

Abschlussbericht

Batteriemanagement für Lithium-Titanat-Zellen

Projekt: 17008

Fachhochschule Kiel
Prof. Dr.-Ing. Christoph Weber
Institut für Mechatronik

in Zusammenarbeit mit

der Liacon GmbH

Institut für Mechatronik
Prof. Dr.-Ing. Christoph Weber

Grenzstr. 3, 24149 Kiel,
E-Mail: Christoph.Weber@FH-Kiel.de

Tel. +49 431 210-2583, Fax +49 431 210-62583
Internet: www.fh-kiel.de/kesh
www.kompetenzzentrum-leistungselektronik.com

Inhaltsverzeichnis:

1	Zusammenfassung	3
2	Aktueller Entwicklungsstand des Batteriemanagementsystems (BMS)	4
2.1	Aufbau des entwickelten BMS	4
2.1.1	Komponenten	4
2.1.2	Kostenoptimierung des BMS-Slaves	5
2.2	Einflussfaktoren für SoC-Bestimmung	5
2.3	Neuronales Netz zur SoC-Bestimmung	7
2.3.1	Erzeugung von Trainingsdatensätzen	7
2.3.2	Konvertierung der Datensätze	9
2.3.3	Training des Neuronalen Netzes	10
2.3.4	Ergebnisse der SoC-Bestimmung durch ein Neuronales Netze	11
3	Zusammenfassung und Ausblick	14
4	Danksagung	16

1 Zusammenfassung

In der heutigen Zeit spielen Akkumulatoren in vielen Bereichen der Wirtschaft eine immer größer werdende Rolle. Dies ist der Grund, weshalb die Industrie seit Jahren an neuen Zelltechnologien forscht. Der Entwicklungstrend liegt auf Eigenschaften, wie höherer Energie- und Leistungsdichte sowie geringeren Herstellungskosten. Jedoch können nicht alle Faktoren zugunsten eines besseren Produktes in positiver Richtung verändert werden. Aus diesem Grund wird immer ein Kompromiss geschlossen. Dabei können nachteilige Eigenschaften wie z.B. eine höhere Empfindlichkeit gegenüber fehlerhaften Zellzuständen (zu hohe Spannungen, Ströme, Temperaturen usw.) entstehen, bei deren Missachtung die Lebenszeiterwartung, Energie- und Leistungsdichte usw. der Akkumulatoren leiden können.

Aus diesem Grund haben sich in der Vergangenheit Batteriemanagementsysteme (BMS) zu unerlässlichen Begleitern neuer Akkumulatortechnologien entwickelt. Einfache BMS verfügen nur über obligatorische Überwachungsfunktionen (Limitmonitoring) der Zellzustände und schützen den Akkumulator bei Grenzüberschreitungen. Darüber hinaus können komplexere Systeme nicht direkt messbare Zustände, wie den Ladezustand (State of Charge = SoC), Verschleiß etc. zuverlässig schätzen und per Schnittstellen über die Systemgrenze hinaus kommunizieren.

Das Ziel des Projektes ist es, ein funktionstüchtiges Batteriemanagementsystem zu schaffen, das neben den Basis-Funktionen (Monitoring der Zellspannungen und Balancing) hochwertige Schätzalgorithmen zur Erfassung des Ladezustandes im laufenden Betrieb bereitstellt. Dabei liegt der Fokus auf der Impedanzmessung als Grundlage für die Erfassung des Ladezustandes. Die grundlegenden Messaufgaben werden dabei von Batteriemangement-Slaves erfüllt. Die hochwertigen Algorithmen werden auf einem Batteriemangement-Master ausgeführt.

Erreicht wurde ein System, das auf Basis von ausgewählten Merkmalen, die Schätzung des SoC erfolgreich durchführen kann. Die Ergebnisse wurden im Rahmen eines überwachten Trainings erzielt.

2 Aktueller Entwicklungsstand des Batteriemanagementsystems (BMS)

2.1 Aufbau des entwickelten BMS

2.1.1 Komponenten

Das BMS der Fachhochschule setzt sich aus drei Teilen zusammen dem BMS-Master, BMS-Gateway und je nach Batteriezellenanzahl ein oder mehrere BMS-Slaves.

BMS-Master

Der BMS-Master übernimmt in diesem Verbund übergeordnete Aufgaben. Bei ihm laufen die Informationen der BMS-Slaves zusammen. Diese Messinformationen werden zum einen direkt für das Limit-Monitoring verwendet und zum anderen um nicht direkt Messbare Größen wie den State-of-Charge (SoC) zu bestimmen. Das Mastersystem ist ein Raspberry PI, welcher in der Lage ist, eine Vielzahl von Messdaten aufzuzeichnen und zu verarbeiten.

