

Abschlussbericht zum HWT-Projekt Intelligentes Energiemanagement für stationäre Energiespeichersysteme

HWT-Förderprojekt der EKSH in Kooperation mit

The logo for EKSH consists of the letters 'EKSH' in a bold, blue, sans-serif font. A horizontal bar is positioned below the letters, with a yellow section on the left and a blue section on the right.

Gesellschaft für Energie und
Klimaschutz Schleswig-Holstein GmbH

The logo for iauv automotive engineering features the lowercase letters 'iauv' in a large, bold, blue, sans-serif font. To the left of the letters, the words 'automotive' and 'engineering' are stacked vertically in a smaller, blue, sans-serif font.

Fachhochschule Kiel

Hochschule für Angewandte Wissenschaften

Projektleitung:

Prof. Dr.-Ing. Christoph Weber

Projektteam:

B.Eng. Max Beckmann
B.Eng. Leif-Erik Burmester
B.Eng. Timo Jäger
M.Sc. Ramakrishna Reddy
M.Eng. Tobias Bothe
M.Eng. Jan Kabelitz
M.Eng. Fabian Franke
M.Eng. Torben Lamp
M.Eng. Asmus Matthiesen

Fachhochschule Kiel
Institut für Mechatronik
Grenzstr. 3
24149 Kiel
email: christoph.weber@fh-kiel.de
Tel.: 0431 210-2583

Inhaltsverzeichnis

Zusammenfassung	3
Erläuterungen zur Steuerung des Teststandes über den RTPC	6
Energiespeichermodell	9
Energiemanagement	10
State of Charge (SoC)-Bestimmung	10
Hausverbrauchsoptimierung	10
Steuerung für Primärenergieleistung und Stromhandel.....	12
SoC-Anpassung der Batterie.....	12
Skalierung der Batterie.....	13
Windkraftanlagenmodell	13
Geldzähler	13
Umrichtermodellierung	13
Reales Batteriesystem.....	14
Datenbasis des EPEX-Spotmarktes für Intraday-Handelsgeschäfte.....	15
Datenaggregation der vorhandenen Datensätze	16
Präparation der Merkmale für das Training.....	16
Präparation der Zielgrößen für das Künstliche Neurale Netz	17
Training des Künstlichen Neuronalen Netzes (KNN).....	18
Erzielte Ergebnisse der Prognose	20
Nutzung der Preisprognose für Intraday Handelsgeschäfte mit dem „Trading-Manager“	21
Erreichte Meilensteine	24
Ergebnisse.....	26
Fazit	30
Literaturverzeichnis	31

Zusammenfassung

Im dem Projektzeitraum sind von den Projektpartnern alle hardwaretechnischen Voraussetzungen für die geplante Energiemanagementsystememulation geschaffen worden, um die zu implementierenden Funktionen (Eigenversorgung, Bereitstellung von Primärregelleistung [1] sowie Intradayhandelsgeschäfte [2] mit elektrischer Energie zu testen.

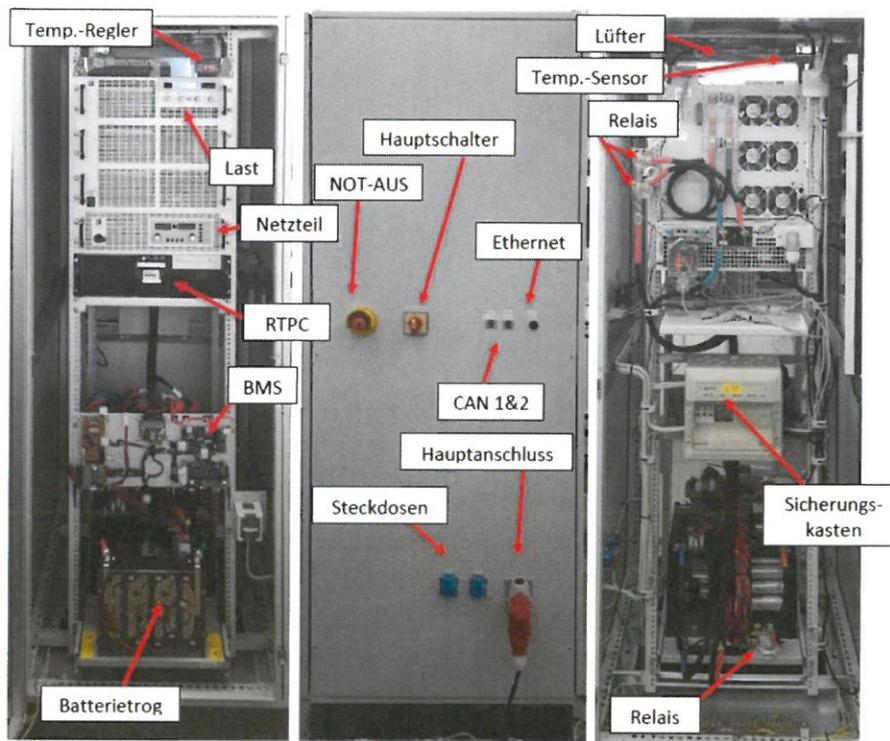


Abbildung 1 Aufgebautes Energiemanagementsystem bestehend aus einem Batteriesystem, einer elektronischen Last und Senke sowie einer RTPC (Echtzeit PC) – Steuerung

Ziel des Projektes ist, für jedes Geschäftsfeld eine Steuerung vorzunehmen. Für die Funktion „Eigenversorgung“ wird die aktuelle Windgeschwindigkeit in Kiel durch einen Kleinstcomputer (1) gemessen und per CAN-Bus an den RTPC (Real Time PC) gesendet. Bei dem Kleinstcomputer handelt es sich um einen handelsüblichen Raspberry PI in der 3. Generation, der einen Netzwerkzugang in das Internet besitzt und wichtige Daten für das Energiemanagementsystem liefert. Im RTPC befindet sich die softwaretechnische Realisierung des Energiemanagementsystems. Des Weiteren wird im RTPC die (fiktive) Leistung einer Kleinwindanlage mit einer Peak-Leistung von 20kW in Abhängigkeit der aktuellen Windgeschwindigkeit berechnet. Gleichzeitig wird im Gebäude 13 der FH Kiel der Hauptstromzähler mit Hilfe eines weiteren Kleinstcomputers (2) ausgelesen. Die Differenz zwischen erzeugter und verbrauchter Leistung legt dabei

fest, ob elektrische Leistung über ein an das Batteriesystem angeschlossenes Netzteil oder eine Senke zur Ladung oder Entladung betrieben wird. Das reale Batteriesystem verfügt nur über 2kWh, wird aber im RTPC als 20-fache Kapazität behandelt.

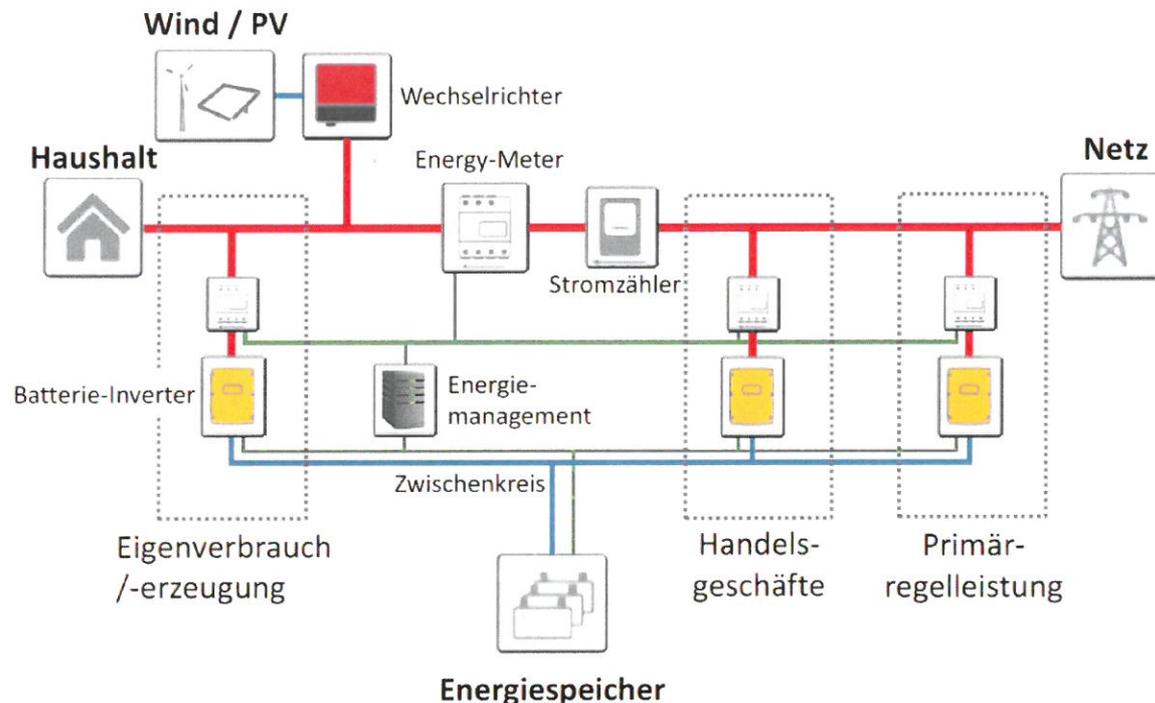


Abbildung 2 Strukturbild des Energiemanagement und die beteiligten emulierten Komponenten

Für die Funktion „Bereitstellung von Primärregelleistung“ wird die Netzfrequenz durch ein eigenes entwickeltes Messgerät [3] mit einer Genauigkeit von 1mHz gemessen und direkt an den RTPC gesendet. Der RTPC berechnet daraus die erforderliche Primärregelleistungsanforderung, die über die Senke und Quelle aufgenommen oder bereitgestellt werden muss. Der Kleinstcomputer (1) liest über das Web-Portal „regelleistung.net“ die einmal in der Woche stattfindende Auktion mit den verhandelten Preisen für die Bereitstellung von Primärregelleistung aus. Der Mittelwert der Erlöse wird in dem Energiemanagement als erzielt Ergebnis für die bereitgestellte Dienstleistung gewertet.

Ein weiterer Schwerpunkt des Projekts ist es, ein für Intradayhandelsgeschäfte geeignetes Prognosemodell zu entwickeln, um zu optimalen Zeitpunkten automatisiert Kauf- und Verkaufsgeschäfte zu vollziehen. Der Kleinstcomputer (1) verfügt über einen lesenden Zugang zu Daten des EPEX-Spotmarktes und liefert damit die Grundlage zur fiktiven Teilnahme an Handelsgeschäften im Intraday-Handel. In der Folge soll aufgezeigt werden, wie dazu Künstliche Neuronale Netze (KNN) eingesetzt werden können. Die zum Training genutzten Daten beziehen sich auf den gesamten Zeitraum von 2014 bis Mitte 2017 und umfassen alle getätigten

- Abfrage des mittleren Wochenpreises der Ausschreibung für die Bereitstellung von Primärregelung in €/MWh [1]
- Abfrage der Windgeschwindigkeit am Standort Kiel Wellingdorf über einen vom *IFM-Geomar* bereitgestellten ftp-Servers
- Steuerung des RTPC über eine CAN-Bus-Schnittstelle mit den erfassten Daten

Die Bereitstellung der Handelsdatensätze des Intradayhandels wurde immer mit einer Verzögerung von zwei Wochen aktualisiert. Aus diesem Grund wurden die alle erfassten Daten im Raspberry Pi mit den Zeitpunkten der Handelsgeschäfte synchronisiert. Dadurch war man im Rahmen des Projektes gezwungen, die gewählte Systemzeit immer um zwei Wochen in der Vergangenheit laufen zu lassen.

