cdot)$ die Gamma-Funktion. Der Erwartungswert der Chi-Quadrat-Verteilung ist

$$\mathbb{E}\{\chi_n^2\} = n, \quad (\text{C.13})$$

daher sollte für eine Chi-Quadrat-verteilte Größe ungefähr $\chi_n^2/n \approx 1$ gelten. Der Verlauf der Chi-Quadrat-Verteilung für verschiedene Freiheitsgrade ist in Abb. C.2 gezeigt.

Liegt eine Messreihe aus n Realisierungen einer normalverteilten Größe vor, so ist deren Mahalanobis-Distanz (siehe (6.24)) Chi-Quadrat-verteilt [190, S. 57]. Dieser Umstand ist beispielsweise für die Konsistenztests basierend auf dem NEES und NIS aus Kapitel 4.1.5 nützlich. Mittels eines Hypothesentests kann eine statistische Aussage darüber getroffen werden, ob die betrachtete Stichprobe Chi-Quadrat-verteilt ist und damit die Schätzung konsistent. Dann gilt die Nullhypothese \mathcal{H}_0 , dass der NEES ϵ_k einer Stichprobe aus N_{MC} Monte-Carlo-Durchläufen Chi-Quadrat-verteilt ist mit dem Freiheitsgrad $n \cdot N_{\text{MC}}$, wobei n die Ordnung des Systems ausdrückt [190, S. 234 f.]. Da es sich um Zufallsgrößen handelt, kann der Mittelwert des NEES $\bar{\epsilon}_k$ aus der konkreten Stichprobe von $n \cdot N_{\text{MC}}$ abweichen. Die Nullhypothese wird jedoch akzeptiert, wenn $\bar{\epsilon}_k$ innerhalb eines Akzeptanzintervalls liegt. Es ergibt sich die bedingte Wahrscheinlichkeit dafür, dass – unter der Annahme, dass \mathcal{H}_0 gültig ist – der mittlere NEES im Akzeptanzintervall liegt als

$$P(r_1 \leq \bar{\epsilon}_k \leq r_2 | \mathcal{H}_0) = 1 - \alpha. \quad (\text{C.14})$$

Hierfür ist ein geeignetes Signifikanzniveau α zu wählen, mit welcher Wahrscheinlichkeit Abweichungen von der Nullhypothese toleriert werden. Ein Wert von $\alpha = 0,05$ beispielsweise entspricht einer Wahrscheinlichkeit von 95 %, dass $\bar{\epsilon}_k$ einer zufälligen Stichprobe innerhalb des Akzeptanzintervalls liegt. Die Intervallgrenzen r_1, r_2 können entsprechenden Tabellen entnommen werden (siehe beispielsweise [190, S. 84]). Zu beachten ist, dass aufgrund der Verzerrtheit der Chi-Quadrat-Verteilung die untere und obere Intervallgrenze nicht symmetrisch um den Erwartungswert liegen [190, S. 83]. Je größer die Stichprobe ist (also je größer N_{MC} ist), desto enger liegen die Intervallgrenzen, weil die Schwankungsbreite innerhalb der Stichprobe abnimmt. Hedderich und Sachs [338, S. 479] empfehlen eine Stichprobengröße von mehr als 40. Im Rahmen dieser Arbeit wird jedoch aus Gründen des Rechenaufwands $N_{\text{MC}} = 30$ gewählt.

C.4 Student-t-Verteilung

Werden verrauschte Messdaten durch eine Normalverteilung beschrieben, treten Messwerte mit einer Distanz zum Erwartungswert von mehr als der dreifachen Standardabweichung mit einer Wahrscheinlichkeit von weniger als 0,3 % auf. Ist diese Annahme in der Realität nicht gegeben, kann mit der Student-t-Verteilung eine Verteilung zur Beschreibung des Messrauschens verwendet werden, bei welchen weit vom Erwartungswert liegende Messwerte mit höherer Wahrscheinlichkeit auftreten. Die WDF wird deshalb auch als *heavy-tailed* bezeichnet.

Die Student-t-Verteilung wird im univariaten Fall mit $p(x) = t(x | \mu, \sigma^2, \nu)$ notiert. Ihre Wahrscheinlichkeitsdichte ist für $\mathbf{x} \in \mathbb{R}^{n \times 1}$ gegeben durch [314, S. 580 f.]

$$p(\mathbf{x}) = t(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma}, \nu) = \frac{\Gamma(\frac{\nu+n}{2})}{\Gamma(\frac{\nu}{2}) \sqrt{\nu^n \pi^n \det\{\boldsymbol{\Sigma}\}}} \left(1 + \frac{1}{\nu} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})\right)^{-\frac{\nu+n}{2}}. \quad (\text{C.15})$$

Neben dem Lageparameter $\boldsymbol{\mu} \in \mathbb{R}^{n \times 1}$, und der Streuungsmatrix $\boldsymbol{\Sigma} \in \mathbb{R}^{n \times n}$ (im univariaten Fall dem Streuungsparameter σ^2) besitzt die Student-t-Verteilung als weiteren Parameter die Anzahl der Freiheitsgrade $\nu > 0$. Häufig wird auch vereinfachend vom Freiheitsgrad der Student-t-Verteilung gesprochen. Aus (C.15) ist ersichtlich, dass sich die Verteilung $t(\boldsymbol{\mu}, \boldsymbol{\Sigma}, \nu)$ für $\nu \rightarrow \infty$

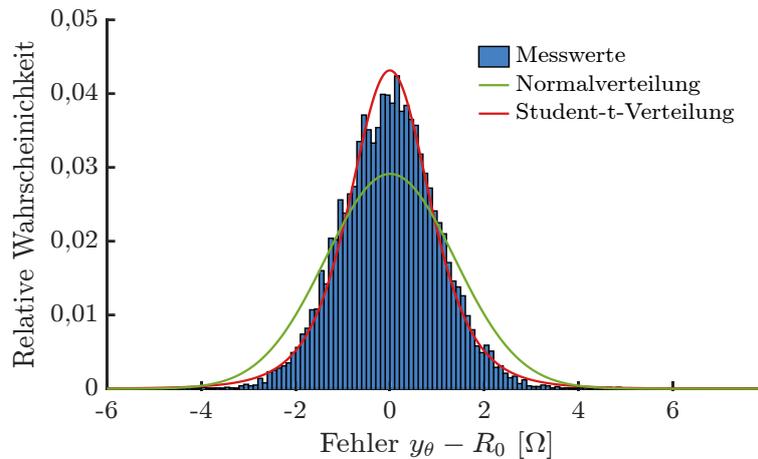


Abbildung C.3: Approximation einer mit Ausreißern durchsetzten Verteilung mit (a) Normalverteilung und (b) Student-t-Verteilung.

der Normalverteilung $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ beliebig annähert [308, S. 691 f.]. Der Erwartungswert einer Student-t-Verteilung ist nur für $\nu > 1$ definiert und beträgt

$$\mathbb{E}\{\boldsymbol{x}\} = \boldsymbol{\mu} \quad \text{für } \nu > 1. \quad (\text{C.16})$$

Die Kovarianzmatrix ist

$$\text{Var}\{\boldsymbol{x}\} = \frac{\nu}{\nu - 2} \boldsymbol{\Sigma} \quad \text{für } \nu > 2. \quad (\text{C.17})$$

Für $\nu \leq 2$ ist die Varianz bzw. Kovarianz nicht definiert.

Die Eignung der Student-t-Verteilung ein mit Messausreißern durchsetztes Signal zu beschreiben, soll anhand eines einfachen synthetischen Beispiels demonstriert werden. Ausgangspunkt ist ein künstliches normalverteiltes Messrauschen, welches entsprechend der Standard-Normalverteilung folgt. Der Datensatz besteht aus 10000 Messdaten. Es werden nun 100 Messdaten stärker verrauscht, indem sie als normalverteilt mit einer Standardabweichung angenommen werden, welche um den Faktor 10 höher ist als die übrigen Messdaten. Damit enthält der Datensatz nun mit einem geringen Anteil von 1% Messausreißer. Ein Histogramm des Datensatzes ist in Abb. C.3 dargestellt. In einem zweiten Schritt wird überprüft, inwiefern sich eine Normalverteilung bzw. eine Student-t-Verteilung dazu eignet, das Messrauschen des Datensatzes zu beschreiben. Hierfür werden die Parameter der Verteilungen durch die MATLAB-Funktion `fitdist` anhand der Daten mit dem Maximum-Likelihood-Verfahren bestimmt. Die resultierenden WDFs sind in Abb. C.3 ebenfalls gezeigt. Es ist ersichtlich, dass schon der geringe Anteil an Ausreißern innerhalb des Datensatzes dazu führt, dass diese nicht mehr durch eine Normalverteilung modelliert werden können. Die gefundenen Parameter unterschätzen das Auftreten kleiner Messfehler, um die Wahrscheinlichkeit größerer Messfehler besser zu modellieren. Dagegen bildet die gefundene Student-t-Verteilung das Messrauschen in sehr guter Näherung ab. Sie ist daher besser geeignet, stark verrauschte Messdaten zu beschreiben, für die keine Normalverteilung angenommen werden kann.

Für die lineare Transformation $\mathbf{Ax} + \mathbf{b}$ einer Student-t-Zufallsvariablen $\mathbf{x} \in \mathbb{R}^{n \times 1}$ mit $\mathbf{A} \in \mathbb{R}^{n \times n}$, $\mathbf{b} \in \mathbb{R}^{n \times 1}$ gilt analog zur Normalverteilung [310, S. 108 f.]

$$p(x) = t(x|\boldsymbol{\mu}, \boldsymbol{\Sigma}, \nu) \Rightarrow p(\mathbf{Ax} + \mathbf{b}) = t(\mathbf{Ax} + \mathbf{b}|\mathbf{A}\boldsymbol{\mu} + \mathbf{b}, \mathbf{A}\boldsymbol{\Sigma}\mathbf{A}, \nu). \quad (\text{C.18})$$

Anhand des Student-t-verteilten Zufallsvektors \mathbf{z}

$$\mathbf{z} = \begin{bmatrix} \mathbf{x} \\ \mathbf{y} \end{bmatrix}, \quad p(\mathbf{z}) = t(\mathbf{z}|\boldsymbol{\mu}, \boldsymbol{\Sigma}, \nu), \quad (\text{C.19})$$

welcher aus den Teilvektoren $\mathbf{x} \in \mathbb{R}^{n_x} \times 1$ und $\mathbf{y} \in \mathbb{R}^{n_y} \times 1$ besteht, können einige Zusammenhänge der Normalverteilung auf die Student-t-Verteilung übertragen werden. Für die Parameter der zusammengesetzten WDF gilt

$$\boldsymbol{\mu} = \begin{bmatrix} \boldsymbol{\mu}_x \\ \boldsymbol{\mu}_y \end{bmatrix}, \quad \begin{bmatrix} \boldsymbol{\Sigma}_{xx} & \boldsymbol{\Sigma}_{xy} \\ \boldsymbol{\Sigma}_{yx} & \boldsymbol{\Sigma}_{yy} \end{bmatrix}, \quad (\text{C.20})$$

wobei aufgrund der Symmetrie $\boldsymbol{\Sigma}_{xy} = \boldsymbol{\Sigma}_{yx}$ ist. Die bedingte Randdichte für \mathbf{x} ist dann

$$p(\mathbf{x}) = t(\mathbf{x}|\boldsymbol{\mu}_x, \boldsymbol{\Sigma}_{xx}, \nu) \quad (\text{C.21})$$

und es lassen sich die Parameter der bedingten Dichte $p(\mathbf{x}|\mathbf{y}) = t(\mathbf{x}|\boldsymbol{\mu}_{x|y}, \boldsymbol{\Sigma}_{x|y}, \nu_{x|y})$ finden, wenn \mathbf{y} gegeben ist [311, S. 109].

$$\boldsymbol{\mu}_{x|y} = \boldsymbol{\mu}_x + \boldsymbol{\Sigma}_{xy}\boldsymbol{\Sigma}_{yy}^{-1}(\mathbf{y} - \boldsymbol{\mu}_y) \quad (\text{C.22a})$$

$$\boldsymbol{\Sigma}_{x|y} = \frac{\nu + (\mathbf{y} - \boldsymbol{\mu}_y)^T \boldsymbol{\Sigma}_{yy}^{-1} (\mathbf{y} - \boldsymbol{\mu}_y)}{\nu + n_y} (\boldsymbol{\Sigma}_{xx} - \boldsymbol{\Sigma}_{xy}\boldsymbol{\Sigma}_{yy}^{-1}\boldsymbol{\Sigma}_{yx}) \quad (\text{C.22b})$$

$$\nu_{x|y} = \nu + n_y \quad (\text{C.22c})$$

Es fällt auf, dass sich die Form der resultierenden WDF gegenüber den Ausgangsdichten verändert hat, da sich der Freiheitsgrad um die Länge des Zufallsvektors \mathbf{y} erhöht.

D Weighted-Least-Squares-Verfahren

Die folgende Darstellung des WLS-Verfahrens und die Herleitung von dessen Lösung beruht zu großen Teilen auf den Werken von Isermann und Münchhof [73] sowie Strutz [318]. Es handelt sich hierbei um eine Erweiterung der Methode der kleinsten Fehlerquadrate. Gegeben sei eine Beobachtung y_k eines Zustands \mathbf{x}_k , wobei beide Größen durch die Modellfunktion $f(\cdot|\mathbf{a})$ miteinander in Beziehung stehen

$$y_k = f(\mathbf{x}_k|\mathbf{a}) + r_k. \quad (\text{D.1})$$

Die Modellfunktion weist die unbekannt Parameter \mathbf{a} auf, die es zu bestimmen gilt. Weiterhin ist die Messung von einem zufälligen Fehler r überlagert. Es wird die Annahme getroffen, dass der Erwartungswert des stochastischen Fehlerrauschens null ist, der Fehler also mittelwertfrei ist. Hat der Parametervektor die Länge N , so sind mindestens $K \geq N$ linear unabhängige Beobachtungen $\{\mathbf{x}_k, y_k\}$ mit $k = 1, \dots, K$ notwendig, um eine eindeutige Lösung für \mathbf{a} zu erhalten. Andernfalls ist das System unterbestimmt. In aller Regel sind jedoch deutlich mehr als N Beobachtungen vorhanden. Der Index k muss sich nicht zwangsläufig auf Zeitpunkte beziehen – es können auch K unabhängige Messungen einer Größe vorliegen. Die Methode der kleinsten Fehlerquadrate minimiert in diesem Fall die Summe der quadratischen Fehler zwischen den Beobachtungen y_k und den berechneten Werten $f(\mathbf{x}_k|\mathbf{a})$ durch Wahl eines optimalen Parametervektors \mathbf{a} .

$$\mathbf{a} = \arg \min_{\mathbf{a}} \sum_{k=1}^K w_k (y_k - f(\mathbf{x}_k|\mathbf{a}))^2 \quad (\text{D.2})$$

In obenstehender Gleichung wurden die Beobachtungsfehler mit den Gewichten w_k unterschiedlich stark gewertet. Diese Gewichtung gibt dem WLS-Verfahren seinen Namen. Das Gewicht w_k kann beispielsweise die spezielle Messunsicherheit der Beobachtung $\{\mathbf{x}_k, y_k\}$ ausdrücken. Im Fall der modellbasierten Sensordatenfusion wird so das Rauschen der Zellsensoren berücksichtigt.

Für die Herleitung der Lösung des WLS-Verfahrens werden die K Gleichungen in Vektorschreibweise zusammengefasst. Hierbei entspricht \mathbf{y} dem Spaltenvektor der abhängigen Beobachtungen, \mathbf{x}_k sei ein Zeilenvektor der unabhängigen Beobachtung zum Zeitpunkt k . Weiterhin gelte die Annahme, dass die Funktion f linear bezüglich des Parametervektors \mathbf{a} ist. Dies ermöglicht es, die Funktion mithilfe der Jacobi-Matrix $\mathbf{J} \in \mathbb{R}^{K \times N}$ zu linearisieren.

$$\mathbf{J} = \begin{bmatrix} \frac{\partial f(\mathbf{x}_1|\mathbf{a})}{\partial a_1} & \frac{\partial f(\mathbf{x}_1|\mathbf{a})}{\partial a_2} & \cdots & \frac{\partial f(\mathbf{x}_1|\mathbf{a})}{\partial a_N} \\ \frac{\partial f(\mathbf{x}_2|\mathbf{a})}{\partial a_1} & \frac{\partial f(\mathbf{x}_2|\mathbf{a})}{\partial a_2} & \cdots & \frac{\partial f(\mathbf{x}_2|\mathbf{a})}{\partial a_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f(\mathbf{x}_K|\mathbf{a})}{\partial a_1} & \frac{\partial f(\mathbf{x}_K|\mathbf{a})}{\partial a_2} & \cdots & \frac{\partial f(\mathbf{x}_K|\mathbf{a})}{\partial a_N} \end{bmatrix} \quad (\text{D.3})$$

Die Suche nach dem optimalen \mathbf{a} lässt sich nun als Minimierung einer Kostenfunktion auffassen, wobei das globale Minimum der Kostenfunktion V

$$V = (\mathbf{y} - \mathbf{J}\mathbf{a})^T \mathbf{W} (\mathbf{y} - \mathbf{J}\mathbf{a}) \quad (\text{D.4})$$

der Lösung mit dem kleinsten gewichteten Fehlerquadrat entspricht. Die Matrix \mathbf{W} ist eine Diagonalmatrix, welche mit den Gewichten w_1, w_2, \dots, w_K auf der Hauptdiagonalen besetzt ist. Das Minimum der Kostenfunktion wird ermittelt, indem die erste Ableitung bezüglich \mathbf{a} gleich null gesetzt wird.

$$0 \stackrel{!}{=} \frac{\partial V}{\partial \mathbf{a}} = \frac{\partial}{\partial \mathbf{a}} (\mathbf{y} - \mathbf{J}\mathbf{a})^T \mathbf{W} (\mathbf{y} - \mathbf{J}\mathbf{a}) \quad (\text{D.5a})$$

$$= \frac{\partial}{\partial \mathbf{a}} (\mathbf{y}^T \mathbf{W} \mathbf{y} - 2\mathbf{a}^T \mathbf{J}^T \mathbf{W} \mathbf{y} + \mathbf{a}^T \mathbf{J}^T \mathbf{W} \mathbf{J} \mathbf{a}) \quad (\text{D.5b})$$

$$= -2\mathbf{J}^T \mathbf{W} \mathbf{y} + 2\mathbf{J}^T \mathbf{W} \mathbf{J} \mathbf{a} \quad (\text{D.5c})$$

Durch einfaches Umformen erhält man die Lösung für die gesuchten Parameter \mathbf{a} zu

$$\mathbf{J}^T \mathbf{W} \mathbf{y} = \mathbf{J}^T \mathbf{W} \mathbf{J} \mathbf{a} \quad (\text{D.6a})$$

$$\Rightarrow \mathbf{a} = (\mathbf{J}^T \mathbf{W} \mathbf{J})^{-1} \mathbf{J}^T \mathbf{W} \mathbf{y}. \quad (\text{D.6b})$$

Voraussetzung für die Existenz einer Lösung ist, dass $\mathbf{J}^T \mathbf{W} \mathbf{J}$ invertierbar ist. Die hinreichende Bedingung, dass die zweite Ableitung ungleich null ist, kann an dieser Stelle vernachlässigt werden, wenn $(\mathbf{J}^T \mathbf{W} \mathbf{J})$ positiv definit ist. Dies ist der Fall, wenn der Ausdruck den Rank N hat. Man spricht an dieser Stelle auch von *ausreichender Anregung* (engl. *persistent excitation*) durch \mathbf{X} . Es ist zu beachten, dass bei dem vorgestellten WLS-Verfahren nur ein Messfehler von \mathbf{y} berücksichtigt wurde. Sind auch die Zustände \mathbf{X} fehlerbehaftet, müssen Verfahren wie z. B. *Total Least Squares* oder *Orthogonal Least Squares* eingesetzt werden. Im Falle der modellbasierten Sensordatenfusion kann jedoch von einer ausreichend genauen Schätzung des Ladezustands und der Innenwiderstände ausgegangen werden.