Durch die Möglichkeit, die Steuergerätesoftware in Python zu programmieren, sind insbesondere Modell, die aus maschinellen Lernverfahren gewonnen wurden, einfach zu importieren und zu nutzen. Im Rahmen des Projektes wurden des weiteren Schnittstellen entwickelt, mit denen die aufgezeichneten Merkmalsdatensätze via WLAN auf ausgelagerte Cloud-Computersysteme übertragen werden können. In Zukunft wird es damit möglich sein, das Training der Modelle auf leistungsfähigen Rechnern durchführen zu lassen.

BMS-Slave

Die BMS-Slave messen direkt an den Batteriezellen und bestimmen Strom, Spannung und Temperatur. Außerdem kann jeder BMS-Slave eine zellindividuelle Impedanzmessung durchführen um weitere Informationen über die einzelnen Zellzustände zu erhalten.

Die Kommunikation erfolgt über ein galvanisch getrennte CAN-Bus-Schnittstelle.

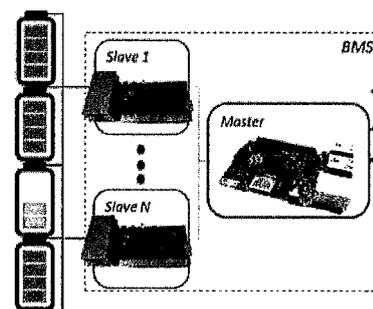


Abbildung 1: BMS der FH Kiel

2.1.2 Kostenoptimierung des BMS-Slaves

Im Rahmen des Projektes wurde der BMS-Slave umgearbeitet um spätere Kostenreduktionen zu ermöglichen. Die Überarbeiteten BMS-Slaves besitzen einen niedriger auflösenden und langsameren AD-Wandler als die Vorgängerversionen für die Impedanzmessung, da dieses Bauteil unter anderem für eine mögliche Kostenreduktion identifiziert wurde. Dabei soll bei der neusten Version nachgewiesen werden, dass der Kostengünstigere AD-Wandler für die Messaufgabe ausreicht.

2.2 Einflussfaktoren für SoC-Bestimmung

Der State-of-Charge zählt zu einer nicht direkt messbaren Batterieeigenschaft. Sie wird bei vielen Batterieanwendung durch Integration des Stroms oder durch eine Referenzierung an der Leerlaufspannung der Batterie von Batteriemanagementsystemen berechnet. Die in diesem Projekt verwendete Lithium-Titanat-Polymerzellen der Firma Liacon weisen jedoch über einen weiten SoC-Bereich (10%-90% SoC) eine sehr geringe Änderung der Leerlaufspannung auf, so dass eine Referenzierung über die Leerlaufspannung in diesem Bereich schwierig ist.

Es hat sich gezeigt das die Impedanzmessung unter anderem Abhängig vom Ladezustand der Batterie sind (siehe Abbildung 2).

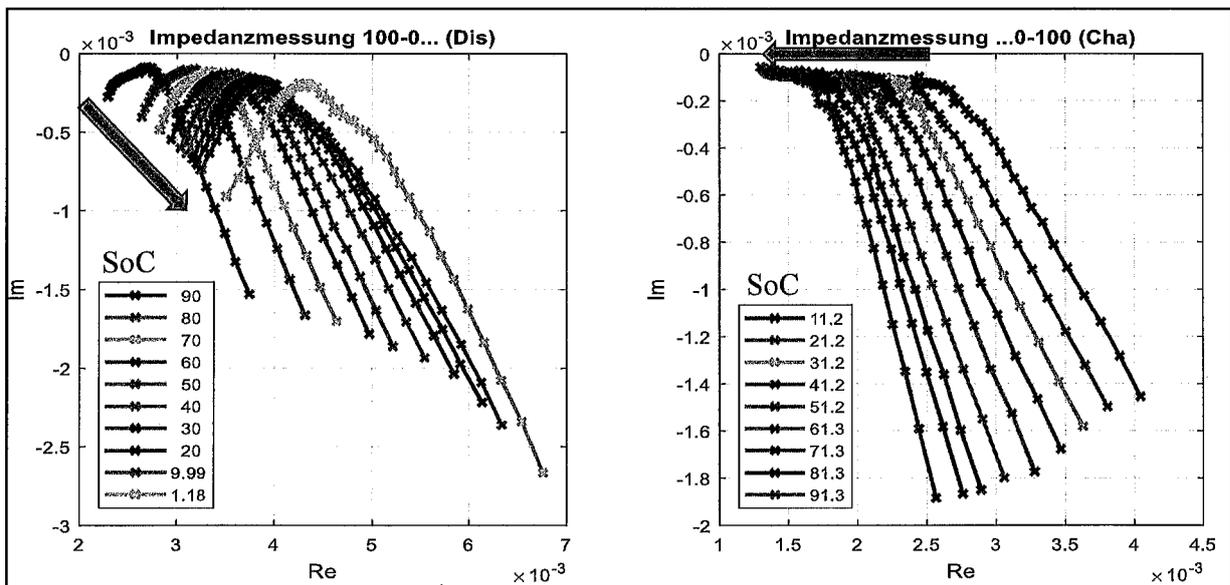


Abbildung 2: Impedanzmessungen, links: Entladung von 100%-0% SoC, rechts: Aufladen von 0%-100%

Im linken Graph dieser Abbildung sind die Messkurven für die Entladung einer Lithium-Titanat-Zelle von 100% auf 0% SoC in 10%-Schritten dargestellt. Im rechtem Graph in gleicher Form die Aufladung in 10%-Schritten dargestellt. Dabei ist deutlich eine Abhängigkeit der Impedanzkurve vom Ladezustand sowie von der Stromrichtung zu erkennen.