Die an dem Batteriesystem angeschlossene Last und das Netzteil haben die Aufgabe, das Batteriesystem mit den jeweiligen Belastungsanforderungen zu beaufschlagen. Der RTPC dient als Echtzeitrechner dazu, die Belastungsamplituden modellbasiert zu berechnen und den Lastfluss der Last und des Netztes zu steuern. An den RTPC wird über eine Kommunikationsschnittstelle ein handelsüblicher PC angeschlossen, um alle wichtigen Prozessgrößen sichtbar zu machen. Diese grundlegenden Arbeiten wurden durch die Masterprojektarbeit [5] umgesetzt.

Erläuterungen zur Steuerung des Teststandes über den RTPC

Das Echtzeitmodell wird mithilfe der ETAS LABCAR-Softwareprodukte auf dem RTPC implementiert. Die tatsächliche Realisierung geschieht in Form von MATLAB-/Simulink-Modellen, die mithilfe der LABCAR-Software in für den RTPC ausführbaren Code übersetzt werden. Wie in Abbildung 4 dargestellt, werden die verschiedenen Aufgaben grundsätzlich auf zwei Modelle verteilt: das COM-Modell für Kommunikationsaufgaben und das Energiespeichermodell. Der Datenaustausch zwischen den Modellen sowie die externe Anbindung an die CAN-Schnittstelle des RTPC werden über den sog. Connection Manager realisiert, wobei hierfür in den Modellen sog. LABCAR-Ports vorgesehen sind.

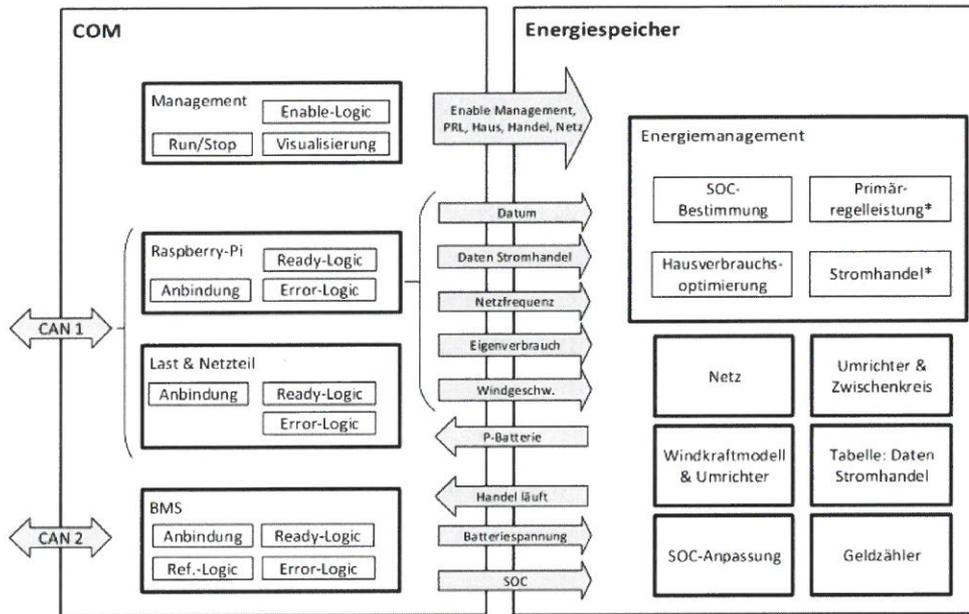


Abbildung 4 Schematische Darstellung der auf dem RTPC implementierten Echtzeitmodelle

Das COM-Modell (Abbildung 4, links) übernimmt auf dem RTPC die Anbindung des Energiespeichermodells an die Umwelt. Innerhalb des COM-Modells werden die ein- und ausgehenden Daten für das Energiespeichermodell aufbereitet, damit im Energiespeichermodell lediglich auf einfache Simulink-Signale zurückgegriffen werden muss. Auf diese Weise wird das Energiespeichermodell von der speziellen Hardware innerhalb des Aufbaus entkoppelt, was insbesondere für die Portierbarkeit in den Model-in-the-Loop-Betrieb des Modells von entscheidender Wichtigkeit ist. Außerdem werden im COM-Modell mögliche Kommunikationsfehler sowie durch die Hardware gemeldete Fehler abgefangen. Zu diesem Zweck übernimmt das COM-Modell ebenfalls Managementaufgaben, wodurch einzelne Funktionen, wie z. B. das Energiemanagement im Energiespeichermodell, deaktiviert werden können. Auf diese Weise kann im Fehlerfall dafür gesorgt werden, dass das System angehalten wird. Gleichzeitig wird über diesen Mechanismus sichergestellt, dass das Energiespeichermodell erst aktiv wird, wenn alle Signale von der Hardware bereitstehen.

Das Energiespeichermodell übernimmt die eigentlichen Simulationsaufgaben in dem gesamten Aufbau, da die Prüfumgebung hardwareseitig nicht in der Lage ist, alle Aspekte des geplanten Energiespeichers abzubilden. Zu diesem Zweck werden das Netz, die Batterieumrichter, die Windkraftanlage und der Zwischenkreis modelliert. Außerdem sind eine Ladezustands-Anpassung der Batterie und diverse Geldzähler implementiert worden, wobei die Geldzähler Rückschlüsse auf die Wirtschaftlichkeit des Systems zulassen, indem z. B. die Gewinne durch den Stromhandel gespeichert werden.

Den Kern des Energiespeichermodells bildet die Einbettung des Energiemanagements, welches mithilfe der hier realisierten Software-in-the-Loop-Testumgebung auf seine Eignung untersucht werden soll. Es beinhaltet eine Ladezustands- (engl. State of Charge: SoC)-Bestimmung, durch welche die Batterie virtuell in drei Teile (für Primärregelleistung, Handelsgeschäfte und Hausverbrauch) gegliedert wird. Weiterhin enthält das Energiemanagement eine Regelung für die Hausverbrauchsoptimierung, eine Steuerung der Primärregelleistung und des Stromhandels, wobei letztere nicht Bestandteile der zugrundeliegenden Arbeit sind, sondern in einer separaten Projektarbeit [6] bearbeitet werden (s. a. „5.4 Energiemanagement“ auf S. 26).

Für die Bedienung des Modells wird mit dem sog. Experiment Environment (Bestandteil der ETAS LABCAR-Software) eine Bedienoberfläche erstellt. Über diese Oberfläche können auf einem separaten Bedien-PC z. B. die Energieflüsse des Systems oder die Zustände des Energiemanagements visualisiert werden. Zudem besteht die Möglichkeit, für eine spätere Beurteilung des Systems Signale mit einem Daten-Logger aufzuzeichnen.

Energiespeichermodell

In Abbildung 5 ist die oberste Ebene des Energiespeichermodells schematisch dargestellt. Das Modell wird in MATLAB/Simulink implementiert und mit der ETAS LABCAR-Software auf den RTPC übertragen. Die Parametrierung des Modells erfolgt über die Matlab-Datei, in der z. B. Parameter für die Nenndaten der Batterie oder die Wirkungsgrade der modellierten Umrichter festgehalten sind.

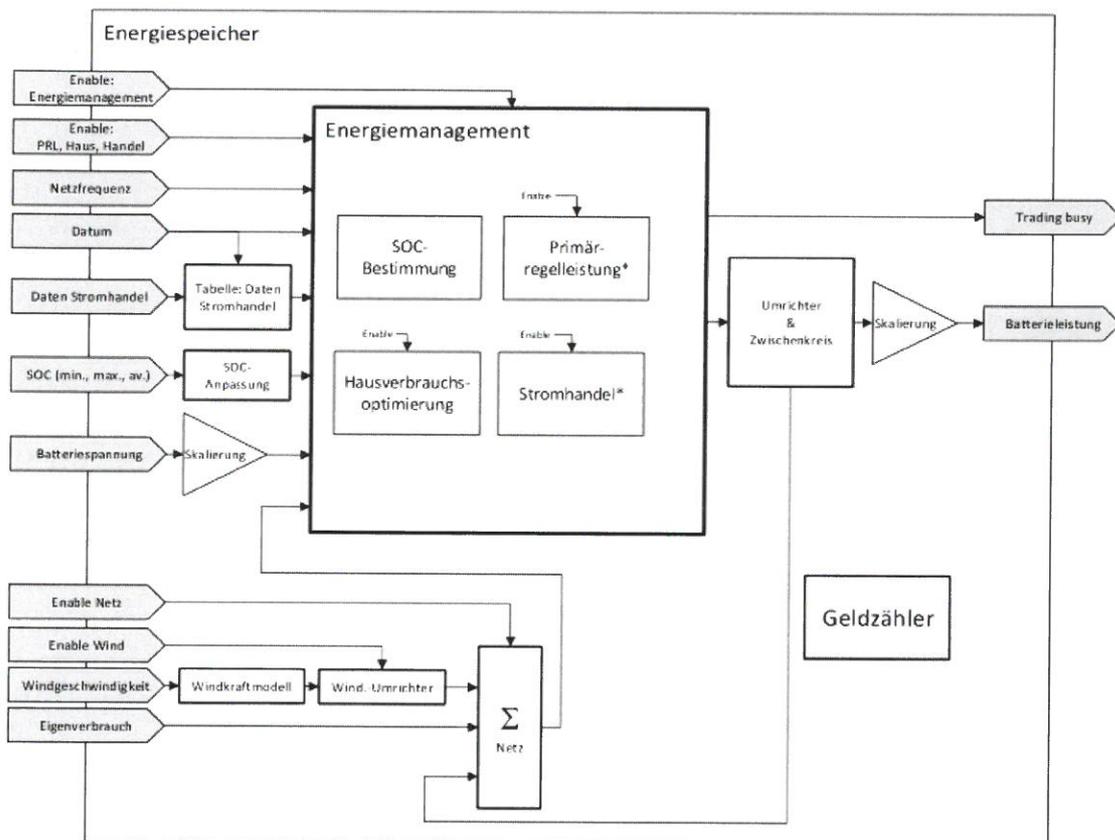


Abbildung 5 Schematische Darstellung des Energiespeichermodells

Das Energiespeichermodell (s. Abbildung 5) übernimmt die Simulation der Aspekte, die nicht durch die Hardware der Prüfumgebung realisiert werden können. Bei der Modellierung gilt, dass sämtliche Signale stets in SI-Einheiten repräsentiert werden und der gesamte Energiefluss im Modell leistungsbezogen (statt strombezogen) realisiert wird. Dabei sorgt eine positive Leistung für ein Laden der Batterie bzw. Einspeisen ins Stromnetz und eine negative Leistung für ein Entladen der Batterie bzw. Verbrauch am Stromnetz.

Energiemanagement

Den Kern des Energiespeichermodells bildet das zu testende Energiemanagement für den stationären Energiespeicher. Innerhalb des Energiemanagements befinden sich die vier Kernfunktionen, die SOC-Bestimmung sowie die Steuerung für die Optimierung des Hausverbrauchs, der Primärregelleistung und des Stromhandels, wobei letztere nicht Bestandteile der zugrundeliegenden Arbeiten sind, sondern in einer separaten Projektarbeit [6, 7] bearbeitet werden.