E Zusätzliche Abbildungen und Diagramme

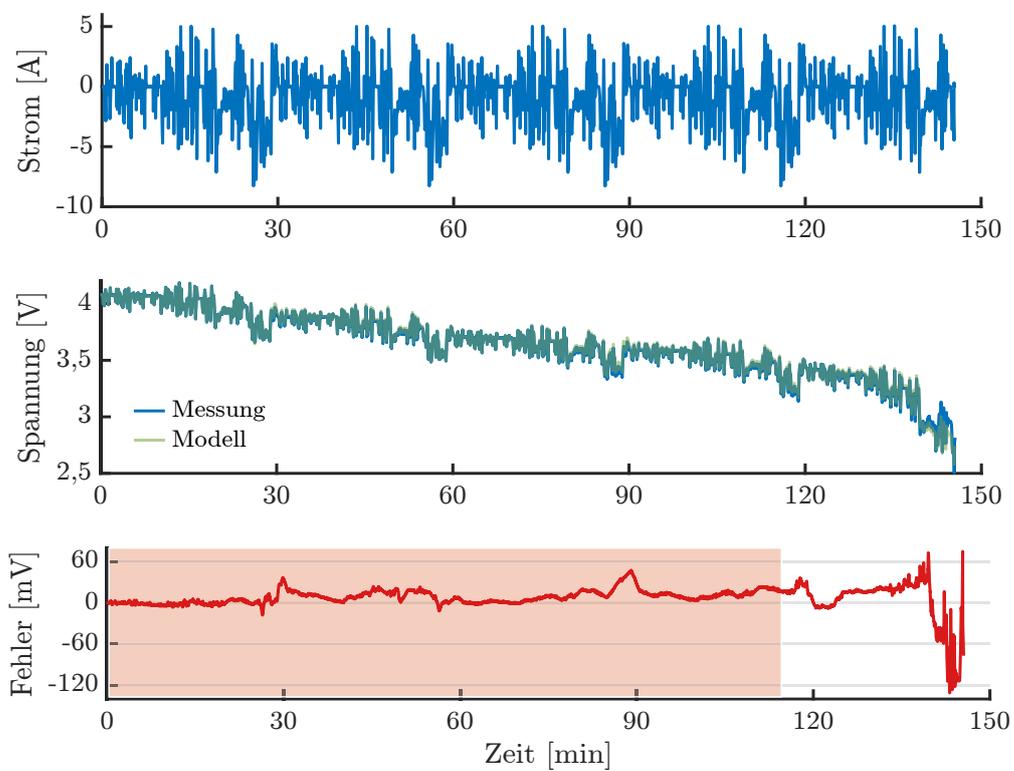


Abbildung E.1: Resultat der Validierung des Modells mit den ermittelten Parametern für eine Zelle anhand des WLTP-Profiles bei 25°C Umgebungstemperatur. Der rot hinterlegte Bereich kennzeichnet einen Ladezustand von über 20%.

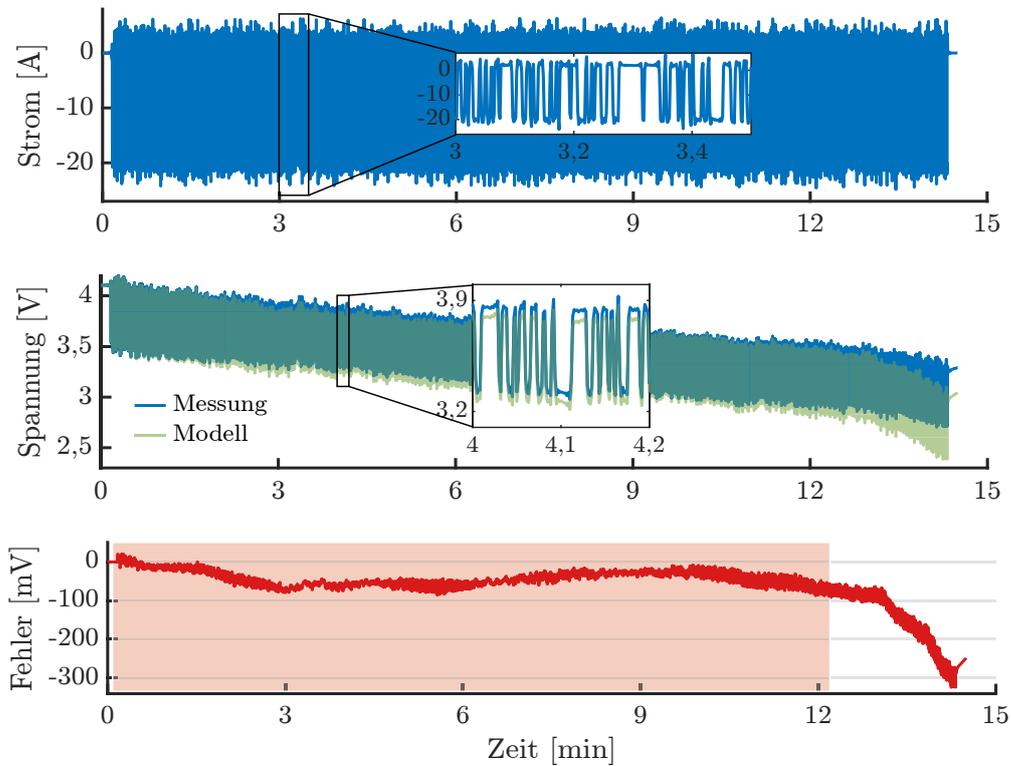


Abbildung E.2: Resultat der Validierung des Modells mit den ermittelten Parametern für eine Zelle anhand des PRBS-Profiles bei 25 °C Umgebungstemperatur. Der rot hinterlegte Bereich kennzeichnet einen Ladezustand von über 20 %.

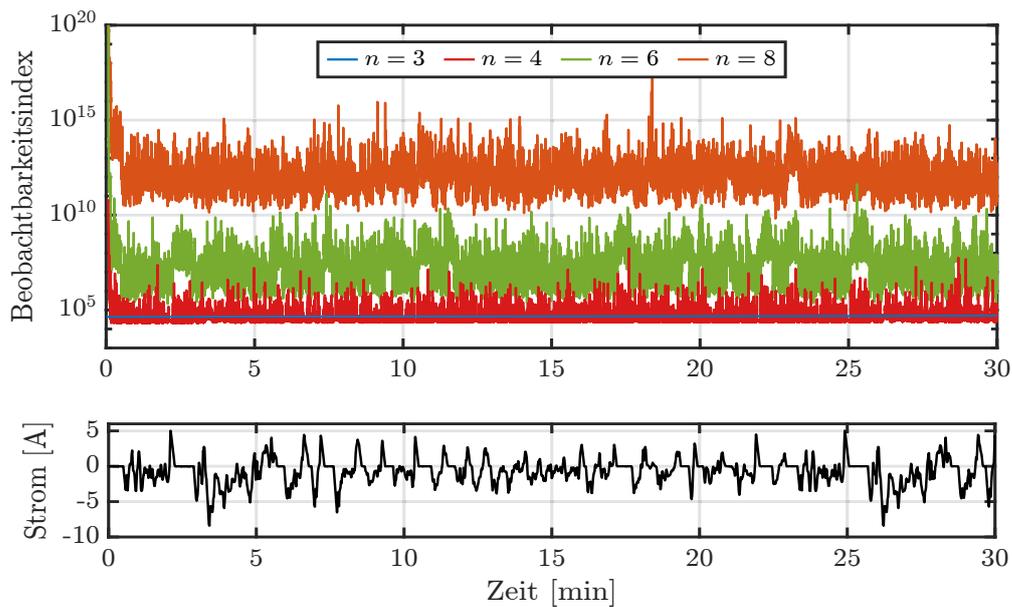


Abbildung E.3: Beobachtbarkeitsindex c für verschiedene Ordnungen n des Systems über den Verlauf eines UDDS-Fahrzyklus.

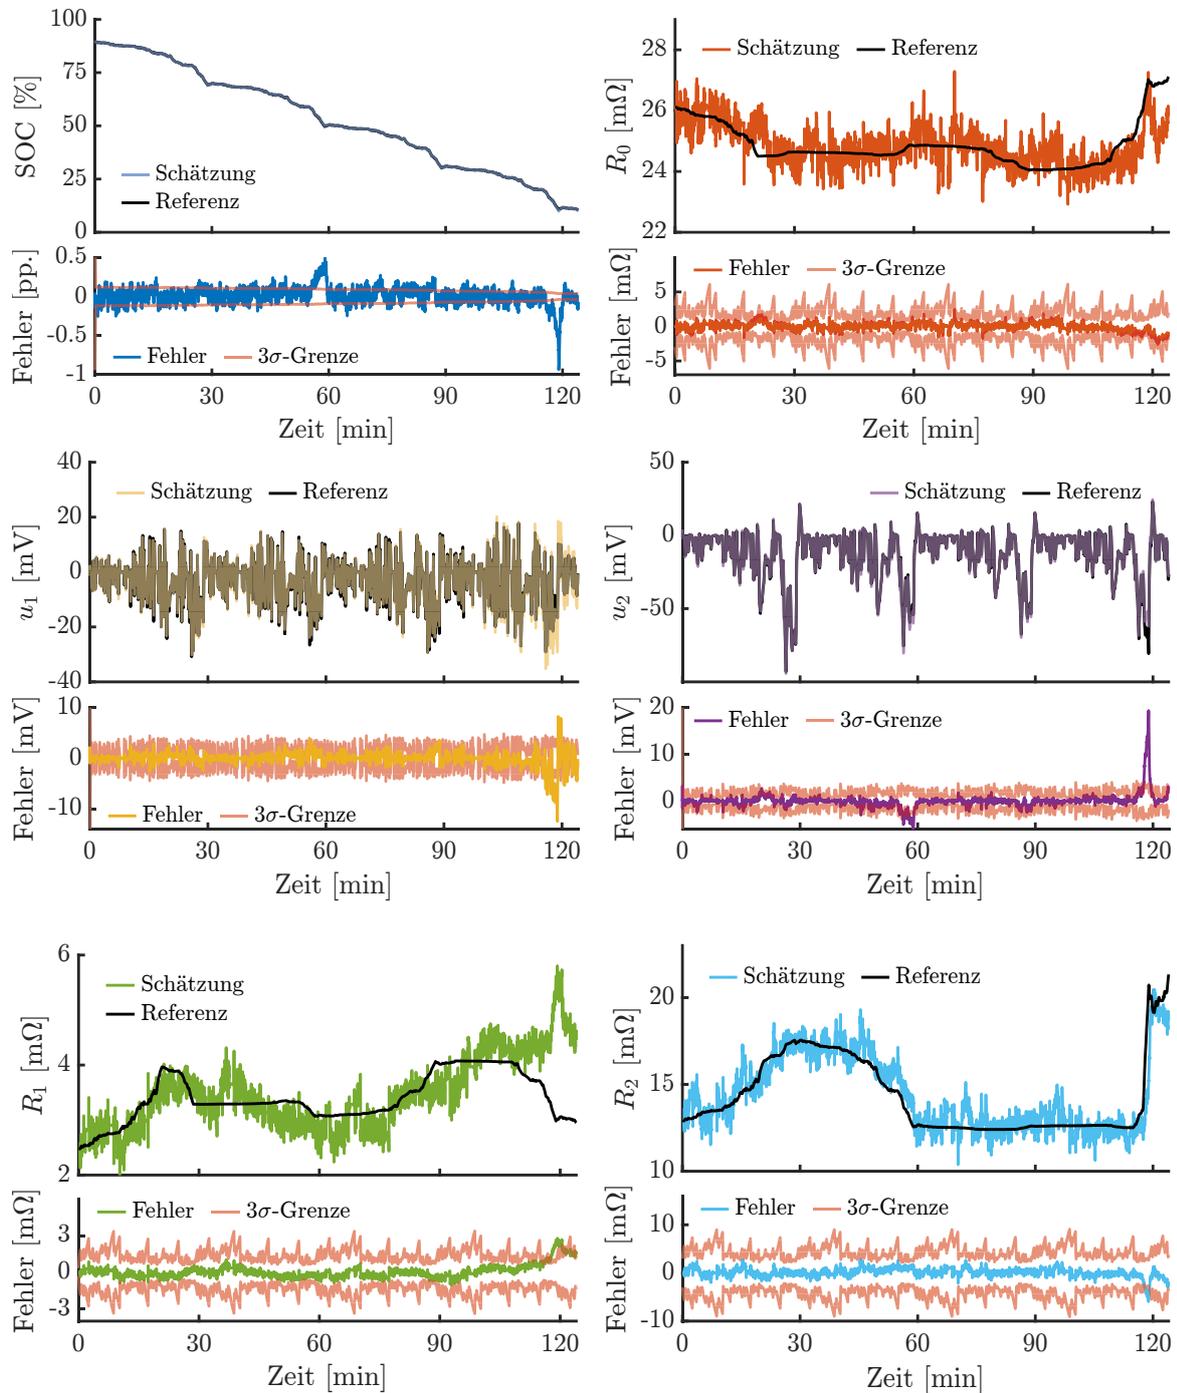


Abbildung E.4: Ergebnisse der Zustands- und Parameterschätzung mit simulativen Daten (Stromprofil: WLTP).

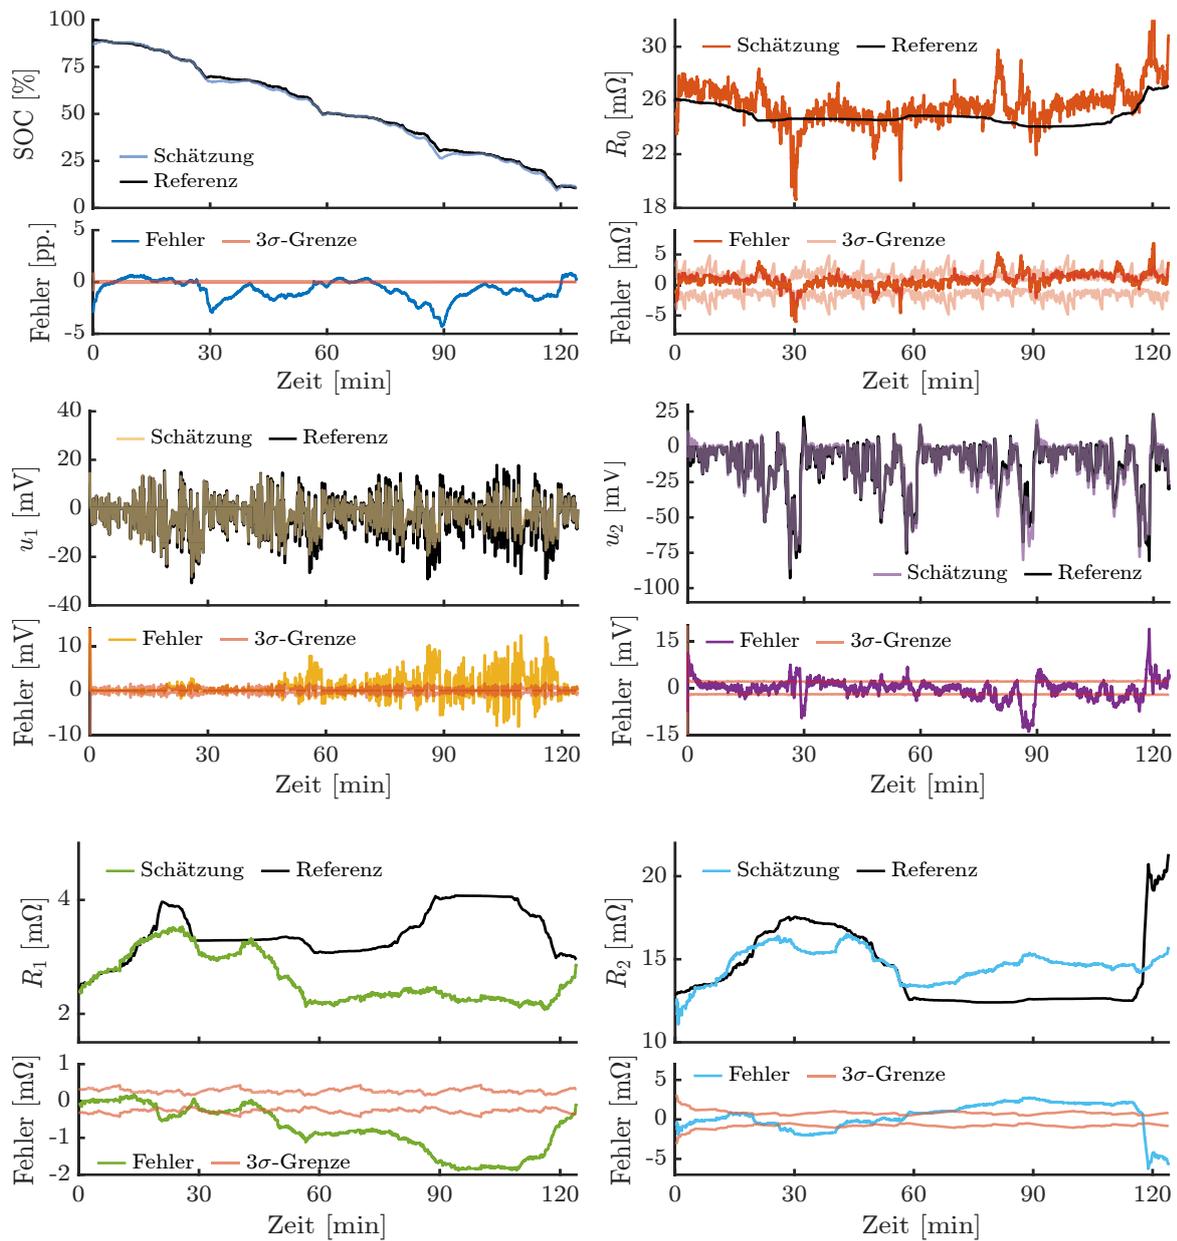


Abbildung E.5: Ergebnisse der Zustands- und Parameterschätzung mit realen Messdaten (Stromprofil: WLTP).