Weitere Messungen haben eine Abhängigkeiten der Impedanzkurve von der Zelltemperatur nahegelegt (siehe Abbildung 3).

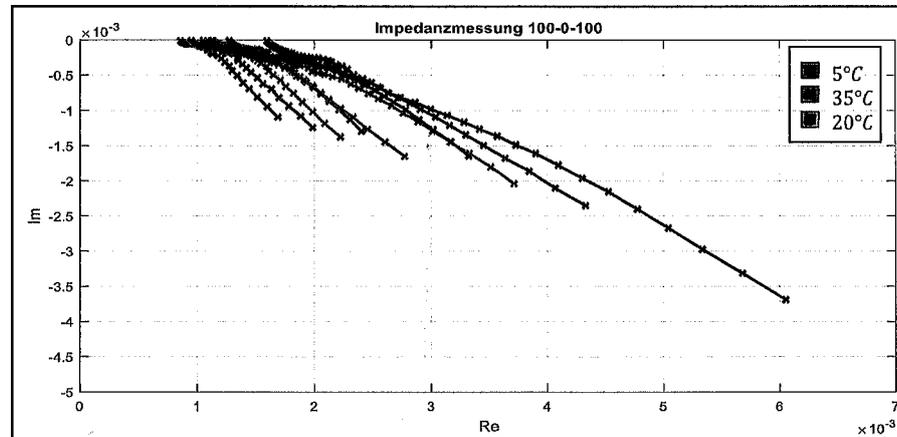


Abbildung 3: Impedanzmessungen, 90%-10%-90% SoC bei 5°C, 20°C und 35°C

Mit diesen Labormessungen konnte gezeigt werden, dass die Impedanzmessungen nicht nur vom Ladezustand der Zelle abhängig sind, sondern auch vom vorher vorliegenden Stromprofil und der Zelltemperatur.

Um aus einer Impedanzmessung den Ladezustand der Batterie zu extrahieren sollen Neuronale Netze verwendet werden. Neuronale Netze finden z.B. bei in der Mustererkennung bereits Einsatz.

2.3 Neuronales Netz zur SoC-Bestimmung

Neuronale Netze werden trainiert. Daher mussten zunächst Datensätze für das Training erstellt werden. Bei dieser Messaufgabe müssen die Faktoren, die später als Ein- bzw. Ausgänge verwendet werden sollen aufgezeichnet werden.

2.3.1 Erzeugung von Trainingsdatensätzen

Zur Erzeugung von Datensätzen für das Training von Neuronalen Netzen wurden mit einem Labormessgerät sechs Lithium-Titanat-Zellen bei verschiedenen Temperaturen mit unterschiedlichen Stromprofilen beaufschlagt und anschließend eine Impedanzmessung durchgeführt. Durch die Integration des Stroms und gelegentlicher Referenzierung des Ladezustandes durch vollständiges aufladen der Batteriezellen könne so Messdatensätze

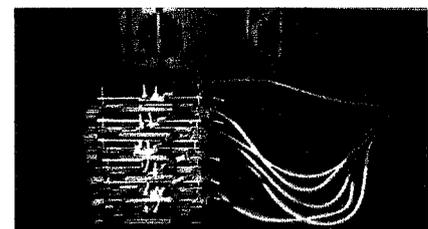


Abbildung 4: Testaufbau, Batteriezellen in Klimakammer

bestehend aus Impedanzmessung, Stromprofil, Temperatur und Ladezustand erzeugt werden.

In Abbildung 5 werden die Datensätze der Eingangsmerkmale gezeigt, mit denen der überwachte Trainingsvorgang durchgeführt wurde:

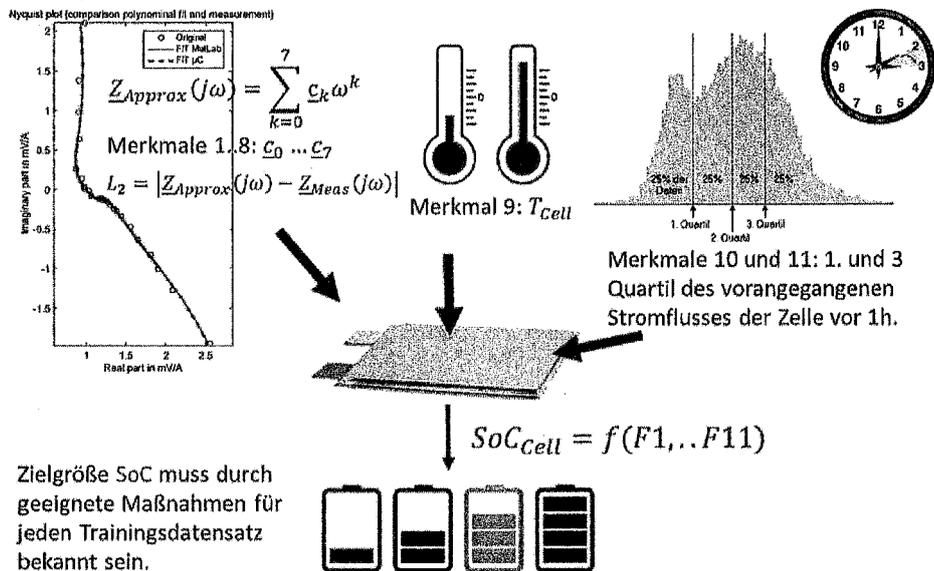


Abbildung 5 Gegenüberstellung Eingangsmerkmale und Zielgröße (SoC)

Die Impedanzkurve einer Zelle zu einem bestimmten Zustand wird mithilfe einer komplexen Polynomapproximation 7. Grades sehr gut gefittet. Hieraus lassen sich insgesamt acht reelle und imaginäre Koeffizienten (c_0 bis c_7) berechnen, welche den frequenzabhängigen Verlauf mit hoher Genauigkeit wiedergeben können. Daneben fließen die Temperatur der Zelle zum Zeitpunkt der Messung sowie zwei weitere statistische Größen des Stromverlaufs (oberes und unteres Quartil) der vorangegangenen Stunde in die Modellbildung mit ein. Als Zielgröße dient der jeweilig vorliegende Ladezustand (SoC) der Zelle.

Um diese Größe für das überwachte Lernverfahren erfassen zu können, müssen die Prüflinge im Labor einem präparierten Test unterzogen werden, welche in Abbildung 6 gezeigt wird.

Darin werden mehrere Lithium-Ionen-Zellen in einer Klimakammer mit Stromprofilen beaufschlagt, deren Verlauf einer Primärregelleistungsanforderung entspricht. Diese ist bis auf einen kleinen Todbereich proportional zur Abweichung der aktuellen Netzfrequenz zu 50Hz. Auf diese Weise kann sichergestellt werden, dass die Zellen einem sehr realistischen Test unterzogen werden.

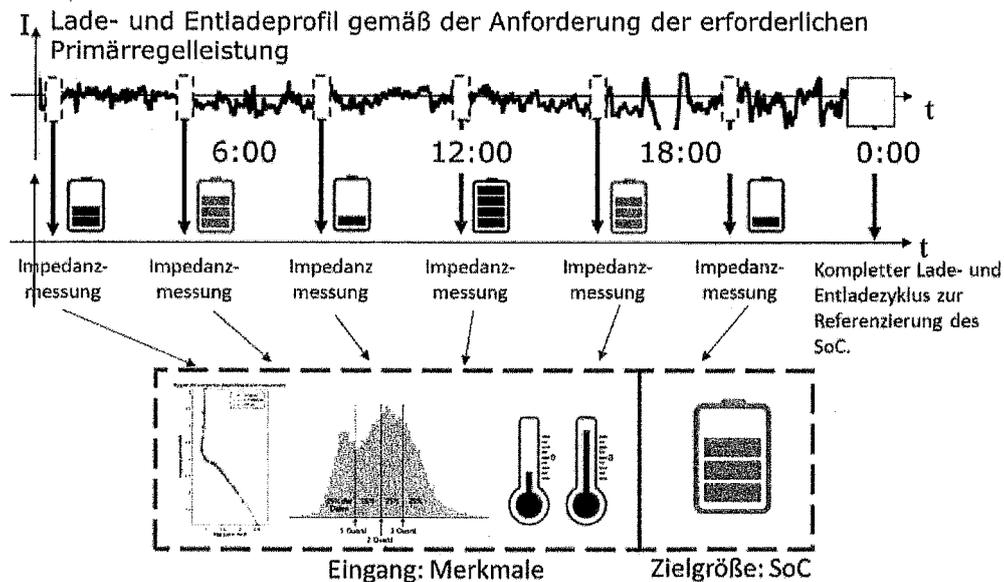


Abbildung 6 Erfassung der Merkmalsdatensätze und der Zielgröße durch Labormessungen

An mehreren Zeitpunkten eines Tages werden dabei die Impedanzspektren der Zellen vermessen. Durch die Klimakammer kann sichergestellt werden, dass alle relevanten Temperaturbereiche im Test erreicht werden.