Über Eingänge vom COM-Modell besteht die Möglichkeit, entweder das Energiemanagement als Ganzes oder, abgesehen von der SoC-Bestimmung, die einzelnen Elemente des Energiemanagements zu aktivieren bzw. zu deaktivieren. Wird das Energiemanagement als Ganzes deaktiviert, werden alle Ausgänge auf null gesetzt, was sämtliche gestellte Leistungen verwirft. Nach einer erneuten Aktivierung befindet sich das Energiemanagement wieder in seinem Ausgangszustand, für den alle inneren Zustände zurückgesetzt werden. So wird die Möglichkeit geschaffen, das Management und alle Leistungsflüsse im Fehlerfall komplett zu deaktivieren. Bei kleineren Fehlern ist es durch die Deaktivierung der einzelnen Bestandteile möglich, nicht alle Zustände zu verwerfen. Dies ermöglicht es beispielsweise, nur die Steuerung für die Primärregelleistung zu deaktivieren, wenn für kurze Zeit kein Wert für die Netzfrequenz zur Verfügung steht. In diesem Fall wird die Steuerung für die Primärregelleistung wieder aktiviert, wenn ein Frequenzwert zur Verfügung steht, ohne dass die Füllstände der fiktiven Batterieteile verworfen werden müssen. Diese Möglichkeit ist insbesondere für den dauerhaften Betrieb des Prüfstands über Wochen oder Monate wichtig.

State of Charge (SoC)-Bestimmung

Die SoC-Bestimmung errechnet innerhalb des Energiemanagements die Füllstände der drei fiktiven Batterieteile anhand der durch die Umrichter beaufschlagten Leistungen und der vom BMS über das COM-Modell bereitgestellten Batteriespannung. Die SoC-Bestimmung der einzelnen Batterieteile erfolgt durch Integration des Batteriestroms (errechnet aus Leistung und Batteriespannung). Weicht dabei der errechnete SoC (Addition der einzelnen Füllstände) vom eingehenden SoC ab, wird diese Abweichung rechnerisch im Batterieteil für den Hausverbrauch korrigiert. Auf diese Weise werden nicht messbare Verluste abgefangen.

Hausverbrauchsoptimierung

Die Hausverbrauchsoptimierung versucht durch eine kaskadierte Regelung, den Stromverbrauch am Stromnetz möglichst zu null zu regeln, sofern die Batterie dafür Energie aufnehmen oder bereitstellen kann [5].

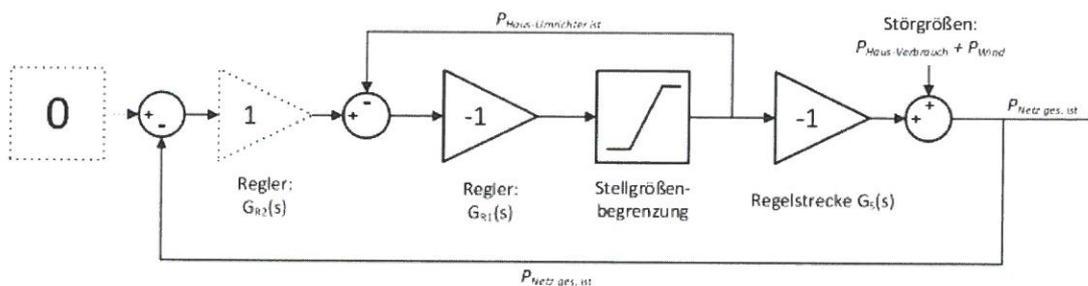


Abbildung 6 Schematische Darstellung der kaskadierten Regelung für die Hausverbrauchsoptimierung

Der äußere Regelkreis (s. Abbildung 6) regelt den Stromverbrauch am Netz zu null und gibt dafür die Abweichung von der Führungsgröße als Stellgröße weiter. Der innere Regelkreis sorgt dafür, dass die Leistung des Hausumrichters genau um die vorliegende Abweichung korrigiert wird und somit der Stromverbrauch am Netz ausgeglichen wird. Die Führungsübertragungsfunktion $G(s)$ des Gesamtsystems ergibt sich zu:

$$G(s) = \frac{G_{R1}(s) \cdot G_S(s)}{G_{R1}(s) \cdot G_S(s) + G_{R1}(s) + 1} \text{ mit } G_S(s) = -1 \quad (\text{Gl. 1})$$

Um nun ein gewünschtes Übertragungsverhalten von $G(s) = 1$ zu erhalten, wird $G_{R1} = G_S(s)$ gewählt. Zudem ist eine Stellgrößenbegrenzung vorgesehen, um die Batterie innerhalb der Vorgaben zu betreiben. Dabei berücksichtigt die Begrenzung einen Maximalstrom I_{max} , der mithilfe der Batteriespannung U_{Bat} entsprechend in eine Leistung umgerechnet wird. Außerdem berücksichtigt die Begrenzung die Leistungen, die durch die Primärenergieleistung und den Stromhandel an der Batterie beaufschlagt werden, um zu jedem Zeitpunkt die für die Hausoptimierung maximal zulässige Leistung zu gewähren.

Die negativen Vorzeichen in den gewählten Proportionalreglern sind mit dem gewählten Zählpfeilbezugssystem der Leistungen zu begründen. Der Regler übernimmt damit die Aufgabe, den regenerativ erzeugten Strom im Hausnetz (zwischen Batterie und dem Eigenverbrauch) zu halten, soweit dies möglich ist.

Steuerung für Primärregelleistung und Stromhandel

Die Steuerung für die **Primärregelleistung** bekommt als Eingang die Netzfrequenz und stellt damit die Leistung des zugehörigen Umrichters. Zudem wird von der SoC-Bestimmung der SoC des entsprechenden Batterieteils übergeben, damit die Steuerung der Primärregelleistung in der Lage ist, Ausgleichsgeschäfte zu tätigen, um Verluste am Umrichter zu kompensieren.

Die Steuerung für den **Stromhandel** bekommt als Eingang ebenfalls den SoC für den betreffenden Batterieteil sowie das aktuelle Datum und eine Datentabelle für den Stromhandel (s. folgender Abschnitt). Wie die Steuerungen für Primärregelleistung und Hausverbrauchsoptimierung stellt die Steuerung für den Stromhandel die Ausgangsleistung des entsprechenden Umrichters zur Verfügung. Außerdem gibt es einen logischen Ausgang, an dem signalisiert wird, ob ein Handel geplant ist (Trading busy). Anhand dieses Signals kann im COM-Modell z. B. gesteuert werden, ob eine SoC-Referenzierung des BMS zu einem Zeitpunkt erlaubt ist oder nicht.

Bei beiden Steuerungen existiert ein Ausgangsvektor, der für die Geldzähler vorgesehen ist. In diesem Vektor gibt es eine Leistungsgröße und den dazugehörigen Preis in €/kWh. Die entsprechende Leistung wird so lange ausgegeben, wie bei der Steuerung der Primärregelleistung der Handel für die Ausgleichsgeschäfte läuft und bei der Steuerung für den Handel entsprechend so lange, wie der Handel läuft. Mithilfe der Leistung und des Preises kann dann durch Integration die Geldmenge bestimmt werden, die durch Ausgleichsgeschäfte verloren und durch Stromhandel verdient wird.

SoC-Anpassung der Batterie

Die SoC-Anpassung hat einerseits die Aufgabe, den SoC zu skalieren und andererseits einen Initial-SoC bereitzustellen. Hierfür bekommt die SoC-Anpassung den minimalen, maximalen und durchschnittlichen SoC aller Zellen sowie die aktuell beaufschlagte Batterieleistung.

Die SoC-Skalierung sorgt dafür, dass der weitergegebene SoC bereits einen Wert von 0 % annimmt, obwohl der tatsächliche SoC noch größer als 0 % ist. Gleiches gilt für den weitergegebenen SoC von 100%, bei dem der tatsächliche SoC kleiner als 100 % ist. Für diesen Zweck können zwei Parameter definiert werden, die die 0 %- und 100 %-Grenze markieren. Auf diese Weise ist es möglich, die reale Batterie garantiert in sicheren Betriebszuständen zu betreiben, um gerade in Testszenarien einem Eingreifen des BMS zuvorzukommen. Gleichzeitig sorgt die SoC-Skalierung dafür, dass immer der Worst-Case-SoC weitergegeben wird. Je nach Vorzeichen der beaufschlagten Batterieleistung wird der minimale bzw. maximale SoC der Zellen weitergegeben. Somit wird von vornherein verhindert, dass beim Laden der Batterie die vollste Zelle überladen bzw. beim Entladen die leerste Zelle

tiefentladen wird und das BMS eingreifen muss. Der durchschnittliche SoC wird ebenfalls skaliert und direkt als Initial-SoC weitergegeben.

Skalierung der Batterie

Durch die Skalierung der Batterie ist es möglich, trotz der festen Kapazität der realen Batterie (hier 2kWh), eine Batterie mit größerer bzw. kleinerer Kapazität zu simulieren. Für die Skalierung werden Parameter für den Aufbau der realen Batterie sowie der skalierten Batterie angegeben. Daraus errechnen sich die Parameter für die Skalierung der Spannung, des Stroms und der Leistung, die direkt als Faktoren eingesetzt werden können.

Windkraftanlagenmodell

Das Netz bzw. der Verbrauch am Stromnetz wird durch die Summation des eingehenden Eigenverbrauchs und über das Modell der Windkraftanlage modelliert. Bei dem Windkraftmodell der Firma Easywind handelt es sich um eine Lookup-Tabelle [8] die in Abhängigkeit der Windgeschwindigkeit v_{Wind} eine regenerativ erzeugte, elektrische Leistung P_{Wind} zur Verfügung stellt. Dabei ist das COM-Modell über die Eingänge *Enable-Netz* und *-Wind* in der Lage, diese zu deaktivieren, wenn z. B. kurzfristig keine Daten für die Windgeschwindigkeit bereitstehen.

Geldzähler

Innerhalb des Energiespeichermodells werden verschiedene Geldzähler vorgesehen, um die Wirtschaftlichkeit des Systems beurteilen zu können. Es wird zwischen realen und fiktiven Geldzählern unterschieden. Die realen Geldzähler summieren dabei das durch die einzelnen Bestandteile erwirtschaftete Geld, während die fiktiven Geldzähler als Vergleich mit herkömmlichen Systemen (normaler Haushalt oder Haushalt nur mit Kleinwindkraftanlage) dienen. Es sind reale Geldzähler für das Netz, den Stromhandel, die Ausgleichsgeschäfte der Primärregelleistung und die Bereitstellung von Primärregelleistung vorgesehen, sowie die Summation aller Zähler, um einen Gesamtbetrag zu erhalten. Als fiktive Geldzähler sind der reine Verbrauch des Hauses vorgesehen sowie die Kombination von reinem Verbrauch des Hauses und Windkraftanlage (jedoch ohne Batterie).

Umrichtermodellierung

Sämtliche Umrichter sind so implementiert, dass sie zusätzlich zu der gestellten Leistung (netzseitig) einen Wirkungsgrad berücksichtigen. Die Wirkungsgrade für das Laden und Entladen der Batterie können in der Parameterdatei des Modells parametrisiert werden. Bei der zukünftigen Weiterentwicklung des Modells ist es denkbar, statt eines konstanten Wirkungsgrads, einen leistungsabhängigen Wirkungsgrad zu implementieren z. B. durch eine Lookup-Tabelle.