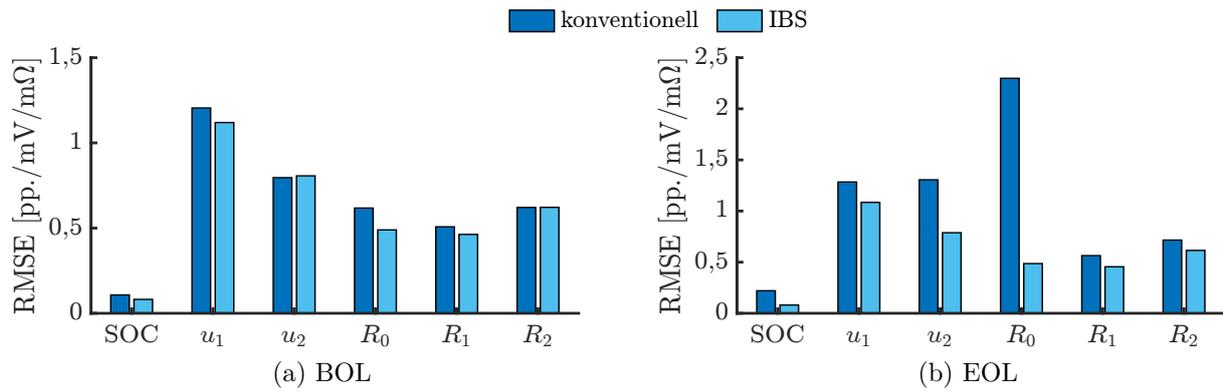


Abbildung E.6: Simulative Ergebnisse der Zustands- und Parameterschätzung mit herkömmlicher Strommessung und Zellstrom-Sensoren. Der RMSE ist der Mittelwert aus den zwölf Zellen des untersuchten Batteriemoduls (Stromprofil: WLTP). Der Fehler des SOC's ist in Prozentpunkten (pp.) angegeben, der beider Überspannungen in Millivolt und der Widerstände in Milliohm.

Abkürzungsverzeichnis

ADF Assumed-Density-Filter

Ah Amperestunden

AKF Adaptive-Kalman-Filter

ANN Künstliches neuronales Netz (engl. *artificial neural network*)

BEV Batterie-Elektrofahrzeug, (engl. *battery electric vehicle*)

BOL Lebensdauerbeginn (engl. *begin of life*)

BMS Batteriemanagementsystem

CAN Controlled-Area-Network

CC Konstantstrom (engl. *constant current*)

CCCV Konstantstrom-Konstantspannung (engl. *constant current constant voltage*)

CV Konstantspannung (engl. *constant voltage*)

CDKF Central-Difference-Kalman-Filter

DB Differenz-basierte

DEKF Dual-Extended-Kalman-Filter

DFT Diskrete Fourier-Transformation

DKF Dual-Kalman-Filter

DP Dual-Polarization

DST Dynamic-Stress-Test

ECM Ersatzschaltbildmodell (engl. *equivalent circuit model*)

EIS elektrochemische Impedanzspektroskopie

EKF Extended-Kalman-Filter

EM Expectation-Maximization

EOL Lebensdauerende (engl. *end of life*)

FUDS Federal-Urban-Driving-Cycle

GA Genetischer Algorithmus

GSM Gesamtstrommessung

HPPC Hybrid-Pulse-Power-Characterization

IBS Intelligentes Batteriesystem

JEKF Joint-Extended-Kalman-Filter

- JKF** Joint-Kalman-Filter
- KL** Kullback-Leibler
- LCO** Lithium-Cobaltoxid
- LFP** Lithium-Eisenphosphat
- LTO** Lithium-Titanat-Oxid
- MAE** Mean-Absolute-Error
- NCA** Nickel-Cobalt-Aluminium
- MISO** Multiple-Input-Single-Output
- MLE** Maximum-Likelihood-Estimation
- MOSFET** Metall-Oxid-Halbleiter-Feldeffekttransistor
- MSE** Mean-Squared-Error
- MTTF** Mittlere Betriebszeit bis zum Ausfall (engl. *mean time to failure*)
- MWB** Mittelwert-basierte
- MWSM** Mittelwert-Strommessung
- NEES** Normierter quadratischer Schätzfehler (engl. *normalized estimation error squared*)
- NEFZ** Neuer Europäischer Fahrzyklus
- NIS** Normierte quadratische Innovationssequenz (engl. *normalized innovation squared*)
- NMC** Lithium-Nickel-Mangan-Cobalt-Oxid
- OCV** Leerlaufspannung (engl. *open circuit voltage*)
- ORKF** Outlier-Robust-Kalman-Filter
- P2D** Pseudo-Two-Dimensional
- PE** Permanente Anregung (engl. *persistent excitation*)
- PNGV** Partnership for New Generation of Vehicles
- pp.** Prozentpunkte
- PRBS** Pseudo-Random-Binary-Sequence
- PSO** Partikelschwarm-Optimierung
- PWM** Pulsweitenmodulation
- RBS** Rekonfigurierbares Batteriesystem
- RLS** Recursive-Least-Squares
- RMS** Root-Mean-Squared
- RMSE** Root-Mean-Squared-Error

RMSRE Root-Mean-Squared-Relative-Error
ROSE Rapid-Ongoing-Stochastic-Covariance-Estimation
RRMSE Relative-Root-Mean-Squared-Error
SD Standardabweichung (engl. *standard deviation*)
SDF Sensordatenfusion
SE Standardfehler (engl. *standard error*)
SEI *solid electrolyte interface*
SGKF Stenlund-Gustafsson-Kalman-Filter
SISO Single-Input-Single-Output
SO Surrogate-Optimization
SOC Ladezustand (engl. *state of charge*)
SOH Gesundheitszustand (engl. *state of health*)
SPM Single-Particle-Model
SRKF Square-Root-Kalman-Filter
SPKF Sigma-Point-Kalman-Filter
TKF Student-t-Kalman-Filter
TLS Total-Least-Squares
UDDS Urban-Dynamometer-Driving-Schedule
UKF Unscented-Kalman-Filter
UT Unscented-Transformation
VB Variational-Bayes
WDF Wahrscheinlichkeitsdichtefunktion
WLS Weighted-Least-Squares
WLTP Worldwide-Harmonized-Light-Duty-Vehicles-Test-Procedure

Symbolverzeichnis

Physikalische Größen

η	Coulombsche Effizienz [%]
ω	Kreisfrequenz [1/s]
Φ	Leistungsdichte [dB · W/Hz]
a	Beschleunigung [m/s ²]
C	Elektrische Kapazität [F]
f	Frequenz [Hz]
i	Strom [A]
P	Leistung [W]
Q	Kapazität einer Batteriezelle [Ah]
R	Widerstand [Ω]
t	Zeit [s]
u	Spannung [V]
v	Geschwindigkeit [m/s]

Modellbildung

τ	Zeitkonstante eines RC-Glieds [s]
$\mathfrak{E}, \mathfrak{E}'$	Verknüpfungs-Matrizen des Batteriesystemmodells
f_g	Grenzfrequenz eines RC-Glieds [Hz]
$\mathfrak{F}, \mathfrak{F}'$	Verknüpfungs-Matrizen des Batteriesystemmodells
K	Anzahl an Schritten einer Simulation
N_{RC}	Anzahl an RC-Gliedern im Ersatzschaltbildmodell
\mathcal{P}	Anzahl paralleler Zellen im Batteriesystem
$\mathfrak{R}, \mathfrak{R}', \mathfrak{G}$	Widerstands-Matrizen des Batteriesystemmodells
\mathcal{S}	Anzahl serieller Zellen im Batteriesystem
t_s	Schrittweite des diskreten Systems [s]
u_j	Polarisationsspannung des j -ten RC-Glieds [V]
u_{OC}	Leerlaufspannung, Leerlaufspannung (engl. <i>open circuit voltage</i>) [V]
\mathcal{Z}	Gesamtzahl an Zellen im Batteriesystem

Zustands- und Parameterschätzung

α	Koeffizient des Anti-Windup
α	Koeffizient des Unscented-Kalman-Filters
β	Koeffizient des Unscented-Kalman-Filters

γ	Koeffizient des Unscented-Kalman-Filters
$\mathbf{\Gamma}$	Eingangsmatrix des kontinuierlichen Systems im Zustandsraum
$\boldsymbol{\theta}$	Parametervektor
λ	Vergessensfaktor
Λ	Prozessrauschen des Outlier-Robust-Kalman-Filters
ς	Beobachtbarkeitsindex
Φ	Kontinuierliche Systemmatrix im Zustandsraum
Ψ	Durchgriffsmatrix des kontinuierlichen Systems im Zustandsraum
\mathbf{A}	Systemmatrix im Zustandsraum
\mathbf{B}	Eingangsmatrix im Zustandsraum
\mathbf{C}	Ausgangsmatrix im Zustandsraum
d	Residuum der Zustandsschätzung
\mathbf{D}	Durchgriffsmatrix im Zustandsraum
e	Innovation der Zustandsschätzung
$f(\mathbf{x}, u)$	Nichtlineare Systemfunktion im Zustandsraum
h	Parameter des Central-Difference-Kalman-Filters
$h(\mathbf{x}, u)$	Nichtlineare Messfunktion im Zustandsraum
\mathbf{H}	Ausgangsmatrix des kontinuierlichen Systems im Zustandsraum
\mathbf{K}	Kalman-Verstärkung
\mathbf{L}	Luenberger-Verstärkung
n	Modellordnung, Anzahl an Zustandsgrößen
\mathcal{O}_B	Beobachtbarkeitsmatrix
\mathcal{O}_S	Strukturelle Beobachtbarkeitsmatrix
p	Anzahl an Systemeingängen
\mathbf{P}	Kovarianzmatrix der Schätzung bzw. des Schätzfehlers
q	Anzahl an Systemausgängen
\mathbf{q}	Prozessrauschen
\mathbf{q}	Zeilenvektor der Lie-Derivierten
\mathbf{Q}	Kovarianzmatrix des Prozessrauschens
r	Messrauschen
\mathbf{R}	Kovarianzmatrix des Messrauschens
\mathbf{S}	Kovarianzmatrix der Innovation
\mathbf{S}_d	Kovarianzmatrix des Residuums
u	Systemeingang im Zustandsraum
\mathbf{x}	Zustandsvektor
y	Messsignal, Systemausgang im Zustandsraum
\mathbf{Z}	Matrix der Parameterschranken

Stochastik

α	Signifikanzlevel des Hypothesen-Tests
$\alpha^{(m)}, \alpha^{(e)}$	Gewichte des Sigma-Point-Kalman-Filters
δ	Normierte quadratische Innovationssequenz (engl. <i>normalized innovation squared</i>)
ε	Fehler der Zustandsschätzung
ϵ	Normierter quadratischer Schätzfehler (engl. <i>normalized estimation error squared</i>)
κ	Koeffizient der Parameterstreuung
λ	Skalierungsparameter des Unscented-Kalman-Filters
μ	Mittelwert
ν	Anzahl der Freiheitsgrade der Student-t-Verteilung
Ξ	Anzahl an Individuen in der Pareto-Menge des genetischen Algorithmus
ρ	Auto-Korrelation
σ	Standardabweichung
Σ	Kovarianzmatrix einer multivariaten Verteilung
$\chi^2(\cdot \nu)$	Chi-Quadrat-Verteilung
$\text{Cov}\{\cdot, \cdot\}$	Kovarianz
$\mathbb{E}\{\cdot\}$	Erwartungswert
$F_k^{\chi^2}$	Hilfsfunktion zur Konsistenzprüfung
\mathcal{H}_0	Null-Hypothese
L_f	Lie-Derivierte der Funktion f
\mathcal{L}	Log-Likelihood
N_{MC}	Anzahl an Monte-Carlo-Simulationen
$\mathcal{N}(\cdot \mu, \sigma^2)$	Normalverteilung
$p(\cdot), q(\cdot)$	Wahrscheinlichkeitsdichte-Funktionen
$P(\cdot)$	Wahrscheinlichkeitsfunktion
r_1, r_2	Akzeptanzintervalle des zweiseitigen Hypothesen-Tests
\mathcal{R}	Redundanz
$t(\cdot \mu, \sigma^2, \nu)$	Student-t-Verteilung
$\text{Var}\{\cdot\}$	(Ko-)Varianz
\mathbf{W}	Gewichtungsmatrix des WLS-Algorithmus

Fahrzeugmodell

η_{mot}	Kombinierter Wirkungsgrad von Motor und Getriebe im Antriebsfall [%]
η_{rek}	Kombinierter Rekuperations-Wirkungsgrad [%]
λ_{rot}	Drehmassenzuschlagsfaktor
ρ_{L}	Luftdichte = 1,2 kg/m ³
A	Fahrzeugstirnfläche [m ²]
c_{w}	Luftwiderstandsbeiwert

F_A	Antriebskraft [F]
F_B	Beschleunigungskraft [F]
F_L	Luftwiderstand [F]
F_R	Rollwiderstand [F]
f_R	Rollwiderstandskoeffizient
g	Erdbeschleunigung = 9,81 m/s ²
m_{Fzg}	Fahrzeuggewicht [kg]
P_A	Antriebsleistung [W]

Sonstige Größen

β	Bessel-Korrekturfaktor
$\Gamma(\cdot)$	Gamma-Funktion
δ	Dirac-Impuls
λ	Eigenwert einer Matrix
σ	Singulärwerte
a	Gesuchter Parameter im Weighted-Least-Squares-Verfahren
\mathbb{C}	Körper der komplexen Zahlen
D	Tastgrad der Pulsweitenmodulation
\mathcal{D}	Anzahl an Sensordefekten
g	Fitness-Funktion
G	Spektralkomponente als Ausgang des Goertzel-Algorithmus
I	Einheits-Matrix
J	Kostenfunktion
J	Jacobi-Matrix
$\text{KL}(\cdot \parallel \cdot)$	Kullback-Leibler-Divergenz
m	Mahalanobis-Distanz
M	Fensterlänge
\mathbb{R}	Körper der rationalen Zahlen
w	Crowding-Distance
\mathbf{x}	Unabhängige Messwerte im Weighted-Least-Squares-Verfahren
\mathbf{y}	Abhängige Messwerte im Weighted-Least-Squares-Verfahren

Mathematische Notation

\odot	Hadamard-Produkt
$\{a, b\}$	Menge bestehend aus a und b
$[a, b]$	Abgeschlossenes Intervall mit den Grenzen a und b
$ \cdot $	Betrag
$\lfloor \cdot \rfloor$	Abrundung auf die nächste Ganzzahl
$\lceil \cdot \rceil$	Aufrundung auf die nächste Ganzzahl
$\ \cdot\ $	Euklidische Norm eines Vektors

$\text{diag}\{\cdot\}$	Diagonal-Matrix
$\text{rank}\{\cdot\}$	Rang einer Matrix
$\text{spur}\{\cdot\}$	Spur
$\det\{\cdot\}$	Determinante einer Matrix
$[\cdot]^{-1}$	Inverse einer Matrix
$[\cdot]^+$	Moore-Penrose-Inverse bzw. Pseudoinverse einer Matrix
$[\cdot]^T$	Transponierte einer Matrix
$[\cdot]^*$	Komplex Konjugierte einer Matrix
$f^{(-1)}$	Umkehrfunktion der bijektiven Funktion f
$\frac{\partial f}{\partial x}$	Partielle Ableitung erster Ordnung der Funktion f nach x
\dot{x}	Zeitableitung von x

Diakritische Zeichen

$\tilde{\cdot}$	Messwert
$\hat{\cdot}$	Schätzwert
$\bar{\cdot}$	Fusionierter Wert, Mittelwert

Literaturverzeichnis

- [1] Canals Casals, L., Martinez-Laserna, E., Amante García, B. und Nieto, N. „Sustainability analysis of the electric vehicle use in Europe for CO2 emissions reduction“. In: *Journal of Cleaner Production* 127 (2016), Seiten 425–437. ISSN: 09596526. DOI: 10.1016/j.jclepro.2016.03.120.
- [2] Eberle, U. und Helmolt, R. von. „Sustainable transportation based on electric vehicle concepts: a brief overview“. In: *Energy & Environmental Science* 3.6 (2010), Seite 689. DOI: 10.1039/C001674H.
- [3] Lu, L., Han, X., Li, J., Hua, J. und Ouyang, M. „A review on the key issues for lithium-ion battery management in electric vehicles“. In: *Journal of Power Sources* 226 (2013), Seiten 272–288. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2012.10.060.
- [4] Waag, W., Fleischer, C. und Sauer, D. U. „Critical review of the methods for monitoring of lithium-ion batteries in electric and hybrid vehicles“. In: *Journal of Power Sources* 258 (2014), Seiten 321–339. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2014.02.064.
- [5] Rivera-Barrera, J., Muñoz-Galeano, N. und Sarmiento-Maldonado, H. „SoC Estimation for Lithium-ion Batteries: Review and Future Challenges“. In: *Electronics* 6.4 (2017), Seite 102. DOI: 10.3390/electronics6040102.
- [6] Adaikkappan, M. und Sathiyamoorthy, N. „Modeling, state of charge estimation, and charging of lithium-ion battery in electric vehicle: A review“. In: *International Journal of Energy Research* (2021). DOI: 10.1002/er.7339.
- [7] Shrivastava, P., Soon, T. K., Idris, M. Y. I. B. und Mekhilef, S. „Overview of model-based online state-of-charge estimation using Kalman filter family for lithium-ion batteries“. In: *Renewable and Sustainable Energy Reviews* 113 (2019), Seite 109233. ISSN: 13640321. DOI: 10.1016/j.rser.2019.06.040.
- [8] Kim, I.-S. „The novel state of charge estimation method for lithium battery using sliding mode observer“. In: *Journal of Power Sources* 163.1 (2006), Seiten 584–590. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2006.09.006.
- [9] Kim, T., Qiao, W. und Qu, L. „Online SOC and SOH estimation for multicell lithium-ion batteries based on an adaptive hybrid battery model and sliding-mode observer“. In: *IEEE Energy Conversion Congress and Exposition (ECCE), 2013*. Piscataway, NJ: IEEE, 2013, Seiten 292–298. ISBN: 978-1-4799-0336-8. DOI: 10.1109/ECCE.2013.6646714.
- [10] Li, W., Rentemeister, M. et al. „Digital twin for battery systems: Cloud battery management system with online state-of-charge and state-of-health estimation“. In: *Journal of Energy Storage* 30 (2020), Seite 101557. ISSN: 2352152X. DOI: 10.1016/j.est.2020.101557.
- [11] Shu, X., Li, G. et al. „An adaptive fusion estimation algorithm for state of charge of lithium-ion batteries considering wide operating temperature and degradation“. In: *Journal of Power Sources* 462 (2020), Seite 228132. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.228132.