Da am Ende eines Tages ein kompletter Lade- und Entladezyklus stattfindet, kann auch der aktuelle Ladezustand (SoC) als Zielgröße referenziert werden. Dies ermöglicht die genaue SoC-Bestimmung der einzelnen Zellen zu den Zeitpunkten, an denen die Impedanzmessungen stattgefunden haben. Auf diese Weise ist es möglich den oben beschriebenen Eingangsmerkmalen jeweils eine gültige Zielgröße zuzuordnen.

2.3.2 Konvertierung der Datensätze

Die so erzeugten Datensätze müssen anschließend konvertiert werden, so dass sie als Eingangs- und Ausgangsparameter für ein Neuronales Netz praktisch einsetzbar sind.

Die Amplituden- und Phasengänge der Impedanzkurven werden jeweils mit einem Polynom sechsten Grades gefittet. Damit wird jede Impedanzkurve auf 16 (acht Real und acht Imaginärteile) Eingangsparameter reduziert.

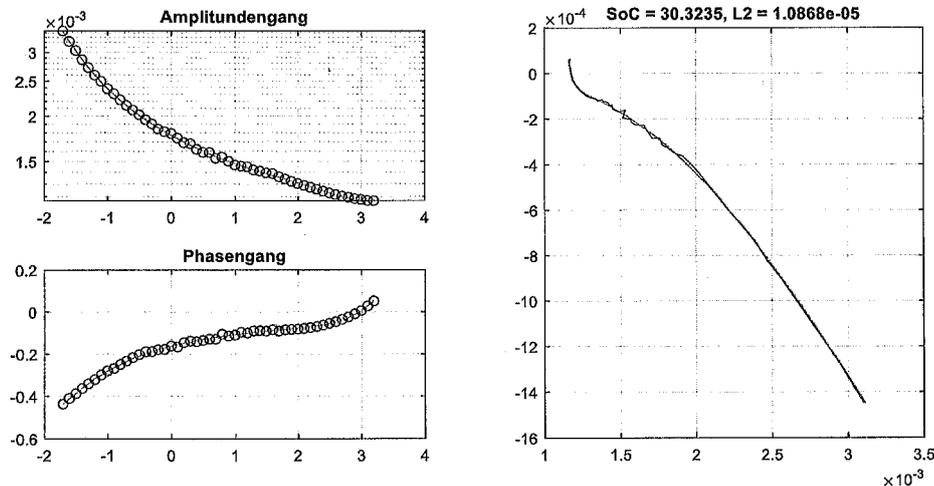


Abbildung 7: Amplitudengang und Phasengang mit resultierendem Nyquist-Diagramm (blau: Messdaten; rot: gefittete Polynome)

Die aufgezeichneten Stromprofile bestehen aus mehreren tausend Datenpunkten und müssen daher zusammengefasst werden. Dazu wird jedes Stromprofil in 10 zeitliche Segmente unterteilt. Für jedes Segment des Stromprofils wird das erste und dritte Quantil sowie der Median und Mittelwert bestimmt. Zusätzlich werden das erste und dritte Quantil und der Median sowie der Mittelwert für das gesamte Stromprofil berechnet. Damit wird das Stromprofil durch bis zu 44 Eingangsparameter dargestellt.

Die Temperatur für jeden Datensatz wird direkt vor der Impedanzmessung erfasst und ist damit in einem Eingangsparameter.

Die Ausgangsgröße des Neuronalen Netzes soll später der SoC der gemessenen Zelle sein. Der Ladezustand wurde bei der Labormessung direkt vor der Impedanzmessung aufgezeichnet und ist damit als ein Ausgangsparameter vorhanden.

Derzeitig sind ca. 2300 Datensätze vorhanden und können für das Training von Neuronalen Netzen verwendet werden.

2.3.3 Training des Neuronalen Netzes

Zum Training wird die Neural Network Toolbox von Matlab verwendet. Dabei wird für das neuronale Netz eine Feedforward-Struktur (keine Rückkopplungen) verwendet.

Die Eingangsparameter werden als Eingänge definiert und der einzige Ausgangsparameter (SoC) wird als Ausgang für das Neuronale Netz verwendet. Dabei wird 85% der Datensätze für das Training verwendet. Die restlichen 15% der Datensätze werden zum Testen des Neuronalen Netzes verwendet.

Um die Eingangsparameter weiter zu reduzieren werden verschiedene Kombination der Eingangsparameter getestet und die Parameterkombinationen verwendet, die den geringsten Fehler (Abweichung zwischen berechneten Ausgangsgrößen und vorgegebenen Ausgangsgrößen) aufweisen.

2.3.4 Ergebnisse der SoC-Bestimmung durch ein Neuronales Netz

Durch diese Optimierung ist das derzeitige beste Neuronale Netz entstanden. Es besitzt 27 Eingangsparameter:

- 16 Parameter des Amplituden- und Phasenpolynoms der Impedanzmessung
- 1 Parameter für Temperatur
- 10 Parameter für das Stromprofil (8 Mediane der zeitlichen Segmente, Median und drittes Quantil des Gesamtprofils)

Das Neuronale Netz besteht aus zwei Hidden Layer mit jeweils 20 Neuronen.