Reales Batteriesystem

Neben dem RTPC zur Integration des Energiemanagementsystems und zur Modellierung der Anbindung einer Windkraftanlage sowie der Verarbeitung der Daten aus den internetbasierten Informationen (Intradayhandelsgeschäfte und der mittlere Preis der wöchentlichen Ausschreibung des Preises der Primärregelung) wird der Einfluss realen Batteriesystems untersucht werden [9]. Das Batteriesystem besteht aus einem von der FH Kiel entwickelten Batteriemanagementsystem und aus drei Batterieträgen bestehend aus Lithium-Eisenphosphatzellen mit einer Gesamtkapazität von 2kWh.

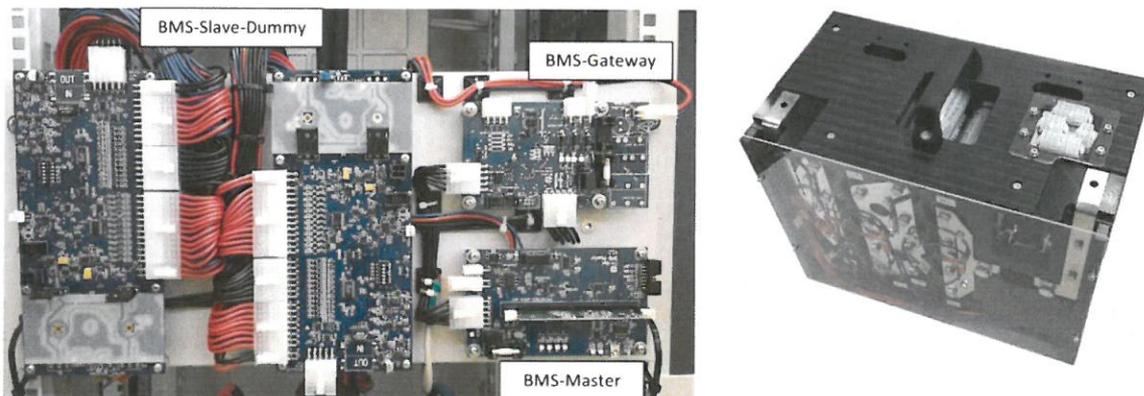


Abbildung 7 Batteriemangement der FH Kiel und einzelner Batterietrog des Energiemanagementsystems

Datenbasis des EPEX-Spotmarktes für Intraday-Handelsgeschäfte

In diesem Abschnitt sollen die wesentlichen Schritte erläutert werden, wie aus der vorhandenen Datenbasis ein geeignetes Prognosemodell hergeleitet werden kann, das für Handelsgeschäfte mit Strom eingesetzt werden kann.

Ein Handelsgeschäft besteht immer aus einem Zeitstempel, dem Lieferzeitpunkt, der Lieferdauer, der gehandelten Strommenge und dem Preis pro MWh wie in Abbildung 8 gezeigt.

Date	Market Area Buy	Market Area Sell	Hour from	Hour to	Volume (MW)	Price (EUR)	Time Stamp	Trade ID
01.09.2015	DE	DE	5	5	15.0	29.79	31.08.2015 16:00:00	1014812856
01.09.2015	DE	DE	5	5	25.0	30.00	31.08.2015 16:00:00	1014812857
01.09.2015	DE	DE	5	5	1.0	30.00	31.08.2015 16:00:00	1014812858

Gehandelte Leistung (hier für 1h) Preis für 1MWh

Datum der Lieferung 01.09.2015

Lieferdauer und Zeitpunkt: 05:00-06:00 Uhr

Zeitstempel des Handelsgeschäfts

Abbildung 8 Auszug von 3 Handelsgeschäften am 31.08.2015 um 16:00 Uhr mit Lieferdatum am 01.09.2015 von 05:00 bis 06:00 Uhr

Wesentliches Merkmal des EPEX-Spotmarkts für den Intradayhandel ist, dass ein Lieferzeitpunkt zwischen einer halben Stunde bis zu 1,33 Tagen in der Zukunft liegen kann (daher auch die Bezeichnung). Jedes Handelsgeschäft ist also dadurch gekennzeichnet, dass es grundsätzlich Informationen über eine Preisentwicklung in der Zukunft enthält, die für eine Prognose herangezogen werden kann.

Künstliche Neuronale Netze verfügen über die Eigenschaften „verborgene“ Trends und Muster durch ein massives überwacht trainieren von bekannten Datensätzen zu detektieren und für Prognosen einzusetzen. Wichtige Voraussetzung ist dabei, die Auswahl geeigneter Trainingsdaten festzulegen. Diese grundlegende Fragestellung wurde im Rahmen einer Projektarbeit [7] nachgegangen.

Eine Prognose des Preises in Euro pro MWh mit einem Zeithorizont von 4h erscheint dabei als sinnvoll, um den Ladezustand des Batteriesystems dafür in geeigneter Weise vorbereitet zu halten. Da die kleinste Lieferdauer von Strom 15 min betragen kann, wurde für die Prognose ebenfalls ein 15 min Takt gewählt. Dies hat zu Folge, dass für die auszuwählenden Trainingsdatensätze eine Datenaggregation aller vorhandenen Daten realisiert werden kann.

Die FH Kiel verfügt über einen lesenden Zugang zu den Intradayhandel des EPEX-Spotmarktes über einen sftp-Server, der vom Kleinstcomputer (1) einmal alle zwei Wochen ausgelesen wird. Der Kleinstcomputer gleicht die dabei die Datensätze mit der eigenen Systemszeit ab und versendet den aktuellen (gemäß der eigenen Systemzeit Datensatz an den RTPC. Zur Erinnerung sei hier erwähnt, dass diese Systemzeit um zwei Wochen zurückdatiert wurde, dass die Daten der Handelsgeschäfte immer um 2 Wochen verzögert zur Verfügung gestellt werden. Ein aktiver Handelszugang besteht nicht sowohl für den Intradayhandel als auch für die Ausschreibung. Dies ist aus Sicht der Projektpartner zum Nachweis eines funktionierenden Energiemanagementsystems nicht erforderlich, da es sich um eine reine Hardwareemulation handelt. Der tatsächlich erzielte Verkaufs- bzw. Einkaufspreis wird durch ein Handelsgeschäft repräsentiert, welches dem ausgehend vom gegenwärtigen Zeitpunkt in der Zukunft liegt und am besten mit den Prognosedaten übereinstimmt (Stellvertretergeschäft).

Datenaggregation der vorhandenen Datensätze

Präparation der Merkmale für das Training

Abbildung 9 zeigt eine grafische Erläuterung der Datenaggregation für die Eingangsdaten anhand der bekannten historischen Handelsgeschäfte. Dabei werden ausgehend für jeden betrachteten aktuellen Zeitstempel alle Handelsgeschäfte berücksichtigt, die 1,33 Tage in der Vergangenheit liegen und ihren Lieferzeitpunkt in 4h haben. Damit werden alle stattgefundenen Handelsgeschäfte für den vierstündigen Prognosehorizont erfasst. In der Regel umfassen 1,33 Tage in der Vergangenheit ca. 8.000-9.000 Datensätze von denen ca. zwischen 20-400 ihren Lieferzeitpunkt in 4h haben.

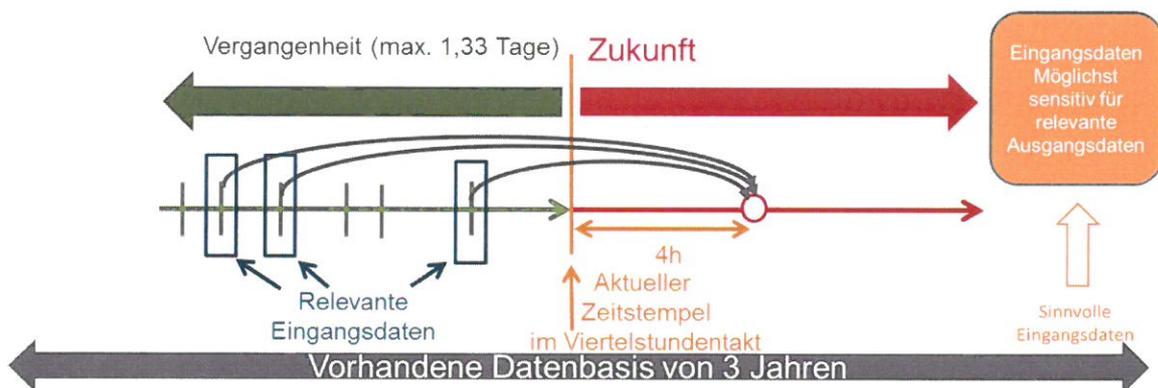


Abbildung 9 Vorbereitung der Eingangsdaten (Merkmale) für das Training des Künstlichen Neuronalen Netzes

Aufgrund der Taktung der Lieferzeitpunkte erfolgt die nächste Datenaggregation dann 15 min später.

Eine derartige Datenaggregation erlaubt es, sensitive Eingangsdaten für das Training eines Künstliche Neurale Netz zu wählen. Dazu ist folgende Datenaggregation durchgeführt worden, welche nur diejenigen Handelsgeschäfte betrachtet, die ihren Lieferzeitpunkt in exakt 4h haben:

- Aktueller Zeitstempel in gebrochen rationalen Tagen seit dem 01.01.2014 im 15min Takt. (Beispiel 15.02.2014, 12:05 Uhr :=46,5d des Jahres 2014)
- Die Anzahl der bereits getätigten Handelsgeschäfte für den Lieferzeitpunkt in 4h bezogen auf den aktuellen Zeitstempel
- Minimaler und maximaler Preis der bereits getätigten Handelsgeschäfte für den Lieferzeitpunkt in 4h bezogen auf den aktuellen Zeitstempel
- Die Gesamtenergie der bereits getätigten Handelsgeschäfte für den Lieferzeitpunkt in 4h bezogen auf den aktuellen Zeitstempel
- Der mittlere Strompreis der bereits getätigten Handelsgeschäfte für den Lieferzeitpunkt in 4h bezogen auf den aktuellen Zeitstempel
- Das 1. Quartil aller Strompreise der bereits getätigten Handelsgeschäfte für den Lieferzeitpunkt in 4h bezogen auf den aktuellen Zeitstempel
- Das 3. Quartil aller Strompreise der bereits getätigten Handelsgeschäfte für den Lieferzeitpunkt in 4h bezogen auf den aktuellen Zeitstempel
- Den Tag der Woche bezogen auf den aktuellen Zeitstempel
- Den Tag im Jahr bezogen auf den aktuellen Zeitstempel

Präparation der Zielgrößen für das Künstliche Neurale Netz

In Abbildung 10 wird dargestellt, wie die relevanten Datensätze für die Zielgrößen des überwachten Trainings aus den vorhandenen Handelsgeschäften erhoben werden. Ausgehend vom aktuellen Zeitstempel existieren in der Regel auch Handelsgeschäfte in der unmittelbaren Zukunft, die ihren Liefertermin in 4h haben. Das Künstliche Neuronale Netz soll dazu in der Lage sein, genau diese Handelsgeschäfte in Hinblick auf lukrative Preisangebote vorhersagen zu können.