- [12] He, W., Williard, N., Chen, C. und Pecht, M. „State of charge estimation for Li-ion batteries using neural network modeling and unscented Kalman filter-based error cancellation“. In: *International Journal of Electrical Power & Energy Systems* 62 (2014), Seiten 783–791. ISSN: 01420615. DOI: 10.1016/j.ijepes.2014.04.059.
- [13] Shi, Q.-S., Zhang, C.-H. und Cui, N.-X. „Estimation of battery state-of-charge using v-support vector regression algorithm“. In: *International Journal of Automotive Technology* 9.6 (2008), Seiten 759–764. ISSN: 1229-9138. DOI: 10.1007/s12239-\$-008\$-\$0090\$-\$x.
- [14] Campestrini, C., Keil, P., Schuster, S. F. und Jossen, A. „Ageing of lithium-ion battery modules with dissipative balancing compared with single-cell ageing“. In: *Journal of Energy Storage* 6 (2016), Seiten 142–152. ISSN: 2352152X. DOI: 10.1016/j.est.2016.03.004.
- [15] Rumpf, K., Rheinfeld, A. et al. „Influence of Cell-to-Cell Variations on the Inhomogeneity of Lithium-Ion Battery Modules“. In: *Journal of The Electrochemical Society* 165.11 (2018), A2587–A2607. ISSN: 0013-4651. DOI: 10.1149/2.0111811jes.
- [16] Paul, S., Diegelmann, C., Kabza, H. und Tillmetz, W. „Analysis of ageing inhomogeneities in lithium-ion battery systems“. In: *Journal of Power Sources* 239 (2013), Seiten 642–650. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.01.068.
- [17] Daowd, M., Omar, N., van den Bossche, P. und van Mierlo, J. „Passive and active battery balancing comparison based on MATLAB simulation“. In: *IEEE Vehicle Power and Propulsion Conference (VPPC), 2011*. Piscataway, NJ: IEEE, 2011, Seiten 1–7. ISBN: 978-1-61284-248-6. DOI: 10.1109/VPPC.2011.6043010.
- [18] Komsijska, L., Buchberger, T. et al. „Critical Review of Intelligent Battery Systems: Challenges, Implementation and Potential for Electric Vehicles“. In: *Energies* 14 (2021), Seiten 5988–5989. DOI: 10.3390/en14185989.
- [19] Liebhart, B., Komsijska, L. und Endisch, C. „Passive impedance spectroscopy for monitoring lithium-ion battery cells during vehicle operation“. In: *Journal of Power Sources* 449 (2020), Seite 227297. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2019.227297.
- [20] Liebhart, B., Diehl, S., Schneider, D., Endisch, C. und Kennel, R. „Enhancing the Cell Impedance Estimation of a Lithium-Ion Battery System with Embedded Power Path Switches“. In: *2021 Applied Power Electronics Conference (APEC) (2021)*. DOI: 10.1109/APEC42165.2021.9487173.
- [21] Liebhart, B., Diehl, S., Schmid, M., Endisch, C. und Kennel, R. „Improved Impedance Measurements for Electric Vehicles with Reconfigurable Battery Systems“. In: *2021 IEEE International Conference on Electrical and Electromechanical Energy Conversion (ECCE Asia)*. 2021. DOI: 10.1109/ECCE-Asia49820.2021.9479060.
- [22] Martiny, N., Geder, J., Wang, Y., Kraus, W. und Jossen, A. „Development of a thin-film thermocouple matrix for in-situ temperature measurement in a lithium ion pouch cell“. In: *IEEE sensors, 2013*. Piscataway, NJ: IEEE, 2013, Seiten 1–4. ISBN: 978-1-4673-4642-9. DOI: 10.1109/ICSENS.2013.6688485.
- [23] Mutyala, M. S. K., Zhao, J. et al. „In-situ temperature measurement in lithium ion battery by transferable flexible thin film thermocouples“. In: *Journal of Power Sources* 260 (2014), Seiten 43–49. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2014.03.004.

- [24] Helling, F., Gluck, J., Singer, A. und Weyh, T. „Modular multilevel battery (M2B) for electric vehicles“. In: *2016 18th European Conference*. 2016, Seiten 1–9. DOI: 10.1109/EPE.2016.7695480.
- [25] Engelhardt, J., Gabderakhmanova, T., Rohde, G. und Marinelli, M. „Reconfigurable Stationary Battery with Adaptive Cell Switching for Electric Vehicle Fast-Charging“. In: *2020 55th International Universities Power*. 2020, Seiten 1–6. DOI: 10.1109/UPEC49904.2020.9209774.
- [26] Hanzl, C., Hartmann, C. et al. „Current Commutation in a Switched Lithium–Ion Cell used in Cascaded Half–Bridge Multilevel Inverters“. In: *IET Power Electronics* (2021). ISSN: 1755-4535. DOI: 10.1049/pe12.12088.
- [27] Schmid, M., Gebauer, E., Hanzl, C. und Endisch, C. „Active Model-Based Fault Diagnosis in Reconfigurable Battery Systems“. In: *IEEE Transactions on Power Electronics* (2020), Seite 1. ISSN: 0885-8993. DOI: 10.1109/TPEL.2020.3012964.
- [28] Schmid, M., Gebauer, E. und Endisch, C. „Structural Analysis in Reconfigurable Battery Systems for Active Fault Diagnosis“. In: *IEEE Transactions on Power Electronics* (2021), Seite 1. ISSN: 0885-8993. DOI: 10.1109/TPEL.2021.3049573.
- [29] Goetz, S. M., Li, Z. et al. „Control of Modular Multilevel Converter With Parallel Connectivity—Application to Battery Systems“. In: *IEEE Transactions on Power Electronics* 32.11 (2017), Seiten 8381–8392. ISSN: 0885-8993. DOI: 10.1109/TPEL.2016.2645884.
- [30] Wei, Z., Zhao, J. et al. „Future smart battery and management: Advanced sensing from external to embedded multi-dimensional measurement“. In: *Journal of Power Sources* 489 (2021), Seite 229462. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2021.229462.
- [31] He, H., Xiong, R. und Guo, H. „Online estimation of model parameters and state-of-charge of LiFePO₄ batteries in electric vehicles“. In: *Applied Energy* 89.1 (2012), Seiten 413–420. ISSN: 03062619. DOI: 10.1016/j.apenergy.2011.08.005.
- [32] Tong, S. J., Same, A., Kootstra, M. A. und Park, J. W. „Off-grid photovoltaic vehicle charge using second life lithium batteries: An experimental and numerical investigation“. In: *Applied Energy* 104 (2013), Seiten 740–750. ISSN: 03062619. DOI: 10.1016/j.apenergy.2012.11.046.
- [33] Korthauer, R. *Handbuch Lithium-Ionen-Batterien*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. ISBN: 978-3-642-30652-5. DOI: 10.1007/978-3-642-30653-2.
- [34] Linden, D. und Reddy, T. B., Herausgeber. *Handbook of batteries*. 3. ed. McGraw-Hill handbooks. New York, NY: McGraw-Hill, 2002. ISBN: 0-07-135978-8.
- [35] Jossen, A. und Weydanz, W. *Moderne Akkumulatoren richtig einsetzen*. 1. Auflage. Neusäß: Ubooks-Verlag, 2006. ISBN: 3-937536-01-9.
- [36] Kurzweil, P. und Dietlmeier, O. *Elektrochemische Speicher: Superkondensatoren, Batterien, Elektrolyse-Wasserstoff, rechtliche Grundlagen*. Lehrbuch. Wiesbaden: Springer Vieweg, 2015. ISBN: 978-3-658-10900-4.
- [37] Keil, P., Schuster, S. F. et al. „Calendar Aging of Lithium-Ion Batteries“. In: *Journal of The Electrochemical Society* 163.9 (2016), A1872–A1880. ISSN: 0013-4651. DOI: 10.1149/2.0411609jes.

- [38] Campestrini, C., Kosch, S. und Jossen, A. „Influence of change in open circuit voltage on the state of charge estimation with an extended Kalman filter“. In: *Journal of Energy Storage* 12 (2017), Seiten 149–156. ISSN: 2352152X. DOI: 10.1016/j.est.2017.04.011.
- [39] Huang, X. „Separator technologies for lithium-ion batteries“. In: *Journal of Solid State Electrochemistry* 15.4 (2011), Seiten 649–662. ISSN: 1432-8488. DOI: 10.1007/s10008-010-1264-9.
- [40] Schmidt, J. P. „Verfahren zur Charakterisierung und Modellierung von Lithium-Ionen Zellen“. Dissertation. 2013. DOI: 10.5445/KSP/1000036622. URL: <http://digbib.ubka.uni-karlsruhe.de/volltexte/1000036622>.
- [41] Wang, Q., Jiang, B., Li, B. und Yan, Y. „A critical review of thermal management models and solutions of lithium-ion batteries for the development of pure electric vehicles“. In: *Renewable and Sustainable Energy Reviews* 64 (2016), Seiten 106–128. ISSN: 13640321. DOI: 10.1016/j.rser.2016.05.033.
- [42] Atkins, P. W., Paula, J. de und Keeler, J. J. *Atkins' physical chemistry*. Eleventh edition. Oxford und New York: Oxford University Press, 2018. ISBN: 0198769865.
- [43] Andrea, D. *Battery management systems for large lithium battery packs*. Power engineering. Norwood: Artech House Publishers, 2010. ISBN: 978-1-60807-104-3.
- [44] Shen, M. und Gao, Q. „A review on battery management system from the modeling efforts to its multiapplication and integration“. In: *International Journal of Energy Research* 43.10 (2019), Seiten 5042–5075. ISSN: 0363-907X. DOI: 10.1002/er.4433. (Besucht am 26.03.2020).
- [45] Brandl, M., Gall, H. et al. „Batteries and battery management systems for electric vehicles“. In: *2012 Design, Automation & Test in Europe Conference & Exhibition (DATE)*. IEEE, 2012, Seiten 971–976. ISBN: 978-1-4577-2145-8. DOI: 10.1109/DATE.2012.6176637.
- [46] Kim, C.-H., Kim, M.-Y. und Moon, G.-W. „A Modularized Charge Equalizer Using a Battery Monitoring IC for Series-Connected Li-Ion Battery Strings in Electric Vehicles“. In: *IEEE Transactions on Power Electronics* 28.8 (2013), Seiten 3779–3787. ISSN: 0885-8993. DOI: 10.1109/TPEL.2012.2227810.
- [47] Fleming, J., Amietszajew, T. et al. „The design and impact of in-situ and operando thermal sensing for smart energy storage“. In: *Journal of Energy Storage* 22 (2019), Seiten 36–43. ISSN: 2352152X. DOI: 10.1016/j.est.2019.01.026.
- [48] Zhu, S., Han, J. et al. „A novel embedded method for in-situ measuring internal multi-point temperatures of lithium ion batteries“. In: *Journal of Power Sources* 456 (2020), Seite 227981. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.227981.
- [49] Martiny, N., Rheinfeld, A. et al. „Development of an All Kapton-Based Thin-Film Thermocouple Matrix for In Situ Temperature Measurement in a Lithium Ion Pouch Cell“. In: *IEEE Sensors Journal* 14.10 (2014), Seiten 3377–3384. ISSN: 1530-437X. DOI: 10.1109/JSEN.2014.2331996.

- [50] Lee, K.-J., Smith, K., Pesaran, A. und Kim, G.-H. „Three dimensional thermal-, electrical-, and electrochemical-coupled model for cylindrical wound large format lithium-ion batteries“. In: *Journal of Power Sources* 241 (2013), Seiten 20–32. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.03.007.
- [51] Lorentz, V., Wenger, M. M. et al. „Novel cost-efficient contactless distributed monitoring concept for smart battery cells“. In: *2012 IEEE International Symposium*. 2012, Seiten 1342–1347. DOI: 10.1109/ISIE.2012.6237285.
- [52] Otto, A., Rzepka, S. et al. „Battery Management Network for Fully Electrical Vehicles Featuring Smart Systems at Cell and Pack Level“. In: *Advanced Microsystems for Automotive Applications 2012*. Herausgegeben von Meyer, G. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, Seiten 3–14. ISBN: 978-3-642-29672-7.
- [53] Saidani, F., Hutter, F. X., Selinger, W., Yu, Z. und Burghartz, J. N. „A lithium-ion battery demonstrator for HEV applications featuring a smart system at cell level“. In: *2017 IEEE International Systems Engineering Symposium (ISSE)*. IEEE, 2017, Seiten 1–5. ISBN: 978-1-5386-3403-5. DOI: 10.1109/SysEng.2017.8088249.
- [54] Steinhorst, S., Lukasiewicz, M., Narayanaswamy, S., Kauer, M. und Chakraborty, S. „Smart Cells for Embedded Battery Management“. In: *2014 IEEE International Conference on Cyber-Physical Systems, Networks, and Applications*. IEEE, 2014, Seiten 59–64. ISBN: 978-1-4799-5387-5. DOI: 10.1109/CPSNA.2014.22.
- [55] Schmid, M., Kneidinger, H.-G. und Endisch, C. „Data-Driven Fault Diagnosis in Battery Systems through Cross-Cell Monitoring“. In: *IEEE Sensors Journal* (2020), Seite 1. ISSN: 1530-437X. DOI: 10.1109/JSEN.2020.3017812.
- [56] Schmid, M., Liebhart, B., Kleiner, J., Endisch, C. und Kennel, R. „Online Detection of Soft Internal Short Circuits in Lithium-Ion Battery Packs by Data-Driven Cell Voltage Monitoring“. In: *2021 IEEE International Conference on Electrical and Electromechanical Energy Conversion (ECCE Asia)*. 2021. DOI: 10.1109/ECCE-Asia49820.2021.9479175.
- [57] Liebhart, B., Satzke, M., Komsijska, L. und Endisch, C. „Application of nonlinear impedance spectroscopy for the diagnosis of lithium-ion battery cells under various operating conditions“. In: *Journal of Power Sources* 480 (2020), Seite 228673. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.228673.
- [58] Ci, S., Lin, N. und Wu, D. „Reconfigurable Battery Techniques and Systems: A Survey“. In: *IEEE Access* 4 (2016), Seiten 1175–1189. DOI: 10.1109/ACCESS.2016.2545338.
- [59] Kim, T., Qiao, W. und Qu, L. „Series-connected reconfigurable multicell battery: A novel design towards smart batteries“. In: *2010 IEEE Energy Conversion Congress and Exposition*. IEEE, 2010, Seiten 4257–4263. ISBN: 978-1-4244-5286-6. DOI: 10.1109/ECCE.2010.5617723.
- [60] Manenti, A., Abba, A., Geraci, A. und Savaresi, S. „A New Cell Balancing Architecture for Li-ion Battery Packs Based on Cell Redundancy“. In: *IFAC Proceedings Volumes* 44.1 (2011), Seiten 12150–12155. ISSN: 14746670. DOI: 10.3182/20110828-6-IT-1002.00280.

- [61] Bouchhima, N., Schnierle, M., Schulte, S. und Birke, K. P. „Active model-based balancing strategy for self-reconfigurable batteries“. In: *Journal of Power Sources* 322 (2016), Seiten 129–137. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.05.027.
- [62] Bouchhima, N., Schnierle, M., Schulte, S. und Birke, K. P. „Optimal energy management strategy for self-reconfigurable batteries“. In: *Energy* 122 (2017), Seiten 560–569. ISSN: 03605442. DOI: 10.1016/j.energy.2017.01.043.
- [63] Kleiner, J., Lechermann, L., Komsijska, L., Elger, G. und Endisch, C. „Thermal Behavior of Intelligent Automotive Lithium-Ion Batteries: Operating Strategies for Adaptive Thermal Balancing by Reconfiguration“. In: *Journal of Energy Storage* (2021). ISSN: 2352152X.
- [64] Venkataramanaiah, J., Suresh, Y. und Panda, A. K. „A review on symmetric, asymmetric, hybrid and single DC sources based multilevel inverter topologies“. In: *Renewable and Sustainable Energy Reviews* 76 (2017), Seiten 788–812. ISSN: 13640321. DOI: 10.1016/j.rser.2017.03.066.
- [65] Zimmermann, T., Keil, P. et al. „Review of system topologies for hybrid electrical energy storage systems“. In: *Journal of Energy Storage* 8 (2016), Seiten 78–90. ISSN: 2352152X. DOI: 10.1016/j.est.2016.09.006.
- [66] Liu, G., Lu, L., Li, J. und Ouyang, M. „Thermal Modeling of a LiFePO₄/Graphite Battery and Research on the Influence of Battery Temperature Rise on EV Driving Range Estimation“. In: *2013 IEEE Vehicle Power and Propulsion Conference (VPPC)*. Piscataway, NJ: IEEE, 2013, Seiten 1–5. ISBN: 978-1-4799-0720-5. DOI: 10.1109/VPPC.2013.6671721.
- [67] Barré, A., Deguilhem, B. et al. „A review on lithium-ion battery ageing mechanisms and estimations for automotive applications“. In: *Journal of Power Sources* 241 (2013), Seiten 680–689. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.05.040.
- [68] Cordoba-Arenas, A., Onori, S., Guezennec, Y. und Rizzoni, G. „Capacity and power fade cycle-life model for plug-in hybrid electric vehicle lithium-ion battery cells containing blended spinel and layered-oxide positive electrodes“. In: *Journal of Power Sources* 278 (2015), Seiten 473–483. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2014.12.047.
- [69] Asakura, K., Shimomura, M. und Shodai, T. „Study of life evaluation methods for Lithium-ion batteries for backup applications“. In: *Journal of Power Sources* 119-121 (2003), Seiten 902–905. ISSN: 03787753. DOI: 10.1016/S0378-7753(03)00208-8.
- [70] Birkl, C. R., Roberts, M. R., McTurk, E., Bruce, P. G. und Howey, D. A. „Degradation diagnostics for lithium ion cells“. In: *Journal of Power Sources* 341 (2017), Seiten 373–386. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.12.011.
- [71] Cai, Y., Yang, L., Deng, Z., Zhao, X. und Deng, H. „Online identification of lithium-ion battery state-of-health based on fast wavelet transform and cross D-Markov machine“. In: *Energy* 147 (2018), Seiten 621–635. ISSN: 03605442. DOI: 10.1016/j.energy.2018.01.001.