Als Ausgangsgröße wird der SoC verwendet.

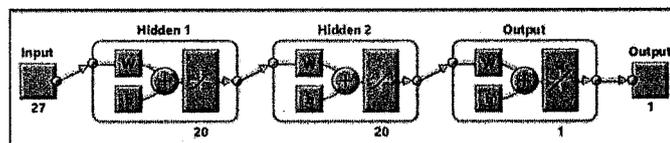


Abbildung 8: Struktur des derzeitigen Neuronalen Netzes

Um die Genauigkeit des trainierten Neuronalen Netzes zu testen, werden die gesamten Eingangsdaten vorgegeben. Der so bestimmte SoC für jeden Datensatz wird mit dem für das Training verwendete SoC des jeweiligen Datensatzes abgeglichen und der Fehler bestimmt. Diese Fehler sind in Abbildung 9 in einem Histogramm dargestellt.

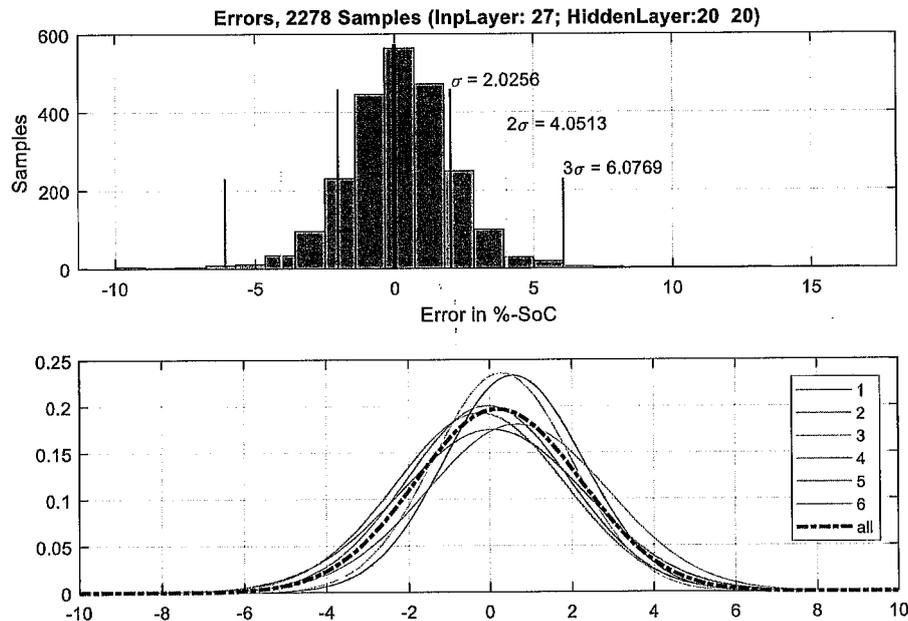


Abbildung 9: Fehler-Diagramm des Neuronalen Netzes (oben: Fehlerhistogramm über alle 2278 Datensätze; unten: Fehlerverteilung aufgeschlüsselt auf die sechs verwendeten Testzellen)

Geht man davon aus, dass die Fehler normalverteilt sind, kann man die Standardabweichung σ der Fehler bestimmen. Diese liegt bei $\sigma = 2\%$ SoC. Folglich ergibt sich für $3\sigma = 6\%$ SoC. Damit ist zu erwarten, dass die von diesem Neuronale Netz bestimmten SoCs mit 99,73% Wahrscheinlichkeit einen Fehler von unter $\pm 6\%$ SoC aufweisen.

Dies ist in Hinblick auf die bisher erreichte Genauigkeit bei Lithium-Tinanzellen ein sehr großer Fortschritt, dass andere Methoden zur Bestimmung des SoC gefahrlaufen, bei einem permanenten Betrieb des Batteriesystems von wahren Wert immer weiter zu divergieren. Die SoC-Zelle konnte noch gesteigert werden, in dem mehrere Schätzwerte zur Bestimmung eines SoC-Wertes durch eine Mittelwertbildung herangezogen werden. Das in Abbildung 9 gezeigte Fehlerhistogramm zeigt das statistische Verhalten einer Normalverteilung mit dem Mittelwert 0 und der Standardabweichung von $\sigma = 2\%$. Die Mittelwertbildung erfolgt dabei von z. B. 10 unmittelbar vorausgegangenen Schätzwerten des SoC der betrachteten Zelle. Im Batteriemanagementsystem läuft zur aktuellen Bestimmung des SoC ein sog. „Coulomb-Counter“ mit, welcher die Differenz des Ladezustandes zwischen zwei SoC-Schätzungen sehr genau messen kann. Wenn die Zeitpunkte der zehn unmittelbar vorausgegangenen, erfassten Schätzwerte des SoC innerhalb weniger Stunden erfasst wurde,

kann davon ausgegangen werden, dass die Differenzwerte des Coulombcounters zum aktuellen SoC noch hinreichend genau sind. Es ist also möglich, für den aktuellen Schätzwert durch diese Methode eine höhere Genauigkeit zu ermöglichen, da für diesen Zustand insgesamt zehn plus der aktuelle Schätzwert vorliegen, die dann nur noch gemittelt werden müssen.