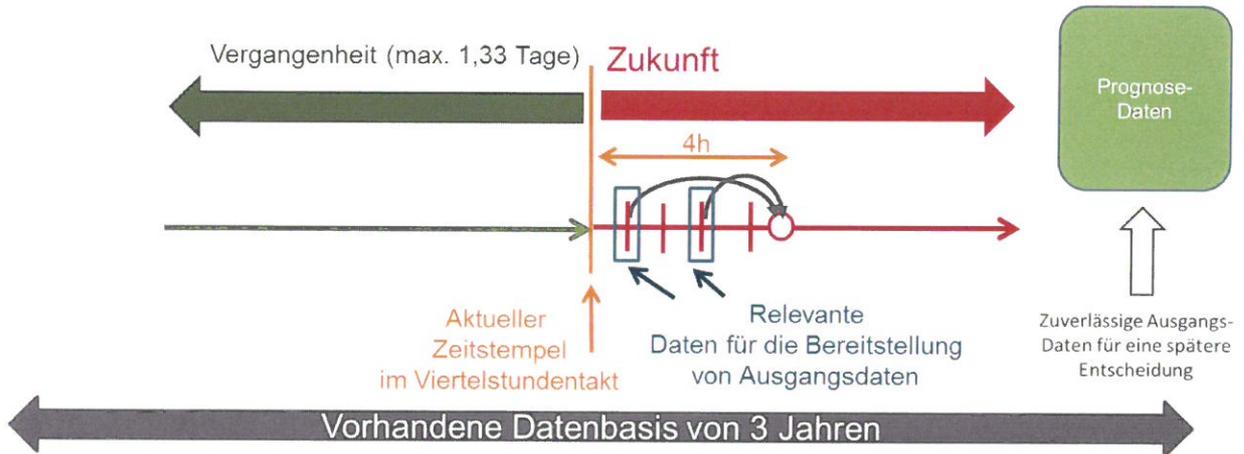


Abbildung 10 Vorbereitung der Ausgangsdaten für das Training des Künstlichen Neuronalen Netzes

Für die Prognose spielt der tatsächliche zukünftige Handelszeitpunkt keine entscheidende Rolle. Wichtig ist dagegen allein, dass in den zukünftigen 4h Stunden vorhergesagte Handelsgeschäfte mit der prognostizierten Preisentwicklung stattfinden.

Zur Präparation der Prädiktoren werden dazu alle Datensätze, welche in der Zukunft vom betrachteten aktuellen Zeitstempel innerhalb der zukünftigen 4h liegen, folgender Weise strukturiert:

- Mittlerer Preis aller in der unmittelbaren Zukunft liegenden Handelsgeschäfte, die ihren Lieferzeitpunkt in 4h haben.
- Oberes Quartil der Preise aller in der unmittelbaren Zukunft liegenden Handelsgeschäfte, die ihren Lieferzeitpunkt in 4h haben
- Unteres Quartil aller in der unmittelbaren Zukunft liegenden Handelsgeschäfte, die ihren Lieferzeitpunkt in 4h haben

Die Wahl der Prädiktoren (Zielgrößen) ermöglicht einer nachgelagerten Steuerungsfunktion „Trading-Manager“, optimale Annahmen für die beste Preisofferte in zukünftigen Handelsgeschäften zu treffen.

Training des Künstlichen Neuronalen Netzes (KNN)

Künstliche Neuronale Netze werden überall dort eingesetzt, wo eine klassische, auf physikalisch nachvollziehbaren Gleichungen basierende Modellierung schwer herzustellen ist oder scheitert. Die Idee des KNN beruht auf der Fähigkeit, eine ähnliche Struktur wie bei biologischen Lernprozessen zu wählen. „Neuronen“ spielen in KNN die wichtige Rolle der Speicherung von „Zwischenergebnissen“ während „Dendriten“ und „Synapsen“ für die Gewichtung und die Weiterleitung der Signale sorgen. „Axone“ fungieren dabei als Ausgangsfunktion, die in einem KNN als Aktivierungsfunktion repräsentiert werden.

Es existieren verschiedene Ausführungsformen von KNN, welche die Projektpartner in detaillierten Versuchen untersucht haben. Gegenwärtig kommen die Projektpartner zu der Einschätzung, dass sog. Feed Forward Netzwerke am viel versprechensten sind.

Zur Veranschaulichung stellt Abbildung 11 ein einfaches Feed Forward Netzwerk bestehend aus drei Eingangssignalen, vier Neuronen und zwei Prädiktoren dar. Ziel des Trainings ist es, auf Basis der vorhandenen Eingangs- und Prädiktionsdaten geeignete Gewichtungsfaktoren zu ermitteln, welche auf Basis des Trainings die beste Übereinstimmung erzielen. Für das Training werden 70 % der vorhandenen Datensätze verwendet. 15 % der Datensätze werden nach jedem Optimierungsschritt verwendet, um das vorhandene Modell gegenüber einer unbekanntem Menge von Datensätzen zu validieren. Die Optimierung der Gewichtungen gilt als abgeschlossen, sobald die Übereinstimmung der Trainingsdaten gegen über den Validierungsdaten erstmalig besser wird.

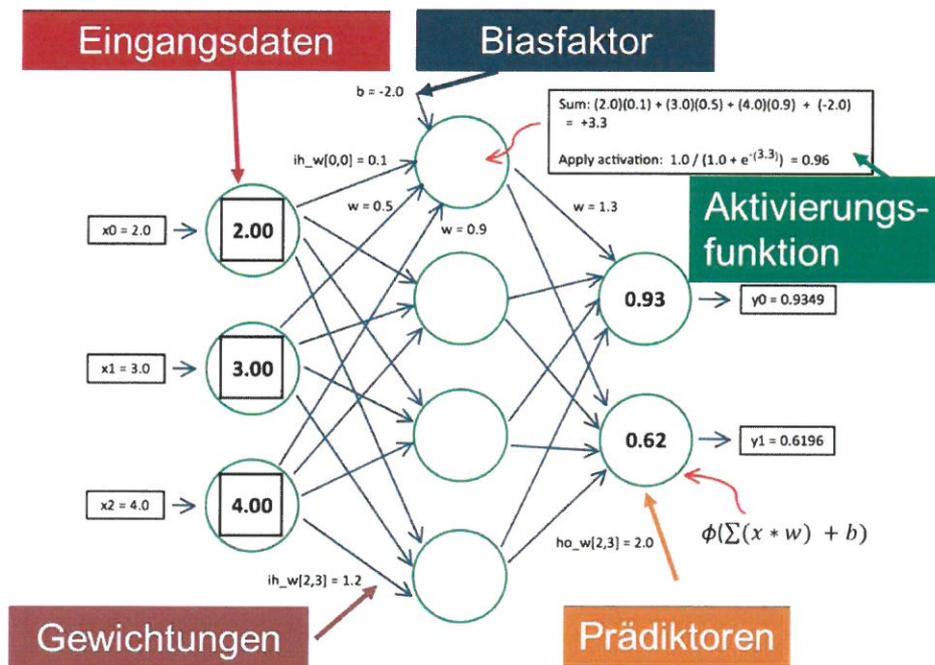


Abbildung 11 Beispiel eines Feed Forward Netzes mit drei Eingangssignalen vier Neuronen und zwei Prädiktoren

Der Abbruch ist dadurch zu begründen, dass das KNN bei weiteren Trainingsvorgängen die bekannten Datensätze „auswendig lernt“ und gegenüber unbekanntem Eingangsdaten keine signifikante Verbesserung zu erzielen ist. Die restlichen 15% der vorhandenen Datensätze wird zum Testen des KNN verwendet und zur endgültigen Gütebeurteilung herangezogen.

Aufgrund der Untersuchungen im Berichtszeitraum wurde für jeden Prädiktor ein eigenes KNN trainiert, dessen Modell im nachfolgenden Abschnitt präsentiert wird.

Erzielte Ergebnisse der Prognose

Drei separat ermittelte KNN sollen im Energiemanagement eingesetzt werden, um den mittleren Preis, das obere und untere Quartil der Preise in vier Stunden prognostizieren zu können. Die Prognose des oberen Quartils soll als aussagekräftige statistische Größe herangezogen werden, um elektrische Energie zu einem möglichst hohen Preis verkaufen zu können. Die Prognose des unteren Quartils dient zur Einschätzung der Kaufoption zu möglichst günstigen Preisen. Statistisch liegen jeweils 25% aller in 4h zu erzielenden Preise über dem oberen bzw. unter dem unteren Quartil. Die Wahrscheinlichkeit bei korrekten Prognosen noch bessere Ergebnisse zu erzielen ist damit sehr hoch. Im Ausblick wird aufgezeigt, wie die Prognosewerte in der Funktion „Trading-Manager“ genutzt wird, um optimale Zeitpunkte für Handelsgeschäfte festzulegen. Zum Projektende steht damit ein Energiemanagementsystem zur Verfügung, das eine vollkommen automatische Steuerung der Eigenverbrauchssituation, der Bereitstellung von Primärregelleistung und der Intraday-Handelsgeschäfte vollziehen kann.

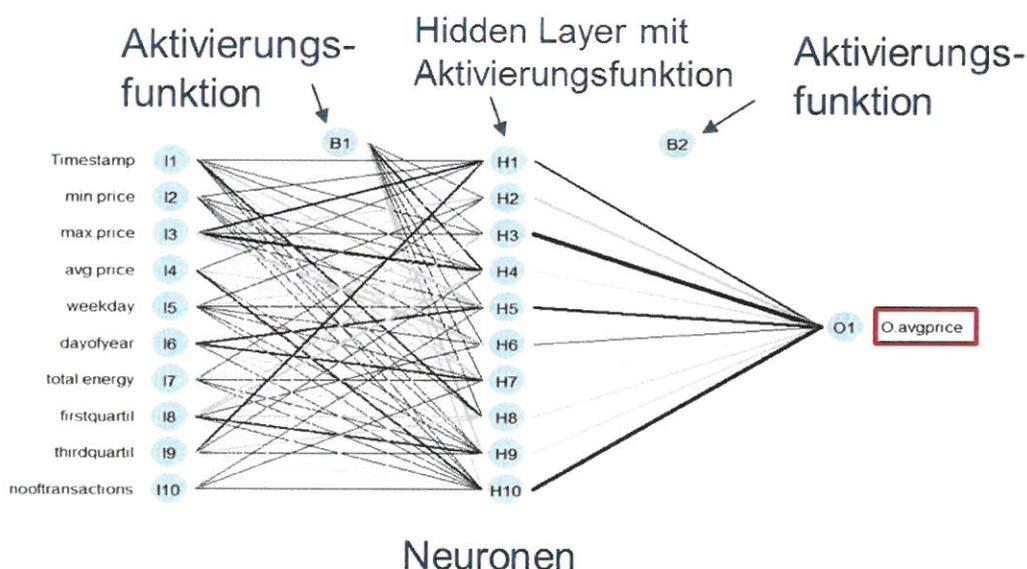


Abbildung 12 Gewählte Struktur des KNN für die Prognose des Durchschnittspreises

Das entwickelte KNN-Modell in Abbildung 12 verfügt über einen „Hidden Layer“ mit insgesamt zehn Neuronen. Für das Training wurden ca. 80.000 Datensätze aus insgesamt drei Jahren an Handelsdaten aggregiert.