- [72] Ren, P., Wang, S., He, M. und Cao, W. „Novel strategy based on improved Kalman filter algorithm for state of health evaluation of hybrid electric vehicles Li-ion batteries during short- and longer term operating conditions“. In: *Journal of Power Electronics* 21.8 (2021), Seiten 1190–1199. ISSN: 1598-2092. DOI: 10.1007/s43236-021-00253-5.
- [73] Isermann, R. und Münchhof, M. *Identification of Dynamic Systems*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. ISBN: 978-3-540-78878-2. DOI: 10.1007/978-3-540-78879-9.
- [74] Meddings, N., Heinrich, M. et al. „Application of electrochemical impedance spectroscopy to commercial Li-ion cells: A review“. In: *Journal of Power Sources* 480 (2020), Seite 228742. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.228742.
- [75] Santhanagopalan, S., Guo, Q., Ramadass, P. und White, R. E. „Review of models for predicting the cycling performance of lithium ion batteries“. In: *Journal of Power Sources* 156.2 (2006), Seiten 620–628. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2005.05.070.
- [76] Smith, K. A., Rahn, C. D. und Wang, C.-Y. „Control oriented 1D electrochemical model of lithium ion battery“. In: *Energy Conversion and Management* 48.9 (2007), Seiten 2565–2578. ISSN: 01968904. DOI: 10.1016/j.enconman.2007.03.015.
- [77] Di Domenico, D., Stefanopoulou, A. und Fiengo, G. „Lithium-Ion Battery State of Charge and Critical Surface Charge Estimation Using an Electrochemical Model-Based Extended Kalman Filter“. In: *Journal of Power Sources* 132.6 (2010), Seite 061302. ISSN: 03787753. DOI: 10.1115/1.4002475.
- [78] Rahimian, S. K., Rayman, S. und White, R. E. „Comparison of single particle and equivalent circuit analog models for a lithium-ion cell“. In: *Journal of Power Sources* 196.20 (2011), Seiten 8450–8462. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2011.06.007.
- [79] Chu, Z., Plett, G. L., Trimboli, M. S. und Ouyang, M. „A control-oriented electrochemical model for lithium-ion battery, Part I: Lumped-parameter reduced-order model with constant phase element“. In: *Journal of Energy Storage* 25 (2019), Seite 100828. ISSN: 2352152X. DOI: 10.1016/j.est.2019.100828.
- [80] Bi, Y., Yin, Y. und Choe, S.-Y. „Online state of health and aging parameter estimation using a physics-based life model with a particle filter“. In: *Journal of Power Sources* 476 (2020), Seite 228655. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.228655.
- [81] Fuller, T. F., Doyle, M. und Newman, J. „Simulation and Optimization of the Dual Lithium Ion Insertion Cell“. In: *Journal of The Electrochemical Society* 141.1 (1994), Seiten 1–10. ISSN: 0013-4651. DOI: 10.1149/1.2054684.
- [82] Jokar, A., Rajabloo, B., Désilets, M. und Lacroix, M. „Review of simplified Pseudo-two-Dimensional models of lithium-ion batteries“. In: *Journal of Power Sources* 327 (2016), Seiten 44–55. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.07.036.
- [83] Santhanagopalan, S. und White, R. E. „Online estimation of the state of charge of a lithium ion cell“. In: *Journal of Power Sources* 161.2 (2006), Seiten 1346–1355. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2006.04.146.

- [84] Hussein, A. A.-H. und Batarseh, I. „An overview of generic battery models“. In: *2011 IEEE Power and Energy Society General Meeting*. IEEE, 2011, Seiten 1–6. ISBN: 978-1-4577-1000-1. DOI: 10.1109/PES.2011.6039674.
- [85] Schmalstieg, J., Kabitz, S., Ecker, M. und Sauer, D. U. „From accelerated aging tests to a lifetime prediction model: Analyzing lithium-ion batteries“. In: *World Electric Vehicle Symposium and Exposition (EVS 27), 2013*. Piscataway, NJ: IEEE, 2013, Seiten 1–12. ISBN: 978-1-4799-3832-2. DOI: 10.1109/EVS.2013.6914753.
- [86] Liu, Z., Wang, Y., Du Jiani und Chen, C. „RBF network-aided adaptive unscented kalman filter for lithium-ion battery SOC estimation in electric vehicles“. In: *2012 7th IEEE Conference on Industrial Electronics and Applications (ICIEA)*. IEEE, 2012, Seiten 1673–1677. ISBN: 978-1-4577-2119-9. DOI: 10.1109/ICIEA.2012.6360994.
- [87] Ozcan, G., Pajovic, M. et al. „Online battery state-of-charge estimation based on sparse gaussian process regression“. In: *2016 IEEE Power and Energy*, Seiten 1–5. DOI: 10.1109/PESGM.2016.7741980.
- [88] Tian, Y., Lai, R., Li, X., Xiang, L. und Tian, J. „A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter“. In: *Applied Energy* 265 (2020), Seite 114789. ISSN: 03062619. DOI: 10.1016/j.apenergy.2020.114789.
- [89] Murphy, K. P. *Machine learning: A probabilistic perspective*. Adaptive computation and machine learning series. Cambridge, Mass.: MIT Press, 2012. ISBN: 978-0-262-01802-9.
- [90] He, H., Xiong, R. und Fan, J. „Evaluation of Lithium-Ion Battery Equivalent Circuit Models for State of Charge Estimation by an Experimental Approach“. In: *Energies* 4.4 (2011), Seiten 582–598. DOI: 10.3390/en4040582.
- [91] Jin, F., Yongling, H. und Guofu, W. „Comparison Study of Equivalent Circuit Model of Li-Ion Battery for Electrical Vehicles“. In: *Research Journal of Applied Sciences, Engineering and Technology* 6.20 (2013), Seiten 3756–3759. ISSN: 20407459. DOI: 10.19026/rjaset.6.3587.
- [92] Wehbe, J. und Karami, N. „Battery equivalent circuits and brief summary of components value determination of lithium ion: A review“. In: *2015 Third International Conference on Technological Advances in Electrical, Electronics and Computer Engineering (TAECE)*. IEEE, 2015, Seiten 45–49. ISBN: 978-1-4799-5680-7. DOI: 10.1109/TAECE.2015.7113598.
- [93] Nejad, S., Gladwin, D. T. und Stone, D. A. „A systematic review of lumped-parameter equivalent circuit models for real-time estimation of lithium-ion battery states“. In: *Journal of Power Sources* 316 (2016), Seiten 183–196. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.03.042.
- [94] Tran, M.-K., DaCosta, A., Mevawalla, A., Panchal, S. und Fowler, M. „Comparative Study of Equivalent Circuit Models Performance in Four Common Lithium-Ion Batteries: LFP, NMC, LMO, NCA“. In: *Batteries* 7.3 (2021), Seite 51. DOI: 10.3390/batteries7030051.
- [95] Gerschler, J. B. *Ortsaufgelöste Modellbildung von Lithium-Ionen-Systemen unter spezieller Berücksichtigung der Batteriealterung: Zugl.: Aachen, Techn. Hochsch., Diss., 2012*. Band 63. Aachener Beiträge des ISEA. Aachen: Shaker, 2012. ISBN: 978-3-8440-1307-8.

- [96] Wang, Q., Wang, J. et al. „Correlation between the model accuracy and model-based SOC estimation“. In: *Electrochimica Acta* 228 (2017), Seiten 146–159. ISSN: 00134686. DOI: 10.1016/j.electacta.2017.01.057.
- [97] Hu, X., Li, S. und Peng, H. „A comparative study of equivalent circuit models for Li-ion batteries“. In: *Journal of Power Sources* 198 (2012), Seiten 359–367. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2011.10.013.
- [98] Liu, G., Lu, L. et al. „A comparative study of equivalent circuit models and enhanced equivalent circuit models of lithium-ion batteries with different model structures“. In: *2014 IEEE Conference and Expo*, Seiten 1–6. DOI: 10.1109/ITEC-AP.2014.6940946.
- [99] Zhang, L., Peng, H., Ning, Z., Mu, Z. und Sun, C. „Comparative Research on RC Equivalent Circuit Models for Lithium-Ion Batteries of Electric Vehicles“. In: *Applied Sciences* 7.10 (2017), Seite 1002. DOI: 10.3390/app7101002.
- [100] Hu, Y., Yurkovich, S., Guezennec, Y. und Yurkovich, B. J. „A technique for dynamic battery model identification in automotive applications using linear parameter varying structures“. In: *Control Engineering Practice* 17.10 (2009), Seiten 1190–1201. ISSN: 09670661. DOI: 10.1016/j.conengprac.2009.05.002.
- [101] Lin, C., Yu, Q., Xiong, R. und Le Wang, Y. „A study on the impact of open circuit voltage tests on state of charge estimation for lithium-ion batteries“. In: *Applied Energy* 205 (2017), Seiten 892–902. ISSN: 03062619. DOI: 10.1016/j.apenergy.2017.08.124.
- [102] Jiang, C., Wang, S. et al. „A state-of-charge estimation method of the power lithium-ion battery in complex conditions based on adaptive square root extended Kalman filter“. In: *Energy* 219 (2021), Seite 119603. ISSN: 03605442. DOI: 10.1016/j.energy.2020.119603.
- [103] Klintberg, A., Klintberg, E., Fridholm, B., Kuusisto, H. und Wik, T. „Statistical modeling of OCV-curves for aged battery cells“. In: *IFAC-PapersOnLine* 50.1 (2017), Seiten 2164–2168. ISSN: 24058963. DOI: 10.1016/j.ifacol.2017.08.275.
- [104] Charkhgard, M. und Farrokhi, M. „State-of-Charge Estimation for Lithium-Ion Batteries Using Neural Networks and EKF“. In: *IEEE Transactions on Industrial Electronics* 57.12 (2010), Seiten 4178–4187. ISSN: 0278-0046. DOI: 10.1109/TIE.2010.2043035.
- [105] Weng, C., Sun, J. und Peng, H. „A unified open-circuit-voltage model of lithium-ion batteries for state-of-charge estimation and state-of-health monitoring“. In: *Journal of Power Sources* 258 (2014), Seiten 228–237. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2014.02.026.
- [106] Lee, S., Kim, J., Lee, J. und Cho, B. H. „State-of-charge and capacity estimation of lithium-ion battery using a new open-circuit voltage versus state-of-charge“. In: *Journal of Power Sources* 185.2 (2008), Seiten 1367–1373. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2008.08.103.
- [107] Ma, S., Jiang, M. et al. „Temperature effect and thermal impact in lithium-ion batteries: A review“. In: *Progress in Natural Science: Materials International* 28.6 (2018), Seiten 653–666. ISSN: 10020071. DOI: 10.1016/j.pnsc.2018.11.002.

- [108] Peabody, C. und Arnold, C. B. „The role of mechanically induced separator creep in lithium-ion battery capacity fade“. In: *Journal of Power Sources* 196.19 (2011), Seiten 8147–8153. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2011.05.023.
- [109] Li, J., Murphy, E., Winnick, J. und Kohl, P. „Studies on the cycle life of commercial lithium ion batteries during rapid charge–discharge cycling“. In: *Journal of Power Sources* 102.1-2 (2001), Seiten 294–301. ISSN: 03787753. DOI: 10.1016/S0378-7753(01)00821-7.
- [110] Broussely, M., Biensan, P. et al. „Main aging mechanisms in Li ion batteries“. In: *Journal of Power Sources* 146.1-2 (2005), Seiten 90–96. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2005.03.172.
- [111] Han, X., Ouyang, M. et al. „A comparative study of commercial lithium ion battery cycle life in electrical vehicle: Aging mechanism identification“. In: *Journal of Power Sources* 251 (2014), Seiten 38–54. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.11.029.
- [112] Gao, Y., Jiang, J. et al. „Lithium-ion battery aging mechanisms and life model under different charging stresses“. In: *Journal of Power Sources* 356 (2017), Seiten 103–114. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2017.04.084.
- [113] Keil, P. „Aging of Lithium-Ion Batteries in Electric Vehicles“. Dissertation. München: Technische Universität, 2017.
- [114] Bruen, T. und Marco, J. „Modelling and experimental evaluation of parallel connected lithium ion cells for an electric vehicle battery system“. In: *Journal of Power Sources* 310 (2016), Seiten 91–101. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.01.001.
- [115] Fouchard, D. und Taylor, J. B. „The molical ® rechargeable lithium system: Multicell aspects“. In: *Journal of Power Sources* 21.3-4 (1987), Seiten 195–205. ISSN: 03787753. DOI: 10.1016/0378-7753(87)80054-X.
- [116] Zhang, J., Ci, S., Sharif, H. und Alahmad, M. „Modeling Discharge Behavior of Multicell Battery“. In: *IEEE Transactions on Energy Conversion* 25.4 (2010), Seiten 1133–1141. ISSN: 0885-8969. DOI: 10.1109/TEC.2010.2048904.
- [117] Brand, M. J., Hofmann, M. H., Steinhardt, M., Schuster, S. F. und Jossen, A. „Current distribution within parallel-connected battery cells“. In: *Journal of Power Sources* 334 (2016), Seiten 202–212. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.10.010.
- [118] Fill, A., Koch, S., Pott, A. und Birke, K.-P. „Current distribution of parallel-connected cells in dependence of cell resistance, capacity and number of parallel cells“. In: *Journal of Power Sources* 407 (2018), Seiten 147–152. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2018.10.061.
- [119] Fill, A., Koch, S. und Birke, K. P. „Analytical model of the current distribution of parallel-connected battery cells and strings“. In: *Journal of Energy Storage* 23 (2019), Seiten 37–43. ISSN: 2352152X. DOI: 10.1016/j.est.2019.02.031.
- [120] Chang, L., Zhang, C. et al. „Correlations of cell-to-cell parameter variations on current and state-of-charge distributions within parallel-connected lithium-ion cells“. In: *Journal of Power Sources* 437 (2019), Seite 226869. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2019.226869.

- [121] Lv, J., Lin, S. et al. „Performance of LiFePO₄ batteries in parallel based on connection topology“. In: *Applied Energy* 252 (2019), Seite 113407. ISSN: 03062619. DOI: 10.1016/j.apenergy.2019.113407.
- [122] Dubarry, M., Devie, A. und Liaw, B. Y. „Cell-balancing currents in parallel strings of a battery system“. In: *Journal of Power Sources* 321 (2016), Seiten 36–46. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.04.125.
- [123] Bruen, T., Marco, J. und Gama, M. „Current Variation in Parallelized Energy Storage Systems“. In: *2014 IEEE Vehicle Power and Propulsion Conference (VPPC)*. Piscataway, NJ: IEEE, 2014, Seiten 1–6. ISBN: 978-1-4799-6783-4. DOI: 10.1109/VPPC.2014.7007040.
- [124] Gong, X., Xiong, R. und Mi, C. C. „Study of the characteristics of battery packs in electric vehicles with parallel-connected lithium-ion battery cells“. In: *Twenty-Ninth Annual IEEE Applied Power Electronics Conference and Exposition (APEC), 2014*. Herausgegeben von Yu, H. Piscataway, NJ: IEEE, 2014, Seiten 3218–3224. ISBN: 978-1-4799-2325-0. DOI: 10.1109/APEC.2014.6803766.
- [125] Miyatake, S., Susuki, Y., Hikiyama, T., Itoh, S. und Tanaka, K. „Discharge characteristics of multicell lithium-ion battery with nonuniform cells“. In: *Journal of Power Sources* 241 (2013), Seiten 736–743. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.05.179.
- [126] Pastor-Fernández, C., Bruen, T., Widanage, W. D., Gama-Valdez, M. A. und Marco, J. „A Study of Cell-to-Cell Interactions and Degradation in Parallel Strings: Implications for the Battery Management System“. In: *Journal of Power Sources* 329 (2016), Seiten 574–585. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.07.121.
- [127] Shi, W., Hu, X. et al. „Effects of imbalanced currents on large-format LiFePO₄ /graphite batteries systems connected in parallel“. In: *Journal of Power Sources* 313 (2016), Seiten 198–204. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.02.087.
- [128] Hofmann, M. H., Czyrka, K. et al. „Dynamics of current distribution within battery cells connected in parallel“. In: *Journal of Energy Storage* 20 (2018), Seiten 120–133. ISSN: 2352152X. DOI: 10.1016/j.est.2018.08.013.
- [129] Neupert, S. und Kowal, J. „Inhomogeneities in Battery Packs“. In: *World Electric Vehicle Journal* 9.2 (2018), Seite 20. DOI: 10.3390/wevj9020020.
- [130] Schmid, M., Vögele, U. und Endisch, C. „A novel matrix-vector-based framework for modeling and simulation of electric vehicle battery packs“. In: *Journal of Energy Storage* 32 (2020), Seite 101736. ISSN: 2352152X. DOI: 10.1016/j.est.2020.101736.
- [131] Baumann, M., Wildfeuer, L., Rohr, S. und Lienkamp, M. „Parameter variations within Li-Ion battery packs – Theoretical investigations and experimental quantification“. In: *Journal of Energy Storage* 18 (2018), Seiten 295–307. ISSN: 2352152X. DOI: 10.1016/j.est.2018.04.031.
- [132] Gogoana, R., Pinson, M. B., Bazant, M. Z. und Sarma, S. E. „Internal resistance matching for parallel-connected lithium-ion cells and impacts on battery pack cycle life“. In: *Journal of Power Sources* 252 (2014), Seiten 574–585. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.11.101.