Das in diesem Forschungsprojekt erarbeitete Verfahren ist damit von der Genauigkeit wesentlich besser als alle bisher erzielten Methoden.

Diese seien hier noch einmal gegenübergestellt:

Tabelle 1 Gegenüberstellung anderer Verfahren zur Bestimmung des SoC und Begründungen, warum diese in stationären Speichersystemen problematisch sind

Verfahren	Probleme
Coulomb-Counting	Durch die permanente Intergration des Stromes divergiert der berechnete SoC-Wert aufgrund von Messfehlern nach mehreren Lade- und Entladezyklen in eine falsche Richtung. Gerade bei Anwendungen, in denen der ideale Ladezustand bei 50% liegt (z. B. für stationäre Speichersysteme) ist dieses Verfahren ohne eine zuverlässige Referenzierungsmöglichkeit ungeeignet.
Referenzierung über die Leerlaufspannung	Typischerweise wird die Leerlaufspannung einer Lithium-Ionen-Zelle erst nach einigen Stunden in vollkommener Ruhe angenommen. Bei Lithium-Titanat-Zellen ist die Spannungskennlinie in Abhängigkeit des Ladezustandes zwischen 10% und 90% sehr flach (Änderung innerhalb weniger mV). Ein Referenzieren des SoC wäre nur bei Ladezuständen oberhalb von 90% bzw. unterhalb von 10% möglich. Das Batteriesystem von stationären Speichern sollten aber genau diesen Bereich nicht bzw. nur äußerst selten anfahren. Dieses Verfahren fällt damit auch in Kombination mit dem Coulomb-Counting ebenfalls aus.
Kalman-Filter	Für ein Kalman-Filter werden genaue Modellparameter des Zellsystems benötigt. Diese sind aufgrund der nichtlinearen Eigenschaften des Impedanzverhaltens quasi nicht erfassbar. Des Weiteren ist auch die Leerlaufspannungscharakteristik der Lithium-Titanatzellen ein Ausschlusskriterium.

3 Zusammenfassung und Ausblick

Durch den Einsatz von zellindividueller Impedanzspektroskopie und einer optimierten Auswahl von Eingangsparametern ist es gelungen ein Neuronales Netz zur SoC-Bestimmung zu trainieren. Das Neuronale Netz ist dabei in der Lage nicht nur für eine Zelle den SoC zu bestimmen, sondern für mehrere Lithium-Titanat-Zellen. Die Standardabweichung für Fehler liegt dabei bei ca. $\sigma = 2\%$ des SoC und ist damit in einem Bereich, der es ermöglicht, diese Technik in einem Batteriemanagementsystem einzusetzen.

Resultierend aus diesen Ergebnissen wurde die SoC-Bestimmung durch ein Neuronales Netz weiterverfolgt und optimiert. Anschließend wurde das Neuronale Netz auf dem BMS-Master implementiert und getestet.

Zur Kostenoptimierung des BMS-Slaves wurden außerdem redundante Schaltungsteile identifiziert werden und ggf. im nächsten Layout der Schaltung entfernt.

Es soll nicht verschwiegen werden, dass das vorgestellte Verfahren eine ausgedehnte Exploration der Merkmalsdatensätze erfordert. So wurde Aufnahme der Daten durch eine Messkampagne von mehreren Monaten durchgeführt.

Dies ist vor dem Hintergrund eines industriellen Einsatzes als unwirtschaftlich zu bezeichnen, zudem auch bei kleineren Änderungen z. B. in den Produktionsprozessen der Zellen eine erneute Exploration der Datensätze erfolgen müsste.

Dennoch ist das Verfahren eine wegweisende Möglichkeit, Zellen mit Hilfe Maschinellem Lernverfahren diagnostizieren zu können.

Ziel der weiteren Forschung ist es, das Batteriemanagementsystem als Explorationswerkzeug zu nutzen. Dazu nimmt das BMS im laufenden Betrieb möglichst viele Impedanzspektren von allen überwachten Zellen auf.

Da das BMS-Mastersteuergerät als Raspberry-Pi mit einer SD-Speicherkarte von mehreren Gigabyte ausgestattet ist, können auf diese Weise Merkmalsdatensätze über mehrere Tage und Wochen gespeichert werden.

In einem weiteren Forschungsprojekt werden diese Daten über die WLAN-Schnittstelle des Raspberry Pi auf ein sehr leistungsfähiges Cloud-Computersystem übertragen.