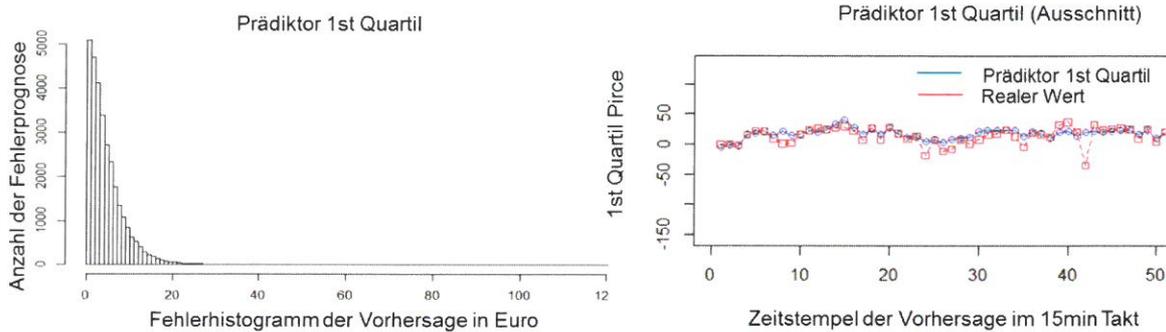


Abbildung 13 Ergebnisse Prädiktion des unteren Quartils mit Testdaten

In Abbildung 13 ist ein Fehlerhistogramm der Abweichung zwischen der Prognose und den realen Werten dargestellt. 75% Prozent aller Prognosewerte liegen innerhalb von 6,23 € pro MWh, 50% aller Prognosewerte haben eine Abweichung unterhalb von 3,20 € pro MWh. Eine ähnliche Trefferquote ergibt sich auch für die anderen Prädiktoren oberes und unteres Quartil. Typischerweise werden im Mittel zwischen 40 und 60 € pro MWh erzielt. Die Prognosegüte kann damit als ausreichend gut bewertet werden.

Nutzung der Preisprognose für Intraday Handelsgeschäfte mit dem „Trading-Manager“

Durch den Trading-Manager stellt eine Funktion im Energiemanagement dar, welche automatisiert die optimalen Handelsgeschäftszeitpunkte wählt. Die Entscheidung dieser Zeitpunkte soll auf Basis der prognostizierten oberen und unteren Quartilspreise getroffen werden. Dabei wird in jedem 15 min-Takt ein neuer Prognosewert berechnet, der in 4h für eine Kilowattstunde gezahlt wird. Nach 16 Takten stehen damit 16 Prognosewerte zur der unmittelbaren Zukunft zur Verfügung, welcher mit jedem weiteren Takt um mit einem weiteren 4h-Prognosewert aktualisiert wird, während der älteste gelöscht wird, der dann in der Vergangenheit liegt.

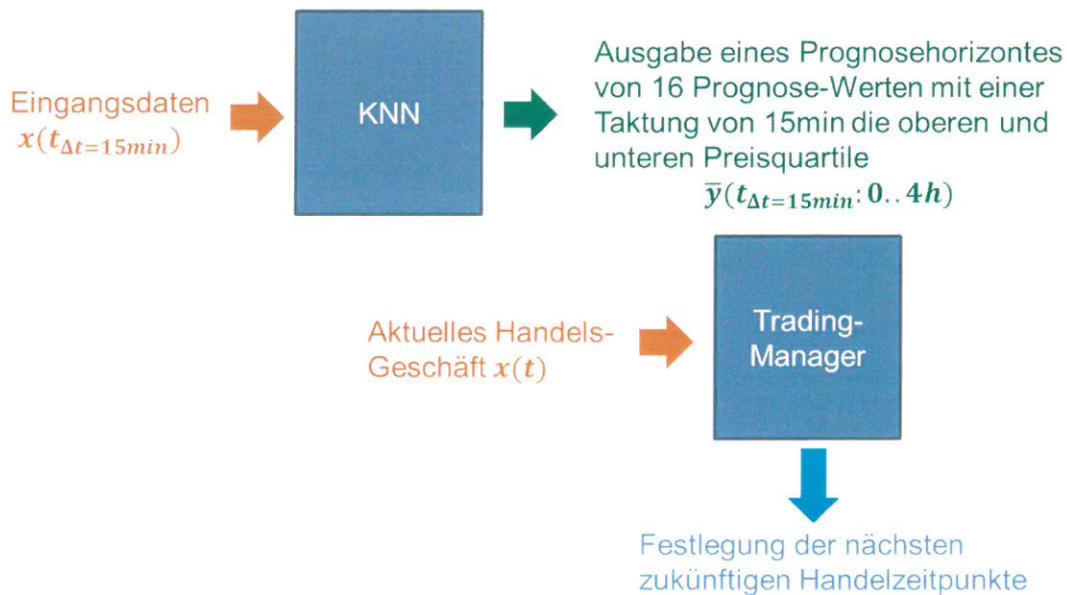


Abbildung 14 Zusammenspiel zwischen dem KNN und dem Trading-Manager

Im Trading-Manager werden die eingehenden 16 Prognosewerte für das obere und untere Quartil für ein Ertragsoptimum auf Basis der besten Handelszeitpunkte ausgewählt. Parallel wird im Trading-Manager jedes aktuelle Handelsgeschäft $x(t)$ begutachtet und mit den prognostizierten Preisen abgeglichen. Im Falle der Koinzidenz (entweder das aktuelle eingelesene Handelsgeschäft überschreitet das obere prognostizierte Quartil oder es unterschreitet das untere Quartil) werden innerhalb des Prognosehorizonts von 4h Handelsgeschäfte gemäß den optimalen Handelszeitpunkten in Form eines „Stellvertreters“ abgeschlossen.

Zur Veranschaulichung wird in Abbildung 15 die Behandlung der Daten im Trading-Manager dargestellt.

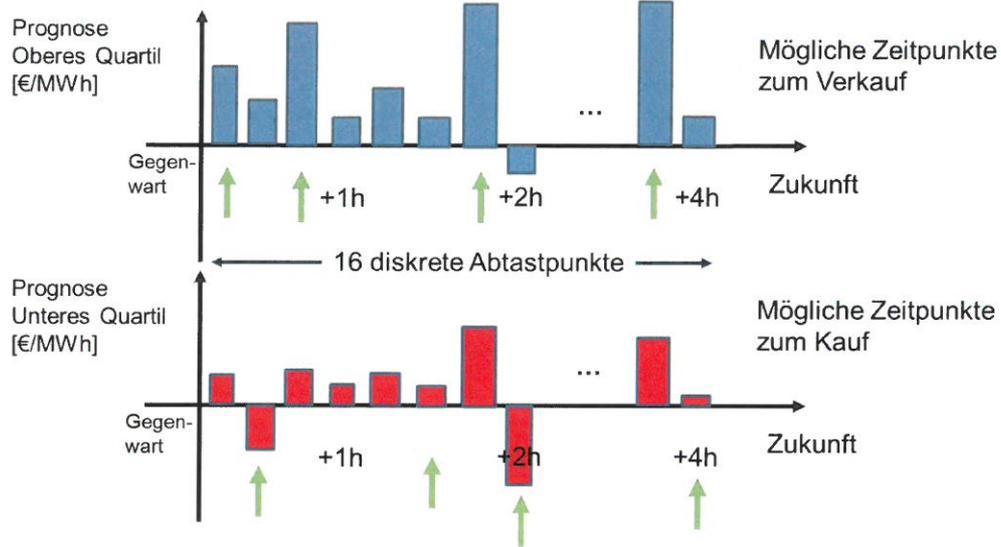


Abbildung 15 Wahl der geeigneten Handelszeitpunkte auf Basis von 16 oberen und unteren Quartilen der Prognose

Die in grün dargestellten Pfeile symbolisieren die Zeitpunkte, zu denen der Trading-Manager ein Kauf- bzw. Verkaufsgeschäft mit besten prognostiziertem Ertrag vorschlägt. Da der Energiemanagementemulator über keinen aktiven Zugang zum EPEX-Spotmarkt verfügt, kann der Emulator auch keine Preisangebote platzieren. Stattdessen wartet der Trading-Manager auf ein „Stellvertreter-Handelsgeschäft“, welches der erwarteten Marktsituation entspricht und als eigenes Handelsgeschäft verbucht wird.

Erreichte Meilensteine

Es wurde ein Energiemanagementsystem auf Basis eines stationären Batteriespeichers funktionstüchtig aufgebaut. Alle wesentlichen Daten werden automatisiert durch Kleinstcomputer mit Netzwerkzugang zyklisch beschafft und an den RTPC weitergesendet. Im RTPC werden die Daten für die elektrische Energieerzeugung und den Verbrauch sowie die aktuelle Netzfrequenz zusammengeführt und weiterverarbeitet.

Der RTPC wird mit der Echtzeitentwicklungsumgebung Labcar der Firma ETAS programmiert. Die Labcar Integrationsplattform erlaubt, Software mit Hilfe von Matlab/Simulink zu ausführbaren Code zu erstellen und im RTPC auszuführen.

Das Labcar Experimental Environment läuft auf einem handelsüblichen PC und kommuniziert mit dem RTPC via Netzverbindung. Dies ermöglicht, alle im RTPC berechneten Daten (Signale) grafisch über ein Human-Machine-Interface (HMI) darzustellen.

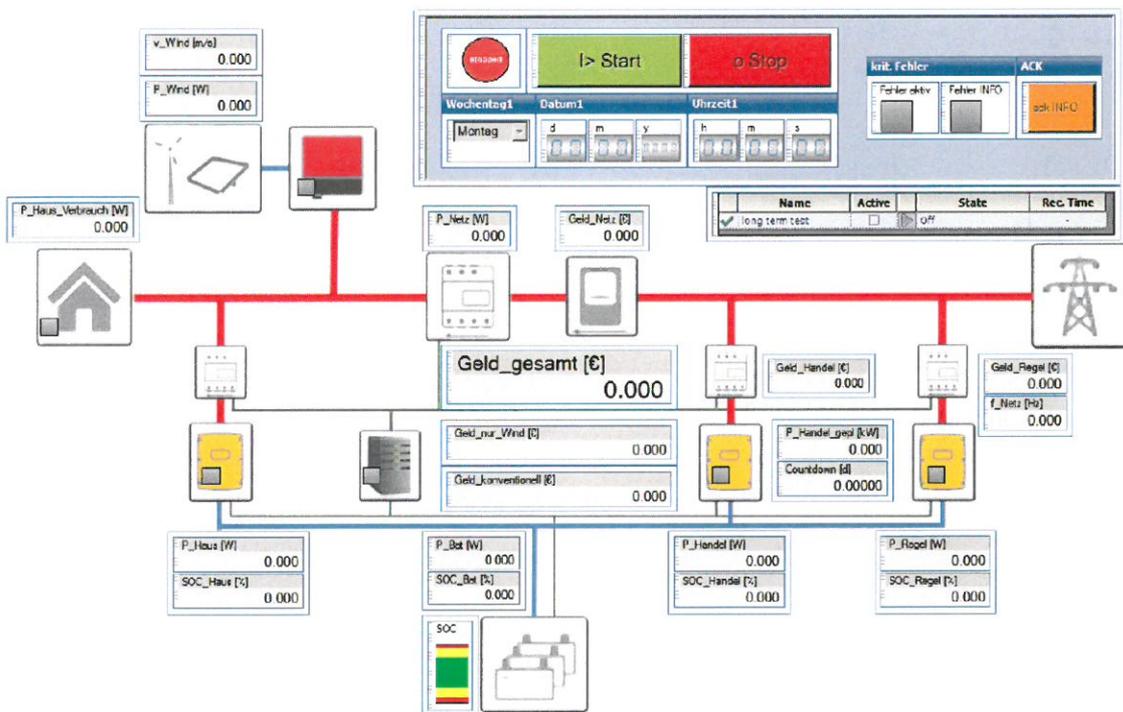


Abbildung 16 Implementiertes HMI zur Darstellung aller relevanten Daten des Energiemanagementsystems

Das HMI in Abbildung 16 soll dazu dienen, alle relevanten Daten wie die aktuell erzeugte elektrische Leistung, die verbrauchte Leistung, die angeforderte Primärregelleistung sowie die aktuell gehandelte Leistung darzustellen. Hinzu kommen weitere wichtige Batterieinformationen aus dem eingebauten

Batteriemanagementsystem. Der Emulator soll des Weiteren den Ertrag der verschiedenen Geschäftsfelder übersichtlich darstellen. Dem gegenübergestellt werden die Kosten der Stromversorgung für das untersuchte Gebäude ohne ein stationäres Energiespeichersystem mit dem im Projekt beschriebenen Funktionsumfang.