- [133] Rumpf, K., Naumann, M. und Jossen, A. „Experimental investigation of parametric cell-to-cell variation and correlation based on 1100 commercial lithium-ion cells“. In: *Journal of Energy Storage* 14 (2017), Seiten 224–243. ISSN: 2352152X. DOI: 10.1016/j.est.2017.09.010.
- [134] Zilberman, I., Ludwig, S. und Jossen, A. „Cell-to-cell variation of calendar aging and reversible self-discharge in 18650 nickel-rich, silicon-graphite lithium-ion cells“. In: *Journal of Energy Storage* 26 (2019), Seite 100900. ISSN: 2352152X. DOI: 10.1016/j.est.2019.100900.
- [135] Schuster, S. F., Brand, M. J., Berg, P., Gleissenberger, M. und Jossen, A. „Lithium-ion cell-to-cell variation during battery electric vehicle operation“. In: *Journal of Power Sources* 297 (2015), Seiten 242–251. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2015.08.001.
- [136] Dubarry, M., Vuillaume, N. und Liaw, B. Y. „Origins and accommodation of cell variations in Li-ion battery pack modeling“. In: *International Journal of Energy Research* 34.2 (2010), Seiten 216–231. ISSN: 0363907X. DOI: 10.1002/er.1668.
- [137] Zheng, Y., Han, X., Lu, L., Li, J. und Ouyang, M. „Lithium ion battery pack power fade fault identification based on Shannon entropy in electric vehicles“. In: *Journal of Power Sources* 223 (2013), Seiten 136–146. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2012.09.015.
- [138] Baumhöfer, T., Brühl, M., Rothgang, S. und Sauer, D. U. „Production caused variation in capacity aging trend and correlation to initial cell performance“. In: *Journal of Power Sources* 247 (2014), Seiten 332–338. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.08.108.
- [139] An, F., Huang, J. et al. „Cell sorting for parallel lithium-ion battery systems: Evaluation based on an electric circuit model“. In: *Journal of Energy Storage* 6 (2016), Seiten 195–203. ISSN: 2352152X. DOI: 10.1016/j.est.2016.04.007.
- [140] Waag, W., Käbitz, S. und Sauer, D. U. „Experimental investigation of the lithium-ion battery impedance characteristic at various conditions and aging states and its influence on the application“. In: *Applied Energy* 102 (2013), Seiten 885–897. ISSN: 03062619. DOI: 10.1016/j.apenergy.2012.09.030.
- [141] Choi, W., Shin, H.-C., Kim, J. M., Choi, J.-Y. und Yoon, W.-S. „Modeling and Applications of Electrochemical Impedance Spectroscopy (EIS) for Lithium-ion Batteries“. In: *Journal of Electrochemical Science and Technology* 11.1 (2020), Seiten 1–13. ISSN: 2093-8551. DOI: 10.33961/jecst.2019.00528.
- [142] Lai, X., Qin, C., Gao, W., Zheng, Y. und Yi, W. „A State of Charge Estimator Based Extended Kalman Filter Using an Electrochemistry-Based Equivalent Circuit Model for Lithium-Ion Batteries“. In: *Applied Sciences* 8.9 (2018), Seite 1592. DOI: 10.3390/app8091592.
- [143] Lai, X., Wang, S., He, L., Zhou, L. und Zheng, Y. „A hybrid state-of-charge estimation method based on credible increment for electric vehicle applications with large sensor and model errors“. In: *Journal of Energy Storage* 27 (2020), Seite 101106. ISSN: 2352152X. DOI: 10.1016/j.est.2019.101106.

- [144] Sarre, G., Blanchard, P. und Broussely, M. „Aging of lithium-ion batteries“. In: *Journal of Power Sources* 127.1-2 (2004), Seiten 65–71. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2003.09.008.
- [145] Käbitz, S., Gerschler, J. B. et al. „Cycle and calendar life study of a graphite|LiNi₁/3Mn₁/3Co₁/3O₂ Li-ion high energy system. Part A: Full cell characterization“. In: *Journal of Power Sources* 239 (2013), Seiten 572–583. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.03.045.
- [146] Schuster, S. F., Bach, T. et al. „Nonlinear aging characteristics of lithium-ion cells under different operational conditions“. In: *Journal of Energy Storage* 1 (2015), Seiten 44–53. ISSN: 2352152X. DOI: 10.1016/j.est.2015.05.003.
- [147] Jang, I.-Y. *Specification of Product: Lithium-ion rechargeable cell for power tools Model name : INR18650-25R*. 2014.
- [148] Lain, Brandon und Kendrick. „Design Strategies for High Power vs. High Energy Lithium Ion Cells“. In: *Batteries* 5.4 (2019), Seite 64. DOI: 10.3390/batteries5040064.
- [149] Petzl, M. und Danzer, M. A. „Nondestructive detection, characterization, and quantification of lithium plating in commercial lithium-ion batteries“. In: *Journal of Power Sources* 254 (2014), Seiten 80–87. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.12.060.
- [150] Petzl, M., Kasper, M. und Danzer, M. A. „Lithium plating in a commercial lithium-ion battery – A low-temperature aging study“. In: *Journal of Power Sources* 275 (2015), Seiten 799–807. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2014.11.065.
- [151] Waag, W. und Sauer, D. U. „Adaptive estimation of the electromotive force of the lithium-ion battery after current interruption for an accurate state-of-charge and capacity determination“. In: *Applied Energy* 111 (2013), Seiten 416–427. ISSN: 03062619. DOI: 10.1016/j.apenergy.2013.05.001.
- [152] Barai, A., Widanage, W. D., Marco, J., McGordon, A. und Jennings, P. „A study of the open circuit voltage characterization technique and hysteresis assessment of lithium-ion cells“. In: *Journal of Power Sources* 295 (2015), Seiten 99–107. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2015.06.140.
- [153] Srinivasan, V. und Newman, J. „Existence of Path-Dependence in the LiFePO₄ Electrode“. In: *Electrochemical and Solid-State Letters* 9.3 (2006), A110. ISSN: 10990062. DOI: 10.1149/1.2159299.
- [154] Dreyer, W., Jamnik, J. et al. „The thermodynamic origin of hysteresis in insertion batteries“. In: *Nature materials* 9.5 (2010), Seiten 448–453. ISSN: 1476-1122. DOI: 10.1038/nmat2730.
- [155] Verbrugge, M. und Tate, E. „Adaptive state of charge algorithm for nickel metal hydride batteries including hysteresis phenomena“. In: *Journal of Power Sources* 126.1-2 (2004), Seiten 236–249. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2003.08.042.
- [156] Plett, G. L. „Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 2. Modeling and identification“. In: *Journal of Power Sources* 134.2 (2004), Seiten 262–276. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2004.02.032.

- [157] Baronti, F., Femia, N., Saletti, R., Visone, C. und Zamboni, W. „Hysteresis Modeling in Li-Ion Batteries“. In: *IEEE Transactions on Magnetics* 50.11 (2014), Seiten 1–4. ISSN: 0018-9464. DOI: 10.1109/TMAG.2014.2323426.
- [158] Lagarias, J. C., Reeds, J. A., Wright, M. H. und Wright, P. E. „Convergence Properties of the Nelder–Mead Simplex Method in Low Dimensions“. In: *SIAM Journal on Optimization* 9.1 (1998), Seiten 112–147. ISSN: 1052-6234. DOI: 10.1137/S1052623496303470.
- [159] Franke, T. und Krems, J. F. „Understanding charging behaviour of electric vehicle users“. In: *Transportation Research Part F: Traffic Psychology and Behaviour* 21 (2013), Seiten 75–89. ISSN: 13698478. DOI: 10.1016/j.trf.2013.09.002.
- [160] Truchot, C., Dubarry, M. und Liaw, B. Y. „State-of-charge estimation and uncertainty for lithium-ion battery strings“. In: *Applied Energy* 119 (2014), Seiten 218–227. ISSN: 03062619. DOI: 10.1016/j.apenergy.2013.12.046.
- [161] Plett, G. L. „Efficient Battery Pack State Estimation using Bar-Delta Filtering“. In: *International Battery, Hybrid and Fuel Cell Electric Vehicle Symposium*. 2009, Seiten 1–8.
- [162] Roscher, M. A., Bohlen, O. S. und Sauer, D. U. „Reliable State Estimation of Multicell Lithium-Ion Battery Systems“. In: *IEEE Transactions on Energy Conversion* 26.3 (2011), Seiten 737–743. ISSN: 0885-8969. DOI: 10.1109/TEC.2011.2155657.
- [163] Dai, H., Wei, X., Sun, Z., Wang, J. und Gu, W. „Online cell SOC estimation of Li-ion battery packs using a dual time-scale Kalman filtering for EV applications“. In: *Applied Energy* 95 (2012), Seiten 227–237. ISSN: 03062619. DOI: 10.1016/j.apenergy.2012.02.044.
- [164] Zheng, Y., Ouyang, M. et al. „Cell state-of-charge inconsistency estimation for LiFePO₄ battery pack in hybrid electric vehicles using mean-difference model“. In: *Applied Energy* 111 (2013), Seiten 571–580. ISSN: 03062619. DOI: 10.1016/j.apenergy.2013.05.048.
- [165] Zhong, L., Zhang, C., He, Y. und Chen, Z. „A method for the estimation of the battery pack state of charge based on in-pack cells uniformity analysis“. In: *Applied Energy* 113 (2014), Seiten 558–564. ISSN: 03062619. DOI: 10.1016/j.apenergy.2013.08.008.
- [166] Sun, F., Xiong, R. und He, H. „A systematic state-of-charge estimation framework for multi-cell battery pack in electric vehicles using bias correction technique“. In: *Applied Energy* 162 (2016), Seiten 1399–1409. ISSN: 03062619. DOI: 10.1016/j.apenergy.2014.12.021.
- [167] Yang, C., Wang, X. et al. „An online SOC and capacity estimation method for aged lithium-ion battery pack considering cell inconsistency“. In: *Journal of Energy Storage* 29 (2020), Seite 101250. ISSN: 2352152X. DOI: 10.1016/j.est.2020.101250.
- [168] Föllinger, O., Konigorski, U., Lohmann, B., Roppenecker, G. und Trächtler, A. *Regelungstechnik: Einführung in die Methoden und ihre Anwendung*. 11., völlig neu bearb. Aufl. Berlin: VDE-Verl., 2013. ISBN: 9783800732319.
- [169] Adamy, J. *Nichtlineare Regelungen*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. ISBN: 978-3-642-00793-4. DOI: 10.1007/978-3-642-00794-1.

- [170] Wei, Z., Zou, C., Leng, F., Soong, B. H. und Tseng, K.-J. „Online Model Identification and State-of-Charge Estimate for Lithium-Ion Battery With a Recursive Total Least Squares-Based Observer“. In: *IEEE Transactions on Industrial Electronics* 65.2 (2018), Seiten 1336–1346. ISSN: 0278-0046. DOI: 10.1109/TIE.2017.2736480.
- [171] Xu, J., Mi, C. C. et al. „The State of Charge Estimation of Lithium-Ion Batteries Based on a Proportional-Integral Observer“. In: *IEEE Transactions on Vehicular Technology* 63.4 (2014), Seiten 1614–1621. ISSN: 0018-9545. DOI: 10.1109/TVT.2013.2287375.
- [172] Plett, G. L. „Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background“. In: *Journal of Power Sources* 134.2 (2004), Seiten 252–261. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2004.02.031.
- [173] Plett, G. L. „Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 3. State and parameter estimation“. In: *Journal of Power Sources* 134.2 (2004), Seiten 277–292. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2004.02.033.
- [174] Plett, G. L. „Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part1: Introduction and state estimation“. In: *Journal of Power Sources* 161.2 (2006), Seiten 1356–1368. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2006.06.003.
- [175] Plett, G. L. „Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 2: Simultaneous state and parameter estimation“. In: *Journal of Power Sources* 161.2 (2006), Seiten 1369–1384. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2006.06.004.
- [176] Urbain, M., Rael, S., Davat, B. und Desprez, P. „State Estimation of a Lithium-Ion Battery Through Kalman Filter“. In: *2007 IEEE Power Electronics Specialists Conference*. IEEE, 2007, Seiten 2804–2810. ISBN: 978-1-4244-0654-8. DOI: 10.1109/PESC.2007.4342463.
- [177] Junping, W., Jingang, G. und Lei, D. „An adaptive Kalman filtering based State of Charge combined estimator for electric vehicle battery pack“. In: *Energy Conversion and Management* 50.12 (2009), Seiten 3182–3186. ISSN: 01968904. DOI: 10.1016/j.enconman.2009.08.015.
- [178] Sun, F., Hu, X., Zou, Y. und Li, S. „Adaptive unscented Kalman filtering for state of charge estimation of a lithium-ion battery for electric vehicles“. In: *Energy* 36.5 (2011), Seiten 3531–3540. ISSN: 03605442. DOI: 10.1016/j.energy.2011.03.059.
- [179] Andre, D., Appel, C., Soczka-Guth, T. und Sauer, D. U. „Advanced mathematical methods of SOC and SOH estimation for lithium-ion batteries“. In: *Journal of Power Sources* 224 (2013), Seiten 20–27. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2012.10.001.
- [180] Guo, X., Kang, L., Yao, Y., Huang, Z. und Li, W. „Joint Estimation of the Electric Vehicle Power Battery State of Charge Based on the Least Squares Method and the Kalman Filter Algorithm“. In: *Energies* 9.2 (2016), Seite 100. DOI: 10.3390/en9020100.
- [181] Shen, P., Ouyang, M., Lu, L., Li, J. und Feng, X. „The Co-estimation of State of Charge, State of Health, and State of Function for Lithium-Ion Batteries in Electric Vehicles“. In: *IEEE Transactions on Vehicular Technology* 67.1 (2018), Seiten 92–103. ISSN: 0018-9545. DOI: 10.1109/TVT.2017.2751613.

- [182] Wassiliadis, N., Adermann, J. et al. „Revisiting the dual extended Kalman filter for battery state-of-charge and state-of-health estimation: A use-case life cycle analysis“. In: *Journal of Energy Storage* 19 (2018), Seiten 73–87. ISSN: 2352152X. DOI: 10.1016/j.est.2018.07.006.
- [183] Verhaegen, M. und van Dooren, P. „Numerical aspects of different Kalman filter implementations“. In: *IEEE Transactions on Automatic Control* 31.10 (1986), Seiten 907–917. ISSN: 0018-9286. DOI: 10.1109/TAC.1986.1104128.
- [184] Kalman, R. E. „A New Approach to Linear Filtering and Prediction Problems“. In: *Journal of Basic Engineering* 82.1 (1960), Seite 35. ISSN: 00219223. DOI: 10.1115/1.3662552.
- [185] Grewal, M. S. *Kalman filtering: Theory and practice using MATLAB*. Fourth edition. Hoboken, New Jersey: Wiley, 2015. ISBN: 9781118851210. DOI: 10.1002/9781118984987.
- [186] Simon, D. *Optimal state estimation: Kalman, H [infinity], and nonlinear approaches*. Hoboken, NJ: Wiley-Interscience, 2006. ISBN: 978-0-471-70858-2. DOI: 10.1002/0470045345.
- [187] Marchthaler, R. und Dingler, S. *Kalman-Filter*. Wiesbaden: Springer Fachmedien Wiesbaden, 2017. ISBN: 978-3-658-16727-1. DOI: 10.1007/978-3-658-16728-8.
- [188] Chen, Z. „Bayesian Filtering: From Kalman Filters to Particle Filters, and Beyond“. In: *Statistics: A Journal of Theoretical and Applied Statistics* 182 (2003). ISSN: 02331888.
- [189] Lunze, J. *Regelungstechnik 2: Mehrgrößensysteme, digitale Regelung*. 9., neu bearbeitete Aufl. Springer-Lehrbuch. Berlin: Springer-Verlag Berlin Heidelberg, 2016. ISBN: 978-3-662-52676-7. DOI: 10.1007/978-3-662-52676-7.
- [190] Bar-Shalom, Y., Li, X.-R. und Kirubarajan, T. *Estimation with applications to tracking and navigation*. 1st ed. New York: Wiley-Interscience, 2001. ISBN: 0-471-46521-6. DOI: 10.1002/0471221279.
- [191] Julier, S. J. und Uhlmann, J. K. „A non-divergent estimation algorithm in the presence of unknown correlations“. In: *Proceedings of the 1997 American Control Conference (Cat. No. 97CH36041)*. IEEE, 1997, 2369–2373 vol.4. ISBN: 0-7803-3832-4. DOI: 10.1109/ACC.1997.609105.
- [192] Wan, E. A. und Merwe, R. van der. „The unscented Kalman filter for nonlinear estimation“. In: *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium*. IEEE, 2000, Seiten 153–158. ISBN: 0-7803-5800-7. DOI: 10.1109/ASSPCC.2000.882463.
- [193] Merwe, R. van der. „Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models“. Dissertation. Oregon, USA: Oregon Health & Science University, 2004.
- [194] Ito, K. und Xiong, K. „Gaussian filters for nonlinear filtering problems“. In: *IEEE Transactions on Automatic Control* 45.5 (2000), Seiten 910–927. ISSN: 0018-9286. DOI: 10.1109/9.855552.
- [195] Nørgaard, M., Poulsen, N. K. und Ravn, O. „New developments in state estimation for nonlinear systems“. In: *Automatica* 36.11 (2000), Seiten 1627–1638. ISSN: 00051098. DOI: 10.1016/S0005-1098(00)00089-3.

- [196] Schwunk, S., Straub, S., Armbruster, N., Matting, S. und Vetter, M. „Parallel particle filter for state of charge and health estimation with a long term test“. In: *World Electric Vehicle Symposium and Exposition (EVS 27), 2013*. Piscataway, NJ: IEEE, 2013, Seiten 1–10. ISBN: 978-1-4799-3832-2. DOI: 10.1109/EVS.2013.6914726.
- [197] Zou, Y., Hu, X., Ma, H. und Li, S. E. „Combined State of Charge and State of Health estimation over lithium-ion battery cell cycle lifespan for electric vehicles“. In: *Journal of Power Sources* 273 (2015), Seiten 793–803. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2014.09.146.
- [198] Anderson, B. D. und Moore, J. B. *Optimal filtering*. Prentice-Hall information and system sciences series. Englewood Cliffs, NJ: Prentice-Hall, 1979. ISBN: 0136381227.
- [199] Wang, Q., Kang, J., Tan, Z. und Luo, M. „An online method to simultaneously identify the parameters and estimate states for lithium ion batteries“. In: *Electrochimica Acta* 289 (2018), Seiten 376–388. ISSN: 00134686. DOI: 10.1016/j.electacta.2018.08.076.
- [200] Campestrini, C., Walder, G., Jossen, A. und Lienkamp, M. „Temperature Influences on State and Parameter Estimation Based on a Dual Kalman Filter“. In: *CoFAT 2014* (2014). URL: <https://mediatum.ub.tum.de/doc/1226678/file.pdf>.
- [201] Shen, K., Jing, Z. und Dong, P. „Simultaneous target tracking and sensor location refinement in distributed sensor networks“. In: *Signal Processing* 153 (2018), Seiten 123–131. ISSN: 01651684. DOI: 10.1016/j.sigpro.2018.07.014.
- [202] Li, Y., Chen, J. und Lan, F. „Enhanced online model identification and state of charge estimation for lithium-ion battery under noise corrupted measurements by bias compensation recursive least squares“. In: *Journal of Power Sources* 456 (2020), Seite 227984. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.227984.
- [203] Wang, Z., Gladwin, D. T., Smith, M. J. und Haass, S. „Practical state estimation using Kalman filter methods for large-scale battery systems“. In: *Applied Energy* 294 (2021), Seite 117022. ISSN: 03062619. DOI: 10.1016/j.apenergy.2021.117022.
- [204] Wei, Z., Zhao, J., Zou, C., Lim, T. M. und Tseng, K. J. „Comparative study of methods for integrated model identification and state of charge estimation of lithium-ion battery“. In: *Journal of Power Sources* 402 (2018), Seiten 189–197. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2018.09.034.
- [205] Nejad, S., Gladwin, D. T. und Stone, D. A. „A hybrid battery parameter identification concept for lithium-ion energy storage applications“. In: *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*. IEEE, 2016, Seiten 1980–1985. ISBN: 978-1-5090-3474-1. DOI: 10.1109/IECON.2016.7793233.
- [206] Maletić, F., Hrgetić, M. und Deur, J. „Dual Nonlinear Kalman Filter-Based SoC and Remaining Capacity Estimation for an Electric Scooter Li-NMC Battery Pack“. In: *Energies* 13.3 (2020), Seite 540. DOI: 10.3390/en13030540.
- [207] Dragicevic, T., Sucic, S. und Guerrero, J. M. „Battery state-of-charge and parameter estimation algorithm based on Kalman filter“. In: *Eurocon 2013*. IEEE, 2013, Seiten 1519–1525. ISBN: 978-1-4673-2232-4. DOI: 10.1109/EUROCON.2013.6625179.