Auf dem können dann so genannte Verstärkende Lernalgorithmen zum Einsatz kommen.

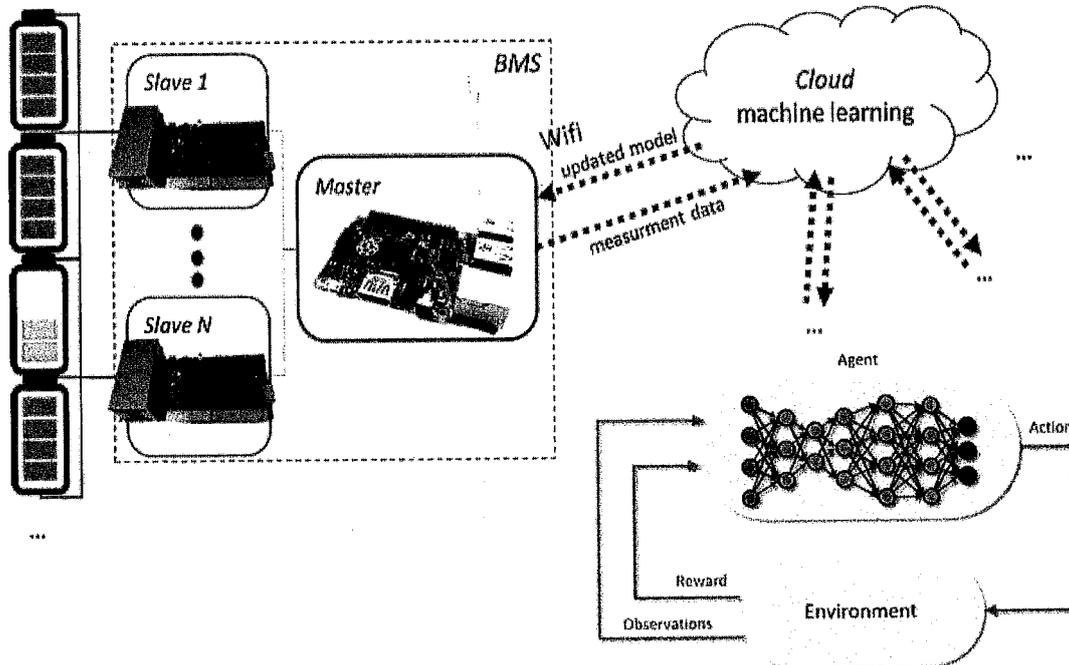


Abbildung 10 Zukünftige Entwicklung, die sich aus diesem Projekt ergeben haben.

Hierin beobachtet ein Agent (repräsentiert durch ein Künstliches Neuronales Netz) permanent die erfassten Merkmalsdatensätze des BMS und gibt eine Schätzung in Form einer Aktion aus. Diese Schätzung wird durch eine Rewardfunktion bewertet. Anders als in diesem Projekt beschrieben liegt der tatsächliche SoC zum beobachteten Merkmalsdatensatz nicht mehr vor. Dennoch besteht die Möglichkeit die Schätzungen bewerten zu lassen. In der Literatur finden sich viele Beispiele in den so genannte Verstärkende Lernalgorithmen beachtenswerte Erfolge erzielt haben.

Als gut bewertete Schätzungen sorgen dafür, dass die Parameter des Agenten graduell immer bessere Schätzergebnisse erzielen.

Die Lösung hätte den bestechenden Vorteil, dass in Zukunft das BMS nur noch an die Batteriezellen angeschlossen werden müsste und das BMS selbstständige erlernt, wie es aus den erfassten Merkmalsdatensätze wichtige Zustandsgrößen prognostiziert.

Die Umsetzung der Algorithmen und die Erforschung der Rewardfunktion sind Gegenstand eines neuen Förderprojektes, das Anfang 2020 beginnen wird.

Die Förderung wurde bereits durch das Land Schleswig-Holstein bekannt gegeben und erfolgt über den Landes-Ideenwettbewerb „Energie-Infrastruktur“.

4 Danksagung

Der Energie und Klimaschutzstiftung Schleswig-Holstein und der Liacon GmbH sei an dieser Stelle herzlich gedankt, für die Förderung im Rahmen dieses Projektes. Durch die vorgestellten Arbeiten ist es gelungen ein neues Verfahren auf den Weg zu bringen, das Chancen für die industrielle Nutzung aufweist.

Nicht nur zur Überwachung von Batteriesystemen finden sich Einsatzmöglichkeiten, sondern auch für die Überwachung während des Produktionsprozesses von z. B. Lithium-Ionen-Zellen.

Der Projektleiter wurde damit in die Lage versetzt, sich mit dieser Technologie einen wichtigen Beitrag für die Energiewende zu leisten. Denn alle Systeme werden in der Regel auf Batteriezellen als Speicher zurückgreifen, für die hohe Zuverlässigkeitsanforderungen bestehen.