Im unteren Teil von Abbildung 16 werden die Leistungen der einzelnen fiktiven Batterieteile (P_{Haus} , P_{Handel} und P_{Regel}) sowie der dazugehörige SOC angezeigt. Außerdem werden die Gesamtbatterieleistung P_{Bat} und der Gesamt-SOC der Batterie angezeigt.

Im mittleren Teil sind symbolisch die drei Frequenzumrichter, mit denen die Batterie an das tatsächliche Stromnetz angebunden wird, und das Energiemanagement dargestellt. Auf jedem der Elemente befindet sich eine Leuchtfläche, die signalisiert, ob die Umrichter bzw. das Energiemanagement aktiviert oder ggf. durch auftretende Fehler deaktiviert sind. In der Mitte befinden sich die Geldzähler zur Beurteilung der Wirtschaftlichkeit des Systems. Sie erlauben den Vergleich zwischen dem insgesamt durch die Anlage umgesetztem Geldbetrag mit einer Anlage ohne Batterie (nur mit Kleinwindkraftanlage) und einem konventionellen Haushalt. Außerdem wird bei den Umrichtern für Handel und Regelleistung angezeigt, wie viel Geld umgesetzt wurde. Ein negativer Wert zeigt den Verlust und ein positiver Wert den Gewinn an.

Im oberen linken Teil von Abbildung 16 wird symbolisch ein Haus für den Hausverbrauch zusammen mit der Messgröße $P_{Haus_Verbrauch}$ dargestellt. Für die Kleinwindkraftanlage wird sowohl die Leistung P_{Wind} sowie die Windgeschwindigkeit v_{Wind} dargestellt. Durch eine Leuchtfläche am Haus sowie am dargestellten Umrichter für die Windkraftanlage wird signalisiert, ob diese aktiviert sind oder ggf. durch auftretende Fehler deaktiviert sind. Etwas weiter rechts befindet sich die Anzeige für den aktuellen Netzverbrauch P_{Netz} sowie die dadurch umgesetzte Geldmenge. Die Anzeige der Geldmenge entspricht dabei dem durch einen Stromzähler angezeigten Geldbetrag.

Im oberen rechten Teil von Abbildung 16 befindet sich die Steuerung des Modells, mit der die Berechnung des Energiespeichermodells gestartet und gestoppt werden kann. Außerdem sind Anzeigeelemente für den Modellbetrieb, das aktuelle Berechnungsdatum und die generelle Anzeige eines Fehlers vorgesehen.

Ergebnisse

Die durch die abschließende Inbetriebnahme durch den Datenlogger aufgezeichneten Daten werden mithilfe von MATLAB/Simulink grafisch dargestellt und ausgewertet. Die grafischen Darstellungen in Form von Diagrammen werden in Abbildung 17 bis Abbildung 19 dargestellt. Die einzelnen Signale werden dabei je nach Komponente des Energiespeichers in einer Abbildung gruppiert. Die Gruppierung folgt der Zusammensetzung des Gesamtsystems.

Abbildung 17 zeigt die grafische Darstellung der Signale, die mit dem fiktiven Batterieteil für die Hausverbrauchsoptimierung zusammenhängen.

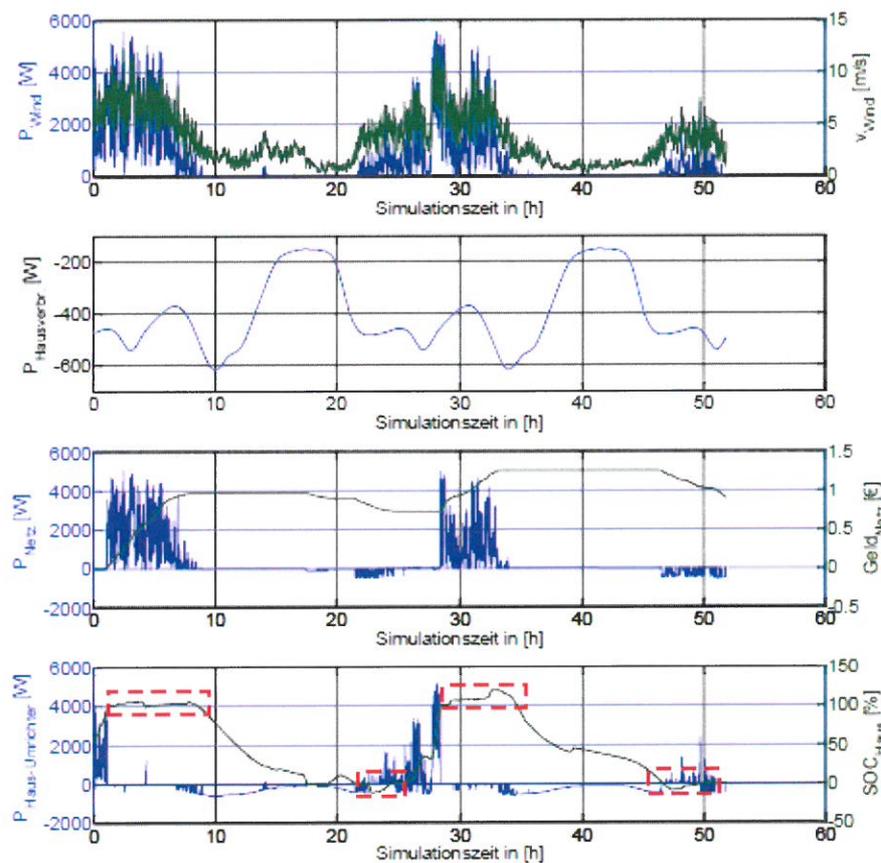


Abbildung 17 Grafische Darstellung der aufgezeichneten Signale anhand einer 60 stündigen Simulation

Die oberen drei in Abbildung 17 gezeigten Signalverläufe stellen sich wie erwartet dar. Der Verlauf für die Leistung der Windkraftanlage (P_{Wind}) zeigt deutlich, dass bei zu geringen Windgeschwindigkeiten kein Strom durch die Anlage produziert wird, was dem Kennlinienverhalten der Windkraftanlage zuzuschreiben ist. Der Verlauf für den Hausverbrauch ($P_{Hausverbr.}$) zeigt das sich wiederholende Standardlastprofil H0. Bei dem Signalverlauf für die am Stromnetz beaufschlagte Leistung

(P_{Netz}) ist zu erkennen, dass überschüssiger Windstrom ins Netz eingespeist wird, und phasenweise Strom aus dem Netz entnommen wird, wenn dieser nicht durch die Windkraftanlage oder die Batterie bereitgestellt werden kann. Dementsprechend steigt und fällt der Betrag des dazugehörigen Geldzählers ($Geld_{Netz}$).

Die untere Darstellung zeigt die Leistung des Umrichters für die Hausverbrauchsoptimierung ($P_{Umrichter-Haus}$) und den dazugehörigen SoC des fiktiven Batterieteils (SOC_{Haus}). Auffällig ist, dass der SoC zeitweise deutlich über 100 % und unter 0 % fällt. Dieses Verhalten ist zwar plausibel, da alle Berechnungsfehler der SoC-Bestimmung in diesem Batterieteil aufgefangen werden (unabhängig vom Füllstand), doch erscheint die Überschreitung der Grenzwerte höher als erwartet. Die genauere Analyse dieses Verhaltens wird im weiteren Verlauf dieses Kapitels anhand der Betrachtung von Abbildung 40 durchgeführt, da an dieser Stelle alle SoCs miteinander verglichen werden.

Abbildung 18 zeigt die grafische Darstellung der Signale, die mit dem fiktiven Batterieteil für die Bereitstellung von Primärregelleistung zusammenhängen

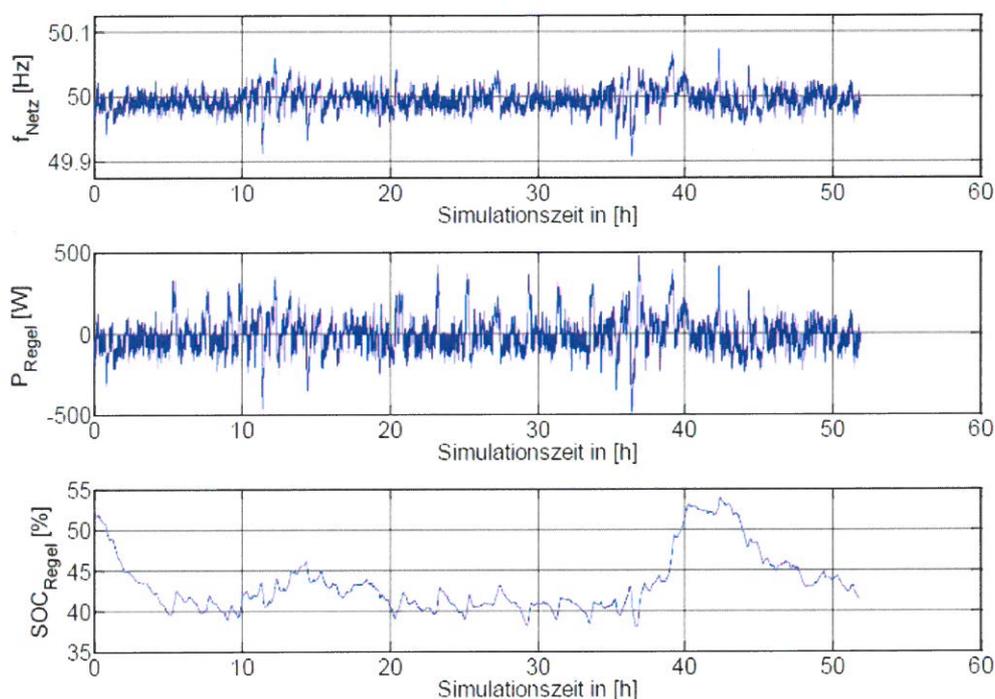


Abbildung 18 Grafische Darstellung bei einem Testfall mit einem fiktiven Batterieteil für die Bereitstellung von Primärregelleistung

Die oberen beiden Diagramme in Abbildung 18 zeigen das Verhalten der Netzfrequenz (f_{Netz}) und der entsprechend bereitgestellten Regelleistung (P_{Regel}). Beide Verläufe verhalten sich wie erwartet qualitativ gleich, da die Regelleistung proportional zur Netzfrequenzabweichung bereitgestellt wird.