- [208] Hu, C., Youn, B. D. und Chung, J. „A multiscale framework with extended Kalman filter for lithium-ion battery SOC and capacity estimation“. In: *Applied Energy* 92 (2012), Seiten 694–704. ISSN: 03062619. DOI: 10.1016/j.apenergy.2011.08.002.
- [209] Campestrini, C., Horsche, M. F. et al. „Validation and benchmark methods for battery management system functionalities: State of charge estimation algorithms“. In: *Journal of Energy Storage* 7 (2016), Seiten 38–51. ISSN: 2352152X. DOI: 10.1016/j.est.2016.05.007.
- [210] Adamy, J. *Nichtlineare Systeme und Regelungen*. 3., aktualisierte Auflage. Berlin: Springer Vieweg, 2018. ISBN: 978-3-662-55685-6. DOI: 10.1007/978-3-662-55685-6.
- [211] Zhao, S., Duncan, S. R. und Howey, D. A. „Observability Analysis and State Estimation of Lithium-Ion Batteries in the Presence of Sensor Biases“. In: *IEEE Transactions on Control Systems Technology* 25.1 (2017), Seiten 326–333. ISSN: 1063-6536. DOI: 10.1109/TCST.2016.2542115.
- [212] Meng, J., Boukhnifer, M., Diallo, D. und Wang, T. „A New Cascaded Framework for Lithium-Ion Battery State and Parameter Estimation“. In: *Applied Sciences* 10.3 (2020), Seite 1009. DOI: 10.3390/app10031009.
- [213] Shi, Z., Auger, F., Schaeffer, E., Guillemet, P. und Loron, L. „Interconnected Observers for online supercapacitor ageing monitoring“. In: *IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society*. IEEE, 2013, Seiten 6746–6751. ISBN: 978-1-4799-0224-8. DOI: 10.1109/IECON.2013.6700249.
- [214] Spielmann, M. *Beobachtbarkeitsanalyse nichtlinearer Systeme mittels Digraphen*. Herausgegeben von Schwarz, H. Duisburg, 1996.
- [215] Albertini, F. und D’Alessandro, D. „Remarks on the observability of nonlinear discrete time systems“. In: *System Modelling and Optimization*. Herausgegeben von Doležal, J. und Fidler, J. Boston, MA: Springer US, 1996, Seiten 155–162. ISBN: 978-1-4757-6671-4.
- [216] Albertini, F. und D’Alessandro, D. „Observability and Forward-Backward Observability of Discrete-Time Nonlinear Systems“. In: *Mathematics of Control, Signals, and Systems*. Band 15. London: Springer London, 2002, Seiten 275–290.
- [217] Nakhaeinejad, M. und Bryant, M. D. „Observability analysis for model-based fault detection and sensor selection in induction motors“. In: *Measurement Science and Technology* 22.7 (2011), Seite 075202. ISSN: 0957-0233. DOI: 10.1088/0957-0233/22/7/075202.
- [218] Bärwolff, G. *Numerik für Ingenieure, Physiker und Informatiker*. 2. Auflage. Lehrbuch. Berlin und Heidelberg: Springer Spektrum, 2016. ISBN: 978-3-662-48016-8.
- [219] Mehra, R. „Approaches to adaptive filtering“. In: *IEEE Transactions on Automatic Control* 17.5 (1972), Seiten 693–698. ISSN: 0018-9286. DOI: 10.1109/TAC.1972.1100100.
- [220] Matisko, P. und Havlena, V. „Noise covariances estimation for Kalman filter tuning“. In: *IFAC Proceedings Volumes* 43.10 (2010), Seiten 31–36. ISSN: 14746670. DOI: 10.3182/20100826-3-TR-4015.00009.
- [221] Odelson, B. J., Rajamani, M. R. und Rawlings, J. B. „A new autocovariance least-squares method for estimating noise covariances“. In: *Automatica* 42.2 (2006), Seiten 303–308. ISSN: 00051098. DOI: 10.1016/j.automatica.2005.09.006.

- [222] Oshman, Y. und Shaviv, I. „Optimal tuning of a Kalman filter using genetic algorithms“. In: *AIAA Guidance, Navigation, and Control Conference and Exhibit*. Reston, Virginia: American Institute of Aeronautics and Astronautics, 2000. ISBN: 978-1-62410-301-8. DOI: 10.2514/6.2000-4558.
- [223] Odelson, B. J. „Estimating Disturbance Covariances From Data For Improved Control Performance“. Dissertation. University of Wisconsin-Madison, 2003.
- [224] Mehra, R. „On the identification of variances and adaptive Kalman filtering“. In: *IEEE Transactions on Automatic Control* 15.2 (1970), Seiten 175–184. ISSN: 0018-9286. DOI: 10.1109/TAC.1970.1099422.
- [225] Wang, J. „Stochastic Modeling for Real-Time Kinematic GPS/GLONASS Positioning“. In: *Navigation* 46.4 (1999), Seiten 297–305. ISSN: 00281522. DOI: 10.1002/j.2161-4296.1999.tb02416.x.
- [226] Matisko, P. und Havlena, V. „Noise covariance estimation for Kalman filter tuning using Bayesian approach and Monte Carlo“. In: *International Journal of Adaptive Control and Signal Processing* 27.11 (2013), Seiten 957–973. ISSN: 0890-6327. DOI: 10.1002/acs.2369.
- [227] Chen, Z., Ahmed, N., Julier, S. und Heckman, C. *Kalman Filter Tuning with Bayesian Optimization*. 17. Dez. 2019. URL: <http://arxiv.org/pdf/1912.08601v1>.
- [228] Zagrobelny, M. A. und Rawlings, J. B. *Identification of Disturbance Covariances Using Maximum Likelihood Estimation*. 2014.
- [229] Bavdekar, V. A., Deshpande, A. P. und Patwardhan, S. C. „Identification of process and measurement noise covariance for state and parameter estimation using extended Kalman filter“. In: *Journal of Process Control* 21.4 (2011), Seiten 585–601. ISSN: 09591524. DOI: 10.1016/j.jprocont.2011.01.001.
- [230] Mohan, M. S., Naik, N., Gemson, R. M. O. und Ananthasayanam, M. R. *Introduction to the Kalman Filter and Tuning its Statistics for Near Optimal Estimates and Cramer Rao Bound*. 2015. URL: <http://arxiv.org/pdf/1503.04313v1>.
- [231] Shumway, R. H. und Stoffer, D. S. „An Approach to Time Series Smoothing and Forecasting using the EM Algorithm“. In: *Journal of Time Series Analysis* 3.4 (1982), Seiten 253–264. ISSN: 0143-9782. DOI: 10.1111/j.1467-9892.1982.tb00349.x.
- [232] Dreano, D., Tandeo, P. et al. „Estimating model-error covariances in nonlinear state-space models using Kalman smoothing and the expectation-maximization algorithm“. In: *Quarterly Journal of the Royal Meteorological Society* 143.705 (2017), Seiten 1877–1885. ISSN: 00359009. DOI: 10.1002/qj.3048.
- [233] Belanger, P. R. „Estimation of Noise Covariance Matrices for a Linear Time-Varying Stochastic Process“. In: *IFAC Proceedings Volumes* 5.1 (1972), Seiten 265–271. ISSN: 14746670. DOI: 10.1016/S1474-6670(17)68341-1.
- [234] Åkesson, B. M., Jørgensen, J. B., Poulsen, N. K. und Jørgensen, S. B. „A generalized autocovariance least-squares method for Kalman filter tuning“. In: *Journal of Process Control* 18.7-8 (2008), Seiten 769–779. ISSN: 09591524. DOI: 10.1016/j.jprocont.2007.11.003.

- [235] Bohlin, T. „Four Cases of Identification of Changing Systems“. In: *System Identification Advances and Case Studies*. Band 126. Mathematics in Science and Engineering. Elsevier, 1976, Seiten 441–518. ISBN: 9780124879508. DOI: 10.1016/S0076-5392(08)60878-4.
- [236] Mohamed, A. H. und Schwarz, K. P. „Adaptive Kalman Filtering for INS/GPS“. In: *Journal of Geodesy* 73.4 (1999), Seiten 193–203.
- [237] Han, J., Kim, D. und Sunwoo, M. „State-of-charge estimation of lead-acid batteries using an adaptive extended Kalman filter“. In: *Journal of Power Sources* 188.2 (2009), Seiten 606–612. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2008.11.143.
- [238] Xiong, R., He, H., Sun, F. und Zhao, K. „Evaluation on State of Charge Estimation of Batteries With Adaptive Extended Kalman Filter by Experiment Approach“. In: *IEEE Transactions on Vehicular Technology* 62.1 (2013), Seiten 108–117. ISSN: 0018-9545. DOI: 10.1109/TVT.2012.2222684.
- [239] Xiong, R., Sun, F., He, H. und Nguyen, T. D. „A data-driven adaptive state of charge and power capability joint estimator of lithium-ion polymer battery used in electric vehicles“. In: *Energy* 63 (2013), Seiten 295–308. ISSN: 03605442. DOI: 10.1016/j.energy.2013.10.027.
- [240] Xiong, R., Gong, X., Mi, C. C. und Sun, F. „A robust state-of-charge estimator for multiple types of lithium-ion batteries using adaptive extended Kalman filter“. In: *Journal of Power Sources* 243 (2013), Seiten 805–816. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.06.076.
- [241] Sun, F. und Xiong, R. „A novel dual-scale cell state-of-charge estimation approach for series-connected battery pack used in electric vehicles“. In: *Journal of Power Sources* 274 (2015), Seiten 582–594. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2014.10.119.
- [242] Yang, J., Xia, B., Shang, Y., Huang, W. und Mi, C. C. „Adaptive State-of-Charge Estimation Based on a Split Battery Model for Electric Vehicle Applications“. In: *IEEE Transactions on Vehicular Technology* 66.12 (2017), Seiten 10889–10898. ISSN: 0018-9545. DOI: 10.1109/TVT.2017.2728806.
- [243] Xiong, R., Sun, F., Gong, X. und He, H. „Adaptive state of charge estimator for lithium-ion cells series battery pack in electric vehicles“. In: *Journal of Power Sources* 242 (2013), Seiten 699–713. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2013.05.071.
- [244] Campestrini, C., Heil, T., Kosch, S. und Jossen, A. „A comparative study and review of different Kalman filters by applying an enhanced validation method“. In: *Journal of Energy Storage* 8 (2016), Seiten 142–159. ISSN: 2352152X. DOI: 10.1016/j.est.2016.10.004.
- [245] Wang, S., Fernandez, C. et al. „A novel charged state prediction method of the lithium ion battery packs based on the composite equivalent modeling and improved splice Kalman filtering algorithm“. In: *Journal of Power Sources* 471 (2020), Seite 228450. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.228450.
- [246] Liu, S., Cui, N. und Zhang, C. „An Adaptive Square Root Unscented Kalman Filter Approach for State of Charge Estimation of Lithium-Ion Batteries“. In: *Energies* 10.9 (2017), Seite 1345. DOI: 10.3390/en10091345.

- [247] Cheng, X., Wang, S. und Yao, L. „Li-ion Battery Pack State-of-Charge Estimation Disturbed by Colored Noises“. In: *Energy Procedia* 105 (2017), Seiten 4104–4109. ISSN: 18766102. DOI: 10.1016/j.egypro.2017.03.871.
- [248] Wang, S.-L., Fernandez, C. et al. „An adaptive working state iterative calculation method of the power battery by using the improved Kalman filtering algorithm and considering the relaxation effect“. In: *Journal of Power Sources* 428 (2019), Seiten 67–75. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2019.04.089.
- [249] Einicke, G. A., Malos, J. T., Reid, D. C. und Hainsworth, D. W. „Riccati Equation and EM Algorithm Convergence for Inertial Navigation Alignment“. In: *IEEE Transactions on Signal Processing* 57.1 (2009), Seiten 370–375. ISSN: 1053-587X. DOI: 10.1109/TSP.2008.2007090.
- [250] Li, R. C., Hari Krishnan, T. V. et al. „LPV-Based Real-Time Intake Oxygen Fraction Estimation of a Turbocharged Diesel Engine with EGR“. In: *2020 IEEE Conference on Control Technology and Applications (CCTA)*. IEEE, 2020.
- [251] Korniyenko, O. V., Sharawi, M. S. und Aloji, D. N. „Neural Network Based Approach for Tuning Kalman Filter“. In: *2005 IEEE International Conference on Electro Information Technology*. IEEE, 2005, Seiten 1–5. ISBN: 0-7803-9232-9. DOI: 10.1109/EIT.2005.1626991.
- [252] Rayyam, M. und Zazi, M. „Particle Swarm optimization of a Non-Linear Kalman Filter for Sensorless Control of Induction Motors“. In: *2018 7th International Conference*. 2018, Seiten 1016–1020. DOI: 10.1109/ICRERA.2018.8566984.
- [253] Ting, T. O., Man, K. L., Lim, E. G. und Leach, M. „Tuning of Kalman filter parameters via genetic algorithm for state-of-charge estimation in battery management system“. In: *TheScientificWorldJournal* 2014 (2014), Seite 176052. DOI: 10.1155/2014/176052.
- [254] Yang, R., Xiong, R., He, H., Mu, H. und Wang, C. „A novel method on estimating the degradation and state of charge of lithium-ion batteries used for electrical vehicles“. In: *Applied Energy* 207 (2017), Seiten 336–345. ISSN: 03062619. DOI: 10.1016/j.apenergy.2017.05.183.
- [255] Powell, T. D. „Automated Tuning of an Extended Kalman Filter Using the Downhill Simplex Algorithm“. In: *Journal of Guidance, Control, and Dynamics* 25.5 (2002), Seiten 901–908. ISSN: 0731-5090. DOI: 10.2514/2.4983.
- [256] Goodall, C. und El-Sheimy, N. „Intelligent Tuning of a Kalman Filter using Low-Cost MEMS Inertial Sensors“. In: *Proceedings of the 20th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS 2007)*. 2007, Seiten 2121–2128.
- [257] Tabatabaei, M., Hakanen, J., Hartikainen, M., Miettinen, K. und Sindhya, K. „A survey on handling computationally expensive multiobjective optimization problems using surrogates: non-nature inspired methods“. In: *Structural and Multidisciplinary Optimization* 52.1 (2015), Seiten 1–25. ISSN: 1615-147X. DOI: 10.1007/s00158-015-1226-z.
- [258] Weicker, K. *Evolutionäre Algorithmen*. Wiesbaden: Springer Fachmedien Wiesbaden, 2015. ISBN: 978-3-658-09957-2. DOI: 10.1007/978-3-658-09958-9.

- [259] Goldberg, D. E. *Genetic algorithms in search, optimization, and machine learning*. Repr. with corr. Reading, Mass.: Addison-Wesley, 1989. ISBN: 978-0-201-15767-3.
- [260] Holland, J. H. *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. 1st MIT Press ed. Complex adaptive systems. Cambridge, Massachusetts: MIT Press, 1992. ISBN: 9780262275552.
- [261] Deb, K. *Multi-objective optimization using evolutionary algorithms*. 1. ed. Wiley-Interscience series in systems and optimization. Chichester: Wiley, 2001. ISBN: 978-0-471-87339-6.
- [262] Theiler, M., Schneider, D. und Endisch, C. „Kalman Filter Tuning Using Multi-Objective Genetic Algorithm for State and Parameter Estimation of Lithium-Ion Cells“. In: *Batteries* 8.9 (2022), Seite 104. DOI: 10.3390/batteries8090104.
- [263] Gerdes, I., Klawonn, F. und Kruse, R. *Evolutionäre Algorithmen: Genetische Algorithmen - Strategien und Optimierungsverfahren - Beispielanwendungen ; [mit Online-Service zum Buch*. 1. Aufl. Computational intelligence. Wiesbaden: Vieweg, 2004. ISBN: 978-3-528-05570-7.
- [264] o. V. *Genetic Algorithm Options (R2021b)*. 2021. URL: <https://de.mathworks.com/help/gads/genetic-algorithm-options.html#f6633> (besucht am 31.01.2022).
- [265] Zhang, W., Wang, L., Wang, L. und Liao, C. „An improved adaptive estimator for state-of-charge estimation of lithium-ion batteries“. In: *Journal of Power Sources* 402 (2018), Seiten 422–433. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2018.09.016.
- [266] Zheng, Y., Ouyang, M., Han, X., Lu, L. und Li, J. „Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles“. In: *Journal of Power Sources* 377 (2018), Seiten 161–188. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2017.11.094.
- [267] Ren, L., Zhu, G., Wang, J. V., Luo, B. und Kang, J. „Comparison of robustness of different state of charge estimation algorithms“. In: *Journal of Power Sources* 478 (2020), Seite 228767. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2020.228767.
- [268] Rhode, S. und Gauterin, F. „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, Seiten 269–276. ISBN: 978-1-4673-2755-8. DOI: 10.1109/IVS.2013.6629481.
- [269] Beyer, S. „Robuste Parameterschätzung für Elektrofahrzeuge“. Dissertation. Neubiberg: Universität der Bundeswehr, 2019.
- [270] Gupta, N. und Hauser, R. *Kalman Filtering with Equality and Inequality State Constraints*. Oxford, UK, 2007. URL: <http://eprints.maths.ox.ac.uk/1084/1/NA-07-18.pdf> (besucht am 04.08.2021).
- [271] Stenlund, B. und Gustafsson, F. „Avoiding windup in recursive parameter estimation“. In: *Reglermöte 2002* (2002), Seiten 148–153. (Besucht am 27.10.2020).
- [272] Åström, K. J. und Wittenmark, B. *Adaptive Control: Second Edition*. Dover Books on Electrical Engineering. Newburyport: Dover Publications, 2013. ISBN: 9780486319148.

- [273] Schneider, D., Liebhart, B. und Endisch, C. „Active state and parameter estimation as part of intelligent battery systems“. In: *Journal of Energy Storage* 39 (2021), Seite 102638. ISSN: 2352152X. DOI: 10.1016/j.est.2021.102638.
- [274] Schneider, D., Liebhart, B., Endisch, C. und Kennel, R. „Enhanced State and Parameter Estimation within Reconfigurable Battery Systems for Electric Vehicles“. In: *2022 12th International Conference on Power, Energy and Electrical Engineering (CPEEE)*. IEEE, 2022, Seiten 71–77. ISBN: 978-1-6654-2049-5. DOI: 10.1109/CPEEE54404.2022.9738700.
- [275] Pintelon, R. *System identification: A frequency domain approach*. 2nd ed. Hoboken, N.J.: John Wiley & Sons, 2012. ISBN: 9781118287392. DOI: 10.1002/9781118287422.
- [276] Schoukens, J., Godfrey, K. und Schoukens, M. „Nonparametric Data-Driven Modeling of Linear Systems: Estimating the Frequency Response and Impulse Response Function“. In: *IEEE Control Systems* 38.4 (2018), Seiten 49–88. ISSN: 1066-033X. DOI: 10.1109/MCS.2018.2830080.
- [277] Goertzel, G. „An Algorithm for the Evaluation of Finite Trigonometric Series“. In: *The American Mathematical Monthly* 65.1 (1958), Seite 34. ISSN: 00029890. DOI: 10.2307/2310304.
- [278] Kammeyer, K.-D. und Kroschel, K. *Digitale Signalverarbeitung: Filterung und Spektralanalyse mit MATLAB-Übungen*. 9., korrigierte und ergänzte Auflage. Lehrbuch. Wiesbaden: Springer Vieweg, 2018. ISBN: 978-3-658-20134-0.
- [279] Meyer, M. *Signalverarbeitung*. Wiesbaden: Springer Fachmedien Wiesbaden, 2017. ISBN: 978-3-658-18320-2. DOI: 10.1007/978-3-658-18321-9.
- [280] Theiler, M., Schneider, D. und Endisch, C. „Experimental Investigation of State and Parameter Estimation within Reconfigurable Battery Systems“. In: *Batteries* 9.3 (2023), Seite 145. DOI: 10.3390/batteries9030145.
- [281] Osswald, P. J., Erhard, S. V. et al. „Current density distribution in cylindrical Li-Ion cells during impedance measurements“. In: *Journal of Power Sources* 314 (2016), Seiten 93–101. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2016.02.070.
- [282] Uddin, K., Moore, A. D., Barai, A. und Marco, J. „The effects of high frequency current ripple on electric vehicle battery performance“. In: *Applied Energy* 178 (2016), Seiten 142–154. ISSN: 03062619. DOI: 10.1016/j.apenergy.2016.06.033.
- [283] Soares, R., Bessman, A., Wallmark, O., Lindbergh, G. und Svens, P. „An Experimental Setup with Alternating Current Capability for Evaluating Large Lithium-Ion Battery Cells“. In: *Batteries* 4.3 (2018), Seite 38. DOI: 10.3390/batteries4030038.
- [284] Elgowainy, A. *Electric, Hybrid, and Fuel Cell Vehicles*. New York, NY: Springer New York, 2021. ISBN: 978-1-0716-1491-4. DOI: 10.1007/978-1-0716-1492-1.
- [285] Bala, S., Tengner, T., Rosenfeld, P. und Delince, F. „The effect of low frequency current ripple on the performance of a Lithium Iron Phosphate (LFP) battery energy storage system“. In: *2012 IEEE Energy Conversion Congress and Exposition (ECCE)*. IEEE, 2012, Seiten 3485–3492. ISBN: 978-1-4673-0803-8. DOI: 10.1109/ECCE.2012.6342318.

- [286] Chang, F., Roemer, F. und Lienkamp, M. „Influence of Current Ripples in Cascaded Multilevel Topologies on the Aging of Lithium Batteries“. In: *IEEE Transactions on Power Electronics* 35.11 (2020), Seiten 11879–11890. ISSN: 0885-8993. DOI: 10.1109/TPEL.2020.2989145.
- [287] Juang, L. W., Kollmeyer, P. J. et al. „Investigation of the influence of superimposed AC current on lithium-ion battery aging using statistical design of experiments“. In: *Journal of Energy Storage* 11 (2017), Seiten 93–103. ISSN: 2352152X. DOI: 10.1016/j.est.2017.02.005.
- [288] Bessman, A., Soares, R., Wallmark, O., Svens, P. und Lindbergh, G. „Aging effects of AC harmonics on lithium-ion cells“. In: *Journal of Energy Storage* 21 (2019), Seiten 741–749. ISSN: 2352152X. DOI: 10.1016/j.est.2018.12.016.
- [289] Hall, D. L. und Llinas, J. „An introduction to multisensor data fusion“. In: *Proceedings of the IEEE* 85.1 (1997), Seiten 6–23. ISSN: 00189219. DOI: 10.1109/5.554205.
- [290] Elmenreich, W. „An Introduction to Sensor Fusion“. Research report. Wien: TU Wien, 2002.
- [291] Schneider, D. und Endisch, C. „Robustness and Reliability of Model-based Sensor Data Fusion in a Lithium-Ion Battery System“. In: *2020 IEEE Conference on Control Technology and Applications (CCTA)*. IEEE, 2020, Seiten 685–691. DOI: 10.1109/CCTA41146.2020.9206336.
- [292] Schneider, D., Vögele, U. und Endisch, C. „Model-based sensor data fusion of quasi-redundant voltage and current measurements in a lithium-ion battery module“. In: *Journal of Power Sources* 440 (2019), Seite 227156. ISSN: 03787753. DOI: 10.1016/j.jpowsour.2019.227156.
- [293] Schneider, D., Liebhart, B. und Endisch, C. „Adaptive Variance Estimation of Sensor Noise within a Sensor Data Fusion Framework“. In: *2021 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. IEEE, 2021. DOI: 10.1109/I2MTC50364.2021.9459790.
- [294] Oliveira, A. und Seijas-Macias, A. „An Approach to Distribution of the Product of Two Normal Variables“. In: *Discussiones Mathematicae Probability and Statistics* 32.1-2 (2012), Seite 87. ISSN: 1509-9423. DOI: 10.7151/dmps.1146.
- [295] Díaz-Francés, E. und Rubio, F. J. „On the existence of a normal approximation to the distribution of the ratio of two independent normal random variables“. In: *Statistical Papers* 54.2 (2013), Seiten 309–323. ISSN: 0932-5026. DOI: 10.1007/s00362-012-0429-2.
- [296] Ruckdeschel, P. „Ansätze zur Robustifizierung des Kalman-Filters“. Dissertation. Bayreuth: Universität Bayreuth, 2001.
- [297] Salgado, M., Goodwin, G. und Middleton, R. „Modified least squares algorithm incorporating exponential resetting and forgetting“. In: *International Journal of Control* 47.2 (1988), Seiten 477–491. ISSN: 0020-7179. DOI: 10.1080/00207178808906026.
- [298] Krus, P. und Gunnarsson, S. „Adaptive Control of a Hydraulic Crane Using On-line Identification“. In: *Proceedings of the Third Scandinavian International Conference on Fluid Power* (1993).

- [299] Cao, L. und Schwartz, H. M. „A novel recursive algorithm for directional forgetting“. In: *Proceedings of the 1999 American Control Conference (Cat. No. 99CH36251)*. IEEE, 1999, Seiten 1334–1338. ISBN: 0-7803-4990-3. DOI: 10.1109/ACC.1999.783584.
- [300] Cao, L. und Schwartz, H. „A directional forgetting algorithm based on the decomposition of the information matrix“. In: *Automatica* 36.11 (2000), Seiten 1725–1731. ISSN: 00051098. DOI: 10.1016/S0005-1098(00)00093-5.
- [301] Cao, L. und Schwartz, H. M. „The Kalman filter based recursive algorithm: windup and its avoidance“. In: *Proceedings of the 2001 American Control Conference. (Cat. No.01CH37148)*. IEEE, 2001, Seiten 3606–3611. ISBN: 0-7803-6495-3. DOI: 10.1109/ACC.2001.946194.
- [302] Cao, L. und Schwartz, H. M. „Analysis of the Kalman filter based estimation algorithm: an orthogonal decomposition approach“. In: *Automatica* 40.1 (2004), Seiten 5–19. ISSN: 00051098. DOI: 10.1016/j.automatica.2003.07.011.
- [303] Aravkin, A., Burke, J. V., Ljung, L., Lozano, A. und Pillonetto, G. „Generalized Kalman smoothing: Modeling and algorithms“. In: *Automatica* 86 (2017), Seiten 63–86. ISSN: 00051098. DOI: 10.1016/j.automatica.2017.08.011.
- [304] Alspach, D. und Sorenson, H. „Nonlinear Bayesian estimation using Gaussian sum approximations“. In: *IEEE Transactions on Automatic Control* 17.4 (1972), Seiten 439–448. ISSN: 0018-9286. DOI: 10.1109/TAC.1972.1100034.
- [305] Schön, T. B., Wills, A. und Ninness, B. „System identification of nonlinear state-space models“. In: *Automatica* 47.1 (2011), Seiten 39–49. ISSN: 00051098. DOI: 10.1016/j.automatica.2010.10.013.
- [306] Agamennoni, G., Nieto, J. I. und Nebot, E. M. „An outlier-robust Kalman filter“. In: *2011 IEEE International Conference on Robotics and Automation*. IEEE, 2011, Seiten 1551–1558. ISBN: 978-1-61284-386-5. DOI: 10.1109/ICRA.2011.5979605.
- [307] Kullback, S. und Leibler, R. A. „On Information and Sufficiency“. In: *The Annals of Mathematical Statistics* 22.1 (1951), Seiten 79–86. ISSN: 0003-4851. DOI: 10.1214/aoms/1177729694.
- [308] Bishop, C. M. *Pattern recognition and machine learning*. Corrected at 8th printing 2009. Information science and statistics. New York, NY: Springer, 2009. ISBN: 978-0387-31073-2.
- [309] Leitner, L. „Lernfähige Algorithmen für die Endfunktionsprüfung am Beispiel der Fahrzeugmotorenherstellung“. Dissertation. München: Technische Universität München.
- [310] Roth, M., Ozkan, E. und Gustafsson, F. „A Student’s t filter for heavy tailed process and measurement noise“. In: *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. IEEE, 2013, Seiten 5770–5774. ISBN: 978-1-4799-0356-6. DOI: 10.1109/ICASSP.2013.6638770.
- [311] Roth, M. „Kalman Filters for Nonlinear Systems and Heavy-Tailed Noise“. Dissertation. Linköping: Linköping University, 2013. URL: <https://pdfs.semanticscholar.org/1c39/88b92ff7a23f379af645ce1e869a72463bab.pdf> (besucht am 21.04.2022).

- [312] Roth, M., Ardeshiri, T., Özkan, E. und Gustafsson, F. *Robust Bayesian Filtering and Smoothing Using Student's t Distribution*. 2017. URL: <http://arxiv.org/pdf/1703.02428v1>.
- [313] Leitner, L. und Endisch, C. „Robust stochastic process models and parameter estimation for industrial end-of-line-testing“. In: *2018 IEEE International Conference on Industrial Technology (ICIT)*. IEEE, 2018, Seiten 1520–1525. ISBN: 978-1-5090-5949-2. DOI: 10.1109/ICIT.2018.8352406.
- [314] Gelman, A., Carlin, J. B. et al. *Bayesian data analysis*. 3rd edition. Texts in statistical science series. Boca Raton, London und New York: CRC Press Taylor and Francis Group, 2014. ISBN: 978-1-4398-4095-5.
- [315] Frolik, J. und Abdelrahman, M. „Synthesis of quasi-redundant sensor data: a probabilistic approach“. In: *Proceedings of the 2000 American Control Conference. ACC*. IEEE, 2000, Seiten 2917–2921. ISBN: 0-7803-5519-9. DOI: 10.1109/ACC.2000.878744.
- [316] Frolik, J., Abdelrahman, M. und Kandasamy, P. „A confidence-based approach to the self-validation, fusion and reconstruction of quasi-redundant sensor data“. In: *IEEE Transactions on Instrumentation and Measurement* 50.6 (2001), Seiten 1761–1769. ISSN: 0018-9456. DOI: 10.1109/19.982977.
- [317] Park, Y.-G., Liu, L. und Jacobi, A. M. „Rational approaches for combining redundant, independent measurements to minimize combined experimental uncertainty“. In: *Experimental Thermal and Fluid Science* 34.6 (2010), Seiten 720–724. ISSN: 08941777. DOI: 10.1016/j.expthermflusci.2010.01.001.
- [318] Strutz, T. *Data fitting and uncertainty: A practical introduction to weighted least squares and beyond*. 2nd, revised and extended edition. Wiesbaden: Springer Vieweg, 2016. ISBN: 978-3-658-11455-8.
- [319] Maybeck, P. S. *Stochastic models, estimation, and control 1*. Band 141,1. Mathematics in Science and Engineering. New York: Acad. Press, 1979. ISBN: 0-12-480701-1.
- [320] Lienig, J. und Brümmer, H. *Fundamentals of electronic systems design*. Electrical Engineering. Cham: Springer, 2017. ISBN: 978-3-319-55840-0.
- [321] Yang, G. *Life Cycle Reliability Engineering*. Hoboken, NJ, USA: John Wiley & Sons, Inc, 2007. ISBN: 9780470117880. DOI: 10.1002/9780470117880.
- [322] Branke, J. *Multiobjective optimization: Interactive and evolutionary approaches*. Band 5252. State of the art survey. Berlin: Springer, 2008. ISBN: 978-3-540-88908-3. DOI: 10.1007/978-3-540-88908-3.
- [323] Bos, R., Bombois, X. und van den Hof, P. M. „Designing a Kalman Filter when no Noise Covariance Information is Available“. In: *IFAC Proceedings Volumes* 38.1 (2005), Seiten 1275–1280. ISSN: 14746670. DOI: 10.3182/20050703-6-CZ-1902.00213.
- [324] Nilsson, M. „Kalman Filtering with Unknown Noise Covariances“. In: *Proceedings of the Reglermöte* (2006). URL: <http://www.diva-portal.org/smash/record.jsf?pid=diva2%3A1041201&dswid=-9470>.

- [325] Jondral, F. und Wiesler, A. *Wahrscheinlichkeitsrechnung und stochastische Prozesse: Grundlagen für Ingenieure und Naturwissenschaftler ; mit 45 Übungsaufgaben und Tabellen*. 2., durchges. und aktualisierte Aufl. Lehrbuch. Stuttgart: Teubner, 2002. ISBN: 3519162636.
- [326] Welford, B. P. „Note on a Method for Calculating Corrected Sums of Squares and Products“. In: *Technometrics* 4.3 (1962), Seite 419. ISSN: 00401706. DOI: 10.2307/1266577.
- [327] Ling, R. F. „Comparison of Several Algorithms for Computing Sample Means and Variances“. In: *Journal of the American Statistical Association* 69.348 (1974), Seite 859. ISSN: 01621459. DOI: 10.2307/2286154.
- [328] West, D. H. D. „Updating mean and variance estimates“. In: *Communications of the ACM* 22.9 (1979), Seiten 532–535. ISSN: 0001-0782. DOI: 10.1145/359146.359153.
- [329] Chan, T. F., Golub, G. H. und LeVeque, R. J. „Algorithms for Computing the Sample Variance: Analysis and Recommendations“. In: *The American Statistician* 37.3 (1983), Seite 242. ISSN: 00031305. DOI: 10.2307/2683386.
- [330] Rogers, S. „Sensor noise fault detection“. In: *Proceedings of the 2003 American Control Conference, 2003*. IEEE, 2003, Seiten 4267–4268. ISBN: 0-7803-7896-2. DOI: 10.1109/ACC.2003.1240506.
- [331] Neumann, J. von. „Distribution of the Ratio of the Mean Square Successive Difference to the Variance“. In: *The Annals of Mathematical Statistics* 12.4 (1941), Seiten 367–395. ISSN: 0003-4851. DOI: 10.1214/aoms/1177731677.
- [332] Rice, J. „Bandwidth Choice for Nonparametric Regression“. In: *The Annals of Statistics* 12.4 (1984), Seiten 1215–1230. ISSN: 0090-5364. DOI: 10.1214/aos/1176346788.
- [333] Gasser, T., Sroka, L. und Jennen-Steinmetz, C. „Residual variance and residual pattern in nonlinear regression“. In: *Biometrika* 73.3 (1986), Seiten 625–633. ISSN: 0006-3444. DOI: 10.1093/biomet/73.3.625.
- [334] Hall, P. und Marron, J. S. „On variance estimation in nonparametric regression“. In: *Biometrika* 77.2 (1990), Seiten 415–419. ISSN: 0006-3444. DOI: 10.1093/biomet/77.2.415.
- [335] Dette, H., Munk, A. und Wagner, T. „Estimating the variance in nonparametric regression—what is a reasonable choice?“ In: *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 60.4 (1998), Seiten 751–764. ISSN: 1369-7412. DOI: 10.1111/1467-9868.00152.
- [336] Dai, W., Ma, Y., Tong, T. und Zhu, L. „Difference-based variance estimation in nonparametric regression with repeated measurement data“. In: *Journal of Statistical Planning and Inference* 163 (2015), Seiten 1–20. ISSN: 03783758. DOI: 10.1016/j.jspi.2015.02.010.
- [337] Braess, H.-H. und Seiffert, U. *Vieweg Handbuch Kraftfahrzeugtechnik*. Wiesbaden: Springer Fachmedien Wiesbaden, 2013. ISBN: 978-3-658-01690-6. DOI: 10.1007/978-3-658-01691-3.
- [338] Hedderich, J. und Sachs, L. *Angewandte Statistik*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018. ISBN: 978-3-662-56656-5. DOI: 10.1007/978-3-662-56657-2.