Abbildung 19 zeigt die grafische Darstellung der Batteriefüllstände der gesamten Batterie sowie der fiktiven Batterieteile.

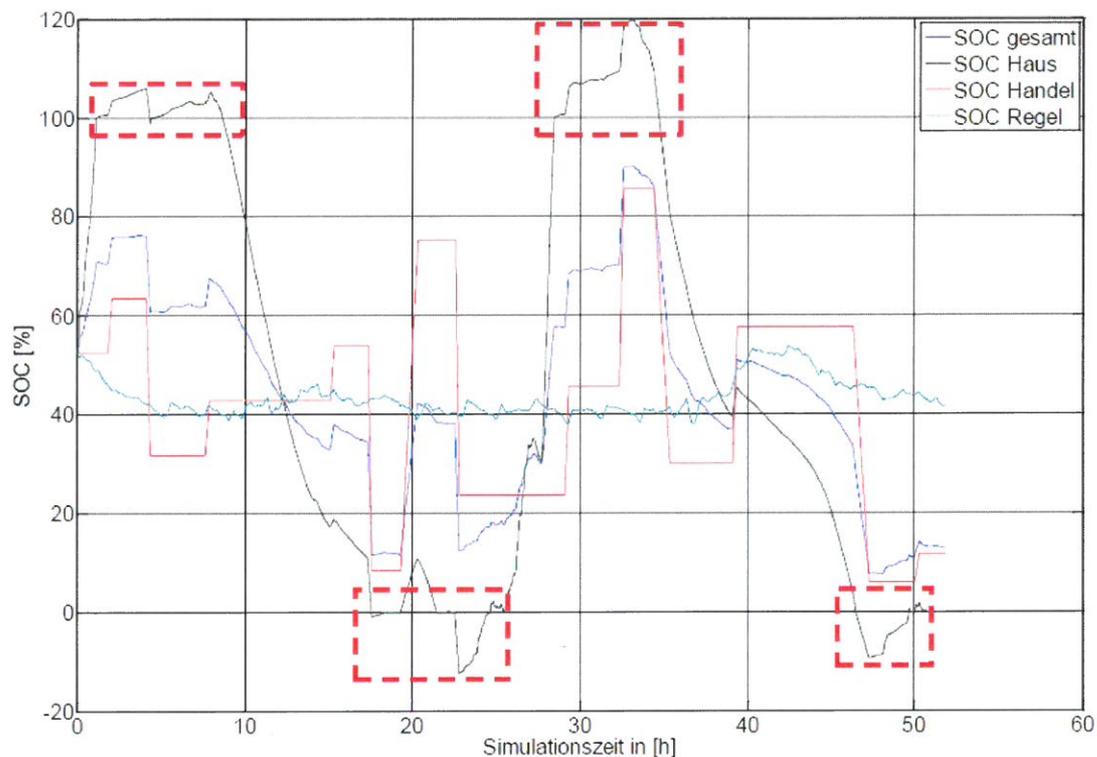


Abbildung 19 Grafische Darsteller der bei der Inbetriebnahme aufgezeichneten Signale für die Batterieladezustände der gesamten Batterie sowie der fiktiven Batterieteile bezogen auf den Hausverbrauch, die Handelsgeschäfte und die Primärregelleistung

Das Diagramm in Abbildung 19 zeigt deutlich die Überschreitung der 0 %- und 100 %-Marke des SoCs für den fiktiven Batterieteil zur Hausverbrauchsoptimierung (s. Markierungen für SoC_{Haus} in Abbildung 19). Auffällig ist, dass diese Grenzwertüberschreitung teils sprunghaft entsteht und immer im Zusammenhang mit einer größeren Änderung des Füllstands des Batterieteils für den Stromhandel (SoC_{Handel}) steht.

Dieses Verhalten ist nur auf den Ausgleich von Berechnungsfehlern im fiktiven Batterieteil für die Hausverbrauchsoptimierung zurückzuführen. Für diesen Ausgleich wird der durch das Batterie-Management-System (BMS) festgestellte SoC als Normalwert angenommen und mit der Addition der Füllstände der fiktiven Batterieteile verglichen. Wird nun eine Abweichung festgestellt, wird der vom BMS gemeldete SoC als wahrer SoC angenommen und SoC_{Haus} entsprechend um die Abweichung angepasst. Dementsprechend ist das in Abbildung 19 gezeigte Verhalten nur auf eine fehlerhafte SOC-Bestimmung des BMS zurückzuführen.

Der durch das BMS eingesetzte Stromsensor hat eine Messgenauigkeit von ± 750 mA und ist ausschlaggebend für die SoC-Bestimmung der Batterie. Die Fehlbestimmung des SoCs durch das BMS wird auf diese Messungenauigkeit zurückgeführt, da während des Betriebs des Prüfstands teils Abweichungen in der Strommessung von 400 mA bis 600 mA festgestellt werden. Durch Integration dieser Abweichungen ist es leicht möglich, auf Über- bzw. Unterschreitungen der 0 %- und 100 %-Grenzen des SOC_{Haus} von 20 % oder mehr zu kommen.

Da der Stromsensor durch das BMS vorgegeben ist, kann dieser bis zum Ende der vorliegenden Arbeit nicht durch einen hinreichend genauen Stromsensor ersetzt werden. Es obliegt also zukünftigen Arbeiten an der hier implementierten Prüfumgebung, die Strommessung zu optimieren.

Die sonstigen Ergebnisse der abschließenden Inbetriebnahme des Gesamtaufbaus entsprechen den Erwartungen und alle integrierten Teile des Energiemanagements (insbesondere Steuerung für Stromhandel und Primärregelleistung) arbeiten zuverlässig. Somit besitzt die implementierte Software-in-the-Loop-Prüfumgebung für Energiemanagementsysteme für stationäre Energiespeicher eine hinreichende Eignung, die Entwicklung dieser Systeme zukünftig zu unterstützen.

Fazit

Das entwickelte Energiemanagementsystem ermöglicht es, ein Batteriesystem als Speichieranwendung von elektrischer Energie für drei Geschäftsfelder mit dem Ziel einer wissenschaftlichen Begleitforschung betreiben:

Dabei wurden die Lastflüsse einer fiktiven Windkraftanlage und des Hausverbrauchs genauso berücksichtigt wie die (skalierte) Teilnahme an der wöchentlich stattfindenden Ausschreibung des Preises für Primärregelleistung.

Es wurde aufgezeigt, wie im Energiemanagementsystem geeignete Zeitpunkte am Intradayhandel automatisch im Sinne einer optimalen Strategie für Handelsgeschäfte feststellen kann.

Auch wenn die aktuellen Profite durch vor allem die Intradayhandelsgeschäfte noch nicht die Investitionen von kleinen Batteriesystem im kWh rechtfertigt, so lassen sich mit den erzielten Projektergebnissen bereits wichtige zukünftige Anforderungen an Batteriesysteme ableiten:

- Hohe Zyklenfestigkeit mit einer hohen kalendarischen Lebensdauer von über 10 Jahren im Dauereinsatz
- Eine sehr genaue Erfassung der zellindividuellen Ladezustände (SoC) und der zellindividuellen Gesundheitszustände (engl. State of Health, SoH)
- Ein Preisziel von deutlich unter 100€/kWh

Das Projekt hat im Weiteren deutlich aufgezeigt, dass moderne Energieversorgungssysteme eine stärkere Einbindung von IT basierten Lösungsstrategien erfordern. Neben dem Einsatz von maschinellen Lernverfahren werden in der Energiewirtschaft im zunehmenden Maße echtzeitfähige Lösungen benötigt, die auch in vergleichsweise kleinen Batteriesystemen (z. B auch in Elektrofahrzeugen) sichere Kommunikationskanäle zu den datenbasierten Systemen ermöglichen.

Literaturverzeichnis

- [1] Regelleistung, „Regelleistung,“ 2018. [Online]. Available: <https://www.regelleistung.net/ext/tender/>.
- [2] EPEX SPOT, Europäische Handelsplattform für elektrischen Strom, „<https://www.epexspot.com/de/>,“ 2018. [Online].
- [3] L.-E. Burmester und T. Jäger, „Realisierung eines Stromnetz Frequenzmessgeräts mit Hilfe einer Schmitt-Trigger Schaltung und einem Arduino Nano,“ FH Kiel, 2017.
- [4] M. Beckmann, „Nutzung des Raspberry Pi als multifunktionales Datenerfassungssystem für Inhalte von Internetseiten und ftp-Servern sowie von Messdaten mit einer CAN-Bus-Anbindung für die weitere Verarbeitung auf einem Echtzeit-PC,“ FH Kiel, 2017.
- [5] T. Bothe und J. Kabelitz, „Planung und Realisierung einer „Software in the Loop“-Prüfungsbung für den realitätsnahen Echtzeittest intelligenter Energiemanagementsysteme für stationäre Energiespeicher an realen Batteriesystemen,“ FH Kiel, 2018.
- [6] A. Matthiesen, „Entwicklung eines Energiemanagements auf Basis eines künstlichen neuronalen Netzes für einen Batteriespeicher,“ FH Kiel, 2017.
- [7] R. R. Janga, „Stock Market Prediction,“ FH Kiel, 2018.
- [8] Easy Wind, „Tabellarische Leistungskennlinie der Kleinwindkraftanlage Easywind 6 AC,“ 2016.
- [9] H. Rathmann, C. Weber, W. Benecke und D. Kähler, „Novel methode of state-of-charge estimation using in-situ impedance measurement: Single cells in-situ impedance measure-ment based state-of-charge estimation for LiFePO4 – Li2TO3 Battery Cells with a real BMS,“ *Industrial Electronics Society, IECON 2014 - 40th Annual Conference of the IEEE*, 2014.

Energiemanagement für stationäre Energiespeichersysteme unter Berücksichtigung der aktuellen Netzschwankungen, der Eigenverbrauchssituation und des Energiemarktes

Im Rahmen des Projektes wurde ein Energiemanagement für stationäre Energiespeichersysteme unter Berücksichtigung der aktuellen Netzschwankungen, der Eigenverbrauchssituation und des Energiemarktes entwickelt. Dazu wurde eine u.a. eine Batteriespeicheremulation aufgebaut.

Im Gegensatz zum Stand der Technik verfolgten die Projektpartner hierbei einen neuen Ansatz, Batteriesysteme nicht nur zur Speicherung von regenerativ erzeugter Energie zu verwenden, sondern auch als Speicher für Primärregelleistung und für sog. Intraday-Handelsgeschäfte am EPEX-Spot Market. Hierfür wurde für das Energiemanagement ein innovatives maschinelles Lernverfahren angewendet, das zuverlässige Prognosen des Strompreises für einen Zeithorizont von 4 Stunden erlaubt. Das eingesetzte Künstliches Neuronales Netz nutzt dazu relevante bekannte Eingangsgrößen und steuert damit den Lastfluss der Batterie, um für den Endanwender maximale ökonomische Ertragschancen zu eröffnen. Die Verfahren wurden mit einem Energiespeichersystem auf Basis von Lithium-Ionen Zellen als Teil eines „Hardware in the Loop“-Teststandes getestet, das anhand der im Energiemanagement erzielten Entscheidungen das Speichersystem real lädt bzw. entlädt.